

Lung Diseases Classification by Analysis of Lung Tissue Densities

S. S. A. Alves, E. S. Rebouças, S. A. F. Oliveira, Alan M. Braga, P. P. Rebouças Filho

Abstract—Lung diseases identification based on analysis and processing of medical images is important to assist medical doctors during the diagnosis process. In this context, this paper proposes a new feature extraction method based on human tissue density patterns, namely Analysis of Human Tissue Densities in Lung Diseases. The proposed method uses human tissues radiological densities, in Hounsfield Units, to perform the features extraction on thorax computerized tomography images. We compared the proposed method against the Gray Level Co-occurrence Matrix and Statistical Moments to accomplish the performance evaluation alongside four machine learning classifiers. Overall, the results revealed that the proposal achieved higher accuracy ratios while it took the lowest runtime in all performed experiments. Thus, we consider our proposal as a valid alternative to be used in real-time applications.

Index Terms—Computerized Tomography, Lung, Lung Disease.

I. INTRODUÇÃO

A importância de pesquisas no campo de Pneumologia tem aumentado significativamente nas últimas décadas [1]–[8]. Doenças do tipo pulmonar obstrutiva crônica (DPOC) [9]–[11] e a fibrose pulmonar (FP) [12]–[14] são exemplos de doenças com elevado número de casos no mundo.

Segundo a métrica DALY (*disability-adjusted life-year*) que combina informações de mortalidade e morbidade para fins de contabilizar anos de vida perdidos por incapacidade, DPOCs compreendem a 5ª doença mais ameaçadora desde 2010 [15]. Além disso, de acordo com a Organização Mundial da Saúde (OMS), estima-se que 3 milhões de mortes em todo o mundo são causadas por DPOCs [16]. Em 2015, por exemplo, DPOCs foram consideradas a 4ª maior causa de morte [17]. Ademais, estima-se que em 2020, as mortes causadas por doenças pulmonares compreenderão 17,5% das mortes em todo o mundo, em que 6,91% serão devidos às DPOCs, 3,67% à pneumonia, 3,53% pela tuberculose e 3,39% por câncer de pulmão [18]. Ainda na mesma estimativa, em meados de 2030,

S. S. A. Alves, Laboratório de Processamento de Imagens e Simulação Computacional (LAPISCO), Instituto Federal de Ciência e Tecnologia do Ceará (IFCE), Fortaleza, Ceará, Brasil, shara.shami@lapisco.ifce.edu.br

E. S. Rebouças, Laboratório de Processamento de Imagens e Simulação Computacional (LAPISCO), Instituto Federal de Ciência e Tecnologia do Ceará (IFCE), Fortaleza, Ceará, Brasil, elizangelareboucas@lapisco.ifce.edu.br

S. A. F. Oliveira, Laboratório de Processamento de Imagens e Simulação Computacional (LAPISCO), Instituto Federal de Ciência e Tecnologia do Ceará (IFCE), Fortaleza, Ceará, Brasil, saulo.freitas.oliveira@gmail.com

Alan M. Braga, Laboratório de Processamento de Imagens e Simulação Computacional (LAPISCO), Instituto Federal de Ciência e Tecnologia do Ceará (IFCE), Fortaleza, Ceará, Brasil, alanmbraga@gmail.com

P. P. Rebouças Filho Laboratório de Processamento de Imagens e Simulação Computacional (LAPISCO), Instituto Federal de Ciência e Tecnologia do Ceará (IFCE), Fortaleza, Ceará, Brasil, pedrosarf@ifce.edu.br

as DPOCs serão responsáveis por 7,8% de todas as mortes em todo o mundo [19], ocupando assim a 3ª maior causa de morte [20].

De acordo com a Sociedade Torácica Americana (*American Thoracic Society*, ATS), a fibrose pulmonar é definida como um grupo de doenças pulmonares intersticiais em que as paredes dos alvéolos tornam-se espessas [21]–[23]. Dentre as doenças com essas características, temos a Fibrose Pulmonar Idiopática (FPI) que é a mais comum e letal [24] com um tempo médio de sobrevivência de 2 a 3 anos [14], [25]–[27]. Estima-se que, em um grupo de 100,000 pessoas, a FPI acomete anualmente, nos Estados Unidos, entre 6,8% e 17,4% dos casos, 93,7% casos em pessoas com idade acima de 65 anos [13], e entre 0,22% a 7,4% na Europa [12].

Neste contexto, a disponibilidade de ferramentas de Diagnóstico Dirigido pelo Computador (*Computer-Aided Diagnosis*, CAD) é importante para a medicina moderna, visto que podem auxiliar os médicos à reportarem diagnósticos mais rápidos e com maior precisão. Além disso, possibilitam o monitoramento da condição clínica dos pacientes de maneira mais eficiente [28], [29]. A maioria das ferramentas de CAD com base em algoritmos de processamento digital de imagens [30], [31] utilizam imagens de Tomografia Computadorizada (TC) [3], [32].

