

## INTELIGÊNCIA ARTIFICIAL APLICADA AOS EXAMES DE IMAGEM ODONTOLÓGICOS – UMA REVISÃO DA LITERATURA

Artificial intelligence applied to dental imaging – a review

 Jerusa Jobim Jardim<sup>a</sup>

 Heraldo Luís Dias da Silveira<sup>a</sup>

 Priscila Fernanda da Silveira Tiecher<sup>a</sup>

 Mariana Boessio Vizzotto<sup>a</sup>

 Nádia Assein Arús<sup>a</sup>

<sup>a</sup>Federal University of Rio Grande do Sul, School of Dentistry, Department of Surgery and Orthopedics, Porto Alegre, RS, Brazil.

Corresponding author: Nádia Assein Arús - E-mail: [nadia.arus@ufrgs.br](mailto:nadia.arus@ufrgs.br)

**Data de envio:** 07/12/2022 **Data de aceite:** 29/06/2023



## RESUMO

**Objetivo:** investigar a literatura relacionada à aplicação e desempenho da Inteligência Artificial (IA) em exames de imagem odontológicos. **Revisão de literatura:** foram incluídos 70 trabalhos experimentais e revisões sistemáticas da literatura, publicados em inglês, no período entre 2018 e 2021, que analisaram a aplicabilidade da IA na detecção automática de: pontos cefalométricos, lesões de cárie, lesões apicais, perda óssea periodontal, sistemas de implantes, cistos e tumores odontogênicos, osteoporose, sinusite maxilar, terceiros molares e canal mandibular, ateromas em carótida, fratura radicular vertical, osteoartrite em articulação temporomandibular, avaliação de morfologia radicular e numeração dentária. **Resultados:** 58,73% dos trabalhos analisados mostrou acurácia diagnóstica acima de 80% com a utilização de IA. **Discussão:** A maior limitação encontrada foi em relação à aquisição de amostras em quantidade suficiente para treinamento e teste dos modelos, já que imagens radiográficas têm sua disponibilidade limitada por questões éticas e legais relativas aos pacientes e Instituições. A falta de padronização na segmentação e processamento das imagens foi outro fator a influenciar os resultados obtidos, dificultando comparação e generalização. Apesar disso, diversos estudos apresentaram sugestões ou possíveis aperfeiçoamentos para pesquisas futuras, de forma a reduzir estas limitações. **Conclusão:** A aplicação da IA no diagnóstico por imagens mostrou-se promissora nas diversas áreas pesquisadas, com desempenhos muito semelhantes ou mesmo superiores, muitas vezes, ao desempenho dos profissionais humanos. Contudo, para a legitimação de sua utilização como parte do fluxo de trabalho na clínica, limitações ainda presentes devem ser superadas, especialmente no treinamento dos algoritmos para obtenção de melhores valores de acurácia.

**Palavras-chave:** Aprendizado de máquina. Tomografia computadorizada de feixe cônico. Radiografia panorâmica. Radiografia dentária digital. Diagnóstico por imagem.

## **ABSTRACT**

**Aim:** to investigate the literature related to the application and performance of Artificial Intelligence (AI) in the analysis of dental imaging. **Literature review:** 70 experimental studies and systematic literature reviews published in English between 2018 and 2021 were included, which analyzed the applicability of AI models in the automatic detection of the following: cephalometric landmarks, dental caries, periapical diseases, alveolar bone loss, dental implant, odontogenic cysts and tumors, osteoporosis, maxillary sinusitis, third molars and mandibular canal, carotid atheromas, vertical root fracture, osteoarthritis in temporomandibular joint, evaluation of root morphology and numbering of dental elements. **Results:** 58.73% of the analyzed studies showed diagnostic accuracy above 80%. **Discussion:** the greatest methodological limitation was the acquisition of samples in sufficient quantity for training and testing phases, since radiographic images are limited to their availability due to ethical and legal issues related to patients and institutions. Lack of standardization in the segmentation and image processing was another factor to influence the results, which was difficult to compare and generalize. Despite this, several studies presented suggestions or possible improvements for future research, in order to reduce the impact of these limitations. **Conclusion:** the investigation of the applicability of AI in the analysis of dental radiographic images seems to be still in its early days. The implementation of AI tools as radiologists' auxiliaries in their daily practice depends on overcoming the limitations of current studies and obtaining better diagnostic accuracy indices in future evaluations.

**Keywords:** Machine Learning. Cone-beam computed tomography. Radiography, panoramic. Radiography, dental, digital. Diagnostic imaging.

## INTRODUÇÃO

Inteligência artificial (IA) é um ramo da ciência da computação dedicada ao desenvolvimento de algoritmos para o cumprimento de tarefas tradicionalmente associadas à inteligência humana, como a habilidade de aprender e de resolver problemas<sup>1</sup>. No campo das atividades profissionais, a Odontologia tem se beneficiado dos modelos de IA em suas diversas áreas<sup>2,3</sup>, utilizando principalmente o aprendizado de máquina (*machine learning* – ML) e, em especial, o aprendizado profundo (*deep learning* – DL), que são subcampos da IA.

Aprendizado de máquina é uma técnica para análise de dados que permite ao sistema computacional aprender a reconhecer padrões a partir de um grande conjunto de dados<sup>4</sup>, tornando possível tarefas de classificação e a predição de resultados. Baseia-se em uma vasta variedade de algoritmos, comumente referidos como *modelos*. A escolha de um modelo em particular é determinada pelas características dos dados, bem como do tipo de resultado pretendido<sup>5</sup>. Os dados utilizados podem ser, por exemplo, um conjunto de imagens. Estas imagens servirão como dados de *input* para o aprendizado do modelo, que envolve várias formas de reconhecimento de padrões, gerando um *output* na forma de classificação ou de identificação de uma determinada característica. Os modelos de ML evoluem conforme são expostos a mais dados e, à medida que analisam mais informações dos pixels de centenas ou milhares de radiografias, “aprendem” a fornecer respostas específicas, em consonância com os parâmetros definidos manualmente pelo especialista<sup>1</sup>. Dessa forma, pode-se dizer que o acréscimo de dados ou informações de treinamento geralmente acarreta melhora do desempenho do modelo. O aprendizado profundo, por sua vez, é um tipo de ML que utiliza as chamadas “redes neurais”. A ideia de redes neurais surgiu como uma tentativa de imitar os padrões de conexão dos neurônios no córtex visual animal<sup>6</sup>. O principal constituinte de uma rede neural é o chamado neurônio artificial, que é um modelo matemático não-linear inspirado no neurônio humano<sup>7</sup>. Na rede neural, vários “neurônios” são conectados entre si de modo a formar uma rede, formada por três tipos de camadas, chamadas de camada de entrada (*input*), camada de saída (*output*) e camadas ocultas (*hidden*). A camada de entrada recebe os dados de entrada e o valor final é gerado na camada de saída. As camadas ocultas fazem cálculos intermediários que auxiliam a rede a encontrar os valores finais. Este modelo, conforme for alimentado por quantidades massivas de dados, sofre uma

automelhoria e um autorrefinamento constantes. Isso ocorre quando o modelo tem acesso a um conjunto de dados de treinamento, em que os processos de aprendizado são repetidos automaticamente, sem necessidade de interferência manual para definição de características da imagem analisada. Assim, os sistemas de aprendizado profundo são capazes de aprender de forma autônoma com as características detectadas na imagem e, simultaneamente, desempenhar a classificação dessa imagem<sup>8</sup>.

Há diversos tipos de redes neurais; contudo, a chamada rede neural convolucional (CNN - *convolutional neural network*) é um tipo de algoritmo de DL especializado em lidar com dados de topologia tipo grade, como imagens em duas dimensões (2D) e em três dimensões (3D), sendo, por esta razão, aplicado à análise e classificação de imagens para fins diagnósticos. As várias camadas nestes algoritmos são usadas para detectar características que variam de simples, como linhas, bordas, texturas e intensidade, até complexas, como formas, lesões ou órgãos em sua totalidade<sup>1</sup>. Neste tipo de rede neural, cada camada contribui com uma pequena informação, reconhecida e assimilada por convolução pela camada seguinte, até chegar à chamada camada *pooling*, que faz a classificação final do objeto<sup>5</sup>. Para chegar até este estágio, é necessário um período de treinamento do modelo. Quando este período é finalizado, a rede neural é capaz de usar informações para inferir as regras, com o aprendizado e o mapeamento das características sendo feitos ao mesmo tempo<sup>7</sup>. Nesse ponto, a efetividade do modelo precisa ser avaliada através dos dados de teste e vai depender de diversos fatores, tais como o tipo e quantidade de dados usados para treinamento, o tipo de CNN utilizado e o número de camadas existentes no modelo.

