

AVALIAÇÃO DE TÉCNICAS DE REDES NEURAIS DE APRENDIZADO PROFUNDO PARA SEGMENTAÇÃO DE FERIDAS MALIGNAS CUTÂNEAS EM IMAGENS

Data de submissão: 07/07/2023

Data de aceite: 01/09/2023

Rafael Cardoso Ribeiro da Costa

Universidade Católica de Pernambuco
Recife - Pernambuco
<https://orcid.org/0009-0003-6451-9522>

Rafael Roque de Souza

Universidade Católica de Pernambuco
Recife - Pernambuco
<http://lattes.cnpq.br/1989456891146597>

Robson Cavalcanti Lins

Universidade Católica de Pernambuco
Recife - Pernambuco
<http://lattes.cnpq.br/8623118472645092>

Iago Richard Rodrigues Silva

Universidade Católica de Pernambuco
Recife - Pernambuco
<http://lattes.cnpq.br/8063460813758195>

RESUMO: A segmentação automática das áreas das feridas malignas cutâneas em imagens é uma parte importante do processo de diagnóstico e atendimento, pois é fundamental medir a área da ferida e fornecer dados quantitativos no tratamento. Para este fim, existem vários modelos de redes neurais de aprendizado profundo. No entanto, o problema com muitos desses modelos é que sua arquitetura é pesada

e possui alto custo computacional. Logo, propomos a avaliação inicial de técnicas duas redes neurais de aprendizado profundo. Um dos modelos (U-Net) é comumente utilizado na segmentação de imagens médicas, enquanto o segundo modelo (DeepLabV3) utiliza como base convoluções utilizadas em redes MobileNetV2, que fornece modelos mais compactos. Com esta avaliação dos modelos de segmentação, esperamos obter uma visão inicial dos resultados de acurácia versus eficiência computacional. **PALAVRAS-CHAVE:** aprendizado profundo, segmentação de feridas, visão computacional.

EVALUATION OF DEEP LEARNING NEURAL NETWORK TECHNIQUES FOR SEGMENTATION OF CUTANEOUS MALIGNANT WOUNDS IN IMAGES

ABSTRACT: Automatic segmentation of malignant skin wound areas on images is an important part of the diagnostic and care process, as it is critical to measure the wound area and provide quantitative data in treatment. For this purpose, there are several models of deep learning neural networks. However, the problem with many of these models is that their architecture is

cumbersome and has a high computational cost. Therefore, we propose an initial evaluation of two deep learning neural networks techniques. One of the models (U-Net) is commonly used in medical image segmentation, while the second model (DeepLabV3) uses the basic convolutions used in MobileNetV2 networks, which provide more compact models. With this evaluation of the segmentation models, we hope to obtain an initial view of the results of accuracy versus computational efficiency.

KEYWORDS: deep learning, wound segmentation, computer vision.

1 | INTRODUÇÃO

As feridas malignas cutâneas representam uma problemática para os sistemas de saúde, afetando milhões de pacientes em todo o mundo [1]. Essas feridas crônicas são feridas que não progrediram através de uma sequência de reparo normal, ordenada e oportuna, ou onde o processo de reparo não retornou à integridade anatômica e funcional após três meses. Em 2014, o custo do tratamento de feridas para os beneficiários do Medicare (agência federal dentro do Departamento de Saúde e Serviços Humanos dos Estados Unidos) foi estimado em US \$28 bilhões a US \$96,8 bilhões [1, 2].

Uma avaliação completa do paciente é uma parte importante do processo de tratamento de feridas. Vários fatores locais e gerais podem retardar ou prejudicar a cicatrização de feridas, a inspeção visual da ferida identifica imediatamente atributos muito importantes que orientarão a avaliação e o tratamento posterior. Dessa forma, fornece pistas importantes sobre a etiologia da lesão e sua complexidade. A profundidade, extensão, localização, aparência geral, odor e sinais de exsudato são componentes importantes da avaliação da ferida e precisam ser registrados na linha de base. [2, 3, 4]. Nenhum método de medição da ferida é 100% preciso, mas todos fornecem medições de linha de base para os profissionais consultarem à medida que a ferida progride [4].

