

USO DE U-NETS PARA SEGMENTAÇÃO DE IMAGENS DE RAIO-X ODONTOLÓGICOS

GUILHERME NUNES PEGLOW¹; ANDERSON PRIEBE FERRUGEM¹; MAURÍCIO BRAGA DE PAULA¹

Universidade Federal de Pelotas¹ – {gnpeglow, ferrugem, maubrapa}@inf.ufpel.edu.br,

1. INTRODUÇÃO

Raios-X intraproximal ou *Bitewing* é um tipo de exame de imagem não invasivo, onde feixes de raio-X são disparados através de uma área do corpo, onde parte destes é absorvida e outra parte passa, sendo capturada por um filme ou detector digital (ALVAREZ, 2012). Um exame intraproximal mostra os dentes superiores e inferiores de um paciente em uma única imagem ou filme. Essa técnica auxilia no diagnóstico das doenças mais comuns na odontologia, como cáries, perda óssea dentária e doenças da gengiva. As imagens deste tipo de exame também podem mostrar eventuais problemas com implantes, posicionamento dos dentes e problemas que podem passar despercebidos em um exame de rotina (CASH, 2008).

Uma Rede Neural Artificial (RNA) é um modelo computacional inspirado pelo sistema nervoso, que é capaz de realizar reconhecimento de padrões (Hardik, 2020). As Redes Neurais são um tipo de inteligência artificial, uma área da computação que atualmente atrai muitos acadêmicos da computação e de diversas outras áreas. Com uma crescente quantidade de artigos sendo produzidos nos últimos anos, aumentado de cerca de 50 artigos em 2008 para aproximadamente 250 em 2018 apenas na área de inteligência artificial junto a biomedicina (GUO-GUANG, 2019). Este tópico também é de grande interesse do setor privado, promovendo avanços em automação e criando formas mais eficientes para tratar vários tipos de problemas, sendo aplicada desde carros autônomos, algoritmos de pesquisa, agricultura e saúde (VICTOR, 2021). Na área da saúde, startups de inteligência artificial já dominam o mercado em termos de receita, subindo de 507 milhões de dólares em 2013 para 6,662 bilhões em 2021 (STATISTA, 2018). Ao redor do mundo, essas ferramentas podem auxiliar profissionais da área de várias formas, como por exemplo, agilizando o processamento de dados e ao mesmo tempo diminuindo o erro humano (SOFTERMII, 2019).

Uma CNN (Convolutional Neural Network) é uma classe de RNA, ou perceptron multicamada, baseada em processos biológicos e comumente usada para analisar imagens (VALUEV, 2020). Essa aproximação tem como vantagem a utilização de um pré-processamento mínimo, não necessitando de conhecimentos a priori. Este tipo de rede pode reconhecer padrões com grande variação, como por exemplo, escrita a mão oriunda diretamente dos pixels de uma imagem (LECUN, 2010).

Tendo em vista que técnicas semelhantes à do trabalho apresentado podem ser aplicadas a outros tipos de exames de imagem, como ressonâncias magnéticas e tomografias, o presente trabalho visa segmentar imagens de raio-X odontológicos com o intuito de auxiliar o profissional da área na identificação de certas patologias.

2. METODOLOGIA

Neste trabalho é feito o uso de uma Rede Neural Convolucional chamada U-Net (RONNENBERG, 2015), a fim de realizar a segmentação de imagens de raios-X odontológicos. Esta RNC deve ser capaz de demarcar anomalias no exame com uma máscara, atribuindo aos pixels contidos na região realçada a uma classe um determinado valor numérico. Para que a rede neural obtenha resultados, são passados como entrada para a rede aproximadamente 240 imagens de raio-X interproximal, as quais são as imagens a serem segmentadas. A arquitetura da U-Net possibilita bons resultados mesmo com dados de treinamento mais escassos, pois foi concebida tendo em vista que dados biomédicos deste tipo são de difícil obtenção.

O funcionamento desta arquitetura utiliza como entrada as imagens de raio-X. A entrada então é propagada por todos os caminhos e camadas da rede, apresentando como saída o mapa de segmentação, isto é, regiões coloridas que apresentam determinada classe, tais como: cárie, tratamento de canal, dentre outras. Durante este processo, várias convoluções 3x3 são feitas ao longo da rede. Em seguida uma operação de *MaxPooling* é feita, onde a dimensão da matriz de entrada é reduzida por um determinado fator, como 2 por exemplo, passando adiante o valor máximo de ativação da janela 2x2 selecionada. Assim, essa janela é transformada em 1x1. Desta forma, a cada passo obtemos uma matriz imagem reduzida por um fator de 2. No final desta etapa sabemos “o que” está na imagem, porém, perdemos a informação espacial de onde o objeto encontrado está localizado na matriz original. Usando as conexões chamadas de *skip* (setas na cor cinza na Figura 1) junto da expansão da matriz (up-conv 2x2), de forma análoga aos passos anteriores procuramos nas imagens propagadas, onde o objeto se encontra na matriz com o objetivo de criar o mapa de segmentação (RONNENBERG, 2015).




