

Uso da inteligência artificial para identificação de lesões periapicais

Use of artificial intelligence for the identification of periapical lesions

Raquel Lellis Colombini

Fundação para o Desenvolvimento Científico e Tecnológico da Odontologia (FUNDECTO).

Aurea do Carmo Pepe de Freitas, DDS, PhD

Fundação para o Desenvolvimento Científico e Tecnológico da Odontologia (FUNDECTO).

Cláudio Fróes de Freitas, DDS, PhD

Fundação para o Desenvolvimento Científico e Tecnológico da Odontologia (FUNDECTO).
Departamento de Estomatologia, Faculdade de Odontologia, Universidade de São Paulo.

Luciana Munhoz, DDS, PhD

Fundação para o Desenvolvimento Científico e Tecnológico da Odontologia (FUNDECTO).
Departamento de Imagens Médicas, Hematologia e Oncologia, Faculdade de Medicina de Ribeirão Preto, Universidade de São Paulo.
Email: dra.lucimunhoz@gmail.com

Como citar: Colombini RL, Freitas ACP, Freitas CF, Munhoz L. Uso da inteligência artificial para identificação de lesões periapicais. Revista Clínica de Odontologia. 2026;8(1):63-83.

RESUMO

Lesões periapicais estão entre as patologias odontológicas mais comuns e apresentam como característica radiográfica radiolusência periapical, no entanto podem ser subdiagnosticadas em pacientes assintomáticos. O objetivo deste trabalho é avaliar a precisão diagnóstica da inteligência artificial na detecção destas patologias apicais em radiografias panorâmicas, radiografias periapicais e tomografias computadorizadas de feixe cônico. Observamos que as CNNs (rede neural convolucional) apresentam alta acurácia, precisão e sensibilidade, ajudam a melhorar o desempenho e velocidade do diagnóstico de dentistas. Estas ferramentas de aprendizado profundo estão revolucionando a odontologia e podem auxiliar os clínicos e o sistema de saúde odontológica. Melhorias adicionais são necessárias para aumentar sua robustez, mas seu futuro é promissor.

Palavras-chave: Inteligência artificial. Endodontia. Lesão periapical. Imagens radiográficas odontológicas.

ABSTRACT

Periapical lesions are among the most common dental pathologies and are radiographically characterized by periapical radiolucency; however, they may be underdiagnosed in asymptomatic patients. The aim of this study is to evaluate the diagnostic accuracy of artificial intelligence in detecting these apical pathologies in panoramic radiographs, periapical radiographs, and cone-beam computed tomography scans. Convolutional neural networks (CNNs) have demonstrated high accuracy, precision, and sensitivity, contributing to improved diagnostic performance and faster interpretation by dental practitioners. These deep learning tools are transforming dentistry and may support clinicians and the oral healthcare system. Although further improvements are required to enhance their robustness, their future application appears promising.

Keywords: Artificial intelligence. Endodontics. Periapical lesion. Dental radiographic imaging.

INTRODUÇÃO

A lesão periapical é uma das doenças inflamatórias de maior prevalência na odontologia¹, causada por uma infecção bacteriana no canal radicular, leva à reabsorção óssea ao redor do ápice radicular. Esta reabsorção óssea é uma resposta do sistema imunológico em combate à infecção bacteriana². A lesão periapical geralmente é diagnosticada através de um exame clínico e radiográfico cauteloso e frequentemente se manifesta nos exames radiográficos como radioluscências periapicais, geralmente denominadas de lesões periapicais. Estas lesões podem apresentar uma variedade de padrões radiográficos, variando desde um pequeno aumento do espaço pericementário até lesões radiolúcidas claramente definidas³. Estas lesões podem ser difíceis de detectar nos exames radiográficos, principalmente quando estas lesões são pequenas e estão na maxila⁴.

Para identificar estas lesões periapicais podemos utilizar diferentes técnicas radiográficas: radiografias periapicais, radiografias panorâmicas e tomografia computadorizada de feixe cônico (TCFC)³. Radiografias periapicais são exames radiográficos úteis para os diagnósticos de lesões periapicais, no entanto, radiografias periapicais da boca toda não são rotineiramente utilizadas

como fim de triagem destas lesões³. Elas podem fornecer informações suficientes sobre a morfologia radicular, ligamento periodontal, osso alveolar e radioluscência periapical com uma dose baixa de radiação, são comumente utilizadas para o exame odontológico e acompanhamento destas lesões⁵. Sua eficácia tem sido limitada para pequenas lesões ósseas devido a sobreposição anatômica⁶. A radiografia panorâmica tem resolução inferior em comparação a TCFC, mas são rotineiramente utilizadas em consultórios odontológicas como ferramenta de imagem para uma avaliação inicial, diagnóstico e planejamento de tratamento da maxila e mandíbula simultaneamente. Ela escaneia uma ampla gama de estruturas orais com uma dose de radiação relativamente menor em relação a TCFC⁷.

A TCFC permite uma avaliação tridimensional das lesões periapicais,⁶ tem maior precisão diagnóstica para detecção das lesões periapicais, porém não está disponível rotineiramente na maioria dos consultórios odontológicos, seu valor no mercado é mais alto, além do fato de expor o paciente a uma maior radiação³. Devido a utilização mais elevada de radiação não se justifica seu uso para acompanhamento de rotina, ela pode ser facilmente afetada por artefatos metálicos (implantes ou incrustações metálicas adjacentes)⁵. TCFC apresentam maior precisão para detecção de imagens de lesões periapicais, seguidas pelas radiografias periapicais e depois as radiografias panorâmicas³.

