Revista Eletrônica ACERVO CIENTÍFICO
ISSN 2595-7899

A utilização da Inteligência artificial (IA) como ferramenta de auxílio ao diagnóstico odontológico em radiografias panorâmicas

The use of Artificial Intelligence (AI) as a tool to assist in dental diagnosis using panoramic radiographs

El uso de la Inteligencia Artificial (IA) como herramienta de apoyo al diagnóstico odontológico en radiografías panorámicas

Nathan do Couto Fiegenbaum[1], Vinícius Guarienti[1], Gaspar Vinicius Girardi[1].

RESUMO

Objetivo: Avaliar a eficácia e a aplicabilidade de uma ferramenta de Inteligência Artificial (IA) baseada em Deep Learning como instrumento de triagem e suporte ao diagnóstico em radiografias panorâmicas. **Métodos:** Trata-se de um estudo observacional transversal, realizado a partir de uma amostra de conveniência de 40 radiografias digitais com laudos técnicos prévios (padrão de referência). As imagens foram processadas por uma plataforma de IA (DIO Inteligência Odontológica) e os relatórios gerados foram comparados aos laudos originais através de matriz de confusão e análise qualitativa para cálculo de acurácia, sensibilidade e especificidade. **Resultados:** A análise de 1.452 pontos de observação indicou uma acurácia global de 67,9%, com sensibilidade de 68,8% e especificidade de 67,5%. A análise qualitativa revelou limitações da IA na interpretação espacial (dentes inclusos e migração dentária), gerando erros de sequenciamento. Em contrapartida, a ferramenta demonstrou alta capacidade na detecção de achados subclínicos, como cáries incipientes e rarefações ósseas sutis. **Conclusão:** Conclui-se que a IA analisada apresenta desempenho moderado, não substituindo o diagnóstico profissional, mas atuando eficazmente como ferramenta de triagem e alerta para otimizar o fluxo clínico sob supervisão humana.

Palavras-chave: Inteligência artificial, Radiografia panorâmica, Diagnóstico por imagem.

ABSTRACT

Objective: To evaluate the effectiveness and applicability of a Deep Learning–based Artificial Intelligence (AI) tool as a screening and diagnostic support instrument in panoramic radiographs. **Methods:** This is a cross-sectional observational study conducted using a convenience sample of 40 digital radiographs with previously issued technical reports (reference standard). The images were processed using an AI platform (DIO Inteligência Odontológica), and the generated reports were compared with the original reports through a confusion matrix and qualitative analysis to calculate accuracy, sensitivity, and specificity. **Results:** The analysis of 1,452 observation points indicated an overall accuracy of 67.9%, with a sensitivity of 68.8% and a specificity of 67.5%. Qualitative analysis revealed limitations of the AI in spatial interpretation (impacted teeth and dental migration), leading to sequencing errors. Conversely, the tool demonstrated a high capacity for

[1] Atitus Educação, Passo Fundo – RS.

SUBMETIDO EM: 4/2026 | **ACEITO EM: 5/2026** | **PUBLICADO EM: 5/2026**

detecting subclinical findings, such as incipient caries and subtle bone rarefactions. **Conclusion:** The evaluated AI system demonstrated moderate performance, not replacing professional diagnosis but functioning effectively as a screening and alert tool to optimize clinical workflow under human supervision.

Keywords: Artificial intelligence, Panoramic radiography, Diagnostic imaging.

RESUMEN

Objetivo: Evaluar la eficacia y aplicabilidad de una herramienta de Inteligencia Artificial (IA) basada en Deep Learning como instrumento de cribado y apoyo diagnóstico en radiografías panorámicas. **Métodos:** Se trata de un estudio observacional transversal realizado a partir de una muestra por conveniencia de 40 radiografías digitales con informes técnicos previos (patrón de referencia). Las imágenes fueron procesadas mediante una plataforma de IA (DIO Inteligência Odontológica), y los informes generados se compararon con los informes originales mediante una matriz de confusión y un análisis cualitativo para el cálculo de la precisión, sensibilidad y especificidad. El estudio fue aprobado por el Comité de Ética en Investigación. **Resultados:** El análisis de 1.452 puntos de observación indicó una precisión global del 67,9%, con una sensibilidad del 68,8% y una especificidad del 67,5%. El análisis cualitativo reveló limitaciones de la IA en la interpretación espacial (dientes incluidos y migración dentaria), generando errores de secuenciación. Por otro lado, la herramienta demostró una alta capacidad para detectar hallazgos subclínicos, como caries incipientes y rarefacciones óseas sutiles. **Conclusión:** La IA evaluada presentó un desempeño moderado, sin sustituir el diagnóstico profesional, pero actuando eficazmente como herramienta de cribado y alerta para optimizar el flujo clínico bajo supervisión humana.

