

**Universidade da Integração Internacional da Lusofonia Afro-Brasileira – Unilab  
Mestrado Acadêmico em Sociobiodiversidade e Tecnologias Sustentáveis – Masts**

**ÁLISSON GOMES LINHARES**

**CLASSIFICAÇÃO DE TIPOS E SEVERIDADES DE ENFISEMAS EM IMAGENS DE  
TOMOGRAFIA COMPUTADORIZADA DE ALTA RESOLUÇÃO DOS PULMÕES**

**Redenção**

**2017**

ÁLISSON GOMES LINHARES

CLASSIFICAÇÃO DE TIPOS E SEVERIDADES DE ENFISEMAS EM IMAGENS DE  
TOMOGRAFIA COMPUTADORIZADA DE ALTA RESOLUÇÃO DOS PULMÕES

Dissertação apresentada ao Mestrado Acadêmico em Sociobiodiversidade e Tecnologias Sustentáveis (Masts) da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (Unilab), como parte dos requisitos para obtenção do título de mestre.

Área de concentração: Tecnologia e Desenvolvimento Sustentável

Orientador: Prof. Dr. John Hebert da Silva Felix

REDENÇÃO

2017

Universidade da Integração Internacional da Lusofonia Afro-Brasileira  
Sistema de Bibliotecas da UNILAB  
Catalogação de Publicação na Fonte.

---

Linhares, Alisson Gomes.

L717c

Classificação de tipos e severidades de enfisemas em imagens de tomografia computadorizada de alta resolução dos pulmões / Alisson Gomes Linhares. - Redenção, 2018.

61f: il.

Dissertação - Curso de Sociobiodiversidade e Tecnologias Sustentáveis, Mest. Sociobiodiversidade e Tec. Sustent, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2018.

Orientador: Prof. Dr. John Hebert da Silva Felix.

1. Tomografia. 2. Multilayer Perceptron (MLP). 3. Doença Pulmonar Obstrutiva Crônica (DPOC). 4. Tomografia Computadorizada de Alta Resolução (TCAR). 5. Local Binary Pattern (LBP). 6. Optimum-Path Forest (OPF). I. Título

CE/UF/BSCL

CDD 616.0757

---

ÁLISSON GOMES LINHARES

CLASSIFICAÇÃO DE TIPOS E SEVERIDADES DE ENFISEMAS EM IMAGENS DE  
TOMOGRAFIA COMPUTADORIZADA DE ALTA RESOLUÇÃO DOS PULMÕES

Dissertação apresentada ao Mestrado Acadêmico em Sociobiodiversidade e Tecnologias Sustentáveis (Masts) da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (Unilab), como parte dos requisitos para obtenção do título de mestre.

Área de concentração: Tecnologia e Desenvolvimento Sustentável.

Aprovada em: \_\_\_/\_\_\_/\_\_\_\_\_.

BANCA EXAMINADORA

---

Prof. Dr. John Hebert da Silva Felix (Orientador)

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

---

Prof. Dr. Paulo César Cortez

Universidade Federal do Ceará (UFC/DETI)

---

Prof. Dr. Auzuir Ripardo de Alexandria

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

---

Prof. Dr. João Paulo do Vale Madeiro

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

---

Prof. Dr. Cícero Saraiva Sobrinho

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

A Deus.

À Liara e à Mayara, minha filha e esposa,  
à minha mãe, ao meu pai e ao meu irmão,  
Rosanira, Edmundo e Bruno.

## AGRADECIMENTOS

À FUNCAP, Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico, pelo apoio financeiro com a manutenção da bolsa de auxílio.

Ao Prof. Dr. John Hebert da Silva Felix, pela excelente orientação e amizade.

Aos professores participantes da Banca examinadora, Prof. Dr. Paulo César Cortez, Prof. Dr. Auzuir Ripardo de Alexandria, Prof. Dr. João Paulo do Vale Madeiro e Prof. Dr. Cícero Saraiva Sobrinho, pelo tempo e pelas valiosas colaborações e sugestões.

Aos Professores do Masts, por sua qualidade excepcional no ensino.

Aos servidores do Masts, por sua presteza e atenção.

À bolsista Fausta, por sua ajuda na análise dos testes.

Aos bolsistas Erick e Darleison, por sua ajuda durante a codificação.

Aos colegas de mestrado, pelas reflexões, críticas, sugestões, compartilhadas com essa turma de conhecimentos tão diversificados, que vão da Engenharia Civil à História, da Farmácia às Letras, da Agricologia à Matemática, do Serviço Social à Química, da Administração à Telemática.

“Não sabendo que era impossível, foi lá e fez.” – Jean Cocteau

## RESUMO

Para auxiliar o diagnóstico de tipos de enfisema pulmonar, a principal componente da Doença Pulmonar Obstrutiva Crônica (DPOC), que é a quarta causa de morte no mundo, tem sido aplicadas diversas técnicas de Processamento Digital de Imagens (PDI). Nesta dissertação, foram desenvolvidos métodos de classificação automática de quatro tipos de enfisema e seis níveis de severidade, combinando as técnicas de extração de atributos por análise de textura ou *Local Binary Pattern (LBP)* com os classificadores *Optimum-Path Forest (OPF)* ou *Multilayer Perceptron (MLP)*. As imagens utilizadas foram de três bancos de imagens de pulmões e de um banco de regiões de interesse (ROI). A extração de características por *Local Binary Pattern* gerou dados melhor discriminantes para classificação do que a análise de textura. Por esse motivo, foi realizada a combinação entre os métodos para realizar os testes. O método LBP-MLP obteve 100% de acerto na classificação de tipos e níveis de severidade de enfisemas, para todos os quatro bancos de imagens, inclusive um banco global de imagens, resultados superiores quando comparado ao LBP-OPF e, até mesmo, ao estado da arte. O LBP-MLP demonstra-se um método automático, eficaz, eficiente e robusto que pode reduzir a variabilidade e o tempo de diagnóstico de enfisemas, não só auxiliando radiologistas na interpretação das imagens médicas, como também promovendo, em regiões onde vivem dois terços da população mundial que tem acesso limitado a radiologistas, o mesmo nível de diagnóstico especializado aos médicos que não possuem alto grau de conhecimento anatômico dessa doença, cuja atenção imediata é requerida pela natureza perigosa e generalizada.

**Palavras-chave:** tipos e severidades de enfisemas, DPOC, TCAR, extração de atributos, análise de textura, *Local Binary Pattern (LBP)*, classificação, *Optimum-Path Forest (OPF)*, *Multilayer Perceptron (MLP)*.

## ABSTRACT

In order to aid in the diagnosis of lung emphysema, which are a major component of Chronic Obstructive Pulmonary Disease (COPD), the fourth leading cause of death in the world, automatic methods of four emphysema subtypes classification and its five severity levels were developed from High Resolution Computed Tomography (HRCT) images of the lungs, through Digital Image Processing (PDI), which has facilitated progress in numerous medicine areas. Use texture analysis or the Local Binary Standard (LBP) as attribute extraction techniques from three lung imaging datasets and regions of interest (ROI) in a standard dataset global, as well as recognition of emphysema subtypes and its severity levels through Optimum-Path Forest (OPF) or Multilayer Perceptron (MLP) classifiers. An extraction of characteristics by Local Binary Pattern generated more discriminating data for classification *than texture analysis*. The LBP-MLP method obtained results higher than the LBP-OPF method and even compared with the state-of-art, with 100% *accuracy* in the classification of *emphysema subtypes* and also of the *emphysema* severity levels, for all four banks of images, including *the* global dataset, even when combined. LBP-MLP demonstrates an automatic, effective, efficient and robust method that can reduce the variability and diagnosis time of emphysema, not only assisting radiologists in the interpretation of medical images, as well as promoting the anatomical knowledge level of this disease in regions where two-thirds of the world population has limited access to radiologists, *because* attention is required by the *dangerous* and generalized nature.

**Keywords:** types and severities of emphysemas, COPD, HRCT, attribute extraction, texture analysis, Local Binary Pattern (LBP), classification, Optimum-Path Forest (OPF), Multilayer Perceptron (MLP).

## LISTA DE ILUSTRAÇÕES

Figura 1 – Tipos de enfisemas pulmonares.....	15
Figura 2 – Ilustração do <i>Local Binary Pattern</i> (LBP).....	21
Figura 3 – Exemplo de cálculo do LBP.....	22
Figura 4 – Várias microestruturas mensuradas por LBP.....	22
Figura 5 – Exemplo de arquitetura de rede neural artificial MLP.....	30
Figura 6 – Modelo de neurônio da rede MLP não linear.....	30
Figura 7 – Metodologias empregadas durante a pesquisa.....	32
Figura 8 – Exemplos de imagens dos <i>slices</i> de Sorensen <i>et al.</i> (2010).....	33
Figura 9 – Exemplos de imagens de pulmões de Fortaleza (2006).....	34
Figura 10 – Exemplo de imagem original de TCAR de pulmões de Winkeler (2006).....	35
Figura 11 – Exemplos dos <i>patches</i> de Sorensen <i>et al.</i> (2010).....	36
Figura 12 – Exemplo de segmentação dos pulmões e da aplicação de máscara colorida.....	37
Figura 13 – Exemplo de sub-segmentação dos pulmões.....	38
Figura 14 – Acerto na classificação de tipos de enfisema pelo LBP-MLP.....	44
Figura 15 – Acerto na classificação de tipos de enfisemas pelo LBP-MLP em regiões de interesse e imagens originais de TCAR.....	48
Figura 16 – Taxa de acerto na classificação da severidade de enfisema pelo LBP-MLP.....	50

## LISTA DE TABELAS

Tabela 1 – Estado da arte das técnicas de classificação de enfisemas.....	18
Tabela 2 – Medidas de textura de sub-imagens dos pulmões.....	39
Tabela 3 – Acerto máximo na classificação de tipos de enfisemas.....	42
Tabela 4 – Tempo de execução em segundos do método LBP-MLP até 100% de acerto.....	46
Tabela 5 – Acerto na classificação do nível de severidade de enfisemas.....	49
Tabela 6 – Matriz de confusão do método LBP-OPF para classificação dos tipos de enfisemas das imagens dos <i>slices</i> de Sorensen <i>et al.</i> (2010).....	59
Tabela 7 – Matriz de confusão do método LBP-OPF para classificação dos tipos de enfisemas das imagens de Fortaleza (2006) e Winkeler (2006).....	60
Tabela 8 – Matriz de confusão do método LBP-OPF para classificação dos tipos de enfisemas das imagens dos <i>slices</i> de Sorensen <i>et al.</i> (2010), Fortaleza (2006) e Winkeler (2006).....	60
Tabela 9 – Matriz de confusão do método LBP-OPF para classificação dos tipos de enfisemas das imagens dos <i>patches</i> de Sorensen <i>et al.</i> (2010).....	61
Tabela 10 – Matriz de confusão do método LBP-OPF para classificação dos níveis de severidade de enfisemas das imagens dos <i>slices</i> de Sorensen <i>et al.</i> (2010).....	61

## LISTA DE ABREVIATURAS E SIGLAS

CLE	Enfisema centrolobular ou centroacinar
DPOC	Doença Pulmonar Obstrutiva Crônica (COPD, em inglês)
IFT	<i>Image Foresting Transform</i>
LBP	<i>Local Binary Pattern</i>
LBP-MLP	Método que combina LBP e MLP
LBP-OPF	Método que combina LBP e OPF
MIL	Enfisema suave
MIN	Enfisema mínimo
MLP	<i>Multilayer Perceptron</i>
MOD	Enfisema moderado
NOE	Sem enfisema
NT	Pulmão com tecido normal
OPF	Optimum-Path Forest
PDI	Processamento Digital de Imagens
PLE	Enfisema panlobular
PSE	Enfisema parasseptal
ROI	Regiões de Interesse
SEV	Enfisema severo
TC	Tomografia Computadorizada
TCAR	Tomografia Computadorizada de Alta Resolução (HRCT, em inglês)
VSE	Enfisema muito severo

## SUMÁRIO

1 INTRODUÇÃO .....	12
1.1 Objetivos.....	15
1.2 Estado da arte .....	16
1.3 Organização da dissertação .....	19
2 REFERENCIAL TEÓRICO .....	20
2.1 <i>Local Binary Pattern</i> (LBP) .....	20
2.2 <i>Watershed</i> e Morfologia Matemática .....	23
2.3 Análise de textura .....	25
2.4 Floresta de Caminhos Ótimos (OPF).....	27
2.5 <i>Multilayer Perceptron</i> (MLP) .....	29
3 METODOLOGIA.....	32
3.1 Bancos de imagens .....	32
3.1.1 Slices de Sorensen et al. (2010) .....	33
3.1.2 Fortaleza (2006).....	34
3.1.3 Winkeler (2006).....	35
3.1.4 Patches de Sorensen et al. (2010).....	36
3.2 Métodos de extração de atributos.....	36
3.3 Métodos de classificação dos tipos e severidades de enfisemas .....	39
4 RESULTADOS E DISCUSSÕES .....	41
4.1 Classificação de tipos de enfisemas por banco de imagens .....	41
4.2 Classificação da severidade de enfisemas em imagens de TCAR.....	48
5 CONCLUSÕES E TRABALHOS FUTUROS.....	51
REFERÊNCIAS.....	53
APÊNDICE .....	59

## 1 INTRODUÇÃO

Imagens médicas são utilizadas principalmente no diagnóstico de doenças pulmonares, cardíacas, ósseas, arteriais, cerebrais, dentre outras. A Tomografia Computadorizada de Alta Resolução (TCAR) é uma técnica de aquisição de imagens médicas que detecta, em especial, os tecidos pulmonares, inclusive os doentes em estágio inicial (FELIX, 2007).

A TCAR permite a obtenção de dados detalhados da destruição pulmonar global, principalmente, mostrando a presença, distribuição e extensão de doenças como os enfisemas pulmonares, que ocasionam fadiga respiratória e necessidade de suporte ventilatório. Enfisemas pulmonares são também o principal componente da Doença Pulmonar Obstrutiva Crônica (DPOC), uma das principais doenças pulmonares e a 4ª causa de morte no mundo (FORTALEZA, 2006).

Em 2012, mais de 3 milhões de pessoas morreram de DPOC, representando 6% de todas as mortes no mundo no referido ano. Mais de 90% das mortes por DPOC ocorrem nos países em desenvolvimento. O principal fator causador da DPOC é a fumaça do tabaco (WHO, 2015a).

O tabagismo é um dos principais causadores das doenças pulmonares, como a DPOC, bronquite, enfisema, câncer, além de outras doenças como a coronariana, acidente vascular encefálico, hipertensão arterial, entre outras. O tabaco é uma das maiores ameaças à saúde pública no mundo, matando cerca de 6 milhões de pessoas por ano. Dessas mortes, mais de cinco milhões são resultado do uso direto do tabaco, enquanto mais de 600.000 são de fumante passivo (WHO, 2015a).

Estimativa da Organização Mundial da Saúde (OMS) afirma que, até 2030, o número de fumantes será de 1,6 bilhões, e as mortes, em decorrência das doenças causadas pelo tabaco, devem chegar a 10 milhões, sendo que 70% acontecerão nos países em desenvolvimento (DA COSTA E SILVA; DAVID, 2004).

No Brasil, cerca de 11 milhões de pessoas com idade a partir de 40 anos são tabagistas, enquanto, no Estado do Ceará, são aproximadamente 440.207 pessoas nessas mesmas condições (JARDIM *et al.*, 2006).

Essa doença já afeta homens e mulheres quase que igualmente, pois houve aumento do uso do tabaco entre as mulheres nos países desenvolvidos. A DPOC não tem cura, mas o tratamento pode retardar o progresso da doença e aumentar a sobrevida dos indivíduos (WHO, 2015b).

O tabagismo causa diversos custos para o país, como gastos com assistência à saúde, perda ou redução de produtividade, aposentadorias precoces, pensões e pagamento de benefícios, além de gerar poluição e degradação ambiental, bem como sofrimento aos fumantes e a seus familiares (não fumantes) (INCA, 2011).

De acordo com The World Bank, o aumento de gastos públicos nos hospitais e os custos diretos e indiretos relacionados aos tratamentos com as doenças associadas ao tabagismo, nos países desenvolvidos, consomem cerca de 6% a 15% dos custos totais aplicados na saúde, e os gastos médios com pacientes fumantes são superiores aos de pacientes não fumantes (JHA; CHALOUPIKA, 1999).

No Brasil, um estudo realizado em 2005, estimou que os gastos do Sistema Único de Saúde (SUS) com internações e procedimentos relacionados com o tabagismo em casos de câncer, doenças do aparelho circulatório e respiratório foram de R\$ 338,7 milhões, ou 8% dos custos totais da assistência médica (INCA, 2011).

Para minimizar os impactos do tabagismo no Brasil, foi criado, em 1989, o Programa Nacional de Controle do Tabagismo (PNCT) por meio do Instituto Nacional de Câncer (INCA). Também foram criadas políticas e legislação nacional de controle do tabaco, tais como: aumento de impostos para as indústrias de tabaco, aumento do valor do cigarro, dentre outras (INCA, 2011).

No mundo, quase 80% dos mais de 1 bilhão de fumantes vivem em países em desenvolvimento, onde a carga de doenças e mortes relacionadas com o tabaco é mais pesada (WHO, 2015a). Vários países em desenvolvimento apresentam índices de fumo e de doenças associadas ao fumo, dentre estes, Brasil, Angola, Cabo Verde, Guiné-Bissau, Moçambique, São Tomé e Príncipe e Timor-Leste.

Outro tipo de fumaça ou poluição que causa mais de 4 milhões de mortes por ano é a poluição do ar doméstico gerado ao cozinhar com combustíveis sólidos. Aproximadamente 3 bilhões de pessoas cozinham e aquecem suas casas, usando fogueiras a céu aberto e fogões simples, queimando biomassas, tais como: madeira, esterco animal, resíduos vegetais e carvão (WHO, 2016).

Mais de 50% das mortes prematuras por pneumonia entre crianças menores de 5 anos são causadas pelo material particulado (fuligem) inalado da poluição do ar doméstico. Deste total de mortes citadas, 3,8 milhões das mortes prematuras por ano são atribuídas à exposição da poluição do ar doméstico, incluindo também acidente vascular cerebral, doença isquêmica do coração, doenças pulmonares, como a DPOC e câncer de pulmão (WHO, 2016).

Ademais, o diagnóstico auxiliado por sistemas computacionais vem ganhando, cada vez mais, espaço em várias modalidades diagnósticas, com a finalidade de reduzir o tempo de leitura dos exames e, ao mesmo tempo, aumentar a acurácia diagnóstica, auxiliando o radiologista e/ou médicos especialistas em suas interpretações (LI *et al.*, 2005; DOI, 2004).

A Tomografia Computadorizada de Alta Resolução (TCAR) é o exame de escolha na avaliação diagnóstica de infecção do parênquima pulmonar. Entretanto, médicos e radiologistas ainda elaboram diagnósticos subjetivos a partir da análise visual de imagens de TCAR dos pulmões. Esses especialistas, muitas vezes, realizam diagnósticos imprecisos, visto que têm fadiga visual ou não conseguem distinguir entre os tons de cinza das imagens de TCAR, que possuem 16 bits de informação (FELIX, 2007), 65.536 níveis de tons de cinza.