Os estudos voltados para a classificação de doenças pulmonares tem alcançado grandes avanços na melhoria das ferramentas CAD e, conseqüentemente, nos desafios enfrentados pela saúde pública. Ramalho *et. al.* [10] propuseram um novo extrator de características, chamado de Matriz de Interdependência Espacial (*Spatial Interdependence Matrix*, SIM), o qual utiliza Máquina de Aprendizado Extremo (*Extreme Learning Machine*, ELM) para classificar imagens de TC do pulmão em sadio, DPOC ou FP. Os autores realizaram uma análise comparativa do método proposto com os métodos *Gray Level Co-occurrence Matrix* (GLCM [33], [34]) e *Visual Information Fidelity* (VIF, [10]). Além disso, propuseram o método *Structural Co-occurrence Matrix* (SCM) e o comparou com os métodos GLCM, *Invariant Statistical Moments* (IM, [35]) e *Local Binary Pattern* (LBP [6]).

Outro estudo foi encontrado em [36], onde foi proposto um esquema para classificação de fragmentos das anormalidades de doenças pulmonares intersticiais (DPI). O método de extração de características utilizado pelo autor foca na análise espectral local utilizando a transformada discreta do cosseno e o classificador *Random Forest* (RF [37]). Além disso, os autores estenderam seus estudos [38] implementando uma Rede Neural Convolutacional (RNC) para classificar os fragmentos das imagens de TC do pulmão em 7 classes.

Zhao *et. al.* [39] introduziram um método com base em representação esparsa para classificar tecidos normais em 5 tipos de padrões de doenças pulmonares difusas. No método, as imagens de TCs e os autovalores das matrizes Hessianas foram utilizados para extrair as características locais. Para etapa de classificação foi aplicado o classificador de Máquinas de Vetores Suporte (*Support Vector Machine*, SVM). Além dos trabalhos citados anteriormente, foram encontrados trabalhos que focam na detecção de doenças específicas, como nódulos [40], [41] e enfisema [28], [42].

Neste contexto, este artigo propõe um método de extração de características para auxiliar o diagnóstico de doenças pulmonares, classificando-o em sadio, DPOC ou FP, a partir da análise de imagens de TC do pulmão. A proposta é comparada com dois algoritmos de extração de características comumente utilizados na literatura, a saber, GLCM e Momentos Estatísticos (ME, [43]). O processo de validação da proposta consiste em analisar o desempenho de quatro classificadores ao utilizar as características extraídas pela proposta e os dois algoritmos comparados. Os classificadores utilizados foram: o Bayesiano Ingênuo (Bayes, [44]), k-Vizinhos Mais Próximos (kNN, [45]), Floresta de Caminhos Ótimos (*Optimum-Path Forest* [37], OPF) e Máquinas de Vetores Suporte (SVM, [46]); e a análise do desempenho é dada em função das métricas acurácia e *F-score*. Os resultados obtidos demonstram que o método proposto é promissor uma vez que o mesmo obteve melhor desempenho em relação aos demais nas métricas supracitadas.

II. ANÁLISE DE DENSIDADE DE TECIDOS HUMANOS EM DOENÇAS PULMONARES

As características presentes nas densidades do tecido humano auxiliam na identificação e classificação de doenças. O conceito por trás da Análise das Densidades de Tecido Humano (ADTH) utilizando as faixas de tecidos em Unidades Hounsfield (UH) das imagens de TC foi proposto por Rebouças Filho *et. al.* [2]. No estudo supracitado, os autores propuseram uma árvore de decisão com base na análise da densidade da vizinhança para encontrar a melhor posição na qual um modelo de contorno ativo pudesse ser inicializado. Essa mesma árvore de decisão também atuou na decisão de identificação de objetos de interesse, avaliando se tais objetos estavam dentro ou fora do pulmão segmentado [2]. O conceito, então, foi aplicado para segmentar vias aéreas [1], [47] e vasos sanguíneos [48] nas imagens de TC dos pulmões. Logo após, foi aplicado por [3] para realizar a tarefa de segmentação através de Rede Neural Artificial (RNA).

A. Análise de Densidades do Tecido Humano em Doenças Pulmonares

Neste artigo, utilizamos o conceito por trás da análise de densidades de tecidos humanos proposta por Rebouças Filho *et. al.* [2] para desenvolver um novo método de extração de características de imagens de TC. A este novo método, chamamos-o de Análise de Densidades do Tecido Humano em Doenças Pulmonares (ADTH-DP), o qual é voltado para a classificação de imagens de TC do pulmão em três diferentes classes: sadio, DPOC ou FP.

O método proposto para a extração de características utiliza o valor de percentagem do tecido humano saudável com base na análise de suas densidades em UH. O valor dessa percentagem P_i é dado como segue

$$P_i = \frac{f(i)}{\sum_{i=0}^{N-1} f(i)}, \quad (1)$$

em que N é o número de tecidos sob análise, i é uma das classes presentes e $f(\cdot)$ determina o número de pontos com densidades presentes em cada classe i .

A função $f(\cdot)$ é computada em uma região de pulmão já segmentada

$$f(i) = \sum_{x=0}^W \sum_{y=0}^H \mathbf{R}_i(x, y), \quad (2)$$

em que $\mathbf{R}_i(\cdot, \cdot)$ é uma região segmentada da imagem de entrada $\mathbf{T}(\cdot, \cdot)$ de dimensões $W \times H$ (com valores de pixel em UH) dada por

$$\mathbf{R}_i(x, y) = \begin{cases} 1, & \text{if } \lambda(i) < \mathbf{T}(x, y) < \Lambda(i); \\ 0, & \text{otherwise.} \end{cases} \quad (3)$$

em que $\lambda(i)$ e $\Lambda(i)$ são os limites inferior e superior, respectivamente, dos valores de densidade associados à classe i .

