

USO DE REDES NEURAIS PARA NUMERAÇÃO EM DENTES DECÍDUOS E PERMANENTES EM RADIOGRAFIAS PANORÂMICAS

SAMUEL STARKE¹; GABRIEL L. BESSA¹; ANDERSON PRIEBE FERRUGEM¹

¹UFPEL - *{sstarke, gabriel.lb, ferrugem}@inf.ufpel.edu.br*

1. INTRODUÇÃO

O presente texto apresenta dados parciais do projeto de pesquisa intitulado “DeepRAD - Auxílio ao Diagnóstico Odontológico em Radiômica através de Aprendizado de Máquina”, financiado pela FAPERGS no âmbito do Centro de Desenvolvimento Tecnológico (CDTec). Este projeto é uma parceria entre a Universidade Federal de Pelotas (UFPel), Universidade Federal do Pampa (Unipampa) e Universidade Federal do Rio Grande do Sul (UFRGS). O objetivo do projeto DeepRAD é desenvolver sistemas baseados em Inteligência Artificial (IA) que possam auxiliar profissionais da odontologia no diagnóstico de doenças bucais e na identificação de dentes decíduos e permanentes.

Técnicas de aprendizado de máquina e aprendizado profundo, como as Redes Neurais Convolucionais (CNNs), têm mostrado grande potencial na análise de imagens radiográficas odontológicas. Essas tecnologias permitem a automação e aprimoramento da interpretação de exames, oferecendo suporte valioso na definição de diagnósticos clínicos. O uso da IA pode, portanto, contribuir significativamente para a tomada de decisões clínicas, auxiliando o cirurgião-dentista no diagnóstico mais rápido e preciso. Essa abordagem pode reduzir o tempo de avaliação e aumentar a precisão das detecções, beneficiando tanto profissionais quanto pacientes (SPEZZIA, 2022).

Para o desenvolvimento deste estudo, foi utilizado um dataset criado por especialistas da UFRGS, composto por 410 radiografias panorâmicas. As imagens foram anotadas com diferentes classes de interesse clínico, que incluem a identificação de dentes decíduos e permanentes em pacientes nas fases de dentição decídua, mista e permanente. As radiografias foram padronizadas em termos de tamanho e qualidade para garantir a consistência e precisão das anotações. Esse processo de padronização é essencial para o sucesso das técnicas de aprendizado profundo e o treinamento das redes neurais, garantindo que os dados utilizados sejam adequados e confiáveis para a modelagem preditiva.

2. METODOLOGIA

Na metodologia para o desenvolvimento deste trabalho, as radiografias do dataset foram pré-processadas para garantir qualidade nas anotações e uniformidade no treinamento do modelo. O dataset foi dividido em 70% para treinamento e 30% para validação, buscando um equilíbrio entre aprendizado e avaliação da generalização do modelo. Para compensar o tamanho limitado do dataset e melhorar a generalização, aplicamos técnicas de aumento de dados (data augmentation), focando em ajustes de contraste e brilho. Essas modificações, controladas para simular diferentes condições de iluminação, ampliaram a diversidade visual do dataset, preservando a estrutura anatômica dos dentes e a integridade das anotações originais.