Nesse contexto, a segmentação automática das áreas das feridas malignas cutâneas em imagens é uma parte essencial do processo de diagnóstico, uma vez que é fundamental medir a área da ferida e fornecer dados quantitativos no tratamento. A segmentação dessas feridas pode ser alcançada usando os métodos baseados em algoritmos tradicionais e de aprendizado profundo [5].

O aprendizado profundo, um ramo de Aprendizado de Máquina e Inteligência Artificial baseado no conceito de rede neural artificial (do inglês Artificial Neural Network - ANN), é agora considerado uma tecnologia central na Quarta Revolução Industrial. Tornou-se popularizada na computação pela sua capacidade de aprender com dados e extrair características de redes neurais profundas treinadas para processar imagens, permitindo vários modelos de análise de imagem e segmentação semântica [6, 7, 8, 9]. Porém é visado o problema de que os dispositivos são uma tecnologia recorrente, em constante desenvolvimento e aprimoramento no contexto da Indústria 4.0 e aplicações em tempo real, crescendo exponencialmente. No entanto, eles são limitados por recursos como

processador, RAM e armazenamento em disco. Essas limitações tornam-se mais evidentes na execução de serviços e aplicações que exigem mais recursos computacionais, como aprendizado profundo, que são conhecidos por suas demandas computacionalmente pesadas. Assim, existem técnicas e pesquisas de compressão desses modelos [10].

Tendo isto em conta, este trabalho visa apresentar modelos de aprendizagem profunda de avaliação e resultados parciais para a segmentação da ferida cutânea. Inicialmente, pretendemos utilizar dois modelos clássicos para a segmentação da imagem médica, a U-Net, e o DeepLabV3. Posteriormente, em trabalhos futuros, pretendemos aplicar técnicas para compactação de redes neurais profundas, objetivando assim seu uso em dispositivos com limitações de hardware.

2 | REVISÃO DE LITERATURA

2.1 Feridas malignas cutâneas

As feridas malignas são lesões que fazem parte do leque de cânceres e tumores. No caso estudado, quando categorizada cutâneas se dá na infiltração do câncer no epitélio se estendendo pela extensão da pele. Ele inicialmente pode se apresentar como feridas que não cicatrizam, com coloração variada, sangramento, a exsudação intensa e a presença de um odor característico [11].

Tem sido relatado que as feridas malignas ocorrem em 14,5% dos pacientes com câncer avançado. Grande parte das feridas malignas são neoplasias primárias da pele, ou o resultado da disseminação metastática de uma neoplasia remota para o sistema cutâneo [12].

Essas feridas são de grande impacto sobre os pacientes não apenas pela deterioração física que podem causar, mas principalmente pelo estigma que ainda existe sobre o prognóstico do câncer. A avaliação é uma parte importante da identificação das angústias do paciente, isso ajuda a garantir cuidados mais adequados ao paciente [11].

As metástases cutâneas são frequentemente o primeiro sinal de doença metastática extranodal, especialmente em pacientes com melanoma, câncer de mama ou neoplasias malignas da mucosa da região de cabeça e pescoço. As feridas malignas podem ser divididas em nódulos e endurecimento, úlceras fúngicas, malignas e outras. Em casos de câncer avançado, as feridas malignas são geralmente consideradas como feridas “não curáveis”, sendo abordados técnicas de tratamento paliativos das feridas.

Os cuidados paliativos de feridas é focado em monitorar a dor e outros sintomas que ocorrem no caso não curáveis, aliviando e melhorando a qualidade de vida [12]. O cuidado adequado da ferida é facilitado inicialmente por meio da avaliação minuciosa do paciente e da ferida. A inspeção é uma etapa crítica que pode determinar a abordagem de tratamento, profundidade, extensão, localização, aparência geral, odor e notação de exsudatos são

todos componentes essenciais da avaliação da ferida e precisam ser registrados [13].