A aplicabilidade clínica do DL se refere principalmente à análise de imagens, com tarefas dentro de três categorias: detecção, para identificar anormalidade em uma imagem; segmentação, em que uma estrutura de interesse é isolada, como na definição dos limites de um órgão na imagem; e classificação, em que uma característica ou lesão na imagem é definida dentro de uma categoria<sup>1,5</sup>. A aplicabilidade do DL mostra, assim, potencial para automatizar tarefas que normalmente requerem muito tempo para serem executadas e para melhorar a capacidade humana de lidar com dados massivos e complexos.

A Radiologia parece oferecer acesso mais direto ao uso de modelos de IA, já que produz imagens digitalmente codificadas que podem ser mais facilmente traduzidas para a linguagem computacional<sup>9,10</sup>. No âmbito da radiologia odontológica, a IA parece ocupar um espaço crescente em estudos que buscam avaliar sua aplicabilidade clínica em diversas especialidades como método auxiliar ao radiologista, com acurácia diagnóstica próxima daquela dos especialistas humanos<sup>3,10</sup>, de forma a otimizar o fluxo de trabalho com qualidade e segurança. A Associação Canadense de Radiologistas (CAR), a respeito do uso da IA na Radiologia, recomenda que a comunidade de radiologistas deva se familiarizar com as diferentes técnicas de IA e se capacitar a analisar criticamente as oportunidades e desafios associados à introdução de novas ferramentas de IA<sup>1</sup>.

Paralelamente à possibilidade de modelos de IA se provarem preciosos auxiliares nas tarefas rotineiras do dentista radiologista, dúvidas necessariamente se interpõem neste cenário, referentes principalmente ao desempenho destes modelos, sua confiabilidade, e à uma possível futura redefinição do papel dos radiologistas enquanto *experts* da análise de imagens.

Assim, a presente revisão tem como objetivo investigar a literatura relacionada à aplicação da Inteligência Artificial na análise de exames de imagem nas diversas especialidades odontológicas, seu desempenho nesta tarefa, possibilidades de aplicação na prática clínica, bem como suas vantagens e limitações.

## REVISÃO DE LITERATURA

Elaborou-se uma revisão de literatura de acordo com os artigos encontrados na base de dados PubMed. Realizou-se uma busca através do PubMed Advanced Search Builder com a combinação dos descritores indexados (MeSh Terms) e dos operadores booleanos “OR” e “AND”: *machine learning; artificial intelligence; computer neural networks; deep learning; dental digital radiography; cone beam computed tomography; cephalometrics; diagnostic imaging; panoramic radiograph; orthodontics; dental caries; periapical diseases; cephalometry; dentistry; periodontitis; odontogenic cysts; odontogenic tumors; temporomandibular joint; maxillary sinus; alveolar bone loss; dental implants*.

Foram aplicados os seguintes filtros de busca e critérios de inclusão: estudos publicados em língua inglesa, em humanos adultos, com data de publicação entre

2018 e 2021, que utilizassem, em sua metodologia, exames de imagem com radiação ionizante, como tomografia computadorizada, radiografias panorâmicas, periapicais e interproximais do complexo dentomaxilofacial, submetidos à análise diagnóstica por modelos baseados em algoritmos de inteligência artificial.

## RESULTADOS

Foram encontrados 486 artigos e, após a leitura seletiva de títulos, foram excluídos 357 artigos, pois não atendiam aos critérios de inclusão. Em seguida, procedeu-se à leitura dos resumos de 129 artigos selecionados. Destes, 70 artigos foram submetidos à leitura interpretativa e incluídos no estudo. Deste total, 07 artigos tratavam de revisões sistemáticas e seus resultados foram considerados na introdução e discussão do presente trabalho. Os restantes 63 artigos, por apresentarem trabalhos experimentais originais que testaram o desempenho de modelos de IA em tarefas de identificação e classificação de estruturas e patologias em imagens radiográficas, foram utilizados para composição de tabela contendo informações quanto à aplicabilidade do modelo de IA, a modalidade de imagem utilizada, a arquitetura do algoritmo, o número de imagens utilizadas no estudo, o referencial comparativo e o desempenho diagnóstico dos modelos (Tabela 1).

A maioria dos trabalhos avaliou a acurácia diagnóstica de modelos de CNN para lesões de cárie, detecção de lesões periapicais, análise morfológica radicular de molares, identificação de sistemas de implantes, avaliação de perda óssea periodontal, localização de pontos cefalométricos, detecção de cistos e tumores odontogênicos.

Os conjuntos de dados utilizados nos estudos foram muito variáveis em tamanho, desde algumas dezenas de imagens a mais de doze mil imagens. A modalidade de imagem variou conforme a aplicabilidade na área em questão. A modalidade mais utilizada foi a radiografia panorâmica<sup>8,11-36</sup>, seguida de TC<sup>4,37-48</sup>, periapicais<sup>6,49-55</sup>, interproximais<sup>56-60</sup>, radiografias cefalométricas<sup>61-64</sup> e associação de panorâmicas e periapicais<sup>65-67</sup>. Um estudo não especificou a modalidade de imagem<sup>68</sup>, um estudo utilizou incidência de Waters<sup>69</sup>, e um estudo utilizou panorâmicas e TCFC<sup>70</sup>. A origem das amostras utilizadas foi, de modo geral, bancos de dados e registros médicos de Instituições de Ensino e de clínicas privadas, bem como, no caso de dois estudos<sup>48,52</sup>, um repositório público virtual de imagens ligado à Instituição de ensino.

O referencial comparativo para análise do desempenho dos modelos testados foi, em geral, a análise das imagens feita por especialistas humanos<sup>4,6,8,11,12,14-16,18-20,23,26-28,33-35,37-40,42-47,49,51,54-60,62-66</sup>, comparação com histopatológico<sup>17,30,36,70</sup>, comparação com outros modelos de IA<sup>21,22,24,48,53,61,68</sup> e, em seis trabalhos, não ficou claro ou não houve referencial comparativo<sup>13,29,41,50,52,67</sup>. Um trabalho comparou os resultados com os de outra modalidade de exame de imagem<sup>25</sup>, um utilizou como referência os registros dos prontuários dos pacientes<sup>32</sup>, e um trabalho comparou os resultados com aqueles obtidos da associação de análise histopatológica com análise por especialistas<sup>31</sup>.

O desempenho dos modelos variou entre os estudos conforme a tarefa a ser desempenhada, o tipo de modelo utilizado, o número de camadas das CNN, a quantidade da amostra de treinamento, o referencial comparativo, a modalidade de imagem utilizada, pré-tratamento das imagens e parâmetros de medição utilizados. O desempenho foi considerado superior ao dos especialistas humanos ou teve acurácia diagnóstica superior a 80% em 58,73% dos estudos analisados. Os resultados não foram promissores em 23,80% dos estudos, e em 17,46%, o desempenho dos modelos foi considerado equivalente ao dos especialistas humanos.

