

# Descrição e Classificação de Nódulos Pulmonares em Imagens de Tomografia Computadorizada

Lima T. J. B<sup>1</sup>., Araújo F. H. D<sup>1</sup>., Vieira P. A<sup>1</sup>., Carvalho N. R. de S<sup>1</sup>., Rodrigues L. A<sup>1</sup>.

<sup>1</sup> Universidade Federal do Piauí (UFPI)  
Campus Senador Helvídeo Nunes de Barros (CSHNB) - Picos-PI - Brasil

{thiagobjb12, pablolukan}@hotmail.com {flavio86, nrdesales}@ufpi.edu.br  
{laecio8andrade}@gmail.com

**Abstract.** Lung cancer is the second most common in Brazil, early detection of solitary pulmonary nodules is essential for patient survival. This paper presents a computational methodology that aims to assist specialists in the detection and classification of pulmonary nodules. For the development of this methodology we performed tests with descriptors HOG, LBP, GLCM and Daisy, and the classifiers MLP, SVM and RF. The tests were performed on a segmented image set containing 1009 benign and 394 malignant nodules. The best results were achieved with the LBP descriptor and the SVM classifier, with an accuracy of 0.85, specificity of 0.84, sensitivity of 0.85, kappa of 0.70 and AUC of 0.85.

**Resumo.** O câncer de pulmão é o segundo mais comum no Brasil, a detecção precoce de nódulos pulmonares solitário é essencial para a sobrevivência do paciente. Este trabalho apresenta uma metodologia computacional que visa auxiliar especialistas na detecção e classificação de nódulos pulmonares. Para o desenvolvimento dessa metodologia realizamos testes com descritores HOG, LBP, GLCM e Daisy, e os classificadores MLP, SVM e RF. Os testes foram realizados em um conjunto de imagens segmentadas contendo 1009 nódulos benignos e 394 malignos. Os melhores resultados foram alcançados com o descritor LBP e o classificador SVM, com uma acurácia de 0,85, especificidade de 0,84, sensibilidade de 0,85, kappa de 0,70 e AUC de 0,85.

## 1. Introdução

O câncer pulmonar é o segundo mais comum no Brasil e o primeiro em todo o mundo. No fim do século XX, o câncer de pulmão se tornou uma das principais causas de morte evitáveis. A análise do nódulo pulmonar utilizando imagens de Tomografia Computadorizada (TC) é uma importante estratégia para o diagnóstico precoce [Inca 2019].

Um nódulo pulmonar é definido como sendo uma opacidade quase esférica de até 3 cm de diâmetro, circundada pelo parênquima pulmonar. Lesões acima de 3 cm são frequentemente classificadas como malignas [de Carvalho Filho et al. 2017].

Com intuito de aumentar a precisão na detecção e diagnósticos de lesões auxiliando o especialista com uma segunda opinião, ferramentas de cunho computacional denominadas *Computer-Aided Detection* (CADe) e *Computer-Aided Diagnosis* (CADx) tem sido amplamente exploradas [Masood et al. 2018].

Este trabalho apresenta uma metodologia computacional que visa auxiliar especialistas na detecção e classificação de nódulos pulmonares. Para o desenvolvimento dessa metodologia realizamos testes com descritores *histogram of oriented gradients* (HOG), *local binary pattern* (LBP), *gray-level co-occurrence matrix* (GLCM) e descritor de imagem local *Daisy* e os classificadores *Multi-layer Perceptron* (MLP), *Support Vector Machines* (SVM) e *Random Forest* (RF). A principal contribuição deste trabalho é a escolha dos melhores parâmetros para cada descritor. Os parâmetros dos descritores foram gerados de forma sequencial e testados com os classificadores, utilizando seus parâmetros *defaults*.

## 2. Trabalhos Relacionados

[da Nobrega et al. 2018] desenvolveu um método utilizando diferentes arquiteturas de *Convolutional Neural Network* (CNN) para a extração de características das imagens do *Lung Image Database Consortium* e o *Image Database Resource Initiative* (LIDC-IDRI). Em seguida, as imagens foram classificadas utilizando os classificadores *Naive bayes*, MLP, SVM, *Near Neighbors* (KNN) e RF. Como resultado foi observado que as melhores combinações de extração profunda e classificação foram obtidos com CNN-ResNet50 com SVM-RBF alcançando Acurácia de 88,41% e Curva ROC (AUC) de 93,19%.