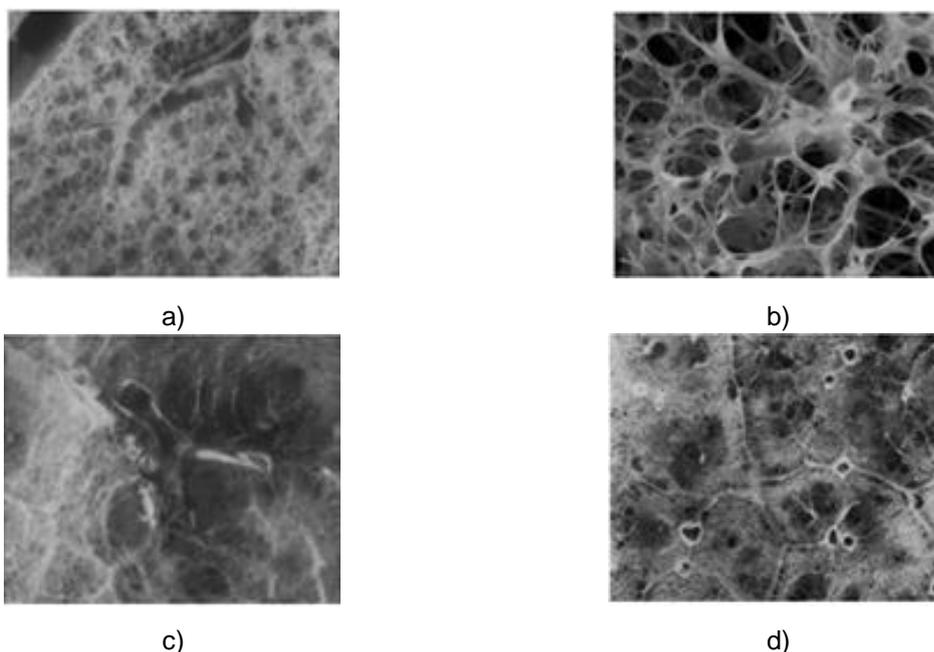
Para promover o aumento de serviços de saúde, em partes do mundo em que não se tem acesso aos serviços de médicos radiologistas, problema pelo qual passam dois terços da população mundial, já se buscam desenvolver sistemas que igualem a performance de radiologistas para detectar doenças pulmonares, como da pneumonia, através de diagnósticos automatizados por raio-X (RAJPURKAR *et al.*, 2017).

Para minimizar imprecisões no diagnóstico das doenças pulmonares, a TCAR deve ser melhor utilizada, já que constitui uma excelente ferramenta para diagnóstico precoce das doenças pulmonares, como a DPOC. Porém, existem limitações, como a ausência de programas (*softwares*) mais robustos que possibilitem realizar a análise dos tipos e níveis de severidade de enfisema de imagens de TCAR dos pulmões, de forma quantitativa, além da qualitativa (FELIX *et al.*, 2010).

Com o advento de ferramentas computacionais, é possível identificar detalhes com maior precisão em imagens de TCAR, a partir de sistemas de Visão Computacional, que utilizam Processamento Digital de Imagens (PDI), para detectar, reconhecer e classificar doenças pulmonares. Isso está auxiliando o diagnóstico médico e proporcionado grandes avanços na medicina, através das contribuições científica e clínica (FELIX, 2007).

Entretanto, faz-se necessária a construção de sistemas de Visão Computacional mais robustos e eficientes, que aplicam técnicas de reconhecimento mais precisas, aproximando-se da classificação manual de um médico especialista, que é tido como padrão ouro (FELIX, 2010).

Figura 1 - Tipos de enfisemas pulmonares.



Fonte: adaptado de Heard *et al.* (1979). (a) pulmão com tecido normal (NT); (b) enfisema panlobular (PLE) com destruição da maioria dos vasos alveolares; (c) enfisema centrolobular (CLE) com bronquíolos ao centro com lesão enfisematosa e alvéolos normais sobrevivendo na periferia do lóbulo; e (d) enfisema parasseptal (PSE) com destruição de alvéolos na periferia dos lóbulos.

Neste contexto, visando a reduzir a subjetividade na análise de imagens em exames de TCAR, a solução proposta é baseada no desenvolvimento de métodos de classificação automática, posteriormente ao PDI, capazes de classificar regiões da imagem pelo tipo de enfisema e também pelo nível de severidade do enfisema.

## 1.1 Objetivos

O objetivo geral deste trabalho consiste em desenvolver um método capaz de classificar os tipos e níveis de severidade de enfisemas em imagens de TCAR dos pulmões, a fim de obter uma técnica que realize a classificação automática.

Além disso, este trabalho possui os seguintes objetivos específicos:

- i. identificar na literatura os métodos mais adequados à extração de atributos de imagens, em especial de TCAR, bem como os métodos de classificação;

- ii. comparar o *Optimum-Path Forest* (OPF) com o *Multilayer Perceptron* (MLP), quando combinados à extração de atributos por análise de textura ou LBP, na classificação de tipos e severidades de enfisemas, em imagens de TCAR de diversos bancos de imagens;
- iii. comparar os resultados dos métodos de classificação de tipos e severidades de enfisemas com o estado da arte, para um mesmo banco de imagens internacional.

## 1.2 Estado da arte

Primeiramente, buscou-se trabalhos relevantes sobre reconhecimento e classificação de enfisemas, utilizando o método de revisão da literatura proposto por Valente (2015), o qual busca, em bases científicas, artigos com uma determinada palavra-chave presente no título. Em seguida, lê-se os títulos e resumos dos trabalhos resultantes, selecionando os que são minimamente relevantes, e por fim, faz-se a leitura desses trabalhos, a fim de selecionar os que são bastante relevantes.

Realizou-se a busca de artigos, teses e dissertações com a presença do termo “enfisema” em português e da sentença: *emphysem\**, em inglês, nas principais bases de artigos científicos (IEEE, Spring Link, Periódicos da Capes, PubMed, Scielo) e de teses e dissertações brasileiras (Biblioteca Digital de Teses e Dissertações - BDTD e apenas trabalhos entre 2013 e 2016 da Plataforma Sucupira, pois eram os que estavam disponíveis).

Buscou-se o termo não apenas no título, como propõe Valente (2015), mas também no resumo, esperando aumentar o número de trabalhos retornados pela pesquisa, em comparação com a busca apenas em títulos.

Também foi realizada a mesma pesquisa nas bases de patentes INPI (Instituto Nacional de Propriedade Intelectual) e Espacenet (*European Patent Office*), agregando relevância acadêmica e profissional para desenvolvimento de produtos inovadores.

A busca de artigos, teses e dissertações retornou 572 artigos e 38 teses e dissertações. Entretanto, verificando a relevância dos trabalhos como proposto por Valente (2015), resultaram 14 artigos sobre reconhecimento e classificação de enfisemas (Tabela 1) e nenhuma tese ou dissertação brasileira.

Por outro lado, a pesquisa no INPI retornou 6 patentes, mas nenhum trabalho relevante, enquanto no Espacenet retornou 1726 patentes, mas garante acesso apenas às 500 primeiras patentes, por política da organização, resultando em 10 patentes sobre reconhecimento de enfisemas (RADHAKRISHNAN *et al.*, 2017; SAKAMOTO *et al.*, 2017a, 2017b; WAKIZAKA *et al.*, 2016; YIN *et al.*, 2015; WIEMKER *et al.*, 2015; MAEDA, 2014; DECRAMER *et al.*, 2013; PU *et al.*, 2013; SHENGWEN, 2012).

Entre esses trabalhos, 5 artigos (VASCONCELOS *et al.*, 2010; SINGH, 2005; PRASAD, SOWMYA e KOCH, 2004; FRIMAN *et al.*, 2002; XU *et al.*, 2006) e todas as 10 patentes faziam apenas a detecção e quantização de regiões com enfisemas, discriminando-as das regiões saudáveis, o que não é o propósito desta pesquisa.

Então, foram selecionados 9 artigos do estado da arte em que os métodos reconhecem ao menos três tipos de enfisemas ou níveis de severidade, podendo ser região normal e pelo menos dois tipos ou níveis de severidade de enfisemas.

A busca do termo de pesquisa apenas nos títulos, como proposto por Valente (2015), é mais eficiente que a busca nos títulos e resumos, como proposto neste trabalho, uma vez que a primeira retorna menor quantidade de trabalhos iniciais, e a segunda, apesar de retornar maior quantidade de trabalhos iniciais, resulta ao fim na mesma quantidade de trabalhos relevantes que a primeira. Pode-se acertar esta afirmação verificando a presença do termo de pesquisa *emphysem\** nos títulos de todos os trabalhos relevantes apresentados na Tabela 1.

Além dos trabalhos do estado da arte da Tabela 1, que foram selecionados a partir do método de revisão da literatura de Valente (2015), adicionou-se o passo metodológico de analisar as referências desses trabalhos em busca de outros artigos relevantes sobre classificação de tipos e severidade de enfisemas, os quais são apresentados a seguir.

Tuba, Tuba e Simian (2017) realizaram a extração de atributos também por *Local Binary Pattern* (LBP) e classificaram regiões de interesse de imagens de TCAR dos pulmões em três tipos de enfisemas, utilizando *Support Vector Machine* (SVM), atingindo 98,18% de acerto na classificação.

Nava *et al.* (2014) realizaram a extração de atributos através de *Local Binary Pattern* (LBP) combinados à *Gabor Feature Vectors* (GFV), assim classificaram regiões de interesse de imagens de TCAR dos pulmões em seis níveis de severidade

de enfisemas, utilizando o classificador *k-Nearest Neighbor* (*k-NN*), alcançando 93,7% de acerto na classificação.

Tabela 1 - Estado da arte das técnicas de classificação de tipos ou severidades de enfisemas.

<b>Autores</b>	<b>Título</b>	<b>Número de classes</b>	<b>Técnica computacional</b>	<b>Acerto máximo</b>
Karabulut e Ibrikci (2015)	<i>Emphysema Discrimination from Raw HRCT Images by Convolutional Neural Networks</i>	3	Classificação por <i>Convolutional Neural Network</i> (CNN) sem extração de atributos	84,24%
Ibrahim e Mukundan (2015)	<i>Analysis of Scale Variations of Local Features for Accurate Classification of Emphysema Images</i>	3	Extração de atributos por <i>Local Binary Pattern</i> (LBP) combinado a Multi-fractais e classificação por <i>Support Vector Machine</i> (SVM) ou <i>Randon Forest</i> (RF)	99%
Kurugol, Washko e Estepar (2014)	<i>Ranking and classification of monotonic emphysema patterns with a multi-class hierarchical approach</i>	5	Ranqueamento por <i>global rankSVM</i> e classificação por <i>Hierarchical SVM</i> , gerando um <i>Hierarchical rankSVM</i>	71%
Dharmagunawardhana et al. (2014)	<i>Quantitative Analysis of Pulmonary Emphysema using Isotropic Gaussian Markov Random Fields</i>	3	Extração de atributos por análise de textura baseada em <i>Isotropic Gaussian Markov Random Fields</i> (IGMRF) e classificação por <i>k-Nearest Neighbor</i> (KNN)	94,6%
Mendoza et al. (2012)	<i>Emphysema quantification in a multi-scanner HRCT Cohort using Local Intensity Distributions</i>	6	Extração de atributos <i>Local Binary Patterns</i> (LBPs) e classificação por <i>Kernel Density Estimation</i> (KDE)	66,4%
Sorensen, Shaker e Bruijne (2010)	<i>Quantitative Analysis of Pulmonary Emphysema Using Local Binary Patterns</i>	3	Extração de atributos por <i>Local Binary Patterns</i> (LBP) combinado a filtros Gaussianos e classificação por <i>K-Nearest Neighbor</i> (KNN)	95,2%
Liang et al. (2008)	<i>An Automated Three-Dimensional Visualization and Classification of Emphysema using Neural Network</i>	5	Divisão do pulmão em 8 níveis de volume e classificação com <i>Neural Network</i>	94,89%
Liang et al. (2007)	<i>A Neural Network based Computer-Aided Diagnosis of Emphysema using CT Lung Images</i>	5	Divisão do pulmão em regiões quadradas e classificação com <i>Neural Network</i>	92,89%
Sonka et al. (2006)	<i>MDCT-Based 3-D Texture Classification of Emphysema and Early Smoking Related Lung Pathologies</i>	5	Extração de atributos por análise de textura e classificador <i>Bayesian</i>	87,5%

Fonte: autor. Estado da arte das técnicas de classificação de enfisemas por tipo (número de classes igual a 3) ou severidade (número de classes igual ou maior que 5), apresentando a técnica computacional empregada: método de extração de atributos e de classificação; e acerto máximo obtido pelo classificador.

Como se pode constatar, por meio das técnicas computacionais da Tabela 1 e dos trabalhos encontrados após busca nas referências, a análise de textura e o uso de *Local Binary Pattern* (LBP) são os métodos mais utilizados na literatura para extração de atributos das imagens de TCAR dos pulmões. Dessa forma, também se

utilizam esses dois métodos de extração de atributos neste trabalho, uma vez que ambos geram vetores de características que possibilitam o processo de classificação de tipos e severidade de enfisemas.

### **1.3 Organização da dissertação**

Na Seção 2, são apresentados conceitos básicos das principais técnicas utilizadas neste trabalho: *Local Binary Pattern* (LBP), *watershed* e morfologia matemática, análise de textura, Floresta de Caminhos Ótimos (OPF) e *Multilayer Perceptron* (MLP).

Na Seção 3, são descritos os dois métodos utilizados para extração de características das imagens, além de como ocorrerá a etapa de classificação dos tipos e severidades de enfisemas das imagens de TCAR.

Na Seção 4, são apresentados os resultados da aplicação da combinação dos métodos de extração de atributos LBP ou análise de texturas com os classificadores OPF ou MLP, quando aplicados sobre quatro bancos de imagens de TCAR dos pulmões.

Na Seção 5, por fim, são apresentadas as contribuições finais desta dissertação e os trabalhos futuros que podem ser desenvolvidos a partir desta.

## 2 REFERENCIAL TEÓRICO

Nesta seção, é apresentada a revisão de alguns conceitos e técnicas utilizadas para o desenvolvimento dos métodos propostos, tanto na etapa de extração de características das imagens de TCAR, quanto para classificação de tipos e de severidades de enfisemas a partir dos vetores de atributos gerados.

### 2.1 Local Binary Pattern (LBP)

O *Local Binary Pattern* é um descritor de texturas definido de acordo com Ojala, Pietikäinen e Mäenpää (2002), que obtém medidas invariantes de níveis de cinza para caracterização de estruturas locais de vizinhança 3 x 3 pixels, através de padrões binários locais, ao comparar pixels vizinhos com o limiar do pixel central (TUBA, TUBA e SIMIAN, 2017; SORENSEN, SHAKER e BRUIJINE, 2010), como demonstra a equação:

$$LBP_{P,R} = \sum_{p=0}^P s(I(x_p, y_p) - I(x, y))2^p, \quad (1)$$

onde  $P$  é o número de pixels vizinhos,  $R$  é o comprimento do raio de um círculo onde se definem os pixels vizinhos,  $I(x, y)$  é a intensidade de nível de cinza do pixel central  $(x, y)$ ,  $I(x_p, y_p)$  é o valor da intensidade de nível de cinza do pixel vizinho  $p$ , e a função  $s$  é definida como:

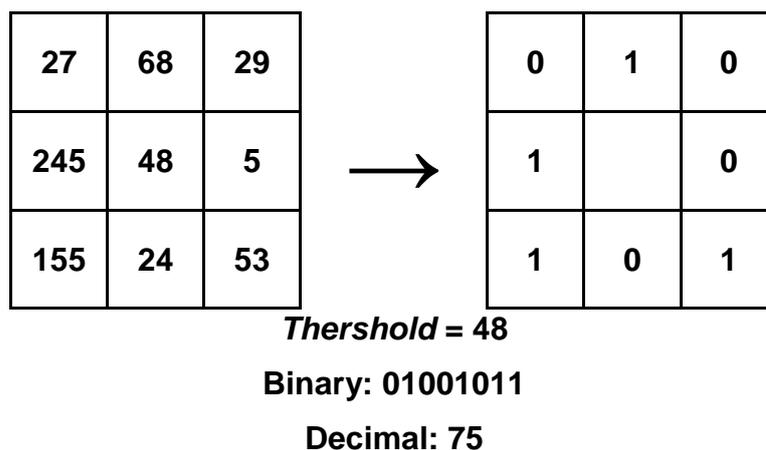
$$s(k) = \begin{cases} 1, & \text{Se } k \geq 0, \\ 0, & \text{outros casos.} \end{cases} \quad (2)$$

onde  $k$  representa  $I(x_p, y_p) - I(x, y)$ .

Um exemplo apresentado na Figura 2 ilustra o cálculo do LBP do valor de intensidade dos pixels de uma imagem com enfisema, em que o limiar do pixel central, chamado de *Threshold*, tem valor 48 e que, depois da comparação com os valores dos pixels vizinhos, segundo as Equações 1 e 2, o correspondente código binário do LBP é gerado (IBRAHIM e MUKUNDAN, 2015).

O pixel central também descreve o nível de cinza de uma parte local e contém informações discriminantes adicionais que podem ser muito úteis durante o processo de classificação (IBRAHIM e MUKUDAN, 2015). O LBP mensura a estrutura local atribuindo identificadores exclusivos, o número binário, para várias microestruturas da imagem.

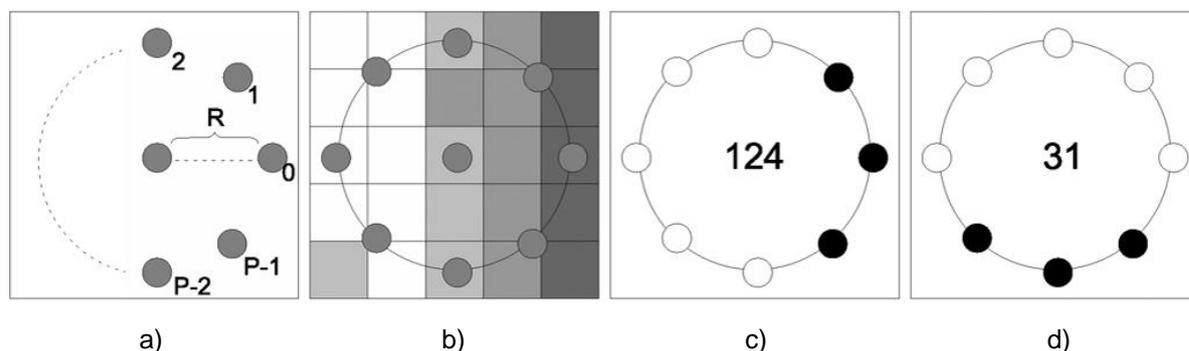
Figura 2 - Ilustração do *Local Binary Pattern* (LBP).



Fonte: adaptado de Tuba, Tuba e Simian (2017). Exemplo da aplicação das Equações 1 e 2 do *Local Binary Pattern* (LBP) a um conjunto de 3 x 3 pixels, com o pixel central e os oito pixels vizinhos.