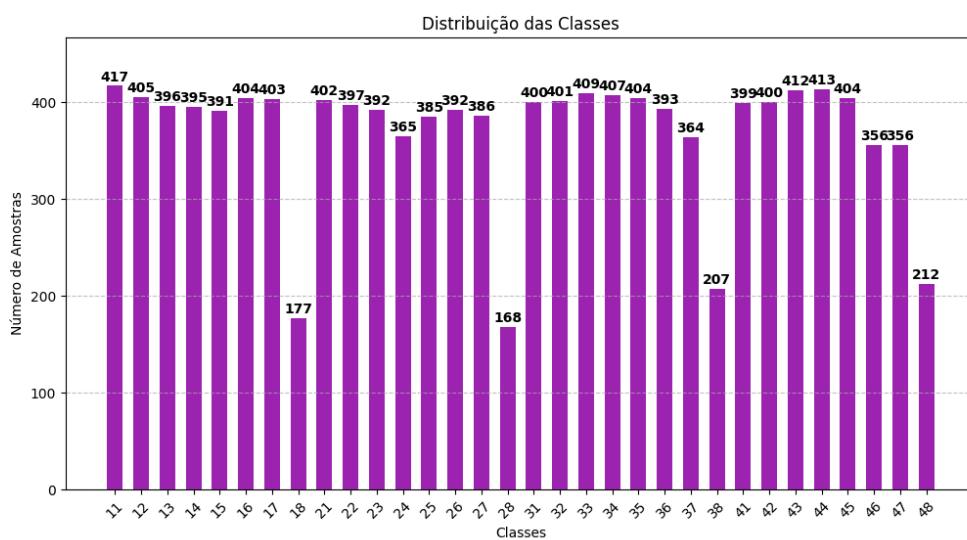


Figura 1: Distribuição do dataset de dentes permanentes. Fonte: Os autores.

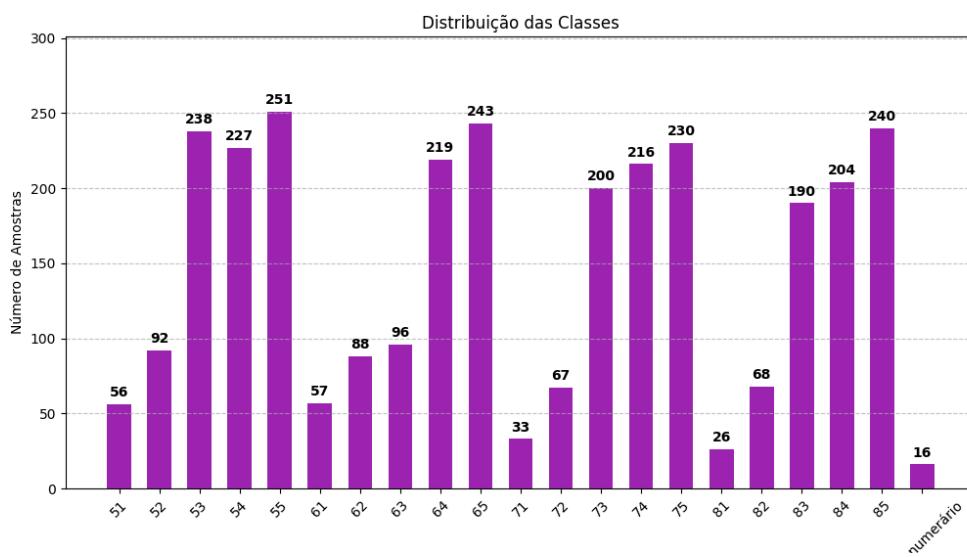


Figura 2: Distribuição do dataset de dentes decíduos e supranumerários. Fonte: Os autores.

Optamos por utilizar o algoritmo YOLOv8 (You Only Look Once, versão 8) devido às suas vantagens em tarefas de detecção e segmentação de objetos em tempo real. A YOLOv8 é conhecida por sua capacidade de realizar inferências rápidas com alta precisão, mesmo em cenários com objetos pequenos ou sobrepostos, como é o caso de dentes decíduos e permanentes em radiografias panorâmicas. Além disso, sua arquitetura balanceada entre velocidade e precisão a torna ideal para aplicações em saúde, onde a rapidez de processamento e a precisão dos diagnósticos são essenciais. O framework YOLOv8 também pode ser utilizado em diversas outras tarefas de visão computacional, como detecção, segmentação, classificação e estimativa de pose, oferecendo modelos pré-treinados para cada uma dessas tarefas (SOHAN, M.; SAI RAM, T.; RAMI REDDY, C.V, 2024)

O modelo YOLOv8 foi treinado utilizando o otimizador Adam, com uma taxa de aprendizado inicial de 0,0001, por um total de 50 épocas. Foi implementada uma técnica de *early stopping* para interromper o treinamento caso o desempenho da rede não apresentasse melhorias após 3 épocas consecutivas, evitando o *overfitting*. Durante o treinamento, foram aplicadas técnicas de aumento de dados (*data augmentation*), incluindo ajustes de brilho e contraste, rotações e espelhamentos, com o objetivo de aumentar a variabilidade das imagens de entrada e melhorar a robustez do modelo frente a diferentes condições de radiografia. As métricas de desempenho utilizadas incluíram a precisão média (mAP) e o tempo de inferência por imagem.

