v7.n8.2026

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

SISTEMA INTELIGENTE BASEADO EM VISÃO COMPUTACIONAL PARA APOIO À IDENTIFICAÇÃO INICIAL DE TRAUMATISMOS DENTÁRIOS

COMPUTER VISION-BASED INTELLIGENT SYSTEM TO SUPPORT THE INITIAL IDENTIFICATION OF DENTAL TRAUMA

SISTEMA INTELIGENTE BASADO EN VISIÓN ARTIFICIAL PARA APOYAR LA IDENTIFICACIÓN INICIAL DE TRAUMATISMOS DENTALES

Warley da Costa Silva[1], Marco Antônio de Souza Leite Cuadros[2], Renner Sartório Camargo[2], Pamela Barbosa dos Santos[3]

e788669
https://doi.org/10.47820/recima21.v7i8.8669

PUBLICADO: 08/2026

RESUMO

Os traumatismos dentários constituem uma condição que demanda identificação e orientação inicial adequadas, especialmente em situações nas quais o atendimento odontológico imediato pode não estar disponível. Este estudo desenvolveu um sistema inteligente baseado em visão computacional para apoio à identificação inicial de traumatismos dentários, integrando o modelo YOLO11n a uma arquitetura automatizada de comunicação e orientação ao usuário. Na etapa de visão computacional, foram utilizadas 1.142 imagens, distribuídas em quatro classes: avulsão, fratura pulpar, fratura de esmalte e fratura dentinária. O conjunto de dados foi dividido em 70% para treinamento, 20% para validação e 10% para teste do modelo YOLO11n. O desempenho obtido apresentou Precision de 66,58%, Recall de 70,52%, mAP@0.50 de 69,20%, mAP@0.50:0.95 de 36,35% e F1-Score de 0,67. Os resultados demonstram desempenho experimental moderado do modelo na identificação das classes de traumatismos dentários avaliadas. A arquitetura desenvolvida possibilitou a integração da visão computacional com o fluxo automatizado de comunicação e orientação ao usuário. A avaliação foi realizada em ambiente experimental, não envolvendo validação clínica prospectiva, comparação direta com cirurgiões-dentistas ou aplicação em ambiente assistencial real. Dessa forma, o sistema deve ser compreendido como uma ferramenta de apoio à identificação inicial e à orientação, não substituindo a avaliação realizada por um cirurgião-dentista.

PALAVRAS-CHAVE: Inteligência Artificial. Visão Computacional. Traumatismos Dentários.

ABSTRACT

Traumatic dental injuries require appropriate initial identification and guidance, particularly in situations where immediate dental care may not be available. This study developed an intelligent system based on computer vision to support the initial identification of traumatic dental injuries, integrating the YOLO11n model into an automated architecture for user communication and guidance. In the computer vision stage, 1,142 images were used, distributed into four classes: avulsion, pulp fracture, enamel fracture, and dentin fracture. The dataset was divided into 70% for training, 20% for validation, and 10% for testing of the YOLO11n model. The obtained performance achieved a Precision of 66.58%, Recall of 70.52%, mAP@0.50 of 69.20%, mAP@0.50:0.95 of 36.35%, and an F1-Score of 0.67.

[1] Mestrando em Engenharia de Controle e Automação (IFES). Graduado em Engenharia Elétrica (Multivix).
[2] Docente do Instituto Federal do Espírito Santo (IFES). Mestre e Doutor em Engenharia Elétrica (UFES).
[3] Doutoranda em Odontologia (UNICAMP). Graduada em Odontologia e Mestre em Ciências Odontológicas (UFES).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

The results demonstrate moderate experimental performance of the model in identifying the evaluated traumatic dental injury classes. The developed architecture enabled the integration of computer vision with an automated workflow for user communication and guidance. The evaluation was conducted in an experimental environment and did not include prospective clinical validation, direct comparison with dental surgeons, or assessment in a real healthcare setting. Therefore, the system should be understood as a tool to support initial identification and guidance and should not replace assessment by a dental surgeon.

