

Redes pré-treinadas na Odontologia: Classificação de imagens de radiografias panorâmicas dentárias fora do domínio

Nator junior Carvalho da Costa
Escola de Saúde pública do Ceará
Universidade Estadual do Ceará
Fortaleza, Ceará, Brasil
natorjuniorcc@gmail.com
nator.costa@esp.ce.gov.br

Marcos José Nunes de Oliveira
Escola de Saúde pública do Ceará
Fortaleza, Ceará, Brasil
marcos.oliveira@esp.ce.gov.br

Igor Dayan Barbosa Lucas
Escola de Saúde pública do Ceará
Fortaleza, Ceará, Brasil
igor.dayan@outlook.com

ABSTRACT

Este trabalho explora uma metodologia para a classificação de imagens radiográficas panorâmicas em odontologia, aplicando técnicas de transferência de aprendizado. Incorpora-se a expertise de um especialista na classificação das imagens, especificamente para procedimentos endodônticos, ampliando assim o escopo e a relevância das bases de dados utilizada. Para a tarefa de classificação, foram empregadas duas redes neurais convolucionais pré-treinadas: VGG19 e EfficientNetB0. A análise de desempenho dessas redes revelou uma pontuação F1 de 65,00% para VGG19 e 96,24% para EfficientNetB0, indicando uma eficácia significativa na segunda arquitetura que consegue convergir e fazer classificação precisa das imagens radiográficas odontológicas com foco em endodontia.

KEYWORDS

Redes pré-treinadas; Endodontia; Classificação de imagens;

1 INTRODUÇÃO

As redes neurais pré-treinadas emergiram como uma metodologia eficaz para otimizar o processo de treinamento, especialmente útil quando se lida com conjuntos de dados menores. Esta técnica foi formalizada em 2017 através do estudo de [1], que definiu conceitos de transferência de aprendizado e ajuste fino, porém trabalhos anteriores já descreviam a transferência de aprendizado [2, 3].

Aplicações fora do domínio original enfrentam desafios devido à discrepância entre as características dos dados do conjunto original e do novo domínio [3]. A capacidade de generalização dessas redes, portanto, torna-se um fator crítico. Muitas vezes, ajustes finos e técnicas de transferência de aprendizado são necessários para melhorar a eficácia nessas novas aplicações, equilibrando a retenção do conhecimento aprendido com a necessidade de adaptar-se a novas características de dados.

O uso de técnicas de Inteligência Artificial (IA) tem demonstrado grande potencial para profissionais da odontologia, especialmente na análise de exames radiográficos panorâmicos. Por meio de algoritmos avançados de processamento de imagem e aprendizado de máquina, os sistemas de IA são capazes de identificar padrões, detectar anormalidades e reconhecer características clínicas relevantes com elevada precisão. Essas capacidades não apenas aumentam a eficiência dos diagnósticos, mas também proporcionam suporte para interpretações mais consistentes e confiáveis, auxiliando os profissionais na tomada de decisões clínicas. Além disso, a IA pode ser integrada ao fluxo de trabalho odontológico para otimizar o

tempo e reduzir a possibilidade de erros humanos, promovendo um atendimento mais ágil e assertivo.

Neste estudo, propomos a inclusão de uma nova categoria, a de endodontia, em dois conjuntos de dados já existentes na literatura, os quais foram aprimorados por um especialista na área. O primeiro conjunto de dados foi disponibilizado por [4], composto por radiografias dentárias panorâmicas anonimizadas e desidentificadas de 116 pacientes, originários do Irã. Este conjunto é originalmente destinado a atividades de segmentação da mandíbula. O segundo conjunto de dados é o DENTEX, apresentado no trabalho de [5, 6], utilizado primariamente para tarefas de classificação e segmentação multi-rótulo, contendo um total de 1571 imagens.

