

DEEPRAD: AUXÍLIO EM DIAGNÓSTICO ODONTOLÓGICO POR APRENDIZADO DE MÁQUINA

WILIANS DONIZETE DA SILVA JUNIOR¹; AMANDA JHENNIFER MARQUES VIEIRA¹; GABRIEL LEITE BESSA¹; LUCIANO LUDWIG HELING¹; PEDRO HENRIQUE LIMA DE MESQUITA¹; ANDERSON PRIEBEN FERRUGEM¹

¹UFPel – {wddsjunior, ajmvieira, gabriel.lb, llheling, phlmesquita, ferrugem}@inf.ufpel.edu.br

1. INTRODUÇÃO

O uso da inteligência artificial na área da saúde, mais especificamente na área de odontologia, vem crescendo fortemente nos últimos anos, impulsionada por novas tecnologias sendo desenvolvidas no campo do aprendizado profundo e redes neurais artificiais cada vez mais potentes e com melhores resultados. Tendo já sido mostrado excelentes resultados em outras áreas da saúde quanto ao seu uso para a identificação, localização, detecção ou segmentação de imagens médicas dos mais diversos tipos de exames, já que de acordo com Siu, Cooke e Broekhoven (1991), erros na análise de radiografias podem ocorrer devido a falhas na condução do exame.

Neste contexto, foi proposto o projeto DeepRAD que é um projeto em parceria com a Faculdade de Odontologia da Universidade Federal do Rio Grande do Sul (UFRGS) no qual busca-se desenvolver *datasets* odontológicos e validar seu uso por meio de técnicas de inteligência artificial, principalmente com redes neurais artificiais. Esses *datasets* desenvolvidos são de grande importância para a comunidade acadêmica, uma vez que eles estarão disponíveis publicamente para que mais pessoas possam treinar seus modelos e aplicá-los para problemas específicos, além dos tratados pelo projeto inicial.

O dataset que está sendo utilizado até o momento foi disponibilizado pela equipe de Odontologia da UFRGS, sendo este composto de 271 imagens de raio-X interproximal anotado em 5 classes: dente, restauração, tratamento de canal, implante dentário e coroa dentária. Uma distribuição dessas classes é apresentada na tabela 1. A diversidade dessas classes permite uma análise abrangente das características das imagens de raio-X odontológicas, tornando possível a identificação e previsão precisa de diferentes condições. Essa riqueza de dados é fundamental para o sucesso de nosso projeto e reflete a colaboração valiosa entre a equipe de Odontologia e a comunidade acadêmica da Universidade Federal de Pelotas (UFPel).

Classe	Instâncias
Dente	3587
Restauração	2432
Tratamento de Canal	986
Implante	10
Coroa	31

Tabela 1 - Distribuição das Classes do Dataset. Fonte: Os Autores.

2. METODOLOGIA

A metodologia utilizada no projeto para a construção do *dataset* foi feita através da escolha de características que eram desejáveis pela equipe de Odontologia do projeto, que se resumiu às 5 classes tratadas acima. Em seguida, foi implementada uma infraestrutura na AWS utilizando o *software* de anotação de imagens LabelMe para a segmentação dos objetos, que foi realizada por 2 professores de odontologia, sendo um da UFPel e outro da UFRGS, 1 cirurgião-dentista e 2 mestrandos em odontologia pela UFRGS.

Em paralelo com a produção dos dados, foi realizada uma pesquisa bibliográfica sobre as redes neurais mais utilizadas para a tarefa de segmentação. Após a análise, foi escolhido, em um primeiro momento, dois modelos para se realizar experimentos sobre os dados: a rede neural U-Net (RONNEBERGER et al, 2015) e a rede Mask R-CNN (HE et al, 2018). Para a utilização das duas foi feita a implementação da rede U-Net utilizando-se a biblioteca Tensorflow e Keras. Já para a rede Mask R-CNN foi utilizada a plataforma Detectron2, que já possui implementada esta rede e possibilita facilidades para o treinamento, validação e teste dos modelos.

A escolha da arquitetura YOLO versão 8 (YOLOv8) foi feita devido à ampla quantidade de trabalhos na literatura que a utilizam. Com o lançamento do YOLOv8 em 2015, buscamos realizar treinamentos utilizando essa arquitetura, pois essa versão foi a primeira da família YOLO a permitir a segmentação de objetos, além da detecção que as versões anteriores suportam. (BADER ALDUGHAYFIQ et al, 2023) e (RAMACHANDRAN et al, 2018).