KEYWORDS: *Artificial Intelligence. Computer Vision. Dental Trauma.*

RESUMEN

Los traumatismos dentales constituyen una condición que requiere una identificación y orientación inicial adecuadas, especialmente en situaciones en las que la atención odontológica inmediata puede no estar disponible. Este estudio desarrolló un sistema inteligente basado en visión por computadora para apoyar la identificación inicial de traumatismos dentales, integrando el modelo YOLO11n en una arquitectura automatizada de comunicación y orientación al usuario. En la etapa de visión por computadora, se utilizaron 1.142 imágenes, distribuidas en cuatro clases: avulsión, fractura pulpar, fractura del esmalte y fractura dentinaria. El conjunto de datos se dividió en un 70% para entrenamiento, un 20% para validación y un 10% para prueba del modelo YOLO11n. El desempeño obtenido presentó una Precision del 66,58%, un Recall del 70,52%, un mAP@0.50 del 69,20%, un mAP@0.50:0.95 del 36,35% y un F1-Score de 0,67. Los resultados demuestran un desempeño experimental moderado del modelo en la identificación de las clases de traumatismos dentales evaluadas. La arquitectura desarrollada permitió integrar la visión por computadora con un flujo automatizado de comunicación y orientación al usuario. La evaluación se realizó en un entorno experimental y no incluyó validación clínica prospectiva, comparación directa con cirujanos dentistas ni evaluación en un entorno asistencial real. Por lo tanto, el sistema debe entenderse como una herramienta de apoyo para la identificación inicial y la orientación, y no debe sustituir la evaluación realizada por un cirujano dentista.

PALABRAS CLAVE*: Inteligencia Artificial. Visión por Computadora. Traumatismos Dentales*

INTRODUÇÃO

Os traumatismos dentários constituem um importante problema de saúde pública devido à sua elevada incidência e aos impactos funcionais, estéticos, psicológicos e sociais decorrentes dessas lesões. Estudos epidemiológicos indicam que aproximadamente um quarto das crianças em idade escolar e cerca de um terço dos adultos sofrerão algum tipo de traumatismo dentário ao longo da vida, evidenciando a relevância clínica dessa condição e a necessidade de estratégias que favoreçam o diagnóstico e a intervenção precoces (Levin *et al.*, 2020).

A identificação rápida do tipo de traumatismo é determinante para a definição das condutas iniciais e pode influenciar diretamente o prognóstico clínico. Entretanto, o acesso imediato ao atendimento odontológico especializado nem sempre é possível, especialmente em situações de urgência ou em regiões com limitações de infraestrutura, tornando necessária a utilização de ferramentas que auxiliem o reconhecimento inicial das lesões e apoiem a tomada de decisão. Além disso, o crescimento das tecnologias digitais na área da saúde tem ampliado

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

as possibilidades de desenvolvimento de soluções computacionais capazes de oferecer suporte ao diagnóstico de forma mais ágil e acessível.

Nesse contexto, a Inteligência Artificial (IA) vem promovendo avanços significativos na saúde, especialmente por meio de técnicas de aprendizado profundo (*Deep Learning*) e Visão Computacional, que possibilitam a análise automatizada de imagens com elevados níveis de precisão. Essas tecnologias têm sido empregadas em diferentes especialidades médicas e odontológicas para identificação de alterações anatômicas, detecção de patologias, segmentação de estruturas e apoio à tomada de decisão clínica, contribuindo para maior eficiência e confiabilidade dos processos diagnósticos.