O LBP é invariante a qualquer transformação de escala de nível de cinza, mantendo as mesmas variações de intensidades entre pixels, mesmo após transformações. Além disso, o LBP permite análise multiresolução e é invariante à rotação (Figura 3d), característica muito desejada para os descritores de textura (TUBA, TUBA e SIMIAN, 2017; SORENSEN, SHAKER e BRUIJINE, 2010). Por exemplo, quando o paciente está parado para a captura da imagem de TCAR, o LBP possibilita ser invariante à rotação da caixa torácica dos pacientes.

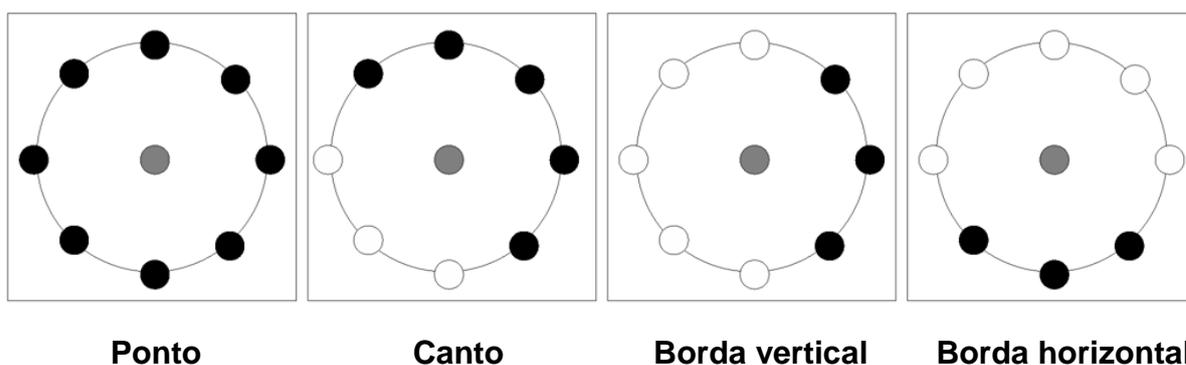
Figura 3 - Exemplo de cálculo do LBP.



Fonte: Sorensen, Shaker e Bruijine (2010). a) O filtro LBP é definido pelos dois parâmetros, o número de vizinhos  $P$  e o raio do círculo  $R$ . b) A estrutura local é mensurada obtendo os pixels vizinhos ao pixel central. c) São calculados os códigos binários do LBP, ao comparar a intensidade dos pixels vizinhos com o do pixel central, sendo que os pontos pretos são zero e os brancos são uns. O exemplo de imagem apresentado em b) tem um código decimal do LBP igual a 124. d) Rotacionando a imagem do exemplo b) em  $90^\circ$  no sentido horário, reduz o código decimal LBP para 31, que é o menor código possível para este padrão binário. Este é o princípio usado para alcançar a invariância de rotação.

O LBP captura muitas estruturas, por exemplo, na Figura 3b, aparece uma borda vertical à direita, bem como na Figura 4, apresentam-se pontos, cantos, bordas verticais e horizontais.

Figura 4 - Várias microestruturas mensuradas por LBP.



Fonte: adaptado de Sorensen, Shaker e Bruijine (2010). O pixel central está indicado com o círculo cinza, enquanto os círculos pretos e brancos são amostras binárias, respectivamente, zeros e uns.

Depois da obtenção dos códigos binários do LBP, é criado um histograma dos mesmos. Como um vetor de características com ampla dimensão de atributos dificulta a classificação, um padrão uniforme pode ser aplicado para reduzir a dimensão de atributos do vetor de características e implementar um simples descritor invariante a

rotação. Para isso, utiliza-se o LBP uniforme, com 8 pixels vizinhos e raio 1 ( $P = 8, R = 1$ ), em que o número de códigos binários possíveis é reduzido de  $2^8 = 256$  para 59, ao se considerar apenas os valores binários que estão no máximo a duas transições de 0 para 1 ou vice-versa, quando o padrão de bits é percorrido circularmente, mantendo todos os outros binários com os valores desses. Em seguida, um histograma de frequências de cada código binário local é gerado em números decimais normalizados (TUBA, TUBA e SIMIAN, 2017; IBRAHIM e MUKUDAN, 2015).

## 2.2 *Watershed* e Morfologia Matemática

Segundo Gonzalez e Woods (2011), a segmentação *watershed* produz resultados de segmentação estáveis, incluindo fronteiras de segmentação conectadas, pois elimina linhas de segmentação descontínuas. O *watershed* (bacias hidrográficas) visualiza uma imagem em três dimensões: duas coordenadas espaciais e a intensidade.

Em analogia a um ambiente topográfico, os vales são os pontos que pertencem a um mínimo regional, níveis de cinza escuro da imagem; as represas são pontos em que uma gota d'água cairia, com certeza, para um mínimo regional específico; e os picos da montanha são os pontos em que a água tem a mesma probabilidade de cair em mais de um mínimo regional, pontos de máximo gradiente da imagem, linhas de divisão do *watershed*. As bacias hidrográficas são formadas nos vales e têm sua máxima capacidade ao encher até o topo das montanhas (GONZALEZ; WOODS, 2011). O principal objetivo dos algoritmos é encontrar as linhas de divisão do *watershed*, que correspondem às linhas desejadas da segmentação.

Inundação e chuva são duas formas de aproximar as linhas de divisão do *watershed* em uma imagem. Na técnica de inundação, cada mínimo regional é uma nascente, por onde ocorre a elevação das águas, inundando toda topografia dos vales da imagem até os picos. Então, uma barragem (de pixels únicos) é construída para que as águas de duas bacias não cheguem ao ponto de se fundir (PRATT, 2007).

A inundação finaliza quando apenas os picos das barragens (maior valor de intensidade da imagem de entrada, normalmente 1) estiverem visíveis acima do nível d'água, formando caminhos conexos e fronteiras contínuas, correspondendo às linhas do *watershed*, a própria segmentação em si. Na aproximação do *watershed* pela técnica da chuva, as gotas caem em direção aos mínimos regionais da imagem, vales,

percorrendo uma região com baixa intensidade de pixels, a qual é atribuída única etiqueta (GONZALEZ; WOODS, 2011).

Para construir barragens, na segmentação por *watershed*, utiliza-se técnicas de Morfologia Matemática, que definem operadores morfológicos, como: dilatação, erosão, anti-dilatação e anti-erosão (FELIX, 2007).

A dilatação morfológica é a maneira mais simples de construir barragens *watershed*, pois duas bacias, em que a água de uma vazou para a outra, têm uma barragem construída para evitar que isso aconteça, à medida que a dilatação, aplicando elemento estruturante 3 x 3 pixel a pixel da represa, amplia a fronteira de cada bacia, mas evita que os conjuntos dilatados das duas bacias se misturem, com a construção de barragens de 1 pixel de espessura. O elemento estruturante é uma máscara planar que pode assumir formas geométricas, como: quadrado, triângulo, retângulo, círculo, hexágono, ponto, cruz (GONZALEZ; WOODS, 2011).

Os operadores morfológicos dilatação (que expande a imagem) e erosão (que a reduz), quando aplicados em sequência em uma imagem, evidenciam melhor as características desta, permitindo a aplicação de outras funções importantes, como abertura, que preenche pequenos buracos ou lacunas no contorno da imagem, e fechamento, que suaviza o contorno, eliminando irregularidades indesejadas (FELIX, 2007).

Seja a imagem em análise definida por  $A$  e o elemento estruturante, por  $B$ , tal que  $A$  e  $B$  são conjuntos não-vazios, as Equações 3 e 4 definem os operadores morfológicos de dilatação e erosão, respectivamente:

$$(A \oplus B) = \{z | [(\hat{B})_z \cap A] \subseteq A\}, \quad (3)$$

$$(A \ominus B) = \{z | (B)_z \subseteq A\}, \quad (4)$$

onde  $(B)_z$  corresponde a  $B$  trasladado por  $z$  e  $(\hat{B})_z$  é a reflexão de  $B$  sobre a própria origem trasladada por  $z$  (GONZALEZ; WOODS, 2011).

A abertura é definida pela erosão de  $A$  por  $B$ , seguida da dilatação desse resultado por  $B$  (Equação 5), e o fechamento inverte a ordem das operações da abertura, dilatando  $A$  por  $B$  seguido da erosão do resultado por  $B$  (Equação 6), segundo (GONZALEZ; WOODS, 2011).

$$(A \circ B) = (A \ominus B) \oplus B \quad (5)$$

$$(A \cdot B) = (A \oplus B) \ominus B \quad (6)$$

### 2.3 Análise de textura

Haralick (1979) revisou a literatura de processamento de imagens sobre análise de texturas, extraíndo técnicas e modelos que podem ser utilizados para medição de propriedades de textura, por ser uma importante característica para análise de muitos tipos de imagens, tanto de imagens microscópicas de culturas de células, quanto de TCAR ou de satélites, a fim de formalizar precisamente as técnicas de análise de textura até então.

Segundo Gonzalez e Woods (2011), a análise de textura é importante descritor de regiões, por quantificar o conteúdo de textura de imagens, a partir de medidas de propriedades como suavidade, rugosidade e regularidade, por meio das abordagens estatística, estrutural e espectral. Estas informações de textura são analisadas na etapa de reconhecimento de padrões.

Existem, na literatura, várias abordagens de análise de textura: momentos estatísticos de histograma de intensidade, matriz de coocorrência, matriz de comprimento de corrida, gradiente, autorregressivos e *wavelet*, apresentadas a seguir (SÁ JUNIOR, 2013).

Momentos estatísticos de histograma representam a média, a variância, a assimetria dos dados em torno da média amostral, a curtose e a frequência do histograma.

A matriz de coocorrência representa a intensidade de textura pelo nível de cinza de um pixel e de seu vizinho, em uma matriz de frequências relativas, quantificando a relação espacial entre pixels vizinhos de uma imagem e englobando os seguintes atributos de textura: energia, contraste, correlação, soma dos quadrados, homogeneidade e entropia (BENTO, 2013).

A matriz de comprimento de corrida corresponde às sequências de pixels consecutivos com o mesmo nível de cinza, definidos como uma corrida. A matriz é formada pelo número de corridas para cada nível de cinza e cada comprimento de

corrida. Os atributos de textura que podem ser extraídos a partir dessa matriz são estes: ênfase em corrida curta e ênfase em corrida longa, que descrevem, respectivamente, a frequência de corridas curtas e longas encontradas na textura; não-uniformidade de nível de cinza, que representa a distribuição de tons de cinza, em que baixos valores indicam homogeneidade nos tons de cinza; não-uniformidade de comprimento de corrida, que mede a uniformidade e distribuição dos comprimentos de corrida; e percentagem de corrida (BENTO, 2013).

Gradiente descreve variações de orientação de intensidade dos níveis de cinza da imagem, sendo largamente utilizado como método de detecção de bordas, através dos pixels com maior valor de gradiente. Além disso, o gradiente é menos invariante, visto que é menos suscetível a mudanças na iluminação do ambiente e às características do equipamento de aquisição de imagens (BENTO, 2013).

Parâmetros autorregressivos são obtidos através de um processo não-determinístico. Cada pixel assume valores em um intervalo, então a imagem se torna de valores aleatórios, e os pixels da imagem interagem probabilisticamente, por exemplo, pela soma ponderada da intensidade dos pixels vizinhos. São definidos cinco atributos autorregressivos: desvio-padrão do ruído independentemente e identicamente distribuído, e o vetor de quatro parâmetros  $\theta = [\theta_1, \theta_2, \theta_3, \theta_4]$ , que representa a vizinhança local de quatro pixels vizinhos (GONZALEZ; WOODS, 2011).

A realização em cascata da transformada *wavelet* unidimensional é aplicada à análise de textura através da decomposição da imagem original em sub-regiões de alta ou baixa frequência, que possibilitam extrair características de cada sub-região, como energia (GONZALEZ; WOODS, 2011).

Numerosas métricas são utilizadas para providenciar úteis informações baseadas em histogramas (TUBA, TUBA e SIMIAN, 2017). Neste trabalho, são calculadas e utilizadas, como vetor de características, seis métricas comuns de primeira ordem:

$$\mu = \sum_{i=0}^N i * p(i), \quad (7)$$

$$\sigma = \sqrt{\sum_{i=0}^N (i - \mu)^2 * p(i)}, \quad (8)$$

$$skewness = \frac{1}{\sigma^3} \sum_{i=0}^N (i - \mu)^3 * p(i), \quad (9)$$

$$kurtosis = \frac{1}{\sigma^4} \sum_{i=0}^N (i - \mu)^4 * p(i) - 3, \quad (10)$$

$$energia = \sum_{i=0}^N p(i)^2, \quad (11)$$

$$entropia = - \sum_{i=0}^N p(i) * \log_2 p(i), \quad (12)$$

onde  $\mu$  é a média,  $\sigma$  é o desvio padrão, o histograma normalizado é dado por  $p$  e o número de valores do histograma é representado por  $N$ . Haralick (1979) descreve, em detalhes, todas as medidas de textura de primeira e segunda ordem, utilizadas neste trabalho.

## 2.4 Floresta de Caminhos Ótimos (OPF)

O classificador OPF ainda não foi utilizado para pesquisas com enfisemas pulmonares, visto que não foi encontrado nenhum resultado do termo “*optimum-path forest*”, em inglês, ou “opf”, seja nos títulos, seja nos resumos dos 572 artigos e das 38 teses e dissertações sobre enfisema revisados para compor o estado da arte (Seção 1.2).

Por outro lado, o OPF apresenta diversas utilizações com excelentes resultados, como a estimativa de ocorrência de precipitação em áreas agrícolas (FREITAS *et al.*, 2010), com 85% de acerto; caracterização microestrutural de soldas e fundições (BARBOSA, 2015), com até 90% de acerto; e análise de lesões na substância branca do cérebro (BENTO, 2013), com acerto de até 98%.

Segundo Papa, Falcão e Suzuki (2009) e Rocha, Cappabianco e Falcão (2009), a classificação foi realizada através de OPF, que é baseado na *Image Foresting Transform* (IFT), em que a imagem é vista como um grafo, o vetor de características das imagens é visto como os nós, e os arcos são definidos pela relação de adjacência entre nós, a distância entre os vetores de atributos dos nós.

A representação de amostras no grafo ocorre por meio da extração de características de todas as amostras. A distância entre duas amostras é calculada utilizando qualquer função de distância entre os seus respectivos vetores de características. Quando se utiliza a versão 2.1 da biblioteca LibOPF (PAPA, FALCÃO e SUZUKI, 2009) para executar o classificador OPF, é possível calcular a distância entre as amostras através de seis funções: Euclidiana, *Chi-Square*, Manhattan,

Canberra, *Squared Chord*, *Squared Chi-Squared* e BrayCurtis, sendo considerada a euclidiana como distância padrão (PAPA; FALCÃO; SUZUKI, 2009).

A divisão ótima das características discretas de cada classe, no conjunto de treinamento, forma uma Floresta de Caminhos Ótimos, bem como um grafo completo em que todos os pares de amostras são conectados por arcos entre eles. Um caminho é ótimo quando é menor que qualquer outro caminho. Então, a OPF é a união de todos esses caminhos ótimos (BARBOSA, 2015).

Os protótipos são nós que pertencem às regiões de fronteira entre as classes. São os principais elementos de cada classe do conjunto de treinamento. O OPF realiza um processo de competição entre amostras, tal que amostras de uma mesma árvore estão mais fortemente conectadas do que a outras árvores, através do menor custo entre amostras. Amostras tentam se conectar a esses nós, chamados de protótipos, sendo conquistados por aqueles que apresentarem o menor custo de ligação, assumindo a mesma classe do protótipo, herdando o mesmo custo ou computando a distância, o que for maior (ROCHA; CAPPABIANCO; FALCÃO, 2009).

No final desse processo, é obtido um conjunto de treinamento de árvores de caminhos ótimos, que, unidas, remetem a uma floresta de caminhos ótimos. Uma amostra é classificada calculando os caminhos ótimos dos protótipos até a amostra e é associada àquele que tem o menor peso. Para cada amostra de teste, ocorre a classificação do protótipo mais fortemente conexo com uma classe, calculando todos os caminhos possíveis até as amostras de treinamento e os respectivos caminhos ótimos (BARBOSA, 2015).

O cálculo dos caminhos ótimos é computado pelo algoritmo da IFT, que é baseado no algoritmo de Dijkstra, mas que consegue receber várias funções de custo. Papa, Falcão e Suzuki (2009) apresentaram um modelo de classificador OPF supervisionado, em que se utiliza a relação de adjacência em um grafo de conexões completas, através da função de custo:

$$fmax(\pi_s \cdot (s, t)) = \max\{fmax(\pi_s), d(s, t)\}, \quad (13)$$

onde o peso dos arcos é a distância  $d(s, t)$  entre os vetores de características  $s$  e  $t$ ,  $\pi_s$  é um caminho qualquer entre esses vetores,  $\pi_s \cdot (s, t)$  é a concatenação do caminho terminado em  $s$  com o arco  $(s, t)$ .

Neste trabalho, as amostras são os atributos de textura de cada imagem ou sub-imagem, que são divididas nos conjuntos de treinamento e teste, assim o OPF supervisionado pode associar as amostras de teste à classe correta (PAPA; FALCÃO; SUZUKI, 2009).

## **2.5 Multilayer Perceptron (MLP)**

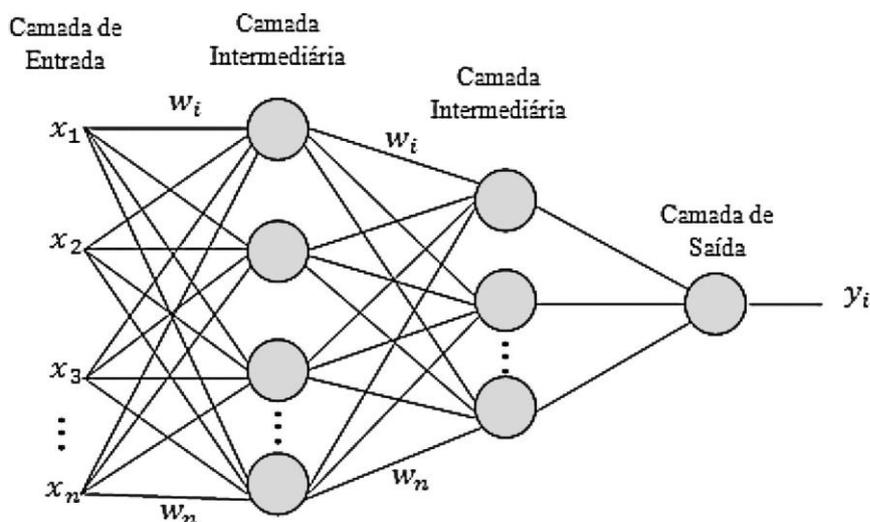
A técnica de Redes Neurais Artificiais (RNA), por meio de MLP, é conhecida como uma classe de RNAs chamada de *feedforward*, além de ser uma aproximadora universal de funções (COUTINHO, SILVA e DELGADO, 2016).