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continua)

<b>Autor/ano</b>	<b>Aplicabilidade do modelo</b>	<b>Modalidade de imagem</b>	<b>Arquitetura do algoritmo</b>	<b>Nº de imagens utilizadas</b>	<b>Referencial comparativo</b>	<b>Resultados/desfechos</b>
Ed-Dhahraouy et al. (2018) <sup>37</sup>	Localização de 21 pontos cefalométricos	TCFC	CNN	n=5	Localização manual por dentistas	Erro médio global: 2,32mm; Desvio Padrão de 1,11.
Montúfar et al. (2018) <sup>38</sup>	Localização de 18 pontos cefalométricos	TCFC FoV amplo	Modelo de formatação ativa (ASM)	n=24	Localização manual por especialista	Erro médio global: 3,64mm; desvio padrão de 1,43. 12 dos 18 pontos foram reproduzidos dentro de um desvio padrão de até 1mm.
Montúfar et al. (2018) <sup>39</sup>	Localização de 18 pontos cefalométricos	TCFC FoV amplo	Modelo de formatação ativa	n=24	Localização manual por 2 especialistas	Erro médio: 2,51mm; desvio padrão de 1,6.
Neelapu et al. (2018) <sup>40</sup>	Localização de 20 pontos cefalométricos	TCFC FoV amplo	Algoritmo de combinação de template	n=30	Localização, manual, feita por 3 especialistas	Erro médio global: 1,88mm, desvio padrão de 1,1mm.
Park et al. (2019) <sup>61</sup>	Identificação automática de 80 pontos cefalométricos	Radiografias cefalométricas	CNN	n=283	Modelo YOLOv3 x modelo SSD	O modelo YOLOv3 apresentou acurácia 5% maior na detecção dos pontos cefalométricos do que o modelo SSD.
Chen et al. (2020) <sup>4</sup>	Localização automática de 3 pontos cefalométricos em casos de canino impactado unilateral	TCFC	LINKS - algoritmo tipo ML	Teste n=30 Controle n=30 Treinamento n=30	Segmentação e localização manuais	Localização dos pontos cefalométricos: diferença mínima entre os grupos de 2 voxels no plano sagital mediano.
Yun et al. (2020) <sup>44</sup>	Localização automática de 93 pontos cefalométricos baseada em ML	TC multislice	CNN com autoencoder variacional (VAE)	n=255	Marcações realizadas por 1 dentista com experiência de 20 anos em TC 3D	Erro médio global: 3,63 mm.

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continuação)

<b>Autor/ano</b>	<b>Aplicabilidade do modelo</b>	<b>Modalidade de imagem</b>	<b>Arquitetura do algoritmo</b>	<b>Nº de imagens utilizadas</b>	<b>Referencial comparativo</b>	<b>Resultados/desfechos</b>
Kunz et al. (2020) <sup>62</sup>	Localização totalmente automatizada de 18 pontos cefalométricos	Radiografias cefalométricas digitais (2D)	CNN de código aberto (Keras & Google Tensorflow)	n=50	Valores médios de localização de cada ponto por 12 especialistas e pós-graduandos em ortodontia	Diferença de 0,37° para parâmetros angulares; <0,2mm para parâmetros lineares; <0,25% para parâmetros de proporção facial.
Hwang et al. (2020) <sup>63</sup>	Detecção automática de 80 pontos cefalométricos	Radiografias cefalométricas	CNN (YOLOv3)	n=283	Examinadores humanos	Erro de detecção menor do que 0.9mm.
Kim et al. (2021) <sup>47</sup>	Detecção automática de pontos cefalométricos	TCFC-PA	CNN	N=430	Identificação manual por dentista	Acurácia média de 2.23 ± 2.02mm; taxa de sucesso de detecção de 60.88% para erros menores ou iguais a 2mm.
Kim et al. (2021) <sup>64</sup>	Detecção automática de pontos cefalométricos	Radiografias cefalométricas	CNN	N=100	Identificação dos pontos por dois ortodontistas usando software	Erro médio de detecção do modelo foi de 1.36 ± 0.98mm.
Lee et al. (2018) <sup>6</sup>	Diagnóstico de cárie	Radiografias periapicais	CNN	n=600	Quatro dentistas experientes	Acurácia de 82%, sensibilidade de 81% e especificidade de 83%.
Patil et al. (2019) <sup>68</sup>	Uso de rede neural adaptiva para detecção de cárie	Não especificado	Modelo MPCA-ADA	n=120	Outros três algoritmos classificadores convencionais	Acurácia até 81% melhor; sensibilidade até 90% melhor; especificidade até 87% melhor que o referencial comparativo.
Geetha et al. (2020) <sup>53</sup>	Detecção de lesões de cárie usando uma rede neural de retro propagação	Radiografias periapicais	BPNN (Back Propagation Neural Network)	n=105	Outros classificadores para diagnóstico de cárie dental	Acurácia de 97% sobre outros métodos de IA, como SVM, KNN, Random forest.
Cantu et al. (2020) <sup>56</sup>	Detecção de lesões de cárie de diferentes extensões	Radiografias interproximais	CNN (U-Net)	n= 141	Análise das radiografias por quatro dentistas experientes	Acurácia: 0.80 CNN e 0.71 dentistas; sensibilidade 0.75 CNN e 0.36 dentistas; especificidade 0.83 CNN e 0.91 dentistas

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continuação)

<b>Autor/ano</b>	<b>Aplicabilidade do modelo</b>	<b>Modalidade de imagem</b>	<b>Arquitetura do algoritmo</b>	<b>Nº de imagens utilizadas</b>	<b>Referecial comparativo</b>	<b>Resultados/desfechos</b>
Lian et al. (2021) <sup>33</sup>	Detecção de cáries e classificação quanto à extensão	Radiografias panorâmicas	CNN (U-Net) (detecção) DenseNet121 (extensão)	n=1.160	6 dentistas	CNNs mostraram acurácia de 0.986 e recall de 0.821 para diagnóstico de cárie e acurácia entre 0.957 e 0.832 para classificação quanto à profundidade da lesão.
Lee et al. (2021) <sup>57</sup>	Detecção de cárie inicial	Radiografias interproximais	CNN (U-Net)	n=354	3 dentistas clínicos	O modelo mostrou precisão de 63,29%, recall de 65,02%, índice F1 de 64,14%.
Mao et al. (2021) <sup>58</sup>	Detecção de cáries e restaurações	Radiografias interproximais	CNN	n=278	3 dentistas clínicos	Acurácia de 95,56% para detecção de restaurações e de 90,30% para diagnóstico de cáries.
Mertens et al. (2021) <sup>59</sup>	Detecção de cáries	Radiografias interproximais	CNN	n=140	22 dentistas, com e sem o uso de IA	Dentistas com IA mostraram AUC e sensibilidade significativamente maiores (0.89 e 0.81) do que dentistas sem IA (0.85 e 0.72); especificidade não foi afetada.
Lee et al. (2018) <sup>49</sup>	Diagnóstico e predição de dentes comprometidos periodontalmente	Radiografias periapicais	CNN	n=348	Diagnóstico e predição por 3 periodontistas	Acurácia do CNN no diagnóstico: para pré-molares 81% e para molares 76,7%. Acurácia de predição de exodontia em dentes clinicamente diagnosticados com doença periodontal severa: 82,8% para pré-molares e 73,4% para molares.
Kim et al. (2019) <sup>15</sup>	Diagnóstico automático de perda óssea periodontal	Radiografias panorâmicas	CNN	n=800	Diagnóstico por 5 dentistas clínicos experientes	Desempenho do modelo: F1 de 0.75, AUC de 0.95, sensibilidade de 0.77, especificidade de 0.95, PPV de 0.73 e NPV de 0.96.
Krois et al. (2019) <sup>16</sup>	Diagnóstico de perda óssea periodontal	Radiografias panorâmicas	CNN	n=2.001	Diagnóstico por 6 dentistas clínicos experientes	Desempenho do modelo: acurácia 81%, sensibilidade de 0.81, e especificidade de 0.81.

