

Segmentação de Nódulos Pulmonares Baseada em Redes Neurais Convolucionais (CNN)

Paulo Henrique Junqueira Amorim (Bolsista CTI); Jorge Vicente Lopes da Silva (CTI);

Thiago Franco de Moraes (Bolsista CTI); Hélio Pedrini (Unicamp)

paulo.amorim@cti.gov.br

Resumo

Segmentação de imagens é utilizada em várias áreas do conhecimento, como medicina, onde desempenha um papel crucial em várias aplicações médicas, sendo uma parte importante do diagnóstico clínico. Recentemente técnicas de redes neurais profundas melhoraram significativamente as tarefas de segmentação e classificação de imagens médicas. Neste trabalho, exploramos o uso das redes neurais convolucionais (CNN) para a segmentação de nódulos pulmonares orientado a patches e múltiplas orientações. Experimentos realizados no conjunto de dados público LIDC-IRI demonstram que os resultados obtiveram altas taxas de acurácia quando comparada com a segmentação realizada pelo especialista, além disso, também foi possível reduzir o número de falsos negativos.

Palavras-chave: Imagens médicas, Segmentação de Imagens, Redes Neurais Profundas.

1. Introdução

Câncer de pulmão é uma das formas mais agressivas da doença. No Brasil, por exemplo, estima-se que 31.270 novos casos ocorreram apenas em 2018. Nos Estados Unidos, 1.688.780 novos casos foram relatados em 2017 (SIEGEL, MILLER & JEMAL 2017).

A detecção precoce de nódulos pulmonares é crucial para aumentar a taxa de sobrevivência do paciente. Uma ferramenta de diagnóstico clínico comum é a tomografia computadorizada (TC) em que os radiologistas geralmente medem certas características do possível nódulo, como tamanho (MARGERIE-MELLON, HEIDINGER & BANKIER 2018) e densidade (HEIDINGER et al. 2017) de possíveis nódulos. Antes de realizar essas medidas, é necessário selecionar a possível lesão usando alguma técnica de segmentação de imagem.

Técnicas de segmentação de imagens têm como objetivo dividir a imagem em regiões ou objetos (SCHWARTZ & PEDRINI 2007). Elas podem ser classificadas em três abordagens diferentes: (i) segmentação manual, onde o radiologista indica cada pixel da lesão manualmente, (ii) segmentação semi-automática, onde alguns parâmetros são definidos pelo usuário e o algoritmo realiza a seleção da lesão e (iii) métodos de segmentação automática, onde não há necessidade de configurar nenhum parâmetro, basta acionar um algoritmo ou sistema inteligente.

O objetivo deste trabalho é realizar segmentação automática de nódulos pulmonares, utilizando redes neurais convolucionais (CNN), com uma abordagem de múltipla orientação e *patches* de imagens. Para redução de falso negativo, foi utilizado o algoritmo de crescimento de regiões após a união dos três volumes contendo a probabilidade de ocorrência de uma lesão. Resultados experimentais no conjunto de dados público LIDC-IRI demonstraram que o método proposto foi capaz de atingir níveis de segmentação próximos de um especialista.

O texto está organizado da seguinte maneira. A seção 2 apresenta conceitos e trabalhos relacionados. A seção 3 descreve a metodologia proposta. Os resultados experimentais são

apresentados e discutidos na seção 4. Por fim, a seção 5 conclui o trabalho e apresenta as direções para trabalhos futuros.

2. Trabalhos Relacionados

A segmentação de nódulos pulmonares a partir de imagens de tomografia computadorizada (TC) fornece informações relevantes para o diagnóstico, reduzindo a intervenção manual e subjetiva de especialistas humanos.

Embora várias abordagens de segmentação de nódulo pulmonar tenham sido desenvolvidas nos últimos anos (BOBADILLA & PEDRINI 2016, WANG et al. 2017, KHOSRAVAN & BAGCI 2018, ALILOU et al. 2017), a obtenção de resultados precisos e robustos de segmentação ainda é uma tarefa desafiadora devido ao grande volume de imagens e variabilidade dos dados de TC.

