

USO DA INTELIGÊNCIA ARTIFICIAL NA PERIODONTIA

USE OF ARTIFICIAL INTELLIGENCE IN PERIODONTICS

Débora C. Teixeira¹; Gilberto F. S. Júnior²; Walmir J. P. R. Rodrigues³

Descritores: Inteligência Artificial; Periodontia; Periodontite.

Keywords: Artificial Intelligence; Periodontics; Periodontitis.

RESUMO

A periodontite é uma doença crônica que promove a destruição dos tecidos de suporte dentário, influenciada por biofilme bacteriano, resposta imune e condições sistêmicas. O diagnóstico atual considera critérios clínicos e radiográficos, classificando a gravidade e o risco de progressão. A inteligência artificial (IA) tem se destacado como ferramenta de apoio na odontologia, utilizando redes neurais, algoritmos de Floresta Aleatória e técnicas de detecção para analisar imagens, avaliar a perda óssea e auxiliar no prognóstico, apresentando precisão comparável à de especialistas. Estudos recentes indicam que a IA pode superar o desempenho de dentistas na avaliação da perda óssea, contribuindo para melhorias clínicas e na qualidade de vida dos pacientes. Além disso, pesquisas evidenciam o avanço da aplicação da IA em diferentes etapas do manejo periodontal, como o diagnóstico precoce, o prognóstico, a análise de radiografias e o uso de biomarcadores salivares. Assim, o uso da IA na periodontia configura-se como um recurso complementar promissor, capaz de aprimorar o diagnóstico, o planejamento e o prognóstico periodontal.

ABSTRACT

Periodontitis is a chronic disease that promotes the destruction of tooth-supporting tissues, influenced by bacterial biofilm, immune response, and systemic conditions. Current diagnosis considers clinical and radiographic criteria, classifying severity and risk of progression. Artificial intelligence (AI) has emerged as a supporting tool in dentistry, using neural networks, Random Forest algorithms, and detection techniques to analyze images, assess bone loss, and aid in prognosis, with accuracy comparable to that of specialists. Recent studies indicate that AI can outperform dentists in assessing bone loss, contributing to clinical improvements and improving patients' quality of life. Furthermore, research highlights the advancement of AI application in different stages of periodontal management, such as early diagnosis, prognosis, radiographic analysis, and the use of salivary biomarkers. Therefore, the use of AI in periodontics represents a promising complementary resource, capable of improving diagnosis, planning, and periodontal prognosis.

¹ Acadêmica do 10º período do Curso de Graduação em Odontologia do UNIFESO- 2025.

² Professor do Curso de Graduação em Odontologia do UNIFESO. Especialista, mestre e doutor em periodontia (UERJ).

³ Docente do Curso de Graduação em Odontologia do UNIFESO, especialista em Atenção Básica em Saúde da Família, Especialista em Periodontia, Mestre em Odontologia, área de concentração Periodontia (UERJ).

INTRODUÇÃO

A periodontite é uma patologia crônica que causa a destruição progressiva dos tecidos de suporte e proteção periodontais, como gengiva, ligamento periodontal e osso alveolar. Essa condição ocorre devido ao acúmulo de colônias bacterianas que saem de uma condição de homeostasia para a disbiose, somadas à desregulação da resposta imune do hospedeiro, ocasionam um processo infeccioso crônico (Fernandes, 2017). A periodontite, considerada a 11ª doença mais comum no mundo, representa um relevante desafio para a saúde pública por seus impactos funcionais e sociais. A progressão da doença pode causar reabsorção óssea periodontal e levar à perda do dente acometido, o que reforça a importância do diagnóstico precoce e de um tratamento adequado (Kim *et al.*, 2019). Esses desfechos, por sua vez, comprometem a função mastigatória, a estética e, consequentemente, a qualidade de vida dos pacientes (Gundelly *et al.*, 2024).

A doença é conhecida mundialmente como o principal motivo de perda de dentes no mundo, sendo prevalente em países desenvolvidos e sub-desenvolvidos, atingindo de 20% a 50% da população mundial (Alalharith *et al.*, 2020). A partir desta alta incidência, a Academia Americana de Periodontologia e a Federação Européia de Periodontologia definiram a nova classificação de doenças e condições periodontais e peri-implantares, padronizando os métodos de diagnóstico, mecanismos fisiopatológicos, gravidade, dentre outros aspectos que caracterizam a doença (Barbosa *et al.* 2018).

A interdisciplinaridade na periodontia é de suma importância, já que a progressão da patologia depende da resposta imunológica do hospedeiro. Além disso, existe uma relação recíproca entre a periodontite e condições sistêmicas como diabetes, alterações cardiovasculares, distúrbios hormonais, alterações pulmonares, dentre outras patologias que podem agravar a periodontite e a destruição tecidual (Rodrigues *et al.*, 2020). Os exames habituais para diagnosticar a doença periodontal incluem o uso de sondas milimetradas e imagens radiográficas. Contudo, o diagnóstico e o prognóstico dependem da aptidão do cirurgião dentista (Thanathornwong *et al.* 2020).

A inteligência artificial (IA) é a habilidade dos computadores funcionarem de maneira semelhante a inteligência humana, tomando decisões de forma independente baseadas em padrões de dados afim de realizar diversas tarefas (Barbosa *et al.* 2023). A IA na área da saúde é utilizada para auxiliar o diagnóstico e minimizar falhas, proporcionando melhor diagnóstico e tratamento para diversas patologias. O escopo de suas funcionalidades é vasto, uma vez que organiza informações com precisão, em tempo real e detecta variáveis através de dados rotulados, sendo utilizada frequentemente para analisar e prever imagens (Soares *et al.*, 2023).

Na Odontologia, a IA é utilizada para auxiliar o diagnóstico e prognóstico em diversas áreas como: periodontia, patologia oral, ortodontia, cirurgia e traumatologia bucomaxilofacial (CTBMF), cariologia, implantodontia e odontologia forense. Desta forma, essa tecnologia promissora é uma ferramenta capaz de aprimorar a exatidão, confiabilidade no diagnóstico e planejamento terapêutico em diversas áreas da odontologia quando associada com a avaliação clínica (Thanathornwong *et al.* 2020; Alotaibi *et al.* 2022; Savegnango *et al.*, 2024).

OBJETIVO PRIMÁRIO:

Realizar uma revisão de literatura sobre a utilização da inteligência artificial na periodontia.

OBJETIVOS SECUNDÁRIOS

- Diferenciar os tipos de IA;

- Elucidar os benefícios do uso da IA na odontologia;
- Discutir vantagens e desvantagens da IA na periodontia;
- Avaliar os resultados do uso de modelos de IA para execução de tarefas em periodontia.

REVISÃO DE LITERATURA

Periodontite

De acordo com o estudo da Carga Global de Doenças (GBD), a doença periodontal foi considerada uma das mais prevalentes entre 1990 e 2010 e, sua prevalência continua sendo grave na atualidade. Nos Estados Unidos a repercussão econômica diante da alta prevalência da doença foi estimado em US\$ 154 bilhões (Trindade *et al.*, 2023). Já no Brasil, a Pesquisa Nacional de Saúde Bucal, realizada em 2010 pelo Ministério da Saúde identificou uma prevalência de 82,2% em adultos de 35 a 44 anos e 98,2% em idosos de 65 a 74 anos (Brasil, 2012).

Em 2021, foi realizada uma nova avaliação por meio do estudo GBD, que reavaliou a prevalência global da periodontite severa, especialmente entre indivíduos na faixa etária de 45 a 64 anos, sendo estimada em 12.500 casos a cada 100.000 habitantes. O Sudeste Asiático destacou-se como a região com o maior número absoluto de casos, com mais de 333 milhões de pessoas afetadas. Em contrapartida, a África apresentou as menores taxas de prevalência, com 12.000 casos por 100.000 habitantes. Diante desse cenário, observa-se uma tendência global de crescimento da doença, apesar de algumas exceções regionais. Ressalta-se o aumento expressivo no número de casos em regiões como o Mediterrâneo Oriental, com incremento de 177%, e o Sudeste Asiático, com 130% de aumento (GBD, 2025).

Hajishengallis e seus colaboradores (2020) afirmaram que a doença periodontal é ocasionada pelo biofilme disbiótico e um processo inflamatório crônico. Este processo leva a disfunção e dano tecidual, além do aumento da carga bacteriana, ocasionando um ciclo contínuo da patologia.

Além dos fatores locais, a periodontite é considerada uma doença crônica localizada que pode gerar uma resposta imune sistêmica do hospedeiro. A inflamação ocorre a partir da secreção de mediadores pró-inflamatórios e destruição do tecido periodontal de forma desregulada. O processo inflamatório inicia-se com a penetração dos produtos bacterianos no epitélio de revestimento, os quais não são eliminados de forma eficaz pela imunidade inata (Almeida, 2022).

