

Segmentação de estruturas pélvicas utilizando técnicas de *Deep Learning*

Eddy Cáceres, Graduando¹, Vania Gryzak (Mentora), Doutora², and Mauro Miazaki (Mentor), Doutor²

¹ *Universidad Nacional de San Agustín, Perú, ecacereshu@unsa.edu.pe*

² *Universidade Estadual Centro-Oeste, Brasil, vaniagg2@gmail.com, maurom@unicentro.br*

Resumo– *Um dos problemas estudados na ciência médica é o tratamento de câncer no corpo humano. Os problemas de câncer de próstata afetam uma grande porcentagem da população masculina. Uma das formas de tratamento é a Radioterapia de Intensidade Modulada (IMRT - Intensity-Modulated Radiation Therapy). Uma das fases do planejamento desse tipo de tratamento é a segmentação das estruturas de interesse, como tumores e órgãos nobres e saudáveis. No Hospital Erasto Gaertner, em Curitiba/PR, essa fase é realizada de forma manual, o que limita o número de planejamentos efetuados. Assim, neste trabalho, pretende-se utilizar técnicas de Deep Learning (Aprendizagem Profunda) para automatizar a segmentação de estruturas pélvicas em imagens de tomografia computadorizada.*

Palavras-chave– *Processamento de Imagens, Segmentação, Estruturas Pélvicas, Deep Learning, Redes Neurais Convolucionais*

I. INTRODUÇÃO

O câncer tem sido um tema muito estudado pela sociedade no último século. A letalidade deste problema na saúde demanda que se coloque uma maior importância nos métodos de precaução e tratamentos. Um destes tipos de câncer é o câncer prostático, que afeta a maioria dos homens no mundo. Este tipo de câncer é o mais frequente diagnosticado e ocupa o terceiro lugar entre as causas de mortes nas regiões Centro e Sul da América [1].

Segundo a CTCA [2], uma das técnicas de tratamento de câncer de próstata é a Radioterapia de Intensidade Modulada (IMRT - *Intensity-Modulated Radiation Therapy*), que consiste em altas doses de radiação para destruir as células cancerosas. Nestas circunstâncias, é preciso realizar um planejamento antes da radiação, que envolve reconhecer as partes de aplicação, com a ajuda de imagens médicas, tais como Tomografias Computadorizadas, com as quais se procura determinar as localizações de interesse no paciente. As imagens médicas são um recurso importante para o diagnóstico e tomada de decisões. O radiologista é quem normalmente realiza a tarefa da segmentação de forma manual das regiões de interesse, mas isto pode tomar muito tempo e está exposto a erros humanos. A automatização deste processo reduziria o tempo de planejamento para o tratamento e, além disso, o tempo de horas-homem utilizadas.

Neste trabalho se pretende realizar segmentação das regiões pélvicas de ossos do fêmur, bexiga e reto, devido a que sua identificação são importantes para sua proteção durante a radioterapia. Para resolver os problemas de segmentação de maneira automática nestes últimos anos as técnicas de Inteligência Artificial, especialmente o *Deep Learning* têm melhorado os resultados obtidos anteriormente por outras técnicas e são consideradas no estado da arte de reconhecimento de voz, reconhecimento de imagens, detecção de objeto, entre outros [3]. *Deep Learning* é a parte da Inteligência Artificial que utiliza várias camadas de Redes Neurais para o processo de aprendizagem. As Redes Neurais Convolucionais (CNN - *Computational Neural Networks*) são uma das técnicas de *Deep Learning* [4].

Dos trabalhos correlatos que se fizeram para resolver este problema, Gryczak [5] desenvolveu o algoritmo ABS (algoritmo de busca de pixels de sementes), com o qual procura-se segmentar as mesmas regiões que neste trabalho.

Este trabalho está organizado da seguinte maneira: descrição dos conceitos envolvidos (Seção 2); resultados parciais (Seção 3); e considerações finais (Seção 4).