Palabras clave: Inteligencia artificial, Radiografía panorámica, Diagnóstico por imagen.

INTRODUÇÃO

A Odontologia tem experimentado avanços tecnológicos expressivos nas últimas décadas, particularmente no campo do diagnóstico por imagem, com o objetivo de aumentar a acurácia diagnóstica e otimizar a tomada de decisão clínica (SAVEGNAGO G, et al., 2024). Nesse contexto, a radiografia panorâmica consolidou-se como um dos exames mais utilizados na prática odontológica, por oferecer uma visão abrangente do complexo maxilomandibular em um único exame, sendo amplamente indicada para a avaliação de dentes impactados, alterações traumáticas e diversas patologias ósseas (JARDIM JJ, et al., 2023). No entanto, apesar de sua aplicabilidade clínica e acessibilidade, trata-se de uma técnica bidimensional, sujeita a limitações inerentes que impactam diretamente sua acurácia diagnóstica.

Do ponto de vista técnico, a radiografia panorâmica apresenta restrições relevantes relacionadas à sobreposição de estruturas anatômicas, distorções geométricas e magnificação desigual, além da perda de informações tridimensionais. Tais características tornam-se particularmente críticas na identificação de alterações sutis ou em regiões com elevada complexidade anatômica. Lesões em estágios iniciais, como alterações periapicais discretas, reabsorções incipientes ou defeitos ósseos de pequena extensão, podem não ser detectadas com precisão, especialmente em áreas de menor resolução espacial. Adicionalmente, variações anatômicas individuais e modificações decorrentes de intervenções cirúrgicas, traumas ou processos patológicos podem gerar padrões radiográficos atípicos, dificultando a interpretação e aumentando o risco de subdiagnóstico ou de resultados falso-positivos. Nesse cenário, a dependência da experiência do examinador e a variabilidade interobservador tornam-se fatores determinantes na qualidade do diagnóstico.

A interpretação de radiografias panorâmicas, portanto, permanece um processo complexo e, em certa medida, subjetivo, exigindo elevado nível de treinamento e atenção aos detalhes. Mesmo entre profissionais experientes, discrepâncias diagnósticas podem ocorrer, especialmente em casos limítrofes ou de baixa expressividade radiográfica. Diante dessas limitações, há uma crescente demanda por ferramentas capazes de auxiliar na análise das imagens, reduzindo a subjetividade e aumentando a reprodutibilidade dos achados.

Nesse contexto, a Inteligência Artificial (IA) tem emergido como uma tecnologia promissora na radiologia odontológica. Definida como um ramo da ciência da computação voltado ao desenvolvimento de sistemas capazes de simular processos cognitivos humanos, a IA permite o reconhecimento automatizado de padrões, aprendizado a partir de dados e suporte à tomada de decisão clínica (MENDES APS e MACEDO PTS, 2025). Entre suas principais abordagens, destacam-se o Machine Learning (ML) e o Deep Learning (DL), sendo este último frequentemente baseado em Redes Neurais Convolucionais (Convolutional Neural Networks – CNNs), que apresentam elevada capacidade de processamento de grandes volumes de dados e identificação de padrões complexos em imagens médicas (MARTINS CA, et al., 2025).

É essencial distinguir os diferentes papéis da Inteligência Artificial na prática clínica. A automação diagnóstica, entendida como a emissão de diagnósticos de forma autônoma, ainda apresenta limitações importantes, sobretudo pela dificuldade de generalização dos algoritmos frente à variabilidade clínica. Por outro lado, o uso da IA como ferramenta de apoio à decisão mostra-se mais consistente, atuando na identificação de padrões e na priorização de achados, sem substituir o julgamento profissional. Assim, a supervisão humana permanece indispensável para a validação e contextualização dos resultados. Além disso, muitos sistemas são desenvolvidos em bases controladas, o que pode superestimar seu desempenho, reforçando a necessidade de validação em cenários clínicos reais, mais heterogêneos e desafiadores.