Para este trabalho, com base em [3], foram definidas cinco classes de densidades $i = 0, \dots, 4$, a saber:

- 1) hiperaeradas (1000 a 950 UH);
- 2) normalmente aeradas (950 a 500 UH);
- 3) pouco aeradas (500 a 100 UH);
- 4) não aeradas (100 a 100 UH);
- 5) osso (600 a 2000 UH).

Na Figura 1 temos o mapa de densidades resultante da proposta usando o seguinte mapeamento proposto por Rebouças Filho *et. al.* [2]:

$$\text{ADTH} - \text{DP}_{\text{MAP}}(x, y) = \begin{cases} r(x, y) = P_2; \\ g(x, y) = \frac{P_3 + 2 \times P_4}{3}; \\ b(x, y) = \frac{P_0 + 2 \times P_1}{3}. \end{cases} \quad (4)$$

em que P_i é definido pela Eq. (1), x e y são as coordenadas da imagem \mathbf{T} e $r(\cdot, \cdot)$, $g(\cdot, \cdot)$, e $b(\cdot, \cdot)$ representam os valores das componentes vermelha, verde e azul do padrão RGB, respectivamente.

III. METODOLOGIA

Foi utilizado o conjunto de dados de imagens de TC do pulmão disponibilizado em [2], no qual as imagens estão na resolução de 512×512 pixels com 16 bits e o plano da tomografia é definido com base no plano axial. Este conjunto foi obtido no Hospital Universitário Cantídio, na cidade de Fortaleza, Ceará, Brasil e o mesmo já foi utilizado em estudos anteriores [2], [3], [7]. O conjunto de dados compreende 12 imagens de voluntários sadios e 24 imagens de pacientes com patologias pulmonares: 12 com enfisema pulmonar e 12 com