A periodontite é caracterizada pela perda de inserção clínica, formação de bolsas periodontais, sangramentos gengivais e perda óssea alveolar. Ademais, somados a disbiose e ao processo inflamatório, fatores como: condições sistêmicas, maus hábitos, alterações hormonais, dentre outros, podem alterar o curso da patologia (Rakic *et al.*, 2021).

Sendo assim, algumas doenças sistêmicas podem influenciar a evolução da periodontite, afetar os tecidos periodontais, independentemente do biofilme bacteriano e do processo inflamatório, ou mimetizar suas manifestações clínicas. Doenças genéticas graves. Como a Síndrome de Papillon-Lefèvre, podem acarretar o desenvolvimento precoce da doença. Condições como diabetes mellitus podem alterar o curso da doença, aumentando a severidade da periodontite. Além disso, patologias raras que atingem os tecidos de suporte periodontal, como o carcinoma de células escamosas ou histiocitose de células de Langerhans podem confundir o profissional devido a semelhança clínica com a periodontite (Jepsen *et al.*, 2018).

A Síndrome de Papillon Lefevre é uma doença hereditária autossômica recessiva que ocasiona o desenvolvimento de hiperqueratose palmoplantar e alterações na quimiotaxia de neutrófilos, aumentando a possibilidade de infecções e acarretando a perda de toda a dentição. As alterações no periodonto também estão associadas a bactéria *aggregatibacter actinomycetemcomitans* que produz

leucotoxina (proteína de 116-kDa) que destrói os leucócitos, aumentando a suscetibilidade ao desenvolvimento de infecções periodontais e agravando a perda dentária precoce (Vieira *et al.*, 2010).

O Diabetes Mellitus (DM) é uma doença crônica, que ocorre devido a insuficiência ou ausência de insulina, ocasionando uma hiperglicemia. Sendo assim, a relação entre a periodontite e a DM é diretamente proporcional, tendo em vista que a DM aumenta os níveis finais de glicação avançada no periodonto (AGEs), intensificando a resposta imunológica local e recrutamento de citocinas pró-inflamatórias que favorecem a progressão da periodontite (De Moura Chaves *et al.*, 2024). Em contrapartida, as bactérias periodontais e seus subprodutos podem atingir a circulação sanguínea, promovendo inflamações sistêmicas e exacerbando a condição diabética (Preshaw *et al.*, 2019).

Em 2017, o Workshop Mundial sobre a Classificação das Doenças e Condições Periodontais e Peri-implantares definiu critérios de diagnóstico para a periodontite, tendo em vista que o diagnóstico e o plano de tratamento são complexos por se tratar de uma patologia multifatorial (Rösing *et al.*, 2020). Assim, a precisão do diagnóstico é imprescindível para a realização do tratamento periodontal correto, prognóstico e manutenção da saúde bucal. Tendo em vista que o diagnóstico fundamentado em critérios clínicos e radiográficos (Rakic *et al.*, 2021).

Inteligência artificial

A IA é o ramo da computação que desenvolve sistemas cujo funcionamento assemelha-se ao raciocínio humano, com capacidade de aprendizagem de máquina (*machine learning*) e armazenamento de grande volume de informações (Neto *et al.*, 2020).

A inteligência artificial (IA) surgiu como uma ferramenta promissora na área de saúde, sendo utilizada para realizar diagnósticos mais rápidos, realizar a triagem de pacientes e auxiliar decisões clínicas (Kim *et al.*, 2019). Da Silva *et al.* (2024), afirmaram que a IA vem sendo muito utilizada na medicina, principalmente devido a sua capacidade de interpretar imagens radiológicas com precisão. A IA é capaz de identificar se a lesão é de origem maligna ou benigna, especificar o tipo histológico da patologia, presença de mutações genéticas, resposta ao tratamento e prognóstico do paciente. Com isso, a IA promove avanços importantes para a saúde moderna, colaborando para diagnósticos mais rápidos e precisos. Dessa forma, a IA atua quatro áreas principais para auxílio médico:

- Detecção assistida por computador (evidencia anomalias e regiões suspeitas na imagem);
- Diagnóstico assistido por computador (avalia padrões e sugere diagnósticos);
- Ferramentas de análise quantitativa (determina estruturas anatômicas e lesões);
- Suporte à decisão clínica (recomendações).

No Brasil, o Ministério da Saúde, por meio do Sistema Único de Saúde (SUS), busca implementar o uso da IA como uma estratégia para ampliar o acesso à saúde pública, promovendo maior agilidade no atendimento e diagnóstico, inclusão da população, melhoria no sistema de gestão, apoio aos profissionais de saúde e consolidação da Vigilância Sanitária. A aplicação da IA abrange desde a atenção primária até em unidades de alta complexidade, contribuindo para a redução letalidade e melhoria dos casos clínicos (BRASIL, 2023).

A IA integra conceitos de *software*, estatística, lógica e ciência da computação, ensinando máquinas a realizarem as funções que eram tradicionalmente feitas por humanos. Sua aplicação é ampla, abrangendo diversas áreas do conhecimento e, conta com múltiplas subdivisões técnicas que possibilitam sua adaptação em diferentes contextos e necessidades. Assim, é possível fornecer informações rápidas e atualizadas, simplificar tarefas, otimizar o tempo e auxiliar em pesquisas (Silva, 2024; Khan *et al.*, 2024).

Aprendizagem de máquina

A inteligência artificial levou a avanços significativos na odontologia e para melhor compreensão do tema, faz-se necessário entender alguns conceitos-chave. A aprendizagem de máquina (*machine learning*–ML) diz respeito ao processo em que os computadores “aprendem” a partir de dados aperfeiçoando suas atividades por meio de treinamento e testes (Coelho, 2020). Neste subcampo da IA os algoritmos aprendem com dados e realizam diversas tarefas. Os modelos de ML evoluem quando são expostos a mais dados, fornecendo respostas mais específicas em conformidade com parâmetros estabelecidos pelo especialista (Jardim *et al.*, 2023). A ML supervisionada, permite que a máquina realize previsões em bases de conjuntos de dados rotulados previamente, enquanto os algoritmos de aprendizagem de máquina não supervisionados processam dados não rotulados, dispensando a intervenção humana para treinamentos (Salgão *et al.*, 2024).

Atualmente, a notável capacidade de aprendizagem dos computadores foi desenvolvida por Alan Turing, considerado o pai da computação. O chamado Teste Turing tem como finalidade avaliar se a máquina é capaz de imitar o comportamento e o raciocínio humano e consiste no interlocutor não conseguir distinguir se está se comunicando com uma inteligência artificial ou com um ser humano. A partir disso, caso a máquina seja capaz de enganar o interlocutor, é considerada aprovada no Teste (Onody, 2021).

A IA foi descrita em três tipos: IA focada (fraca), IA generalizada e IA superinteligente. Basicamente, a IA focada é desenvolvida para resolver comandos específicos, sem ultrapassar os limites da função para qual foi programada. A IA generalizada, por sua vez, é capaz de realizar as mesmas tarefas que os humanos, com flexibilidade cognitiva semelhante à humana. Já na IA superinteligente, refere-se a um estágio teórico em que os algoritmos superem amplamente as habilidades dos humanos em todos os domínios (Ludemir, 2021).

Algoritmos aplicados à inteligência artificial

Algoritmos como as Redes Neurais (NN) constituem um subconjunto do modelo de ML e são inspirados no funcionamento do cérebro humano. Esses modelos trabalham com dados previamente rotulados e são compostos por uma rede de “neurônios” que se conectam entre si organizados em três camadas: camada de entrada, camada oculta e camada de saída. Com isso, ao processar imagens, a informação fica dissolvida entre as camadas da rede (Souza, 2023). A camada de entrada (*input*) recebe os dados e o valor final é criado na camada de saída (*output*); as camadas ocultas (*hidden*) realizam os cálculos que fazem a máquina encontrar os resultados finais. Quanto maior for o número de dados, maior a automelhoria e autorrefinamento das informações (Jardim *et al.*, 2021).