2.2 Segmentação de imagens médicas

Com a evolução das técnicas de aquisição de imagens médicas, tais como a tomografia computadorizada (CT) e a ressonância magnética (MRI), que fornecem informações mais detalhadas do ponto de vista de resolução e de distinção de tecidos, a capacidade e a fidelidade do diagnóstico por imagens foram ampliadas. O processamento de Imagens e Visão Computacional vêm desenvolvendo técnicas de visualização, processamento e análise destas imagens. Tais técnicas permitem que os médicos visualizem, classifiquem, analisem e manipulem tanto as imagens bidimensionais como as representações tridimensionais dos órgãos em estudo [14].

A segmentação em imagens médicas permite isolar uma região da imagem que possua características comuns, ajudando, assim, a classificar imagens de acordo com as estruturas presentes nas mesmas, tais como órgãos ou estruturas patológicas. O banco de imagens propicia, dessa maneira, uma pesquisa baseada em padrões e estruturas presentes nas imagens [14].

O papel da segmentação é subdividir os objetos em uma imagem. No caso de segmentação de imagens médicas, o objetivo é: (i) estudar estrutura anatômica; (ii) identificar a região de interesse, ou seja, localizar tumor, lesão e outras anormalidades; (iii) medir o volume do tecido para medir o crescimento do tumor (e também diminuir o tamanho do tumor com tratamento); e (iv) ajudar no planejamento do tratamento antes da radioterapia ou no cálculo da dose de radiação.

2.3 Segmentação de feridas cutâneas

É importante dar atenção à problemática da segmentação de feridas em hospitais. Para isso é necessário o processamento dessas imagens sendo em tempo real através de câmeras ou com um banco de dados. Com esses dados é realizada a segmentação dessas imagens com o uso de redes de aprendizado profundo.

O aprendizado profundo tem sido amplamente aplicado para processamento de imagens biomédicas [15, 16, 17]. Também existem diversas pesquisas voltadas para segmentação de imagens com aprendizado profundo [18, 19]. A aplicação de processamento de imagem utilizando redes neurais convolucionais (CNNs, do inglês Convolutional Neural Networks), foi o objetivo de diversas iniciativas para a resolução de problemas com imagens biomédicas [15, 16, 17, 18]. Temos nestas pesquisas, softwares baseados em aprendizado profundo totalmente automatizado, alguns exemplos utilizam CNNs para a tarefa de detectar micro-hemorragias cerebrais em imagens de ressonância magnética e para segmentação e classificação na detecção de danos na cartilagem. Além desses modelos, existem diversas contribuições para a área médica com conceitos de aprendizagem relevantes para análise de imagens médicas [19], pesquisando o uso de redes de aprendizado profundo para

classificação de imagens, detecção de objeto, segmentação, registro e outras tarefas, obviamente mostrando a popularização do tema nos últimos anos. Outros artigos [20, 21] são focados na segmentação e vale ressaltar a utilização comum da U-Net, arquitetura de rede convolucional para segmentação rápida e precisa de imagens.

Essas propostas mostram resultados satisfatórios para o ambiente médico, porém, para muitos o financiamento é onde cria barreiras. Ter o hardware necessário capaz de executar um programa com aprendizado profundo é caro. Grande parte da tensão da computação neural é colocada na GPU, e o poder de processamento é outra grande parte de uma rede neural eficaz. Mais especificamente, maximizar a quantidade de núcleos de CPU executados em paralelo é o que permite que a computação neural complete rapidamente os muitos cálculos complicados necessários para que as redes neurais funcionem de forma eficaz.

