doi.org/10.51891/rease.v12i11.32875

APLICAÇÃO DE ALGORITMOS DE DEEP LEARNING NA DETECÇÃO AUTOMÁTICA DE PERDA ÓSSEA PERIODONTAL EM RADIOGRAFIAS PERIAPICAIS E PANORÂMICAS

Alice da Silva Borges Martins[1]
Alice da Silva Alencar[2]
Kheops Renoir de Oliveira[3]

RESUMO: Introdução: A doença periodontal pode provocar perda óssea alveolar e comprometer os tecidos de suporte dos dentes. Radiografias periapicais e panorâmicas auxiliam na avaliação periodontal, mas sua interpretação pode variar conforme as características das imagens e a experiência profissional. Objetivo: Analisar a aplicação de algoritmos de Deep Learning na detecção da perda óssea periodontal em radiografias periapicais e panorâmicas, considerando o desempenho diagnóstico, a aplicabilidade clínica e as limitações descritas na literatura. Metodologia: Foi realizada uma revisão narrativa, de abordagem qualitativa e caráter descritivo, com buscas na base PubMed. Foram utilizados os descritores "periodontitis", "deep learning" e "dental radiography", combinados pelo operador AND. Dos 135 registros inicialmente identificados, 33 foram selecionados para avaliação detalhada e 15 artigos foram incluídos na revisão. Resultados e discussão: Os estudos apontaram potencial para a classificação, detecção e avaliação de alterações relacionadas à perda óssea periodontal. Entretanto, os resultados variaram conforme a modalidade radiográfica, a tarefa diagnóstica e os métodos de avaliação. A heterogeneidade dos dados, o risco de viés e a limitada validação externa restringem a generalização dos modelos. Considerações finais: O Deep Learning apresenta potencial como ferramenta de apoio à interpretação radiográfica periodontal, mas sua aplicação clínica requer validação em diferentes populações e condições de atendimento, sem substituir a avaliação clínica e o julgamento profissional.

Palavras-chave: Periodontite. Aprendizado profundo. Radiografia odontológica.

ABSTRACT: Introduction: Periodontal disease can cause alveolar bone loss and compromise the supporting tissues of the teeth. Periapical and panoramic radiographs support periodontal assessment, but their interpretation may vary according to image characteristics and professional experience. Objective: To analyze the application of Deep Learning algorithms for detecting periodontal bone loss in periapical and panoramic radiographs, considering diagnostic performance, clinical applicability, and limitations reported in the literature. Methodology: A narrative literature review with a qualitative and descriptive approach was conducted using the PubMed database. The descriptors "periodontitis," "deep learning," and "dental radiography" were combined with the Boolean operator AND. Of the 135 records initially identified, 33 were selected for detailed assessment and 15 articles were included in the review. Results and discussion: The studies indicated potential for the classification, detection, and assessment of changes associated with periodontal bone loss. However, results varied according to radiographic modality, diagnostic task, and evaluation methods. Data heterogeneity, risk of bias, and limited external validation restrict the generalizability of the models. Final considerations: Deep Learning shows potential as a support tool for periodontal radiographic interpretation, but clinical use requires validation across different populations and care settings and must not replace clinical assessment or professional judgment.

Keywords: Periodontitis. Deep learning. Dental radiography.

[1]Discente do curso de odontologia no Centro Universitário Maurício de Nassau.
[2]Mestre, docente do curso de odontologia no Centro Universitário Maurício de Nassau.
[3]Orientador. docente do curso de odontologia no Centro Universitário Maurício de Nassau. Mestre.

1 INTRODUÇÃO

A doença periodontal constitui uma condição inflamatória crônica de grande relevância para a saúde bucal, cuja progressão pode provocar destruição dos tecidos de suporte dos dentes e perda óssea alveolar. O diagnóstico e o acompanhamento da doença dependem da integração de informações clínicas e radiográficas, sendo a avaliação do nível ósseo um dos elementos importantes para caracterizar seu comprometimento. Nesse contexto, a Inteligência Artificial (IA) vem sendo investigada como recurso complementar para auxiliar diferentes etapas do diagnóstico e do acompanhamento periodontal (Messina et al., 2026; Jafer et al., 2025).

As radiografias periapicais e panorâmicas apresentam papel relevante na avaliação periodontal. As periapicais permitem a análise mais localizada das estruturas dentoalveolares, enquanto as panorâmicas possibilitam uma visão mais ampla das arcadas. Entretanto, por serem exames bidimensionais, apresentam características próprias de representação e interpretação que precisam ser consideradas na análise da perda óssea periodontal (Khubrani et al., 2025; Turosz et al., 2023).

A interpretação radiográfica pode variar conforme os critérios adotados, a experiência do examinador e as características das imagens. Nesse cenário, o Deep Learning, uma abordagem de aprendizado de máquina baseada em redes neurais com múltiplas camadas, tem sido estudado para reconhecer padrões em imagens odontológicas e apoiar a identificação e classificação de alterações periodontais (Cholan et al., 2023; Patel et al., 2025). Entre as estratégias empregadas estão redes neurais convolucionais (CNNs) e modelos destinados à classificação, segmentação e detecção de estruturas ou regiões de interesse (Chatzopoulos et al., 2025; Hashim et al., 2026).

As evidências disponíveis indicam resultados promissores, mas também demonstram que o desempenho dos modelos varia conforme a finalidade diagnóstica e a modalidade radiográfica. Lee et al. (2025), em meta-análise que comparou classificações binárias e por estadiamento em diferentes modalidades, observaram diferenças de desempenho entre radiografias periapicais e panorâmicas. Tichy et al. (2026), por sua vez, identificaram 29 estudos de Deep Learning para diagnóstico de periodontite por imagens, com predominância das radiografias panorâmicas, além de desempenho inferior em tarefas de estadiamento e avaliação da gravidade quando comparadas a classificações mais simples (Lee et al., 2025; Tichy et al., 2026).

Na avaliação específica da perda óssea em radiografias intraorais, Hashim et al. (2026) reuniram estudos que utilizaram modelos de classificação, segmentação, detecção de objetos, localização de pontos anatômicos e transformers. Os autores observaram acurácias de 0,73 a 0,97 para detecção binária, além de limitações importantes, como o predomínio de bases retrospectivas e a escassez de validação externa. Em radiografias panorâmicas, Almutairi et al. (2026) também identificaram desempenho promissor, mas ressaltaram a heterogeneidade dos conjuntos de dados e dos padrões de referência, além da validação externa limitada.

De forma semelhante, Khubrani et al. (2025) encontraram, em meta-análise de estudos sobre perda óssea periodontal em radiografias bidimensionais, sensibilidade de 87%, especificidade de 76% e acurácia de 84%. Esses resultados não devem ser interpretados como uma medida única da capacidade dos modelos, pois diferenças entre tarefas, bases de dados, padrões de referência e estratégias de validação podem produzir variações importantes no desempenho (Khubrani et al., 2025; Almutairi et al., 2026).

