

APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO EM ENDODONTIA: UMA REVISÃO DE LITERATURA

APPLICATION OF ARTIFICIAL INTELLIGENCE IN ENDODONTIC DIAGNOSIS: A LITERATURE REVIEW

Matheus Araújo Brito Santos Lopes¹, Máximo de Oliveira Medeiros², Alana Cácia Soares
Moraes Souza³

1. Professor(a) do curso de Odontologia da Afya Centro Universitário UNINOVAFAPI, Teresina, Piauí, Brasil
2. Professor(a) do curso de Odontologia da Afya Centro Universitário UNINOVAFAPI, Teresina, Piauí, Brasil
3. Professor(a) do curso de Odontologia da Afya Centro Universitário UNINOVAFAPI, Teresina, Piauí, Brasil.

E-mail do autor correspondente: alana.souza@afya.com.br

Eixo: 01

RESUMO

Introdução: O diagnóstico em Endodontia exige precisão na identificação de variações anatômicas, lesões periapicais, fraturas radiculares e reabsorções, mas a interpretação das imagens permanece sujeita à sobreposição de estruturas, a artefatos de técnica e à variabilidade interobservador. Modelos de inteligência artificial (IA), sobretudo redes neurais convolucionais (CNNs), vêm sendo propostos como ferramentas de apoio a essa interpretação. **Objetivo:** Analisar as evidências científicas disponíveis sobre a acurácia diagnóstica e as aplicações clínicas da inteligência artificial no auxílio ao diagnóstico endodôntico. **Metodologia:** Realizou-se uma revisão integrativa da literatura nas bases PubMed/MEDLINE, Scopus, Web of Science e Biblioteca Virtual em Saúde (BVS), incluindo estudos que avaliaram algoritmos de IA aplicados a radiografias periapicais, radiografias panorâmicas e tomografia computadorizada de feixe cônico (TCFC) e que reportassem métricas quantitativas de desempenho. **Resultados e Discussão:** Os estudos analisados descrevem desempenho diagnóstico elevado, porém heterogêneo, na detecção de lesões periapicais, na identificação do segundo canal mesiovestibular (MV2), no reconhecimento de morfologias radiculares atípicas e na detecção de fraturas radiculares verticais. Os melhores resultados foram obtidos em condições controladas, com amostras reduzidas e provenientes de centro único, observando-se redução de desempenho diante de artefatos metálicos e de imagens adquiridas em equipamentos distintos daqueles utilizados no treinamento. **Conclusão:** A inteligência artificial configura-se como ferramenta promissora de suporte à decisão clínica em Endodontia, embora a validação externa em amostras multicêntricas, a transparência dos modelos e a definição da responsabilidade ético-legal permaneçam como desafios, mantendo-se a decisão diagnóstica e terapêutica final sob responsabilidade do cirurgião-dentista.

Palavras-chave: Inteligência Artificial; Endodontia; Diagnóstico por Imagem; Tomografia Computadorizada de Feixe Cônico.

INTRODUÇÃO

O sucesso da terapia endodôntica depende de um diagnóstico preciso e de um planejamento adequado do procedimento. A interpretação correta das condições pulpares e periapicais requer a correlação entre achados clínicos e o exame minucioso de imagens radiográficas convencionais ou de tomografia computadorizada de feixe cônico (TCFC)¹⁻³. Contudo, a avaliação por imagem está sujeita a limitações intrínsecas, como a sobreposição de estruturas anatômicas, os artefatos de técnica e a subjetividade inerente à experiência do observador, fatores associados à variabilidade interobservador na identificação de lesões periapicais⁴.

Nos últimos anos, a Odontologia digital incorporou tecnologias baseadas em inteligência artificial (IA) e aprendizado profundo (deep learning) à análise de exames por imagem⁵. Entre os modelos computacionais disponíveis, as redes neurais convolucionais (convolutional neural networks — CNNs) destacam-se pela capacidade de processar grandes volumes de dados visuais e reconhecer padrões a partir de exemplos previamente anotados, atuando como sistemas de suporte à decisão clínica^{6,7}.

Na Endodontia, a aplicação da IA tem se expandido da detecção de lesões periapicais à identificação de anatomias radiculares complexas, ao reconhecimento de fraturas radiculares e à determinação do comprimento de trabalho⁸. Diante do impacto potencial dessas ferramentas sobre a rotina do especialista, torna-se necessário analisar criticamente o desempenho relatado e as condições em que esses resultados foram obtidos. O objetivo desta revisão é analisar as evidências científicas disponíveis sobre o uso da inteligência artificial no diagnóstico endodôntico, abordando suas principais aplicações, sua acurácia diagnóstica e os desafios para a implementação na prática clínica.