Evidências recentes têm demonstrado o potencial da IA na análise de exames radiográficos odontológicos, com aplicações que incluem a detecção de cáries, lesões periapicais, alterações periodontais e outras condições bucais, frequentemente com desempenho comparável ao de especialistas em contextos específicos (JARDIM JJ, et al., 2023). Além disso, sistemas baseados em aprendizado profundo são capazes de realizar segmentação automática de estruturas anatômicas, identificação de anomalias e classificação de tecidos, contribuindo para maior eficiência no fluxo de trabalho clínico e redução do tempo de análise (OLIVEIRA JS, et al., 2025).

Apesar dos avanços, a implementação clínica da IA ainda enfrenta desafios relevantes, como a necessidade de grandes bases de dados para treinamento robusto dos algoritmos, padronização dos protocolos de aquisição de imagens e validação externa em diferentes populações e cenários clínicos (JARDIM JJ, et al., 2023). Ademais, é fundamental compreender a IA como uma ferramenta complementar ao julgamento clínico, e não como substituta do profissional, sendo imprescindível a supervisão humana na interpretação final dos achados.

Diante desse cenário, torna-se essencial avaliar o desempenho dessas tecnologias em condições clínicas reais, caracterizadas por variabilidade na qualidade das imagens e na apresentação das alterações anatômicas e patológicas. Assim, o presente estudo tem como objetivo avaliar a eficácia de uma plataforma comercial de Inteligência Artificial na análise de radiografias panorâmicas, comparando seu desempenho com laudos técnicos humanos previamente estabelecidos (BARBOSA MES, et al., 2025).

MÉTODOS

Trata-se de um estudo observacional transversal, com abordagem quantitativa e qualitativa. A amostra foi selecionada por conveniência e composta por 40 radiografias panorâmicas digitais de pacientes adultos (idade ≥ 18 anos), provenientes do banco de dados da clínica-escola da Atitus Educação (Passo Fundo/RS). Todas as imagens possuíam laudos radiográficos previamente emitidos por radiologistas de um laboratório parceiro da instituição, os quais foram adotados como padrão de referência (padrão-ouro) para o estudo.

Os critérios de inclusão foram: radiografias panorâmicas digitais de pacientes adultos; imagens com qualidade técnica adequada para diagnóstico; disponibilidade no banco de dados da clínica-escola; e presença de laudo radiológico prévio. Foram excluídas radiografias com artefatos técnicos que comprometessem a análise imagiológica e imagens de pacientes com histórico de cirurgias maxilofaciais extensas. A coleta de dados foi realizada de forma independente por um único pesquisador. Não foi necessário treinamento prévio para leitura das imagens, pois essa etapa consistiu exclusivamente na extração e organização de diagnósticos previamente estabelecidos nos laudos radiológicos, sem nova interpretação das imagens neste primeiro momento. Cada radiografia foi processada individualmente em uma plataforma de Inteligência Artificial, que gerou um relatório automatizado indicando condições anatômicas e patológicas

detectadas. As informações foram sistematicamente extraídas e organizadas em uma planilha estruturada no Microsoft Excel®, software também utilizado para a análise estatística. O processo de validação cruzada foi realizado linha a linha e elemento a elemento: para cada radiografia, os diagnósticos descritos no laudo original (padrão-ouro) foram registrados em uma coluna primária e comparados diretamente com os achados apontados pela IA em uma coluna subsequente.

Cada ponto de observação correspondeu à avaliação de uma condição clínica específica em um determinado elemento ou região da arcada - como presença ou ausência do dente, achados cariosos, restaurações (metálica ou em resina), cálculo dental, rarefações ósseas periapicais, reabsorção radicular, dentes impactados e supranumerários, entre outras alterações registradas nos laudos. Como cada exame continha múltiplos elementos passíveis de avaliação por diversas categorias de achados, um único exame gerava vários pontos de observação independentes, totalizando 1.452 comparações distribuídas ao longo dos 40 exames analisados. A análise dos dados foi conduzida em duas etapas complementares. Inicialmente, realizou-se uma análise quantitativa por meio de uma matriz de confusão, ferramenta amplamente utilizada para avaliar o desempenho de algoritmos de classificação e testes diagnósticos. Essa matriz cruza as predições do sistema com os dados reais (padrão-ouro), permitindo identificar acertos e erros do modelo. Cada comparação foi classificada sistematicamente conforme os critérios apresentados na **Tabela 1**.

Tabela 1 - Modelo esquemático dos critérios de classificação adotados.

Elemento	Achado (Padrão de Referência)	Predição da Inteligência Artificial	Classificação (Matriz de Confusão)
W	Presença de achado	Presença de achado	Verdadeiro Positivo (VP)
X	Ausência de achado	Ausência de achado	Verdadeiro Negativo (VN)
Y	Ausência de achado	Presença de achado	Falso Positivo (FP)
Z	Presença de achado	Ausência de achado	Falso Negativo (FN)

Fonte: Fiegenbaum NC, et al., 2026.