Nos últimos anos, redes neurais profundas (LECUN, BENGIO & HINTON 2015) foram aplicadas em várias áreas, incluindo a medicina (BREBISSON & MONTANA 2015, MOESKOPS et al. 2016, LI, JIA & Hu 2015). Mais especificamente para a segmentação de nódulos pulmonares, essas redes foram aplicadas nos trabalhos propostos por WANG et al. 2017 e KAMAL et al. 2018.

Uma rede neural convolucional (CNN) (KRIZHEVSKY, SUTSKEVER & HINTON 2012), se comparada a rede perceptron de multi-camadas (MLP), é diferenciada pela rede convolucional aplicar diversos filtros na imagem de entrada com objetivo de extrair quais filtros melhor aprende determinadas características. Além disso, elas são invariantes ao espaço e deslocamento. Outra característica é a quantidade excessiva de dados necessários para executar a etapa de treinamento.

3. Metodologia

Neste trabalho foram consideradas imagens de tomografia computadorizada (TC) de pulmão com nódulos de diferentes tamanhos. Os principais passos da metodologia proposta neste trabalho são ilustradas na figura 1. Inicialmente, o brilho e contraste das imagens foram normalizados para visualização de pulmão, com valores de -600 HU e 1500 HU (BANKIER et al. 2017).

As imagens e o *ground truth* foram empilhadas e interpoladas usando a interpolação de spline cúbico (BOOR et al. 1978). Em seguida, ambos os volumes foram re-amostrados nas orientações axial (XZ), coronal (XY) e sagital (YZ).

O *ground truth* foi usado para selecionar os pixels que tinham mais de 50% de consenso entre pelo menos dois radiologistas. Para evitar inconsistências na fase de treinamento, nódulos reconhecidos por apenas um radiologista foram descartados.

A partir das imagens de cada uma das três orientações (axial, coronal e sagital), foi extraída amostras de resolução de 128×128 pixels em passos de 64 pixels. Três instâncias da rede neural convolucional de arquitetura U-Net foram empregadas, cada uma para treinamento e predição dos *patches* de cada orientação. As dimensões das imagens de entrada e os pesos da rede foram alterados em relação ao trabalho que deu origem a rede U-Net (RONNEBERGER, FISCHER & BROX 2015). Esses novos valores podem ser observados na figura 2.