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continuação)

<b>Autor/ano</b>	<b>Aplicabilidade do modelo</b>	<b>Modalidade de imagem</b>	<b>Arquitetura do algoritmo</b>	<b>Nº de imagens utilizadas</b>	<b>Referencial comparativo</b>	<b>Resultados/desfechos</b>
Chang et al. (2020) <sup>27</sup>	Diagnóstico e estagiamento automáticos de doença periodontal	Radiografias panorâmicas	Aprendizado profundo híbrido	n=52	Diagnóstico e estagiamento de perda óssea por 3 radiologistas	Acurácia diagnóstica para o modelo: 0.93 em relação à perda óssea periodontal, 0.91 em relação à junção cimento-esmalte e 0.91 para o dente analisado. PCC global de 0.73, e ICC global de 0.91.
Thanathornwong e Suebnukarn (2020) <sup>28</sup>	Identificação automática de dentes comprometidos periodontalmente	Radiografias panorâmicas	Faster R-CNN	n=100 (conjunto total de imagens antes do aumento)	Diagnóstico por 3 periodontistas experientes	Índice médio de precisão de 0.81, índice de revocação médio (recall) de 0.80, sensibilidade de 0.84, especificidade de 0.88 e índice F-1 de 0.81.
Danks et al. (2021) <sup>54</sup>	Estimativa automática da perda óssea periodontal	Radiografias periapicais	CNN	n=360	Avaliação das imagens por dentistas clínicos	Índice PCK médio global do sistema foi de 83,3%
Poedjiastoeti e Suebnukarn (2018) <sup>11</sup>	Identificação de ameloblastomas e ceratocistos odontogênicos em mandíbula	Radiografias panorâmicas	CNN	n=500	Diagnóstico das lesões por 5 especialistas bucomaxilofaciais	CNN - sensibilidade de 81,8%, especificidade de 83,3%, acurácia de 83%.
Ariji et al. (2019) <sup>17</sup>	Identificação automática de 5 tipos de lesões radiolúcidas em mandíbula	Radiografias panorâmicas	CNN	n=285	Diagnóstico das lesões por exame histopatológico	Acurácia de detecção de 88%. Acurácia de classificação: variou de 13%, para ceratocisto odontogênico e 82%, para cisto dentígero.
Kwon et al. (2020) <sup>30</sup>	Diagnóstico automático de cistos e tumores odontogênicos de mandíbula e maxila	Radiografias panorâmicas	CNN (modificado do YOLOv3)	n=1.282	Diagnóstico das lesões por exame histopatológico	O desempenho global do modelo revelou acurácia de 95,6% para o diagnóstico de doença. O melhor desempenho diagnóstico foi para cistos dentígeros, com acurácia de 97,8%. A detecção de normalidade teve acurácia de 96%.

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continuação)

Autor/ano	Aplicabilidade do modelo	Modalidade de imagem	Arquitetura do algoritmo	Nº de imagens utilizadas	Referencial comparativo	Resultados/desfechos
Yang et al. (2020) <sup>31</sup>	Diagnóstico automático de cistos e tumores odontogênicos em mandíbula e maxila	Radiografias panorâmicas	CNN (YOLOv2)	n=1.603	Exame histopatológico Diagnóstico por cirurgiões e clínicos gerais	A acurácia diagnóstica do modelo foi de 66%, enquanto a dos especialistas variou de 64% a 66% e a dos clínicos gerais ficou entre 58% e 60%.
Lee et al. (2020) <sup>70</sup>	Diagnóstico de 3 tipos de lesões císticas (ceratocisto odontogênico, cisto dentífero e cisto periapical)	Radiografias panorâmicas e TCFC	CNN	n=2.126 (1.140 panorâmicas e 986 TCFC)	Diagnóstico das lesões por exame histopatológico	Ao utilizar imagens panorâmicas, a precisão diagnóstica total foi de 84,6%; a precisão diagnóstica foi maior para cistos periapicais (87,0%) e menor para ceratocistos (81,8%). Para as TCFC, a acurácia total de diagnósticos foi de 91,4%; a precisão diagnóstica foi maior para cistos periapicais (93,7%) e menor para ceratocistos (87,2%).
Liu et al. (2021) <sup>36</sup>	Diagnóstico diferencial de ameloblastoma e ceratocisto odontogênico	Radiografias panorâmicas	CNN	n=420	Análise histopatológica	Precisão de 90,36%, sensibilidade e especificidade de 92,88% e 87,80%, respectivamente.
Zhang et al. (2018) <sup>50</sup>	Detecção e numeração dentária	Radiografias periapicais	CNN em cascata	n=200	-	Precisão de 95,8%, e recall de 96,1%
Tuzoff et al. (2019) <sup>13</sup>	Detecção e numeração dentária	Radiografias panorâmicas	CNN	n=222	-	Precisão e sensibilidade para detecção de 99%, e de 99% e 98% para numeração, respectivamente.
Chen et al. (2019) <sup>51</sup>	Detecção e numeração dentária	Radiografias periapicais	Faster R-CNN	n=250	Detecção e numeração por 3 dentistas	Precisão e recall de 98% para detecção e de 91% para numeração
Kwada et al. (2020) <sup>21</sup>	Detecção e numeração de elementos dentários	Radiografias panorâmicas	AlexNet VGG-16 Detect-Net	n=550	Comparação entre os 3 sistemas	O recall, a precisão e o índice F1 foram todos 1.0, indicando detecção perfeita.

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continuação)

<b>Autor/ano</b>	<b>Aplicabilidade do modelo</b>	<b>Modalidade de imagem</b>	<b>Arquitetura do algoritmo</b>	<b>Nº de imagens utilizadas</b>	<b>Referencial comparativo</b>	<b>Resultados/desfechos</b>
Yüksel et al. (2021) <sup>34</sup>	Enumeração dentária e detecção de múltiplos tratamentos	Radiografias panorâmicas	CNN	n=1.005	Análise por dentistas clínicos	Precisão média para enumeração dentária de 89,4%, e para identificação de tratamento, de 59%.
Bilgir et al. (2021) <sup>35</sup>	Detecção e enumeração dentária	Radiografias panorâmicas	CNN	n=2.482	Análise por 3 dentistas radiologistas	Sensibilidade do modelo foi de 95,59%, precisão de 96,52% e medida F foi de 96,06%.
Yasa et al. (2021) <sup>60</sup>	Detecção e enumeração dentária	Radiografias interproximais	R-CNN	n=1.125	Análise por um radiologista, com uso de software	Índice F1 foi de 95,15%, precisão foi de 92,93% e sensibilidade foi de 97,48%.
Kats et al. (2019) <sup>12</sup>	Detecção de placas ateroscleróticas carotídeas	Radiografias panorâmicas	Faster R-CNN	-	Detecção por 2 radiologistas	Sensibilidade de 75%, especificidade de 80% e acurácia de 83%.
Ekert et al. (2019) <sup>14</sup>	Detecção automática de lesões apicais	Radiografias panorâmicas	CNN	n=2.001	Detecção por 6 examinadores experientes independentes	Quando concordância geral entre examinadores foi de 54,6%: a AUC da CNN foi de 0.85, especificidade de 0.87 e sensibilidade de 0.65. Quando 100% de concordância inter examinadores: AUC de 0.95, sensibilidade de 0.74 e especificidade de 0.94.
Endres et al. (2020) <sup>26</sup>	Detecção automática de lesões radiolúcidas periapicais	Radiografias panorâmicas	CNN	n=102	Detecção das lesões por 24 cirurgiões bucomaxilofaciais	Escore F1 do modelo: 0.58; PPV=0.67; TPR=0.51. Cirurgiões: PPV=0.69; TPR=0.51.
Orhan et al. (2020) <sup>45</sup>	Detecção automática de lesões apicais (com medição de volume)	TCFC	CNN (Diagnocat)	n=153	Média dos valores de localização, manual, feita por 3 especialistas	Índice de acurácia do sistema testado: 92,8% (detectou 142 de um total de 153 lesões). TPR=0.89; PPV=0.95; F1=0.93. Medição de volume das lesões: equivalente à medição manual.

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continuação)

Autor/ano	Aplicabilidade do modelo	Modalidade de imagem	Arquitetura do algoritmo	Nº de imagens utilizadas	Referencial comparativo	Resultados/desfechos
Setzer et al. (2020) <sup>46</sup>	Segmentação de imagens e detecção automáticas de lesões apicais	TCFC (FoV restrito)	CNN (U-Net)	n=20 imagens com 61 raízes	Segmentação e análise das imagens por 3 dentistas	Resultados: sensibilidade=0.93; especificidade=0.88, PPV= 0.87.
Li et al. (2021) <sup>55</sup>	Detecção de lesões apicais	Radiografias periapicais	CNN	n=460	3 dentistas clínicos e comparação com outros estudos	Acurácia do modelo foi de 92,5%; sensibilidade de 94,87%; especificidade de 90,00%; precisão de 92,50% e recall de 94,87%.
Hiraiwa et al. (2019) <sup>8</sup>	Avaliação da morfologia radicular do 1º molar inferior	Radiografias panorâmicas	CNN (AlexNet x GoogleNet)	n=760	Detecção da raiz distal extra por dois radiologistas	Presença de raiz D extra em 21,4% dos dentes. Acurácia do AlexNet: 87,4%. Acurácia do GoogleNet: 85,3%. Acurácia dos radiologistas:81,2%.
Sherwood et al. (2021) <sup>48</sup>	Segmentação e classificação da morfologia de canais em C de segundos molares inferiores	TCFC	CNN (U-Net, residual U-Net e Xception U-Net)	n=135	Comparação entre os três modelos de CNN	Os coeficientes médios de dados foram de 0,768 ± 0,0349 para Xception U-Net, 0,736 ± 0,0297 para U-Net residual e 0,660 ± 0,0354 para U-Net. Os valores médios de sensibilidade foram de 0,786 ± 0,0378 para Xception U-Net, 0,746 ± 0,0391 para U-Net residual e 0,720 ± 0,0495 para U-Net. Os valores preditivos positivos médios foram de 77,6% ± 0,1998% para a U-Net, 78,2% ± 0,1971% para a U-Net residual e 80,0% ± 0,1098% para a Xception U-Net.
Lee et al. (2019) <sup>18</sup>	Detecção de osteoporose	Radiografias panorâmicas	CNN	n=200	Diagnóstico feito por radiologistas experientes	Desempenho do modelo: valores acurácia variaram de 92,5% a 98,5%