O rico ambiente da cavidade oral e dos maxilares, incluindo as diferentes estruturas, tecidos e materiais restauradores aumenta significativamente a chance das lesões periapicais sejam mascaradas, principalmente nos estágios iniciais. Além destes fatores, a detecção e o diagnóstico diferencial dependem da interpretação do observador, que é inconsistente⁸. A avaliação adequada da imagem depende do conhecimento, treinamento, e experiência do clínico que examina as imagens, a avaliação imprecisa leva a diagnósticos incorretos e resulta em tratamentos incorretos da situação. Embora dentistas sejam treinados a fazer o diagnóstico correto de lesões periapicais, diagnósticos incorretos podem acontecer.

A inteligência artificial (IA) é um campo científico focado em replicar processos neurológicos dos seres humanos, como resolução de problemas, reconhecimento de objetos e tomadas de decisões através de máquinas⁷. As redes neurais estão entre os primeiros tipos de algoritmos de IA (inteligência artificial) desenvolvidos, seu poder computacional depende da qualidade e do volume dos dados de treinamento, que permitem que as redes refinem sua conexão. Redes de estrutura simples e com poucas camadas são denominadas de redes neurais de aprendizagem “rasa” já aquelas com camadas maiores e numerosas são denominadas de redes neurais de aprendizagem “profunda”.

O aprendizado profundo é um subconjunto do aprendizado da máquina. Estas construções de aprendizado profundo são conhecidas como redes neurais convolucionais, elas analisam e categorizam dados, apoiando a capacidade de aprendizado profundo, assim como os neurônios no cérebro humano. Elas são utilizadas para processar imagens grandes e complexas⁹. Como um subconjunto da IA, o aprendizado profundo é um método de aprendizado da máquina que ensina computadores, por meio de exemplos, a partir de imagens, texto ou som. Através de uma enorme quantidade de dados rotulados e poder computacional, os modelos de aprendizado profundo aprendem características das imagens, sem a necessidade de processos manuais para extração de informações. As redes neurais convencionais possuem cerca de três camadas ocultas, os modelos de aprendizado profundo podem ter até 150 camadas, alcançando uma maior precisão que antigamente⁷.

Entre as muitas tecnologias de IA, a classificação é frequentemente realizada por redes neurais artificiais e do subtipo denominado redes neurais convolucionais⁶. A IA tira interferências das informações armazenadas em um banco de dados, quanto mais dados ela analisa, melhor seu desempenho⁹. Nos últimos anos, as abordagens baseadas em aprendizagem profunda tornaram-se cada vez mais populares na odontologia fornecendo suporte ou substituindo processos demorados e minimizando erros causados por inexperiência^{4,5}. A inteligência artificial (IA) tem sido aplicada em muitas especialidades da

odontologia, tanto para aprimorar as decisões clínicas quanto no suporte para detecção de doenças e planejamento de tratamentos¹.

O aprendizado profundo tem se mostrado um campo promissor no que se refere ao desenvolvimento de sistemas especialistas em imagens, especialmente as redes neurais convolucionais, pois apresentam bom desempenho no reconhecimento de padrões de imagem. Desta maneira, técnicas de inteligência artificial são utilizadas na área da saúde como alternativa para auxiliar o diagnóstico por imagem. Assim é possível reduzir o tempo necessário para a realização de diagnóstico e até mesmo aumentar a precisão quando comparado à avaliação realizada por especialistas⁹.

Esta revisão tem como objetivo a análise de estudos sobre o uso de diversas redes neurais convolucionais em diferentes modalidades de imagem, radiografias panorâmicas, periapicais e TCFC na detecção de lesões periapicais, avaliando sua acurácia individual e comparativa a cirurgiões dentistas, desta maneira verificando a confiabilidade na prática clínica.

METODOLOGIA

Este artigo é uma revisão da literatura sobre a identificação de lesões periapicais pela IA através da análise de diferentes meios de imagens, radiografias panorâmicas, radiografias periapicais e TCFC. As bases de dados eletrônicas pesquisadas foram: PubMed e GoogleAcadêmico. Os resultados da busca eletrônica foram importados para o Endnote X9 (Clarivose, Filadélfia, EUA). Foram analisados 18 artigos entre os anos de 2020 e 2024, 6 artigos de cada modalidade radiográfica.

Como critérios de inclusão e exclusão temos:

Estudos incluídos abordaram os seguintes itens:

1. População: imagens radiográficas dentárias em diversas modalidades bidimensionais (2D) e tridimensionais (3D);
2. Intervenção: tarefas de aprendizagem profunda, incluindo classificação, segmentação ou detecção de objetos;
3. Comparação: padrão de referência (por exemplo, anotação de especialista);
4. Resultado: desempenho diagnóstico e estimativa de precisão.

Como critérios de exclusão foi adotado:

1. Artigos duplicados foram removidos;
2. Resumos e títulos irrelevantes foram excluídos,

RESULTADOS

Os artigos selecionados e suas principais informações estão apresentados na Tabela 1. Na Tabela 2, estão os tipos de IA utilizados em cada estudo, com suas siglas/abreviações, definição e função de cada IA simplificados.