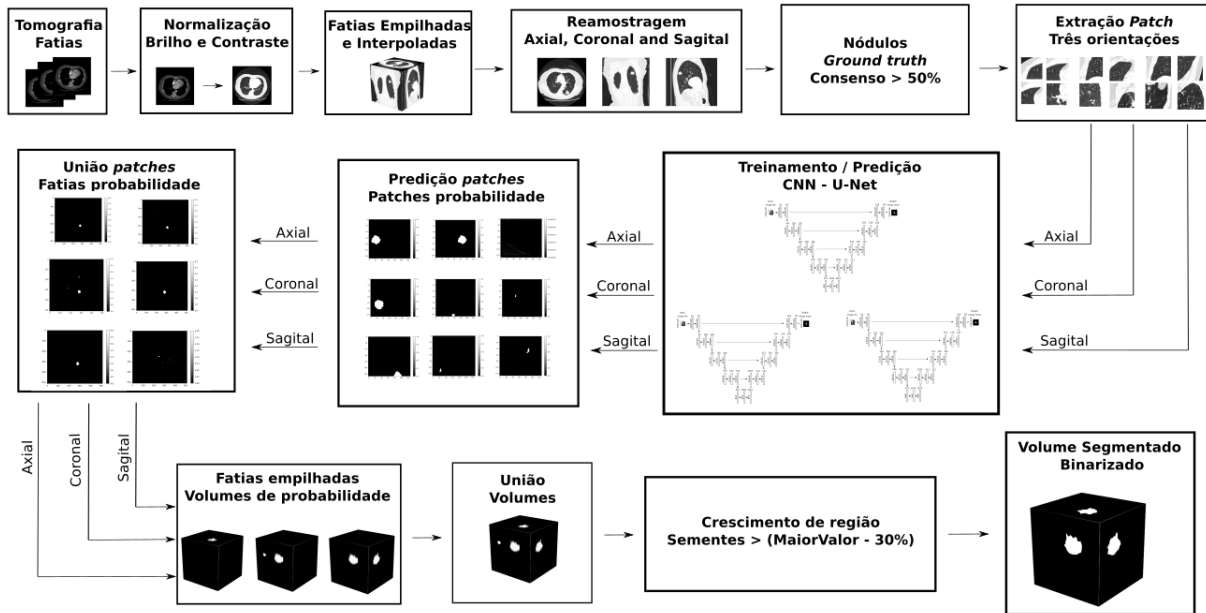


Figura 1 – Diagrama da metodologia utilizada no trabalho

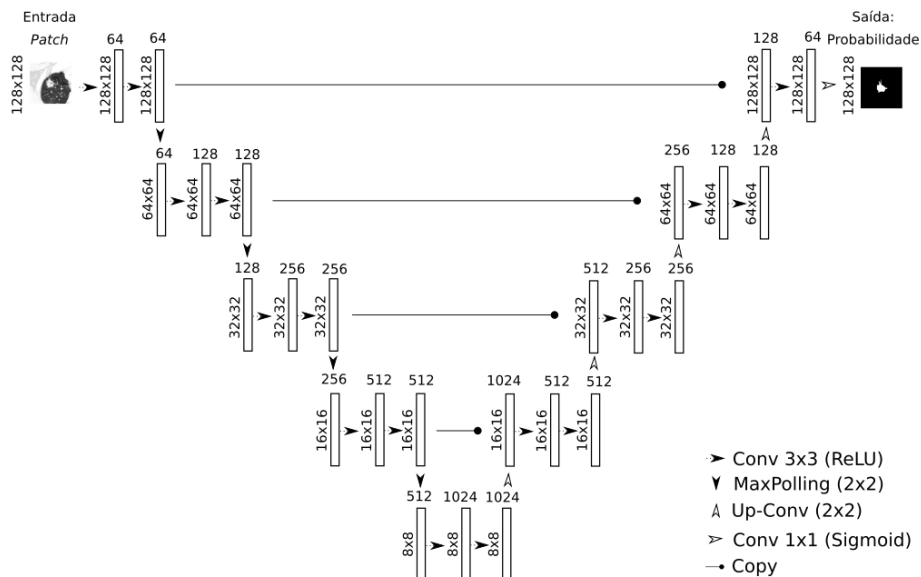


Figura 2 – Arquitetura da rede U-Net modificada

Após cada camada de ativação, a normalização em lote (*batch normalization*) foi usada. Na última camada foi utilizada a função sigmóide. Além disso, o otimizador Adam foi usado com uma taxa de aprendizado de 0.0001. Na etapa de treinamento, foi empregada a técnica de *data augmentation*, essa técnica consiste em gerar novas imagens a partir da aplicação de transformação geométrica: rotação (1-180), cisalhamento (1-60%), zoom (1-30%), reflexão horizontal e vertical.

Na etapa de predição, a saída da rede é um conjunto de *patches*, onde o valor de cada pixel indica a probabilidade de pertencer a um nódulo. Esses *patches* são unidos para formar uma imagem de probabilidade em ambas as orientações. Três volumes são formados a partir do empilhamento dessas imagens de probabilidade. Os volumes são unidos, gerando um único volume. Para reduzir os falsos negativos, todos os pixels com valores que satisfazem a

equação 1 são selecionados no volume resultante. Os pixels são usados como sementes na aplicação do algoritmo de crescimento da região (ADAMS & BISCHOF 1994).

$$\text{Sementes} = p(x,y,z) > \text{MaiorValor}(p) - 0.30 * \text{MaiorValor}(p)$$