Já as Redes Neurais Convolucionais (CNNs) são especializadas no processamento de imagens, utilizando operações matemáticas que usam características de dados com operações de convolução, podendo ser aplicadas em dados brutos, sendo amplamente utilizadas em aplicações de diagnóstico por imagem. Além disso, são capazes de preservar as informações devido a organização espacial dos pixels, gerando maior veracidade às informações (Salgão *et al.*, 2024). As CNNs são compostas por estágios fundamentais chamados de: convolução, ativação e *pooling*. O estágio de convolução os filtros percorrem a entrada gerando ativações lineares. Em seguida, no segundo estágio ocorre uma ativação não linear, permitindo que o modelo aprenda informações mais complexas. Por último, o terceiro estágio, onde a informação é detectada e traduzida, mantendo as informações mais relevantes tornando o modelo mais eficiente (Reis, Romero, 2024).

O algoritmo Floresta aleatória (*random forest*) é baseado em árvores de decisão independentes e combinadas que utiliza dados diversos, a fim de obter resultados mais desenvolvidos. Essa técnica de ML desempenha um papel importante quando inserida em múltiplas aplicações (Santana, 2023). Cada árvore possui uma versão *bootstrapped* do conjunto de treinamento, e as informações são processadas repetidamente até que as regras de decisão sejam atendidas. A exatidão do modelo depende da agregação de múltiplas informações provenientes dos diferentes nós das árvores (Hu; Szymczak, 2023).

Du *et al.* (2020) afirmaram que o algoritmo *U-net* é uma rede neural capaz de aprender de forma autônoma segmentação semântica de imagens médicas, lesões e estruturas anatômicas. Essa tecnologia avalia e processa as imagens de forma objetiva. Esta IA possui um campo abrangente no uso de diferentes tipos de imagens, como tomografias, radiografias e microscopia (Siddique *et al.*, 2020).

Aliferis e Simon (2024) realizaram um estudo sobre sobreajuste (*overfitting*), subajuste (*underfitting*) e modelo geral (que compreende bem os dados). Esses problemas geram erros na seleção de modelos de IA, podendo resultar em excesso ou baixa confiança relacionados à seleção de modelos, complexidade da aprendizagem e dados incompletos. Tais erros podem ser sutis, sendo dificilmente percebidos antes de acarretarem grandes falhas na análise de dados. O sobreajuste ocorre quando um modelo se ajusta bem aos dados de treinamento, mas não é capaz de generalizar os padrões para novos dados. Esse erro pode ser causado pelo método de aprendizado de máquina utilizado, pelo tipo de aprendizagem adotado e por um sistema de dados deficiente. Já o subajuste ocorre devido ao desempenho insatisfatório do modelo, que apresenta baixa performance tanto nos dados de treinamento quanto em novos dados.

Prajapati (2023) definiu sobreajuste como o fenômeno em que a máquina gera dados a partir das informações pré-rotuladas. Contudo, ao adquirir uma nova base de dados, produz resultados inconsistentes. O sobreajuste ocorre devido a ruídos, sobrecarga de dados quando o modelo possui informações impertinentes e pelo aumento do número de camadas em redes neurais. Já o subajuste ocorre quando o aprendizado de máquina não obtém dados robustos, seleção incorreta do modelo, menor capacidade de aprendizagem e baixa variabilidade das informações, fazendo com que o modelo funcione de forma deficiente.

Aplicações da inteligência artificial na periodontia

Manjunatha (2024) destacou a importância da inteligência artificial na periodontia, ressaltando sua contribuição para a precisão do diagnóstico, o planejamento otimizado do tratamento e a análise de informações relacionadas à progressão da doença. A IA utiliza a aprendizagem de máquina para aprimorar a acurácia diagnóstica; o aprendizado profundo, uma subárea do ML, para refinar ainda mais o diagnóstico; e técnicas de visão computacional para processar e interpretar imagens. Esse conjunto de abordagens permite que a IA analise grandes volumes de dados e identifique padrões complexos.

Chen *et al.* (2023) utilizaram o YOLOv7 (You Only Look Once, versão 7) para analisar imagens de radiografias periapicais. O estudo constatou que o YOLOv7 é um software avançado, capaz de detectar objetos em tempo real em um único estágio, apresentando alta eficiência, baixa demanda computacional e elevada velocidade de processamento. Esse algoritmo demonstrou precisão média de 97,1% e tem sido amplamente aplicado no diagnóstico por imagem radiográfica odontológica de dentes individuais sem periodontite.

Em 2020, Alalharith e seus colaboradores, realizaram pesquisas utilizando técnicas de aprendizado de máquina na periodontia. Foi usado o ResNet (*Residual Network*) que realiza “ligações de salto” que facilita o fluxo de informação e aptidão das redes profundas. A pesquisa utilizou uma Rede Neural Convolutiva (CNN) baseada na estrutura *Faster R-CNN*, que analisou através de imagens

microscópicas de placa bacteriana, radiográficas e fluorescentes. O modelo foi capaz de detectar e diagnosticar a gengivite, com uma precisão 10% maior do que métodos tradicionais de ML.

Li *et al.* (2024) avaliaram quatro modelos *ConvNet* para o reconhecimento de gengivite crônica por meio de fotografias intraorais obtidas com câmeras digitais ou celulares, utilizando dados limitados e comandos complexos para aprimorar o desempenho das máquinas. O modelo *ResNet* apresentou a maior acurácia, com 97%, seguido pelo *GoogleLeNet* (94%), *AlexNet* (92%) e *VGGNet* (89%). A *ResNet* permite o treinamento de redes mais profundas com maior precisão; o *AlexNet* apresentou bom desempenho na análise de imagens; o *GoogleLeNet* aumenta o número de camadas e filtros por camada sem elevar significativamente a carga de processamento computacional; por fim, a *VGGNet* utiliza filtros pequenos para análise de redes mais profundas, sendo eficaz na captura de detalhes nas imagens. Contudo, o estudo apresenta diversas limitações: os modelos apresentam dificuldade para aprender novos dados, a amostra utilizada é deficiente e problemas no processamento podem comprometer os resultados.

Uma rede neural convolucional (CNN) foi utilizada para aferir o nível ósseo, a junção cimento-esmalte e os dentes, com base nos critérios estabelecidos pelo *Workshop* Mundial de 2017 sobre a Classificação de Doenças e Condições Periodontais e Peri-implantares, atribuindo o estágio de perda óssea radiográfica para cada dente. Para isso, foram empregadas três redes, destacando-se a *U-Net* associada ao *encoder ResNet-34/CNN*. A *ResNet* pode ser adaptada para a extração de características a partir de imagens, possibilitando a obtenção de saídas das camadas intermediárias. O processo de detecção de objetos consiste na identificação e rotulagem de estruturas por meio de caixas delimitadoras (*bounding boxes*) em radiografias odontológicas. Radiografias periapicais e panorâmicas em alta resolução foram analisadas após um pré-processamento de padronização de contraste e redução de ruídos. As métricas de desempenho foram utilizadas para aprovação do modelo, alcançando resultados superiores a 90% de precisão equivalente com a análise de periodontistas (Salgão *et al.*, 2024).

Deng *et al.* (2024) utilizaram algoritmos de Regressão Logística (LR) e Floresta Aleatória (RF) para o desenvolvimento de uma ferramenta de triagem da saúde periodontal, baseada em biomarcadores salivares e parâmetros não clínicos obtidos através de um auto questionário, sangramento gengival durante a higiene oral auto-relatado, níveis de hemoglobina, idade do paciente e metaloproteínase-8 da matriz ativada. Dessa maneira, foi possível analisar o estado de saúde ou doença gengival, a necessidade de limpeza dentária, a mobilidade dentária e a presença de sangramento provocado segundo a Classificação de 2017. O estudo foi realizado em 408 pacientes, submetidos ao exame periodontal em toda arcada dentária, calibração dos examinadores para mensuração da profundidade de bolsa e nível de inserção clínica. A Regressão Logística Multivariada para avaliar dos parâmetros não clínicos como variáveis independentes, enquanto a Floresta Aleatória para classificação de saúde gengival, periodontite e estágios de progressão da doença. Os resultados indicaram acurácia de 80% para auxiliar em contexto de triagem em caso de ausência do exame tradicional, deixando evidente a aplicabilidade de métodos não invasivos para a detecção precoce da periodontite.

Ezhov *et al.* (2021) utilizaram o *Diagnocat* para analisar seu desempenho no diagnóstico de tomografias computadorizadas de feixe cônico (TCFC). Os pesquisadores avaliaram a eficácia clínica, a precisão diagnóstica e o tempo necessário para a análise. O sistema apresenta cinco padrões de análise: segmentação da região de interesse, localização dentária, detecção de periodontite, detecção de cáries e de lesões periapicais. Baseado em uma arquitetura semelhante à *U-Net*, o *Diagnocat* demonstrou uma redução no tempo de diagnóstico de 6,78%, passando de 18,7 minutos sem o uso de IA para 17,6 minutos com IA.