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continuação)

<b>Autor/ano</b>	<b>Aplicabilidade do modelo</b>	<b>Modalidade de imagem</b>	<b>Arquitetura do algoritmo</b>	<b>Nº de imagens utilizadas</b>	<b>Referencial comparativo</b>	<b>Resultados/desfechos</b>
Lee et al. (2020) <sup>24</sup>	Detecção de osteoporose	Radiografias panorâmicas	CNN3 VGG-16 VGG-16 TF VGG-16 TF FT	n=136	Comparação entre os 4 modelos entre si	Acurácia diagnóstica entre 66% e 84%.
Nakamoto et al. (2020) <sup>25</sup>	Detecção de osteoporose	Radiografias panorâmicas	Computer-aided diagnosis (CAD) system	n=40	Comparação com exame de densidade óssea lombar	Desempenho diagnóstico: sensibilidade 90,9%, especificidade 64,7%, acurácia 75%.
Murata et al. (2019) <sup>19</sup>	Diagnóstico de sinusite maxilar	Radiografias panorâmicas	AlexNet CNN	n=120	Diagnóstico por 4 profissionais; tomografias de feixe cônico dos seios paranasais	Acurácia de 87,5%, sensibilidade de 86,7%, especificidade de 88,3%, AUC de 0.875.
Kim et al. (2019) <sup>69</sup>	Diagnóstico de sinusite maxilar	Radiografia Waters	CNN	n=200	Diagnóstico feito por 5 radiologistas experientes; tomografias de feixe cônico dos seios paranasais	O algoritmo mostrou AUC significativamente maior (0.93) do que o radiologista. Em termos de sensibilidade e especificidade, o algoritmo foi comparável aos radiologistas.
Vinayahalingam et al. (2019) <sup>20</sup>	Detecção automática de terceiros molares e canal mandibular	Radiografias panorâmicas	CNN (U-Net)	n=81	Segmentação manual em panorâmicas	Média do Coeficiente DICE para detecção de terceiros molares foi de 93,6% e do canal mandibular, de 80,5%. Média dos índices de sensibilidade para terceiros molares foi de 94,7% e para canal mandibular, de 84,7%. Média dos índices de especificidade para terceiros molares foi de 99,9% e para canal mandibular foi de 96,7%.

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(continuação)

Autor/ano	Aplicabilidade do modelo	Modalidade de imagem	Arquitetura do algoritmo	Nº de imagens utilizadas	Referencial comparativo	Resultados/desfechos
Fukuda et al. (2020) <sup>22</sup>	Detecção automática de terceiros molares e canal mandibular	Radiografias panorâmicas	AlexNet, GoogLeNet e VGG-16	n=600	Comparação dos 3 sistemas entre si	Os modelos tiveram melhor desempenho nos recortes de imagem menores, com valores de AUC variando de 0.88 a 0.93, enquanto os valores para os recortes maiores variaram de 0.75 a 0.93. O GoogLeNet aplicado aos recortes menores teve o melhor valor da AUC, de 0.93.
Jaskari et al. (2020) <sup>42</sup>	Detecção automática de terceiros molares e canal mandibular	TCFC	CNN	n=637	Segmentação manual por 2 radiologistas	A precisão da previsão do modelo foi da ordem de 0,5 mm para cerca de 90% do comprimento do canal mandibular.
Kwak et al. (2020) <sup>43</sup>	Detecção automática de terceiros molares e canal mandibular	TCFC (imagens 2D e 3D)	2D SegNet 2D U-Net 3D U-Net	-	Segmentação manual por radiologistas	Índices de acurácia entre 0.76 e 0.99, com os maiores índices para imagens 3D.
Fukuda et al. (2020) <sup>23</sup>	Detecção de fratura radicular vertical	Radiografias panorâmicas	CNN	n=60	2 radiologistas e 1 endodontista	Recall de 0.75, precisão de 0.93 e escore F1 (média harmônica entre recall e precisão) de 0.83.
Lee et al. (2020) <sup>41</sup>	Detecção de osteoartrite em ATM	TCFC (cortes sagitais)	SSD (deep-learning)	n=300	-	Acurácia de 0.86, precisão de 0.85, recall de 0.84 e escore F1 de 0.84.
Sukegawa et al. (2020) <sup>29</sup>	Classificação automática de 11 sistemas de implantes	Radiografias panorâmicas	5 modelos DCNN	n=8.859	Não há	Desempenho dos modelos: todos apresentaram acurácia diagnóstica entre 0.860 e 0.935, mostrando-se altamente eficazes na identificação de 11 sistemas de implantes em panorâmicas.
Kim et al. (2020) <sup>52</sup>	Identificação automática de 4 sistemas de fixação de implante	Radiografias periapicais	CNN (teste de 5 modelos)	n=801	Não há	Todos os 5 modelos mostraram acurácia acima de 90%.

Tabela 1 – Desempenho dos modelos baseados em IA na análise de imagens nas diversas especialidades odontológicas

(conclusão)

<b>Autor/ano</b>	<b>Aplicabilidade do modelo</b>	<b>Modalidade de imagem</b>	<b>Arquitetura do algoritmo</b>	<b>Nº de imagens utilizadas</b>	<b>Referencial comparativo</b>	<b>Resultados/desfechos</b>
Lee e Jeong (2020) <sup>65</sup>	Identificação automática de 3 sistemas de implante semelhantes	Radiografias panorâmicas e periapicais	CNN (GoogLeNet Inception-v3)	n=10.770 (5.390 panorâmicas e 5.380 periapicais)	Identificação dos 3 sistemas de implante por 1 periodontista	Desempenho do modelo: AUC=0,971; sensibilidade de 95.3 e especificidade de 97.6. Desempenho do especialista: AUC=0,925; sensibilidade de 88.7 e especificidade de 87.1.
Lee et al. (2020) <sup>66</sup>	Identificação automática de 6 sistemas de implante	Radiografias panorâmicas e periapicais	DCNN automatizado	n=11.980	Diagnóstico por 25 dentistas clínicos	Desempenho do modelo: acurácia de 0.954, sensibilidade de 0.955, e especificidade de 0.853. O tipo de radiografia não foi significativo.
Said et al. (2020) <sup>67</sup>	Identificação automática de 6 modelos de implante	Radiografias panorâmicas e periapicais	CNN	n=1.206	Não há	Desempenho do modelo: acurácia de 93,8%, sensibilidade de 93,5%, especificidade de 94,2%, PPV de 92%, NPV de 91,5%.
Sukegawa et al. (2021) <sup>32</sup>	Identificação de sistemas de implantes e estágio do tratamento	Radiografias panorâmicas	5 modelos CNN: ResNet18, 34, 50, 101 e 152	n=9.767	Registros dos prontuários dos pacientes	Todos os modelos obtiveram acurácia acima de 100 para identificação e classificação. Quanto maior o número de parâmetros e mais profunda a rede neural, maior a acurácia.

## DISCUSSÃO

A maioria dos trabalhos utilizou *Deep Learning*, especialmente redes neurais convolucionais (CNN), como método específico de IA, demonstrando que este método está associado a um campo de pesquisa altamente dinâmico, sendo considerado o mais promissor na Odontologia, especialmente por suas vantagens em relação a outras modalidades de IA. De fato, o método de *Deep Learning* consegue lidar com variações anatômicas pronunciadas, além de apresentar baixa sensibilidade a artefatos na imagem<sup>9</sup>.