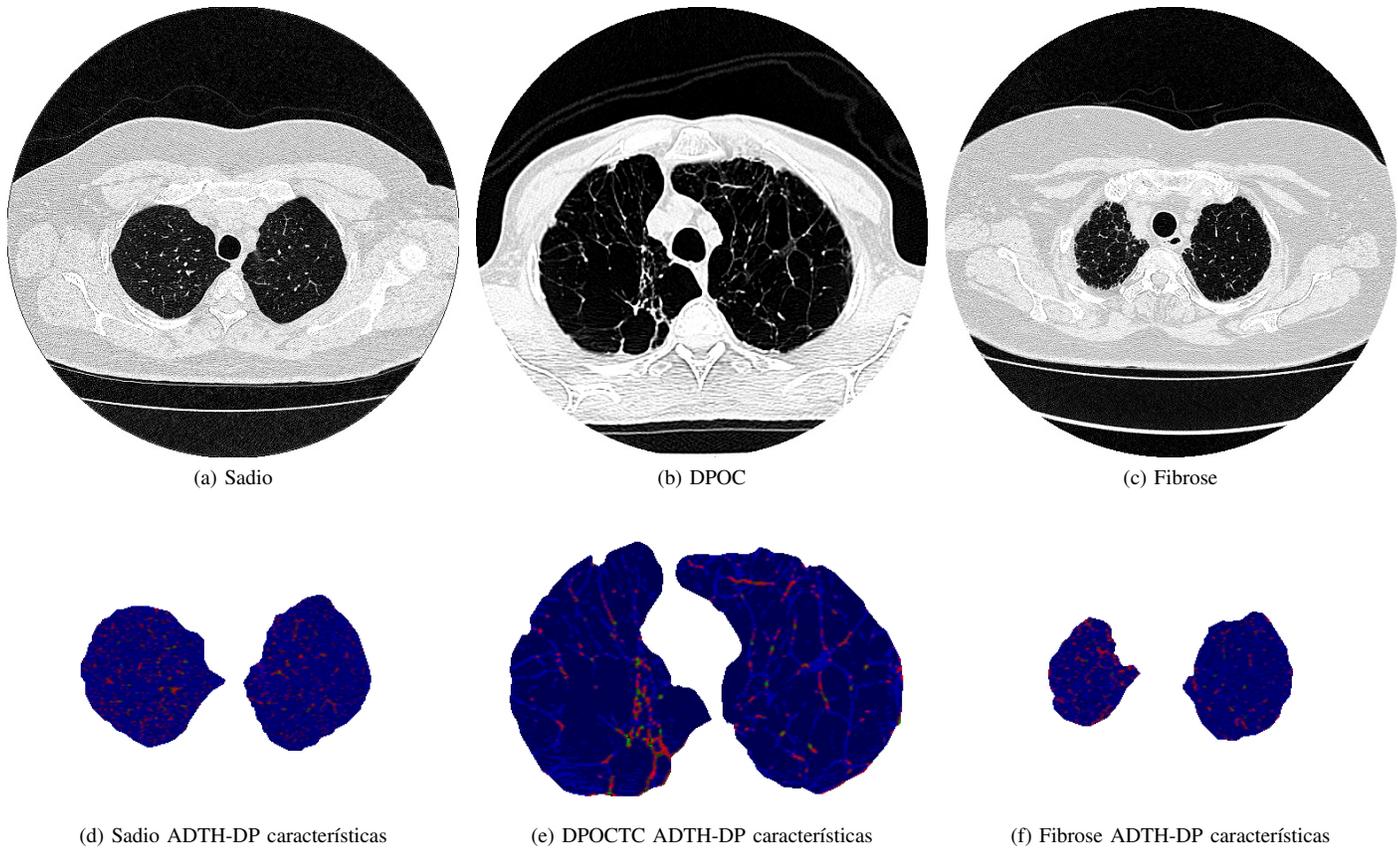


Fig. 1: Exemplos de imagem de TC do pulmão (parte superior, (a) a (c)) e o resultado da segmentação e mapeamento $ADTH - DP_{MAP}$ (parte inferior, (d) a (f)). Nas imagens (a) e (d) tem-se o resultado do método proposto pulmão sadio, nas imagens (b) e (e) tem-se o resultado para um pulmão com enfisema, e por fim, nas imagens (c) e (f) tem-se o resultado para um pulmão com fibrose.

fibrose. Dado que cada imagem apresenta dois pulmões, o conjunto de dados possui então um total de 24 exemplos de cada classe (voluntários sadios, pacientes com enfisema e pacientes com fibrose).

O desempenho de nossa proposta é então comparado a dois extratores de características: *Gray Level Co-occurrence Matrix* (GLCM) e Momentos Estatísticos (ME), através da aplicação de quatro classificadores: Bayesiano Ingênuo (Bayes), *k*-Vizinhos mais próximos (*k*NN), Floresta de Caminhos Ótimos (OPF) e Máquinas de Vetor Suporte (SVM) com *kernel* RBF (*Radial Basis Functions*) sobre as características extraídas. Os parâmetros de cada classificador foram estimados utilizando o método de validação cruzada com 10 *folds*. Dez diferentes permutações aleatórias de todas as imagens foram utilizadas, em que 50% compreendem o conjunto de treinamento e os 50% restantes o conjunto de teste. Destacamos que as imagens do pulmão em escala de cinza foram obtidas das imagens de TCs originais utilizando uma janela com 600 UH de largura e centralizada em 1000 UH, tal qual utilizado em Webb *et al.* [49]. Os experimentos foram conduzidos em um notebook Intel Core i5 2.4 GHz, 8 GB de RAM, e sistema operacional MAC OS X El Capitan 10.11.2.

IV. RESULTADOS

Na Fig. 2 são apresentados os resultados dos experimentos em termos de acurácia média e *F-score* médio em relação à cada classe, respectivamente. O *F-score* utiliza a sensibilidade e a especificidade como entrada para computo do mesmo. Para se obter esse *F-score* médio, no nosso trabalho, foi empregada uma estratégia na qual cada classe teve seu valor de *F-score* computado e a média desses valores resulta no *F-score* médio em relação à cada classe. Como pode ser visto na Fig. 2a, o método proposto alcançou a maior acurácia com menor desvio padrão dentre os outros métodos de extração de características, demonstrando que as características extraídas são de fato bem representativas. Sabendo que o desempenho de um classificador depende da representatividade dos dados e com o exposto supracitado, sustentamos que o conjunto de dados (padrões) obtidos pelo método proposto é mais representativo que os conjuntos obtidos pelos demais extratores de características. Em relação ao *F-score*, como pode ser visto na Fig. 2b, o método proposto obteve resultado similar ao método GLCM, que obteve o melhor desempenho nessa métrica, com uma diferença pequena de $< 2\%$. Além disso, nossa proposta superou o método ME em 15%, em média.

Na Tabela I são apresentados os tempos de execução do treinamento e de teste dos classificadores utilizando a proposta