Equação 1

Método	Técnica	Dice (%)
Farag et al. (Farag et al. 2013)	Level Sets	60
Ye et al. (Ye, Beddoe e Slabaugh 2010)	Graph Cut	74
Kamal et al. (Kamal et al. 2018)74	Deep Learning U-Net 3D	74
Ye et al. (Ye et al. 2009)	Shape based + SVM	76
Wang et al. (Wang et al. 2017)	Multi-View Deep Convolutional Neural Networks	77
Wang et al. (Wang et al. 2017)	Deep Learning CF-CNN	80
Khosravan and Bagci (Khosravan e Bagci 2018)	Single Task Learning	82
Metodologia proposta	U-Net with Multi-Orientation and Patchwise	83
Khosravan and Bagci (Khosravan e Bagci 2018)	Multi-Task Learning	86

Tabela 2 – Comparativo dos resultados obtidos com o método proposto (negrito) com outros métodos obtidos na literatura.

4. Resultados experimentais

Esta apresenta os resultados experimentais obtidos com a segmentação de nódulos pulmonares baseado em redes neurais convolucionais.

Em nossos experimentos, usamos o conjunto de dados público LIDC-IRI (ARMATO et al. 2011) para avaliar a eficácia de nosso método de segmentação de nódulos pulmonares. Esse conjunto de dados consiste em 1.018 exames de tomografia computadorizada adquiridos de 1.010 pacientes, resultando em 7.371 lesões reconhecidas por pelo menos um radiologista.

O conjunto de dados, após a etapa de pré-processamento, foi dividido na proporção de 80% para treinamento e 20% para validação e teste. A estratégia de utilizar *patches* de 128×128 foi escolhida para não sobrecarregar a memória da placa de vídeo e para poder usar um lote de 64 imagens ground truth durante o treinamento. O processo de treinamento foi executado em 200 épocas e utilizada a validação cruzada. As seguintes métricas foram usadas na etapa de validação: Coeficiente de Sørensen-Dice (DSC) (Equação 2) e interseção sobre união (IoU) ou coeficiente Jaccard (Equação 3). Nas duas equações, P é o resultado da predição e G é o ground truth, ambas são imagens binárias.

$$\frac{2 | P \cap G |}{| P \cap G | + | P \cup G |}$$

Equação 2: Coeficiente de Sørensen-Dice (DSC)

$$\frac{P \cap G}{P \cup G}$$

Equação 3: Interseção sobre união (IoU) ou coeficiente Jaccard

Em nossos experimentos, foi possível obter 83% de coeficiente de Sørensen-Dice e 76% no coeficiente de interseção sobre a união após somar o resultado dos três volumes. Apenas para orientação axial, foram obtidos 74% no coeficiente Dice, enquanto 63% e 68% para

orientações coronal e sagital, respectivamente. A abordagem de somar todos os três volumes de probabilidade de cada orientação e depois usar os maiores valores como semente no algoritmo de crescimento de região permitiu reduzir a quantidade de falsos positivos em média de 50% e aumentar o coeficiente de Dice.

5. Conclusões e trabalhos futuros

Neste trabalho, propusemos e analisamos um método para segmentar nódulos pulmonares em imagens de tomografia computadorizada usando redes neurais convolucionais com abordagem multi-orientação e *multi-patches*. Os resultados experimentais demonstraram a eficácia do método proposto, alcançando altas taxas de coeficiente de Sørensen-Dice.

Como orientações para trabalhos futuros, pretendemos explorar a segmentação de outras partes do corpo humano, bem como incorporar a abordagem de segmentação de nódulos pulmonares no software livre InVesalius (AMORIM et al. 2015).