Entre as arquiteturas de detecção de objetos, a família YOLO (*You Only Look Once*) destaca-se pela capacidade de realizar inferências em tempo real, mantendo elevado desempenho na localização e classificação de objetos. Revisões recentes demonstram que modelos baseados em YOLO apresentam resultados promissores em aplicações odontológicas, incluindo detecção de cáries, estruturas dentárias, lesões e outras alterações clínicas, evidenciando o potencial dessa arquitetura para sistemas inteligentes de apoio ao diagnóstico.

Apesar desses avanços, observa-se que a maior parte das pesquisas se concentra em tarefas específicas de classificação ou detecção de imagens, havendo ainda uma limitada integração entre modelos de Visão Computacional e sistemas inteligentes capazes de disponibilizar os resultados de forma acessível aos usuários. Essa lacuna evidencia a necessidade de soluções que aliem elevado desempenho computacional, facilidade de utilização e potencial de aplicação em cenários reais de atendimento inicial.

Diante desse cenário, esta pesquisa justifica-se pela necessidade de desenvolver um sistema inteligente baseado em Visão Computacional capaz de apoiar o diagnóstico inicial de traumatismos dentários por meio da análise automatizada de imagens clínicas. A proposta busca contribuir para o avanço da aplicação da Inteligência Artificial na Odontologia, oferecendo uma ferramenta que possa auxiliar na identificação inicial das lesões e ampliar o acesso a tecnologias de apoio ao diagnóstico.

O objetivo geral deste trabalho é desenvolver um sistema inteligente baseado em Visão Computacional para o diagnóstico inicial de traumatismos dentários. Como objetivos específicos, pretende-se construir uma base de imagens clínicas representativa, treinar e validar um modelo de detecção utilizando a arquitetura YOLO, integrar o modelo desenvolvido a uma arquitetura computacional para disponibilização dos resultados e avaliar o desempenho da solução por meio de métricas consolidadas na literatura para problemas de detecção de objetos.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REFERENCIAL TEÓRICO

Traumatismos dentários

Os traumatismos dentários constituem um dos principais problemas de saúde bucal em todo o mundo, apresentando elevada incidência entre crianças, adolescentes e adultos jovens. Essas lesões podem resultar em comprometimentos funcionais, estéticos, psicológicos e sociais, além de demandarem tratamentos complexos e acompanhamento clínico prolongado. Estudos epidemiológicos estimam que aproximadamente 25% das crianças em idade escolar e cerca de um terço da população adulta sofrerão algum tipo de traumatismo dentário ao longo da vida, evidenciando a relevância dessa condição para os serviços de saúde (Levin *et al.*, 2020).

Os traumatismos dentários podem ser decorrentes de quedas, acidentes esportivos, colisões, acidentes de trânsito e episódios de violência, sendo classificados conforme o comprometimento das estruturas dentárias e dos tecidos de suporte. Entre as lesões mais frequentes destacam-se as fraturas de esmalte, fraturas coronárias, luxações e avulsões, cada uma apresentando diferentes níveis de gravidade e exigindo abordagens específicas para seu manejo clínico. A diversidade dessas manifestações torna o diagnóstico inicial uma etapa fundamental para o direcionamento adequado do atendimento odontológico.

O prognóstico dessas lesões está diretamente relacionado à rapidez com que são identificadas e às condutas adotadas nos primeiros momentos após o trauma. Em diversos casos, principalmente nas avulsões dentárias, atrasos na identificação da lesão podem comprometer significativamente as possibilidades de preservação do elemento dentário, aumentando a ocorrência de complicações e elevando os custos do tratamento. Dessa forma, estratégias que favoreçam o reconhecimento precoce dos traumatismos apresentam potencial para melhorar os desfechos clínicos e ampliar o acesso à informação em situações de urgência (Fouad *et al.*, 2020; GBD 2021 Oral Disorders Collaborators, 2025).

Nesse contexto, o avanço das tecnologias digitais e da Inteligência Artificial tem possibilitado o desenvolvimento de ferramentas capazes de auxiliar na identificação automática de lesões por meio da análise de imagens clínicas, abrindo novas perspectivas para o apoio ao diagnóstico inicial e à tomada de decisão em Odontologia.