A partir dessa matriz, as ocorrências foram categorizadas em Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN), fornecendo os parâmetros necessários para o cálculo das métricas de desempenho. O processamento estatístico para obtenção da Acurácia Global, Sensibilidade e Especificidade foi realizado no Microsoft Excel®, aplicando-se as equações descritas por Fletcher RH, et al. (2014).

Posteriormente, foi realizada uma análise qualitativa dos dados com o objetivo de identificar padrões de erro, sua natureza clínica e possíveis justificativas morfológicas para as divergências. Os erros foram organizados em três categorias temáticas: (1) falhas na detecção de anomalias macroscópicas, incluindo dentes inclusos e supranumerários; (2) erros de sequenciamento topográfico, caracterizados pela renumeração incorreta de elementos em arcadas com ausências dentárias e migração; e (3) divergências em achados subclínicos, nas quais a IA identificou lesões cariosas incipientes ou rarefações ósseas discretas não relatadas no laudo de referência. Essa categorização permitiu distinguir as falhas sistêmicas da ferramenta de seu potencial como instrumento de triagem e alerta clínico.

O estudo seguiu rigorosamente os princípios éticos estabelecidos pelas Resoluções CNS nº 466/12 e 510/16 e foi aprovado pelo Comitê de Ética em Pesquisa da Atitus Educação (parecer nº 7.783.474, CAAE 89573225.3.0000.5319). Considerando a natureza retrospectiva da análise em banco de dados, todos os exames foram utilizados de forma totalmente anonimizada, garantindo a privacidade dos pacientes e justificando a dispensa de novo Termo de Consentimento Livre e Esclarecido (TCLE).

RESULTADOS

O processo de comparação entre as predições geradas pela Inteligência Artificial e os laudos de referência resultou em 1.452 pontos de observação clínica a partir das radiografias analisadas. A consolidação desses dados permitiu a construção da matriz de confusão final, na qual foram quantificadas as proporções de acertos e erros do algoritmo em relação ao padrão-ouro (**Tabela 2**).

Com base nos valores absolutos obtidos na matriz de confusão, foram calculadas as métricas de desempenho diagnóstico do sistema. A Acurácia Global foi utilizada para representar a capacidade geral de acerto do algoritmo. Complementarmente, calculou-se a Sensibilidade, que indica a capacidade da ferramenta em identificar corretamente achados anatômicos e patológicos presentes, e a Especificidade, que representa a capacidade do sistema em reconhecer corretamente a ausência de alterações descritas no laudo de referência (**Tabela 3**).

Tabela 2 - Resultado geral matriz de confusão.

	Laudo de Referência: Positivo (Achado Presente)	Laudo de Referência: Negativo (Achado Ausente)	Total (Predito pela IA)
IA: Positivo	**329 (VP)**	**317 (FP)**	**646**
IA: Negativo	**149 (FN)**	**657 (VN)**	**806**
Total	**478**	**974**	**1.452**

Fonte: Fiegenbaum NC, et al., 2026.

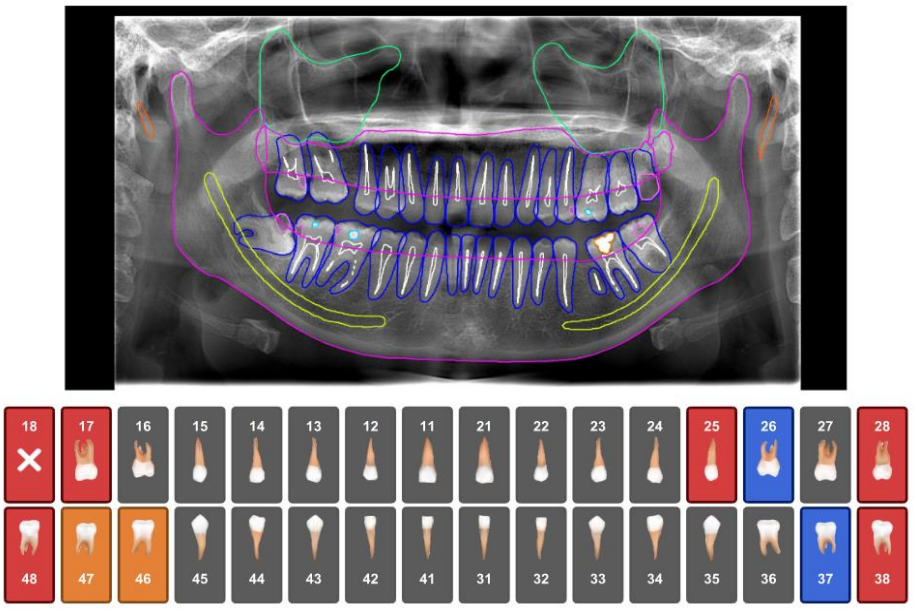
Tabela 3 - Métricas de desempenho diagnóstico da IA.