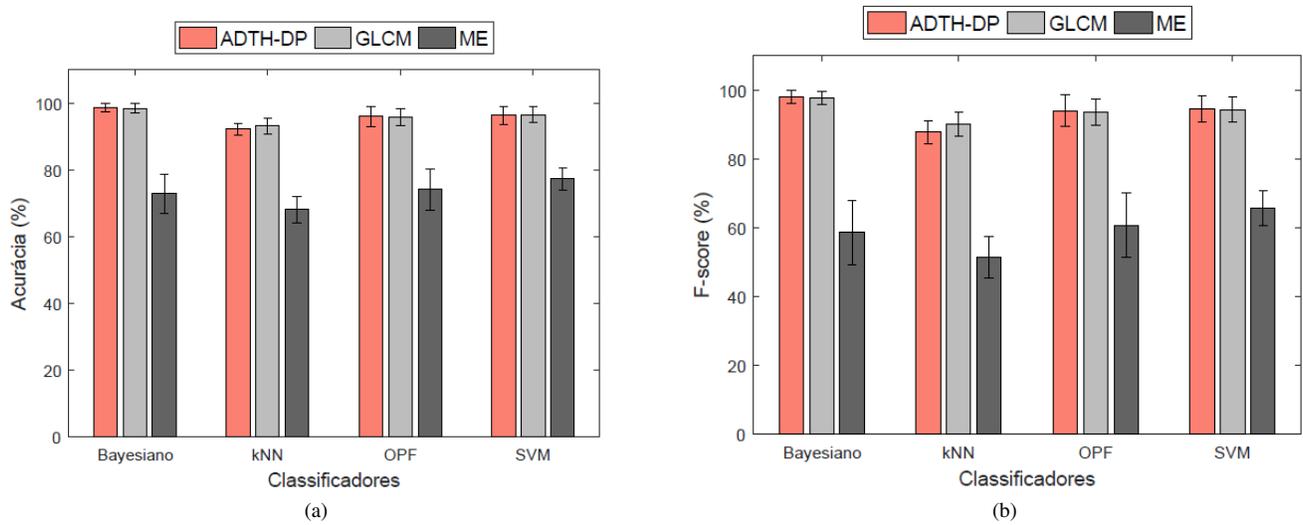


Fig. 2: Resultado das 10 execuções independentes em termos de acurácia média e desvio padrão.

ADTH-DP e os dois métodos de extração de características comparados: GLCM e ME. Os valores de tempo são dados em termos de média e desvio padrão das 10 realizações independentes. Como pode ser visto, o ADTH-DP alcançou menor tempo de treinamento em 2 dos 4 classificadores, ocupando sempre a 1a e a 2a posição. Além disso, no teste, o método proposto foi o mais rápido. Tal comportamento, no que se refere ao tempo de teste, é relevante, visto que a etapa de treinamento ocorre uma única vez e o custo computacional só impacta no desempenho quando da etapa de teste. Exposto isso, temos que o método proposto é rápido.

Table I: Tempo de execução do treinamento e teste dos classificadores por método de extração de características. Os valores de tempo são média e o desvio padrão das 10 realizações independentes.

Classificador	Método	Tempo treino (seg)	Tempo teste (seg)
Bayesiano	ADTH-DP	1.67e-04 ± 6.26e-05	3.35e-06 ± 1.50e-06
	GLCM	3.14e-04 ± 8.03e-05	4.10e-06 ± 2.07e-06
	ME	1.17e-04 ± 3.71e-05	3.50e-06 ± 2.35e-06
kNN	ADTH-DP	1.48e-05 ± 4.09e-06	1.34e-05 ± 3.84e-06
	GLCM	1.79e-05 ± 9.47e-06	1.58e-05 ± 9.48e-06
	ME	4.10e-05 ± 1.18e-04	1.45e-03 ± 6.44e-03
OPF	ADTH-DP	1.61e-04 ± 7.04e-05	2.05e-06 ± 5.10e-07
	GLCM	2.58e-04 ± 1.57e-04	2.70e-06 ± 1.22e-06
	ME	1.52e-04 ± 7.97e-05	2.45e-06 ± 1.10e-06
SVM	ADTH-DP	1.40e-02 ± 2.04e-03	1.00e-06 ± 2.17e-22
	GLCM	1.56e-02 ± 3.14e-03	1.00e-06 ± 2.17e-22
	ME	1.47e-02 ± 1.64e-03	1.45e-06 ± 1.57e-06

V. CONCLUSÃO

Neste artigo foi proposto um método para extração de características de imagens de pulmão com base nas densidades radiológicas do tecido humano para o auxílio ao diagnóstico de doenças pulmonares. O método proposto foi comparado a métodos tradicionais de extração de características, a saber, Matriz de Co-ocorrência e Momentos Estatísticos. A avaliação do método foi realizada através da aplicação de quatro classificadores sobre um conjunto de dados de imagens de tomografia

computadorizada de pulmão. Os resultados revelaram que a proposta alcançou altas taxas de acurácia, menor tempo na etapa de teste e na etapa de treinamento ocupou sempre 1o e 2o lugar em comparação aos demais extratores. Desta forma, consideramos que a nossa proposta é uma alternativa válida para ser empregada em aplicações de tempo real para o auxílio ao diagnóstico de doenças pulmonares. Tendo demonstrado o potencial do método proposto para a extração de características, os trabalhos futuros compreendem a identificação e classificação de outras doenças no pulmão a partir das imagens de tomografia computadorizada, assim como, em outras imagens médicas. Além disso, a identificação e classificação de estruturas e órgãos do corpo humano também compreendem os trabalhos futuros.

AGRADECIMENTOS

Ao CNPq por incentivo e apoio a esta pesquisa. Ao Instituto Federal de Educação, Ciência e Tecnologia do Ceará, IFCE, ao LAPISCO, Laboratório de Processamento de Imagens e Simulação Computacional e ao Grupo de Pesquisa em Sistemas Inteligentes, GPSI, pelo apoio a esta pesquisa.

REFERENCES

- [1] T. d. S. Cavalcante, P. Cortez, P. Rebouças Filho, J. Felix, A. Alexandria, and M. Holanda, "Comparative analysis of segmentation techniques of airways on images of chest computed tomography," *Signals and Image Processing*, pp. 142–145, 2010.
- [2] P. P. Rebouças Filho, P. C. Cortez, and M. A. Holanda, "Active contour modes crisp: new technique for segmentation of the lungs in ct images," *Revista Brasileira de Engenharia Biomédica*, vol. 27, no. 4, pp. 259–272, 2011.
- [3] P. P. Rebouças Filho, P. C. Cortez, J. H. da Silva Félix, T. da Silveira, and M. A. H. Cavalcante, "Modelo de contorno ativo crisp adaptativo 2d aplicado na segmentação dos pulmões em imagens de tc do tórax de voluntários saudáveis e pacientes com enfisema pulmonar," *Revista Brasileira de Engenharia Biomédica*, vol. 29, no. 4, pp. 363–376, 2013.
- [4] J. H. S. Felix, P. C. Cortez, T. S. Cavalcante, A. R. Alexandria, P. P. Rebouças Filho, and M. A. Alcantara, *Method of Automatic Initialization of Active Contours Applied to Lungs in Computed Tomography Images*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, pp. 1019–1022.