MÉTODO

Trata-se de uma revisão integrativa da literatura, conduzida por meio de levantamento bibliográfico nas bases de dados PubMed/MEDLINE, Scopus, Web of Science e Biblioteca Virtual em Saúde (BVS). A estratégia de busca combinou descritores controlados, indexados nos vocabulários Medical Subject Headings (MeSH) e Descritores em Ciências da Saúde (DeCS), e termos livres correspondentes, articulados pelos operadores booleanos AND e OR, conforme a seguinte equação, adaptada a cada plataforma: ("Artificial Intelligence" OR "Deep Learning" OR "Machine Learning" OR "Convolutional Neural Network") AND ("Endodontics" OR "Root Canal System") AND ("Diagnosis" OR "Periapical Lesion" OR "Root Fracture" OR "Cone-Beam Computed Tomography").

A busca abrangeu publicações no período de [INSERIR: mês/ano inicial] a [INSERIR: mês/ano final], realizada em [INSERIR: data da última busca]. Os critérios de elegibilidade contemplaram artigos originais, estudos de validação tecnológica e revisões sistemáticas publicados em inglês, português ou espanhol, que tivessem como escopo principal a avaliação de algoritmos de inteligência artificial aplicados ao diagnóstico de condições endodônticas. Foram excluídos relatos de caso, editoriais, cartas ao editor, resumos de congressos e investigações que não apresentassem métricas quantitativas de desempenho, como acurácia, sensibilidade, especificidade ou área sob a curva ROC (receiver operating characteristic).

A seleção ocorreu em duas etapas: triagem de títulos e resumos quanto à aderência temática e, posteriormente, leitura na íntegra dos estudos pré-selecionados para confirmação dos critérios de inclusão. A busca recuperou [INSERIR: nº] registros; após a remoção de duplicatas e a aplicação dos critérios de elegibilidade, [INSERIR: nº] estudos compuseram a amostra final. De cada estudo incluído foram extraídos, de forma padronizada, a arquitetura do modelo, a modalidade de imagem utilizada, o tamanho das amostras de treinamento e teste e as métricas de desempenho relatadas, procedendo-se à síntese descritivo-qualitativa das evidências. Por tratar-se de revisão da literatura, conduzida a partir de dados publicados e de domínio público, o estudo dispensou apreciação por Comitê de Ética em Pesquisa.

RESULTADOS E DISCUSSÃO

A análise da literatura revela expansão acelerada da aplicação de algoritmos de aprendizado profundo, especialmente das redes neurais convolucionais, ao diagnóstico endodôntico. De modo geral, os estudos relatam desempenho elevado na interpretação de radiografias periapicais, radiografias panorâmicas e volumes de TCFC^{9,10}, embora as métricas variem consideravelmente conforme a modalidade de imagem, a arquitetura empregada e a forma de composição da amostra. As aplicações concentram-se em quatro frentes clínicas: detecção de lesões periapicais, identificação de anatomias radiculares complexas, diagnóstico de fraturas radiculares verticais e avaliação da morfologia radicular.

No contexto das patologias periapicais, a identificação radiográfica precoce de rarefações ósseas é dificultada pela sobreposição de estruturas e pelo contraste reduzido nos estágios iniciais da periodontite apical. Modelos de segmentação aplicados a volumes tomográficos têm sido desenvolvidos para delimitar automaticamente a área de reabsorção óssea e estimar o volume da lesão, permitindo o acompanhamento do reparo de forma padronizada⁹. Em TCFC, um sistema baseado em CNN alcançou aproximadamente 93% de acurácia na detecção de lesões periapicais, com estimativa volumétrica próxima à segmentação

realizada por especialistas¹⁰. Em radiografias periapicais e panorâmicas, o desempenho também se mostrou promissor^{11,12}, embora estudos comparativos com observadores humanos indiquem que a vantagem da IA não é uniforme entre as diferentes condições avaliadas¹³.

Outro ponto amplamente debatido é o mapeamento de variações anatômicas do sistema de canais radiculares. A omissão do segundo canal mesiovestibular (MV2) em molares superiores figura entre as principais causas de insucesso terapêutico. Um modelo baseado na arquitetura U-Net, desenvolvido para detectar canais MV2 não obturados em TCFC, alcançou sensibilidade de 0,80, especificidade de 1,00 e acurácia de 0,90 na amostra de teste; o desempenho da segmentação, contudo, foi substancialmente inferior ao da detecção, e os autores registram interferência de artefatos metálicos e de variações na calcificação dos canais¹⁴. Abordagens semelhantes têm sido aplicadas à classificação de canais em forma de C em segundos molares inferiores¹⁵. Esse mapeamento pré-operatório funciona como orientação anatômica adicional ao cirurgião-dentista, com potencial de reduzir o tempo de exploração e o desgaste desnecessário de estrutura dentinária.