Jiang *et al.* (2022) utilizaram uma arquitetura de dois estágios baseada em *U-Net* e *YOLOv4* para realizar o cálculo preciso da perda óssea alveolar periodontal e o estadiamento da periodontite

por meio de radiografias panorâmicas. O sistema *U-Net* foi empregado para segmentar automaticamente a posição dos dentes na radiografia, reduzindo interferências de estruturas adjacentes. Já o sistema *YOLOv4* foi utilizado para identificar a junção amelo-cementária (JCE), o ápice radicular, a crista óssea alveolar e as áreas de lesão de furca, possibilitando o cálculo da perda óssea vertical e a classificação automatizada dos estágios periodontais. O modelo demonstrou alta acurácia, com taxa de concordância superior a 90% em comparação com periodontistas, apresentando boa robustez mesmo em radiografias com qualidade de imagem variável.

Jundaeng *et al.* (2024) avaliaram as tendências do uso da IA no diagnóstico da periodontite por meio de uma revisão de literatura rigorosa realizada entre 2018 e 2023. Foram utilizados modelos avançados de redes neurais convolucionais, sistemas automatizados de identificação e classificadores de aprendizado de máquina, cujas taxas de precisão na detecção da perda óssea periodontal variaram de 0,76 a 0,98. O estudo concluiu que a IA apresenta implicações positivas para o diagnóstico da periodontite.

Khan *et al.* (2024) realizaram uma revisão de literatura em que os achados sobre o uso da inteligência artificial (IA) na periodontia foram favoráveis para a detecção e classificação da doença, avaliação do risco periodontal, análise óssea, halitose, entre outros. O cálculo da perda óssea radiográfica é subjetivo, dependendo das habilidades do profissional. Os modelos de IA demonstraram capacidade de identificar automaticamente a perda óssea de forma rápida; contudo, a precisão média em radiografias panorâmicas variou entre 63% e 94%, indicando que ainda é necessário um aprimoramento desses sistemas para que a avaliação clínica não seja indispensável. Além disso, o ChatGPT também pode ser utilizado por periodontistas como fonte de informação, desde que com cautela, considerando a possibilidade de erros.

Ossowska *et al.* (2022) utilizaram CNNs para detectar, por meio de radiografias panorâmicas, a perda óssea periodontal em relação ao comprimento da raiz dentária. Neste estudo, os resultados obtidos pela inteligência artificial foram comparados com os de seis cirurgiões-dentistas. A rede neural convolucional apresentou uma precisão de 83%, enquanto os profissionais alcançaram 80%. A porcentagem de perda óssea radiográfica, o diagnóstico precoce e o estadiamento da periodontite foram analisados de acordo com a nova classificação pela CNN e comparados aos resultados dos avaliadores humanos. A precisão da CNN nessa etapa foi de 85%.

Lee *et al.* (2018) desenvolveram um sistema baseado em CNNs para avaliar a precisão do diagnóstico e o prognóstico de dentes com periodontite. Inicialmente, foi realizada a coleta de radiografias periapicais no período de 2015 a 2016. Radiografias de baixa qualidade, dentes que haviam recebido outros tipos de tratamento, com cáries moderadas ou severas, alterações anatômicas ou coroas protéticas foram excluídos. Foi utilizada a combinação de algoritmos de uma CNN profunda pré-treinada, geralmente associada a métodos de ML supervisionada, com uma rede autotreinada, caracterizada por gerar dados por um processo de ML não supervisionada. A precisão da previsão diagnóstica da perda de suporte periodontal foi de 76,7% para molares e 81% para pré-molares. A previsão de exodontia foi de 82,8% para pré-molares e 73,4% para molares.

Santamaria *et al.* (2024) realizaram um estudo com o objetivo de comparar o prognóstico periodontal feito por periodontistas com aquele gerado por inteligência artificial (IA). Foram analisados dentes classificados com prognóstico “favorável”, que seriam mantidos por até 10 anos, e “desfavorável”, que seriam perdidos nesse mesmo período. Utilizou-se um modelo de regressão logística e uma rede neural, após os especialistas emitirem seus prognósticos com base em parâmetros clínicos e radiográficos. Os modelos de IA tiveram uma resposta compatível com o prognóstico clínico, demonstrando ser uma boa ferramenta para um prognóstico preciso e rápido de dentes perdidos por periodontite.

Bashir *et al.* (2022) compararam algoritmos de aprendizagem de máquina e validaram modelos preditivos para periodontite. O estudo utilizou dados de pesquisas realizadas em Taiwan (3.453 pacientes) e nos Estados Unidos (3.685 pacientes), com dez algoritmos treinados. Os preditores foram extraídos a partir de um banco de dados e pré-processados com técnicas de aprendizagem de máquina e redução de dimensionalidade. Os modelos foram submetidos à validação interna (*bootstrap*) e externa (com dados de outro país). Os algoritmos foram avaliados segundo as seguintes métricas: área sob a curva da característica de operação do receptor (AUC), acurácia, sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo. Na avaliação interna, a AUC apresentou resultado superior a 0,95, e a acurácia foi superior a 95%. No entanto, na validação externa, o desempenho reduziu significativamente, mas sem apresentar valores numéricos específicos, indicando a necessidade de um maior número de amostras de preditores.

Içoz *et al.* (2023) avaliaram o uso da inteligência artificial (IA) para a detecção de raízes com periodontite apical (PA) em radiografias panorâmicas. O estudo foi conduzido com 306 radiografias panorâmicas, totalizando 400 raízes com PA. O modelo foi comparado à avaliação de dois radiologistas bucomaxilofaciais, que também realizaram o agrupamento e a delimitação das lesões. A precisão do Diagnóstico Auxiliado por Computador (CAD), baseado no algoritmo YOLOv3 *Darknet*, foi avaliada por meio do recall (sensibilidade), precisão e medida-F. Das 400 raízes com PA, 225 foram diagnosticadas corretamente, enquanto 4 raízes sem PA foram identificadas incorretamente. Entre as raízes diagnosticadas com precisão, 169 eram mandibulares e 56 maxilares. O estudo concluiu que a IA apresentou boa acurácia para lesões na mandíbula; contudo, na maxila, os resultados foram insatisfatórios devido à interferência do seio maxilar.

Parihar *et al.* (2024) realizaram uma revisão de literatura sobre o processamento de linguagem natural (PLN), ferramentas de diagnóstico inteligentes e a integração com registros eletrônicos em saúde (EHR). Os algoritmos de PLN podem revisar ensaios clínicos não estruturados, extraíndo dados sobre a saúde periodontal do paciente, o que facilita a análise do histórico clínico e auxilia no planejamento do tratamento. As ferramentas de diagnóstico inteligentes utilizam a inteligência artificial (IA) em aplicativos de celular e plataformas digitais para avaliação e monitoramento tanto do paciente quanto do profissional em relação à saúde periodontal, por meio de mecanismos de autoanálise, monitoramento em tempo real e sugestões individualizadas de higiene oral. Já os sistemas de EHR fornecem acesso aos dados do paciente, favorecendo a abordagem multidisciplinar do tratamento e permitindo uma atuação mais abrangente.

Revilla-León *et al.* (2022) realizaram uma revisão de literatura para avaliar a performance da inteligência artificial (IA) na detecção da placa bacteriana e no diagnóstico de doenças periodontais a partir de imagens. Os modelos de IA analisados incluíram redes neurais convolucionais, como *U-Net*, *Mask R-CNN* e *Faster R-CNN*. Em relação à detecção da placa bacteriana, os modelos baseados em CNN apresentaram acurácia entre 73,3% e 99%; para o diagnóstico de gengivite a partir de fotografias intraorais, a acurácia variou entre 74% e 78,2%; para o diagnóstico de periodontite a partir das mesmas imagens, os valores oscilaram entre 47% e 81%; e, na avaliação da perda óssea periodontal, a acurácia variou de 73,4% a 99%.

You *et al.* (2024) avaliaram os impactos de sistemas de inteligência artificial (IA) para acompanhamento remoto de três grupos de pacientes com periodontite: o primeiro grupo recebeu monitoramento com IA e orientações de higiene oral, enquanto o segundo recebeu apenas o monitoramento com IA e o terceiro atuou como grupo controle, sem uso de IA. O estudo avaliou o impacto dessas abordagens na qualidade de vida relacionada à saúde bucal (QVRSB). Vinte e oito pacientes foram submetidos ao grupo IA, vinte e sete ao grupo IA com instruções de saúde (IAHC) e vinte e sete pacientes integraram o grupo controle, sem o uso de tecnologia. Após 3 e 6 meses, o grupo que utilizou apenas IA apresentou

gingiva mais saudável em comparação ao grupo controle. O grupo que recebeu orientações juntamente com o uso da IA apresentou resultados melhores, incluindo maior qualidade de vida. Após 3 meses, os grupos IA e IAHC apresentaram redução média na profundidade de sondagem de bolsa entre -0,5 e -0,7 mm e no nível de inserção clínica entre -0,5 e -0,6 mm. Após 6 meses, esses mesmos grupos mostraram melhora média na qualidade de vida, com diferença de -4,5 e -4,7, respectivamente, em comparação ao grupo controle. O grupo IAHC obteve ainda redução média de -0,2 no índice de placa bacteriana e melhora média de -4,3 na QVRSB em relação ao grupo IA.