II. MÉTODOS

A. Redes Neurais Convolucionais

Nos últimos anos têm sido criados diferentes modelos de segmentação utilizando Redes Neurais Convolucionais (CNN - *Computational Neural Networks*) e Redes Convolucionais Completas (FCN - *Fully Convolutional Networks*) [6] para a segmentação em imagens médicas. Ronneberg [7] propõe a U-Net, um modelo de aprendizagem para segmentação de MRI (*Magnetic Resonance Imaging*), foi denominado assim por ter um modelo de Rede Convolucional Completa em formato de “U”. Utiliza técnicas de *data augmentation* (aumento de dados) para evitar *overfitting* e é treinado para segmentar todas as fatias (*slices*) dos volumes. A partir do modelo anterior foram feitos novos modelos como o 3D-Unet [8], e estudos para áreas específicas do corpo humano como o cérebro [9]. No caso de segmentação de áreas pélvicas Zhu [10] realizou uma segmentação de próstata sobre imagens de

ressonância magnética, e conseguiu fazer uma segmentação bem sucedida da próstata. Em Millerati [11] foi implementado a V-Net, similarmente a U-net, utilizando uma Rede Convolutiva Completa, que treina o modelo para realizar a segmentação da próstata, no entanto realiza esta ação utilizando voxels 3D.

Com base na revisão realizada pretende-se utilizar a arquitetura da U-net, mostrada na Fig. 1, devido a simplicidade da arquitetura e rendimento que tem sido demonstrado na sua aplicação, assim como o fato de ter ganhado o desafio de seguimento celular em ISBI 2015[7].

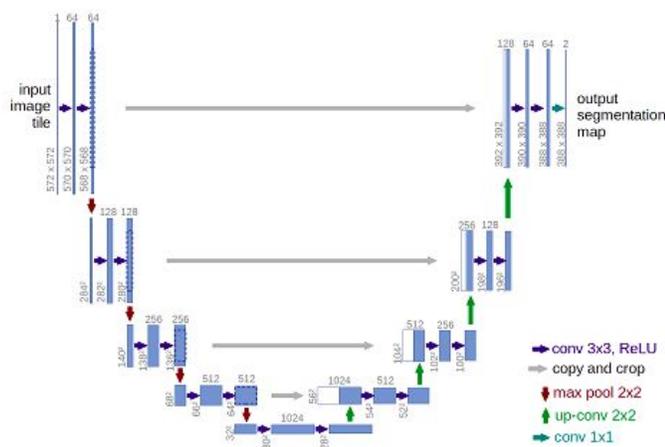


Fig. 1. Arquitetura da U-net. Fonte: [6].

B. Data Augmentation

Data Augmentation (Aumento de Dados) é uma técnica utilizada nos problemas de segmentação e classificação quando não se dispõe de uma quantidade suficiente de dados para realizar treinamento e teste de classificadores [12]. Esta técnica é geralmente utilizada com imagens médicas quando não é possível obter um banco de dados suficientemente grande. Como não há uma grande quantidade de imagens para a realização deste trabalho, foi realizado um aumento de dados utilizando os parâmetros mostrados na Tabela I.

Esta tarefa foi realizada utilizando a função *ImageDataGenerator* implementada em keras [13], utilizando TensorFlow [14] como backend. Keras é uma API de Redes Neurais de alto nível construída para facilitar o trabalho com plataformas como TensorFlow e Theano. TensorFlow e Theano são bibliotecas construídas para cálculos numéricos que têm adaptabilidade sobre arquiteturas paralelas de CPU e GPU.

TABELA I

RESUMO DOS MÉTODOS UTILIZADOS PARA O AUMENTO DE DADOS

Método	Valor
Rotation range ^a	20°
Shift (horizontal e vertical) ^b	5%
Shear (corte) ^c	5%
Zoom ^d	5%
Horizontal Flip ^e	50%
Fill Mode ^f	nearest

^a Graus de rotação, ^b Deslocamento, ^c intensidade de corte, ^d Ampliação/Redução, ^e probabilidade aleatória de reflexo, ^f Maneira de completar os pontos fora dos limites da entrada.

C. Conjunto de Dados

As imagens utilizadas neste trabalho, em formato *dicom*, foram obtidas de exames de tomografia computadorizada (CT) com o tomógrafo da marca GE Medical System, modelo HiSpeed. No total, foram obtidas 9 amostras de pacientes com câncer de próstata. Um dosimetrista do hospital (profissional especialista) realizou o delineamento de todas as imagens, identificando as estruturas pélvicas (Fig. 2).

Cada amostra é composta de várias imagens (secções), as quais seguem a simetria axial inerente à forma da próstata. Para este trabalho, foram selecionadas apenas as secções em que as regiões de interesse apareciam. Assim, foram selecionadas 30 imagens para cada amostra.