Assim, embora existam evidências sobre o uso de Deep Learning na análise de alterações periodontais, ainda permanecem lacunas relacionadas à generalização dos modelos entre diferentes populações, modalidades radiográficas e tarefas diagnósticas. A predominância de estudos retrospectivos, a heterogeneidade metodológica e a escassez de validação externa dificultam a transposição direta dos resultados de pesquisa para a prática clínica (Tichy et al., 2026; Hashim et al., 2026).

Outro ponto relevante é a necessidade de transparência e interpretabilidade. A explicabilidade da Inteligência Artificial, frequentemente discutida no campo da Explainable Artificial Intelligence (XAI), busca tornar mais compreensíveis os fatores associados às decisões dos modelos. Na Periodontia, essa questão é importante para avaliar a confiabilidade das ferramentas e favorecer sua integração ao processo de decisão profissional (Chatzopoulos et al., 2025; Tichy et al., 2026).

Diante disso, permanece relevante compreender de que maneira os algoritmos de Deep Learning têm sido empregados na detecção automática da perda óssea periodontal em radiografias periapicais e panorâmicas, considerando seu desempenho, aplicabilidade clínica e limitações. Assim, o presente estudo tem como objetivo analisar, por meio de revisão da literatura científica, a aplicação desses algoritmos na detecção da perda óssea periodontal, com ênfase no desempenho diagnóstico, na aplicabilidade clínica e nas principais limitações descritas na literatura (Khubrani et al., 2025; Tichy et al., 2026).

2 O DESENVOLVIMENTO DO ARTIGO CIENTÍFICO

2.1 Inteligência Artificial e Deep Learning na Odontologia

A Inteligência Artificial (IA) tem ampliado sua participação na área da saúde e, consequentemente, na Odontologia, sendo investigada em aplicações relacionadas ao diagnóstico, à análise de imagens, à classificação de doenças e ao suporte à tomada de decisão clínica. Na Periodontia, seu emprego tem sido estudado em diferentes situações, incluindo a identificação de alterações periodontais por meio de exames de imagem e a avaliação de características associadas à doença periodontal (Chatzopoulos et al., 2025; Patel et al., 2025).

Entre as diferentes abordagens de Inteligência Artificial, o aprendizado de máquina (Machine Learning – ML) e, de forma mais específica, o Deep Learning constituem métodos utilizados na investigação das doenças periodontais. O Deep Learning utiliza redes neurais artificiais compostas por múltiplas camadas de processamento, permitindo que os modelos aprendam representações e padrões a partir dos dados empregados durante o treinamento. Essa característica favorece sua utilização em tarefas que envolvem imagens, nas quais os modelos podem reconhecer características relacionadas a alterações anatômicas e patológicas (Cholan et al., 2023; Nadarge; Das, 2026).

No campo da análise de imagens odontológicas, as redes neurais convolucionais (Convolutional Neural Networks – CNNs) ocupam posição de destaque entre as abordagens de Deep Learning. Essas redes são utilizadas para reconhecer padrões visuais e podem ser aplicadas a diferentes tarefas de análise de imagens. Na Periodontia, estudos têm investigado CNNs para identificação e classificação de alterações associadas à doença periodontal e à perda óssea, demonstrando a importância dessas arquiteturas no desenvolvimento de ferramentas de análise automatizada (Cholan et al., 2023; Chatzopoulos et al., 2025).

As arquiteturas empregadas nos estudos apresentam finalidades distintas. Modelos de classificação, como a VGG16, são utilizados para atribuir categorias às imagens ou às regiões analisadas. Já arquiteturas de segmentação, como a U-Net e variantes da Mask R-CNN, permitem delimitar estruturas ou regiões de interesse, enquanto modelos de detecção de objetos, como o YOLO, possibilitam localizar estruturas específicas na imagem. Também foram descritas abordagens baseadas em GoogLeNet/InceptionV3, Cascade R-CNN e transformers. Essa diferenciação é relevante, pois a escolha do modelo está diretamente relacionada ao tipo de

informação que se pretende extrair da radiografia (Chatzopoulos et al., 2025; Hashim et al., 2026).

A aplicação do Deep Learning na Periodontia não se restringe a uma única finalidade diagnóstica. As pesquisas disponíveis abrangem tarefas relacionadas à detecção e classificação da periodontite, avaliação do nível e da perda óssea alveolar, identificação de alterações periodontais e predição de diferentes desfechos clínicos. Tichy et al. (2026) identificaram 29 estudos de Deep Learning voltados ao diagnóstico de periodontite por imagens, além de aplicações baseadas em dados não radiográficos, demonstrando a diversidade de possibilidades de utilização da Inteligência Artificial na área (Tichy et al., 2026).

A análise automatizada de imagens também pode contribuir para diferentes etapas do processo diagnóstico. Nadarge e Das (2026), em revisão sistemática sobre interpretação de imagens odontológicas, identificaram aplicações de Inteligência Artificial na avaliação de perda óssea periodontal, além de outras condições odontológicas. Os autores destacaram que essas ferramentas podem contribuir para a eficiência e a consistência da interpretação radiográfica, mas ressaltaram que a evidência disponível ainda é limitada e heterogênea, sendo necessária validação externa antes de uma utilização clínica mais ampla (Nadarge; Das, 2026).

Além das aplicações radiográficas, a Inteligência Artificial vem sendo investigada como ferramenta de apoio em diferentes etapas do cuidado periodontal. As aplicações descritas incluem avaliação de alterações periodontais, classificação da doença, análise de risco, planejamento terapêutico e acompanhamento do tratamento. Damgaard e

Liedtke (2026) destacam que as tecnologias digitais, incluindo sistemas de reconhecimento de imagens, podem contribuir para o diagnóstico e o prognóstico periodontal, embora sua incorporação clínica ainda dependa de padronização, validação em populações diversas e integração adequada ao fluxo de atendimento (Damgaard; Liedtke, 2026).

Apesar do avanço dessas aplicações, os resultados dos modelos não podem ser considerados uniformes. Diferenças entre conjuntos de dados, tarefas diagnósticas, modalidades radiográficas, padrões de referência e estratégias de validação podem modificar o desempenho observado. Dessa forma, os modelos de Deep Learning devem ser interpretados de acordo com a finalidade para a qual foram desenvolvidos e como ferramentas de apoio à avaliação profissional, e não como substitutos do julgamento clínico do cirurgião-dentista (Tichy et al., 2026; Herz; Bartha, 2026).

2.2 Aplicações do Deep Learning no Diagnóstico Periodontal

A aplicação do Deep Learning no diagnóstico periodontal tem sido investigada principalmente na análise automatizada de imagens e na identificação de padrões relacionados às alterações dos tecidos periodontais. Entre as principais aplicações descritas estão a detecção da periodontite, a classificação da doença, a avaliação da perda óssea alveolar e o desenvolvimento de modelos voltados à predição de diferentes condições periodontais. As CNNs estão entre as abordagens mais utilizadas, especialmente nas aplicações relacionadas à análise de imagens odontológicas (Jafer et al., 2025; Chatzopoulos et al., 2025).