3. RESULTADOS E DISCUSSÃO

Com relação aos resultados obtidos, foi realizada a execução do dataset em 3 arquiteturas diferentes com objetivo de segmentar as classes propostas.

A implementação da U-Net no qual foi treinado com o *dataset* do projeto foi desenvolvida por (PEGLOW et al, 2022). Foi aplicado normalização e redimensionamento da imagem para 256 x 256 pixels, assim como um aumento no conjunto de dados utilizando rotações, inversões, ajustes de brilho e de contraste. Sendo os resultados mostrados na figura 1.

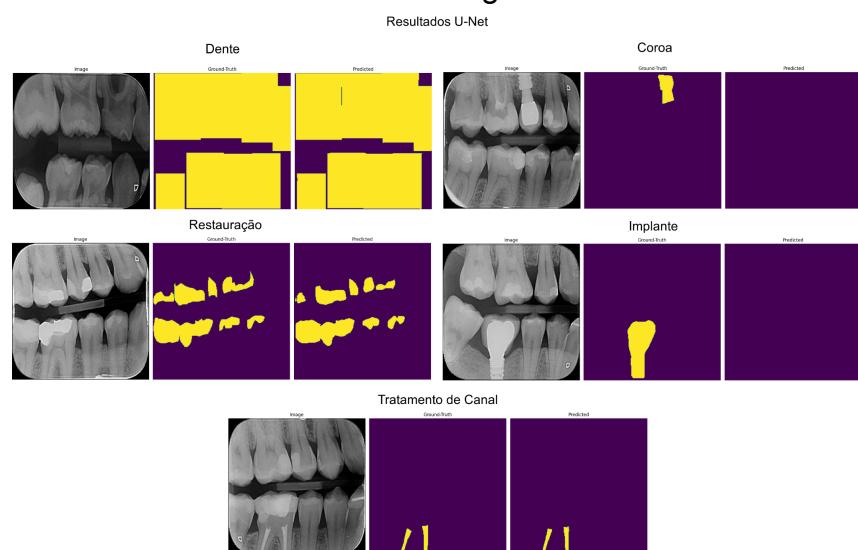


Figura 1 - Resultados obtidos com a arquitetura U-Net. Imagem original, máscara e predição de cada classe respectivamente. Fonte: Os Autores

A arquitetura YOLOv8 utilizada foi a menor disponibilizada pela Ultralytics, a YOLOv8 N. Sendo que nos dados também foi aplicado aumento no *dataset* por meio de inversões e rotações. A figura 2 apresenta a segmentação realizada.

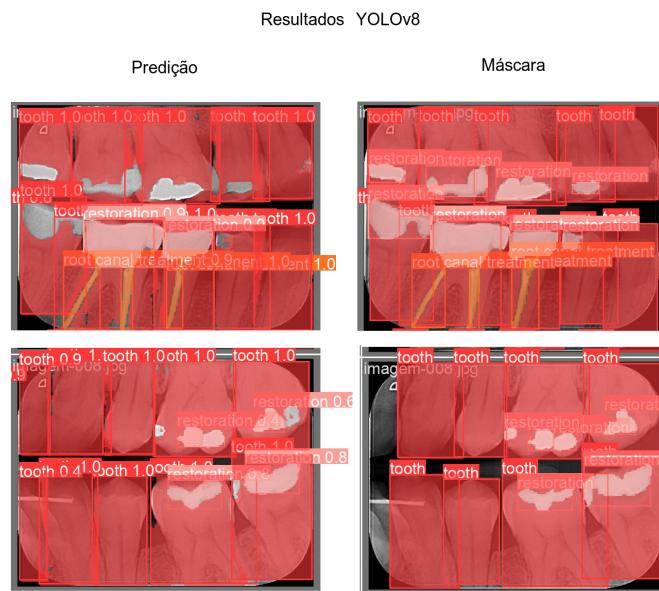


Figura 2 - Resultados com a YOLO versão 8 para as classes restauração, dente e tratamento de canal. Fonte: Os Autores.