Essas propostas mostram resultados satisfatórios para o ambiente médico, porém, para muitos o financiamento é onde cria barreiras. Ter o hardware necessário capaz de executar um programa com aprendizado profundo é caro. Grande parte da tensão da computação neural é colocada na GPU, e o poder de processamento é outra grande parte de uma rede neural eficaz. Mais especificamente, maximizar a quantidade de núcleos de CPU executados em paralelo é o que permite que a computação neural complete rapidamente os muitos cálculos complicados necessários para que as redes neurais funcionem de forma eficaz.

3 | MATERIAIS E MÉTODOS

3.1 Base de dados

O conjunto de dados utilizado nesta pesquisa foi construído pelo laboratório e clínica de colaboração, Advancing the Zenith of Healthcare (AZH) Wound and Vascular Center [22], contendo imagens de feridas malignas cutâneas, mais especificamente de úlceras nos pés, tiradas de 889 pacientes. As imagens brutas foram tiradas por uma câmera digital Canon SX 620 HS e iPad Pro sob condições de iluminação não controladas, com vários fundos.

3.2 Modelos de aprendizagem profunda

Os modelos utilizados para se realizar a segmentação de feridas escolhidos neste trabalho foram U-Net e DeeplabV3, este último com backbone do modelo MobileNetV2.

O modelo U-Net [23] não é um modelo sequencial, tendo informações de saída de cada convolução sendo compartilhadas por cada camada de deconvolução, as quais realizam o aumento da resolução das imagens de saída. A U-Net o ato de expansão da resolução é simétrico à parte contratante (lado esquerdo da arquitetura) e produz uma arquitetura em forma de U (por isso a nomenclatura da rede se segue assim). A rede é

composta apenas por camadas convolucionais, pooling e deconvoluções, não se fazendo o uso de camadas totalmente conectadas, como em autoencoders clássicos.

O modelo DeepLabV3 [24] faz parte de um grupo de modelos desenvolvidos pelo Google Brain com a finalidade de realizar a tarefa de segmentação. Seu diferencial é o uso da operação de atrous spatial pyramid pooling (ASPP) no final do codificador. O ASPP é um módulo de pooling que permite a sondagem da imagem original com vários filtros, capturando objetos e contexto de imagem útil em várias escalas. Em vez de realmente reduzir a dimensionalidade de das imagens pós-convolução, o mapeamento é implementado usando várias camadas convolucionais paralelas com diferentes taxas de amostragem. O backbone utilizado de MobileNetV2 permite uma maior compactação da rede, reduzindo assim a quantidade de parâmetros treináveis.

3.3 Configurações experimentais

Treinamos os modelos de aprendizado profundo propostos na base de dados definida na seção III.A. Para treinamento, consideramos a divisão percentual para validação do modelo. Configuramos 75% do conjunto de dados para treinamento e 25% para validação. Após o processo de treinamento, usamos os modelos para prever no conjunto de testes. O treinamento foi feito em 100 épocas em uma máquina virtual com GPU fornecida gratuitamente pelo Google Colab. Já a métrica Dice Similarity Coeficient (DSC) foi utilizada para avaliação dos modelos.

4 | RESULTADOS PARCIAIS

A Tabela I apresenta os resultados de DSC obtidos para cada um dos modelos.

DSC	Modelo
0.8532	DeepLabV3
0.8820	U-Net

Tabela 1. Resultados de segmentação obtidos pelos modelos em análise.

Os resultados mostram que ambos os modelos foram capazes de aprender a realizar a tarefa de segmentação das feridas, tendo alcançado no mínimo um DSC aproximado de 0.85.

O modelo U-Net alcançou um DSC de 0.8820, o que garantiu o melhor resultado se comparado ao outro modelo analisado. A superioridade do modelo U-Net foi notória, sendo este comprovadamente pelo estado da arte o que geralmente alcança melhores resultados para a tarefa de segmentação de imagens médicas.