A perda óssea alveolar apresenta importância particular nas aplicações de Deep Learning voltadas à Periodontia, uma vez que sua avaliação radiográfica fornece informações relacionadas ao comprometimento dos tecidos de suporte. Hashim et al. (2026) identificaram estudos que utilizaram modelos para detectar, quantificar, classificar e realizar o estadiamento da perda óssea alveolar em radiografias intraorais. Os trabalhos analisados empregaram diferentes estratégias, demonstrando que a avaliação automatizada pode assumir objetivos distintos conforme a tarefa proposta (Hashim et al., 2026).

Entre as estratégias identificadas estão modelos destinados à classificação, segmentação, detecção de objetos e localização de pontos anatômicos, além de arquiteturas baseadas em transformers. Na classificação, o objetivo é determinar uma categoria para a imagem ou região analisada. Na segmentação, procura-se delimitar estruturas ou regiões de interesse, enquanto a detecção de objetos associa a identificação à localização dessas estruturas. Já a localização de pontos anatômicos pode auxiliar na identificação de referências utilizadas posteriormente para estimar o nível ósseo (Hashim et al., 2026).

A complexidade da tarefa também pode influenciar o desempenho dos modelos. A identificação da presença ou ausência de uma condição periodontal corresponde a uma tarefa diferente da determinação de seu estágio ou gravidade. Lee et al. (2025), ao comparar classificações binárias e por estadiamento em diferentes modalidades radiográficas, observaram diferenças no desempenho conforme a finalidade diagnóstica e o tipo de imagem analisada. Essa diferença demonstra que resultados obtidos em uma tarefa não devem ser automaticamente transferidos para outra (Lee et al., 2025).

A revisão sistemática de Jafer et al. (2025) também demonstra a amplitude das aplicações de Inteligência Artificial na Periodontia. Os estudos analisados envolveram diagnóstico, classificação, graduação e predição de doenças periodontais, incluindo aplicações relacionadas à

avaliação radiográfica do nível e da perda óssea. Os resultados apresentados pelos estudos foram heterogêneos, reforçando a necessidade de considerar o objetivo específico de cada modelo ao interpretar seu desempenho (Jafer et al., 2025).

Além da perda óssea alveolar, a Inteligência Artificial tem sido investigada em outras aplicações periodontais, incluindo a identificação de defeitos infraósseos, envolvimento de furca, cálculo dentário, gengivite e biofilme. Chatzopoulos et al. (2025) descrevem diferentes estratégias de análise de imagens e dados clínicos destinadas a auxiliar a identificação e a avaliação dessas condições, demonstrando que a aplicação da IA na Periodontia ultrapassa a detecção isolada da perda óssea (Chatzopoulos et al., 2025).

As aplicações também podem envolver diferentes fontes de informação além das radiografias. Jafer et al. (2025) identificaram modelos empregados com diferentes tipos de dados e objetivos, incluindo diagnóstico, classificação e predição de doenças periodontais. Tichy et al. (2026), de maneira semelhante, observaram aplicações baseadas tanto em imagens quanto em dados não radiográficos, incluindo estratificação de risco e previsão de diferentes desfechos relacionados à doença periodontal (Jafer et al., 2025; Tichy et al., 2026).

No entanto, a diversidade de aplicações também evidencia uma importante limitação: os resultados não são diretamente comparáveis entre todas as tarefas. Tichy et al. (2026) observaram que modelos utilizados para classificação binária apresentaram desempenho diferente daqueles empregados no estadiamento e na avaliação da gravidade da periodontite. Os autores relacionaram essa dificuldade à diversidade dos dados, à inconsistência entre tarefas e métricas e à escassez de validação externa (Tichy et al., 2026).

No contexto específico da perda óssea periodontal, a avaliação pode envolver não apenas a classificação da presença da alteração, mas também a localização e a mensuração de estruturas anatômicas. Essa característica amplia a complexidade da tarefa e ajuda a explicar a utilização de diferentes arquiteturas e estratégias computacionais nos estudos. Dessa maneira, a finalidade do modelo precisa ser considerada juntamente com o tipo de imagem e o método de avaliação utilizado (Hashim et al., 2026; Herz; Bartha, 2026).

Assim, o Deep Learning apresenta diferentes possibilidades de aplicação no diagnóstico periodontal, desde a classificação de imagens até a segmentação, detecção e localização de estruturas relacionadas à perda óssea. No presente trabalho, destacam- se particularmente as aplicações voltadas às radiografias periapicais e panorâmicas, pois essas modalidades

constituem importantes fontes de informação para a avaliação radiográfica periodontal (Khubrani et al., 2025; Lee et al., 2025).

2.3 Radiografias Periapicais e Panorâmicas na Análise Periodontal

As radiografias periapicais e panorâmicas constituem importantes recursos de imagem para a avaliação das estruturas periodontais e da perda óssea alveolar. Por apresentarem uma representação bidimensional das estruturas anatômicas, essas modalidades possuem características específicas que devem ser consideradas na interpretação das alterações periodontais. A literatura demonstra que ambas podem ser utilizadas em sistemas baseados em Inteligência Artificial, embora existam diferenças relacionadas à qualidade das imagens, à extensão da área analisada e à finalidade diagnóstica (Khubrani et al., 2025; Turosz et al., 2023).

As radiografias periapicais permitem uma avaliação mais localizada das estruturas dentoalveolares, possibilitando a análise de regiões específicas e a identificação de alterações relacionadas ao nível ósseo. Na revisão sistemática de Hashim et al. (2026), foram identificados estudos que empregaram Deep Learning para a avaliação da perda óssea em radiografias intraorais, incluindo modelos destinados à classificação, segmentação, detecção de objetos e localização de pontos anatômicos. Os autores observaram que os modelos apresentaram desempenho variável conforme a tarefa realizada, com melhores resultados para a detecção binária da perda óssea quando comparada a classificações mais complexas (Hashim et al., 2026).

Nas radiografias panorâmicas, a maior extensão da imagem permite a visualização simultânea das arcadas dentárias, tornando essa modalidade particularmente relevante para aplicações de Inteligência Artificial voltadas à análise de alterações periodontais em diferentes regiões. Turosz et al. (2023), ao analisarem revisões sistemáticas sobre aplicações da Inteligência Artificial em radiografias panorâmicas, identificaram resultados relacionados à avaliação da perda óssea periodontal, embora tenham destacado a heterogeneidade dos estudos e a quantidade limitada de evidências específicas para algumas aplicações (Turosz et al., 2023).