Tabela 1. Tipo de imagem radiográfica, tipo de inteligência artificial (IA), objetivo e resultados dos artigos selecionados

ESTUDO/ TIPO DE IMAGEM	TIPO IA (nome/sigla da IA desenvolvida)	OBJETIVO	RESULTADO
RADIOGRAFIA PANORÂMICA ³	U2 Net	Avaliar acurácia diagnóstica da IA baseado na U2- Net	IA tem aplicações promissoras no auxílio de diagnóstico de radiolucências periapicais
RADIOGRAFIA PANORÂMICA ⁷	R-CNN mais rápido, Retina Net, YOLOv3, SSD, Libra R-CNN, R-CNN dinâmico, Cascade R-CNN, Caixa de Fóvea, SABL, ATSS	Detectar automaticamente lesões periapicais usando aprendizado profundo (10 frameworks)	Detecção de lesões periapicais de maneira confiável
RADIOGRAFIA PANORÂMICA ¹⁰	Fast R-CNN, Faster R-CNN, SSD e YoLo	Comparação da capacidade diagnóstica: dentista recém-formados x IA	IA teve resultado mais rápido

RADIOGRAFIA PANORÂMICA⁹	Diagnocat	Avaliar a precisão e eficácia da IA nas condições dentárias em radiografias panorâmicas	A IA pode ajudar na detecção de condições dentárias na clínica odontológica quando usados com a panorâmica
RADIOGRAFIA PANORÂMICA¹¹	LLC Diagnocat	Confiabilidade diagnóstica na avaliação automática da IA	IA útil para avaliação inicial de triagem
RADIOGRAFIA PANORÂMICA¹²	Modelo baseado na UNet	Avaliar a capacidade de 24 dentistas comparando a IA	Desempenho do algoritmo de aprendizado profundo atinge desempenho melhor que 14 dos 24 dentistas
RADIOGRAFIA PERIAPICAL²	YoCNET	Testar o YoCNET para identificar múltiplos alvos de lesões periapicais	Desempenho geral melhor que os modelos de IA anteriores
RADIOGRAFIA PERIAPICAL⁵	Faster R-CNN e YoLOv4	Uso do Faster R-CNN e YoLOv4 para detecção e classificação de lesões periapicais através de radiografias em três diferentes regiões do arco dentário	Ambos têm potencial para detectar e classificar as lesões periapicais
RADIOGRAFIA PERIAPICAL¹³	Alex Net	Reduzir a carga sobre os dentistas, através da CNN, na identificação de lesões periapicais	Melhorou o sucesso diagnóstico das lesões, melhorou a precisão em 5%
RADIOGRAFIA PERIAPICAL¹⁴	YOLO versão 3	Aplicar rede neural convolucional (CNN) para pontuar lesão periapical	O modelo treinado mostrou potencial para pontuação que beneficiaria clínicos e pesquisadores
RADIOGRAFIA PERIAPICAL¹⁵	CNN, ResNet, AlexNet, U-net, YoLo, R-CNN, R-CNN mais rápida	Revisão sistemática e meta-análise foi investigar a precisão da CNN comparado a clínicos especialistas	A CNN apresentou resultados altamente precisos na detecção de lesões periapicais.
RADIOGRAFIA PERIAPICAL⁶	CNN usando a interface de programação de aplicativos Keras e Tensor Flow	Comparar o desempenho de diagnóstico de redes neurais convolucionais (CNN) com o desempenho de observadores humanos	Resultado promissor onde IA apresenta mais acertos que radiologistas
TCFC¹	PAL-Net	Detectar e segmentar lesões periapicais através do algoritmo de rede neural convolucional profunda 3D, PAL-Net	Melhora em todos os resultados comparativos

TCFC ¹⁶	SCN e U-Net	Avaliar de modo abrangente a capacidade e desempenho de um algoritmo de identificação de lesão periapical	Resultados promissores, precisa de melhorias para lesões muito pequenas e tratamento de artefato
TCFC ⁴	Rede siamesa, rede VGG-16 e DEnse-121	Classificar dentes saudáveis e com lesões endodônticas usando IA (Rede Siamesa, rede VGG-16 e DEnse-121)	Precisão de 70% deste sistema
TCFC ¹⁷	SpacialConfiguration-Net e U-Net).	Estudo conduzido para desenvolver e validar uma rede neuronal convolucional profunda para detecção automatizada de lesões	Excelente resultado em relação a literatura comparada (sensibilidade e especificidade da detecção de lesões)
TCFC ¹⁸	Diagnocat	Comparar a eficácia de diagnóstico por um grupo de dentistas quando auxiliados pela IA baseada em métodos de aprendizado profundo e grupo que não obteve este auxílio	Este estudo mostrou que a IA melhorou significativamente as capacidades de diagnóstico dos dentistas
TCFC ⁸	U-Net	Uso do algoritmo DL para segmentação automatizada das imagens de TCFC e detecção de lesões periapicais	O algoritmo DL em ambiente limitado mostrou excelentes resultados para lesões periapicais

Abreviações: TCFC: Tomografia computadorizada de feixe cônico; IA: inteligência artificial.

Tabela 2. Explicação simplificada de cada inteligência artificial (IA) utilizada no estudo, com sigla, nome por extenso, definição e função.