Métrica	Valor	Descrição
Acurácia Global	67,9%	Capacidade geral de acerto.
Sensibilidade	68,8%	Capacidade de identificar achados positivos.
Especificidade	67,5%	Capacidade de identificar achados negativos.

Fonte: Fiegenbaum NC, et al., 2026.

Os resultados quantitativos evidenciaram um desempenho global moderado do algoritmo. A análise qualitativa demonstrou que os erros de predição não ocorreram de maneira homogênea, revelando tanto falhas sistêmicas quanto um potencial diagnóstico auxiliar relevante. Observou-se uma falha sistemática na identificação de dentes supranumerários e inclusos, além de erros no sequenciamento topográfico em arcadas com ausências dentárias e migração dentária (mesialização ou distalização). Esses erros desencadearam um efeito cascata de diagnósticos incorretos. Em um dos casos avaliados, com ausência do elemento 16 e mesialização dentária, a plataforma não identificou o espaço edêntulo, classificando o elemento 17 como sendo o 16 e o elemento 18 como sendo o 17, além de indicar o elemento 18 real como ausente. Essa falha resultou no remapeamento incorreto da arcada e na atribuição de diagnósticos aos elementos dentários errados (**Figura 1**).

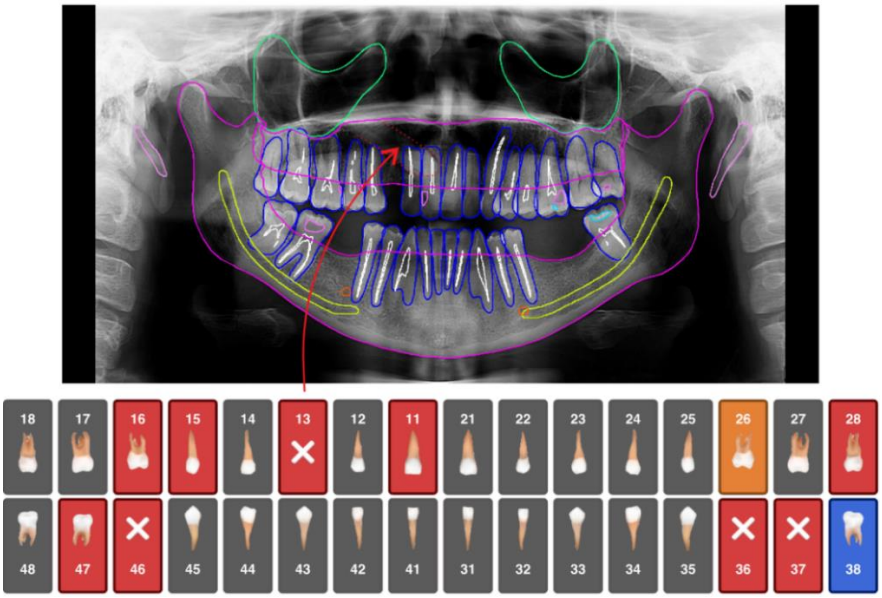
Figura 1 - Erro de sequenciamento da IA em arcada com ausência e migração dentária (Elemento 16 ausente).



Fonte: Fiegenbaum NC, et al., 2026.

Em relação às anomalias macroscópicas, a ferramenta não identificou dentes supranumerários ou inclusos presentes na amostra. Em uma radiografia com o elemento 13 incluso em mesioangulação, o algoritmo não reconheceu a alteração e classificou o dente como ausente no odontograma digital. Essa falha de detecção contribuiu para o aumento dos erros qualitativos e para o remapeamento incorreto da sequência anatômica da arcada (**Figura 2**).

Figura 2 - Falha da IA ao classificar o dente 13 incluso como ausente.



Fonte: Fiegenbaum NC, et al., 2026.

Por outro lado, ao desconsiderar os casos de erro de mapeamento topográfico, a plataforma demonstrou elevada granularidade na identificação de achados subclínicos. O sistema apresentou os resultados de forma individualizada por elemento dentário, diferentemente dos laudos de referência, que frequentemente apresentavam descrições agrupadas, como “cálculo generalizado”.