Krois *et al.* (2019) realizaram um estudo sobre perda óssea periodontal (PBL) em radiografias panorâmicas, mensurada em percentual em relação ao comprimento da raiz. Foi utilizada uma rede neural convolucional (CNN) do tipo *feed-forward*, composta por sete camadas, em que os dados fluem da camada inicial até a saída, sem ciclos. Essa CNN foi treinada para avaliar a PBL e comparada com avaliações subjetivas realizadas por seis dentistas. A acurácia da CNN foi de 81%, com desvio padrão de 0,02; a sensibilidade média (casos com PBL) e a especificidade média (casos sem PBL) também foram de 81%, indicando alta precisão. A precisão média dos dentistas foi de 76%, com alta sensibilidade (0,92), mas baixa especificidade (0,63), o que indica menor precisão na identificação de casos sem perda óssea. O desempenho da CNN e dos dentistas, de acordo com os diferentes grupos de dentes, foi avaliado. Nos molares, a PBL apresentou maior acurácia, atribuída às suas características anatômicas. Já nos pré-molares e caninos, observaram-se diferenças limitadas, sem grandes variações nos resultados. Em relação aos incisivos, tanto a CNN quanto os dentistas apresentaram redução na acurácia, possivelmente devido ao fato de serem dentes menores e com diagnóstico mais complexo.

Feres *et al.* (2018) testaram 40 espécies bacterianas dos complexos microbianos subgingivais com o objetivo de auxiliar na identificação de 435 pacientes, sendo 308 com periodontite crônica generalizada (ChP), 74 com periodontite agressiva generalizada (AgP) e 53 com saúde periodontal (PH). Amostras do biofilme bacteriano foram coletadas de nove sítios interproximais não adjacentes dos pacientes com ChP, AgP e PH, e analisadas por meio da técnica de hibridização *checkerboard* DNA-DNA. A aplicação do aprendizado de máquina foi dividida em duas etapas: na primeira, avaliou-se se havia diferenças na composição das colônias bacterianas entre os grupos com saúde periodontal e com periodontite; na segunda, se havia distinções bacterianas entre ChP e AgP. O modelo obteve sensibilidade de 86%, indicando boa identificação da AgP; especificidade de 79%, relacionada à correta identificação da ChP; e uma AUC de 0,83. As bactérias *P. gingivalis*, *T. forsythia*, *Fusobacterium ssp. polymorphum*, *T. denticola* e *Prevotella intermedia* apresentaram maior associação com ChP, enquanto *Fusobacterium nucleatum ssp. nucleatum*, *Capnocytophaga ochracea*, *Veillonella parvula*, *F. nucleatum ssp. vincentii* e *Capnocytophaga gingivalis* foram mais indicativas de AgP.

Patel *et al.* (2025) revisaram o uso de ferramentas de inteligência artificial (IA) no planejamento do tratamento periodontal. Os modelos de IA demonstraram acurácia, especialmente no diagnóstico por imagem, com desempenho destacado nas métricas de acurácia, sensibilidade e especificidade. Entre as vantagens da utilização da IA na periodontia, destaca-se a possibilidade de auxiliar o diagnóstico clínico em menor tempo. No entanto, suas desvantagens incluem questões relacionadas à privacidade e à proteção de dados, à confiabilidade dos algoritmos e à necessidade de validação clínica rigorosa.

Parihar *et al.* (2024) afirmaram que, apesar das vantagens da inteligência artificial (IA) na periodontia, ainda existem diversas deficiências que precisam ser corrigidas para que a IA seja amplamente utilizada em ambientes ambulatoriais. Faz-se necessária a ampliação e a melhoria da qualidade dos conjuntos de dados para o treinamento dos algoritmos, bem como a proteção da privacidade e segurança dos dados, o estabelecimento de diretrizes regulatórias para os sistemas, além da superação de obstáculos como o alto custo, a infraestrutura e a aprovação por parte dos pacientes.

Questões éticas e desafios da inteligência artificial

Apesar de todo o avanço proporcionado pelo uso da IA, Khan *et al.* (2024) citam a necessidade de supervisão humana das máquinas, a desconsideração de questões socioeconômicas dos pacientes, o risco de desemprego, erros relacionados a doenças específicas e fatores regionais, além de problemas com a privacidade dos usuários.

Dourado e Aith (2022) realizaram uma revisão de literatura sobre a regulamentação da IA aplicada à saúde no Brasil, com base na Lei Geral de Proteção de Dados Pessoais (LGPD – Lei Federal nº 13.709/2018). De acordo com os autores, a Lei não detalha explicitamente o direito à explicação e à revisão de decisões automatizadas, embora envolva a transparência das informações coletadas pelos algoritmos. Os princípios que orientam a padronização dos sistemas são: autonomia, não maleficência/beneficência, transparência, responsabilidade, equidade e agilidade. A transparência permite que o usuário compreenda como as decisões tomadas pela IA influenciam sua vida. Já a LGPD autoriza que máquinas realizem decisões automatizadas, contudo, não exige intervenção humana. Os autores concluíram que ainda são necessárias regulamentações específicas para o uso da IA no Brasil.

Da Silva, Paixão e De Acioly Rodrigues (2024) realizaram uma revisão de literatura sobre os obstáculos ao uso da IA no auxílio ao diagnóstico rápido e preciso no Brasil. Um desses desafios é a perda da confidencialidade das informações dos pacientes. A Lei LGPD regulamenta o uso dos dados dos pacientes, autorizando ou não a exposição dessas informações. A Lei prevê que os dados sejam protegidos, armazenados por determinado período e que o acesso aos dados pessoais dos usuários seja limitado. Outro empecilho é o grande volume de informações, que pode acarretar *overfitting*, erros no diagnóstico e interferir no direito integral de acesso à saúde. O impacto do uso da IA na área da saúde é notável. Contudo, é necessário a implementação de normas que limitem seu uso, sobretudo relacionadas aos aspectos éticos e ao vazamento de dados dos pacientes.

Embora a IA seja uma boa ferramenta, erros podem ser prejudiciais, devido a interpretação errônea de dados pela máquina. As informações pré-rotuladas utilizadas durante o aprendizado de máquina tende a refletir problemas sociais caso os dados sejam disponibilizados com informações que reforcem a desigualdade e discriminação. Faz-se necessário o desenvolvimento de uma legislação que promova o uso responsável dessa tecnologia, protegendo a qualidade de vida dos usuários. O Projeto de Lei 2338/2023 prevê responsabilidade civil dos operadores da IA, independentemente do grau de automatização da máquina. A responsabilidade objetiva, os desenvolvedores das máquinas são responsabilizados por erros no algoritmo, negligência ou testes insuficientes. Na responsabilidade objetiva, os fabricantes também serão indiciados, independente da comprovação de culpa, para proteger os consumidores (Senado Federal, 2023; Ratti, 2024).

Neto, Camardela e De Carvalho (2025) realizaram uma revisão de literatura sobre os impactos da inteligência artificial (IA) na odontologia, seus princípios éticos no Brasil e as recomendações para a ampliação ética do uso dessa tecnologia. Os autores destacam que um dos principais obstáculos à adoção da IA refere-se à proteção dos dados dos pacientes, ao consentimento informado e à responsabilidade pelas decisões clínicas baseadas em IA, sendo necessário o desenvolvimento de leis que garantam a transparência, a equidade e a segurança das informações. No contexto brasileiro, dilemas relacionados à infraestrutura, regulamentação, qualificação dos profissionais e respeito à autonomia do paciente ainda representam desafios. O uso adequado da IA exige que os profissionais sigam as diretrizes estabelecidas pela Lei Geral de Proteção de Dados (LGPD), assegurando os direitos e a privacidade dos pacientes. A expectativa é que, com a implementação de políticas públicas, o uso dessa tecnologia seja amplamente incorporado ao sistema de saúde odontológico no Brasil.