Nos trabalhos relacionados à Ortodontia incluídos nesta revisão, observou-se que os esforços foram direcionados para o desenvolvimento de algoritmos que automatizassem a tarefa de localização dos pontos cefalométricos, priorizando-se os exames de imagem tridimensionais (tomografias computadorizadas). Os métodos propostos apresentaram desempenho promissor, sugerindo um possível avanço da cefalometria para uma fase tridimensional, embora, presentemente, ainda não atenda às exigências para aplicação clínica imediata. Para as imagens em duas dimensões, houve acurácia na localização dos pontos e redução de tempo de trabalho, quando comparado ao especialista humano, sugerindo resultados compatíveis com parâmetros para utilização clínica<sup>63,64</sup>.

Na área de Cariologia, a utilização dos modelos de IA na análise de radiografias para detecção de lesões de cárie pode ser considerada promissora, com precisão e eficiência consideráveis, refletidos nos índices de acurácia de 80%, aproximadamente. O estudo de Geetha et al.<sup>53</sup> obteve o mais alto índice de acurácia na detecção de lesões de cárie, sobressaindo em relação aos demais. Ressalta-se, no entanto, que a rede neural utilizada continha apenas uma camada, e a amostragem foi a menor entre os trabalhos. Apenas um estudo comparou os resultados do modelo de IA com diagnósticos realizados por especialistas<sup>59</sup>. Esta seria a situação que melhor refletiria o valor da aplicabilidade clínica do modelo pois, para o profissional da clínica odontológica, o modelo de IA deveria ser transformado em um *software* cujo desempenho fosse superior ao seu em tempo de processamento e confiabilidade dos resultados. Este também foi o único trabalho a diferenciar a profundidade das lesões de cárie detectadas, verificando que a rede neural testada mostrou sensibilidade acima de 70% para lesões iniciais e avançadas, e que os dentistas em grande parte apresentaram baixa sensibilidade para lesões iniciais: todos, exceto um, mostraram

sensibilidade abaixo de 25%. Os autores consideram que, no caso do diagnóstico de lesões iniciais, provavelmente os dentistas foram mais prudentes em identificar alterações de imagem como lesões iniciais de cárie, temendo falsos positivos e sobretratamento, enquanto a CNN não mostrou tal comportamento.

Na Endodontia, os estudos<sup>14,26,45,46,55</sup> tiveram como foco principal a detecção de lesões radiolúcidas periapicais pelos modelos de IA, sendo que apenas dois dos sete trabalhos incluídos direcionaram-se de forma diferente, testando a utilização da IA para analisar a morfologia radicular dentária<sup>8,48</sup>. O desempenho das redes neurais foi semelhante ao dos especialistas nestas tarefas, com melhores precisão e acurácia, podendo ser de grande ajuda como uma segunda opinião especializada para o clínico menos experiente ou não-especialista.

Na área de Periodontia, os seis estudos revisados<sup>15,16,27,28,49,54</sup> tiveram como objeto avaliar o desempenho de CNNs na detecção automática de dentes com comprometimento periodontal, visando reduzir o esforço do profissional e prover uma “segunda opinião” acerca do diagnóstico. Apesar do bom desempenho geral dos modelos, com acurácia acima de 75%, pode-se considerar muito difícil fazer um diagnóstico completo e previsão de doença periodontal usando apenas imagens radiográficas, devendo-se levar em conta o histórico do paciente e dados clínicos, como profundidade de sondagem, nível de inserção, sangramento à sondagem, mobilidade, percussão e teste pulpar. Portanto, o modelo de IA por si só não parece capaz de fornecer evidências suficientes, embora ainda possa ser usado como referência para o diagnóstico e previsão de doença.

Os estudos da área de Implantodontia<sup>29,32,52,65-67</sup>, com foco na identificação de sistemas de implantes em radiografias, tarefa especialmente importante em situações de manutenção do trabalho realizado e em que não se dispõe de registros do paciente, mostraram que os sistemas analisados têm potencial para ajudar profissionais e pacientes a evitar tratamentos e despesas desnecessários, resultantes do desconhecimento do tipo exato de implante utilizado. Os modelos foram capazes de identificar com precisão as características discriminatórias de cada tipo de implante, mesmo entre sistemas de configuração semelhante, com resultados similares tanto em panorâmicas quanto em periapicais.

Quanto à detecção de cistos e de tumores odontogênicos<sup>11,17,30,31,36,70</sup>, parece haver um consenso, nos trabalhos analisados, de que a aplicação das redes neurais

para o diagnóstico das lesões poderia representar um suporte na prática clínica, no sentido de formular uma “segunda opinião” ou mesmo de reconfirmar a detecção e classificação dos cistos e tumores odontogênicos. A velocidade de detecção das lesões representaria uma vantagem considerável, mesmo que o desempenho diagnóstico tenha se mostrado similar ao dos humanos. Tanto as redes neurais quanto os especialistas apresentaram altas taxas de precisão na classificação de lesões maxilofaciais radiolúcidas em comparação com a biópsia histopatológica. No entanto, observou-se uma heterogeneidade metodológica moderada entre os estudos, o que dificultaria uma transposição pragmática do uso das redes na clínica.

A aplicação de redes neurais convolucionais também foi encontrada em três trabalhos que avaliaram a acurácia diagnóstica de modelos na detecção de osteoporose em panorâmicas<sup>18,24,25</sup>, através da análise de alterações na textura e características morfológicas do tecido ósseo. Os resultados promissores sugerem que a avaliação baseada em aprendizagem profunda das imagens de panorâmicas pode ser útil e confiável na triagem automatizada de pacientes com osteoporose.

Outra aplicação clínica encontrada para as redes neurais foi como auxiliar no diagnóstico de sinusite maxilar<sup>19,69</sup>. Ambos os estudos, com metodologias semelhantes, mostraram redes neurais com desempenho comparável ao dos radiologistas, com habilidade diagnóstica suficientemente alta para prover apoio diagnóstico na clínica, especialmente para profissionais inexperientes.

O emprego das redes neurais convolucionais também se estendeu à tarefa de identificação e numeração de elementos dentários em radiografias<sup>13,21,34,35,50,51,60</sup>. Os trabalhos analisados buscaram validar o uso de redes neurais com o intuito de agilizar o processo de numeração dentária na prática clínica, ao mesmo tempo em que poderiam fornecer resultados confiáveis que serviriam como confirmação do diagnóstico ou da análise realizada pelo profissional. Nesse sentido, um dos estudos<sup>34</sup> mostrou resultados de desempenho do modelo compatíveis com potencial para futura utilização na rotina clínica. Ressalta-se que nenhum trabalho analisou dentição mista, condição que pode ser frequente na clínica e que representaria maior desafio aos modelos testados.

Alguns estudos focaram na detecção automática de terceiros molares e canal mandibular<sup>20,22,42,43</sup>, com o objetivo de facilitar a avaliação do risco de dano ao nervo alveolar inferior quando da remoção dos terceiros molares e proporcionar maior

segurança quando da fixação de implantes. Esses estudos, de caráter preliminar, mostraram que as redes parecem ter potencial para classificar corretamente a relação entre o terceiro molar inferior e o canal mandibular, encorajando novos experimentos e novas oportunidades de aplicar com sucesso o aprendizado profundo na rotina clínica.

Outras aplicabilidades das redes neurais convolucionais testadas foram na detecção de placas ateroscleróticas nas carótidas em radiografias panorâmicas, com o intuito de auxiliar na prevenção de acidente vascular cerebral<sup>12</sup>; na detecção de fratura radicular vertical<sup>23</sup>, e na detecção de osteoartrite em articulação temporomandibular<sup>41</sup>. Esses trabalhos mostraram que o desempenho das redes pareceu insuficiente para aplicação na prática clínica, mas com resultados promissores e sugestivos de potencial para futura utilização, necessitando estudos adicionais para aperfeiçoamentos dos modelos.