Além disso, a ferramenta identificou e destacou visualmente variações sutis de densidade radiográfica, sugerindo pequenas lesões cariosas incipientes e áreas de rarefação óssea difusa, como observado na região apical do elemento 11. Esses achados, que não estavam detalhadamente descritos no laudo padrão, evidenciam o potencial do algoritmo como ferramenta de rastreamento inicial e alerta visual (**Figura 3**).

Figura 3 - Detecção de rarefação óssea periapical sutil (elemento 11) pela IA.



Fonte: Fiegenbaum NC, et al., 2026.

DISCUSSÃO

O presente estudo avaliou o desempenho de uma ferramenta de inteligência artificial (IA) na interpretação de radiografias panorâmicas, demonstrando uma acurácia global de 67,9%, com sensibilidade de 68,8% e especificidade de 67,5%. Esses resultados indicam desempenho diagnóstico moderado do algoritmo quando aplicado a imagens provenientes de um cenário clínico real. A acurácia global de 67,9% encontrada neste estudo difere de pesquisas conduzidas em ambientes controlados, como a de De Angelis F, et al. (2022), que reportaram sensibilidade de 89%. Essa discrepância pode ser explicada pela maior variabilidade das imagens clínicas, incluindo diferenças de posicionamento do paciente, variações anatômicas e sobreposição de estruturas, características frequentemente presentes na prática clínica e que desafiam a generalização dos algoritmos de IA (BARBOSA MES, et al., 2025).

A natureza bidimensional da radiografia panorâmica impõe limitações diagnósticas relevantes, como a sobreposição de estruturas anatômicas e distorções geométricas, o que pode comprometer tanto a interpretação humana quanto a análise automatizada por algoritmos (ARAÚJO LCP, et al., 2025). Nesse contexto, a principal limitação observada no presente estudo foi a dificuldade de interpretação espacial em casos de migração dentária e ausência de elementos dentários. Esse achado corrobora a literatura atual, que atesta a ocorrência de diagnósticos automatizados errados devido à confusão de estruturas anatômicas muito próximas, como ocorre no apinhamento (KAHALIAN S, et al., 2024 apud MENDES APS e MACEDO PTS, 2025). Além disso, já está bem estabelecido que alterações na sequência anatômica natural da arcada representam um desafio metodológico expressivo para os algoritmos de IA (JARDIM JJ, et al., 2023).

Entre os principais padrões de erro identificados, destacaram-se falhas na identificação de dentes inclusos e supranumerários e erros no sequenciamento dentário em arcadas parcialmente edêntulas. Esses resultados sugerem limitações na capacidade do algoritmo em interpretar relações espaciais complexas em imagens bidimensionais. A segmentação automatizada de estruturas dentárias depende da identificação correta de marcos anatômicos e da manutenção da sequência topográfica da arcada, o que pode ser comprometido em casos de perda dentária, movimentação dentária ou alterações anatômicas relevantes.

Por outro lado, observou-se que, quando o mapeamento anatômico da arcada foi corretamente estabelecido, o sistema demonstrou elevada granularidade na identificação de alterações radiográficas sutis. A ferramenta foi capaz de destacar pequenas variações de densidade óssea e possíveis lesões cariosas iniciais que não estavam detalhadas no laudo radiológico de referência. Esse comportamento está alinhado com evidências da literatura que demonstram o potencial da inteligência artificial, particularmente de modelos baseados em redes neurais convolucionais, para identificar padrões radiográficos discretos que podem passar despercebidos durante a análise visual convencional (OLIVEIRA LPS, et al., 2025).

Além disso, a capacidade da IA de detectar lesões sutis também se relaciona com as observações de Carvalho VG, et al. (2025) sobre a subjetividade inerente à interpretação radiográfica humana. Nesse sentido, a IA pode funcionar como um “segundo par de olhos”, capaz de identificar variações discretas de densidade que podem não ser priorizadas em uma análise visual rápida. Esse papel complementar reforça o potencial da IA como ferramenta de suporte diagnóstico, especialmente em contextos de triagem.