- [5] G. L. B. Ramalho, D. S. Ferreira, P. P. R. Filho, and F. N. S. de Medeiros, "Rotation-invariant feature extraction using a structural co-occurrence matrix," *Measurement*, vol. 94, pp. 406–415, 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0263224116304730>
- [6] E. C. Neto, P. C. Cortez, T. S. Cavalcante, V. E. Rodrigues, P. P. R. Filho, and M. A. Holanda, "3d lung fissure segmentation in tc images based in textures," *IEEE Latin America Transactions*, vol. 14, no. 1, pp. 254–258, Jan 2016.
- [7] P. P. Rebouças Filho, P. C. Cortez, A. C. da Silva Barros, V. H. C. Albuquerque, and J. M. R. Tavares, "Novel and powerful 3d adaptive crisp active contour method applied in the segmentation of ct lung images," *Medical image analysis*, vol. 35, pp. 503–516, 2017.
- [8] M. B. Rodrigues, L. B. Marinho, R. V. M. Nóbrega, J. W. M. Souza, and P. P. Rebouças Filho, *Lung Segmentation in Chest Computerized Tomography Images Using the Border Following Algorithm*. Cham: Springer International Publishing, 2017, pp. 539–548.
- [9] R. J. Mieloszyk, G. C. Verghese, K. Deitch, B. Cooney, A. Khalid, M. A. Mirre-Gonzalez, T. Heldt, and B. S. Krauss, "Automated quantitative analysis of capnogram shape for copd-normal and copd-chf classification," *IEEE Transactions on Biomedical Engineering*, vol. 61, no. 12, pp. 2882–2890, 2014.
- [10] G. L. B. Ramalho, P. P. Rebouças Filho, F. N. S. d. Medeiros, and P. C. Cortez, "Lung disease detection using feature extraction and extreme learning machine," *Revista Brasileira de Engenharia Biomédica*, vol. 30, no. 3, pp. 207–214, 2014.
- [11] G. Spina, P. Casale, P. S. Albert, J. Alison, J. Garcia-Aymerich, R. W. Costello, N. A. Hernandez, A. J. van Gestel, J. D. Leuppi, R. Mesquita *et al.*, "Identifying physical activity profiles in copd patients using topic models," *IEEE journal of biomedical and health informatics*, vol. 19, no. 5, pp. 1567–1576, 2015.
- [12] L. Nalysnyk, J. Cid-Ruzafa, P. Rotella, and D. Esser, "Incidence and prevalence of idiopathic pulmonary fibrosis: review of the literature," *European Respiratory Review*, vol. 21, no. 126, pp. 355–361, 2012.
- [13] G. Raghu, S.-Y. Chen, W.-S. Yeh, B. Maroni, Q. Li, Y.-C. Lee, and H. R. Collard, "Idiopathic pulmonary fibrosis in {US} medicare beneficiaries aged 65 years and older: incidence, prevalence, and survival, 2001–11," *The Lancet Respiratory Medicine*, vol. 2, no. 7, pp. 566–572, 2014. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2213260014701018>
- [14] E. C. O'Brien, M. T. Durheim, V. Gamerman, S. Garfinkel, K. J. Anstrom, S. M. Palmer, and C. S. Conoscenti, "Rationale for and design of the idiopathic pulmonary fibrosis-prospective outcomes (ipf-pro) registry," *BMJ open respiratory research*, vol. 3, no. 1, p. e000108, 2016.
- [15] J. Luis Lopez-Campos, W. Tan, and J. B. Soriano, "Global burden of COPD," *Respirology*, vol. 21, no. 1, pp. 14–23, JAN 2016.
- [16] W. H. Organization, "Chronic obstructive pulmonary disease (copd)," <http://who.int/mediacentre/factsheets/fs315/en/>, nov 2016, accessed: 2017-01-31.
- [17] —, "The top 10 causes of death," <http://who.int/mediacentre/factsheets/fs310/en/>, jan 2017, accessed: 2017-01-31.
- [18] M. N. *et al.*, "Global, regional, and national age-sex specific all-cause and cause-specific mortality for 240 causes of death, 1990-2013: a systematic analysis for the Global Burden of Disease Study 2013," *Lancet*, vol. 385, no. 9963, pp. 117–171, JAN 10 2015.
- [19] C. D. Mathers and D. Loncar, "Projections of global mortality and burden of disease from 2002 to 2030," *Plos Medicine*, vol. 3, no. 11, NOV 2006.
- [20] R. de Marco, S. Accordini, I. Cerveri, A. Corsico, J. Sunyer, F. Neukirch, N. Kunzli, B. Leynaert, C. Janson, T. Gislason, P. Vermeire, C. Svanes, J. Anto, P. Burney, and E. C. R. H. Surve, "An international survey of chronic obstructive pulmonary disease in young adults according to GOLD stages," *Thorax*, vol. 59, no. 2, pp. 120–125, FEB 1 2004.
- [21] A. Katzenstein and J. Myers, "Idiopathic pulmonary fibrosis - Clinical relevance of pathologic classification," *American Journal Of Respiratory And Critical Care Medicine*, vol. 157, no. 4, pp. 1301–1315, APR 1998.
- [22] G. Raghu, H. R. Collard, J. J. Egan, F. J. Martinez, J. Behr, K. K. Brown, T. V. Colby, J.-F. Cordier, K. R. Flaherty, J. A. Lasky, D. A. Lynch, J. H. Ryu, J. J. Swigris, A. U. Wells, J. Ancochea, D. Bousros, C. Carvalho, U. Costabel, M. Ebina, D. M. Hansell, T. Johkoh, D. S. Kim, T. E. King, Jr., Y. Kondoh, J. Myers, N. L. Mueller, A. G. Nicholson, L. Richeldi, M. Selman, R. F. Duden, B. S. Griss, S. L. Protzko, H. J. Schuenemann, and A. E. J. A. Comm, "An Official ATS/ERS/ALAT Statement: Idiopathic Pulmonary Fibrosis: Evidence-based Guidelines for Diagnosis and Management," *American Journal Of Respiratory And Critical Care Medicine*, vol. 183, no. 6, pp. 788–824, MAR 15 2011.
- [23] E. S. White, Z. Borok, K. K. Brown, O. Eickelberg, A. Guenther, R. G. Jenkins, M. Kolb, F. J. Martinez, J. Roman, P. Sime, and A. T. S. R. Cell, "An American Thoracic Society Official Research Statement: Future Directions in Lung Fibrosis Research," *American Journal Of Respiratory And Critical Care Medicine*, vol. 193, no. 7, pp. 792–800, APR 1 2016.
- [24] R. Prasad, N. Gupta, A. Singh, and P. Gupta, "Diagnosis of idiopathic pulmonary fibrosis: current issues," *Intractable & rare diseases research*, vol. 4, no. 2, pp. 65–69, 2015.
- [25] T. E. King, Jr., A. Pardo, and M. Selman, "Idiopathic pulmonary fibrosis," *Lancet*, vol. 378, no. 9807, pp. 1949–1961, DEC 3 2011.
- [26] K. Raimundo, E. Chang, M. S. Broder, K. Alexander, J. Zazzali, and J. J. Swigris, "Clinical and economic burden of idiopathic pulmonary fibrosis: a retrospective cohort study," *Bmc Pulmonary Medicine*, vol. 16, JAN 5 2016.
- [27] P. Spagnolo, "Pirfenidone and mortality in idiopathic pulmonary fibrosis," *Lancet Respiratory Medicine*, vol. 5, no. 1, pp. 3–5, JAN 2017.
- [28] J. H. da Silva Felix, P. C. Cortez, M. A. Holanda, and R. C. S. Costa, *Automatic Segmentation and Measurement of the Lungs in healthy persons and in patients with Chronic Obstructive Pulmonary Disease in CT Images*, bookTitle="IV Latin American Congress on Biomedical Engineering 2007, Bioengineering Solutions for Latin America Health: September 24th–28th, 2007 Margarita Island, Venezuela". Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, pp. 370–373.
- [29] T. K. Liang, T. Tanaka, H. Nakamura, T. Shirahata, and H. Sugiura, "An Automated 3D Emphysema Extraction Method using Lung CT," in *2008 Proceedings Of Sice Annual Conference, Vols 1-7, 2008*, pp. 2994–2998, Annual Conference of the SICE, Chofu, JAPAN, AUG 20-22, 2008.
- [30] J. H. d. S. Felix, P. C. Cortez, and M. A. Holanda, "Sistema automático para quantificação e visualização da aeração pulmonar em imagens de tomografia computadorizada de tórax: Sistema de análise de imagens pulmonares: Saip," *Revista Brasileira de Engenharia Biomédica*, vol. 26, no. 3, pp. 195–208, 2010.
- [31] T. da Silveira Cavalcante, P. C. Cortez, T. M. de Almeida, J. H. da Silva, and M. A. H. Felix, "Segmentação automática 2d de vias aéreas em imagens de tomografia computadorizada do tórax," *Revista Brasileira de Engenharia Biomédica*, vol. 29, no. 4, pp. 389–403, 2013.
- [32] G. T. Herman, *Fundamentals of computerized tomography: image reconstruction from projections*. Springer Science & Business Media, 2009.
- [33] M.-K. Hu, "Visual pattern recognition by moment invariants," *IRE transactions on information theory*, vol. 8, no. 2, pp. 179–187, 1962.
- [34] R. M. Haralick, K. Shanmugam *et al.*, "Textural features for image classification," *IEEE Transactions on systems, man, and cybernetics*, vol. 3, no. 6, pp. 610–621, 1973.
- [35] R. C. Gonzalez and R. E. Woods, *Digital Image Processing (3rd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006.
- [36] M. Anthimopoulos, S. Christodoulidis, A. Christe, and S. Mougialakou, "Classification of Interstitial Lung Disease Patterns Using Local DCT Features and Random Forest," in *2014 36th Annual International Conference Of the IEEE-Engineering-in-Medicine-and-Biology-Society (EMBC)*, ser. IEEE Engineering in Medicine and Biology Society Conference Proceedings, 2014, pp. 6040–6043.
- [37] J. P. Papa, A. X. Falcao, and C. T. N. Suzuki, "Supervised Pattern Classification Based on Optimum-Path Forest," *International Journal Of Imaging Systems And Technology*, vol. 19, no. 2, SI, pp. 120–131, 2009, 12th International Workshop on Combinatorial Image Analysis, Buffalo, NY, APR 07-09, 2008.
- [38] M. Anthimopoulos, S. Christodoulidis, L. Ebner, A. Christe, and S. Mougialakou, "Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network," *Ieee Transactions On Medical Imaging*, vol. 35, no. 5, SI, pp. 1207–1216, MAY 2016.
- [39] W. Zhao, R. Xu, Y. Hirano, R. Tachibana, and S. Kido, "Classification of Diffuse Lung Diseases Patterns by a Sparse Representation Based Method on HRCT Images," in *2013 35th Annual International Conference Of the IEEE-Engineering-in-Medicine-and-Biology-Society (EMBC)*, ser. IEEE Engineering in Medicine and Biology Society Conference Proceedings, 2013, pp. 5457–5460.
- [40] A. A. A. Setio, A. Traverso, T. de Bel, M. S. Berens, C. v. d. Bogaard, P. Cerello, H. Chen, Q. Dou, M. E. Fantacci, B. Geurts *et al.*, "Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: the luna16 challenge," *arXiv preprint arXiv:1612.08012*, 2016.
- [41] N. Tajbakhsh and K. Suzuki, "Comparing two classes of end-to-end machine-learning models in lung nodule detection and classification: MTANNs vs. CNNs," *Pattern Recognition*, vol. 63, pp. 476–486, MAR 2017.