A utilização de radiografias panorâmicas também tem avançado para além da simples classificação da presença ou ausência de perda óssea. Brunet-Llobet et al. (2026) discutem o desenvolvimento do mapeamento periodontal radiográfico assistido por Inteligência Artificial, com sistemas capazes de auxiliar na identificação de estruturas anatômicas relevantes, como a junção cemento-esmalte (JCE) e a crista óssea alveolar (COA). A localização automatizada

dessas estruturas permite analisar a distância entre a JCE e a COA, contribuindo para a caracterização radiográfica da perda de suporte periodontal (Brunet-Llobet et al., 2026).

Nesse contexto, Brunet-Llobet et al. (2026) apresentam a Perda de Inserção Radiográfica (PIR) como uma medida obtida a partir da relação entre a junção cemento- esmalte e a crista óssea alveolar. O mapeamento dessas estruturas por meio de Inteligência Artificial pode ampliar a utilização das radiografias panorâmicas em estratégias de triagem, estratificação de risco e acompanhamento longitudinal das alterações periodontais. Entretanto, os autores ressaltam que essa abordagem possui caráter complementar, não substituindo o exame periodontal convencional (Brunet-Llobet et al., 2026).

A comparação entre as modalidades radiográficas demonstra que o desempenho dos modelos pode variar de acordo com o tipo de imagem e a finalidade da análise. Lee et al. (2025), em uma meta-análise que comparou classificações binárias e por estadiamento, observaram diferenças de desempenho entre radiografias periapicais e panorâmicas. Para a classificação binária, as radiografias periapicais apresentaram sensibilidade de 87,2% e especificidade de 81,5%, enquanto as panorâmicas apresentaram acurácia de 88,2%. Nos modelos destinados ao estadiamento, também foram observadas diferenças de desempenho, demonstrando que a complexidade da tarefa influencia os resultados obtidos (Lee et al., 2025).

A heterogeneidade das imagens e dos conjuntos de dados constitui outro fator importante para a interpretação dos resultados. Tichy et al. (2026) observaram que a maioria dos estudos de Deep Learning em Periodontia utilizou radiografias panorâmicas, mas também identificaram limitações relacionadas à diversidade dos dados e à escassez de validação externa. Essas características podem dificultar a generalização dos modelos para diferentes populações, serviços odontológicos e condições de aquisição das imagens (Tichy et al., 2026).

Além disso, os padrões utilizados como referência para determinar a presença ou a extensão da perda óssea podem influenciar diretamente o desempenho dos modelos. Almutairi et al. (2026) verificaram que alguns estudos utilizaram diagnósticos clínicos como referência, enquanto outros recorreram a anotações realizadas por especialistas. Essa diferença pode contribuir para a variação dos resultados encontrados entre os estudos e deve ser considerada na comparação dos modelos de Inteligência Artificial (Almutairi et al., 2026).

Dessa forma, as radiografias periapicais e panorâmicas apresentam aplicações distintas e complementares no desenvolvimento de ferramentas baseadas em Deep Learning para avaliação da perda óssea periodontal. Enquanto as radiografias periapicais permitem análises

mais localizadas das estruturas dentoalveolares, as panorâmicas oferecem uma visão mais abrangente e vêm sendo exploradas para estratégias de mapeamento periodontal assistido por Inteligência Artificial. Entretanto, as diferenças entre modalidades, bases de dados, padrões de referência e tarefas diagnósticas reforçam a necessidade de interpretar os resultados considerando as características específicas de cada estudo (Brunet-Llobet et al., 2026; Hashim et al., 2026).

2.4 Desempenho Diagnóstico e Potencial Clínico da IA

A avaliação do desempenho dos modelos de Inteligência Artificial aplicados ao diagnóstico periodontal pode utilizar diferentes métricas, entre as quais se destacam acurácia, sensibilidade, especificidade e área sob a curva ROC (AUC). Esses indicadores devem ser interpretados de acordo com a tarefa diagnóstica, a modalidade radiográfica, o conjunto de dados e o padrão de referência empregado, pois diferentes condições metodológicas podem produzir resultados distintos (Khubrani et al., 2025; Almutairi et al., 2026).

Na avaliação da perda óssea periodontal em radiografias bidimensionais, Khubrani et al. (2025) encontraram, na meta-análise, sensibilidade de 87%, especificidade de 76% e acurácia de 84%. Entretanto, os autores observaram variação entre os estudos e limitações relacionadas à qualidade metodológica das evidências disponíveis. Dessa forma, os valores agrupados fornecem uma síntese dos estudos analisados, mas não representam necessariamente o desempenho esperado de qualquer modelo aplicado a uma nova população (Khubrani et al., 2025).

Resultados específicos para radiografias panorâmicas também demonstram variação entre os estudos. Almutairi et al. (2026), ao analisarem nove estudos envolvendo mais de 20 mil radiografias, encontraram sensibilidades entre 0,795 e 1,00, especificidades entre 0,784 e 0,99 e valores de AUC entre 0,843 e 0,967. Apesar desses resultados, somente quatro estudos realizaram validação externa, além de terem sido observadas diferenças entre os conjuntos de dados e os padrões de referência utilizados (Almutairi et al., 2026).

A modalidade radiográfica e a finalidade da classificação também estão associadas à variação do desempenho. Na meta-análise de Lee et al. (2025), a classificação binária em radiografias periapicais apresentou sensibilidade de 87,2% e especificidade de 81,5%, enquanto as radiografias panorâmicas apresentaram acurácia de 88,2%. No estadiamento, as radiografias

panorâmicas apresentaram acurácia de 88,9% e especificidade de 85,4%, enquanto as periapicais apresentaram sensibilidade de 76,4% (Lee et al., 2025).

Esses resultados demonstram que não existe uma única medida de desempenho aplicável a todas as situações. Tichy et al. (2026) observaram acurácias de 81% a 99% para classificação binária da periodontite em radiografias panorâmicas, enquanto tarefas relacionadas ao estadiamento e à gravidade apresentaram acurácias de 64% a 91% nessa modalidade. A amplitude observada pode estar relacionada às diferenças entre tarefas, bases de dados, critérios de referência e métodos de avaliação empregados nos estudos (Tichy et al., 2026).

A revisão de Jafer et al. (2025) também identificou ampla variação nos resultados publicados, com acurácia entre 73% e 99,4%, sensibilidade entre 75% e 100% e precisão (precision) entre 56% e 99,5%. Esses valores devem ser interpretados considerando que a revisão reuniu diferentes aplicações de Inteligência Artificial, objetivos diagnósticos, conjuntos de dados e métodos de avaliação, não sendo adequado utilizá-los como se representassem uma única tarefa de detecção de perda óssea periodontal (Jafer et al., 2025).

A diferença entre os resultados pode estar relacionada, portanto, à combinação de fatores metodológicos. A composição da base de dados, o número de imagens, a distribuição das classes, a modalidade radiográfica, a qualidade e a forma de anotação das imagens, a arquitetura utilizada, a tarefa diagnóstica e o padrão de referência podem interferir no desempenho observado. Nadarge e Das (2026) ressaltam que a heterogeneidade dos estudos de interpretação de imagens odontológicas constitui uma limitação para comparações diretas entre os modelos (Nadarge; Das, 2026).