Tipo (Sigla)	Nome por extenso	O que é / Para que serve
CNN	Convolutional Neural Network (Rede Neural Convolucional)	Modelo de aprendizado profundo utilizado para análise de imagens, capaz de identificar padrões visuais e detectar lesões periapicais automaticamente.
U-Net	Convolutional Network for Biomedical Image Segmentation	Arquitetura de rede neural voltada para segmentação de imagens médicas, delimitando precisamente áreas de lesão.

U²-Net	Nested U-Net Architecture	Versão aprimorada da U-Net com supervisão profunda, utilizada para melhorar a segmentação de radiolucências periapicais.
PAL-Net	Periapical Lesion Network	Rede neural tridimensional desenvolvida para detectar e segmentar lesões periapicais em TCFC, permitindo análise volumétrica.
Faster R-CNN	Faster Region-Based Convolutional Neural Network	Modelo de detecção de objetos que identifica e localiza automaticamente lesões em imagens radiográficas.
R-CNN	Region-Based Convolutional Neural Network	Rede baseada em regiões propostas para detecção de objetos em imagens.
RetinaNet	Single-Stage Object Detector	Modelo de detecção de objetos que combina boa precisão com velocidade adequada.
YOLO (v3, v4, v5)	You Only Look Once	Modelo de detecção de objetos em tempo real que analisa a imagem inteira de uma vez para identificar lesões rapidamente.
SSD	Single Shot MultiBox Detector	Detector rápido de objetos que realiza identificação em etapa única.
ConvNeXt	Convolutional Network Next Generation	Arquitetura moderna de rede convolucional voltada para melhorar desempenho em classificação de imagens.
ResNet	Residual Network	Rede neural profunda que utiliza conexões residuais para facilitar o treinamento de múltiplas camadas.
DenseNet-121	Densely Connected Convolutional Network	Rede profunda em que cada camada se conecta às anteriores, melhorando fluxo de informação e desempenho.
VGG-16	Visual Geometry Group 16-layer Network	Rede convolucional clássica composta por 16 camadas utilizada para classificação de imagens.
Rede Siamesa	Siamese Neural Network	Arquitetura que compara duas imagens simultaneamente para identificar semelhanças ou diferenças.
Spatial Configuration-Net	Spatial Configuration Network	Rede voltada para localização de estruturas dentárias antes da segmentação de lesões.
Diagnocat	Sistema comercial de IA baseado em Deep Learning	Software clínico que realiza detecção automatizada de patologias em radiografias panorâmicas e TCFC.
Keras + TensorFlow	Bibliotecas de Deep Learning	Plataformas computacionais utilizadas para desenvolvimento e treinamento de modelos de redes neurais convolucionais.

RESULTADOS

Lesões radiolúcidas são os achados radiográficos mais comuns associados a dentes com infecções endodônticas primárias ou persistentes. Ainda assim, são frequentemente encontradas incidentalmente em radiografias periapicais, panorâmicas ou imagens de TCFC, muitas dessas lesões são assintomáticas no momento da detecção.

Estudos demonstraram que, entre as doenças dentárias comuns identificadas por meio do aprendizado profundo, as lesões periapicais representam o maior desafio.

Os avanços na inteligência artificial levaram a melhorias rápidas na análise de imagens odontológicas, facilitadas pela utilização de algoritmos de aprendizagem profunda. A IA oferece um diagnóstico eficiente, importante para obtenção dos melhores resultados nos tratamentos oferecidos, desta forma entrega ao paciente um atendimento superior. O software da IA podem servir aos dentistas com um guia para melhores decisões num período mais curto. Desta forma, a segurança entre dentista e paciente aumentaria.

Neste estudo trazemos alguns artigos que relatam o uso da IA em radiografias panorâmicas, radiografias periapicais e tomografias computadorizadas.

Radiografias Panorâmicas:

Neste trabalho¹² observou-se que a radiografia digital passa por avanços expressivos nos últimos tempos na área médica, um foco semelhante não é observado na odontologia. Apesar dos CBMF (cirurgiões bucomaxilofaciais) analisarem radiografias panorâmicas rotineiramente, neste estudo observa-se que a capacidade de identificação de radioluscências periapicais em panorâmicas pode ser limitada. Os resultados sugerem que estas alterações periapicais

radioluciolúcidas podem passar despercebidas, levando a desfechos piores aos pacientes¹².

Com base nessas descobertas, foi desenvolvido um algoritmo de aprendizado para identificação de radiolucências periapicais que não apenas teve um desempenho melhor do que metade dos cirurgiões CBMF experientes em comparação com algumas métricas, mas pode servir como uma ferramenta complementar para diagnósticos, bem como servir como base para uma ferramenta de detecção de radiolucência periapical mais abrangente e totalmente automatizada no futuro. 2902 radiografias panorâmicas foram analisadas por 24 CBMF e o algoritmo preditivo de aprendizado profundo desenvolvido pela Universidade, os dentistas, em média, diagnosticaram erroneamente 31% dos casos de radiolucência e 49% de todas as radiolucências foram perdidas. O resultado deste trabalho mostrou que o algoritmo de aprendizado profundo obteve um desempenho superior ao de 14 dos 24 cirurgiões (CBMF) da coorte¹².