Inteligência artificial aplicada à saúde e à odontologia

A Inteligência Artificial (IA) tem promovido avanços significativos na área da saúde ao possibilitar o desenvolvimento de sistemas capazes de analisar grandes volumes de dados, identificar padrões complexos e apoiar profissionais na tomada de decisão clínica. O crescimento

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

do poder computacional, aliado à disponibilidade de bases de dados e ao aprimoramento dos algoritmos de aprendizado de máquina, tem ampliado a aplicação dessas tecnologias em diversas especialidades médicas, contribuindo para diagnósticos mais rápidos, precisos e consistentes (Topol, 2019).

Entre as abordagens mais utilizadas destaca-se o aprendizado profundo (*Deep Learning*), que emprega redes neurais artificiais com múltiplas camadas para extrair automaticamente características relevantes dos dados. Diferentemente dos métodos tradicionais, essas arquiteturas reduzem a necessidade de extração manual de atributos, permitindo que o próprio modelo aprenda representações complexas a partir de grandes conjuntos de imagens e outras informações clínicas. Essa capacidade tem impulsionado aplicações em diagnóstico por imagem, segmentação de estruturas anatômicas, detecção de doenças e sistemas inteligentes de apoio à decisão.

Na Odontologia, a IA vem sendo empregada em diferentes aplicações, incluindo a identificação de cáries, doenças periodontais, lesões periapicais, alterações ósseas e traumatismos dentários. Estudos recentes demonstram que modelos baseados em aprendizado profundo apresentam elevado desempenho na interpretação de imagens odontológicas, contribuindo para aumentar a precisão diagnóstica e reduzir o tempo necessário para análise clínica. Além disso, essas tecnologias favorecem a padronização das avaliações e podem atuar como ferramentas auxiliares ao cirurgião-dentista, especialmente em ambientes com acesso limitado a especialistas.

Apesar dos resultados promissores, desafios importantes ainda precisam ser superados para ampliar a utilização da IA em cenários clínicos reais. Entre eles destacam-se a escassez de bases de imagens anotadas por especialistas, a variabilidade das imagens obtidas em diferentes condições de iluminação e qualidade, além da necessidade de validação contínua dos modelos desenvolvidos. Nesse contexto, pesquisas têm investido na construção de bases de dados mais robustas, no uso de técnicas de aumento artificial de dados (*data augmentation*) e no desenvolvimento de arquiteturas capazes de oferecer maior capacidade de generalização, tornando os sistemas mais confiáveis para aplicações em saúde.

Dentre as diversas áreas da Inteligência Artificial aplicadas ao diagnóstico por imagem, a Visão Computacional destaca-se por possibilitar a identificação automática de objetos, estruturas e padrões em imagens digitais, tornando-se um dos principais pilares para o desenvolvimento de sistemas inteligentes voltados ao apoio ao diagnóstico odontológico.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Visão computacional e arquiteturas YOLO

A Visão Computacional constitui uma das principais áreas da Inteligência Artificial, dedicada ao desenvolvimento de métodos capazes de interpretar e compreender informações presentes em imagens e vídeos de forma automatizada. Seu objetivo é permitir que sistemas computacionais identifiquem objetos, padrões, características e relações espaciais, reproduzindo, em parte, a capacidade humana de percepção visual. Nos últimos anos, os avanços em aprendizado profundo (*Deep Learning*) impulsionaram significativamente essa área, tornando possível o desenvolvimento de modelos com elevada precisão para aplicações em saúde, indústria, agricultura e segurança (Goodfellow; Bengio; Courville, 2016).