A fim de orientar-nos de maneira mais eficaz em relação às questões em aberto e às propostas de solução neste trabalho, é destacado a seguir uma pergunta de pesquisa: **RQ1:** Como é a eficácia, medida pelo F1 score, de redes neurais pré-treinadas em conjuntos de dados como ImageNet quando aplicadas a classificações fora do domínio original?

Diversos estudos são pertinentes para embasar esta pesquisa, destacando-se o trabalho de [7] no qual foi realizada uma avaliação do emprego de redes neurais convolucionais na classificação de cáries dentárias. O autor justifica que o uso pode potencializar a expansão da tele-odontologia. No estudo, foram empregadas as arquiteturas Vgg16, Vgg19, Inception-V3 e Resnet50, sendo as classes definidas como com cárie e sem cárie. Destaca-se que a InceptionV3 obteve a melhor performance, alcançando uma precisão de 98% e uma taxa de acurácia de 99%.

Em [8] também propõem o uso de redes neurais convolucionais e transferência de aprendizado para uma classificação de imagens, porém através de raio-x panorâmico, para identificação de imagens com caries e sem cáries. O autor se utiliza de uma arquitetura inceptionV3 e separa a performance da classificação em pre-molar, molar e pre-molar-e-molar.

Em [9] é discutido a utilização de redes neurais convolucionais profundas (CNNs) para analisar radiografias panorâmicas dentárias (DPRs) e detectar sinais de osteoporose. O estudo utilizou 680 imagens de pacientes para treinar os modelos de CNN. Quatro diferentes modelos foram testados: um modelo CNN básico com três camadas, o modelo VGG-16, uma versão de aprendizagem por transferência do VGG-16 (VGG-16_TF), e um modelo VGG-16_TF com ajuste fino. O objetivo era avaliar a eficácia de várias estratégias de aprendizado por transferência. O modelo mais eficaz alcançou uma precisão significativa, indicada por uma área sob a curva de característica operacional do receptor de 0,858. O estudo também descobriu que a aprendizagem por transferência e o ajuste fino

aprimoraram o desempenho da CNN na detecção de osteoporose em DPRs.

O documento está dividido em 4 seções. A metodologia aplicada, a descrição da base de dados e as métricas de validação estão na seção 2. Os resultados após aplicação da proposta são apresentados na seção 3, a seção 4 consiste na conclusão.

2 METODOLOGIA

Neste trabalho, adotaremos a seguinte sequência de ações: iniciaremos com a classificação das imagens de raio-x panorâmico em duas categorias - aqueles que possuem **tratamento endodôntico** e aqueles que não possuem. Em seguida, faremos uma comparação de dois modelos de classificação de imagens para a identificação dos elementos dentais que possuem este procedimento clínico nas imagens.

O conjunto de dados utilizado nesta pesquisa foi derivado dos estudos conduzidos por [4] e [5, 6]. Esses trabalhos anteriores forneceram imagens para segmentação de mandíbulas ([4]) e para classificação [5, 6] multi-rotulo. No presente estudo, foi explorada a acessibilidade desses dados e adicionada uma nova categoria classificatória: a diferenciação de imagens contendo procedimentos endodônticos. A classificação foi executada por um especialista, que categorizou as imagens em dois grupos distintos: aqueles que apresentavam procedimentos endodônticos e os que não. Este processo de classificação baseou-se na análise do especialista, permitindo a identificação do procedimento endodôntico.

A Figura 1 exibe radiografias panorâmicas dentárias, instrumentos para a avaliação odontológica da saúde dentária e estrutural da mandíbula. Na radiografia superior, um círculo vermelho indica uma área que sugere a intervenção de tratamento endodôntico, enquanto a radiografia inferior demonstra ausência de tal procedimento.