Em outro trabalho¹¹ foram avaliadas 30 radiografias panorâmicas, abrangendo pelo menos 6 dentes para avaliação do periodonto marginal e apical, por 6 dentistas, manualmente, com experiência de 12, 15 e 28 anos na odontologia e elas foram carregadas na conta Diagnocat (LLC Diagnocat, Moscou, Rússia) e gerado relatório. Os dados foram coletados para análise estatística do software SPSS Statistics (IBM, Armonk, NY, EUA) e 90 relatórios foram criados. Foi observada uma especificidade muito alta da IA nas comparações, exceto para perda óssea periodontal. A análise estatística entre os avaliadores apresentou-se bem correlacionada, mostrando boa credibilidade. Obteve-se credibilidade inaceitável para avaliação de cárie e lesões periapicais. Portanto, o sistema de IA testado fornece laudos com credibilidade adequada e sugere diagnósticos adicionais para um diagnóstico mais preciso, é uma ferramenta muito útil para uma avaliação inicial de triagem¹¹.

Usando aprendizado profundo para detectar lesões periapicais em 454 objetos em 357 radiografias panorâmicas anonimizadas e rotuladas

manualmente, neste trabalho⁷ elas foram pré-processadas para aprimorar a qualidade da imagem. Os dados obtidos foram colocados aleatoriamente em pastas de treinamento, validação e teste. Dez frameworks de detecção (R-CNN mais rápido, RetinaNet, YOLOv3, SSD, Libra R-CNN, R-CNN dinâmico, Cascade R-CNN, Caixa de Fóvea, SABL, ATSS) baseados em aprendizado profundo foram aplicados para detecção de lesões periapicais. Estas estruturas de detecção baseadas em aprendizagem profunda foram bem-sucedidas na detecção de lesões periapicais (com o melhor resultado apresentado pelo RetinaNet), mostrando que estas ferramentas são confiáveis, conclui-se que o aprendizado profundo baseado na IA é uma revolução na odontologia que vem para auxiliar o clínico e sistema de saúde odontológica⁷.

O principal objetivo neste estudo¹⁰ foi avaliar o desempenho diagnóstico de um software de IA em comparação com três dentistas juniores (com 1 ou 2 anos de experiência), enquanto o diagnóstico dos dentistas especialistas (2 dentistas especialistas com mais de 10 anos de experiência) é definido como um diagnóstico verdadeiro. 500 radiografias panorâmicas foram incluídas neste estudo para detecção de cárie e lesões periapicais. A IA mostrou resultados melhores e mais rápidos para ambos os diagnósticos. De acordo com os resultados, os softwares de IA atuais devem ser usados tanto na prática clínica com a educação odontológica, dentistas iniciantes, especialmente, devem receber suporte da IA até adquirirem experiência, tanto pela rapidez do diagnóstico quanto pelo diagnóstico correto de doenças¹⁰.

Radiografias panorâmicas de 100 pacientes (4497 dentes) foram selecionadas aleatoriamente de um banco de dados universitários neste trabalho⁹. Elas foram avaliadas por 3 radiologistas CBMF e o software Diagnocat AI. As avaliações foram focadas em várias condições e tratamentos dentários. A sensibilidade foi muito alta para a grande maioria das situações, exceto para: avaliação de cáries, lesões periapicais, lacunas no canal e saliências. A IA pode ajudar na detecção de condições dentárias na clínica odontológica, mas mostra algumas limitações que exigem diagnóstico complementar⁹.

Esta pesquisa³ avaliou a precisão diagnóstica de um modelo de IA baseado na arquitetura U²-Net na detecção de lesões periapicais em radiografias panorâmicas determinando se elas ajudam os clínicos no diagnóstico destas lesões e em seu fluxo de trabalho. 400 radiografias panorâmicas anonimizadas com 780 radioluscências periapicais rotuladas manualmente por 2 examinadores foram utilizadas. Estas radiografias foram usadas para treinar o modelo de IA baseado na arquitetura U²-Net treinado usando um algoritmo de supervisão profunda. O estudo demonstrou que este modelo pode diagnosticar com precisão as lesões periapicais, auxiliando dentistas no diagnóstico e planejamento clínico de casos, mas ressalta que estudos adicionais são necessários para maior precisão diagnóstica da IA³.

Radiografias Periapicais:

Com o objetivo de comparar o desempenho diagnóstico de redes neurais convolucionais (CNN) com observadores humanos na detecção de lesões periapicais simuladas em radiografias periapicais (placas de fósforo de armazenamento foto estimulável), este trabalho⁶ usou dez alvéolos preparados em costelas bovinas onde defeitos periapicais de 3 tamanhos foram criados sequencialmente. As radiografias dos alvéolos foram adquiridas sem lesão e com cada tamanho de lesão. O desempenho da CNN (Keras e TensorFlow) foi comparado com o de 3 radiologistas. A CNN superou os radiologistas nas avaliações e demonstram que são promissoras na detecção de lesões periapicais⁶.

A fim de reduzir a sobrecarga dos dentistas, este artigo¹³ propõe um modelo de análise baseado em uma rede neural convolucional (CNN) para lesões periapicais em imagens periapicais. O banco de dados foi fornecido por dentistas com mais de 3 anos de experiência. Observa-se neste trabalho: uma técnica avançada de pré-processamento para segmentação das imagens; uma técnica de aprimoramento das lesões periapicais e um modelo para detecção de lesões periapicais com mais precisão de até 96,21%. Quando comparada com a tecnologia de ponta existente, o modelo proposto por este trabalho, melhorou a

precisão em 5%, portanto, aprimorou o sucesso do diagnóstico automático de lesões periapicais¹³.