Na área da saúde, a Visão Computacional tem sido amplamente empregada para apoiar o diagnóstico por imagem, possibilitando a identificação automática de alterações anatômicas e patologias em exames médicos e odontológicos. Na Odontologia, essas técnicas vêm sendo utilizadas na detecção de cáries, doenças periodontais, lesões periapicais, dentes impactados, anomalias craniofaciais e traumatismos dentários, contribuindo para aumentar a precisão diagnóstica, reduzir o tempo de análise e padronizar a interpretação das imagens (Huang *et al.*, 2024; Hua *et al.*, 2025).

Grande parte desses avanços tornou-se possível com a utilização das Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNNs), arquiteturas capazes de aprender automaticamente características relevantes das imagens por meio de sucessivas operações de convolução, ativação e agrupamento (*pooling*). Diferentemente das técnicas tradicionais de processamento de imagens, as CNNs dispensam a extração manual de atributos, permitindo que o modelo identifique padrões complexos diretamente a partir dos dados de treinamento. Essa característica tornou as CNNs a base da maioria dos sistemas modernos de reconhecimento e classificação de imagens.

Entre as diferentes tarefas executadas pela Visão Computacional, a detecção de objetos destaca-se por permitir não apenas identificar a presença de um objeto em uma imagem, mas também localizar sua posição por meio de caixas delimitadoras (*bounding boxes*). Essa abordagem é especialmente relevante para aplicações odontológicas, pois possibilita identificar simultaneamente diferentes tipos de lesões e indicar sua localização precisa, fornecendo informações importantes para sistemas de apoio ao diagnóstico.

Nesse cenário, a família de arquiteturas **YOLO (*You Only Look Once***) tornou-se uma das principais referências em detecção de objetos em tempo real. Diferentemente de métodos baseados em múltiplas etapas, a YOLO realiza a localização e a classificação dos objetos em

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

uma única passagem pela rede neural, proporcionando elevada velocidade de processamento sem comprometer significativamente a precisão. Essa característica favorece sua utilização em aplicações que exigem respostas rápidas, como sistemas inteligentes de apoio ao diagnóstico, monitoramento em tempo real e dispositivos móveis (Redmon *et al.*, 2016).

A evolução contínua da arquitetura YOLO resultou em versões progressivamente mais eficientes, incorporando melhorias relacionadas à precisão, velocidade de inferência e capacidade de detectar objetos de pequenas dimensões. Trabalhos recentes demonstram que essas arquiteturas apresentam desempenho competitivo em aplicações odontológicas, alcançando elevados índices de sensibilidade e especificidade na identificação de diferentes alterações clínicas. Além disso, sua capacidade de processamento em tempo real torna a YOLO particularmente adequada para sistemas que necessitam fornecer respostas imediatas aos usuários, característica essencial em cenários de atendimento inicial (Hua *et al.*, 2025).

Considerando essas características, a arquitetura YOLO foi adotada neste trabalho como modelo de detecção de objetos para identificação automática dos traumatismos dentários. Sua elevada eficiência computacional, aliada à capacidade de localizar e classificar diferentes tipos de lesões em uma única etapa de processamento, torna essa arquitetura adequada ao desenvolvimento de sistemas inteligentes voltados ao apoio ao diagnóstico inicial.

Sistemas inteligentes para apoio ao diagnóstico

Os sistemas inteligentes representam uma das principais aplicações da Inteligência Artificial, sendo desenvolvidos para simular processos de raciocínio e tomada de decisão em diferentes contextos. Na área da saúde, essas soluções têm sido amplamente utilizadas para apoiar profissionais durante o diagnóstico, interpretação de exames e planejamento terapêutico, proporcionando maior agilidade, padronização e confiabilidade na análise das informações clínicas (Russell; Norvig, 2022).

O avanço das técnicas de Visão Computacional e dos modelos de aprendizado profundo possibilitou a construção de sistemas capazes de analisar imagens médicas e odontológicas de forma automatizada, reduzindo o tempo necessário para identificação de alterações e contribuindo para o apoio à tomada de decisão. Entretanto, o desempenho desses sistemas depende não apenas da qualidade dos modelos de detecção, mas também da integração entre diferentes componentes computacionais responsáveis pelo processamento, interpretação e disponibilização das informações ao usuário.