Um importante ponto a ser levado em conta nas pesquisas com IA diz respeito à aquisição dos conjuntos de dados necessários para treinamento e teste dos modelos. Praticamente todos os estudos relataram quantidade insuficiente de amostras para treinamento, visto a metodologia utilizada para esta fase requerer quantidades enormes de dados, a fim de aumentar a acurácia final do modelo. Os dados em questão, sendo imagens radiográficas, tem sua disponibilidade limitada por questões éticas e legais relativas aos pacientes e às Instituições. A falta de padronização no tratamento e processamento das imagens utilizadas nos diversos estudos provavelmente também teve influência nos resultados obtidos, dificultando a comparação e generalização.

A utilização da IA como auxiliar no diagnóstico por imagem pode trazer, como vantagem importante, maior agilidade na análise das imagens, completando a tarefa muito mais rapidamente do que os especialistas humanos<sup>35,37,40,44,66</sup>. A associação da rapidez com a obtenção de altos índices de acurácia diagnóstica, aspecto esse ainda em fase de amadurecimento, poderia contribuir sobremaneira para a consolidação da utilização da IA na rotina clínica de diagnóstico por imagem, aumentando a produtividade com confiabilidade de resultados.

A existência de limitações nos estudos parece mostrar que, de forma geral, a investigação da aplicabilidade clínica de modelos de IA está em seus primórdios. Apesar disso, mais da metade dos trabalhos analisados mostrou acurácia dos

modelos acima de 80%, e diversos estudos apresentaram sugestões ou possíveis aperfeiçoamentos a serem utilizados em pesquisas futuras, de forma a reduzir o impacto destas limitações nos resultados.

## **CONCLUSÃO**

Observou-se um esforço consistente no desenvolvimento e aperfeiçoamento de sistemas baseados principalmente em aprendizado profundo, método mais adequado para análise de imagens. A avaliação dos modelos de IA no diagnóstico por imagens em Odontologia mostrou, em diversas áreas pesquisadas, resultados promissores, com desempenhos muito semelhantes ou mesmo superiores, muitas vezes, àqueles dos profissionais humanos. Evidencia-se, assim, o potencial para sua utilização como eficientes auxiliares na interpretação de imagens, sobretudo na detecção de lesões de cárie, com índices de acurácia de 80% ou maiores, e na identificação de sistemas de implantes, em que os modelos foram capazes de identificar com precisão as características discriminatórias de cada tipo de implante. A maior agilidade no processo de análise das imagens constitui vantagem importante que, aliada a altos índices de acurácia diagnóstica, pode representar incremento na produtividade com confiabilidade de resultados na prática clínica. Contudo, para a legitimação de sua efetiva utilização como parte do fluxo de trabalho na clínica, um caminho ainda deve ser percorrido, possibilitando a conquista de desempenho com precisão próxima a 100%, e a superação de limitações metodológicas ainda presentes.

## **CONFLICT OF INTEREST**

The authors declare that they have no conflict of interest.

## **REFERÊNCIAS**

1. Tang A, Tam R, Cadrin-Chenevert A, Binge WG, Chong J, Barfett J, et al. Canadian association of radiologists white paper on artificial intelligence in radiology. *Can Assoc Radiol J*. 2018;69:120-35.
2. Park WJ, Park JB. History and application of artificial neural networks in dentistry. *Eur J Dent*. 2018 Oct-Dec;12(4):594-601.
3. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Sci Dent*. 2019 Mar;49(1):1-7.

4. Chen S, Wang L, Li G, Wu TH, Diachina S, Tejera B, et al. Machine learning in orthodontics: introducing a 3D auto-segmentation and auto-landmark finder of CBCT images to assess maxillary constriction in unilateral impacted canine patients. *Angle Orthod.* 2020 Jan;90(1):77-84.
5. Nichols JA, Chan HWH, Baker MAB. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophys Rev.* 2019 Feb;11(1):111-8.
6. Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent.* 2018 Oct;77:106-11.
7. Schwendicke F, Samek W, Krois J. Artificial intelligence in dentistry: chances and challenges. *J Dent Res.* 2020 Jul;99(7):769-74.
8. Hiraiwa T, Arijy Y, Fukuda M, Kise Y, Nakata K, Katsumata A, et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol.* 2019 Mar;48(3):20180218.
9. 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 Jan;49(1):20190107.
10. Leite AF, Vasconcelos KF, Willems H, Jacobs R. Radiomics and machine learning in oral healthcare. *Proteomics Clin Appl.* 2020 May;14(3):e1900040.
11. Poedjiastoeti W, Suebnukarn S. Application of convolutional neural network in the diagnosis of jaw tumors. *Healthc Inform Res.* 2018 Jul;24(3):236-41.
12. Kats L, Vered M, Zlotogorski-Hurvitz A, Harpaz I. Atherosclerotic carotid plaque on panoramic radiographs: neural network detection. *Int J Comput Dent.* 2019;22(2):163-9.
13. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, et al. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol.* 2019 May;48(4):20180051.
14. 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 Jul;45(7):917-22.e5.
15. Kim J, Lee HS, Song IS, Jung KH. DeNTNet: deep neural transfer network for the detection of periodontal bone loss using panoramic dental radiographs. *Sci Rep.* 2019 Nov 26;9(1):17615-22.
16. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep learning for the radiographic detection of periodontal bone loss. *Sci Rep.* 2019 Jun 11;9(1):8495.
17. Arijy Y, Yanashita Y, Kutsuna S, Muramatsu C, Fukuda M, Kise Y, et al. Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2019 Oct;128(4):424-30.
18. Lee JS, Adhikari S, Liu L, Jeong HG, Kim H, Yoon SJ. Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminar study. *Dentomaxillofac Radiol.* 2019 Jan;48(1):20170344.
19. Murata M, Arijy Y, Ohashi Y, Kawai T, Fukuda M, Funakoshi T, et al. Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiol.* 2019 Sep;35(3):301-7.

20. Vinayahalingam S, Xi T, Bergé S, Maal T, de Jong G. Automated detection of third molars and mandibular nerve by deep learning. *Sci Rep.* 2019 Jun 21;9(1):9007.
21. Kuwada C, Arijji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, et al. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020 Oct;130(4):464-9.
22. Fukuda M, Arijji Y, Kise Y, Nozawa M, Kuwada C, Funakoshi T, et al. Comparison of 3 deep learning neural networks for classifying the relationship between the mandibular third molar and the mandibular canal on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020 Sep;130(3):336-43.
23. Fukuda M, Inamoto K, Shibata N, Arijji Y, Yanashita Y, Kutsuna S, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiol.* 2020 Oct;36(4):337-43.
24. Lee KS, Jung SK, Ryu JJ, Shin SW, Choi J. Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs. *J Clin Med.* 2020 Feb 1;9(2):392.
25. Nakamoto T, Hatsuta S, Yagi S, Verdonschot RG, Taguchi A, Kakimoto N. Computer-aided diagnosis system for osteoporosis based on quantitative evaluation of mandibular lower border porosity using panoramic radiographs. *Dentomaxillofac Radiol.* 2020 May 1;49(4):20190481.
26. 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):430.
27. Chang HJ, Lee SJ, Yong TH, Shin NY, Jang BG, Kim JE, et al. Deep learning hybrid method to automatically diagnose periodontal bone loss and stage periodontitis. *Sci Rep.* 2020 May 5;10(1):7531.
28. Thanathornwong B, Suebnukarn S. Automatic detection of periodontal compromised teeth in digital panoramic radiographs using faster regional convolutional neural networks. *Imaging Sci Dent.* 2020 Jun;50(2):169-74.
29. Sukegawa S, Yoshii K, Hara T, Yamashita K, Nakano K, Yamamoto N, et al. Deep neural networks for dental implant system classification. *Biomolecules.* 2020 Jul 1;10(7):984.
30. Kwon O, Yong TH, Kang SR, Kim JE, Huh KH, Heo MS, et al. Automatic diagnosis for cysts and tumors of both jaws on panoramic radiographs using a deep convolutional neural network. *Dentomaxillofac Radiol.* 2020 Dec 1;49(8):20200185.
31. Yang H, Jo E, Kim HJ, Cha IH, Jung YS, Nam W, et al. Deep learning for automated detection of cyst and tumors of the jaw in panoramic radiographs. *J Clin Med.* 2020 Jun 12;9(6):1839.
32. Sukegawa S, Yoshii K, Hara T, Matsuyama T, Yamashita K, Nakano K, et al. Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images. *Biomolecules.* 2021 May;11(6):815.
33. Lian L, Zhu T, Zhu F, Zhu H. Deep learning for caries detection and classification. *Diagnostics (Basel).* 2021 Sep;11(9):1672.
34. Yüksel AE, Gültekin S, Simsar E, Özdemir ŞD, Gündoğar M, Tokgöz SB, et al. Dental enumeration and multiple treatment detection on panoramic X-rays using deep learning. *Sci Rep.* 2021 Jun 11;11(1):12342.