Além das métricas, a qualidade metodológica dos estudos deve ser considerada. Khubrani et al. (2025) observaram diferenças importantes na qualidade dos trabalhos incluídos e destacaram limitações relacionadas à transparência dos métodos e à apresentação dos resultados. Assim, valores elevados de desempenho não são suficientes, isoladamente, para demonstrar que um modelo esteja preparado para utilização clínica ampla (Khubrani et al., 2025).

A generalização representa outra questão central para a possível utilização clínica da Inteligência Artificial. Tichy et al. (2026) apontaram a diversidade limitada dos dados, a inconsistência entre tarefas e métricas e a escassez de validação externa como importantes limitações. Herz e Bartha (2026) acrescentam que a literatura atual é predominantemente retrospectiva e apresenta limitações relacionadas à validação externa, à calibração dos modelos

e à ausência de evidências suficientes sobre seu impacto na tomada de decisão clínica e nos resultados relevantes para os pacientes (Tichy et al., 2026; Herz; Bartha, 2026).

O potencial clínico da Inteligência Artificial, portanto, não deve ser avaliado somente pela capacidade de classificar imagens corretamente. Damgaard e Liedtke (2026) destacam que a utilização de tecnologias digitais na Periodontia também depende de sua integração ao fluxo clínico, da padronização dos métodos e da validação em populações diversas. Dessa forma, um modelo pode apresentar desempenho elevado em uma base de pesquisa e, ainda assim, necessitar de novas avaliações antes de ser incorporado à rotina clínica (Damgaard; Liedtke, 2026).

A Inteligência Artificial também vem sendo estudada como ferramenta de apoio à decisão clínica. Herz e Bartha (2026) ressaltam que, embora os modelos apresentem desempenho diagnóstico promissor, ainda existem poucas evidências de que essas ferramentas melhorem efetivamente a tomada de decisão clínica ou os resultados relacionados aos pacientes. Dessa maneira, o desempenho diagnóstico deve ser considerado uma etapa da avaliação, e não a única evidência necessária para demonstrar utilidade clínica (Herz; Bartha, 2026).

Nesse contexto, as evidências disponíveis indicam que a Inteligência Artificial apresenta potencial para auxiliar a análise radiográfica periodontal, especialmente em tarefas de detecção, classificação e avaliação de alterações ósseas. Entretanto, sua utilização clínica deve ocorrer de forma complementar à avaliação profissional, considerando os achados clínicos, radiográficos e demais informações disponíveis sobre o paciente (Nadarge; Das, 2026; Messina et al., 2026).

2.5 Limitações Atuais e Perspectivas Futuras

Apesar dos avanços observados na aplicação da Inteligência Artificial à Periodontia, a literatura ainda apresenta limitações importantes que dificultam a incorporação ampla dessas tecnologias à prática clínica. Entre os principais problemas estão a heterogeneidade dos conjuntos de dados, as diferenças entre as tarefas diagnósticas, os diferentes padrões de referência e a variação dos métodos empregados para treinamento e avaliação dos modelos (Tichy et al., 2026; Khubrani et al., 2025).

A composição das bases de dados constitui uma questão particularmente relevante. Estudos de Inteligência Artificial em Periodontia ainda são frequentemente desenvolvidos com conjuntos de imagens provenientes de instituições ou centros específicos, o que pode limitar a representação da diversidade encontrada na prática clínica. Tichy et al. (2026) identificaram a diversidade limitada dos dados e a predominância de conjuntos provenientes de centros

individuais como importantes preocupações para a generalização dos modelos (Tichy et al., 2026).

A validação externa representa uma das principais lacunas da literatura atual. Almutairi et al. (2026) identificaram apenas quatro estudos com validação externa entre os trabalhos incluídos em sua revisão sobre radiografias panorâmicas. Da mesma forma, Hashim et al. (2026) encontraram somente dois conjuntos de teste externos entre os estudos voltados à avaliação da perda óssea em radiografias intraorais, além de não identificarem estudos prospectivos. Esses dados demonstram que muitos modelos ainda são avaliados em condições próximas àquelas utilizadas durante seu desenvolvimento (Almutairi et al., 2026; Hashim et al., 2026).

A ausência de padronização também dificulta a comparação dos resultados disponíveis. Os estudos podem utilizar diferentes definições de doença, unidades de análise, métodos de anotação, modalidades radiográficas e métricas de desempenho. Khubrani et al. (2025) destacaram essa heterogeneidade nos estudos sobre perda óssea periodontal e ressaltaram a necessidade de maior qualidade metodológica e transparência na descrição dos métodos (Khubrani et al., 2025).

A escolha do padrão de referência constitui outro aspecto importante. Alguns estudos utilizam anotações realizadas por especialistas em imagens, enquanto outros empregam informações provenientes do diagnóstico periodontal clínico. Almutairi et al. (2026) observaram diferenças de desempenho entre essas estratégias, indicando que a forma de estabelecimento do diagnóstico de referência pode influenciar a avaliação da capacidade diagnóstica dos modelos (Almutairi et al., 2026).

Outra questão relevante está relacionada à interpretabilidade dos modelos. Sistemas de Deep Learning podem apresentar elevada complexidade, dificultando a compreensão direta dos elementos considerados pelo algoritmo para produzir determinada classificação. Nesse contexto, a Explainable Artificial Intelligence (XAI) busca desenvolver métodos capazes de tornar as decisões dos modelos mais compreensíveis, contribuindo para a análise das regiões ou características da imagem que influenciaram determinada previsão (Chatzopoulos et al., 2025; Herz; Bartha, 2026).

A interpretabilidade possui importância particular na área da saúde porque o desempenho estatístico de um modelo não demonstra, por si só, que suas decisões estejam baseadas em características clinicamente relevantes. Na Periodontia, compreender como o algoritmo utiliza as informações presentes nas radiografias pode contribuir para a avaliação de

sua confiabilidade e para uma integração mais transparente ao processo de decisão profissional (Chatzopoulos et al., 2025; Tichy et al., 2026).

A qualidade metodológica das pesquisas também permanece como uma preocupação. Hashim et al. (2026) observaram risco de viés predominantemente alto ou incerto nos estudos sobre perda óssea em radiografias intraorais, além de evidência considerada de muito baixa qualidade. Os autores também identificaram limitações relacionadas à ausência de validação externa e à inexistência de estudos prospectivos, indicando que os resultados atuais ainda devem ser interpretados com cautela (Hashim et al., 2026).

As limitações identificadas não significam ausência de utilidade da Inteligência Artificial na Periodontia. As evidências disponíveis indicam potencial para auxiliar na detecção e classificação das alterações periodontais, especialmente na análise de imagens. Entretanto, Nadarge e Das (2026) ressaltam que a pequena quantidade e a heterogeneidade dos estudos disponíveis exigem novas pesquisas antes de uma implementação clínica ampla (Nadarge; Das, 2026).