DISCUSSÃO

A alta prevalência da periodontite em diferentes idades e áreas, explicitados pelo GBD (2025) e pela Pesquisa Nacional de Saúde Bucal (Del Buono 2022), reforçam a importância e o impacto socioeconômico dessa patologia. Nesse contexto, fica evidente a necessidade de estratégias de prevenção, diagnóstico precoce e tratamento, principalmente em adultos e idosos (Trindade *et al.* 2023).

Utilizando a capacidade de análise de imagens da IA, estudos com os algoritmos *U-Net* e *YOLOv4*, como os utilizados por Juang *et al.* (2022), realizaram a segmentação automática de dois dentes e calcularam a perda óssea alveolar, atingindo consenso acima de 90% com periodontistas, mesmo em radiografias de diferentes qualidades. De forma semelhante, Ossowska *et al.* (2022) utilizaram uma CNN para avaliar a perda óssea periodontal em radiografias panorâmicas e obtiveram acurácia de 83%, enquanto seis periodontistas alcançaram 80%. Em relação ao diagnóstico precoce e à classificação periodontal, a confiabilidade da CNN aumentou para 85%, superando o desempenho humano.

Entretanto, Lee *et al.* (2018) afirmaram que, apesar de os modelos de IA pré-treinada e autotreinada atingirem alta precisão na detecção de perda de tecido periodontal (76,7% para molares e 81% para pré-molares) e na indicação de exodontia (73,4% a 82,8%), o desempenho geral permaneceu inferior ao dos periodontistas experientes, devido à limitação dos dados de treinamento, variações anatômicas e qualidade das imagens, enfatizando que a habilidade clínica humana continua sendo de suma importância. Além disso, Içoz *et al.* (2023) perceberam que a IA apresentou melhor acurácia em raízes mandibulares do que em maxilares –devido ao seio maxilar– reforçando que a anatomia pode afetar a performance da máquina em comparação ao diagnóstico humano.

Uma das aplicações da IA diz respeito à utilização da *ResNet* para realizar a segmentação automática e a identificação de estruturas importantes de forma mais precisa que métodos tradicionais de aprendizado de máquina. Li *et al.* (2024) evidenciaram que modelos *ResNet* alcançaram 97% de acurácia na identificação da gengivite crônica por meio da análise de imagens intraorais, apesar das limitações relacionadas ao número de pacientes e à generalização do modelo. De maneira semelhante, outros autores exploraram a associação entre diferentes arquiteturas de redes neurais. Allarith *et al.* (2020) demonstraram que redes neurais profundas, como a *ResNet* associada ao *Faster R-CNN*, podem analisar imagens para o diagnóstico da gengivite com desempenho superior aos métodos convencionais. Salgão *et al.* (2024) demonstraram que o uso de CNNs, como a *U-Net* combinada ao *encoder ResNet-34*, possibilita a análise da altura óssea, da junção cimento-esmalte e dos dentes, com 90% de acurácia em comparação aos periodontistas.

Com relação às ferramentas diagnósticas, Deng *et al.* (2024) classificaram de forma não invasiva o estado de saúde periodontal a partir de biomarcadores salivares e parâmetros não clínicos com algoritmos de Regressão Logística e Floresta Aleatória. O estudo realizado em 408 pacientes revelou acurácia de 80% na triagem da periodontite, evidenciando que o uso de tecnologias pode auxiliar no diagnóstico precoce. Ezhov *et al.* (2021) evidenciaram grande redução do tempo em tomografias computadorizadas de feixe cônico, com alta precisão de diagnóstica. Contudo, Revilla-León *et al.* (2022) estudaram a importância da análise de imagens através modelo de redes neurais convolucionais para detecção de placa bacteriana, gengivite, periodontite e perda óssea alveolar e concluíram que a acurácia da IA varia de acordo com a complexidade das tarefas. Isso demonstra que, apesar dos modelos serem eficazes em tarefas objetivas, quando são expostos a dados mais complexos a acurácia torna-se menor.

Em relação ao prognóstico da periodontite, Santamaria *et al.* (2024) estudaram as redes neurais e modelos de regressão logística, e concluíram que apresentam resultados compatíveis com o prognóstico dado pelos periodontistas, indicando que a IA é capaz de acelerar e padronizar a decisão sem

comprometer a precisão para o tratamento periodontal. You *et al.* (2024) avaliaram o uso da IA no acompanhamento remoto dos pacientes. Neste estudo, os resultados indicaram benefícios clínicos, como a redução da profundidade de bolsa a sondagem e melhora na qualidade de vida relacionada à saúde oral quando associadas a tecnologia. Esses dados deixam evidente que, a IA auxilia em aspectos terapêuticos e motivacionais para o manejo da doença.

A comparação de desempenho entre profissionais e ferramentas de IA também é necessária. Nesse sentido, Krois *et al.* (2019) compararam a CNN com os dentistas e ressaltaram essa diferença. Os profissionais apresentam alta sensibilidade e baixa especificidade, enquanto a IA obteve um desempenho superior em ambos os critérios. Esse resultado indica que a IA pode ser assertiva quando ocorre perda óssea discreta, onde ocorre maior subjetividade na interpretação radiográfica humana. Khan *et al.* (2024) avaliaram que a precisão média de modelos de IA em radiografias panorâmicas variaram entre 63% a 94%, evidenciando que, apesar da IA acelerar as análises e reduzir a subjetividade, ainda existe desafios quanto a confiabilidade da tecnologia, sobretudo dependendo da técnica e do tipo de imagem, reforçando a necessidade do monitoramento humano. Patel *et al.* (2025) destacam que o uso da IA no planejamento periodontal obteve desempenho igual ou superior aos periodontistas. Neste estudo, os autores também destacaram as limitações técnicas e éticas do uso de dado e da validação clínica, destacando a importância da integração com a realidade clínica.

CONCLUSÃO

O presente trabalho teve como objetivo revisar a aplicação da inteligência artificial na periodontia, destacando seu potencial para auxiliar o diagnóstico e o prognóstico da doença. Nesse contexto, com o apoio da IA, os periodontistas podem realizar o diagnóstico de forma mais rápida e eficiente, reduzindo a probabilidade de perda dentária e outros efeitos negativos à saúde do paciente. Além disso, fazem-se necessários novos estudos clínicos padronizados que possibilitem a validação de diferentes modelos, a ampliação dos bancos de dados e o estabelecimento de diretrizes que garantam confiabilidade e acurácia. Ademais, aspectos relacionados ao desenvolvimento de normas éticas, à privacidade, ao consentimento, à responsabilidade profissional e à qualificação dos profissionais também precisam ser solucionados para viabilizar o uso da IA em larga escala. Por fim, tais medidas podem favorecer a integração segura e eficaz da IA à prática clínica, reforçando seu papel como ferramenta complementar ao julgamento profissional, e não como substituta.

REFERÊNCIAS

ALALHARITH, D. M. et al. A deep learning-based approach for the detection of early signs of gingivitis in orthodontic patients using faster region-based convolutional neural networks. **International Journal of Environmental Research and Public Health**, v. 17, n. 22, p. 8447, 2020.

ALIFERIS, Constantin; SIMON, Gyorgy. Overfitting, Underfitting and General Model Overconfidence and Under-Performance: Pitfalls and Best Practices in Machine Learning and AI. In: **ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING IN HEALTH CARE AND MEDICAL SCIENCES: BEST PRACTICES AND PITFALLS**, 2024. Disponível em: <https://www.ncbi.nlm.nih.gov/books/NBK610560/>. Acesso em: 29 jul. 2025.

ALMEIDA, Gabriel Carvalho. Associação da doença periodontal e o diabetes: revisão de literatura. 2022. 32 f. Trabalho de Conclusão de Curso (Graduação em Odontologia) — **Universidade Federal de Sergipe**, 2022.

ALOTAIBI, G. et al. Artificial intelligence (AI) diagnostic tools: Utilizing a convolutional neural network (CNN) to assess periodontal bone level radiographically—A retrospective study. **BMC Oral Health**, v. 22, n. 1, p. 399, 2022.

BARBOSA, L. M.; PORTES, L. A. F. A inteligência artificial. **Revista Tecnologia Educacional** [online], Rio de Janeiro, n. 236, p. 16-27, 2023.

BARBOSA, M. D. S.; DA ROCHA TUNES, U. Nova classificação das doenças e condições periodontais e peri-implantares. **Journal of Dentistry & Public Health**, v. 9, n. 3, p. 184-186, 2018.

BASHIR, Nasir Z.; RAHMAN, Zahid; CHEN, Sam Li-Sheng. Systematic comparison of machine learning algorithms to develop and validate predictive models for periodontitis. **Journal of Clinical Periodontology**, [S.l.], v. 49, n. 10, p. 958–969, 2022. Disponível em: <https://doi.org/10.1111/jcpe.13692>. Acesso em: 26 set. 2025.