A respeito do modelo DeepLabV3, apesar de ter alcançado piores resultados em relação ao modelo U-Net, foi possível reportar resultados competitivos, tendo um DSC de 0.8532. A diferença na taxa de DSC entre estes dois modelos pode ser explicada devido

a característica específica do modelo DeepLabV3 em prover maior compactação de rede neural em comparação com o modelo U-Net, já que este primeiro utiliza-se de convoluções especiais denominadas *depthwise separable convolutions*, as quais garantem operações de convolução mais simplificadas (originárias dos modelos MobileNetV2). A competitividade dos resultados pode ser explicitada através da Fig. 1, a qual demonstra que apesar da diferença quantitativa entre os modelos, os resultados são qualitativamente próximos.

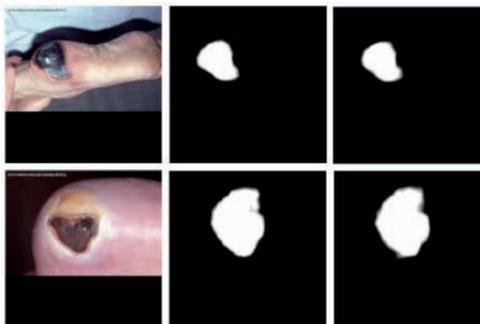


Fig. 1. Análise qualitativa entre os modelos analisados. À esquerda, a imagem de entrada. Ao centro, segmentação gerada pela U-Net. Por fim, À direita, segmentação gerada pela DeepLabV3.

5 | CONCLUSÃO

Este trabalho avaliou dois modelos de aprendizagem profunda (U-Net e DeepLabV3) para segmentação de feridas cutâneas. Através de experimentos realizados, foi possível observar que o modelo U-Net por não ter foco em compressão obteve melhores resultados de segmentação. Enquanto, o modelo DeepLabV3 apresentou resultados competitivos, apesar de ter um foco em compressão de suas camadas convolucionais. Através deste trabalho, foi possível observar que a técnica de compressão de redes convolucionais baseada em *depthwise separable convolutions* fornece resultados de segmentação competitivos e não causam impactos severos na qualidade da segmentação das feridas.

Como trabalho futuro pretende-se a avaliar novas técnicas de compressão de redes, tais como a poda e convoluções *octave*, as quais podem continuar fornecer bons resultados de compressão dos modelos, sem afetar a qualidade da segmentação das feridas. Além disso, outros modelos clássicos de segmentação como SegNet e PSPNet serão avaliados em conjuntos com novas técnicas de compressão de redes neurais.

REFERÊNCIAS

[1] Frykberg, R. G. **Challenges in the treatment of chronic wounds**. *Adv. Wound Care* 4, 560–582 (2015).

[2] Bowers S, Franco E. **Chronic wounds: evaluation and management**. *Am. Fam. Physician*. 2020;101:159–166. - PubMed