Entre as perspectivas futuras, destaca-se a realização de estudos multicêntricos, com conjuntos de dados maiores e mais diversificados, capazes de representar diferentes populações, equipamentos e condições de aquisição das imagens. Tichy et al. (2026) recomendam avaliações multicêntricas, maior transparência na apresentação dos métodos e estudos prospectivos que analisem o impacto da Inteligência Artificial no fluxo de trabalho e nos resultados relacionados aos pacientes (Tichy et al., 2026).

A padronização dos métodos de aquisição, anotação e avaliação das imagens também poderá contribuir para melhorar a comparação entre os estudos. Protocolos mais consistentes e critérios de referência claramente definidos podem favorecer a reprodução dos resultados e permitir avaliações mais adequadas dos diferentes modelos de Deep Learning em condições semelhantes (Khubrani et al., 2025; Damgaard; Liedtke, 2026).

Outra perspectiva está relacionada à integração da Inteligência Artificial ao processo de decisão clínica. Herz e Bartha (2026) destacam que o desenvolvimento de modelos clinicamente úteis deve ultrapassar a demonstração de desempenho diagnóstico e incluir validação externa, avaliação prospectiva e análise de seu impacto sobre a tomada de decisão. Dessa forma, a utilidade clínica deve ser investigada dentro de situações reais de atendimento, e não somente em bases de pesquisa (Herz; Bartha, 2026).

A utilização clínica dessas ferramentas também envolve questões relacionadas à privacidade e à segurança dos dados dos pacientes. O desenvolvimento de modelos de Inteligência Artificial depende de conjuntos de dados adequados para treinamento e avaliação, tornando necessário considerar a forma como essas informações são obtidas, armazenadas e utilizadas. Messina et al. (2026) destacam a privacidade dos dados e as questões éticas como desafios importantes para a integração da Inteligência Artificial à prática periodontal (Messina et al., 2026).

Diante dessas limitações e perspectivas, a Inteligência Artificial pode ser compreendida como uma ferramenta de apoio à avaliação periodontal, especialmente na análise de imagens, sem substituir a integração dos achados clínicos e radiográficos realizada pelo cirurgião-dentista. A consolidação dessas tecnologias dependerá da demonstração de resultados reprodutíveis, da validação em diferentes populações, da transparência dos modelos e de evidências que demonstrem sua utilidade em situações clínicas reais (Almutairi et al., 2026; Herz; Bartha, 2026).

Assim, o desenvolvimento futuro da Inteligência Artificial aplicada à Periodontia dependerá não apenas da criação de modelos com elevado desempenho, mas também da qualidade e diversidade dos dados, da validação externa, da padronização metodológica, da interpretabilidade dos sistemas e da demonstração de benefício clínico. Esses aspectos são fundamentais para que os resultados obtidos em pesquisas possam ser avaliados quanto à sua reprodutibilidade, segurança e aplicabilidade no contexto odontológico (Messina et al., 2026; Tichy et al., 2026).

3 MATERIAL E MÉTODOS

O presente estudo foi caracterizado como uma revisão narrativa da literatura, de abordagem qualitativa e caráter descritivo, desenvolvida com o objetivo de analisar a aplicação de algoritmos de Deep Learning na detecção da perda óssea periodontal em radiografias periapicais e panorâmicas. A revisão narrativa permitiu reunir, sintetizar e discutir criticamente o conhecimento científico disponível sobre a temática, possibilitando uma compreensão abrangente das evidências relacionadas ao emprego da Inteligência Artificial na avaliação radiográfica periodontal (GIL, 2022).

A busca bibliográfica foi realizada na base de dados PubMed, selecionada em razão de sua relevância e abrangência na área das Ciências da Saúde. A estratégia de busca foi composta

pelos descritores em língua inglesa “periodontitis”, “deep learning” e “dental radiography”, combinados por meio do operador booleano AND. Foram aplicados filtros referentes ao período de publicação dos últimos cinco anos, priorizando-se revisões sistemáticas, artigos de revisão e estudos relacionados à aplicação da Inteligência Artificial e do Deep Learning na análise radiográfica periodontal.

Inicialmente, foram identificados 135 artigos científicos na busca bibliográfica. Após a aplicação dos critérios de elegibilidade, que consideraram a relação com a temática proposta, a disponibilidade do texto completo e a publicação em língua inglesa ou portuguesa, foram selecionados 33 artigos para uma avaliação mais detalhada. Posteriormente, realizou-se a leitura dos títulos, resumos e textos completos, com o objetivo de verificar a pertinência dos estudos em relação aos objetivos da pesquisa. Ao final do processo de seleção, 15 artigos científicos foram incluídos na revisão.

Foram incluídos estudos que abordaram a utilização da Inteligência Artificial ou de algoritmos de Deep Learning aplicados à análise de imagens radiográficas relacionadas à perda óssea periodontal. Foram excluídos estudos duplicados, publicações que não abordaram diretamente a temática investigada, trabalhos indisponíveis na íntegra e estudos que não apresentaram informações suficientes para a análise dos aspectos definidos nos objetivos da revisão.

Após a seleção final, as informações pertinentes foram organizadas e analisadas de forma descritiva e qualitativa. Foram considerados aspectos relacionados aos algoritmos e modelos de Deep Learning empregados, aos tipos de radiografias utilizadas, ao desempenho diagnóstico, à aplicabilidade clínica, às limitações metodológicas e às perspectivas futuras da utilização da Inteligência Artificial na Periodontia. Essa análise possibilitou sintetizar os principais achados da literatura e identificar aspectos relevantes para a aplicação clínica dessas tecnologias (GIL, 2022).

4 RESULTADOS E DISCUSSÕES

A busca bibliográfica realizada na base de dados PubMed identificou inicialmente 135 artigos científicos. Após a aplicação dos critérios de elegibilidade, 33 publicações foram selecionadas para avaliação mais detalhada. Posteriormente, mediante a leitura dos títulos, resumos e textos completos, foram incluídos 15 artigos na revisão narrativa. A análise dos estudos permitiu reunir informações sobre os algoritmos de Deep Learning empregados na

detecção da perda óssea periodontal, as modalidades radiográficas utilizadas, o desempenho diagnóstico, a aplicabilidade clínica e as principais limitações dessas tecnologias.

Os estudos analisados demonstraram que a Inteligência Artificial, especialmente por meio de algoritmos de Deep Learning, apresenta potencial para auxiliar a identificação de alterações periodontais em imagens radiográficas. Entre as abordagens descritas, destacam-se as redes neurais convolucionais (CNNs), além de modelos destinados à classificação, segmentação, detecção de objetos e localização de pontos anatômicos. Essas estratégias apresentam finalidades distintas, desde a identificação da presença de perda óssea até a delimitação de estruturas relacionadas à avaliação do nível ósseo alveolar (Chatzopoulos et al., 2025; Hashim et al., 2026).