BRASIL. Ministério da Saúde. SB Brasil 2010: Pesquisa Nacional de Saúde Bucal: resultados principais. Brasília, DF: **Ministério da Saúde**, 2012. Disponível em: <http://www.saude.gov.br/bvs>. Acesso em: 26 set. 2025.

BRASIL. Ministério da Saúde. Ministério da Saúde planeja inclusão de inteligência artificial no SUS. **Agência Brasil**, Brasília, 22 maio 2023. Disponível em: <https://agenciabrasil.ebc.com.br/saude/noticia/2023-05/ministerio-da-saude-planeja-inclusao-de-inteligencia-artificial-no-sus>. Acesso em: 1 maio 2025.

BRASIL. **Senado Federal**. Projeto de Lei n.º 2.338, de 2023. Dispõe sobre a utilização da inteligência artificial no Brasil. 2023. Disponível em: <https://www25.senado.leg.br/web/atividade/materias/-/materia/162065>. Acesso em: 29 jul. 2025.

COELHO, Denilson Belo. Aprendizado de máquinas inserido no ambiente da inteligência artificial. 2020. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – **Instituição Educacional Anhanguera de Niterói**, Niterói, 2020.

CHEN, Ivane Delos Santos et al. Deep learning-based recognition of periodontitis and dental caries in dental x-ray images. **Bioengineering**, v. 10, n. 8, p. 911, 2023.

DA SILVA, Gabriela Gomes; PAIXÃO, Hugo; DE ACIOLY RODRIGUES, Mariana Luiza. Desafios do uso da inteligência artificial nos diagnósticos de saúde: uma revisão integrativa. **Cadernos Ibero-Americanos de Direito Sanitário**, v. 13, n. 2, p. 11-18, 2024.

DE MOURA CHAVES, M. F. et al. Interconexão entre diabetes e periodontite: impactos na saúde bucal e sistêmica. **Brazilian Journal of Implantology and Health Sciences**, v. 6, n. 2, p. 1365-1373, 2024.

DENG, K.; ZONTA, F.; YANG, H.; PELEKOS, G.; TONETTI, M. S. Development of a machine learning multiclass screening tool for periodontal health status based on non-clinical parameters and salivary biomarkers. **Journal of Clinical Periodontology**, [S.l.], v. 51, n. 12, p. 1547–1560, 2024

DOURADO, Daniel de Araújo; AITH, Fernando Mussa Abujamra. A regulação da inteligência artificial na saúde no Brasil começa com a Lei Geral de Proteção de Dados Pessoais. **Revista de Saúde Pública**, v. 56, p. 80, 2022.

DU, Getao et al. Medical image segmentation based on U-net: A review. **Journal of Imaging Science & Technology**, v. 64, n. 2, 2020.

EZHOV, M.; GUSAREV, M.; GOLITSYNA, M.; YATES, J. M.; KUSHNEREV, E.; TAMIMI, D.; AKSOY, S.; SHUMILOV, E.; SANDERS, A.; ORHAN, K. Clinically applicable artificial intelligence system for dental diagnosis with CBCT. **Scientific Reports**, [S.l.], v. 11, p. 22217, 2021. Disponível em: <https://doi.org/10.1038/s41598-021-94093-9>. Acesso em: 26 set. 2025.

FERES, M. et al. Differentiation by machine learning using support vector machines between aggressive and chronic periodontitis using microbial profiles. **International Dental Journal**, v. 68, n. 1, p. 39–46, 2018.

FERNANDES, Sara Raquel Matos. Dysbiotic biofilms increase the inflammatory response in periodontitis. 2017. **Tese de Doutorado**.

GBD 2021 ORAL DISORDERS COLLABORATORS. Tendências na carga global, regional e nacional de condições orais de 1990 a 2021: uma análise sistemática para o Estudo Global de Carga de Doença 2021. **The Lancet**, v. 405, p. 897–910, mar. 2025.

GUNDELLY, M.; PUSULURI, S. V.; KODUGANTI, R. R.; AMBATI, M.; CHILUVERU, S.; CHANDAKA, M. Precision medicine in periodontics: a literature review. **Cureus**, v. 16, n. 9, p. e68952, 2024. Disponível em: <https://doi.org/10.7759/cureus.68952>. Acesso em: 28 jan. 2025.

HAJISHENGALLIS, George; CHAVAKIS, Triantafyllos; LAMBRIS, John D. Current understanding of periodontal disease pathogenesis and targets for host-modulation therapy. **Periodontology** 2000, v. 84, n. 1, p. 14–34, 2020.

HU, J.; SZYMCAK, S. A review on longitudinal data analysis with random forest. **Briefings in bioinformatics**, v. 24, n. 2, 2023.

IÇOZ, Derya; TERZİOĞLU, Hakan; ÖZEL, Mustafa Aydın; KARAKURT, Ramazan. Evaluation of an artificial intelligence system for the diagnosis of apical periodontitis on digital panoramic images. **Nigerian Journal of Clinical Practice**, [S.l.], v. 26, n. 8, p. 1085–1090, 2023. Disponível em: https://doi.org/10.4103/njcp.njcp_624_22. Acesso em: 26 set. 2025.

JARDIM, Jerusa Jobim et al. **Inteligência artificial aplicada aos exames de imagem odontológicos: uma revisão da literatura**. Revista da Faculdade de Odontologia de Porto Alegre, v. 64, p. e128781-e128781, 2023.

JEPSEN, S. et al. Periodontal manifestations of systemic diseases and developmental and acquired conditions: consensus report of workgroup 3 of the 2017 World Workshop on the Classification of Periodontal and Peri-Implant Diseases and Conditions. **Journal of Clinical Periodontology**, v. 45, p. S219–S229, 2018.

JIANG, L.; CHEN, D.; CAO, Z.; WU, F.; ZHU, H.; ZHU, F. A two-stage deep learning architecture for radiographic staging of periodontal bone loss. **BMC Oral Health**, [S.l.], v. 22, n. 106, p. 1–9, 2022. Disponível em: <https://doi.org/10.1186/s12903-022-02119-z>. Acesso em: 26 set. 2025.

JUNDAENG, J.; CHAMCHONG, R.; NITHIKATHKUL, C. Periodontitis diagnosis: a review of current and future trends in artificial intelligence. **Technology and Health Care**, [S.l.], v. 32, n. 1, p. 1–10, jan. 2024. Disponível em: <https://doi.org/10.3233/THC-241169>. Acesso em: 22 jul. 2025.

KHAN, Safiya Fatima et al. Artificial intelligence in periodontology and implantology—a narrative review. **Journal of Medical Artificial Intelligence**, v. 7, 2024.

KIM, Jaeyoung et al. DeNTNet: deep neural transfer network for the detection of periodontal bone loss using panoramic dental radiographs. **Scientific Reports**, [S.l.], v. 9, p. 17615, nov. 2019. Disponível em: <https://doi.org/10.1038/s41598-019-53758-2>. Acesso em: 22 jul. 2025.

KROIS, J. et al. Deep learning for the radiographic detection of periodontal bone loss. **Scientific Reports**, v. 9, n. 1, p. 8495, 2019.

LEE, Jae-Hong et al. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. **Journal of periodontal & implant science**, v. 48, n. 2, p. 114–123, 2018.

LI, W.; GUO, E.; ZHAO, H.; LI, Y.; MIAO, L.; LIU, C.; SUN, W. Evaluation of transfer ensemble learning-based convolutional neural network models for the identification of chronic gingivitis from oral photographs. **BMC Oral Health**, [S.l.], v. 24, n. 1, p. 814, 2024. Disponível em: <https://doi.org/10.1186/s12903-024-04460-x>. Acesso em: 26 set. 2025.

LUDERMIR, Teresa Bernarda. Inteligência artificial e aprendizado de máquina: estado atual e tendências. **Estudos Avançados**, [S.l.], v. 35, n. 101, p. 85-94, abr. 2021. Disponível em: <https://doi.org/10.1590/s0103-4014.2021.35101.007>. Acesso em: 22 jul. 2025.