Nesse contexto, arquiteturas integradas têm recebido crescente atenção por combinar módulos especializados em aquisição de dados, processamento de imagens, inferência baseada

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

em Inteligência Artificial e comunicação com o usuário. Essa abordagem permite automatizar todo o fluxo de análise, desde o recebimento da imagem até a apresentação dos resultados, reduzindo a necessidade de intervenção manual e favorecendo aplicações em ambientes clínicos e de teleatendimento.

Na Odontologia, a utilização de sistemas inteligentes apresenta potencial para ampliar o acesso ao diagnóstico inicial, especialmente em situações nas quais o atendimento especializado não está imediatamente disponível. Ao integrar modelos de Visão Computacional com mecanismos automatizados de processamento e comunicação, essas soluções tornam-se capazes de fornecer respostas rápidas, padronizadas e acessíveis, contribuindo para otimizar o fluxo de atendimento e apoiar profissionais e usuários durante a avaliação inicial de traumatismos dentários.

Dessa forma, o desenvolvimento de um sistema inteligente baseado em Visão Computacional representa uma alternativa promissora para aplicações em saúde digital, reunindo técnicas modernas de Inteligência Artificial em uma arquitetura capaz de automatizar o processamento de imagens e fornecer suporte ao diagnóstico inicial. Essa abordagem fundamenta a proposta apresentada neste trabalho, cuja metodologia é descrita na seção seguinte.

METODOLOGIA

A presente pesquisa caracteriza-se como um estudo de natureza aplicada, com abordagem quantitativa e delineamento experimental, cujo objetivo consiste no desenvolvimento e na avaliação de um sistema baseado em Visão Computacional para o diagnóstico inicial de traumatismos dentários. A proposta integra técnicas de Inteligência Artificial, aprendizado profundo e detecção de objetos em uma arquitetura computacional capaz de analisar imagens clínicas e fornecer suporte ao diagnóstico inicial. O desenvolvimento do sistema foi organizado em etapas sequenciais, abrangendo a construção do conjunto de dados, a anotação das imagens, o treinamento do modelo de detecção, a implementação da arquitetura computacional e a avaliação do desempenho da solução proposta.

As imagens utilizadas na construção da base de dados foram obtidas a partir de diferentes fontes disponíveis na internet, incluindo sites especializados, artigos científicos e publicações disponíveis na plataforma Instagram. A seleção, triagem, classificação e anotação das imagens foram realizadas pela autora do trabalho, Pamela Barbosa, cirurgiã-dentista.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

A seleção das imagens foi realizada a partir da identificação visual dos traumatismos dentários de interesse do estudo. As imagens foram classificadas em quatro categorias: avulsão, fratura de esmalte, fratura dentinária e fratura pulpar. A triagem e a definição da classificação de cada imagem foram realizadas pela autora, considerando as características clínicas observáveis nas imagens. As anotações utilizadas para o treinamento do modelo também foram realizadas e posteriormente revisadas pela autora. Nos casos em que havia dúvida quanto à identificação ou classificação do traumatismo, a decisão final foi realizada pela autora, responsável pela triagem das imagens e pela definição das respectivas classes. Dessa forma, a seleção, classificação e anotação da base de dados foram conduzidas sob avaliação de uma profissional cirurgiã-dentista.

Não foi realizado um procedimento específico de agrupamento das imagens por paciente antes da divisão da base nos conjuntos de treinamento, validação e teste. Da mesma forma, não foi realizada avaliação formal de concordância interavaliadores, uma vez que a seleção, classificação e anotação das imagens foram conduzidas por uma única profissional.