A MLP é vastamente utilizada para diversas aplicações de reconhecimento de padrões, entre elas, para segmentação de vias em imagens de TCAR do tórax, com similaridade de 81,20% (CAVALCANTE *et al.*, 2013); para reconhecimento de doenças, como a osteoartrite da coluna lombar, com acerto de 62,85% (VERONEZI *et al.*, 2011); para identificação de gasolina adulterada, com 100% de acerto na identificação das adulterações (BORSATO *et al.*, 2009); e para predição de dados meteorológicos, com 96% de acerto na previsão do clima (COUTINHO, SILVA e DELGADO, 2016).

As redes neurais MLP possuem duas fases de execução: a de treinamento e a de testes. Na fase de treinamento, parâmetros de entrada são apresentados à rede, cujas classes já são conhecidas. Em seguida, o erro de classificação para cada exemplo de treinamento é utilizado para atualizar os pesos da rede. Durante a fase de testes, exemplos são selecionados, cujas classes não são conhecidas, e o conjunto dos seus parâmetros são apresentados na entrada da rede, utilizando os pesos definidos na fase de treinamento, assim ocorre a classificação desses exemplos de teste (CAVALCANTE *et al.*, 2013).

Segundo Coutinho, Silva e Delgado (2016), a MLP é formada por neurônios em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, sendo que cada neurônio da primeira camada está conectado a todos os neurônios da camada intermediária, da mesma forma que cada um desses também estão conectados com todos os neurônios da camada de saída (Figura 5).

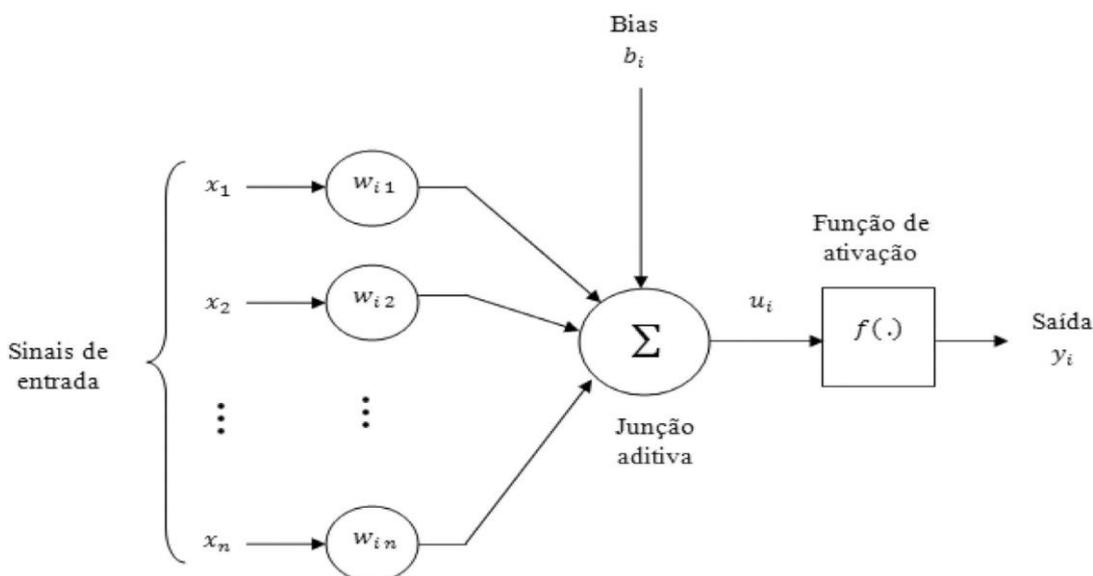
Figura 5 - Exemplo de arquitetura de rede neural artificial MLP.



Fonte: Coutinho, Silva e Delgado (2016). Uma camada de entrada, duas camadas ocultas e uma camada de saída.

Cada camada possui pesos que estão associados ao produto  $w_i * x_i$ , cuja soma ponderada ativa a função de transferência, emitindo uma resposta para o neurônio da próxima camada, sendo que a camada de saída recebe o padrão que se está classificando. Dessa forma, as camadas ocultas extraem características para cada neurônio, codificando os padrões de entrada, permitindo que a rede extraia atributos do vetor de características ainda mais detalhados e complexos, gerando qualquer tipo de saída, até mesmo não linear, conforme é mostrado na Figura 6.

Figura 6 - Modelo de neurônio da rede MLP não linear.



Fonte: Coutinho, Silva e Delgado (2016).

Na Figura 6,  $x_i$  é um dos  $n$  dados de entrada de um neurônio  $j$  de uma camada oculta;  $w_{ij}$  são os pesos sinápticos entre esse neurônio  $j$  e cada uma de suas  $n$  entradas;  $b_i$  é o *bias*, que aumenta ou diminui a entrada da função de ativação,  $u_i$  é a combinação linear representada pela Equação 14,  $f(\cdot)$  é a função de ativação ou transferência aplicada a  $u_i$  (função logística da Equação 15) e  $y_i$  é a saída do neurônio

$$u_i = \sum_{i=1}^n w_{ij} * x_i + b_i, \quad (14)$$

$$f(\cdot) = f(u_i) = \frac{1}{(1+e^{-u_i})}. \quad (15)$$

Durante a fase de treinamento, utiliza-se o algoritmo *Back-propagation*. Em uma primeira fase, chamada *forward*, a MLP insere as entradas na rede, gerando saídas sem a alteração dos pesos sinápticos. Na fase seguinte, chamada *backward*, realiza-se o ajuste dos pesos sinápticos através do gradiente descendente de retro programação do erro  $e(t)$  para o neurônio  $i$  da camada de saída. Calcula-se a diferença entre a classe desejada  $y_{di}(t)$  e a predita pela rede  $y_{pi}(t)$  a cada iteração ou tempo  $t$  (Equação 16), a fim de classificar corretamente a resposta da rede às mesmas classes de entrada, sendo, pois, uma técnica de treinamento supervisionado. Assim, a função de custo para uma rede com  $n$  neurônios na camada de saída é determinada pela Equação 17 (COUTINHO; SILVA; DELGADO, 2016).

$$e(t) = y_{di}(t) - y_{pi}(t) \quad (16)$$

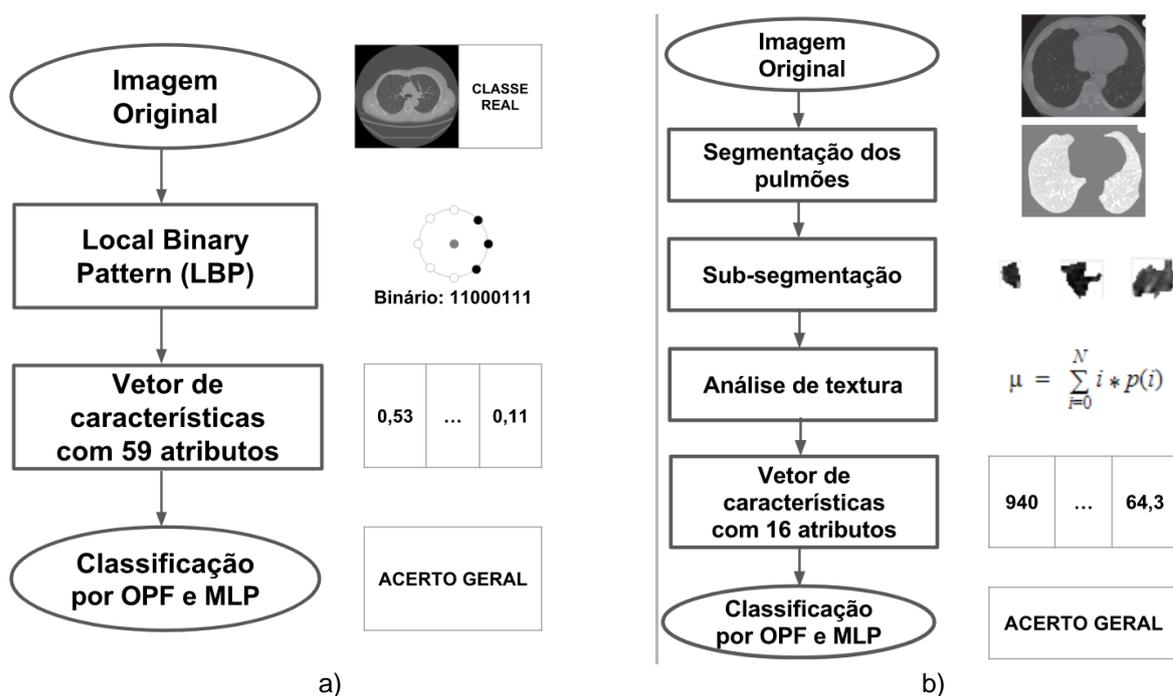
$$E(t) = \frac{1}{2} \sum_{i=1}^n e_i^2(t) \quad (17)$$

Os neurônios localizados na camada oculta da rede não têm uma resposta desejada  $y_{di}(t)$ , sendo seu erro determinado recursivamente em relação ao erro de todos os neurônios conectados diretamente a este (COUTINHO; SILVA; DELGADO, 2016).

### 3 METODOLOGIA

As metodologias utilizadas neste trabalho consistem em extrair características de imagens de TCAR dos pulmões por *Local Binary Pattern* (Figura 7a) ou análise de textura (Figura 7b) e aplicar essas características nos classificadores *Optimum-Path Forest* (OPF) ou *Multilayer Perceptron* (MLP). Veja a seguir, em mais detalhes, cada etapa dessas metodologias, iniciando pelos bancos de imagens utilizados.

Figura 7 - Metodologias empregadas durante a pesquisa.



Fonte: autor. a) Metodologia que aplica LBP para extração de características das imagens, gerando um vetor de 59 atributos. b) Metodologia que realiza a segmentação dos pulmões, os sub-segmenta em regiões menores, gerando sub-imagens, nas quais aplica-se análise de textura para extração de 16 características. No final, ambos os métodos a) e b) classificam as imagens conforme os vetores de atributos gerados.

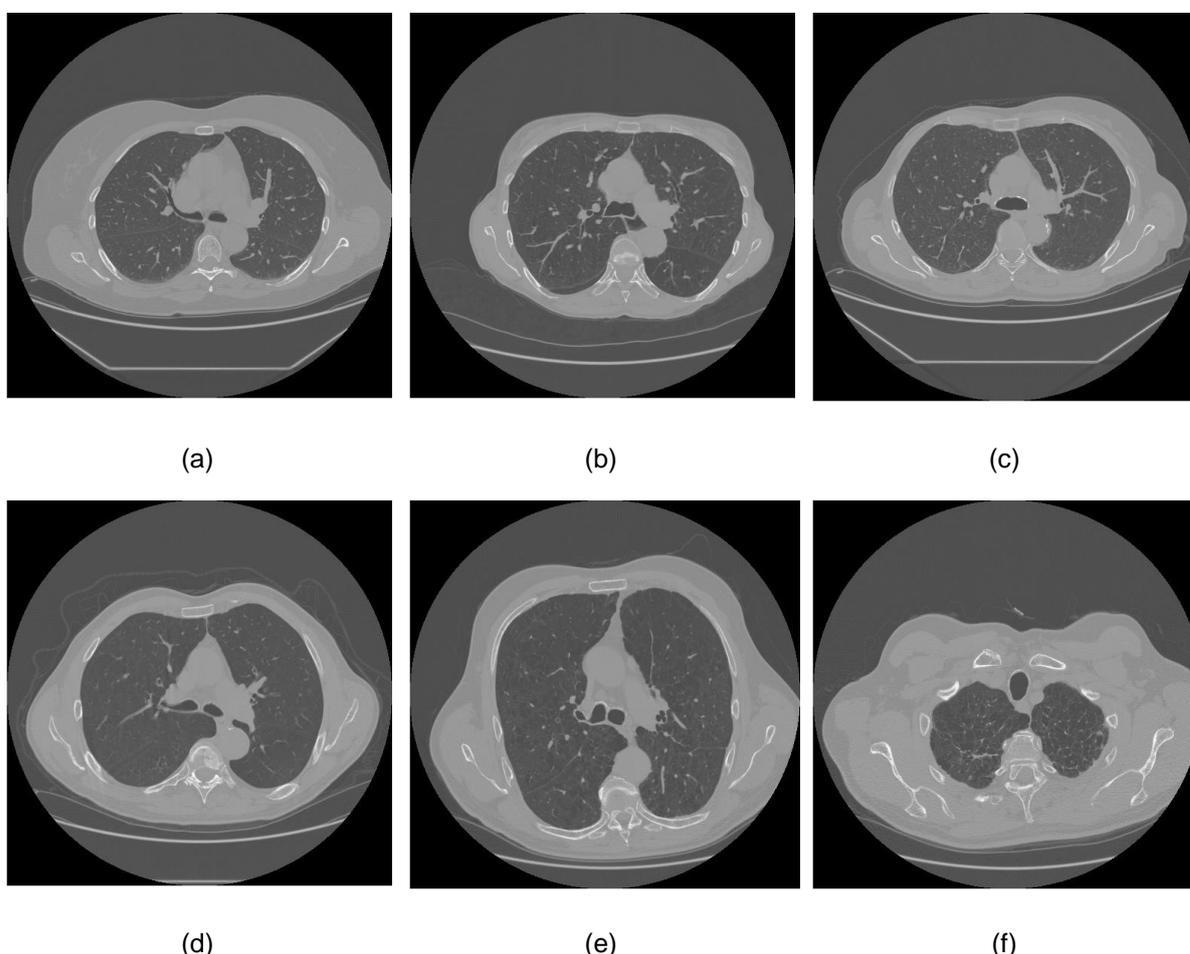
#### 3.1 Bancos de imagens

Para realizar a classificação de tipos de enfisemas, foram utilizadas quatro bases de imagens de Tomografia Computadorizada de Alta Resolução (TCAR) dos pulmões, apresentadas a seguir. A primeira dessas bases também foi utilizada para classificação da severidade dos enfisemas.

### 3.1.1 Slices de Sorensen et al. (2010)

São 115 imagens de pulmões com dimensão 512 x 512 pixels (Figura 8), classificadas segundo os **tipos de enfisemas**: 61 com tecido normal (NT), 21 com enfisema centroacinar (CLE), 27 com enfisema parasseptal (PSE) e 6 com enfisema panlobular (PLE); e segundo as **severidades dos enfisemas**: 61 sem enfisema (NOE), 26 enfisema mínimo (MIN), 11 suave (MIL), 12 moderado (MOD), 3 severo (SEV) e 2 muito severo (VSE); através do consenso entre um experiente radiologista em pulmões e um pneumologista experiente em Tomografia Computadorizada (TC).

Figura 8 - Exemplos de imagens dos *slíces* de Sorensen et al. (2010).



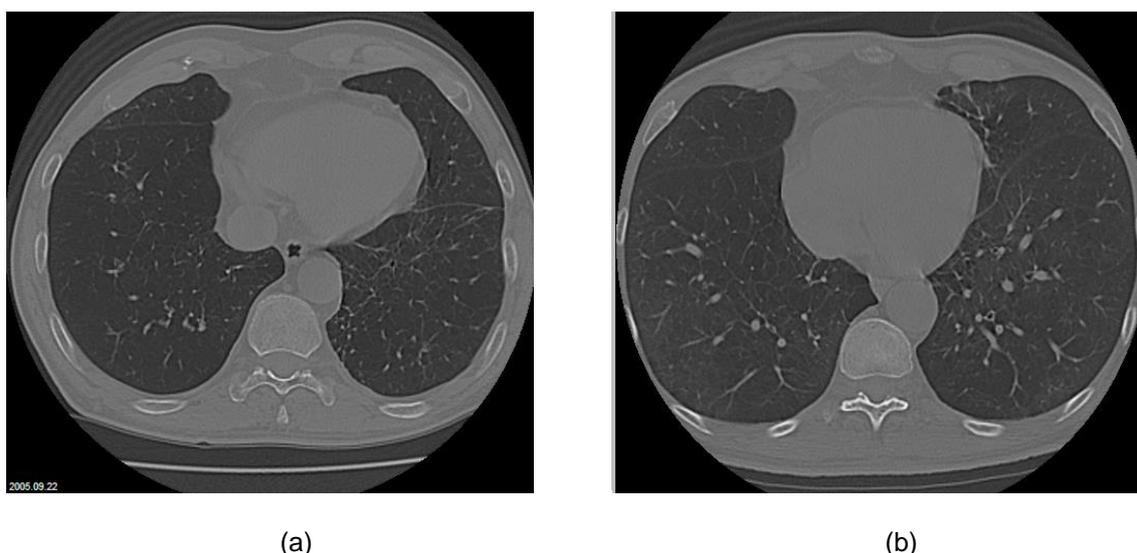
Fonte: Sorensen et al. (2010). Exemplos de imagens dos *slíces* de Sorensen et al. (2010), na posição de hilo (a-e) e ápice (f), com os níveis de severidade: sem enfisema (a), enfisema mínimo (b), suave (c), moderado (d), severo (e) e muito severo (f); além, dos tipos de enfisema: tecido normal (a), enfisema centroacinar (b, e, f), enfisema parasseptal (c) e enfisema panlobular (d).

Foram obtidas na posição ápice, hilo e base, a partir de 39 pessoas (9 nunca fumantes, 10 fumantes e 20 fumantes com DPOC), por meio de equipamento de TCAR da General Electric, modelo LightSpeed QX/i (GE Medical Systems, Milwaukee, WI, USA), com quatro detectores de linhas, usando os seguintes parâmetros: resolução plana de 0,78 x 0,78 mm, espessura de fatia de 1,25 mm, tubo de voltagem de 140 kV e corrente no tubo de 200 mAs.

### 3.1.2 Fortaleza (2006)

São 25 imagens de pulmões com dimensão 512 x 512 pixels (Figura 9), classificadas em 17 imagens com enfisema centroacinar (CLE) e 8 com enfisema panlobular (PSE), por meio da análise de uma médica pneumologista, um estudante de medicina e um técnico de radiologia, a partir de 11 pacientes, 4 do sexo feminino e 7 do sexo masculino, maiores de 50 anos de idade (59-74 anos; média: 64,9; desvio padrão: +/- 4,8 anos), sendo 1 com diagnóstico de DPOC grau leve, 3 de grau moderado e 7 de intensidade grave, segundo classificação GOLD (*Global Initiative for Chronic Obstrutive Lung Disease*).

Figura 9 - Exemplos de imagens de pulmões de Fortaleza (2006).



Fonte: Fortaleza (2006). Exemplos de imagens de pulmões com dois tipos de enfisemas: enfisema centroacinar (a) e panlobular (b).

