

INTELIGÊNCIA ARTIFICIAL · UNIFOR · 30 DE ABRIL DE 2026

Annotation-free deep learning approach for detection of periapical bone rarefactions on panoramic radiographs: a feasibility study

Por José Evando da Silva-Filho, Caio Marques Silva, Giovanna Tacchi, Igor Rodrigues-Fontenele, Mateus Bôto-Marques, André Wescley Oliveira de Aguiar, Pedro P. Rebouças Filho, Danielle Frota de Albuquerque e Eduardo Diogo Gurgel-Filho

Fonte: OpenAlex · Unifor · [Publicação original](#)

INOVAÇÃO	APLICABILIDADE	POTENCIAL ECONÔMICO	MATURIDADE
6/10	8/10	7/10	Baixa

Estudo de viabilidade da UNIFOR que propõe uma abordagem de Deep Learning 'annotation-free' (sem anotação manual detalhada) para detecção de rarefações ósseas periapicais em radiografias panorâmicas. O modelo Xception fine-tuned atingiu F1-score de 64,7%, demonstrando potencial para reduzir custos de rotulagem de dados em diagnósticos odontológicos automatizados.

NÚCLEO DA ANÁLISE

Ideia de startup ou produto

Startup SaaS B2B focada em triagem radiológica inteligente que utiliza este modelo leve para integrar-se a sistemas digitais de radiografia existentes, oferecendo alertas automáticos de patologias para dentistas generalistas.

Aplicações práticas

Implementação como ferramenta de 'segunda opinião' ou triagem pré-analítica em softwares de imagem odontológica (PACS) para destacar exames com probabilidade de lesão, otimizando o tempo do especialista.

Potencial de mercado

Alto. O setor de Healthtech odontológico busca ansiosamente por soluções de IA que reduzam a barreira de entrada de dados (custo de anotação) e automatizem o fluxo de trabalho em clínicas e diagnósticos por imagem.

FUNDAMENTO CIENTÍFICO

Problema abordado

Alto custo e intensidade de mão de obra para criar datasets de imagens médicas anotadas espacialmente (pixel a pixel) necessários para treinar modelos de IA, além da necessidade de triagem eficiente em grandes volumes de exames radiográficos.

Metodologia

Análise retrospectiva de 2.527 radiografias panorâmicas classificadas em nível de imagem (binário). Foram avaliadas arquiteturas CNN (como Xception) e Vision Transformers (ViT) sob estratégias de fine-tuning e mecanismos de atenção, medindo acurácia, recall, especificidade e F1-score.

Principais descobertas

Modelos baseados em CNN superaram as arquiteturas ViT. A abordagem sem anotação espacial é viável para classificação binária, mantendo comportamento clinicamente interpretável, embora o desempenho (F1 de 64,7%) indique necessidade de melhorias e validação externa.

LEITURA PARA GESTÃO PÚBLICA

Integração em programas de telessaúde bucal do SUS para triagem automatizada em grandes campanhas de saúde, identificando pacientes prioritários para tratamento em centros de especialidade e reduzindo filas de espera.

PARCERIA UNIVERSIDADE × EMPRESA

Colaboração tecnológica entre o grupo de pesquisa da UNIFOR e empresas de software odontológico (Software Houses locais ou nacionais) para validação clínica do algoritmo e sua incorporação como módulo proprietário de IA.

OPORTUNIDADES DERIVADAS

3 direções estratégicas identificadas

STARTUP · IMPACTO ALTO · HEALTHTECH

Plataforma de Triagem Odontológica IA

Desenvolvimento de uma solução SaaS que utiliza a abordagem annotation-free para pré-analisar radiografias automaticamente, reduzindo a necessidade de anotação cara e acelerando o diagnóstico em clínicas.

POLÍTICA PÚBLICA · IMPACTO ALTO · GOVTECH

Triagem Inteligente na Atenção Básica

Uso do modelo na rede pública de saúde para triagem inicial de radiografias panorâmicas, encaminhando automaticamente casos suspeitos para especialistas e otimizando recursos do governo.

Validação Clínica UNIFOR-Empresa

Parceria entre a universidade e uma empresa de equipamentos ou software odontológico para refinar o algoritmo com dados reais e validá-lo em ambiente clínico para lançamento comercial.