Conjunto de dados

O conjunto de dados utilizado nesta pesquisa foi composto por imagens clínicas de traumatismos dentários obtidas em fontes públicas de caráter científico e educacional, incluindo repositórios de imagens odontológicas e publicações disponibilizadas para fins acadêmicos. Após a etapa de coleta, todas as imagens passaram por um processo de seleção manual, sendo removidas aquelas que apresentavam baixa resolução, duplicidade, enquadramento inadequado ou qualidade insuficiente para identificação das lesões.

As imagens selecionadas foram organizadas em quatro classes representativas de traumatismos dentários: avulsão, fratura de esmalte, fratura dentinária **e** fratura pulpar, escolhidas em função de sua relevância clínica e da disponibilidade de exemplos suficientes para o treinamento do modelo de Inteligência Artificial. A Figura 1 apresenta exemplos das imagens utilizadas na construção do conjunto de dados.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 1. Exemplos das quatro classes de traumatismos dentários



Fonte: Elaboração própria (2026).

Ao final da etapa de organização, o conjunto de dados totalizou 1.142 imagens, distribuídas em 344 imagens de avulsão, 305 de fratura pulpar, 255 de fratura de esmalte **e** 238 de fratura dentinária. Posteriormente, a base foi dividida automaticamente pela plataforma Roboflow em subconjuntos destinados ao treinamento (70%), validação (20%) e teste (10%), possibilitando a avaliação do desempenho do modelo em dados não utilizados durante o processo de aprendizagem. A Tabela 1 apresenta o resumo da distribuição do conjunto de dados empregado nesta pesquisa.

Tabela 1. Distribuição do conjunto de dados

Característica	Valor
Número de Imagens	1.142
Número de Classes	4
Avulsão	344
Fratura Pulpar	305
Fratura de Esmalte	255
Fratura Dentinária	238

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Treinamento	744 (70%)
Validação	205 (20%)
Teste	109 (10%)
Pré-processamento	Auto-Orient e Resize (640x640)
Data augmentation	Não Aplicado

Fonte: Elaboração própria (2026).

Desenvolvimento do sistema inteligente

O sistema foi desenvolvido com o objetivo de automatizar o diagnóstico inicial de traumatismos dentários por meio da integração de técnicas de Visão Computacional, aprendizado profundo e comunicação entre serviços. A arquitetura foi projetada de forma modular, permitindo que cada componente desempenhasse uma função específica no processamento das imagens e na disponibilização dos resultados ao usuário.

Inicialmente, todas as imagens do conjunto de dados foram anotadas utilizando a plataforma Roboflow, na qual foram definidas manualmente as regiões de interesse por meio de *bounding boxes*, correspondentes aos diferentes tipos de traumatismos dentários. Após a etapa de anotação, o conjunto de dados foi exportado no formato compatível com a arquitetura YOLO11, incluindo as imagens, os arquivos de anotação e o arquivo de configuração (*data.yaml*), necessários para o treinamento do modelo.

Para o desenvolvimento do modelo de detecção dos traumatismos dentários, foi utilizado o YOLO11n, a partir dos pesos pré-treinados yolo11n.pt. O treinamento foi configurado para um máximo de 100 épocas, utilizando batch size de 16, imagens com resolução de 640 × 640 pixels, patience de 20 épocas e seed igual a 42, com o objetivo de favorecer a reprodução do experimento. O otimizador foi definido no modo automático (optimizer="auto"), com taxa de aprendizagem inicial (lr0) de 0,01 e taxa de aprendizagem final (lrf) de 0,01. Para a configuração do processo de detecção, foi utilizado IoU de 0,70. O treinamento foi realizado utilizando a biblioteca Ultralytics versão 8.4.84, em ambiente Python 3.12.13, com PyTorch 2.11.0+cu128 e CUDA 12.8, utilizando uma GPU NVIDIA Tesla T4, com aproximadamente 14,9 GB de memória disponível. Ao final do treinamento, o modelo utilizado nas etapas posteriores de avaliação foi o arquivo best.pt, gerado durante o processo de treinamento da Ultralytics. O arquivo best.pt corresponde ao modelo selecionado pela rotina de treinamento como o melhor resultado obtido durante as épocas executadas. O limiar de confiança não foi definido como um parâmetro

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

específico durante o treinamento do modelo, sendo utilizado posteriormente na etapa de avaliação e inferência.