[Tang et al. 2018] desenvolveu um algoritmo que consiste de uma R-CNN 3d *Faster* inspirada em U-Net e um classificador 3D para a redução de falsos positivos. No método proposto os autores abordaram aproximadamente dois estágios: (1) triagem candidata usando uma RCNN 3D *Faster*, e (2) redução de falsos positivos subsequentes usando classificadores 3D *Deep Convolutional Neural Networks* (DCNN).

[Sharma et al. 2018] em seu trabalho desenvolveu um algoritmo de duas etapas para a detecção precoce do câncer de pulmão. Na 1ª etapa é abordado um método Otsu seguido de operações morfológicas para a segmentação. Na 2ª etapa, foi utilizado uma CNN para a classificação de nódulos em malignos ou benignos. Neste experimento foram utilizados 6.306 imagens de TC do banco de dados do LIDC-IDRI sendo alcançado uma precisão de 84,13%, com a sensibilidade e especificidade de 91,69% e 73,16%.

## 3. Método Proposto

Nesta seção, descrevemos a metodologia utilizada para segmentar as imagens da base LIDC-IDRI e classificar os nódulos pulmonares em benignos ou malignos. Os estágios envolvidos nestas etapas são apresentados na Figura 1.

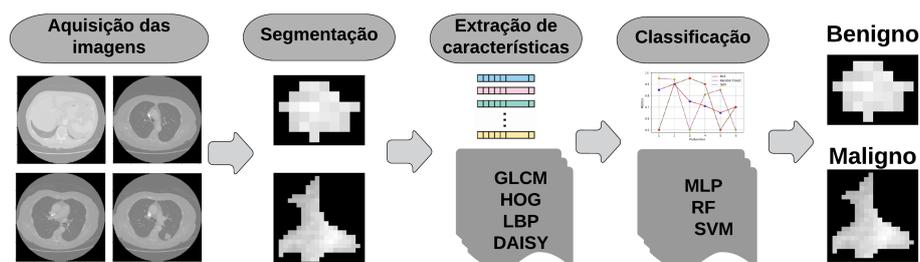


Figura 1. Fluxograma do método proposto dividido em quatro etapas: aquisição das imagens, segmentação, extração de características e classificação.

A metodologia proposta está dividida em quatro etapas: aquisição das imagens, segmentação, extração de características e classificação. Afim de encontrar uma melhor combinação de parâmetros para os descritores, na etapa de classificação foram testados cada conjunto de características geradas a partir dos descritores, utilizando os classificadores MLP, RF e SVM com seus parâmetros *defaults*.

### 3.1. Aquisição das imagens

A coleção de imagens LIDC-IDRI consiste no diagnóstico e rastreamento do câncer pulmonar em TCs com lesões marcadas. O conjunto contém 1018 exames, cada um inclui imagens de uma tomografia computadorizada torácica clínica e um arquivo XML associado que registra os resultados de um processo de anotação de imagens de duas fases realizado por quatro radiologistas torácicos [Armato III et al. 2011].

### 3.2. Segmentação

Como o objetivo deste trabalho foi a descrição das imagens, utilizamos um método proposto por [de Carvalho Filho et al. 2017] para a segmentação das regiões candidatas a nódulos.

### 3.3. Extração de características

Os descritores utilizados foram: LBP [Awad and Hassaballah 2016], HOG [Dalal and Triggs 2005], Daisy [Tola et al. 2010] e GLCM [Cuzzocrea et al. 2012]. Os parâmetros dos descritores foram gerado de forma sequencial. Na seção de resultados serão mostrados os melhores parâmetros encontrados para cada descritor.

### 3.4. Classificação

Os classificadores utilizados foram: MLP [Nicolas 2015], RF [Suthaharan 2016] e SVM [Bell 2014]. Foram utilizados os parâmetros *defaults* de cada classificador, afim de encontrar a melhor combinação de parâmetros dos descritores.