Como as imagens tinham tamanhos variados, para este trabalho, essas imagens foram todas ajustadas para ter o tamanho de 512 x 512 pixels. Para isso, as bordas em preto foram apropriadamente aumentadas para as imagens atingirem o tamanho especificado. Um exemplo de imagem (secção) com a borda ajustada pode ser visto na Fig. 3.

A partir do delineamento feito pelo especialista, foram criadas imagens binárias que apresentam de maneira segmentada as regiões de interesse. Esse conjunto de imagens segmentadas, seguindo o delineamento do especialista, é chamado de Padrão Ouro (*Gold Standard*) e será utilizado para treinamento do classificador e para determinar a qualidade da segmentação realizada nos testes. Um exemplo de imagem binária pode ser visualizado na Fig. 4.

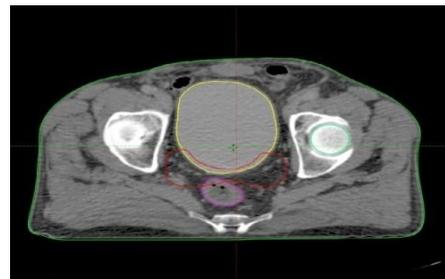


Fig. 2. Delineação manual da imagem de CT.

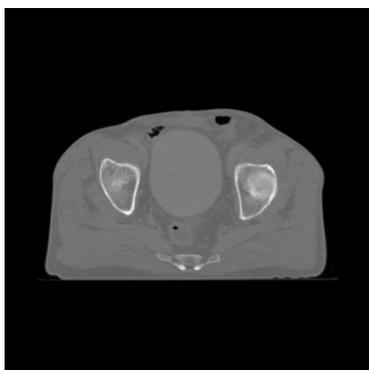


Fig. 3. Imagem original ajustada para o tamanho 512 x 512 pixels.

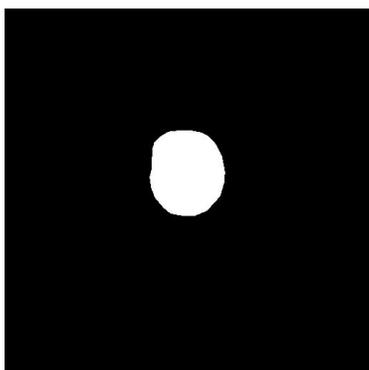


Fig. 4. Imagem binária criada a partir da segmentação manual.

III. RESULTADOS PRELIMINARES

Os primeiros resultados obtidos neste trabalho são os gerados pela aplicação dos métodos de *data augmentation* e a segmentação da bexiga. Alguns exemplos de imagens geradas por *data augmentation* são mostrados na Fig. 5. Na Fig. 6 são mostradas as segmentações correspondentes às imagens da Fig. 5.

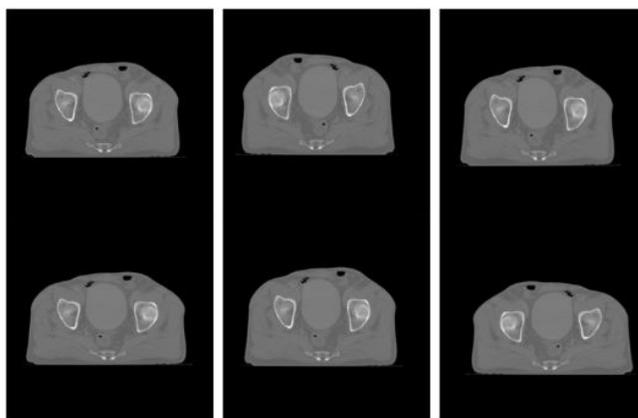


Fig. 5. Resultado da aplicação de métodos de aumento de dados, sobre dados de treinamento. Imagem original (acima esquerda). As demais imagens foram criadas aleatoriamente segundo os métodos mostrados na tabela I, Neste exemplo, foram geradas 5 imagens extras.

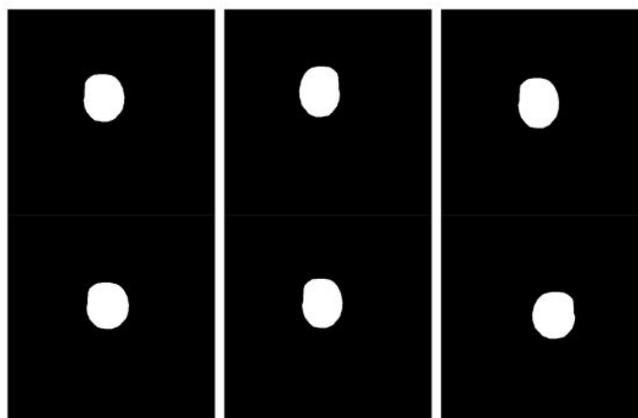


Fig. 6. Segmentações correspondentes às imagens mostradas na Fig. 5.