No que se refere à avaliação da perda óssea periodontal, Hashim et al. (2026), em revisão sistemática sobre o uso de Deep Learning em radiografias intraorais, identificaram acurácias entre 0,73 e 0,97 nas tarefas de detecção binária. Embora esses resultados indiquem desempenho promissor, os autores também apontaram limitações metodológicas importantes, como a escassez de validação externa e o risco de viés nos estudos incluídos. Esses aspectos demonstram que resultados elevados de acurácia não são suficientes, isoladamente, para comprovar a confiabilidade dos modelos em diferentes contextos clínicos.

Resultados semelhantes foram descritos por Khubrani et al. (2025), que encontraram, em meta-análise sobre a detecção da perda óssea periodontal e da periodontite em radiografias bidimensionais, sensibilidade de 87%, especificidade de 76% e acurácia de 84%. Esses indicadores sugerem que os modelos podem contribuir para a identificação de alterações periodontais. Entretanto, a diferença entre as métricas evidencia a importância de considerar a capacidade de identificar corretamente os casos positivos e negativos, uma vez que o desempenho diagnóstico não pode ser avaliado por um único indicador.

Em relação às radiografias periapicais e panorâmicas, os estudos demonstraram que ambas apresentam possibilidades de aplicação na análise automatizada da perda óssea periodontal, embora possuam características distintas. As radiografias periapicais permitem uma avaliação mais localizada das estruturas dentoalveolares, enquanto as panorâmicas oferecem uma visualização mais abrangente das arcadas dentárias. Essas diferenças precisam ser consideradas na interpretação dos resultados e na escolha dos modelos utilizados para cada finalidade diagnóstica (Khubrani et al., 2025; Turosz et al., 2023).

A comparação entre as modalidades radiográficas também evidencia diferenças de desempenho conforme o tipo de imagem e a complexidade da tarefa. Lee et al. (2025), ao compararem a classificação binária e o estadiamento da periodontite, observaram que, na classificação binária, as radiografias periapicais apresentaram sensibilidade de 87,2% e especificidade de 81,5%, enquanto as panorâmicas apresentaram acurácia de 88,2%. Para as tarefas de estadiamento, os resultados também variaram entre as modalidades, indicando que a identificação da presença de uma alteração é diferente da determinação de sua gravidade.

No contexto das radiografias panorâmicas, Almutairi et al. (2026) analisaram nove estudos envolvendo mais de 20 mil radiografias e encontraram sensibilidades entre 0,795 e 1,00, especificidades entre 0,784 e 0,99 e valores de área sob a curva ROC (AUC) entre 0,843 e 0,967. Apesar dos resultados favoráveis, somente quatro estudos realizaram validação externa. Além disso, foram observadas diferenças entre os conjuntos de dados e os padrões de referência utilizados. Esses achados reforçam a necessidade de pesquisas que avaliem a capacidade de generalização dos modelos para populações e condições de aquisição de imagens diferentes daquelas utilizadas durante seu desenvolvimento.

Outra aplicação relevante identificada na literatura envolve a localização automatizada de estruturas anatômicas relacionadas à avaliação do nível ósseo. Brunet-Llobet et al. (2026) discutem o uso da Inteligência Artificial no mapeamento periodontal radiográfico, incluindo a identificação da junção cemento-esmalte e da crista óssea alveolar. A análise dessas estruturas permite estimar a distância entre os pontos anatômicos e contribuir para a avaliação radiográfica da perda de suporte periodontal. Entretanto, essa aplicação deve ser compreendida como complementar, uma vez que não substitui o exame periodontal convencional.

Quanto à aplicabilidade clínica, os estudos indicam que os algoritmos de Deep Learning podem contribuir para a padronização da interpretação radiográfica, a identificação de alterações e o suporte à tomada de decisão profissional. Contudo, o desempenho observado em bases de pesquisa não garante, necessariamente, resultados semelhantes na rotina odontológica. Tichy et al. (2026) destacam que a heterogeneidade dos dados, as diferenças entre as tarefas diagnósticas e a escassez de validação externa representam obstáculos à incorporação dessas tecnologias na prática clínica. Dessa forma, a utilização desses sistemas deve considerar tanto suas métricas de desempenho quanto a qualidade metodológica das pesquisas que sustentam sua aplicação.

Entre as principais limitações identificadas, destacam-se a diversidade dos conjuntos de dados, a ausência de padronização dos métodos de avaliação, as diferenças entre os critérios utilizados como referência diagnóstica e a quantidade limitada de estudos com validação externa. Hashim et al. (2026) também observaram risco de viés predominantemente alto ou incerto nos trabalhos sobre perda óssea em radiografias intraorais, além de evidências de qualidade muito baixa. Essas limitações dificultam a comparação direta entre os resultados e indicam que ainda são necessárias pesquisas com métodos mais consistentes e amostras diversificadas.

Outro aspecto relevante é a interpretabilidade dos modelos. Embora os algoritmos possam identificar padrões em imagens radiográficas, nem sempre é possível compreender diretamente quais características determinaram suas previsões. Nesse sentido, a Inteligência Artificial explicável pode contribuir para tornar as decisões dos sistemas mais compreensíveis, favorecendo a avaliação de sua confiabilidade pelo cirurgião-dentista. Além disso, questões relacionadas à privacidade dos dados, à transparência dos métodos e à integração dessas ferramentas ao fluxo de atendimento devem ser consideradas antes de sua utilização clínica mais ampla (Chatzopoulos et al., 2025; Herz; Bartha, 2026).

Diante dos achados discutidos, observa-se que o Deep Learning apresenta potencial para auxiliar a detecção e a avaliação da perda óssea periodontal em radiografias periapicais e panorâmicas. Entretanto, as diferenças entre as modalidades de imagem, as tarefas diagnósticas e os métodos de avaliação impedem que os resultados sejam generalizados indiscriminadamente. A consolidação dessas tecnologias na Odontologia depende do aprimoramento dos estudos, da realização de validações externas e prospectivas e da demonstração de benefícios concretos para a tomada de decisão clínica.

Assim, os resultados desta revisão narrativa indicam que os algoritmos de Deep Learning constituem ferramentas promissoras de apoio à interpretação radiográfica periodontal, mas ainda apresentam limitações que precisam ser superadas. Sua utilização deve ocorrer de forma complementar à avaliação clínica e radiográfica realizada pelo cirurgião-dentista, sem substituir o julgamento profissional. Dessa maneira, o avanço dessas tecnologias dependerá não apenas do desenvolvimento de modelos com bom desempenho diagnóstico, mas também da produção de evidências consistentes sobre sua segurança, reprodutibilidade e aplicabilidade em situações reais de atendimento.

5 CONSIDERAÇÕES FINAIS

A presente revisão narrativa analisou a aplicação de algoritmos de Deep Learning na detecção da perda óssea periodontal em radiografias periapicais e panorâmicas. Os estudos incluídos indicam que essas ferramentas apresentam potencial para auxiliar a identificação, a classificação e a avaliação de alterações relacionadas ao nível ósseo alveolar. Contudo, o desempenho varia conforme a modalidade radiográfica, a tarefa diagnóstica, a composição dos conjuntos de dados e os métodos utilizados como referência.