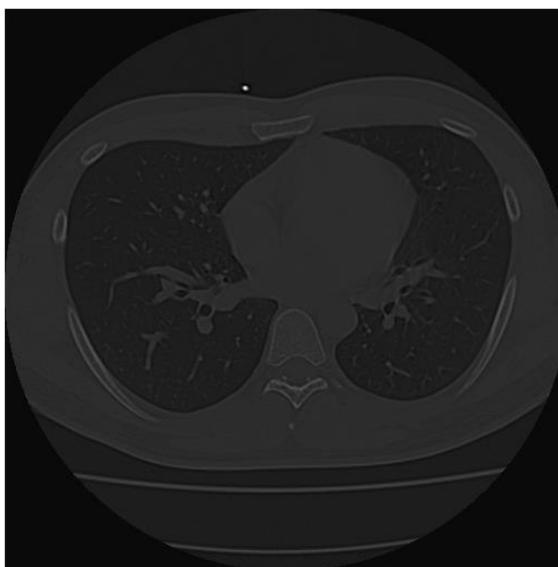
Foram obtidas na posição ápice, hilo e base, por meio de equipamento de TCAR da Aukelet Toshiba TSX-003A (Toshiba Medical®, Tóquio, Japão), calibrado

para ar em densidade de 1000 UH (Unidades Hounsfield), com colimação de 1,5 mm, campo de visão de 312 mm, tempo de corte de 1,8 segundos, tubo de voltagem de 120 kV, corrente no filamento do tubo de 200 mA e ajuste da janela pulmonar centro e largura, respectivamente, de -600/1600 UH.

### **3.1.3 Winkeler (2006)**

São 95 imagens de pulmões com dimensão 512 x 512 pixels (Figura 10), classificadas como imagens de tecidos normais (NT), nos cortes ao nível de ápice (2 cm acima do arco aórtico), hilo (1 cm abaixo da carina) e em base (2 cm acima do diafragma). As imagens deste banco têm níveis de cinza mais escuros do que as dos demais bancos utilizados. Portanto, faz-se necessário um método de classificação de tipos e severidades de enfisemas que seja invariante a imagens de diversos bancos, mesmo com intensidades mais escuras ou mais claras no nível médio de cinza.

Figura 10 - Exemplo de imagem original de TCAR de pulmões de Winkeler (2006).



Fonte: Winkeler (2006).

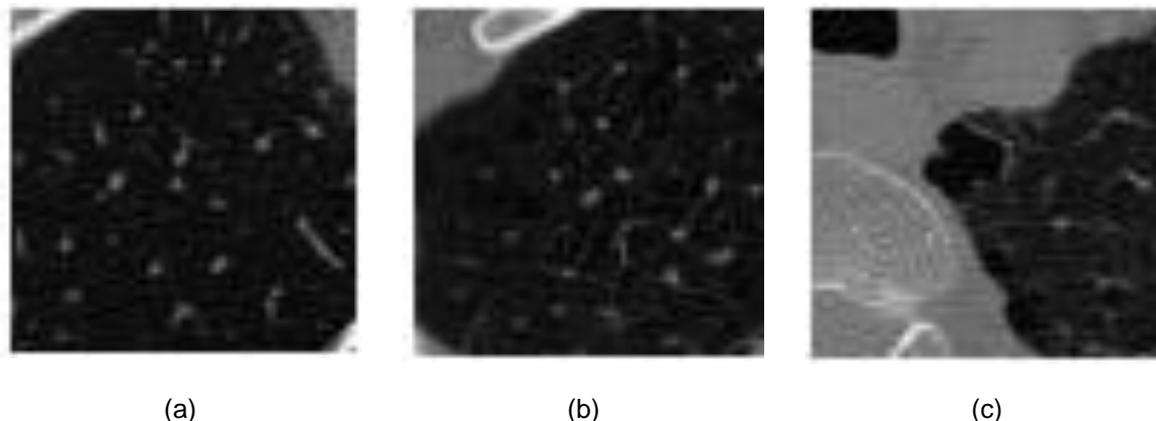
Foram obtidas a partir de 8 voluntários, maiores de 18 anos de idade, de ambos os sexos, sem histórico de tabagismo passivo ou ativo e sem progressa ou atual doença cardiopulmonar, por meio de equipamento de TCAR da Aukelet Toshiba®

TSX-003A (Toshiba Medical®, Tóquio, Japão), calibrado para ar em densidade de 1000 UH (Unidades Hounsfield), com colimação de 1,5 mm, campo de visão de 312 mm, tempo de corte de 1,8 segundo, tubo de voltagem de 120 kV, corrente no filamento do tubo de 200 mA e ajuste da janela pulmonar centro e largura, respectivamente, de -600/1600 UH, com dose de radiação de 23,3 mGy, dentro da recomendação das diretrizes brasileiras e europeias.

### 3.1.4 *Patches de Sorensen et al. (2010)*

São 168 regiões de interesse (ROI) com dimensões 61 x 61 pixels, recortadas a partir dos *slices* de Sorensen *et al.* (2010) e classificadas como: 59 tecidos normais (NT), nunca fumantes; 50 com enfisema centroacinar (CLE) e 59 com enfisema parasseptal (PSE), entre fumantes saudáveis e com DPOC. Na Figura 11, são apresentados exemplos dessas imagens.

Figura 11 - Exemplos dos *patches* de Sorensen *et al.* (2010).



Fonte: Sorensen *et al.* (2010). Os *patches* de Sorensen *et al.* (2010) foram nomeados pelo mesmo autor por serem recortes 61 x 61 pixels dos *slices* 512 x 512. Os *patches* são classificados em três classes, como tecido normal (a), com enfisema centroacinar (b) e com enfisema parasseptal (c).

## 3.2 Métodos de extração de atributos

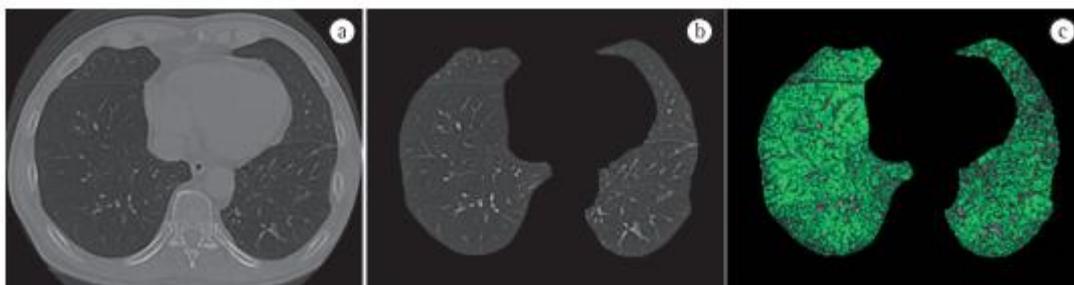
Foram testados dois métodos de extração de atributos para criar vetores de características a partir de imagens de TCAR, que serviram como entrada na etapa de classificação dos tipos e dos níveis de severidade de enfisemas.

Utilizou-se o *Local Binary Pattern* (LBP) como primeiro método de extração de atributos. Para isso, cada imagem foi inserida na função “*extractLBPFeatures*” do Matlab 2017a, resultando em vetores de 59 atributos para cada imagem, sem realizar pré-processamento.

O segundo método de extração de atributos utilizou análise de texturas. Para isso, foi necessário realizar o procedimento descrito a seguir.

Primeiro, aplicou-se o Sistema para a Detecção e a quantificação de Enfisema Pulmonar (SISDEP), como método automático de segmentação dos pulmões e identificação de regiões enfisematosas ou saudáveis (FELIX, 2009). O SISDEP permitiu, assim, a visualização de regiões com enfisemas a partir da ferramenta de máscara colorida, que as discrimina das áreas normais. Outros métodos de detecção de regiões enfisematosas são apresentados por Vasconcelos *et al.* (2010), Singh (2005), Prasad, Sowmya e Kock (2004) e Friman *et al.* (2002). A segmentação dos pulmões e identificação de regiões enfisematosas com o SISDEP resultaram em imagens, como as apresentadas na Figura 12.

Figura 12 - Exemplo de segmentação dos pulmões e da aplicação de máscara colorida.

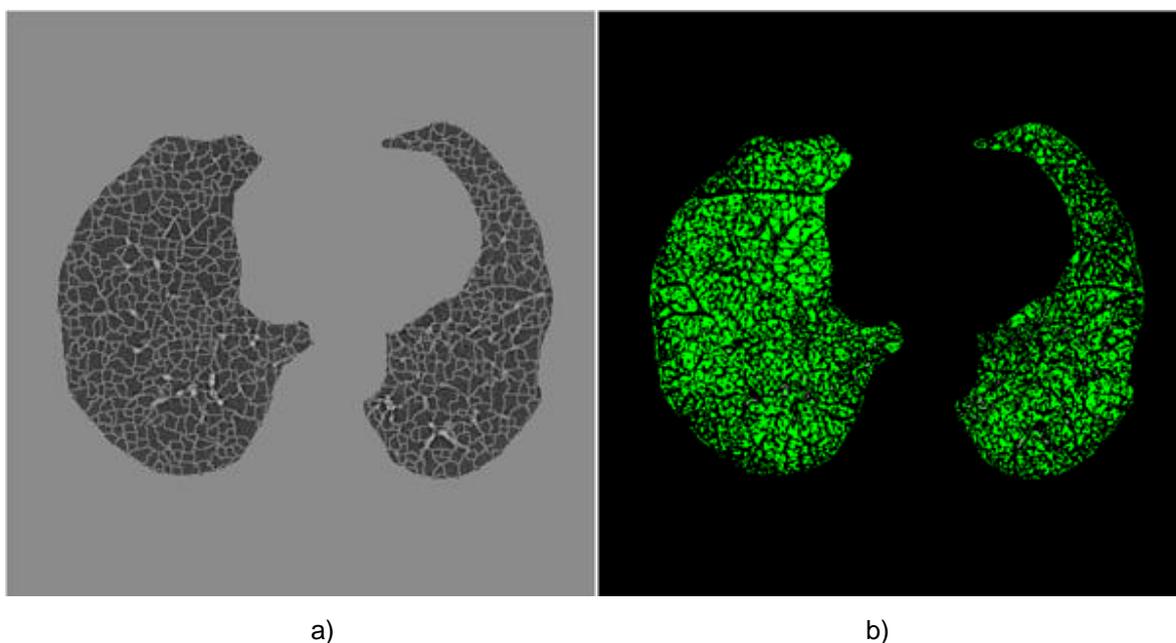


Fonte: Felix (2009). Segmentação de uma imagem de TCAR de paciente com DPOC utilizando o SISDEP, a) imagem original, b) imagem de segmentação dos pulmões; e c) segmentação dos pulmões com a máscara colorida (verde claro) e identificação de regiões com enfisema. Fonte: Felix (2009).

Segundo, depois da segmentação, aplicou-se a função “*watershed*” do Matlab, resultando em regiões pequenas “super-segmentadas”. Então, para reduzir a presença das regiões menores, que não permitem a extração das medidas de textura, foi aplicada a Morfologia Matemática nas imagens, a partir da abertura morfológica e posterior fechamento morfológico com elemento estruturante 3 x 3 quadrado, resultando em sub-imagens maiores, como as apresentadas na Figura 13 (a-b), em

que é possível identificar sub-regiões ao compará-las, respectivamente, com as Figuras 12b e 12c.

Figura 13 - Exemplo de sub-segmentação dos pulmões.



Fonte: autor. Segmentação da imagem de TCAR dos pulmões direito e esquerdo e segmentação em sub-regiões com *watershed* e Morfologia Matemática; b) aplicação de máscara colorida para identificação de enfisema pulmonar a partir da imagem a).

Terceiro, depois da sub-segmentação dos pulmões e da identificação de sub-imagens enfisematosas pelo SISDEP, a técnica de análise de textura foi utilizada, para extração de atributos de tons de cinza e de área (HARALICK, 1979), para cada imagem das sub-regiões. Esse passo tem a finalidade de extrair informações relevantes para discriminar tecidos normais de tecidos com enfisema, assim como diferenciar os enfisemas de acordo com sua classe. Atributos de forma não foram mensurados, visto que as sub-regiões não possuem tamanhos ou formatos específicos (BENTO, 2013).

A análise de textura é eficiente na quantificação de atributos em imagens com enfisemas pulmonares, como demonstra Sorensen *et al.* (2010), Dharmagunawardhana *et al.* (2014), e Mendoza *et al.* (2012). Os atributos de textura de primeira ordem, utilizados para quantificação das sub-regiões, foram média, desvio padrão, *skewness*, *kurtosis*, energia, entropia; e os de segunda ordem foram: autocorrelação, contraste, correlação, covariância, energia e entropia do vetor soma

de níveis de cinza, homogeneidade, probabilidade máxima, *cluster shade* e *cluster prominence*.

A partir da Figura 13a, foram extraídas características de amostras de imagens de sub-regiões baseadas nas medidas de textura de primeira e segunda ordens, e são apresentados alguns exemplos na Tabela 2.

Tabela 2 - Medidas de textura de exemplos de sub-imagens dos pulmões.

Medidas de textura	recorte 7 	recorte 22 	recorte 487 	recorte 535 
Média	-906,92	-915,78	-869,23	-849,41
Desvio-padrão	124,63	50,26	104,42	128,41
Skewness	2,43	0,90	1,58	1,50
Curtose	5,17	1,04	3,20	1,89
Energia	0,019	0,010	0,007	0,008
Entropia	5,85	6,70	7,27	7,08
Autocorrelação	$5,11 \times 10^5$	$3,51 \times 10^5$	$4,51 \times 10^5$	$4,28 \times 10^5$
Contraste	$1,36 \times 10^5$	$9,35 \times 10^4$	$9,09 \times 10^4$	$7,12 \times 10^4$
Correlação	$9,22 \times 10^9$	$1,68 \times 10^9$	$4,82 \times 10^9$	$4,32 \times 10^9$
Covariância	$5,11 \times 10^5$	$3,51 \times 10^5$	$4,51 \times 10^5$	$4,28 \times 10^5$
Energia do vetor	0,030	0,171	0,088	0,082
Entropia do vetor	7,582	6,418	8,053	7,707
Homogeneidade	0,186	0,423	0,304	0,296
Probabilidade máxima	0,171	0,413	0,296	0,287
<i>Cluster shade</i>	$4,08 \times 10^9$	$2,70 \times 10^9$	$3,47 \times 10^9$	$3,18 \times 10^9$
<i>Cluster prominence</i>	$7,80 \times 10^{12}$	$4,96 \times 10^{12}$	$6,51 \times 10^{12}$	$5,81 \times 10^{12}$

Fonte: autor. Medidas de textura de alguns exemplos de sub-imagens dos pulmões extraídas da Figura 13a.

### 3.3 Métodos de classificação dos tipos e severidades de enfisemas

No último passo metodológico, comparou-se a combinação dos métodos de extração de atributos LBP ou análise de textura como entrada de dados dos classificadores OPF e MLP, utilizando cada banco de imagens ou a combinação deles, a fim de classificar os tipos de enfisema: tecido normal (NT), enfisema centroacinar (CLE), enfisema parasseptal (PSE) e enfisema panlobular (PLE), apresentados na

Figura 1; e os níveis de severidade de enfisema: sem enfisema (NOE), enfisema mínimo (MIN), suave (MIL), moderado (MOD), severo (SEV) e muito severo (VSE), apresentados na Figura 8.

Os resultados dos classificadores OPF e MLP são comparados não apenas entre si, como também com resultados de outros classificadores apresentados no estado da arte (Seção 1.2).

Assim, conclui-se a apresentação das metodologias de classificação de tipos e severidades de enfisemas aplicadas durante este trabalho.

## 4 RESULTADOS E DISCUSSÕES

Para analisar a classificação e performance do OPF e MLP, a partir da extração de atributos de imagens por análise de textura ou LBP, para classificação de tipos e severidade de enfisemas, muitos experimentos foram conduzidos combinando bases diferentes.

Os algoritmos foram implementados no Matlab R2017a, e os experimentos foram realizados em um computador com as seguintes características: Intel® Core™ i7-5500U CPU com 2,40 GHz, 8 GB RAM, SSD SanDisk 240 GB, GPU GeForce 920M (acelerador CUDA) e sistema operacional Windows 10 Home.

### 4.1 Classificação de tipos de enfisemas por banco de imagens

Vários testes foram realizados, combinando as quatro bases de imagens apresentadas na Seção 3.1, para avaliar o acerto na classificação de tipos de enfisemas, combinando cada classificador, OPF supervisionado ou MLP, a um método de extração de atributos, LBP ou análise de textura, apresentando o acerto máximo resultante na Tabela 3.

O OPF supervisionado foi testado através da LibOPF 2.1 (PAPA, FALCÃO e SUZUKI, 2009) e configurado para 50% de dados de treinamento e 50% de dados de teste, apresentando, na Tabela 3, o melhor resultado após a repetição do mesmo teste por dez vezes. O MLP teve o código implementado e foi configurado para conjuntos de treinamento e de teste que variam entre 20% e 80% dos dados, com até 2000 iterações, 59 neurônios na camada oculta e taxa de aprendizagem de 0,1, apresentando o melhor resultado na Tabela 3. Os conjuntos de treinamento e testes foram gerados de forma aleatória em cada novo teste.

Entre os métodos de extração de atributos das imagens, o uso do LBP apresenta resultados sempre melhores que a análise de texturas, na classificação tanto com OPF, quanto com MLP (Tabela 3). Isso se deve ao LBP ser invariante à rotação da imagem e à luminosidade. Ao se comparar pixel com pixel, por meio do LBP, permanece o mesmo padrão da imagem, como se não houvesse variação da rotação ou luminosidade. Situação diferente da extração de características por análise de textura, que sofrem com esses problemas, mas não os resolvem, o que dificulta a classificação das imagens de TCAR por meio dessa extração de características.

Tabela 3 - Acerto máximo na classificação de tipos de enfisemas.

Bancos de imagens	Número de imagens	Classes	Método de extração de atributos	OPF	MLP
<i>Slices</i> de Sorensen <i>et al.</i> (2010)	115	4	LBP	72,08%	<b>100%</b>
			Análise de textura	57,78%	56,9%
Fortaleza (2006) e Winkeler (2006)	120	3	LBP	70,13%	<b>100%</b>
			Análise de textura	66,15%	67%
<i>Slices</i> de Sorensen <i>et al.</i> (2010), Fortaleza (2006) e Winkeler (2006)	235	4	LBP	73,83%	<b>100%</b>
<i>Patches</i> de Sorensen <i>et al.</i> (2010)	168	3	LBP	79,39%	<b>100%</b>
			Análise de textura	62,58%	66,3%

Fonte: autor. Classificação de tipos de enfisemas por banco de imagens, conforme combinação de cada método de extração de atributos (LBP e análise de textura) com cada classificador (OPF e MLP). São apresentados resultados de acerto máximo, a fim de compará-los aos resultados de acerto máximo do estado da arte (Tabela 1).

Várias estratégias foram adotadas para melhorar os resultados da análise de textura. Entretanto, o método de extração de atributos das sub-regiões dos pulmões segmentados teve problemas na classificação dessas sub-regiões, visto que nem sempre uma sub-região possuía o mesmo tipo de enfisema do pulmão. Isso é possível, por exemplo, porque podem existir sub-regiões saudáveis em um pulmão comprometido com qualquer um dos três tipos de enfisemas da Figura 1. Por conta disso, os resultados da classificação utilizando atributos da análise de textura devem ter sido prejudicados.