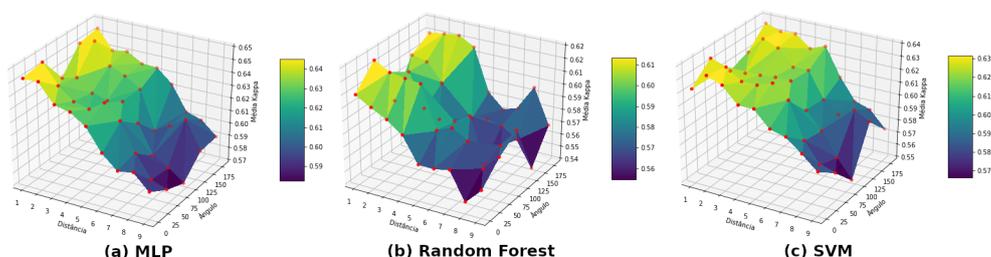
## 4. Resultados e discussão

Nessa seção são apresentados os resultados obtidos para cada um dos descritores e classificadores avaliados. Os testes foram realizados em um conjunto com 1009 nódulos benignos e 394 malignos, nos quais 70% foram utilizados para o treino e 30% para o teste. Os nódulos segmentados são formados por varias fatias de imagens, e consideramos cada uma dessas fatias como uma instância, sendo 4.327 benigno e 3.967 maligno.

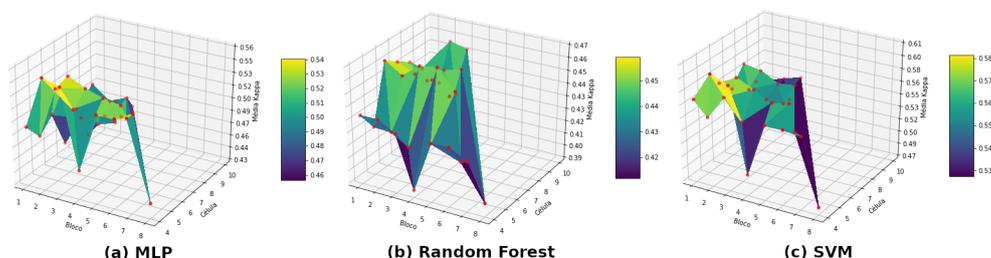
A Figura 2 apresenta as combinações dos parâmetros do descritor GLCM. Foi variado a distância de 1 a 9 e os ângulos (0, 45, 90, 135 e 180). Para o classificador MLP apresentado na Figura 2 (a), a melhor combinação de parâmetro foi distância 2 e ângulo 135, com valor do kappa de 0,65. O classificador RF (Figura 2 (b)), apresenta a distância 1 e ângulos 45 como melhores parâmetros, obtendo um kappa de 0,62. Já na Figura 2 (c), onde é apresentado o classificador SVM, tivemos como melhores parâmetros a distância 1 e ângulo 180, obtendo kappa de 0,63. Podemos perceber que quanto menor a distância melhor o resultado obtido, mesmo variando o ângulo.

O descritor HOG é apresentada na Figura 3. Foi variado a célula de 4 a 10 e o bloco de 1 a 8. A Figura 3 (a) apresenta os resultados após a classificação com a MLP,

a célula 4 e bloco 2 foi o que obteve um melhor resultado, obtendo o kappa de 0,55. A Figura 3 (b) apresenta o resultado da classificação com o RF, o melhor parâmetro foi a célula 6 e bloco 4, obtendo o kappa de 0,46. Já o classificador SVM apresentado na Figura 3 (c), teve como melhor parâmetro a célula 4 e bloco 2, apresentando o kappa de 0,60. Observamos que quando o valor célula for menor, obtemos um melhor resultado.