Agradecimentos

Referências

- ADAMS, R.; BISCHOF, L. *Seeded Region Growing*. IEEE Transactions on Pattern Analysis and Machine Intelligence, IEEE, v. 16, n. 6, p. 641–647, 1994.
- ALILOU, M.; BEIG, N.; OROOJI, M.; RAJIAH, P.; VELCHETI, V.; RAKSHIT, S.; REDDY, N.; YANG, M.; JACONO, F.; GILKESON, R. C. *An Integrated Segmentation and Shape-based Classification Scheme for Distinguishing Adenocarcinomas from Granulomas on Lung CT*. Medical Physics, Wiley Online Library, v. 44, n. 7, p. 3556–3569, 2017.
- AMORIM, P.; MORAES, T.; SILVA, J.; PEDRINI, H. *InVesalius: An Interactive Rendering Framework for Health Care Support*. In: SPRINGER. International Symposium on Visual Computing. [S.l.], 2015. p. 45–54.
- ARMATO, S. G.; MCLENNAN, G.; BIDAUT, L.; MCNITT-GRAY, M. F.; MEYER, C. R.; REEVES, A. P.; ZHAO, B.; ABERLE, D. R.; HENSCHKE, C. I.; HOFFMAN, E. A. *The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A Completed Reference Database of Lung Nodules on CT Scans*. Medical Physics, Wiley Online Library, v. 38, n. 2, p. 915–931, 2011.
- BANKIER, A. A.; MACMAHON, H.; GOO, J. M.; RUBIN, G. D.; SCHAEFER-PROKOP, C. M.; NAIDICH, D. P. *Recommendations for Measuring Pulmonary Nodules at CT: A Statement from the Fleischner Society*. Radiology, Radiological Society of North America, v. 285, n. 2, p. 584–600, 2017.
- BOBADILLA, J. C. M.; PEDRINI, H. *Lung Nodule Classification based on Deep Convolutional Neural Networks*. In: SPRINGER-VERLAG. 21st Iberoamerican Congress on Pattern Recognition. Lima, Peru, 2016. p. 117–124.
- BOOR, C. D.; BOOR, C. D.; MATHÉMATICIEN, E.-U.; BOOR, C. D.; BOOR, C. D. *A Practical Guide to Splines*. [S.l.]: Springer-Verlag New York, 1978.
- BREISSON, A. & MONTANA, G. *Deep Neural Networks for Anatomical Brain Segmentation*. In: IEEE Conference on Computer Vision and Pattern Recognition Workshops. [S.l.: s.n.], 2015. p. 20–28.
- FARAG, A. A.; MUNIM, H. E. A. E.; GRAHAM, J. H. & FARAG, A. A. *A Novel Approach for Lung Nodules Segmentation in Chest CT using Level Sets*. IEEE Transactions on Image Processing, IEEE, v. 22, n. 12, p. 5202–5213, 2013.
- HEIDINGER, B. H.; ANDERSON, K. R.; NEMEC, U.; COSTA, D. B.; GANGADHARAN, S. P.; VANDERLAAN, P. A. & BANKIER, A. A. *Lung Adenocarcinoma Manifesting as Pure Ground-Glass Nodules: Correlating CT Size, Volume, Density, and Roundness with Histopathologic Invasion and Size*. Journal of Thoracic Oncology, Elsevier, v. 12, n. 8, p. 1288–1298, 2017.