A combinação do LBP e OPF, chamado método LBP-OPF, melhora pouco o próprio resultado à medida que se aumenta o tamanho do banco de imagens (Tabela 3), pois obtém-se acerto maior de 73,83% para a junção das 235 imagens dos *slices* de Sorensen *et al.* (2010), Fortaleza (2006) e Winkeler (2006), em comparação com 72,08% de acerto apenas para as 115 imagens dos *slices* de Sorensen *et al.* (2010) e 70,13% de acerto para as 120 imagens da junção de Fortaleza (2006) e Winkeler (2006). Matrizes de confusão do método LBP-OPF foram criadas, segundo os resultados de classificação da Tabela 3, e são apresentadas no Apêndice.

A combinação do LBP e MLP, chamado de método LBP-MLP, manteve a taxa de 100% de acerto na classificação de tipos de enfisema, para os conjuntos de 20%,

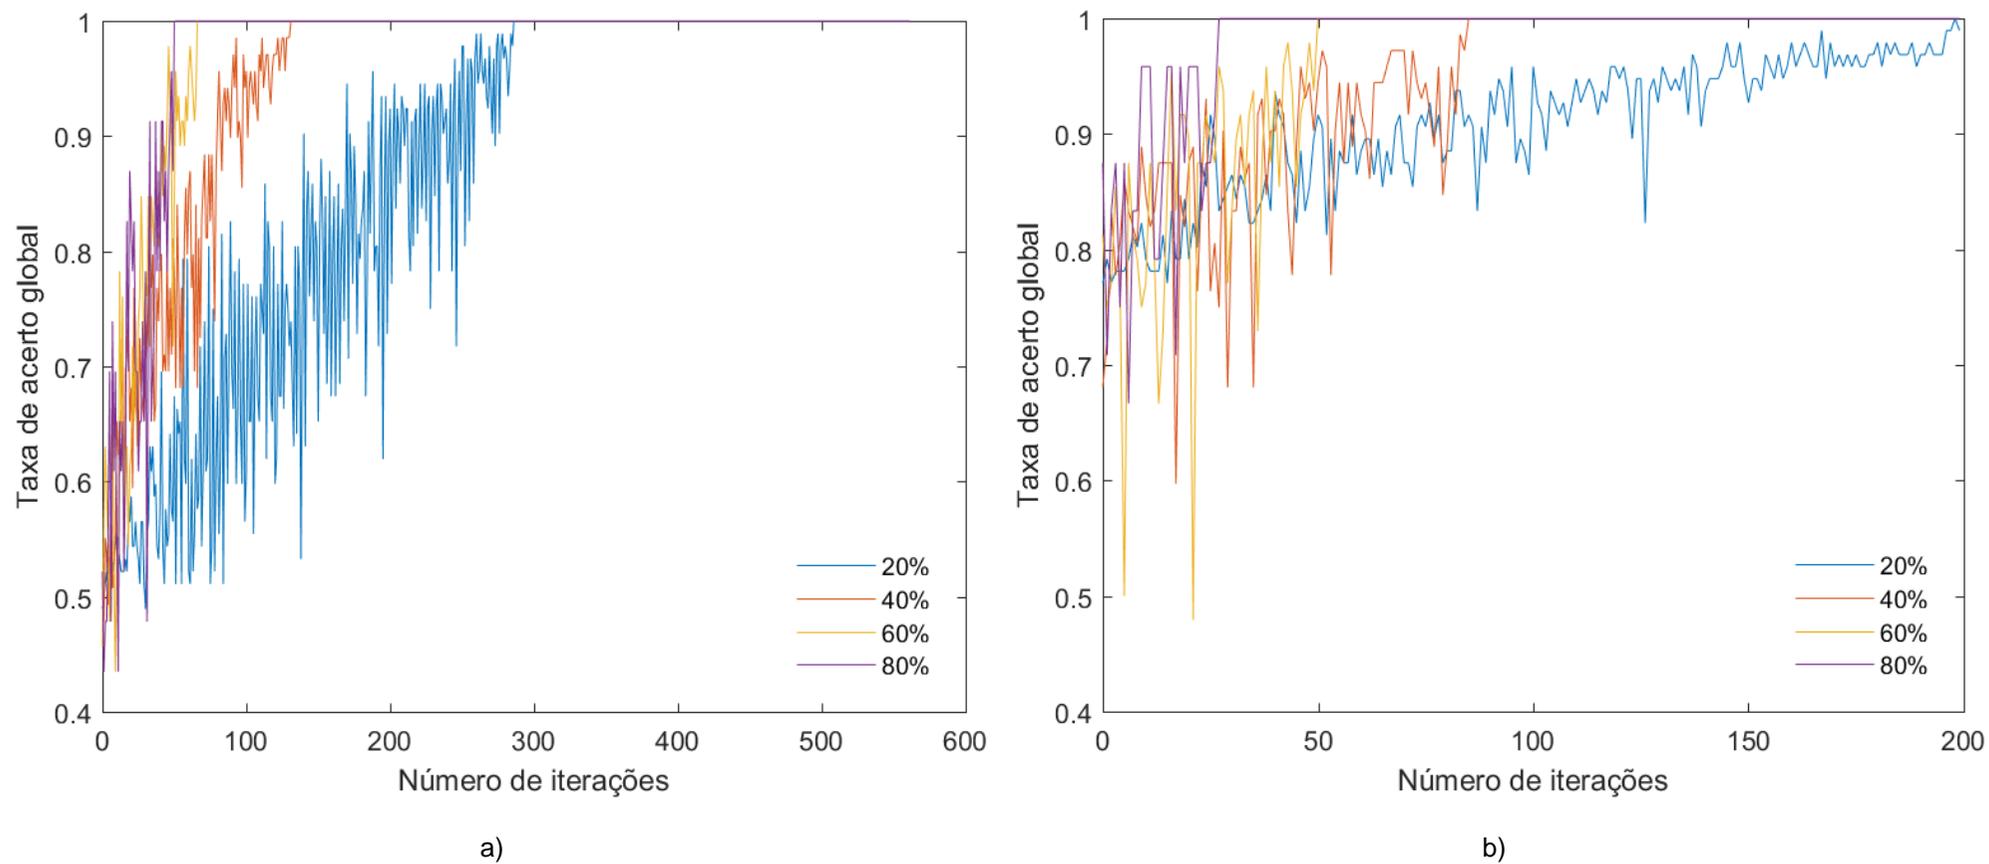
40%, 60% e 80% das imagens para treinamento (Figura 14b-c), classificando tanto as quatro bases de imagens testadas (Tabela 3), quanto três ou quatro tipos de enfisemas.

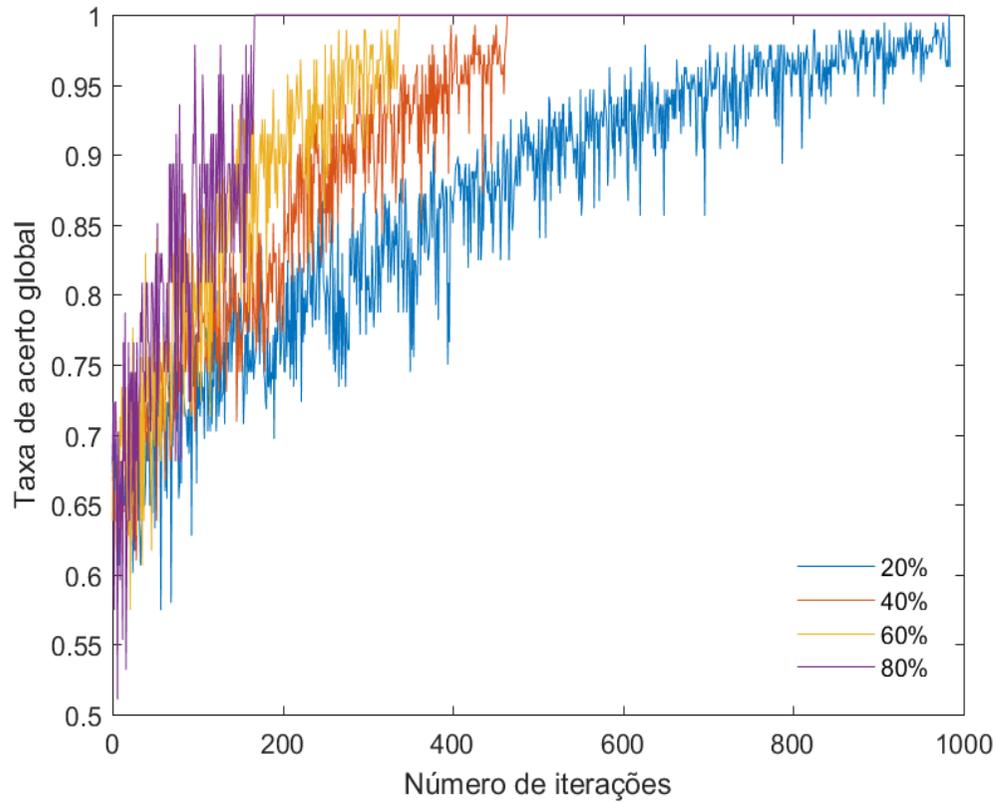
O LBP-MLP alcança excelentes resultados de classificação de tipos de enfisemas, independente da união de imagens de diferentes bases em um mesmo teste, como mostram as Figuras 14(b-c), que unem duas e três bases de imagens respectivamente. Nenhum trabalho do estado da arte (Seção 1.2) une bases diferentes em um mesmo teste, demonstrando, assim, a robustez do LBP-MLP.

O método LBP-MLP foi comparado a outros da literatura para avaliar sua qualidade. O LBP-MPL alcançou o maior e melhor resultado para classificação dos *patches* de Sorensen *et al.* (2010), 100% de acerto, comparados aos da literatura (Tabela 1), que, para as mesmas imagens, obtiveram, respectivamente, os acertos de 98,18% (TUBA, TUBA e SIMIAN, 2017), 99% (IBRAHIM e MUKUNDAN, 2015), 84,24% (KARABULUT e IBRIKCI, 2015), 94,6% (DHARMAGUNAWARDHANA *et al.*, 2014) e 95,2% (SORENSEN, SHAKER E BRUIJNE, 2010).

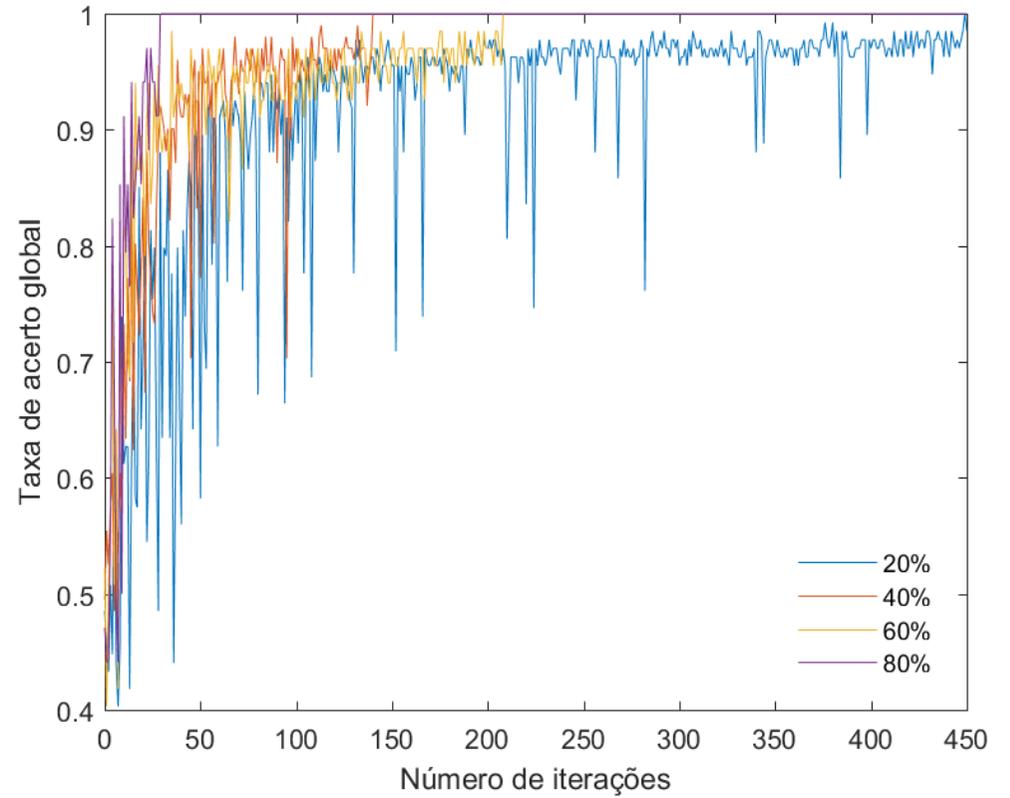
O método LBP-OPF apresentou resultado inferior aos desses outros autores, de apenas 72,08% de acerto. Apresenta-se apenas a acurácia do LBP-MLP, porque classificou corretamente todas as classes de enfisema, diferentemente dos métodos dos outros autores, que apresentam matrizes de confusão, a fim de mostrar os acertos na classificação de cada tipo de enfisema.

Figura 14 - Taxa de acerto na classificação de tipos de enfisema pelo LBP-MLP.





c)



d)

Fonte: autor. Taxa de acerto na classificação de tipos de enfisemas do método LBP-MLP pelo número de iterações necessárias para alcançar 100% de acerto nas sequências de treinamento: 20%, 40%, 60% e 80% das imagens de todas as combinações das bases: a) *slices* de Sorensen *et al.* (2010); b) Fortaleza (2006) e Winkeler (2006); c) *slices* de Sorensen *et al.* (2010), Fortaleza (2006) e Winkeler (2006); e d) *patches* de Sorensen *et al.* (2010).

O efeito do número de iterações sobre a performance do classificador LBP-MLP aplicado aos *patches* de Sorensen *et al.* (2010) foi investigado (Figura 14d), atingindo 100% de acerto em 450 iterações (20% dos *patches* para treinamento), 141 iterações (40%), 209 iterações (60%) e 30 iterações (80%). Superou os resultados de Karabulut e Ibrikci (2015), que alcançaram 84,25% de acerto máximo após 20.000 iterações, utilizando 80% *patches* para treinamento e 20% para testes, contra 100% de acerto do LBP-MLP, em apenas 30 iterações.

O LBP-MLP teve resultados melhores que os desse autor, tanto na mesma divisão de dados, quanto em conjuntos de treinamento menores, 20%, 40% e 60% (em até 450 iterações), que são mais difíceis de classificar corretamente, uma vez que os respectivos conjuntos de testes são diversas vezes maiores, 80%, 60% e 40%, que os desse autor.

Enquanto o método de análise de textura e MLP obteve acerto máximo de 68,62%, após 100.000 iterações, em 2h2min20s (7340 segundos), com 80% dos *patches* de Sorensen *et al.* (2010) para treinamento e 20% para testes, a Tabela 4 demonstra que o LBP-MLP atinge a performance mais adequada para um sistema automático de auxílio ao diagnóstico médico, com acerto de 100%, em apenas 0,62 segundos sob os mesmos tamanhos de treinamento e teste, ambos utilizando a GPU como processador paralelo para diminuição do tempo de processamento, como demonstra Karabulut e Ibrikci (2015).

Tabela 4. Tempo de execução em segundos do método LBP-MLP até 100% de acerto.

Bancos de imagens	Número de imagens	Número de classes testadas	Tamanho da sequência de treinamento			
			20%	40%	60%	80%
<i>Slices</i> de Sorensen <i>et al.</i> (2010)	115	4	5,5775	2,5349	1,3424	1,0522
Fortaleza (2006) e Winkeler (2006)	120	3	3,6824	1,7412	0,9517	0,6178
<i>Slices</i> de Sorensen <i>et al.</i> (2010), Fortaleza (2006) e Winkeler (2006)	235	4	21,9608	10,9744	8,4649	4,5194
<i>Patches</i> de Sorensen <i>et al.</i> (2010)	168	3	9,3303	2,9142	4,3839	<b>0,6280</b>

Fonte: autor. Tempo de execução em segundos do método LBP-MLP para atingir 100% de acerto em cada combinação das bases de imagens, por cada tamanho de sequência de treinamento.

Segundo a pesquisa do estado da arte (Seção 1.2), nem mesmo Sorensen, Shaker e Brujine (2010) classificaram os *slices* de Sorensen *et al.* (2010), visto que os trabalhos que utilizam a base de dados desse autor classificaram apenas as regiões de interesse das imagens, os *patches* de Sorensen *et al.* (2010).

A classificação dos *slices* é muito mais complexa, motivo de não ser abordada pelos outros trabalhos que se restringiram a classificar os *patches*, porque são as imagens originais de TCAR dos pulmões, logo têm muito mais regiões da imagem com informações irrelevantes para a classificação, como: a região fora do corpo, a caixa torácica, a região fora dos pulmões e as regiões dentro dos próprios pulmões, como vasos sanguíneos e vias aéreas, que apresentam tecidos com densidades diferentes, principalmente em relação ao tipo de enfisema.

Mesmo assim, o método LBP-MLP obteve 100% de acerto (Tabela 3) ao classificar os *slices*, tanto após a segmentação dos pulmões, quanto sem segmentá-los e sem nenhum pré-processamento, em 287 iterações (Figura 14a), 5,58 segundos (Tabela 4), não só para 20% dos *slices* para treinamento e 80% para testes, como também para os conjuntos de 20%, 40% e 60% de treinamento e restante para testes.

Dessa forma, gera, na literatura, um novo campo de classificação de tipos de enfisemas sem recortes de regiões de interesse (ROI), mas sim classificando as imagens originais de TCAR.