Figure 1: Arquitetura da U-Net (exemplo para 32x32 pixels na resolução mais baixa). Cada retângulo (caixa) na cor azul corresponde a um mapa de características multicanal. O número de canais é indicado na parte superior do retângulo. A dimensão x-y é indicada na borda inferior esquerda a caixa retangular. As caixas na cor branca representam os mapas de características (bordas) copiadas. As setas indicam as diferentes operações realizadas pela rede.

As imagens que compõem o conjunto de dados que será utilizado nesse trabalho foram

obtidas através de clínicas de radiografia respeitando a anonimidade dos pacientes.

3. RESULTADOS E DISCUSSÃO

O trabalho proposto visa segmentar imagens anotadas através da ferramenta de anotação *LabelMe* (TORRALBA, 2010). A ferramenta auxilia na demarcação dos dentes visíveis no exame de raio-X e outras alterações. A Figura 2 apresenta como o *LabelMe* foi usado para rotular os dentes com um polígono retangular (cor amarela) e outro polígono irregular na cor azul para demarcar cáries.




Figure 2: Exemplo de rotulação do LabelMe e verificação das anotações realizadas em uma imagem de raio-X

As anotações são usadas no processamento da U-Net, de forma análoga ao que é demonstrado nas duas últimas colunas da imagem acima.

4. CONCLUSÕES

O trabalho proposto mostra a crescente utilização da área de Inteligência Artificial no dia a dia dos profissionais de saúde. Desta forma é de suma importância buscar por melhores formas de apresentar dados para que diagnósticos precisos possam ser obtidos o mais rápido possível, uma vez que o diagnóstico precoce pode trazer grandes benefícios ao paciente, facilitando o tratamento e evitando possíveis complicações. A U-Net e, outras formas de aprendizado de máquina já apresentam bons resultados em suas aplicações na área biomédica. Assim, é possível concluir que este tópico de pesquisa é de grande importância tanto para a área da saúde quanto da área de computação.

5. REFERÊNCIAS BIBLIOGRÁFICAS

RONNENBERG, O. U-Net: Convolutional Networks for Biomedical Image Segmentation). Disponível em: Acesso em: 2015- 5-18.

LONG, J. Fully Convolutional Networks for Semantic Segmentation. Disponível em: <<https://doi.org/10.48550/arXiv.1411.4038>>. Acesso em: 2014-11-14

A. Torralba, B. C. Russell and J. Yuen, "LabelMe: Online Image Annotation and Applications," in **Proceedings of the IEEE**, vol. 98, no. 8, pp. 1467-1484, Aug. 2010, doi: 10.1109/JPROC.2010.2050290.

ALVAREZ, Fernando Suarez; Canetti, Marcelo Dominguez; Corrêa Filho, Wilson Braz; Borghi, Danielle. **Protocolos de Avaliação Simplificada de Radiografias: Avaliação Sistemática de Radiografias do Tórax** (Capítulo 114). Secretaria de Saúde e Defesa Civil - Governo do Estado do Rio de Janeiro - 2010. Número: 874 / Publicado em 12/03/2012

CASH, M; PERSCHBACHER, S. Bitewing-xrays, University of Toronto, Faculty of dentistry.
Disponível em: <https://patients.dentistry.utoronto.ca/bitewing-xrays> 2008-06-11

VALUEVA, N.; NAGORNOV, N. Application of the residue number system to reduce hardware costs of the convolutional neural network implementation. [S.l.: s.n.], 2020

Y. LECUN, K. Kavukcuoglu and C. Farabet, "Convolutional networks and applications in vision," **Proceedings of 2010 IEEE International Symposium on Circuits and Systems**, 2010, pp. 253-256, doi: 10.1109/ISCAS.2010.5537907.

Guoguang Rong, Arnaldo Mendez, Elie Bou Assi, Bo Zhao, Mohamad Sawan, Artificial Intelligence in Healthcare: Review and Prediction Case Studies, Engineering, Volume 6, Issue 3, 2020, Pages 291-301, ISSN 2095-8099, <https://doi.org/10.1016/j.eng.2019.08.015>
Disponível em: (<https://www.sciencedirect.com/science/article/pii/S2095809919301535>)

Victor, Allen; 10 Uses of Artificial Intelligence in Day to Day Life, Jul 24, 2021
Disponível em: <https://insights.daffodilsw.com/blog/10-uses-of-artificial-intelligence-in-day-to-day-life>

(Statista,2018)Revenue from artificial intelligence systems in healthcare worldwide from 2013 to 2021.

Disponível em:<https://www.statista.com/statistics/938775/global-healthcare-artificial-intelligence-market-revenue/>

(SOFTERMII, 2019) How AI in healthcare is changing the industry, 09-12-2019.
Disponível em :<https://www.softermii.com/blog/how-ai-in-healthcare-is-changing-the-industry>