- [3] Robert G. Frykberg and Jaminelli Banks. **Advances in Wound Care**. Sep 2015.560-582.
- [4] Karen Ousey. **Importance of holistic wound assessment**. 2012 - IndependentNurse. <https://www.independentnurse.co.uk/>
- [5] Wang, C., Anisuzzaman, D.M., Williamson, V. et al. **Fully automatic wound segmentation with deep convolutional neural networks**. Sci Rep 10, 21897 (2020). <https://doi.org/10.1038/s41598-020-78799-w>
- [6] J. Long, E. Shelhamer, and T. Darrell, “**Fully convolutional networks for semantic segmentation**,” in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR’15), pp. 3431–3440, IEEE, Boston, Mass, USA, June 2015.
- [7] K. Simonyan and A. Zisserman, “**Very deep convolutional networks for large-scale image recognition**” 2014, <https://arxiv.org/abs/1409.1556>.
- [8] C. Wang, X. Yan, X. Smith et al., “**A unified framework for automatic wound segmentation and analysis with deep convolutional neural networks**” in Proceedings of the 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC ’15), pp. 2415–2418, Milan, Italy, August 2015.
- [9] Sarker, I.H. Deep Learning: **A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions**. SN COMPUT. SCI. 2, 420 (2021).
- [10] M. Dantas, I. Rodrigues, A. Filho, G. Barbosa, D. Bezerra, D. Sadok, J. Kelner, M. Marquezzini, R. Silva. **FCN-Pose: A Pruned and Quantized CNN for Robot Pose Estimation for Constrained Devices**.
- [11] Poletti, N. A. A., Caliri, M. H. L., Simão, C. D. S. R., Juliani, K. B., & Tácio, V. E. (2002). **Feridas malignas: uma revisão de literatura**. *Revista Brasileira de Cancerologia*, 48(3), 411-417.
- [12] Vincent Maida, Marguerite Ennis, Craig Kuziemy, Linda Trozzolo, **Symptoms Associated with Malignant Wounds: A Prospective Case Series**, *Journal of Pain and Symptom Management*, Volume 37, Issue 2, 2009, Pages 206-211, ISSN 0885-3924.
- [13] Frykberg RG, Banks J. **Challenges in the Treatment of Chronic Wounds**. *Adv Wound Care (New Rochelle)*. 2015 Sep 1;4(9):560-582. doi: 10.1089/wound.2015.0635. PMID: 26339534; PMCID: PMC4528992.
- [14] Medaglia, D. R., & Manssour, I. H. (2006). **Segmentação de imagens médicas baseada no uso das bibliotecas itk e vtk**. Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens-SIBGRAPI. Manaus.
- [15] Dou Q, Chen H, Yu L, Zhao L, Qin J, Wang D, Mok VC, Shi L, Heng PA. **Automatic detection of cerebral microbleeds from MR images via 3D convolutional neural networks**. *IEEE Trans Med Imaging* 2016;35(5):1182–95.
- [16] Liu F, Zhou Z, Samsonov A, Blankenbaker D, Larison W, Kanarek A, Lian K, Kambhampati S, Kijowski R. **Deep learning approach for evaluating knee MR images: Achieving high diagnostic performance for cartilage lesion detection**. *Radiology* 2018;289(1):160–9.

- [17] Silva, I. R., Silva, G. S., de Souza, R. G., dos Santos, W. P., & Roberta, A. D. A. (2019, July). **Model based on deep feature extraction for diagnosis of Alzheimer's disease**. In 2019 International Joint Conference on Neural Networks (IJCNN) (pp. 1-7). IEEE.
- [18] Rodrigues, I., Santos, G. L., Sadok, D. F., & Endo, P. T. (2021). **Classifying COVID-19 positive X-ray using deep learning models**. IEEE Latin America Transactions, 19(6), 884-892.
- [19] Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, van der Laak JA, van Ginneken B, Sánchez CI. **A survey on deep learning in medical image analysis**. Med Image Anal 2017;42:60–88.
- [20] Ronneberger O, Fischer P, Brox T. **U-net: Convolutional networks for biomedical image segmentation**. In: Lect. notes comput. sci. (Including subser. lect. notes artif. intell. lect. notes bioinformatics), Vol. 9351. Springer Verlag; 2015, p. 234–41.
- [21] Lugagne J-B, Lin H, Dunlop MJ. **DeLTA: Automated cell segmentation, tracking, and lineage reconstruction using deep learning**. PLOS Comput Biol 2020;16(4):e1007673.
- [22] Wang, C., Anisuzzaman, D. M., Williamson, V., Dhar, M. K., Rostami, B., Niezgodá, J., ... & Yu, Z. (2020). **Fully automatic wound segmentation with deep convolutional neural networks**. Scientific reports, 10(1), 1-9.
- [23] Ronneberger, O., Fischer, P., & Brox, T. (2015, October). **U-net: Convolutional networks for biomedical image segmentation**. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.
- [24] Chen, L. C., Papandreou, G., Schroff, F., & Adam, H. (2017). **Rethinking atrous convolution for semantic image segmentation**. arXiv preprint arXiv:1706.05587.