O diagnóstico de fraturas radiculares verticais (FRV) também tem sido investigado. Em dentes com obturação endodôntica ou retentores intrarradiculares, a leitura da TCFC é frequentemente prejudicada por artefatos de endurecimento do feixe (beam hardening), que podem simular ou mascarar linhas de fratura. Uma rede neural probabilística aplicada a pré-molares em condições ex vivo apresentou bom desempenho na identificação de FRV em imagens periapicais e tomográficas¹⁶. Em radiografias panorâmicas, um sistema baseado em CNN alcançou sensibilidade de 75% e valor preditivo positivo de 93%¹⁷. É importante notar que grande parte desses resultados provém de estudos ex vivo, com dentes extraídos e fraturas induzidas, o que limita a extrapolação direta para a prática clínica.

Apesar das métricas favoráveis, a incorporação dessas ferramentas à rotina clínica esbarra em limitações relevantes. Boa parte dos modelos foi desenvolvida a partir de bancos de dados restritos a um único centro ou a um único equipamento, o que favorece o sobreajuste (overfitting) e compromete o desempenho diante de imagens com diferentes resoluções, protocolos de aquisição e níveis de ruído. Soma-se a isso o caráter de "caixa-preta" de algumas redes profundas, cujos passos que conduzem à decisão não são plenamente interpretáveis, o que dificulta a auditoria clínica dos resultados e a atribuição de responsabilidade em caso de erro¹⁸. Consolida-se, portanto, o entendimento de que a IA deve atuar como sistema de suporte à decisão clínica (computer-aided diagnosis), permanecendo a responsabilidade ética e legal e a decisão terapêutica final sob domínio do cirurgião-dentista.

CONCLUSÃO

A inteligência artificial apresenta-se como ferramenta promissora de suporte ao diagnóstico em Endodontia, com resultados favoráveis na detecção de lesões periapicais, na identificação de anatomias complexas — como o canal MV2 — e no reconhecimento de fraturas radiculares verticais. Os desempenhos relatados, entretanto, foram majoritariamente obtidos em condições controladas, com amostras reduzidas, provenientes de centro único e, em parte, ex vivo, o que recomenda cautela na interpretação desses valores. A validação externa em bases multicêntricas e heterogêneas, a maior interpretabilidade dos modelos e a definição clara das responsabilidades ético-legais constituem requisitos para a incorporação segura dessas tecnologias à prática clínica, mantendo-se o julgamento clínico final sob domínio do cirurgião-dentista.

REFERÊNCIAS

1. Patel S, Brown J, Semper M, Abella F, Mannocci F. European Society of Endodontology position statement: use of cone beam computed tomography in endodontics. *Int Endod J*. 2019;52(12):1675-8.
2. Cotton TP, Geisler TM, Holden DT, Schwartz SA, Schindler WG. Endodontic applications of cone-beam volumetric tomography. *J Endod*. 2007;33(9):1121-32.
3. Hargreaves KM, Berman LH. Cohen's pathways of the pulp. 12th ed. St. Louis: Elsevier; 2021.
4. Parker JM, Mol A, Rivera EM, Tawil PZ. Cone-beam computed tomography uses in clinical endodontics: observer variability in detecting periapical lesions. *J Endod*. 2017;43(2):184-7.
5. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: a systematic review. *Dentomaxillofac Radiol*. 2020;49(1):20190107.
6. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436-44.
7. Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: a scoping review. *J Dent*. 2019;91:103226.
8. Setzer FC, Li J, Khan AA. The use of artificial intelligence in endodontics. *J Dent Res*. 2024;103(9):853-62.

9. 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;46(7):987-93.
10. Orhan K, Bayrakdar IS, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *Int Endod J.* 2020;53(5):680-9.
11. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, et al. Deep learning for the radiographic detection of apical lesions. *J Endod.* 2019;45(7):917-22.e5.
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;10(6):430.
13. 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;131(5):610-6.
14. Albitar L, Zhao T, Huang C, Mahdian M. Artificial intelligence (AI) for detection and localization of unobturated second mesial buccal (MB2) canals in cone-beam computed tomography (CBCT). *Diagnostics (Basel).* 2022;12(12):3214.
15. Sherwood AA, Sherwood AI, Setzer FC, Shamili JV, John C, Schwendicke F. A deep learning approach to segment and classify C-shaped canal morphologies in mandibular second molars using cone-beam computed tomography. *J Endod.* 2021;47(12):1907-16.
16. Johari M, Esmacili F, Andalib A, Garjani S, Saberkari H. Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofac Radiol.* 2017;46(2):20160107.
17. Fukuda M, Inamoto K, Shibata N, Ariji Y, Yanashita Y, Kutsuna S, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiol.* 2020;36(4):337-43.
18. Schwendicke F, Samek W, Krois J. Artificial intelligence in dentistry: chances and challenges. *J Dent Res.* 2020;99(7):769-74.