A avaliação preliminar do modelo é realizada utilizando métricas padronizadas, que incluem a *accuracy*, demonstrando a performance geral do modelo [10], conforme descrito na Equação 1:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

O *recall* indica a proporção de verdadeiros positivos corretamente identificados pelo modelo em relação ao total de casos positivos reais [11], como definido na Equação 2:

$$recall = \frac{TP}{TP + FN} \quad (2)$$

A *precision* mede a proporção de verdadeiros negativos corretamente identificados em relação ao total de casos negativos reais [12]. Essa métrica está descrita na Equação 3:

$$precision = \frac{TN}{TN + FP} \quad (3)$$

Por fim, a métrica F1-score fornece uma medida harmônica entre a precisão e o *recall*, sendo especialmente útil em cenários de desequilíbrio de classes. O F1-score é definido pela Equação 4:

$$F1 - score = 2 \cdot \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$




Figure 1: Demonstração de imagens com endodontia e sem o procedimento.

3 RESULTADOS E DISCUSSÃO

Neste estudo, é realizada uma avaliação da eficiência de redes neurais pré-treinadas em tarefas de classificação. É incluída também a classificação de um especialista, que categoriza as imagens em duas classes distintas: imagens que apresentam procedimentos de endodontia e aquelas que não os apresentam. Esta avaliação é conduzida exclusivamente por meio de radiografias panorâmicas.

O foco central deste estudo é investigar a eficácia das arquiteturas de redes neurais pré-treinadas na incorporação de novas classes. Isso surge do fato que as redes são ajustadas utilizando o conjunto de dados com classes diversas como o ImageNet, que abrange milhares de categorias genéricas, incluindo objetos como cadeiras, carros, motos e pessoas. Entretanto, estas categorias não incluem imagens de raio-X ou contextos específicos da área da saúde. Apesar disso, considerando a habilidade das redes convolucionais em extrair características relevantes de imagens para a classificação, surge a hipótese de que estas redes possam ser eficientemente adaptadas para analisar imagens fora de seu contexto original, focando especificamente na extração de características.

Com base nesses conhecimentos, formulamos a seguinte questão de pesquisa, destacada para ênfase: **RQ1:** Qual é a eficácia, avaliada pelo F1 score, de redes neurais pré-treinadas em conjuntos de dados como o ImageNet, quando aplicadas a classificações em domínios distintos do original? Para responder a essa questão, implementamos e avaliaremos duas arquiteturas de redes neurais convolucionais pré-treinadas: a EfficientNetB0 [13] e a VGG19 [14]. Além disso, dispomos os resultados obtidos com base em métricas padrão como precisão, sensibilidade, especificidade e F1 score.

A rede VGG19 aplicada ao conjunto de dados de raio-x panorâmico, teve uma F1-score de 62,45 % e a EfficientNetB0 obteve 96,24 %,

Métrica	EfficientNetB0	VGG19
Precisão	96.36 %	65.94 %
Acurácia	96.25 %	65.61 %
Recall	96.25 %	65.61 %
F1-Score	96.24 %	65.00 %

Table 1: Comparativo das métricas de classificação binária entre VGG19 e EfficientNetB0.

Matriz de Confusão - VGG19		
	Predicted Negative	Predicted Positive
Real Negative	207	60
Real Positive	114	125

Matriz de Confusão - EfficientNetB0		
	Predicted Negative	Predicted Positive
Real Negative	223	16
Real Positive	3	264

Table 2: Matrizes de Confusão para VGG19 e EfficientNetB0

conforme demonstrado na Tabela 1. Apenas a EfficientNetB0 conseguiu alcançar uma precisão elevada, o que indica sua capacidade de identificar corretamente as características relevantes das imagens dentais. A EfficientNetB0 mostrou um equilíbrio melhor entre as medidas. Isso sugere que a EfficientNetB0 pode ser mais adequada que a VGG19 para essa atividade. É possível verificar o desempenho na matriz de confusão, que pode nos dar indicativos de influência de falsos positivos e negativos através das medidas de precisão e recall. Na tabela 2 podemos ver a matriz de confusão das duas redes usadas aqui para fazer o comparativo.