De fato, revisões recentes indicam que sistemas de IA aplicados ao diagnóstico por imagem têm apresentado desempenho promissor na detecção de lesões dentárias, especialmente em estágios iniciais da doença. Algoritmos baseados em aprendizado profundo podem analisar grandes volumes de imagens e identificar padrões radiográficos com elevado nível de consistência, contribuindo para diagnósticos mais rápidos e potencialmente mais padronizados (MARTINS CA, et al., 2025). Entretanto, como destacado por Mendes APS e Macedo PTS (2025), o principal valor dessas tecnologias não reside na substituição do cirurgião-dentista, mas no suporte à tomada de decisão clínica, permitindo que o profissional concentre sua análise no julgamento clínico final.

Apesar desses avanços, a literatura enfatiza que o uso clínico da inteligência artificial ainda enfrenta desafios importantes. A confiabilidade dos algoritmos depende fortemente da qualidade e diversidade das bases de dados utilizadas em seu treinamento, bem como da padronização dos métodos de validação clínica

(CARVALHO VG, et al., 2025). Além disso, sistemas treinados em bases de dados específicas podem apresentar redução de desempenho quando aplicados a diferentes populações ou condições clínicas, reforçando a necessidade de validação em cenários clínicos reais.

Embora o desempenho global observado tenha sido classificado como moderado, esse nível de acurácia pode apresentar relevância clínica significativa quando interpretado no contexto de triagem. Em cenários clínicos reais, a capacidade da IA de sinalizar áreas suspeitas e chamar a atenção do examinador para possíveis alterações — especialmente aquelas de caráter subclínico — pode contribuir para a redução de falhas diagnósticas iniciais (OLIVEIRA LPS, et al., 2025). Nesse sentido, mesmo sistemas com sensibilidade e especificidade intermediárias podem agregar valor ao atuar como ferramenta de priorização de achados, direcionando o foco do profissional para regiões que merecem análise mais detalhada.

Entretanto, a utilização clínica desses sistemas deve considerar criticamente o impacto dos erros diagnósticos. Falsos positivos podem levar ao aumento de exames complementares, sobretratamento e maior custo clínico, além de potencial ansiedade ao paciente. Por outro lado, falsos negativos representam um risco ainda mais relevante, pois implicam na não detecção de alterações potencialmente significativas, retardando o diagnóstico e o início do tratamento. Dessa forma, o equilíbrio entre sensibilidade e especificidade torna-se essencial, reforçando a necessidade de utilização da IA como ferramenta de apoio, e não como substituta da avaliação clínica (MENDES APS e MACEDO PTS, 2025).

Quando comparados a estudos conduzidos em ambientes controlados, os resultados do presente trabalho evidenciam desempenho inferior, o que pode ser atribuído à maior complexidade dos dados clínicos reais. A presença de ausências dentárias, dentes inclusos, alterações topográficas e variações anatômicas amplia o grau de dificuldade interpretativa, diferindo substancialmente das bases de treinamento mais padronizadas. Essa heterogeneidade reforça que a validação em condições reais é indispensável para estimar com maior precisão a aplicabilidade clínica dos sistemas de IA (CARVALHO VG, et al., 2025).

Nesse contexto, os achados do presente estudo reforçam a perspectiva de que a inteligência artificial deve ser compreendida como uma ferramenta complementar ao diagnóstico odontológico, e não como substituta da interpretação clínica. A integração entre algoritmos de análise radiográfica e o julgamento clínico do cirurgião-dentista tende a oferecer maior segurança diagnóstica e melhor aproveitamento do potencial dessas tecnologias (OLIVEIRA LPS, et al., 2025).

CONCLUSÃO

A ferramenta de inteligência artificial avaliada apresentou desempenho moderado e equilibrado (sensibilidade de 68,8% e especificidade de 67,5%). Embora tenha demonstrado limitações relevantes na interpretação espacial e no sequenciamento de estruturas em casos complexos, os resultados evidenciam seu potencial como instrumento de triagem e suporte diagnóstico, particularmente na identificação de alterações subclínicas. Na prática clínica, a IA pode ser especialmente útil como sistema de alerta inicial, auxiliando na detecção precoce de achados discretos, na priorização de áreas de interesse e no apoio à documentação radiográfica, contribuindo para maior padronização e rastreabilidade das análises. Assim, sua integração ao fluxo de trabalho em radiologia odontológica deve ocorrer como recurso complementar, sempre sob rigorosa supervisão do cirurgião-dentista, responsável pela interpretação final e pela tomada de decisão clínica. Estudos futuros com amostras maiores, diferentes populações clínicas e validação multicêntrica permanecem essenciais para aprimorar sua confiabilidade e consolidar seu papel na prática clínica.