As evidências também apontam limitações importantes, incluindo heterogeneidade metodológica, risco de viés e quantidade restrita de estudos com validação externa. Por isso, os resultados obtidos em bases de pesquisa não devem ser generalizados automaticamente para diferentes populações e contextos clínicos. São necessárias pesquisas com amostras mais diversificadas, métodos padronizados e validações externas e prospectivas que avaliem a utilidade dessas ferramentas na prática odontológica.

Conclui-se que o Deep Learning constitui uma ferramenta promissora de apoio à interpretação radiográfica periodontal, mas não substitui o exame periodontal, a integração dos achados clínicos e radiográficos nem o julgamento do cirurgião-dentista. Sua incorporação clínica deve ser orientada pela qualidade das evidências, pela segurança dos dados e pela demonstração de benefícios em situações reais de atendimento.

REFERÊNCIAS

ALMUTAIRI, Khalid et al. Diagnostic performance of artificial intelligence models for periodontitis disease detection using panoramic radiographs: a systematic review. Dent J, Basel, v. 14, n. 7, p. 416, 2026. DOI: 10.3390/dj14070416. Disponível em: https://pubmed.ncbi.nlm.nih.gov/42505724/. Acesso em: 28 set. 2026.

BRUNET-LLOBET, Lluís et al. From panoramic radiographs to AI-assisted radiographic periodontal charting: current evidence and future perspectives. Dentistry Journal, Basel, v. 14, n. 9, art. 612, 2026. DOI: 10.3390/dj14090612. Disponível em: https://pubmed.ncbi.nlm.nih.gov/42782999/. Acesso em: 29 set.2026.

CHATZOPOULOS, Georgios S. et al. Clinical applications of artificial intelligence in periodontology: a scoping review. Medicina, Basel, v. 61, n. 6, p. 1066, 2025. DOI: 10.3390/medicina61061066. Disponível em: https://pubmed.ncbi.nlm.nih.gov/40572754/. Acesso em: 28 set. 2026.

CHOLAN, Priyanka et al. The impetus of artificial intelligence on periodontal diagnosis: a brief synopsis. Cureus, Palo Alto, v. 15, n. 8, e43583, 2023. DOI: 10.7759/cureus.43583. Disponível em: https://pubmed.ncbi.nlm.nih.gov/37719493/. Acesso em: 28 set. 2026.

DAMGAARD, Christian; LIEDTKE, Nils Benedikt. Innovations using digital technologies for periodontal diagnosis and prognosis: a narrative review. Acta Odontologica Scandinavica, v. 85, p. 538-548, 2026. DOI: 10.2340/aos.v85.46561. Disponível em: https://pubmed.ncbi.nlm.nih.gov/42578725/. Acesso em: 28 set. 2026.

GIL, Antonio Carlos. Como elaborar projetos de pesquisa. 7. ed. São Paulo: Atlas, 2022.

HASHIM, Nada Tawfig et al. Deep learning for the assessment of alveolar bone loss on intraoral radiographs: a systematic review. Diagnostics, Basel, v. 16, n. 16, p. 2575, 2026. DOI: 10.3390/diagnostics16162575. Disponível em: https://pubmed.ncbi.nlm.nih.gov/42650978/. Acesso em: 28 set. 2026.

HERZ, Marco M.; BARTHA, Valentin. Artificial intelligence in periodontology: from automated diagnosis to prediction and clinical decision support—a narrative review. Dent J, Basel, v. 14, n. 8, art. 531, 2026. DOI: 10.3390/dj14080531. Disponível em: https://pubmed.ncbi.nlm.nih.gov/42645505/. Acesso em: 28 set. 2026.

JAFER, Mohammed et al. The application and performance of artificial intelligence (AI) models in the diagnosis, classification, and prediction of periodontal diseases: a systematic review. Diagnostics, Basel, v. 15, n. 24, p. 3247, 2025. DOI: 10.3390/diagnostics15243247. Disponível em: https://pubmed.ncbi.nlm.nih.gov/41464246/. Acesso em: 28 set. 2026.

KHUBRANI, Yahia H. et al. Detection of periodontal bone loss and periodontitis from 2D dental radiographs via machine learning and deep learning: systematic review employing APPRAISE-AI and meta-analysis. Dentomaxillofacial Radiology, v. 54, n. 2, p. 89-108, 2025. DOI: 10.1093/dmfr/twae070. Disponível em: https://pubmed.ncbi.nlm.nih.gov/39656957/. Acesso em: 28 set. 2026.

LEE, Ji-Eun; CHOI, Eunhye; PARK, Jun-Beom. Radiographic diagnosis of periodontitis using artificial intelligence: a meta-analysis comparing binary and staging classifications across imaging modalities. BMC Oral Health, v. 25, n. 1, p. 1921, 2025. DOI: 10.1186/s12903-025-07171-z. Disponível em: https://pubmed.ncbi.nlm.nih.gov/41327145/. Acesso em: 28 set. 2026.

MESSINA, Bianca Maria et al. The impact of artificial intelligence on periodontal disease detection and treatment. Frontiers in Dental Medicine, v. 7, p. 1784123, 2026. DOI: 10.3389/fdmed.2026.1784123. Disponível em: https://pubmed.ncbi.nlm.nih.gov/41727354/. Acesso em: 28 set. 2026.

NADARGE, Madura C.; DAS, Deepa A. Evaluation of the use of artificial intelligence in dental imaging interpretation: a systematic review. Cureus, v. 18, n. 5, e109628, 2026. DOI: 10.7759/cureus.109628. Disponível em: https://pubmed.ncbi.nlm.nih.gov/42359172/. Acesso em: 28 set. 2026.

PATEL, Maitri S. et al. Impact of artificial intelligence on periodontology: a review. Cureus, Palo Alto, v. 17, n. 3, e81162, 2025. DOI: 10.7759/cureus.81162. Disponível em: https://pubmed.ncbi.nlm.nih.gov/40134460/. Acesso em: 28 set. 2026.

TICHY, Antonin et al. Artificial intelligence in periodontology: a systematic review. Journal of Periodontal Research, v. 61, n. 6, p. 639-661, 2026. DOI: 10.1111/jre.70107. Disponível em: https://pubmed.ncbi.nlm.nih.gov/41907011/. Acesso em: 28 set. 2026.

TUROSZ, Natalia et al. Applications of artificial intelligence in the analysis of dental panoramic radiographs: an overview of systematic reviews. Dentomaxillofacial Radiology, v. 52, n. 7, p. 20230284, 2023. DOI: 10.1259/dmfr.20230284. Disponível em: https://pubmed.ncbi.nlm.nih.gov/37665008/. Acesso em: 28 set. 2026.