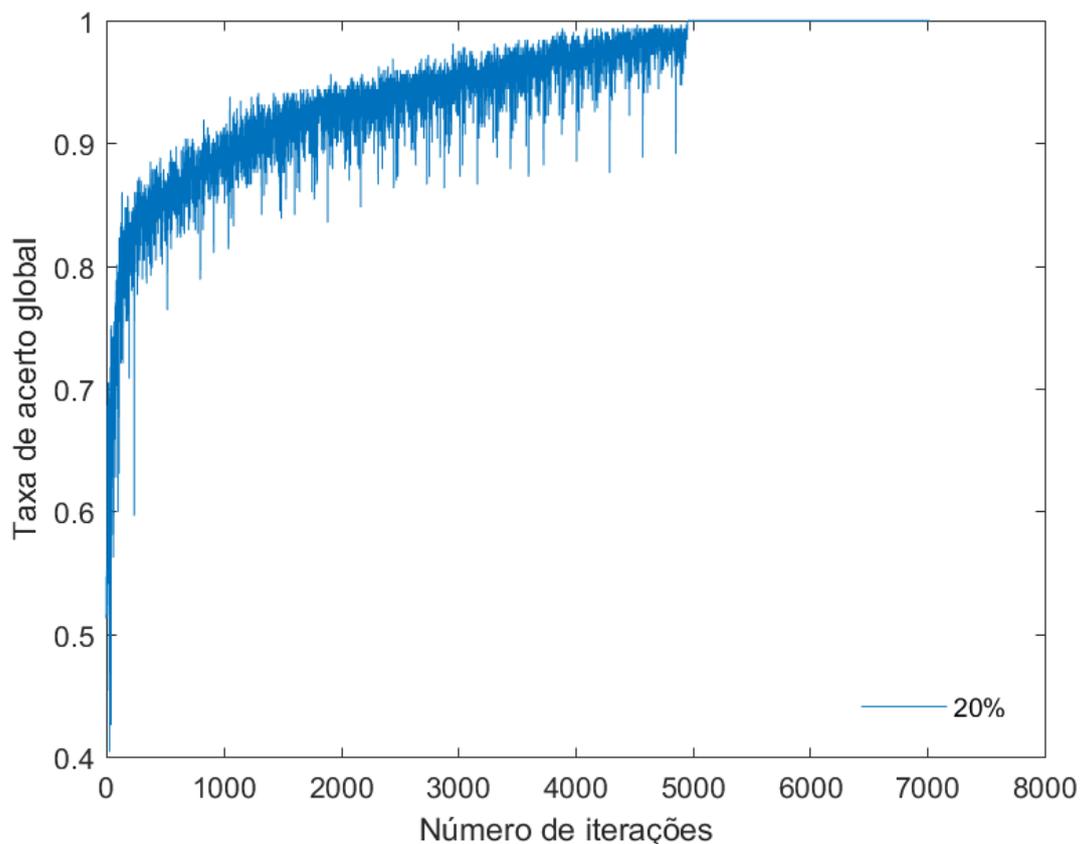
Para tanto, o método LBP-MLP também obteve 100% de acerto não apenas ao classificar as imagens originais de TCAR de Fortaleza (2006) e Winkeler (2006), em 199 iterações e 3,68 segundos, como também ao uni-las aos *slices* de Sorensen *et al.* (2010), classificando essas três bases de imagens em 984 iterações e 21,96 segundos, mesmo sendo imagens obtidas de equipamentos diferentes. Assim, demonstra-se a robustez, eficácia e alta eficiência do método LBP-MLP ao classificar os tipos de enfisemas a partir de imagens originais de TCAR (Figura 14, Tabela 3 e 4).

Além disso, em uma abordagem de teste, juntou-se os *patches* 61 x 61 de Sorensen *et al.* (2010) às três bases de imagens 512 x 512: *slices* de Sorensen *et al.* (2010), Fortaleza (2006) e Winkeler (2006), formando um conjunto de 403 imagens, que foram classificadas de acordo com 4 tipos de enfisemas.

Obteve-se 100% de acerto para conjunto de treinamento de 20% das imagens e 80% para teste, conforme apresentado na Figura 15, em 152,16 segundos e 4955

iterações, demonstrando a robustez, eficácia e eficiência do LBP-MLP na classificação de tipos de enfisemas, combinando tanto recortes de regiões de interesse, quanto imagens originais dos pulmões, abrindo um novo campo na classificação de tipos de enfisemas.

Figura 15 - Acerto na classificação de tipos de enfisemas pelo LBP-MLP em regiões de interesse e imagens originais de TCAR.



Fonte: autor. Junção das regiões de interesse dos patches de Sorensen *et al.* (2010) com as imagens de TCAR dos pulmões dos *slices* de Sorensen *et al.* (2010), Fortaleza (2006) e Winkeler (2006), demonstrando acerto de 100% ao utilizar 20% das imagens para treinamento e 80% para testes.

## 4.2 Classificação da severidade de enfisemas em imagens de TCAR

Os testes foram realizados para avaliar o acerto na classificação dos seis níveis de severidade de enfisemas dos *slices* de Sorensen *et al.* (2010), combinando cada classificador, OPF supervisionado ou MLP, a um método de extração de atributos, LBP ou análise de textura, apresentando o acerto máximo resultante na

Tabela 5. O OPF e o MLP foram configurados da mesma maneira que na classificação de tipos de enfisemas, apresentados na seção anterior (Seção 4.1).

O LBP permaneceu apresentando resultados melhores que a análise de texturas para extração de características das imagens, tanto na classificação com OPF, quanto com MLP, de acordo com o que é mostrado na Tabela 5. Isso se deve aos mesmos motivos de invariabilidade de rotação e luminosidade, explicados na seção anterior.

Tabela 5 - Acerto na classificação do nível de severidade de enfisemas.

Bancos de imagens	Número de imagens	Número de classes testadas	Método de extração de atributos	OPF	MLP
<i>Slices</i> de Sorensen <i>et al.</i> (2010)	115	6	LBP	59,42%	100%
			Análise de textura	56,15%	51,43%

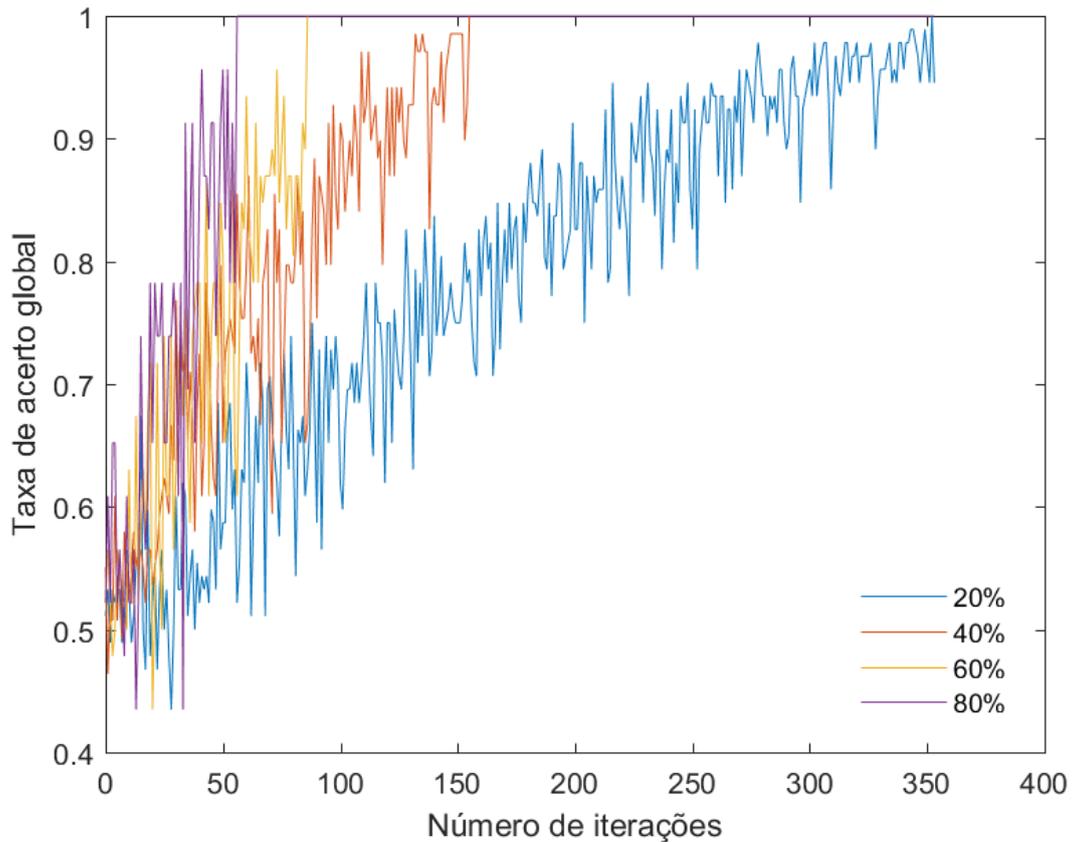
Fonte: autor.

Da mesma forma, a análise de textura teve seu resultado prejudicado, porque ocorreram problemas na extração de características das sub-regiões, pelos mesmos motivos apresentados na seção anterior, visto que nem sempre uma sub-região possuía o mesmo tipo de enfisema ou nível de severidade do pulmão.

O método LBP-MLP também obteve 100% de acerto na classificação de níveis de severidade de enfisema para os *slices* de Sorensen *et al.* (2010), com os conjuntos de treinamento de 20%, 40%, 60% e 80% das imagens e o restante das imagens para teste. Em comparação ao estado da arte, o LBP-MPL alcançou o maior e melhor resultado, visto que Kurugol, Washko e Estepar (2014) obtiveram 71% de acerto, e Mendonza *et al.* (2012) obtiveram 66,4% de acerto. O método LBP-OPF apresentou resultado inferior ao desses outros autores, de apenas 59,42% de acerto, cuja matriz de confusão é apresentada no Apêndice.

A performance do método LBP-MLP aplicado aos *slices* de Sorensen *et al.* (2010) é apresentada a cada iteração na Figura 16, atingindo 100% de acerto em todos os tamanhos de conjuntos de imagens testados, com 353 iterações em 7,41 segundos (20% dos *slices* para treinamento), 156 iterações em 3,45 segundos (40%), 87 iterações em 1,78 segundos (60%) e 57 iterações em 1,08 segundos (80%), utilizando a GPU como processador paralelo e o restante dos *slices* para testes.

Figura 16 - Taxa de acerto na classificação da severidade de enfisema pelo LBP-MLP.



Fonte: autor. Taxa de acerto na classificação de níveis de severidade de enfisemas do método LBP-MLP pelo número de iterações necessárias para alcançar 100% de acerto nas sequências de treinamento: 20%, 40%, 60% e 80% das imagens dos *slices* de Sorensen *et al.* (2010).

O LBP-MLP, com acerto de 100%, demonstra-se um método eficaz e robusto para classificação de níveis de severidade de enfisemas.

## 5 CONCLUSÕES E TRABALHOS FUTUROS

Desenvolveu-se um método que é capaz de classificar automaticamente tipos e níveis de severidade de enfisemas com mais precisão do que os métodos presentes na literatura. Com essa automação no mesmo nível dos médicos especialistas, acredita-se que essa tecnologia pode beneficiar, enormemente, não apenas a análise clínica, como também fornecer melhor serviço de saúde e aumentar o acesso ao diagnóstico médico especializado em partes do mundo que não têm acesso a médicos radiologistas, situação enfrentada por dois terços da população global (MOLLURA *et al.*, 2010).

Foram propostos dois métodos de classificação, para facilitar a investigação e diagnóstico da heterogeneidade de quatro tipos e de seis níveis de severidade de enfisemas, possibilitando a melhor interpretação de especialistas neste diagnóstico.

Comparado a outros métodos da literatura, principalmente com os que usam LBP, por serem os melhores, os resultados de um dos métodos propostos, chamado LBP-MLP, com extração de características por LBP e classificação com *Multilayer Perceptron* (MLP), foram melhores do que todos os outros métodos relatados na literatura. Supera esses resultados, na performance geral de classificação, com 100% acerto, para os conjuntos de 20%, 40%, 60% e 80% das imagens para treinamento e o restante para testes, gerados aleatoriamente em cada novo teste.

Portanto, o LBP-MLP classifica com precisão de 100% os pulmões normais (NT), bem como os casos com as classes de enfisema: panlobular (PLE), parasseptal (PSE) e centroacinar (CLE); tanto em dois bancos privados (FORTALEZA, 2006; WINKELER, 2006), quanto no banco *online* de imagens de pulmões com enfisemas de Sorensen *et al.* (2010), obtendo esse acerto em ambos os casos das imagens originais dos pulmões (*slices* 512 x 512) e dos cortes de regiões de interesse (*patches* 61 x 61).

Além disso, o método LBP-MLP também obteve 100% de acerto na classificação da severidade dos enfisemas das imagens de Sorensen *et al.* (2010), em uma abordagem que analisa o progresso natural da doença.

Esses resultados demonstram que o método proposto LBP-MLP é promissor pelo desempenho de excelente performance. Converte o algoritmo de forma eficiente e efetiva, em todos os casos, independentemente do tamanho da base de dados que

foram testadas e da proporção do conjunto de treinamento e teste, fornecendo uma ferramenta de diagnóstico que classifica com êxito os tipos e severidades de enfisemas em imagens de TCAR.

Comparado ao classificador *Optimum Path-Forest* (OPF), os resultados da classificação usando os cortes das imagens (61 x 61) do banco de Sorensen *et al.* (2010) indicam que o vetor de características LBP atinge 100% de acerto usando o classificador MLP, enquanto o OPF alcança apenas 60,5%.

Diferentes tipos de enfisema foram descritos não só através de *Local Binary Patterns* (LBP), como também por meio de análise de texturas. Por outro lado, aplicar a segmentação dos pulmões e sub-segmentá-los, extraíndo vetores de características região-por-região, por meio de análise de textura, obteve acerto menor na classificação de tipos e severidade de enfisemas, usando os classificadores MLP (66,3%) ou OPF (62,58%), comparado com o estado da arte.

Em trabalhos futuros, avaliações do método LBP-MLP devem ser consideradas para outras bases públicas de imagens de pulmões com enfisemas ou de dados de testes clínicos, bem como para outras doenças pulmonares, além de testar a classificação com outros classificadores supervisionados, como SVM.

## REFERÊNCIAS

- BARBOSA, C. V. **Reconhecimento de padrões de sinais ultrassônicos para caracterização microestrutural utilizando Floresta de Caminhos Ótimos**. Dissertação (mestrado), Universidade de Fortaleza, Programa de Pós-Graduação em Informática Aplicada, 2015.
- BENTO, M. P. **Análise de lesões na substância branca do cérebro a partir de imagens de ressonância magnética**. Dissertação (mestrado), Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, 2013.
- BORSATO, Dionísio; Moreira, Ivanira; Nobrega, Marcelo Medre; Moreira, Mariete Barbosa; Dias, Gabriel Henrique; Silva, Rui Sérgio dos Santos Ferreira da & Bona, Evandro. (2009). **Aplicação de redes neurais artificiais na identificação de gasolinas adulteradas comercializadas na região de Londrina - Paraná**. Química Nova, 32(9), 2328-2332. Disponível em: <<https://dx.doi.org/10.1590/S0100-40422009000900017>>. Acesso em: 19 nov. 2017.
- CASTELO FERNÁNDEZ, C. C. **Novos algoritmos de aprendizagem para classificação de padrões utilizando florestas de caminhos ótimos**. Dissertação (mestrado), Universidade Estadual de Campinas, Instituto de Computação, 2011.
- CAVALCANTE, Tarique da Silveira; Cortez, Paulo César; Almeida, Thomaz Maia de; Felix, John Hebert da Silva & Holanda, Marcelo Alcantra. (2013). **Segmentação automática 2D de vias aéreas em imagens de tomografia computadorizada do tórax**. Revista Brasileira de Engenharia Biomédica, 29(4), 389-403. Disponível em: <<https://dx.doi.org/10.4322/rbeb.2013.038>>. Acesso em: 19 nov. 2017.
- COUTINHO, Eluã Ramos; SILVA, Robson Mariano; DELGADO, Angel Ramon Sanchez. (2016). **Utilização de Técnicas de Inteligência Computacional na Predição de Dados Meteorológicos**. Revista Brasileira de Meteorologia, 31(1), 24-36. Disponível em: <<https://dx.doi.org/10.1590/0102-778620140115>>. Acesso em: 19 nov. 2017.
- DA COSTA E SILVA, V. L.; David, A. **Building blocks for tobacco control: a handbook**. Geneva, 2004. World Health Organization. Acesso em: 16 jan. 2015. Disponível em: <[http://www.who.int/tobacco/resources/publications/tobaccocontrol\\_handbook/en/](http://www.who.int/tobacco/resources/publications/tobaccocontrol_handbook/en/)>. Acesso em: 19 nov. 2017.
- DECRAMER, M; JANSSENS, W. **Apparatus For Automatically Diagnosing Emphysema**. US2013165811, 27 jun. 2013. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?II=394&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20130627&CC=US&NR=2013165811A1&KC=A1](https://worldwide.espacenet.com/publicationDetails/biblio?II=394&ND=3&adjacent=true&locale=en_EP&FT=D&date=20130627&CC=US&NR=2013165811A1&KC=A1)>. Acesso em: 27 nov. 2017.
- DHARMAGUNAWARDHANA, C.; S. Mahmoodi, M. Bennett e M. Niranjan. **Quantitative analysis of pulmonary emphysema using isotropic Gaussian**

**Markov random fields.** 2014 International Conference on Computer Vision Theory and Applications (VISAPP), Lisbon, Portugal, 2014, pp. 44-53.

FORTALEZA, S. C. **Efeitos da Administração de Pressão Positiva Contínua em Vias Aéreas de Modo não Invasivo Sobre a Aeração do Parênquima Pulmonar em Pacientes com Doença Pulmonar Obstrutiva Crônica.** Dissertação (mestrado). Universidade Federal do Ceará, 2006.

FELIX, J. H. S. **Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar.** Dissertação (mestrado), Universidade Federal do Ceará, Departamento de Teleinformática, 2007.

FELIX, J. H. S.; Cortez, P. C.; Costa, R. C. S.; Fortaleza, S. C. B.; Pereira, E. D. B.; HOLANDA, M. A. Avaliação computacional de enfisema pulmonar em TC: comparação entre um sistema desenvolvido localmente e um sistema de uso livre. **Jornal Brasileiro de Pneumologia**, São Paulo, v. 35, n. 9, p. 868-876, 2009.

FELIX, J.H.S.; Cortez, P.C.; Holanda, M.A. Sistema automático para quantificação e visualização aeração da pulmonar em imagens de tomografia computadorizada do tórax: Sistema de Análise de Imagens Pulmonares SAIP. **Revista Brasileira de Engenharia Biomédica**, v.26, n.3, p. 195-208, 2010

FREITAS, Greice Martins de, Papa, João Paulo, Avila, Ana Maria Heuminski de, Pinto, Alexandre Xavier Falcão Hilton Silveira, & Pinto, Hilton Silveira. (2010). **Estimativa de ocorrência de precipitação em áreas agrícolas utilizando floresta de caminhos ótimos.** Revista Brasileira de Meteorologia, 25(1), 13-23. Disponível em: <<https://dx.doi.org/10.1590/S0102-77862010000100002>>. Acesso em: 19 nov. 2017.

FRIMAN, O.; M. Borga, M. Lundberg, U. Tuyen and H. Knutsson. **Recognizing emphysema - a neural network approach.** *Object recognition supported by user interaction for service robots*, 2002, pp. 512-515 vol.1. doi: 10.1109/ICPR.2002.1044781.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens.** 3ª ed, São Paulo: Pearson, Prentice Hall, 2010.

HARALICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, Vol. 67, No. 5. (1979), pp. 786-804.

HEARD, B. E.; Khachaturov, V.; Otto, H.; Putov, N. V.; Sobin, L. The morphology of emphysema, chronic bronchitis, and bronchiectasis: definition, nomenclature, and classification. **Journal of Clinical Pathology**, 32(9), 882–892, 1979.

IBRAHIM, M. A.; R. MUKUNDAN. **Analysis of scale variations of local features for accurate classification of Emphysema images.** 2015 8th International Conference on Biomedical Engineering and Informatics (BMEI), Shenyang, 2015, pp. 6-13. doi: 10.1109/BMEI.2015.7401464.

INSTITUTO NACIONAL DE CÂNCER. **Organização Pan-Americana da Saúde. Pesquisa especial de tabagismo – PETab**: relatório Brasil. Instituto Nacional de Câncer. Organização Pan-Americana da Saúde. – Rio de Janeiro: INCA, 2011.

JARDIM, J. R.; OLIVEIRA, J. A. de; NASCIMENTO, O. Revisão de alguns aspectos de epidemiologia e tratamento da doença estável. **Sociedade brasileira de pneumologia e fisiologia**, 2006.