IV. CONSIDERAÇÕES FINAIS

Neste trabalho em andamento, até o momento, foi realizado o aumento de dados para possibilitar a utilização de *Deep Learning*. O próximo passo será realizar testes com a segmentação apenas da bexiga utilizando U-net. Em seguida, os testes serão ampliados para todas as partes de interesse. Finalmente, como métrica de precisão na segmentação, pretende-se utilizar o Coeficiente de Similaridade de Dice (DSC – *Dice Similarity Coefficient*), pois é o mais frequentemente utilizado em tarefas de segmentação [9,15].

AGRADECIMENTOS

Agradecemos à equipe de física-médica do hospital Erasto Gaertner pelas imagens fornecidas, com projeto aprovado pelo Comitê de Ética do Hospital na Pesquisa nº 2042.

Agradecimentos ao Centro de Alto Rendimento Computacional da Amazonía Peruana del Instituto de Investigaciones de la Amazonía Peruana [16], pois os experimentos computacionais foram desenvolvidos em seu supercomputador.

REFERÊNCIAS

- [1] M. S. Sierra, I. Soerjomataram, and D. Forman. Prostate cancer burden in central and south america. *Cancer Epidemiology*, 44:S131 – S140, 2016. Supplement: Cancer in Central and South America. doi: 10.1016/j.canep.2016.06.010.
- [2] Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. *Nature* 521:436-44, 2015.
- [3] Cancer Treatment Centers of America, IMRT for prostate cancer, 2018. [Online]. Disponível em <https://www.cancercenter.com/prostate-cancer/imrt/>. Acesso em 05 de Março de 2018.
- [4] J. Schmidhuber. Deep Learning in Neural Networks: An Overview. *CoRR*, abs/1404.7828, 2014.
- [5] J. Long and, E. Shelhamer and T. Darrell. Fully Convolutional Networks for Semantic Segmentation. *CoRR*, abs/1411.4038, 2014.
- [6] V. Gryczak. Segmentação automática de estruturas pélvicas de imagens de tomografia computadorizada para planejamento da radioterapia de câncer de próstata. Ph.D. dissertation. Programa de Pós Graduação em Métodos Numéricos. Universidade Federal do Paraná, Curitiba-Pr, 2017.
- [7] O. Ronneberger, P. Fischer, and T. Brox. U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. Vol. 9351, pp 234-241, 2015.
- [8] Ö. Çiçek, A. Abdulkadir, S. S. Lienkamp, T. Brox, and O. Ronneberger. 3d u-net: Learning dense volumetric segmentation from sparse annotation. *CoRR*, abs/1606.06650, 2016.
- [9] H. Dong, G. Yang, F. Liu, Y. Mo, and Y. Guo. Automatic brain tumor detection and segmentation using u-net based fully convolutional networks. *CoRR*, abs/1705.03820, 2017.
- [10] Q. Zhu, B. Du, B. Turkbey, P. L. Choyke, and P. Yan. Deeply-supervised CNN for prostate segmentation. *CoRR*, abs/1703.07523, 2017.
- [11] F. Milletari, N. Navab, and S. Ahmadi. V-net: Fully convolutional neural networks for volumetric medical image segmentation. *CoRR*, abs/1606.04797, 2016.
- [12] A. Halevy, P. Norvig and F. Pereira. The Unreasonable Effectiveness of Data. *IEEE Intelligent Systems* vol. 22, no 2, 2009.
- [13] Chollet, François and others. Keras. 2015. Disponível em: <https://keras.io>. Acesso em 30 Abril 2018.
- [14] M. Abadi et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems. Disponível em <https://www.tensorflow.org/>. Acesso em 30 Abril 2018.
- [15] A. Işın, C. Direkoğlu, M. Şah, Review of MRI-based Brain Tumor Image Segmentation Using Deep Learning Methods, *Procedia Computer Science*, vol. 102, pp 317-324, 2016.
- [16] Centro de alto rendimiento computacional de la amazonía peruana del instituto de investigaciones de la amazonía peruana. <http://iiap.org.pe/web/carcap.aspx>. Acesso em 30 de Abril de 2018.