A escolha da YOLOv8 foi justificada pela sua eficiência em tarefas de detecção de objetos com alta resolução espacial e pela sua capacidade de generalizar bem em conjuntos de dados relativamente pequenos, como o utilizado neste trabalho. Essa abordagem permitiu prever de maneira confiável a presença e posição dos dentes, demonstrando o potencial do modelo em auxiliar diagnósticos odontológicos baseados em imagens radiográficas.

3. RESULTADOS E DISCUSSÃO

Nesta seção, apresentamos os resultados obtidos durante a avaliação do modelo YOLOv8 no conjunto de validação. Inicialmente, analisamos o desempenho do modelo em termos de precisão na detecção de dentes decíduos e permanentes, utilizando a métrica de precisão média (mAP). Também avaliamos a eficiência do modelo, considerando o tempo de inferência por imagem, uma vez que a rapidez de processamento é crucial para aplicações clínicas. Além disso, comparamos o desempenho do modelo antes e após a aplicação das técnicas de aumento artificial de dados, a fim de verificar o impacto dessas estratégias na capacidade de generalização do modelo. Os resultados obtidos são detalhados a seguir, com uma discussão sobre os principais pontos fortes e limitações observados no experimento.

Classe	Precisão (%)	Recall (%)	F1-Score (%)	AP médio (%)
Decíduos e permanentes	71,10	79,12	74,64	74,74
Permanentes	74,93	82,24	78,33	79,93
Decíduos	64,97	74,12	68,74	66,43

Tabela 1: Desempenho da YOLOv8 na numeração de dentes decíduos e permanentes. Fonte: Os autores.

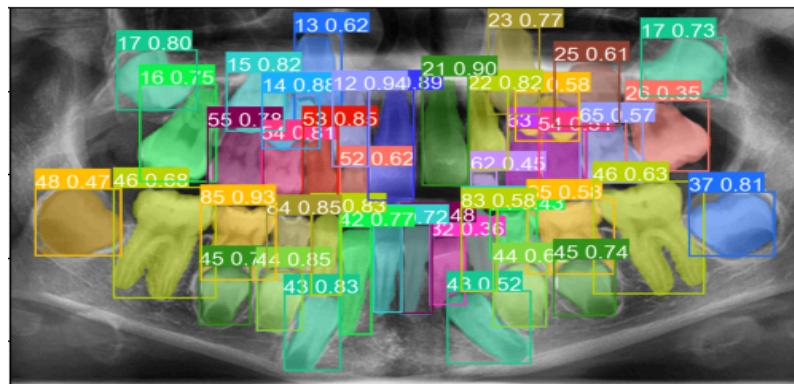


Figura 3: Demonstração da predição da rede com uma radiografia de dentição mista. Fonte: Os autores.

4. CONCLUSÕES

O uso de redes neurais convolucionais mostrou ser uma abordagem eficaz para a detecção e segmentação de dentes decíduos e permanentes em radiografias panorâmicas. O modelo apresentou resultados satisfatórios na numeração de dentes permanentes e mistos, com altas taxas de precisão e recall, comprovando sua eficiência na identificação das diferentes classes dentárias. Nos dentes decíduos, as taxas de precisão e recall foram menores devido à limitação de exemplares no dataset.

Para superar essa restrição, os trabalhos futuros do projeto DeepRAD podem explorar técnicas avançadas de geração de dados sintéticos, como redes adversariais generativas (GANs) e Redes de Difusão. As GANs podem criar imagens artificiais realistas de radiografias dentárias, ampliando o dataset original sem necessidade de novas coletas. As Redes de Difusão, uma técnica emergente na geração de imagens, podem contribuir para a produção de dados sintéticos de alta qualidade, melhorando a variabilidade dos dados e a capacidade de generalização dos modelos, resultando em soluções de IA mais robustas para contextos clínicos.

5. REFERÊNCIAS BIBLIOGRÁFICAS

SPEZZIA, S. Aplicabilidade da inteligência artificial em odontologia. International Journal of Science Dentistry, Niteroi, v.1, n.60, p23-29, 2023.

SOHAN, M.; RAM, T.; CH, V. A Review on YOLOv8 and Its Advancements. Em: [s.l.: s.n.], Singapore, p. 529–545, 2024.