- [42] Y. Haeme, E. D. Angelini, E. A. Hoffman, R. G. Barr, and A. F. Laine, "Adaptive Quantification and Longitudinal Analysis of Pulmonary Emphysema With a Hidden Markov Measure Field Model," *Ieee Transactions On Medical Imaging*, vol. 33, no. 7, pp. 1527–1540, JUL 2014.
- [43] M. S. Nixon and A. S. Aguado, *Feature extraction & image processing for computer vision*. Academic Press, 2012.
- [44] O. Sayadi and M. Shamsollahi, "A model-based bayesian framework for ecg beat segmentation," *Physiological measurement*, vol. 30, no. 3, p. 335, 2009.
- [45] S. L. Gomes, E. d. S. Rebouças, E. C. Neto, J. P. Papa, V. H. C. d. Albuquerque, P. P. Rebouças Filho, and J. M. R. S. Tavares, "Embedded real-time speed limit sign recognition using image processing and machine learning techniques," *Neural Computing and Applications*, pp. 1–12, 2016.
- [46] C.-C. Chang and C.-J. Lin, "LIBSVM: A Library for Support Vector Machines," *Acm Transactions On Intelligent Systems And Technology*, vol. 2, no. 3, SI, 2011.
- [47] T. d. S. Cavalcante, P. C. Cortez, T. M. d. Almeida, J. H. d. S. Felix, and M. A. Holanda, "Automatic 2d segmentation of airways in thorax computed tomography images," *Revista Brasileira de Engenharia Biomédica*, vol. 29, no. 4, pp. 389–403, 2013.
- [48] A. B. N. Ribeiro, "Lung blood vessels segmentation in thoracic ct scans," Master's thesis, Universidade Federal do Ceará, Fortaleza, CE, 2013.
- [49] W. R. Webb, W. E. Brant, and N. M. Major, *Fundamentals of body CT*. Elsevier Health Sciences, 2014.