A arquitetura Mask R-CNN utilizada foi implementada por meio do Detectron2 (WU et al, 2019) com menor modelo disponibilizado, o R 50 FPN 3x. Foi feito também um aumento no conjunto de dados utilizando inversões e rotações. Os resultados são demonstrados na figura 3.

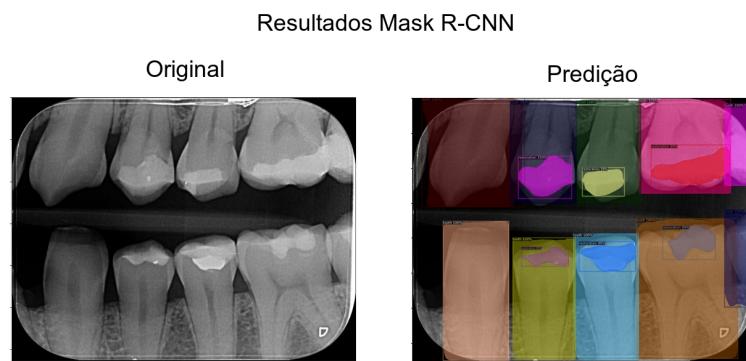


Figura 3 - Resultados com a Mask R-CNN usando o Detectron2. Fonte: Os Autores

4. CONCLUSÕES

Podemos concluir assim que os resultados obtidos com este primeiro *dataset* foram satisfatórios para as classes mais representativas. Já para as classes menos representativas como implante e coroa os modelos não conseguiram prever com exatidão.

Para trabalhos futuros será feito o treinamento com o *dataset* de outras arquiteturas como UneTr (HATAMIZADEH et al, 2021), SegFormer (XIE, 2021), Swin-Unet (CAO et al, 2021) que são utilizadas para se realizar a tarefa de

segmentação de imagens e são citadas por (LI et al, 2023) e (YANG et al, 2022). Será realizada também a utilização de redes neurais adversárias generativas para o aumento do dataset como revisado por (CHLAP et al, 2021) e verificar o comportamento dos modelos e suas métricas.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- BADER ALDUGHAYFIQ et al. YOLO-Based Deep Learning Model for Pressure Ulcer Detection and Classification. v. 11, n. 9, p. 1222–1222, 2023.
- CAO, H. et al. Swin-Unet: Unet-like Pure Transformer for Medical Image Segmentation. arXiv:2105.05537 [cs, eess], 2021.
- CHLAP, P.; MIN, H.; VANDENBERG, N.; DOWLING, J.; HOLLOWAY, L.; HAWORTH, A. A review of medical image data augmentation techniques for deep learning applications. J Med Imaging Radiat Oncol, 2021.
- HATAMIZADEH, A. et al. UNETR: Transformers for 3D Medical Image Segmentation. arXiv:2103.10504 [cs, eess], 2021.
- HE, K.; GKIOXARI, G.; DOLLÁR, P.; GIRSHICK, R. Mask R-CNN. arXiv:1703.06870v3 [cs], 24 de janeiro de 2018.
- LI, X. et al. Transformer-Based Visual Segmentation: A Survey. arXiv:2304.09854v2, 2023.
- PANETTA, K.; RAJENDRAN, R.; RAMESH, A; RAO, S.; AGAIAN, S. Tufts Dental Database: A Multimodal Panoramic X-Ray Dataset for Benchmarking Diagnostic Systems, in IEEE Journal of Biomedical and Health Informatics, vol. 26, no. 4, pp. 1650-1659, 2022.
- PEGLOW, G.; FERRUGEM, A.; PAULA, M. Uso de U-Nets para a Segmentação de Imagens de Raio-X Odontológicos. SIIEPE, Pelotas. 1-4, 2022.
- RAMACHANDRAN, S. et al. Using YOLO based deep learning network for real time detection and localization of lung nodules from low dose CT scans. Medical Imaging, 2018.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. arXiv:1505.04597 [cs], 2015.
- XIE, E. et al. SegFormer: Simple and Efficient Design for Semantic Segmentation with Transformers. arXiv:2105.15203 [cs], 2021.
- YANG, Y. et al. Transformers Meet Visual Learning Understanding: A Comprehensive Review. arXiv:2203.12944, 2022.
- YANG, R.; YU, Y. Artificial Convolutional Neural Network in Object Detection and Semantic Segmentation for Medical Imaging Analysis. Frontiers in Oncology, v. 11, 2021.