- KAMAL, U.; RAFI, A. M.; HOQUE, R. & HASAN, M.** *Lung Cancer Tumor Region Segmentation Using Recurrent 3D-DenseUNet*. arXiv preprint arXiv:1812.01951, 2018.
- KHOSRAVAN, N. & BAGCI, U.** *Semi-Supervised Multi-Task Learning for Lung Cancer Diagnosis*. In: IEEE. 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). [S.l.], 2018. p. 710–713.
- KRIZHEVSKY, A.; SUTSKEVER, I. & HINTON, G. E.** *Imagenet Classification with Deep Convolutional Neural Networks*. In: Advances in Neural Information Processing Systems. [S.l.: s.n.], 2012. p. 1097–1105.
- LECUN, Y.; BENGIO, Y. & HINTON, G.** *Deep Learning*. Nature, Nature Publishing Group, v. 521, n. 7553, p. 436, 2015.
- LI, W.; JIA, F. & HU, Q.** *Automatic Segmentation of Liver Tumor in CT Images with Deep Convolutional Neural Networks*. Journal of Computer and Communications, Scientific Research Publishing, v. 3, n. 11, p. 146, 2015.
- MARGERIE-MELLON, C.; HEIDINGER, B. H. & BANKIER, A. A.** *2D or 3D Measurements of Pulmonary Nodules: Preliminary Answers and More Open Questions*. Journal of thoracic disease, AME Publications, v. 10, n. 2, p. 547, 2018.
- MOESKOPS, P.; WOLTERINK, J. M.; VELDEN, B. H. van der; GILHUIJS, K. G.; LEINER, T.; VIERGEVER, M. A. & IŞGUM, I.** *Deep Learning for Multi-Task Medical Image Segmentation in Multiple Modalities*. In: SPRINGER. International Conference on Medical Image Computing and Computer-Assisted Intervention. [S.l.], 2016. p. 478–486.
- RONNEBERGER, O.; FISCHER, P. & BROX, T.** *U-Net: Convolutional Networks for Biomedical Image Segmentation*. In: SPRINGER. International Conference on Medical Image Computing and Computer-Assisted Intervention. [S.l.], 2015. p. 234–241.
- SCHWARTZ, W. R. & PEDRINI, H.** *Color Textured Image Segmentation based on Spatial Dependence using 3D Co-occurrence Matrices and Markov Random Fields*. In: 15th International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision. Plzen, Czech Republic: [s.n.], 2007. p. 81–87. IX Seminário em TI do PCI/CTI – 2019
- SIEGEL, R. L.; MILLER, K. D.; JEMAL, A.** *Cancer Statistics*. CA: A Cancer Journal for Clinicians, Wiley Online Library, v. 66, n. 1, p. 7–30, 2017.
- SILVA, R. D.; MINETTO, R.; SCHWARTZ, W. R. & PEDRINI, H.** *Satellite Image Segmentation using Wavelet Transforms based on Color and Texture Features*. In: SPRINGER. International Symposium on Visual Computing. [S.l.], 2008. p. 113–122.
- SÜNDERHAUF, N.; BROCK, O.; SCHEIRER, W.; HADSELL, R.; FOX, D.; LEITNER, J.; UPCROFT, B.; ABBEEL, P.; BURGARD, W. & MILFORD, M.** *The Limits and Potentials of Deep Learning for Robotics*. The International Journal of Robotics Research, SAGE Publications Sage UK: London, England, v. 37, n. 4-5, p. 405–420, 2018.
- WANG, S.; ZHOU, M.; GEVAERT, O.; TANG, Z.; DONG, D.; LIU, Z. & TIAN, J.** *A Multi-View Deep Convolutional Neural Networks for Lung Nodule Segmentation*. In: IEEE. 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. [S.l.], 2017. p. 1752–1755.
- WANG, S.; ZHOU, M.; LIU, Z.; LIU, Z.; GU, D.; ZANG, Y.; DONG, D.; GEVAERT, O. & TIAN, J.** *Central Focused Convolutional Neural Networks: Developing a Data-Driven Model for Lung Nodule Segmentation*. Medical Image Analysis, Elsevier, v. 40, p. 172–183, 2017.
- YE, X.; BEDDOE, G. & SLABAUGH, G.** *Automatic Graph Cut Segmentation of Lesions in CT using Mean Shift Superpixels*. Journal of Biomedical Imaging, Hindawi Publishing Corp., v. 2010, p. 19, 2010.
- YE, X.; LIN, X.; DEHMESHKI, J.; SLABAUGH, G. & BEDDOE, G.** *Shape-based Computer-Aided Detection of Lung Nodules in Thoracic CT Images*. IEEE Transactions on Biomedical Engineering, IEEE, v. 56, n. 7, p. 1810–1820, 2009.