35. Bilgir E, Bayrakdar İŞ, Çelik Ö, Orhan K, Akkoca F, Sağlam H, et al. An artificial intelligence approach to automatic tooth detection and numbering in panoramic radiographs. *BMC Med Imaging*. 2021 Aug;21(1):124.
36. Liu Z, Liu J, Zhou Z, Zhang Q, Wu H, Zhai G, et al. Differential diagnosis of ameloblastoma and odontogenic keratocyst by machine learning of panoramic radiographs. *Int J Comput Assist Radiol Surg*. 2021 Mar;16(3):415-22.
37. Ed-Dhahraouy M, Riri H, Ezzahmouly M, Bourzgui F, El Moutaoukkil A. A new methodology for automatic detection of reference points in 3D cephalometry: a pilot study. *Int Orthod*. 2018 Jun;16(2):328-37.
38. Montúfar J, Romero M, Scougall-Vilchis RJ. Automatic 3-dimensional cephalometric landmarking based on active shape models in related projections. *Am J Orthod Dentofacial Orthop*. 2018 Mar;153(3):449-58.
39. Montúfar J, Romero M, Scougall-Vilchis RJ. Hybrid approach for automatic cephalometric landmark annotation on cone-beam computed tomography volumes. *Am J Orthod Dentofacial Orthop*. 2018 Jul;154(1):140-50.
40. Neelapu BC, Kharbanda OP, Sardana V, Gupta A, Vasamsetti S, Balachandran R, et al. Automatic localization of three-dimensional cephalometric landmarks on CBCT images by extracting symmetry features of the skull. *Dentomaxillofac Radiol*. 2018 Feb;47(2):20170054.
41. Lee KS, Kwak HJ, Oh JM, Jha N, Kim YJ, Kim W, et al. Automated detection of TMJ osteoarthritis based on artificial intelligence. *J Dent Res*. 2020 Nov;99(12):1363-7.
42. Jaskari J, Sahlsten J, Järnstedt J, Mehtonen H, Karhu K, Sundqvist O, et al. Deep learning method for mandibular canal segmentation in dental cone beam computed tomography volumes. *Sci Rep*. 2020 Apr;10(1):5842.
43. Kwak GH, Kwak EJ, Song JM, Park HR, Jung YH, Cho BH, et al. Automatic mandibular canal detection using a deep convolutional neural network. *Sci Rep*. 2020 Mar;10(1):5711.
44. Yun HS, Jang TJ, Lee SM, Lee SH, Seo JK. Learning-based local-to-global landmark annotation for automatic 3D cephalometry. *Phys Med Biol*. 2020 Apr;65(8):085018.
45. 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 May;53(5):680-9.
46. 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.
47. Kim MJ, Liu Y, Oh SH, Ahn HW, Kim SH, Nelson G. Evaluation of a multi-stage convolutional neural network-based fully automated landmark identification system using cone-beam computed tomography-synthesized posteroanterior cephalometric images. *Korean J Orthod*. 2021 Mar;51(2):77-85.
48. Sherwood AA, Sherwood AI, Setzer FC, K SD, Shamili JV, John C, et al. A deep learning approach to segment and classify C-shaped canal morphologies in mandibular second molars using cone-beam computed tomography. *J Endod*. 2021 Dec;47(12):1907-16.
49. Lee JH, Kim DH, Jeong SN, Choi SH. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci*. 2018 Apr;48(2):114-23.

50. Zhang K, Wu J, Chen H, Lyu P. An effective teeth recognition method using label tree with cascade network structure. *Comput Med Imaging Graph.* 2018 Sep;68:61-70.
51. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, et al. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep.* 2019 Mar;9(1):3840.
52. Kim JE, Nam NE, Shim JS, Jung YH, Cho BH, Hwang JJ. Transfer learning via deep neural networks for implant fixture system classification using periapical radiographs. *J Clin Med.* 2020 Apr;9(4):1117.
53. Geetha V, Aprameya KS, Hinduja DM. Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health Inf Sci Syst.* 2020 Jan;8(1):8.
54. Danks RP, Bano S, Orishko A, Tan HJ, Moreno Sancho F, D'Aiuto F, et al. Automating periodontal bone loss measurement via dental landmark localisation. *Int J Comput Assist Radiol Surg.* 2021 Jul;16(7):1189-99.
55. Li CW, Lin SY, Chou HS, Chen TY, Chen YA, Liu SY, et al. Detection of dental apical lesions using CNNs on periapical radiograph. *Sensors (Basel).* 2021 Oct;21(21):7049.
56. Cantu AG, Gehrung S, Krois J, Chaurasia A, Rossi JG, Gaudin R, et al. Detecting caries lesions of different radiographic extension on bitewings using deep learning. *J Dent.* 2020 Sep;100:103425.
57. Lee S, Oh SI, Jo J, Kang S, Shin Y, Park JW. Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep.* 2021 Aug;11(1):16807.
58. Mao YC, Chen TY, Chou HS, Lin SY, Liu SY, Chen YA, et al. Caries and restoration detection using bitewing film based on transfer learning with CNNs. *Sensors (Basel).* 2021 Jul;21(13):4613.
59. Mertens S, Krois J, Cantu AG, Arsiwala LT, Schwendicke F. Artificial intelligence for caries detection: randomized trial. *J Dent.* 2021 Dec;115:103849.
60. Yasa Y, Çelik Ö, Bayrakdar IS, Pekince A, Orhan K, Akarsu S, et al. An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. *Acta Odontol Scand.* 2021 May;79(4):275-81.
61. Park JH, Hwang HW, Moon JH, Yu Y, Kim H, Her SB, et al. Automated identification of cephalometric landmarks: Part 1-Comparisons between the latest deep-learning methods YOLOV3 and SSD. *Angle Orthod.* 2019 Nov;89(6):903-9.
62. Kunz F, Stellzig-Eisenhauer A, Zeman F, Boldt J. Artificial intelligence in orthodontics: evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *J Orofac Orthop.* 2020 Jan;81(1):52-68.
63. Hwang HW, Park JH, Moon JH, Yu Y, Kim H, Her SB, et al. Automated identification of cephalometric landmarks: part 2-might it be better than human? *Angle Orthod.* 2020 Jan;90(1):69-76.
64. Kim J, Kim I, Kim YJ, Kim M, Cho JH, Hong M, et al. Accuracy of automated identification of lateral cephalometric landmarks using cascade convolutional neural networks on lateral cephalograms from nationwide multi-centres. *Orthod Craniofac Res.* 2021 Dec;24 Suppl 2:59-67.
65. Lee JH, Jeong SN. Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs: a pilot study. *Medicine (Baltimore).* 2020 Jun;99(26):e20787.

66. Lee JH, Kim YT, Lee JB, Jeong SN. A performance comparison between automated deep learning and dental professionals in classification of dental implant systems from dental imaging: a multi-center study. *Diagnostics (Basel)*. 2020 Nov;10(11):910.
67. Hadj Saïd M, Le Roux MK, Catherine JH, Lan R. Development of an artificial intelligence model to identify a dental implant from a radiograph. *Int J Oral Maxillofac Implants*. 2020 Nov/Dec;36(6):1077-82.
68. Patil S, Kulkarni V, Bhise A. Algorithmic analysis for dental caries detection using an adaptive neural network architecture. *Heliyon*. 2019 May;5(5):e01579.
69. Kim Y, Lee KJ, Sunwoo L, Choi D, Nam CM, Cho J, et al. Deep learning in diagnosis of maxillary sinusitis using conventional radiography. *Invest Radiol*. 2019 Jan;54(1):7-15.
70. Lee JH, Kim DH, Jeong SN. Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral Dis*. 2020 Jan;26(1):152-8.