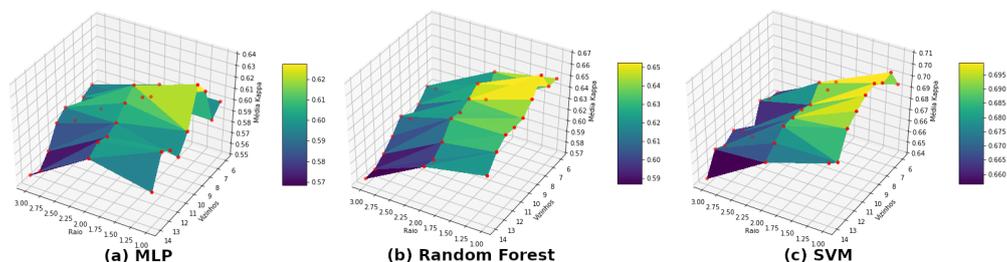


**Figura 2. Variação de parâmetros (distância e ângulo) do descritor GLCM.**



**Figura 3. Variação de parâmetros (célula e bloco) do descritor HOG.**

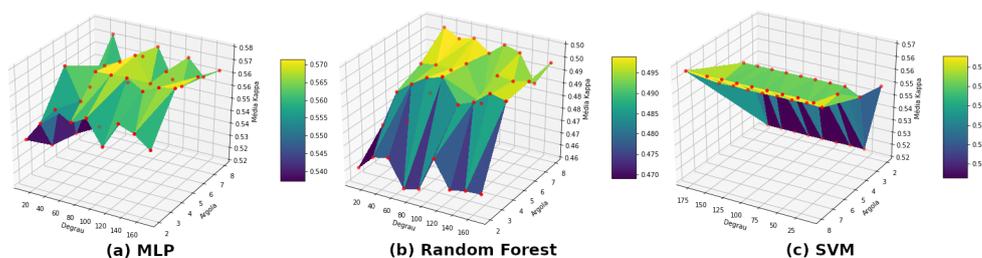
O descritor LBP mostrado na Figura 4, com variação de parâmetros: raio de 1 a 3 e número de vizinhos de 6 a 14, apresenta ótimos resultados. A classificação com a MLP apresentada na Figura 4 (a), com a combinação de parâmetro raio 1 e vizinhos 9, apresentou o kappa de 0,63. A Figura 4 (b) apresenta os resultados do classificador RF, destacando os parâmetros raio 1 e vizinho 8 com o kappa de 0,66. O SVM apresentado na Figura 4 (c) teve como melhor parâmetro o raio 1 e vizinhos 9, obtendo um kappa de 0,70. Observamos que o raio 1 e número de vizinhos 8 e 9, se destacaram, obtendo os melhores resultados apresentados por cada classificador.



**Figura 4. Variação de parâmetros (raio e número de vizinhos) do descritor LBP.**

A Figura 5 apresenta o descritor *Daisy*. Foi variado o degrau em (10, 30, 50, 70, 90, 110, 130, 150 e 170), argola(2, 4, 6 e 8) e raio com valor fixo 7. Inicialmente foi realizados outros teste e o parâmetro raio 7 apresentou o melhor resultado. A Figura 4

(a) apresenta os resultados após a classificação com a MLP, onde se destaca o degrau 170 e argola 4, com o kappa 0,57. A Figura 5 (b) apresenta os resultados referente ao classificador RF, onde se destaca o degrau 30 e argola 8, com o kappa 0,50. Por último, a Figura 5 (c) com os resultados do SVM, contendo como melhor parâmetro o degrau 30 e argola 8, obtendo o kappa de 0,56. Podemos observar que os melhores resultados foram com argola 8, mesmo variando o degrau.



**Figura 5. Variação de parâmetros (degrau, argola e raio 7) do descritor *Daisy*.**

A Tabela 1 apresenta os melhores resultados das combinações de parâmetros dos descritores em relação a cada classificador. Foram utilizadas as métricas: acurácia (Ac), especificidade (Es), sensibilidade (Se), kaapa (Ka) e AUC.

**Tabela 1. Melhores resultados de cada descritor**

Descritor	Classificador	Ac	Es	Se	Ka	AUC	Parâmetros
GLCM	MLP	0,82	0,79	0,85	0,65	0,82	Distância 2, Ângulo 135
	RF	0,81	0,79	0,82	0,62	0,81	Distância 1, Ângulo 45
	SVM	0,81	0,78	0,85	0,63	0,81	Distância 1, Ângulo 180
HOG	MLP	0,77	0,77	0,78	0,55	0,77	Célula(4, 4), Bloco(2, 2)
	RF	0,73	0,76	0,71	0,46	0,73	Célula(6, 6), Bloco(4, 4)
	SVM	0,80	0,77	0,82	0,60	0,80	Célula(4, 4), Bloco(2, 2)
LBP	MLP	0,81	0,84	0,79	0,63	0,82	Raio 1, Vizinhos 9
	RF	0,83	0,87	0,80	0,66	0,83	Raio 1, Vizinhos 8
	SVM	0,85	0,84	0,85	0,70	0,85	Raio 1, Vizinhos 9
Daisy	MLP	0,78	0,77	0,79	0,57	0,78	Degrau 170, Argola 4
	RF	0,75	0,75	0,75	0,50	0,75	Degrau 30, Argola 8
	SVM	0,78	0,77	0,78	0,56	0,78	Degrau 30, Argola 8