ABSTRACT ORIGINAL

Objective To evaluate an annotation-free deep learning (DL) approach for the image-level detection of periapical bone rarefactions (PBRs) on panoramic radiographs (PRs). Study Design A retrospective dataset of 2,527 PRs was classified at the image level based on expert consensus using internationally accepted radiographic criteria. Multiple pretrained convolutional neural network (CNN) and vision transformer (ViT) architectures were evaluated under different modeling strategies, including fine-tuning and attention mechanisms. Model performance was assessed using accuracy, recall, specificity, and F1 score. Inferential comparisons were performed using non-parametric statistical tests. Results CNN-based models consistently outperformed ViT architectures in binary classification of periapical bone rarefactions. The fine-tuned Xception model achieved the highest overall performance, with an F1-score of 64.7% and low variability across repeated runs. Analyses were restricted to Classes A and B due to class imbalance constraints, then multi-class evaluation was not performed at this stage. Conclusions Annotation-free DL demonstrated feasibility for binary image-level detection of PBRs on PRs, reducing dependence on labor-intensive spatial annotations while maintaining clinically interpretable behavior. Multi-class classification remains a target for investigation with balanced datasets. The approach supports scalable image-level analysis under clinically realistic conditions, although external validation is still required to confirm generalizability.

MATÉRIA PARA LEIGOS

Para leigos: IA detecta problemas na raiz dos dentes sem precisar de marcações manuais

O cenário atual

Detectar problemas nos ossos ao redor da raiz dos dentes (chamados de rações ósseas periapicais) em radiografias panorâmicas geralmente exige o olhar atento de especialistas. Atualmente, muitas tecnologias de inteligência artificial para essa tarefa dependem de um trabalho braçal humano: profissionais precisam desenhar manualmente as áreas de problema nas imagens para "ensinar" a máquina. Esse processo é demorado e trabalhoso.

O que os pesquisadores fizeram

Cientistas da Universidade de Fortaleza (UNIFOR) testaram um novo método que dispensa essas marcações manuais detalhadas (anotações espaciais). O objetivo foi avaliar se uma abordagem de "Deep Learning" sem anotações conseguiria detectar essas alterações ósseas apenas analisando a radiografia inteira. Para isso, utilizaram um banco de dados retrospectivo com 2.527 radiografias, classificadas por consenso de especialistas segundo critérios internacionais. Eles testaram diferentes arquiteturas de inteligência artificial (CNNs e Transformers) usando estratégias de ajuste fino e mecanismos de atenção.

Como funciona na prática

Em vez de um humano desenhar o contorno exato da doença em cada raio-X, o sistema foi treinado para olhar para a imagem inteira e dizer se ela tem ou não a alteração óssea (classificação em nível de imagem). Os pesquisadores compararam modelos de Redes Neurais Convolucionais (CNN) e Transformers de Visão (ViT), ajustando modelos que já haviam sido pré-treinados em outras imagens.

Resultados e evidência

Os modelos baseados em CNN (Redes Neurais Convolucionais) tiveram desempenho melhor do que os Transformers de Visão para essa tarefa específica. O modelo campeão foi o "Xception" (ajustado), que atingiu uma pontuação F1 de 64,7%. Este valor indica o equilíbrio entre precisão e capacidade de encontrar os casos positivos. Devido a um desequilíbrio nos dados (havia muitos mais casos de um tipo do que de outro), as análises foram limitadas apenas às Classes A e B, e uma avaliação com múltiplas classes não foi realizada nesta etapa.

Implicações práticas

O estudo mostra que é viável usar inteligência artificial para detectar esses problemas dentários sem o trabalho pesado de fazer anotações pixel a pixel. Isso torna a análise de imagens mais escalável e aplicável a condições clínicas reais, podendo auxiliar profissionais de saúde a identificar casos mais rapidamente, mantendo um comportamento interpretável clinicamente.

Limitações e próximos passos

O estudo não realizou classificação multiclasse (diferenciar vários graus de severidade ao mesmo tempo) porque o conjunto de dados não estava balanceado. Além disso, os autores ressaltam que ainda é necessária uma validação externa (testar o modelo em dados de outros lugares) para confirmar que a tecnologia funciona bem em geral e não apenas nos dados específicos deste estudo.

QUEM SÃO OS PESQUISADORES

Quem são os pesquisadores

A pesquisa foi conduzida por um grupo de autores vinculado à Universidade de Fortaleza (UNIFOR). A equipe é composta por: José Evando da Silva-Filho, Caio Marques Silva, Giovanna Tacchi, Igor Rodrigues-Fontenele, Mateus Bôtto-Marques, André Wescley Oliveira de Aguiar, Pedro P. Rebouças Filho, Danielle Frota de Albuquerque e Eduardo Diogo Gurgel-Filho. O paper não detalha a formação acadêmica específica, títulos ou trajetória profissional prévia de cada autor, além de não informar qual foi a contribuição individual de cada um no desenvolvimento do estudo.

PALAVRAS-CHAVE

Deep learning · Pattern recognition (psychology)