JHA, P.; CHALOUPEK, F. J. **Curbing the epidemic**: governments and the economics of tobacco control. Washington, 1999. 134 p. The World Bank. ISBN 0-8213-4519-2.

KURUGOL, S.; G. R. WASHKO E R. S. J. ESTEPAR. **Ranking and classification of monotonic emphysema patterns with a multi-class hierarchical approach**. 2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI), Beijing, 2014, pp. 1031-1034. doi: 10.1109/ISBI.2014.6868049.

KARABULUT, E. M.; IBRIKCI, T. **Emphysema discrimination from raw HRCT images by convolutional neural networks**. 2015 9th International Conference on Electrical and Electronics Engineering (ELECO), Bursa, 2015, pp. 705-708. doi: 10.1109/ELECO.2015.7394441.

LIANG, T. K.; Toshiyuki Tanaka, Hidetoshi Nakamura and Akitoshi Ishizaka. **A neural network based computer-aided diagnosis of emphysema using CT lung images**. SICE Annual Conference 2007, Takamatsu, 2007, pp. 703-709. doi: 10.1109/SICE.2007.4421073

LIANG, T. K.; Toshiyuki Tanaka, Hidetoshi Nakamura, Toru Shirahata e Hiroaki Sugiura. **An automated three-dimensional visualization and classification of emphysema using neural network**. 2008 42nd Asilomar Conference on Signals, Systems and Computers, Pacific Grove, CA, 2008, pp. 1936-1940. Doi: 10.1109/ACSSC.2008.5074767.

MAEDA, T. **Medical Imaging Apparatus And Image Processing Apparatus**. JP2014104249, 09 ago. 2014. Disponível em: [https://worldwide.espacenet.com/publicationDetails/biblio?I1=307&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20140609&CC=JP&NR=2014104249A&KC=A](https://worldwide.espacenet.com/publicationDetails/biblio?I1=307&ND=3&adjacent=true&locale=en_EP&FT=D&date=20140609&CC=JP&NR=2014104249A&KC=A)>. Acesso em: 27 nov. 2017.

MENDOZA C. S.; Washko, G.R.; Ross, J. C.; Diaz, A. A.; Lynch, D. A.; Crapo, J. D.; Silverman, E. K.; Acha, B.; Serrano, C.; Estépar, R. S. **Emphysema quantification in a multi-scanner HRCT cohort using local intensity distributions**. 2012 9th IEEE International Symposium on Biomedical Imaging (ISBI), Barcelona, 2012, pp. 474-477. doi: 10.1109/ISBI.2012.6235587.

MOLLURA, D. J.; Azene, E. M; Starikovskiy, A.; Thelwell, A.; Iosifescu, S.; Kimble, C.; Polin, A.; Garra, B. S.; DeStigter, K. K.; Short, B. *et al*. White paper report of the rad-aid conference on international radiology for developing countries: identifying challenges, opportunities, and strategies for imaging services in the developing world. **Journal of the American College of Radiology**, 7(7):495-500, 2010.

OJALA, T., M. PIETIKAINEN; T. MÄENPÄÄ. **Multiresolution Gray Scale and Rotation Invariant Texture Classification With Local Binary Patterns**. IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol. 24, Issue 7, July 2002, pp. 971-987.

PRASAD, M. N.; A. SOWMYA E I. KOCH. **Feature subset selection using ICA for classifying emphysema in HRCT images**. Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004., 2004, pp. 515-518 Vol.4. doi: 10.1109/ICPR.2004.1333824.

PAPA, J. P.; FALCÃO, A. X. e SUZUKI, C. T. N. (2009), Supervised pattern classification based on optimum-path forest. **Int. J. Imaging Syst. Technol.**, 19: 120–131. doi:10.1002/ima.20188. A LibOPF está disponível para download em <[www.ic.unicamp.br/~afalcao/libopf/](http://www.ic.unicamp.br/~afalcao/libopf/)>.

PRATT, W. K. Digital Image Processing: PIKS Scientific Inside. 4. Ed. John Wiley and Sons, Inc, 2007. ISBN 9780470097434. doi:10.1002/0470097434.

PU, J.; GU, S. **The Airway Wall Recognition Method**. WO2013078782, 06 jun. 2013. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?II=400&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20130606&CC=WO&NR=2013078782A1&KC=A1](https://worldwide.espacenet.com/publicationDetails/biblio?II=400&ND=3&adjacent=true&locale=en_EP&FT=D&date=20130606&CC=WO&NR=2013078782A1&KC=A1)>. Acesso em: 27 nov. 2017.

RADHAKRISHNAN, S.; OLIVERA, R. **Methods, Systems, And Devices For Analyzing Lung Imaging Data**. WO2017136781, 10 ago. 2017. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?CC=WO&NR=2017136781A1&KC=A1&FT=D&ND=3&date=20170810&DB=&locale=en\\_EP](https://worldwide.espacenet.com/publicationDetails/biblio?CC=WO&NR=2017136781A1&KC=A1&FT=D&ND=3&date=20170810&DB=&locale=en_EP)>. Acesso em: 27 nov. 2017.

RAJPURKAR, Pranav; Irvin, Jeremy; Zhu, Kaylie; Yang, Brandon; Mehta, Hershel; Duan, Tony; Ding, Daisy; Bagul, Aarti; Langlotz, Curtis; Shpanskaya, Katie; Lungren, Matthew P.; Ng, Andrew Y. **CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning**. eprint arXiv:1711.05225. Nov 2017. Disponível em: <<https://arxiv.org/abs/1711.05225?context=cs.LG>>. Acessado em: 17 nov. 2017.

ROCHA, L. M., CAPPABIANCO, F. A. M. AND FALCÃO, A. X. (2009), Data clustering as an optimum-path forest problem with applications in image analysis. **Int. J. Imaging Syst. Technol.**, 19: 50–68. doi:10.1002/ima.20191.

SÁ JÚNIOR, J. J. de M. **Novos métodos de análise de texturas baseados em modelos gravitacionais simplificados e caminhos mais curtos em grafos**. Dissertação (mestrado). Universidade Federal do Ceará, 2013.

SAKAMOTO, T; IMASUGI, Y. **Medical Image Diagnostic Assistance Device, Controlling Method And Program For The Same**. JP2017080396, 18 mai. 2017. Disponível em: <<https://worldwide.espacenet.com/publicationDetails/biblio?FT=D&date=20170518&>

[DB=&locale=&CC=JP&NR=2017080396A&KC=A&ND=6](#)>. Acesso em: 27 nov. 2017a.

SAKAMOTO, T; IMASUGI, Y. Image Processing Apparatus, Control Method Thereof, And Storage Medium. US2017124705, 04 mai. 2017. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?II=7&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20170504&CC=US&NR=2017124705A1&KC=A1](https://worldwide.espacenet.com/publicationDetails/biblio?II=7&ND=3&adjacent=true&locale=en_EP&FT=D&date=20170504&CC=US&NR=2017124705A1&KC=A1)>. Acesso em: 27 nov. 2017.

SHENGWEN, G. **Computer-assisted emphysema analysis system based on chest CT (Computerized Tomography) image**. CN102429679, 02 mai. 2012. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?II=468&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20120502&CC=CN&NR=102429679A&KC=A](https://worldwide.espacenet.com/publicationDetails/biblio?II=468&ND=3&adjacent=true&locale=en_EP&FT=D&date=20120502&CC=CN&NR=102429679A&KC=A)>. Acesso em: 27 nov. 2017.

SINGH, P. K. **Emphysema detection in JPEG compressed HRCT lung images**. Proceedings of the Eighth International Symposium on Signal Processing and Its Applications, 2005., 2005, pp. 195-198. doi: 10.1109/ISSPA.2005.1580229.

SORENSEN, L.; S. B. SHAKER E M. DE BRUIJNE. Quantitative Analysis of Pulmonary Emphysema Using Local Binary Patterns. In: **IEEE Transactions on Medical Imaging**, vol. 29, no. 2, pp. 559-569, Feb. 2010. doi: 10.1109/TMI.2009.2038575. Banco online de imagens de TCAR com enfisemas disponível para download em <[image.diku.dk/emphysema\\_database/](http://image.diku.dk/emphysema_database/)>.

TANG, B. **Auxiliary device of operating room collection heart and lungs treatment**. CN206103046, 19 abr. 2017. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?II=34&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20170504&CC=US&NR=2017124705A1&KC=A1](https://worldwide.espacenet.com/publicationDetails/biblio?II=34&ND=3&adjacent=true&locale=en_EP&FT=D&date=20170504&CC=US&NR=2017124705A1&KC=A1)>. Acesso em: 27 nov. 2017.

TUBA, E.; TUBA, M.; SIMIAN, M. **Support Vector Machine Optimized by Firefly Algorithm for Emphysema Classification in Lung Tissue CT Images**. 25th International Conferences in Central Europe on Computer Graphics, Visualization and Computer Vision, published In: Computer Science Research Notes (CSRN), ISSN 2464-4614.

VALENTE, I.R. S.; Cortez, P. C.; Neto, E. C.; Soares, J. M.; Albuquerque, V. H. C. de; Tavares, J. M. R.S. **Automatic 3D pulmonary nodule detection in CT images: A survey**. Computer Methods and Programs in Biomedicine, Volume 124 , 91 - 107, 2015. doi: 10.1016/j.cmpb.2015.10.006.

VASCONCELOS, V.; J. S. Silva, L. Marques e J. Barroso. **Statistical textural features for classification of lung emphysema in CT images: A comparative study**. 5th Iberian Conference on Information Systems and Technologies, Santiago de Compostela, 2010, pp. 1-5.

VERONEZI, Carlos Cassiano Denipotti, Simões, Priscyla Waleska Targino de Azevedo, Santos, Robson Luiz dos, Rocha, Edroaldo Lummertz da, Melão, Suelen,

Mattos, Merisandra Côrtes de, & Cechinel, Cristian. (2011). **Análise computacional para auxílio ao diagnóstico de osteoartrite de coluna lombar baseado em redes neurais artificiais**. Revista Brasileira de Ortopedia, 46(2), 195-199. Disponível em: <<https://dx.doi.org/10.1590/S0102-36162011000200014>>

WAKIZAKA, T; FUKUSHIMA, K. **Automatic Analysis Device And Automatic Analysis Method**. JP2016174773, 06 out. 2016. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?II=92&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20161006&CC=JP&NR=2016174773A&KC=A](https://worldwide.espacenet.com/publicationDetails/biblio?II=92&ND=3&adjacent=true&locale=en_EP&FT=D&date=20161006&CC=JP&NR=2016174773A&KC=A)>. Acesso em: 27 nov. 2017.

WIEMKER, R; KLINDER, T. **Extracting Bullous Emphysema And Diffuse Emphysema In E.G. Ct Volume Images Of The Lungs**. US2015036908, 05 fev. 2015. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?II=259&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20150205&CC=US&NR=2015036908A1&KC=A1#](https://worldwide.espacenet.com/publicationDetails/biblio?II=259&ND=3&adjacent=true&locale=en_EP&FT=D&date=20150205&CC=US&NR=2015036908A1&KC=A1#)>. Acesso em: 27 nov. 2017.

WINKELER, Georgia Freire Paiva. **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**. 2006. 133 f. Dissertação (Mestrado em Medicina) - Universidade Federal do Ceará, Fortaleza, 2006.

WHO - World Health Organization. **Tabacco. Fact sheet no 339**. Acessado em : 17 nov 2017 . Disponível em: <<http://www.who.int/mediacentre/factsheets/fs339/en/>>. 2015a.

\_\_\_\_\_. **Chronic obstructive pulmonary disease (COPD)**. Fact sheet no 315. Acessado em: 17 nov. 2017. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs315/en/>>. 2015b.

\_\_\_\_\_. **Household air pollution and health**. Fact sheet no 292. Acessado em: 17 nov. 2017. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs292/en/>>. 2016.

XU, Y.; M. Sonka, G. McLennan, Junfeng Guo and E. A. Hoffman. MDCT-based 3-D texture classification of emphysema and early smoking related lung pathologies. In: **IEEE Transactions on Medical Imaging**, vol. 25, no. 4, pp. 464-475, April 2006. doi: 10.1109/TMI.2006.870889.

YIN, Y; RAFFY, P.; WOOD, S. A. **Visualization And Quantification Of Lung Disease Utilizing Image Registration**. US2015332454, 19 nov. 2015. Disponível em: <[https://worldwide.espacenet.com/publicationDetails/biblio?II=190&ND=3&adjacent=true&locale=en\\_EP&FT=D&date=20151119&CC=US&NR=2015332454A1&KC=A1#](https://worldwide.espacenet.com/publicationDetails/biblio?II=190&ND=3&adjacent=true&locale=en_EP&FT=D&date=20151119&CC=US&NR=2015332454A1&KC=A1#)> . Acesso em: 27 nov. 2017.

## APÊNDICE

### MATRIZES DE CONFUSÃO DO MÉTODO LBP-OPF

Nesta seção, apresentam-se as matrizes de confusão do método LBP-OPF, ao classificar os tipos de enfisemas de quatro combinações de bancos de imagens (Tabela 3); e níveis de severidade de enfisemas de um banco de imagens (Tabela 5). Reitera-se que metade das imagens foram utilizadas para treinamento, e a outra metade, para testes.

Os resultados do LBP-OPF, apresentados nas Tabela 3 e 5, foram gerados automaticamente através da função “*opf\_accuracy*” da LibOPF 2.1. Por outro lado, os resultados das matrizes de confusão, apresentados a seguir, foram obtidos ao contar o número de classes de entrada (colunas) e de saída (linhas) com resultados iguais, dividindo-o pelo número de imagens de teste.

Visando à transparência dos resultados, espera-se que o “*opf\_accuracy*” e as matrizes de confusão gerem o mesmo valor de taxa de acerto. Entretanto, apresentam taxas de acerto diferentes, para os testes das Tabelas 3 e 5, como discutido nas legendas das Tabelas 6, 7, 8, 9 e 10, demonstrando inconsistência da LibOPF 2.1 na apresentação da taxa de acerto. Além disso, o método LBP-OPF tem a limitação de identificar os tipos de enfisemas ou níveis de severidade, que corresponde à tarefa de maior complexidade na análise do tecido pulmonar.

Tabela 6 – Matriz de confusão do método LBP-OPF para classificação dos tipos de enfisema das imagens dos *slices* de Sorensen *et al.* (2010).

	NT	CLE	PSE	PLE
NT	21	2	7	1
CLE	4	5	1	1
PSE	3	3	8	0
PLE	1	0	0	2

%	Resultado por classe			
	NT	CLE	PSE	PLE
NT	67.7%	6.5%	22.6%	3.2%
CLE	36.4%	45.5%	9.1%	9.1%
PSE	21.4%	21.4%	57.1%	0.0%
PLE	33.3%	0.0%	0.0%	66.7%

Fonte: autor. Sobre o mesmo teste de 59 imagens de 4 classes de tipos de enfisema, a função “*opf\_accuracy*” retornou acerto de 72,08% (Tabela 3), maior que 61% de acerto da matriz de confusão.

Tabela 7 – Matriz de confusão do método LBP-OPF para classificação dos tipos de enfisema das imagens de Fortaleza (2006) e Winkeler (2006).

	NT	CLE	PLE
NT	45	1	2
CLE	4	5	0
PLE	2	1	1

%	Resultado por classe		
	NT	CLE	PLE
NT	93.8%	2.1%	4.2%
CLE	44.4%	55.6%	0.0%
PLE	50.0%	25.0%	25.0%

Fonte: autor. Sobre o mesmo teste de 61 imagens de 3 classes de tipos de enfisema, a função “*opf\_accuracy*” retornou acerto de 70,13% (Tabela 3), menor que 83,6% de acerto da matriz de confusão. Vale ressaltar que foi alta a taxa de acerto dos tecidos normais (NT), atingindo 93,8%.

Tabela 8 – Matriz de confusão do método LBP-OPF para classificação dos tipos de enfisema das imagens dos slices de Sorensen *et al.* (2010), Fortaleza (2006) e Winkeler (2006).

	NT	CLE	PSE	PLE
NT	62	11	2	3
CLE	8	9	2	0
PSE	5	0	9	0
PLE	3	0	0	4

%	Resultados por classe			
	NT	CLE	PSE	PLE
NT	79.5%	14.1%	2.6%	3.8%
CLE	42.1%	47.4%	10.5%	0.0%
PSE	35.7%	0.0%	64.3%	0.0%
PLE	42.9%	0.0%	0.0%	57.1%

Fonte: autor. Sobre 118 imagens de 4 classes de tipos de enfisema, função “*opf\_accuracy*” retornou acerto de 73,83% (Tabela 3), maior que 71,2% de acerto da matriz de confusão.

Tabela 9 – Matriz de confusão do método LBP-OPF para classificação dos tipos de enfisema das imagens dos *patches* de Sorensen *et al.* (2010).

	NT	CLE	PSE
NT	22	6	2
CLE	1	22	2
PSE	6	7	17

%	Resultado por classe		
	NT	CLE	PSE
NT	73.3%	20.0%	6.7%
CLE	4.0%	88.0%	8.0%
PSE	20.0%	23.3%	56.7%

Fonte: autor. Sobre o mesmo teste de 85 imagens de 3 classes de tipos de enfisema, a função “*opf\_accuracy*” retornou acerto de 79,39% (Tabela 3), maior que 71,8% de acerto da matriz de confusão. Vale ressaltar que foi alta a taxa de acerto dos enfisemas centroacinar (CLE), com 88% de acerto.

Tabela 10 – Matriz de confusão do método LBP-OPF para classificação dos níveis de severidade de enfisemas das imagens dos *slices* de Sorensen *et al.* (2010).

	NOE	MIN	MIL	MOD	SEV	VSE
NOE	22	7	1	0	0	1
MIN	1	9	1	0	1	1
MIL	3	1	0	2	0	0
MOD	1	2	1	2	0	0
SEV	0	1	0	1	0	0
VSE	0	1	0	0	0	0

%	NOE	MIN	MIL	MOD	SEV	VSE
NOE	71.0%	22.6%	3.2%	0.0%	0.0%	3.2%
MIN	7.7%	69.2%	7.7%	0.0%	7.7%	7.7%
MIL	50.0%	16.7%	0.0%	33.3%	0.0%	0.0%
MOD	16.7%	33.3%	16.7%	33.3%	0.0%	0.0%
SEV	0.0%	50.0%	0.0%	50.0%	0.0%	0.0%
VSE	0.0%	100.0%	0.0%	0.0%	0.0%	0.0%

Fonte: autor. Sobre o mesmo teste de 59 imagens de 6 classes de níveis de severidade de enfisema, a função “*opf\_accuracy*” retornou acerto de 59,42% (Tabela 3), maior que 55,9% de acerto da matriz de confusão. Vale ressaltar a maior taxa de acerto na classificação de imagens sem enfisema (NOE) e com enfisema mínimo (MIN), respectivamente 71% e 69,2%. Além disso, o pequeno número de amostras de imagens de teste com enfisema severo (SEV), apenas duas, e bastante severo (VSE), apenas uma, dificulta a classificação através do LBP-OPF.