Neste estudo¹⁴ o objetivo foi aplicar uma rede neural convolucional (CNN) para pontuar lesões periapicais em radiografias periapicais baseadas no sistema de pontuação do índice periapical (PAI). Este índice de pontuação, estruturado e preciso, tem como referência radiografias, desenhos correspondentes e suas respectivas pontuações PAI, nas quais as radiografias periapicais são pontuadas. 3000 áreas radiculares periapicais em 1950 radiografias periapicais intraorais foram pré-pontuadas por 3 endodontistas, dados que foram usados para o treinamento da CNN (YOLO versão 3). 450 radiografias periapicais foram utilizadas para a validação do modelo. 540 em 250 radiografias periapicais intraorais foram utilizadas para testar o desempenho desta rede neural convolucional. Este modelo treinado, com quantidade limitada de dados de radiografias periapicais intraorais, mostrou potencial para pontuação de PAI da lesão periapical nas radiografias periapicais intraorais digitais¹⁴.

Nesta revisão sistemática e meta-análise¹⁵ foi investigada a precisão geral dos modelos de aprendizado profundo na detecção de lesões radiolúcidas periapicais em radiografias odontológicas comparando-se com clínicos especialistas. As bases de dados pesquisadas foram: Medline (via PubMed), Embase (via Ovid), Scopus, Google Acadêmico e arXiv. Foram feitas análises de subgrupos em diferentes modalidades de imagem (radiografia periapical, radiografia panorâmica e imagens de tomografia computadorizada de feixe cônico) e diferentes tarefas de aprendizado profundo (classificação, segmentação, detecção de objetos). 932 estudos foram selecionados e 18 foram incluídos. O estudo demonstrou sensibilidade e especificidade relativamente altas para a detecção de lesões radiolúcidas periapicais usando aprendizado profundo em todas as modalidades de imagem, o que demonstra potencial para uso independente em ambientes clínicos. Em comparação com clínicos especialistas, o aprendizado profundo apresentou resultados altamente precisos na detecção de lesões radiolúcidas periapicais em radiografias odontológicas¹⁵.

Visando superar as limitações de um único modelo de classificação e identificação simultânea de múltiplos alvos de lesões periapicais em radiografias periapicais, este estudo² propõe o YoCNET (união do Yolov5 e ConvNeXt), um modelo integrado de aprendizado profundo. Ele extrai as melhores características de ambos, aproveita a capacidade de detecção de alvos do Yolov5 e a capacidade de classificação de imagens do ConvNeXt, desta maneira obtém a segmentação automática de dentes individuais e a detecção de lesões periapicais em múltiplos dentes. 1305 radiografias periapicais foram usadas para treinar e validar os modelos ConvNeXt e ResNet34. O modelo YoCNET exibiu desempenho geral de dados superior, as métricas foram superiores às alcançadas pelo modelo integrado YoRNET (Yolov5+ResNet34), tornando o YoCNET um modelo integrado de aprendizado profundo mais adequado para aplicações clínicas².

Este estudo⁵ teve como aplicar 2 modelos de aprendizado profundo, Faster R-CNN e YOLOv4, usados para detecção e classificação de lesões periapicais, para tal usam a pontuação do PAI de radiografias periapicais em três regiões diferentes: dentes anteriores, pré-molares e molares (sistema de pontuação do PAI atribui uma pontuação de 1 a 5 a cada dente, com 1 indicando ausência de alterações apicais visíveis e 5 indicando grande radiolucência apical com evidência de alargamento do ligamento periodontal). Foram selecionadas 2658 radiografias periapicais, 2122 usadas para treinamento, 268 para validação e 268 para teste. A localização da lesão dentro do arco dentário pode não ser um fator importante que afeta a detecção de lesões periapicais na radiografia periapical. O Faster R-CNN apresentou resultados melhores que YOLOv4 para detectar e classificar as lesões periapicais com base no sistema de pontuação PAI através de radiografias periapicais.

Tomografias Computadorizadas de Feixe Cônico:

Neste estudo¹ foi validado um novo algoritmo de rede neural convolucional profunda tridimensional, o PAL-Net, para detectar e segmentar de

forma rápida e precisa lesões periapicais associadas nas imagens tomográficas de feixe cônico. O algoritmo melhorou o desempenho diagnóstico de dentistas com diferentes níveis de experiência (juniores: menos de 1 ano de experiência e seniores: endodontista com mais de 5 anos de experiência), além de reduzir significativamente o tempo de diagnóstico. Além disso, o algoritmo forneceu resultados de segmentação clinicamente relevantes que podem auxiliar os clínicos no tratamento de lesões relacionadas lesão periapical. O PAL-Net mostrou forte robustez, fornecendo informações de volume das lesões periapicais clinicamente relevantes, mesmo para lesões pequenas. Sugere-se que o PAL-Net tem potencial para aplicação em clínicas odontológicas¹.