MANJUNATHA, V. Artificial intelligence in periodontics: Transforming the future of periodontal care. **International journal of maxillofacial imaging**, [s. l.], v. 10, n. 3, p. 129–131, 2024. Disponível em: <https://doi.org/10.18231/j.ijmi.2024.028>

MONTERO, Eduardo; SÁNCHEZ, Nerea; SANZ-SÁNCHEZ, Ignacio; LÓPEZ-DURÁN, Mercedes; CARRILLO DE ALBORNOZ, Ana; DIETRICH, Thomas. Emerging technologies and algorithms for periodontal screening and risk of disease progression in non-dental settings: a scoping review. **Journal of Clinical Periodontology**, [S.l.], v. 52, n. S29, p. 246-291, jun. 2025. Disponível em: <https://doi.org/10.1111/jcpe.14168>. Acesso em: 22 jul. 2025

NETO, Raimundo Nonato da Silva Neves; CAMARDELA, Thiago Willian Meireles; DE CARVALHO, Helder Donizeti. Inteligência Artificial na Odontologia: avanços tecnológicos, desafios éticos e diretrizes para uma aplicação responsável no Brasil. **Brazilian Journal of Health Review**, v. 8, n. 2, p. e79411-e79411, 2025.

PARIHAR, Anuj Singh et al. Artificial intelligence in periodontics: a comprehensive review. **Journal of Pharmacy and Bioallied Sciences**, v. 16, n. Suppl 3, p. S1956-S1958, 2024.

PATEL, M. S. et al. Impact of artificial intelligence on periodontology: a review. **Cureus**, [S.l.], v. 17, n. 3, e81162, 25 mar. 2025. DOI: <https://doi.org/10.7759/cureus.81162>.

PITCHIKA, Vinay; BUTTNER, Martha; SCHWENDICKE, Falk. Artificial intelligence and personalized diagnostics in periodontology: a narrative review. **Periodontology 2000**, v. 95, n. 1, p. 220–231, 2024. DOI: <https://doi.org/10.1111/prd.12586>. Acesso em: 7 set. 2024.

PRAJAPATI, Anil Kumar. An Optimal Solution to the Overfitting and Underfitting Problem of Healthcare Machine Learning Models. **Journal of Systems Engineering and Information Technology**, v. 2, n. 2, p. 77-84, out. 2023. DOI: 10.29207/joseit.v2i2.5460.

PRESHAW, P. M.; BISSETT, S. M. Periodontitis and diabetes. **British dental journal**, v. 227, n. 7, p. 577–584, 2019.

RATTI, Helena Soares. **Responsabilidade civil perante erros causados por sistemas de inteligência artificial**. 2024. Trabalho de conclusão de curso (Bacharelado em Direito) – Universidade Presbiteriana Mackenzie, São Paulo, 2024.

RAKIC, Mia et al. A roadmap towards precision periodontics. **Medicina**, v. 57, n. 3, p. 233, 2021.

REIS, Gustavo F. G.; ROMERO, Milton E. R. **Controle PID em Redes Neurais Convolucionais**. 2024. Trabalho de conclusão de curso (Bacharelado em Engenharia Elétrica) – Universidade Federal de Mato Grosso do Sul, Campo Grande, 2024.

REVILLA-LEÓN, Marta; GÓMEZ-POLO, Miguel; BARMAK, Abdul B.; INAM, Wardah; KAN, Joseph Y. K.; KOIS, John C.; AKAL, Orhan. Artificial intelligence models for diagnosing gingivitis and periodontal disease: a systematic review. **The Journal of Prosthetic Dentistry**, v. 130, n. 6, p. 816–824, 2023. DOI: <https://doi.org/10.1016/j.prosdent.2022.01.026>. Acesso em: 23 jul. 2025.

RODRIGUES, Katryne Targino et al. Associação entre condições sistêmicas e gravidade da doença periodontal em pacientes atendidos na Clínica-Escola da UFCG. **Revista de Odontologia da UNESP**, v. 49, p. e20200025, 2020.

RÖSING, Cassiano Kuchenbecker et al. Periodontal disease and its impact on general health in Latin America. Section IV: Diagnosis. **Brazilian Oral Research**, v. 34, p. e022, 2020. Disponível em: <https://www.scielo.br/j/bor/a/R5LCs3KGW8FwWd3Tgc3n4Ng/>. Acesso em: 17 set. 2025.

SIDDIQUE, N.; SIDIKE, P.; ELKIN, C.; DEVABHAKTUNI, V. U-Net and its variants for medical image segmentation: a review of theory and applications. **IEEE Access**, v. 9, p. 82031-82057, 2021. DOI: <https://doi.org/10.1109/ACCESS.2021.3086020>.

ONODY, Roberto Nicolau. **Teste de Turing e inteligência artificial**. 2021. Tese (Doutorado em Física) – Universidade de São Paulo, Instituto de Física de São Carlos, São Carlos, 2021. Disponível em: <https://www2.ifsc.usp.br/portal-ifsc/teste-de-turing-e-inteligencia-artificial/>. Acesso em: 7 nov. 2023.

OSSOWSKA, A.; KUSIAK, A.; ŚWIETLIK, D. Artificial intelligence in dentistry—Narrative review. **International Journal of Environmental Research and Public Health**, v. 19, n. 6, p. 3449, 2022.

ŞALGÄU, C. A.; MORAR, A.; ZGARTA, A. D. et al. Applications of machine learning in periodontology and implantology: a comprehensive review. **Annals of Biomedical Engineering**, v. 52, p. 2348–2371, 2024. Disponível em: <https://doi.org/10.1007/s10439-024-03559-0>. Acesso em: 11 set. 2024.

SANTAMARIA, P.; TROIANO, G.; SERRONI, M.; ARAÚJO, T. G.; RAVIDÀ, A.; NIBALI, L. Exploring the accuracy of tooth loss prediction between a clinical periodontal prognostic system and a machine learning prognostic model. **Journal of Clinical Periodontology**, v. 51, n. 8, p. 1061–1069, 2024. Disponível em: <https://doi.org/10.1111/jcpe.14023>. Acesso em: 6 set. 2024.

SANTANA, J. H. da C. Random Forest: uma abordagem poderosa para aprendizado de máquina. Paracambi: **Faculdade de Educação Tecnológica do Estado do Rio de Janeiro**, 2023.. Disponível em: https://www.academia.edu/109016063/Random_Forest_Uma_Abordagem_Poderosa_para_Aprendizado_de_Máquina. Acesso em: 2 maio 2025.

ŞALGÄU, C. A.; MORAR, A.; ZGARTA, A. D. et al. Applications of machine learning in periodontics and implantology: a comprehensive review. **Annals of Biomedical Engineering**, v. 52, p. 2348-2371, 2024. Disponível em: <https://doi.org/10.1007/s10439-024-03559-0>. Acesso em: 11 set. 24

SAVEGNAGO, Gleica et al. Inteligência artificial na odontologia: uma revisão narrativa de literatura. **Revista da Faculdade de Odontologia-UPF**, v. 29, n. 1, 2024.

SILVA, Julia Mombach. Vieses em aprendizado de máquina na saúde: uma abordagem baseada em complexidade de dados. In: XXXVI SALÃO DE INICIAÇÃO CIENTÍFICA, 2024, Porto Alegre. **Resumo publicado** [...] Porto Alegre: RS, 2024. Disponível em: <http://hdl.handle.net/10183/287368>. Acesso em: 24 set. 2025.

SOARES, Romerio Alves et al. O uso da inteligência artificial na medicina: aplicações e benefícios. **Research, Society and Development**, v. 12, n. 4, p. e5012440856-e5012440856, 2023.

SOUZA, V. S. S. **Introdução à interpretabilidade de redes neurais convolucionais**. 2025. Monografia. Disponível em: <https://monografias.ufop.br/handle/35400000/5358>. Acesso em: 25 set. 2025.

STEFFENS, João Paulo; MARCANTONIO, Rosemary Adriana Chiéríci. Classificação das doenças e condições periodontais e peri-implantares 2018: guia prático e pontos-chave. **Revista de Odontologia da UNESP**, v. 47, p. 189-197, 2018.

TAULLI, Tom. Introdução à Inteligência Artificial: Uma abordagem não técnica. **Novatec Editora**, 2020.

THANATHORNWONG, Bhornsawan; SUEBNUKARN, Siriwan. Automatic detection of periodontal compromised teeth in digital panoramic radiographs using faster regional convolutional neural networks. **Imaging Science in Dentistry**, v. 50, n. 2, p. 169, 2020.

TRINDADE, D. et al. Prevalência de periodontite em pessoas dentadas entre 2011 e 2020: Uma revisão sistemática e meta-análise de estudos epidemiológicos. **Journal of clinical periodontology**, v. 50, n. 5, p. 604–626, 2023.

VIEIRA, A. R. **Síndrome de Papillon-Lefèvre: aspectos clínicos e genéticos**. 2010. Dissertação (Mestrado em Odontologia) – Universidade de São Paulo, São Paulo, 201

YOU, Fu-Tzu et al. Artificial intelligence with counseling on the treatment outcomes and quality of life in periodontitis patients. **Journal of Periodontology**, 2024.