Alan Magalhães Braga holds a bachelor's (2013) degree in Industrial Mechatronics and master's (2016) degree in Telecommunications Engineering from Federal Institute of Ceará (IFCE), Fortaleza, CE, Brazil. He is currently pursuing his doctorate in Teleinformatics Engineering from Federal University of Ceará (UFC), Fortaleza, CE, Brazil.



Pedro Pedrosa Rebouças Filho received the PhD degree in Teleinformatics Engineering from Federal University of Ceara, Fortaleza, Brazil, in 2013, and is a professor at Federal Institute of Science and Technology, Maracanau, Ceara, Brazil. His current research interest is applications in Computational Vision.



Shara Shami Araújo Alves holds a bachelor's (2015) degree in Computer Science and master's (2017) degree in Telecommunications Engineering from Federal Institute of Ceará (IFCE), Brazil. Her current research interest is applications in Machine Learning.



Elizângela de Souza Rebouças holds a bachelor's (2014) degree in Telecommunication Engineering and master's (2017) degree in Telecommunications Engineering from Federal Institute of Ceará (IFCE), Brazil. Her current research interest are applications of computational intelligence techniques to biomedical images.



Saulo Anderson Freitas de Oliveira holds a bachelor's (2013) degree in Computer Science and master's (2016) degree in Telecommunications Engineering from Federal Institute of Ceará (IFCE), Brazil. He is currently pursuing his doctorate in Computer Science from Universidade Federal do Ceará (UFC), Fortaleza, CE, Brazil.