Este estudo¹⁶ visou avaliar de forma abrangente o desempenho e capacidade de um algoritmo de detecção de lesões periapicais baseando-se em aprendizado profundo em um conjunto de dados de TCFC clinicamente representativo e testar a não inferioridade. Foram avaliadas 195 imagens de TCFC de maxila e mandíbula de adultos, estratificadas por maxila (diferença não significativa) e por tipo de dente (terceiros molares, caninos e incisivos laterais, apresentaram menor sensibilidade). As lesões periapicais presentes receberam uma pontuação de índice periapical com base em seu tamanho para que fosse possível uma avaliação baseada em pontuação (de 1 a 5 conforme seu tamanho, sendo classe 1, com diâmetro de radiolusência periapical entre 0,5 e 1 mm e as classes 2 a 5 com diâmetros de radiolusência periapical maiores que 1 mm), a partir da classe 2 as sensibilidades são muito maiores. O algoritmo demonstrou resultados promissores, mas são necessárias melhorias na detecção de lesões muito pequenas, no tratamento de artefatos e valores discrepantes que são encontrados em situações clínicas¹⁶.

O proposto artigo⁴ tem como objetivo classificar dentes como saudáveis ou com lesão endodôntica através de um sistema de classificação desenvolvido com base em uma Rede Siamesa (não para comparar duas imagens, mas para extrair características de ambas simultaneamente) combinada com o uso de redes neurais convolucionais com aprendizado de transferência para redes VGG-16 e

DenseNet-121. Usou 1000 cortes sagitais e coronais de tomografias computadorizadas de feixe cônico. Este trabalho pioneiro em utilizar uma rede siamesa mostrou uma precisão de 70% sendo a dificuldade decorrente da distinção entre dentes sem lesões e aqueles com lesões pequenas.

A intenção deste estudo¹⁷ foi desenvolver e validar uma rede neural convolucional profunda para a detecção automatizada de lesões periapicais osteolíticas em conjuntos de dados de TCFC. Um conjunto de dados de TCFC de cirurgias clínicas de rotina (maxila, mandíbula ou ambas) foram triadas e selecionadas. Uma abordagem em duas etapas foi utilizada para detecção automática de lesões periapicais. Para localização e identificação dos dentes foram realizadas utilizando a SpatialConfiguration-Net com base na regressão de mapa de calor. Depois, uma segmentação binária das lesões foi realizada utilizando uma arquitetura U-Net modificada. A taxa de sucesso de detecção da rede de localização dentária variou entre 72,6% e 97,3% e detecção de lesões foram de 97,1% e 88,0%. Desta maneira, as lesões periapicais apresentaram variações na aparência, tamanho e forma no conjunto de dados TCFC e tenha havido um alto desequilíbrio entre os dentes com e sem lesões periapicais, mas houve um bom resultado quando comparado com a literatura selecionada¹⁷.

Um novo sistema de IA em métodos de aprendizado profundo foi avaliada¹⁸ para determinar seu desempenho em tempo real no diagnóstico por imagem de TCFC (anatomia, patologias, eficácia clínica e segurança quando utilizada por dentistas num ambiente clínico). Este sistema é composto por 5 módulos: módulo de localização (segmentação de dentes e maxilares), módulo de localização e numeração de dentes, módulo de periodontite, módulo de localização de cáries e de lesões periapicais. A CNN utilizada para estes módulos foram de última geração. 1246 TCFC foram utilizadas para treinar os módulos e depois de anotação e desenvolvimento do modelo, o sistema de IA foi testado quanto às capacidades de diagnóstico do sistema de IA Diagnocat. 24 dentistas participaram da avaliação do sistema. 30 exames de TCFC foram examinados por dois grupos de dentistas, onde um grupo foi auxiliado pelo Diagnocat e o outro

não. Este estudo demonstrou que o sistema de IA proposto melhorou significativamente a capacidade diagnóstica dos dentistas¹⁸.

O objetivo deste estudo⁸ foi usar um algoritmo de aprendizagem profunda na segmentação automatizada de imagens de tomografia computadorizada de feixe cônico e na detecção de lesões periapicais. Para isto foram utilizados volumes de TCFC com campo de visão limitado (n520) em 61 raízes com e sem lesões que foram segmentadas a critério clínico versus abordagem da IA com base em uma arquitetura U-Net. Esta segmentação rotulou cada voxel em categorias de 1 a 5: “lesão” (lesão periapical), “estrutura dentária”, “osso”, “materiais restauradores” e “fundo”. Todas as imagens passaram por treinamento e validação usando a segmentação de aprendizado profundo. Concluiu-se, neste trabalho, que este algoritmo de aprendizado profundo treinado em um ambiente limitado apresentou excelentes resultados na precisão da detecção de lesões e que pode ser beneficiado por versões aprimoradas de IA⁸.

CONCLUSÃO

As lesões periapicais não são facilmente detectáveis. A inteligência artificial na forma de aprendizagem profunda é, em geral, uma ferramenta precisa para detecção destas lesões em radiografias periapicais, panorâmicas e em tomografias computadorizadas. Radiografias panorâmicas são exames frequentemente solicitados na rotina clínica e com o auxílio da IA diagnósticos podem ser aprimorados, assim como nas radiografias periapicais que são exames de fácil execução na clínica odontológica e com o artifício da inteligência artificial os resultados serão mais precisos, rápidos e efetivos. Em relação a TCFC, exame mais completo, sua capacidade diagnóstica será ainda mais ampliada com o uso da IA. Modelos baseados em IA tem aplicações promissoras para ajudar no diagnóstico destas lesões, planejamento de procedimentos para seu tratamento, melhorando a eficiência do fluxo do trabalho clínico. Dentista iniciantes,

especialmente, são beneficiados com o uso de IA, tanto para ganhar experiência, com diagnósticos mais rápidos e precisos. No entanto, mais pesquisas e validações são essenciais para estabelecer a generalização e a confiabilidade do algoritmo em cenários clínicos. As limitações atuais devem ser abordadas no futuro para uma melhor integração com a clínica.