## 5. Conclusão

Neste trabalho, foi apresentada uma metodologia computacional que visa auxiliar especialistas na detecção e classificação de nódulos pulmonares. Os melhores resultados da metodologia foram alcançados com o descritor LBP e o classificador SVM, obtendo uma acurácia de 0,85, especificidade de 0,84, sensibilidade de 0,85, kappa de 0,70 e AUC de 0,85. O descritor GLCM ficou em segundo lugar e dentre os classificadores a MLP se destacou, obtendo uma acurácia de 0,82, especificidade de 0,79, sensibilidade de 0,85, kappa de 0,65 e AUC de 0,82.

Apesar do descritor LBP e o classificador SVM obterem melhor acurácia, esta combinação não domina a combinação LBP e RF no critério Es. Os resultados encontrados demonstram a importância da escolha dos melhores parâmetros na etapa de extração

de características. Pretende-se em trabalhos futuros, encontrar melhores parâmetros para cada classificador abordado neste trabalho, como também realizar testes utilizando arquiteturas de CNNs.

## Referências

- Armato III, S. et al. (2011). The lung image database consortium (lidc) and image database resource initiative (idri): A completed reference database of lung nodules on ct scans. *Medical Physics*, 38:915–931.
- Awad, A. I. and Hassaballah, M. (2016). Image feature detectors and descriptors. *Studies in Computational Intelligence. Springer International Publishing, Cham*.
- Bell, J. (2014). *Machine learning: hands-on for developers and technical professionals*. John Wiley & Sons.
- Cuzzocrea, A., Manco, G., and Masciari, E. (2012). Effective detection of xml outliers. In *KES*, pages 1221–1232.
- da Nobrega, R. V. M. et al. (2018). Lung nodule classification via deep transfer learning in ct lung images. In *2018 IEEE 31st International Symposium on Computer-Based Medical Systems (CBMS)*, pages 244–249.
- Dalal, N. and Triggs, B. (2005). Histograms of oriented gradients for human detection. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, volume 1, pages 886–893 vol. 1.
- de Carvalho Filho, A. O., , et al. (2017). Computer-aided diagnosis system for lung nodules based on computed tomography using shape analysis, a genetic algorithm, and svm. *Medical & Biological Engineering & Computing*, 55(8):1129–1146.
- Inca (2019). Instituto Nacional do Câncer - ministério da saúde, câncer de pulmão. <https://www.inca.gov.br/tipos-de-cancer/cancer-de-pulmao>. Acessado em: 02/08/2019.
- Masood, A. et al. (2018). Computer-assisted decision support system in pulmonary cancer detection and stage classification on ct images. *Journal of Biomedical Informatics*, 79:117 – 128.
- Nicolas, P. R. (2015). *Scala for machine learning*. Packt Publishing Ltd.
- Sharma, M., Bhatt, J. S., and Joshi, M. V. (2018). Early detection of lung cancer from ct images: nodule segmentation and classification using deep learning. In *Tenth International Conference on Machine Vision (ICMV 2017)*, volume 10696, page 106960W. International Society for Optics and Photonics.
- Suthaharan, S. (2016). Machine learning models and algorithms for big data classification. *Integr. Ser. Inf. Syst*, 36:1–12.
- Tang, H., Kim, D. R., and Xie, X. (2018). Automated pulmonary nodule detection using 3d deep convolutional neural networks. In *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, pages 523–526.
- Tola, E., Lepetit, V., and Fua, P. (2010). Daisy: An efficient dense descriptor applied to wide-baseline stereo. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(5):815–830.