4 CONCLUSÃO

Os resultados deste estudo destacam o potencial das redes neurais pré-treinadas na classificação de imagens de raio-x panorâmicas dentais. A transferência de aprendizado demonstrou ser eficaz na captura de detalhes suficientes para a classificação de imagens específicas de endodontia, evidenciando sua aplicabilidade na prática clínica. Apesar dos resultados promissores, a pesquisa atual abre caminho para futuros avanços e aprimoramentos metodológicos.

Como continuidade deste trabalho, pretende-se expandir o conjunto de dados, incorporando uma gama mais diversificada de imagens de raio-x panorâmicas. Essa ampliação visa criar uma base de dados mais robusta e representativa, permitindo análises mais detalhadas e, consequentemente, aumentando a precisão e a generalização dos modelos de diagnóstico.

Outra linha de pesquisa planejada envolve a implementação de redes neurais pré-treinadas ajustadas para o domínio específico de imagens de raio-x dentais. A utilização de tais modelos pode acelerar o treinamento, reduzir o tempo computacional e melhorar a eficácia dos resultados.

REFERÊNCIAS

- [1] Zhizhong Li and Derek Hoiem. Learning without forgetting. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(12):2935–2947, 2018. doi: 10.1109/TPAMI.2017.2773081.
- [2] Sinno Jialin Pan and Qiang Yang. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10):1345–1359, 2010. doi: 10.1109/TKDE.2009.191.
- [3] Xiaoxiao Shi, Wei Fan, and Jiangtao Ren. Actively transfer domain knowledge. In *Machine Learning and Knowledge Discovery in Databases: European Conference, ECML PKDD 2008, Antwerp, Belgium, September 15-19, 2008, Proceedings, Part II*, 2008.
- [4] Amir Hossein Abdi, Shohreh Kasaei, and Mojdeh Mehdizadeh. Automatic segmentation of mandible in panoramic x-ray. *Journal of Medical Imaging*, 2(4): 044003–044003, 2015.
- [5] Ibrahim Ethem Hamamci, Sezgin Er, Enis Simsar, and Atif Emre Yuksel. Dentex: An abnormal tooth detection with dental enumeration and diagnosis benchmark for panoramic x-rays, 2023.
- [6] Ibrahim Ethem Hamamci, Sezgin Er, Enis Simsar, Anjany Sekuboyina, and Gundogar. Diffusion-based hierarchical multi-label object detection to analyze panoramic dental x-rays. 2023.
- [7] Devesh Saini, Richa Jain, and Anita Thakur. Dental caries early detection using convolutional neural network for tele dentistry. In *International Conference (ICACCS)*, 2021.
- [8] Jae-Hong Lee et. al. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of Dentistry*, 77: 106–111, 2018. ISSN 0300-5712. doi: <https://doi.org/10.1016/j.jdent.2018.07.015>. URL <https://www.sciencedirect.com/science/article/pii/S0300571218302252>.
- [9] Ki-Sun et. al. Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs. *Clinical Medicine*, 2020.
- [10] Nator Junior Carvalho da Costa, Jose Vigno Moura Sousa, Domingos Bruno Sousa Santos, Francisco das Chagas Fontenele Marques Junior, and Rodrigo Teixeira de Melo. Classification of x-ray images for detection of childhood pneumonia using pre-trained neural networks. *Revista Brasileira de Computação Aplicada*, 12(3):132–141, 2020.
- [11] Arata Andrade Saraiva, Nuno M Fonseca Ferreira, Luciano Lopes de Sousa, Nator Junior C Costa, José Vigno M Sousa, DBS Santos, Antonio Valente, and Salviano Soares. Classification of images of childhood pneumonia using convolutional neural networks. In *Bioimaging*, pages 112–119. Geneva, Switzerland, 2019.
- [12] DBS Santos, Nator Junior C Costa, Jose Vigno M Sousa, Antonio Valente, and Salviano Soares. Models of learning to classify x-ray images for the detection of pneumonia using neural networks. 2019.
- [13] Mingxing Tan and Quoc Le. Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning*, pages 6105–6114. PMLR, 2019.
- [14] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.