AGRADECIMENTOS E FINANCIAMENTO

Agradecimentos especiais ao Dr. Renan Lucio Berbel da Silva, Head de Radiologia da DIO Inteligência Odontológica, pela valiosa colaboração ao disponibilizar a plataforma para a pesquisa. Agradeço também à instituição Atitus Educação, pelo apoio fundamental no fornecimento dos exames que tornaram este estudo possível.

REFERÊNCIAS

1. ARAÚJO LCP, et al. A eficácia da radiologia na precisão diagnóstica na prática odontológica: uma revisão sistemática. Revista Contemporânea, 2025; 5(5): 1-20.
2. BARBOSA MES, et al. Uso da inteligência artificial na odontologia. Revista Multidisciplinar Integrada - REMI, 2025; 5: 1-12.
3. BONNY T, et al. Contemporary Role and Applications of Artificial Intelligence in Dentistry. F1000Research, 2023; 12: 1179.
4. CARVALHO VG, et al. Impacto da inteligência artificial na odontologia: revisão integrativa da literatura. In: Interfaces atuais da odontologia: conexões entre tecnologia, educação e humanização na saúde bucal. IMEA: João Pessoa-PB, 2025; p14-47.
5. DE ANGELIS F, et al. Artificial Intelligence: A New Diagnostic Software in Dentistry: A Preliminary Performance Diagnostic Study. Int. J. Environ. Res. Public Health, 2022; 19: 1728.
6. DHOPTE A, BAGDE H. Smart Smile: Revolutionizing Dentistry With Artificial Intelligence. Cureus, 2023; 15(6): e41227.
7. FLETCHER RH, et al. Epidemiologia Clínica: Elementos Essenciais. 5. ed. Porto Alegre: Artmed, 2014.
8. GIRI D, DONGR P. Artificial Intelligence - Future trend in Oral Diagnosis and Radiology. International Journal of Current Science Research and Review, 2022; 5(9): 1-5.
9. HEO MS, et al. Artificial intelligence in oral and maxillofacial radiology: what is currently possible?. Dentomaxillofac Radiol, 2021; 50: 20200375.
10. JARDIM JJ, et al. Inteligência artificial aplicada aos exames de imagem odontológicos – uma revisão da literatura. Revista da Faculdade de Odontologia de Porto Alegre, 2023; 64: 1-28.
11. MAIA DC, et al. Os desafios e impactos da inteligência artificial na radiologia: uma revisão sistemática. Revista de Ciências Biológicas e da Saúde, 2025; 15: 63-71.
12. MARTINS CA, et al. Análise da inteligência artificial no diagnóstico de lesões cariosas em radiografia interproximal: uma revisão de literatura. Brazilian Journal of Implantology and Health Sciences, 2025; 7(10): 751-769.
13. MENDES APS, MACEDO PTS. Uso da inteligência artificial na radiologia odontológica: revisão sistemática. JNT Facit Business and Technology Journal, 2025; 2(68): 400-412.
14. OLIVEIRA LPS, et al. Inteligência artificial no diagnóstico de lesões cariosas: revisão integrativa. Revista Odontológica de Araçatuba, 2025; 46(1): 32-38.
15. PEREIRA CAB, et al. Inteligência artificial aplicada aos exames de imagem: impactos na tomada de decisão clínica e na atuação multiprofissional em saúde. Revista de Geopolítica, 2026; 17(2): e1484.
16. PRADOS-PRIVADO M, et al. Dental Images Recognition Technology and Applications: A Literature Review. Appl. Sci., 2020; 10: 2856.
17. PRASANNAM RP, et al. Artificial intelligence in dental practice: a review. International Journal of Community Medicine and Public Health, 2023; 10(5): 1955-1960.
18. PUTRA RH, et al. Current applications and development of artificial intelligence for digital dental radiography. Dentomaxillofac Radiol, 2022; 51: 20210197.
19. SAVEGNAGO G, et al. Inteligência artificial na odontologia: uma revisão narrativa de literatura. Revista da Faculdade de Odontologia - UPF, 2024; 29(1)**:** 1-18.
20. SCHWENDICKE F, et al. Artificial Intelligence in Dentistry: Chances and Challenges. Journal of Dental Research, 2020; 99(7): 769-774.
21. SILVA TP, et al. Estado da arte da Inteligência Artificial (IA) na radiologia odontológica: revisão sistemática. Archives of Health Investigation, 2021; 10(7): 1084-1089.
22. THURZO A, et al. Where Is the Artificial Intelligence Applied in Dentistry? Systematic Review and Literature Analysis. Healthcare, 2022; 10: 1269.