REFERÊNCIAS

1. Fu WT, Zhu QK, Li N, Wang YQ, Deng SL, Chen HP, et al. Clinically Oriented CBCT Periapical Lesion Evaluation via 3D CNN Algorithm. *J Dent Res*. 2024 Jan;103(1):5-12.
2. Liu J, Liu X, Shao Y, Gao Y, Pan K, Jin C, et al. Periapical lesion detection in periapical radiographs using the latest convolutional neural network ConvNeXt and its integrated models. *Sci Rep*. 2024 Oct 25;14(1):25429.
3. Boztuna M, Firincioglugulari M, Akkaya N, Orhan K. Segmentation of periapical lesions with automatic deep learning on panoramic radiographs: an artificial intelligence study. *BMC Oral Health*. 2024 Nov 01;24(1):1332.
4. Calazans MAA, Ferreira FABS, Alcoforado MLMG, Santos AD, Pontual ADA, Madeiro F. Automatic Classification System for Periapical Lesions in Cone-Beam Computed Tomography. *Sensors (Basel)*. 2022 Aug 28;22(17).
5. Viet DH, Son LH, Tuyen DN, Tuan TM, Thang NP, Ngoc VTN. Comparing the accuracy of two machine learning models in detection and classification of periapical lesions using periapical radiographs. *Oral Radiol*. 2024 Oct;40(4):493-500.
6. Pauwels R, Brasil DM, Yamasaki MC, Jacobs R, Bosmans H, Freitas DQ, et al. Artificial intelligence for detection of periapical lesions on intraoral radiographs: Comparison between convolutional neural networks and human observers. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2021 May;131(5):610-6.
7. Çelik B, Savaştaer EF, Kaya HI, Çelik ME. The role of deep learning for periapical lesion detection on panoramic radiographs. *Dentomaxillofac Radiol*. 2023 Nov;52(8):20230118.

8. Setzer FC, Shi KJ, Zhang Z, Yan H, Yoon H, Mupparapu M, et al. Artificial Intelligence for the Computer-aided Detection of Periapical Lesions in Cone-beam Computed Tomographic Images. *J Endod.* 2020 Jul;46(7):987-93.
9. Orhan K, Aktuna Belgin C, Manulis D, Golitsyna M, Bayrak S, Aksoy S, et al. Determining the reliability of diagnosis and treatment using artificial intelligence software with panoramic radiographs. *Imaging Sci Dent.* 2023 Sep;53(3):199-208.
10. Güneç HG, Ürkmez E, Danaci A, Dilmaç E, Onay HH, Cesur Aydin K. Comparison of artificial intelligence. *Quant Imaging Med Surg.* 2023 Nov 01;13(11):7494-503.
11. Zadrożny Ł, Regulski P, Brus-Sawczuk K, Czajkowska M, Parkanyi L, Ganz S, et al. Artificial Intelligence Application in Assessment of Panoramic Radiographs. *Diagnostics (Basel).* 2022 Jan 17;12(1).
12. Endres MG, Hillen F, Salloumis M, Sedaghat AR, Niehues SM, Quatela O, et al. Development of a Deep Learning Algorithm for Periapical Disease Detection in Dental Radiographs. *Diagnostics (Basel).* 2020 Jun 24;10(6).
13. Chuo Y, Lin WM, Chen TY, Chan ML, Chang YS, Lin YR, et al. A High-Accuracy Detection System: Based on Transfer Learning for Apical Lesions on Periapical Radiograph. *Bioengineering (Basel).* 2022 Dec 06;9(12).
14. Moidu NP, Sharma S, Chawla A, Kumar V, Logani A. Deep learning for categorization of endodontic lesion based on radiographic periapical index scoring system. *Clin Oral Investig.* 2022 Jan;26(1):651-8.
15. Sadr S, Mohammad-Rahimi H, Motamedian SR, Zahedrozegar S, Motie P, Vinayahalingam S, et al. Deep Learning for Detection of Periapical Radiolucent Lesions: A Systematic Review and Meta-analysis of Diagnostic Test Accuracy. *J Endod.* 2023 Mar;49(3):248-61.e3.
16. Hadzic A, Urschler M, Press JA, Riedl R, Rugani P, Štern D, et al. Evaluating a Periapical Lesion Detection CNN on a Clinically Representative CBCT Dataset-A Validation Study. *J Clin Med.* 2023 Dec 29;13(1).
17. Kirnbauer B, Hadzic A, Jakse N, Bischof H, Stern D. Automatic Detection of Periapical Osteolytic Lesions on Cone-beam Computed

Tomography Using Deep Convolutional Neuronal Networks. J Endod. 2022 Nov;48(11):1434-40.

18. Ezhov M, Gusarev M, Golitsyna M, Yates JM, Kushnerev E, Tamimi D, et al. Clinically applicable artificial intelligence system for dental diagnosis with CBCT. Sci Rep. 2021 Jul 22;11(1):15006.