A integração entre os diferentes componentes foi realizada por meio de uma arquitetura computacional composta pelas plataformas FastAPI, n8n e Telegram. O FastAPI foi utilizado para disponibilizar o modelo de Visão Computacional como um serviço de inferência, enquanto o n8n foi responsável pela orquestração do fluxo de processamento entre os módulos da aplicação. Como interface de interação com o usuário, foi utilizado o aplicativo Telegram, permitindo o envio de imagens clínicas e o recebimento automático dos resultados.

Figura 2. Arquitetura geral do sistema inteligente

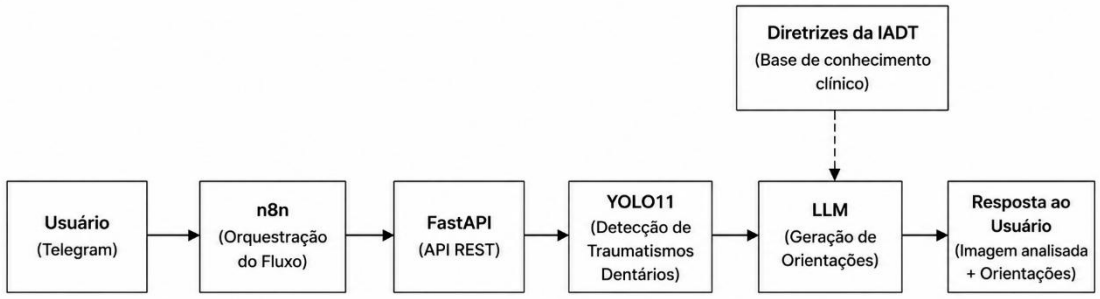

Fonte: Elaboração própria (2026).

Avaliação experimental

A avaliação experimental foi conduzida com o objetivo de analisar o desempenho no diagnóstico inicial de traumatismos dentários. Para isso, o modelo foi submetido ao conjunto de teste, composto por imagens que não participaram do processo de treinamento, permitindo verificar sua capacidade de generalização diante de novos dados.

O desempenho do modelo foi analisado por meio de métricas amplamente utilizadas em tarefas de detecção de objetos, incluindo Precisão (Precision), Revocação (Recall), F1-Score e mean Average Precision (mAP). A métrica *Precision* foi utilizada para avaliar a proporção de detecções corretamente classificadas em relação ao total de detecções realizadas pelo modelo, enquanto o *Recall* mediu a capacidade do sistema em identificar corretamente as lesões presentes nas imagens. O *F1-Score* foi empregado para fornecer uma medida de equilíbrio entre precisão e revocação, permitindo uma análise mais robusta do desempenho do modelo.

Além dessas métricas, foi utilizado o mean Average Precision (mAP), considerado uma das principais medidas de desempenho para modelos de detecção de objetos. Neste trabalho,

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

foram analisados os indicadores mAP@0.50 e mAP@0.50:0.95, que avaliam simultaneamente a capacidade de localização e classificação das lesões, considerando diferentes limiares de sobreposição (*Intersection over Union* – IoU). Esses indicadores possibilitam uma avaliação mais abrangente da eficiência do modelo em cenários reais de aplicação.

Além da análise quantitativa, foram realizados testes funcionais para verificar o comportamento da arquitetura desenvolvida durante o processamento das imagens. Essa etapa contemplou a comunicação entre os diferentes módulos do sistema, desde o envio da imagem pelo usuário até a geração da resposta contendo o diagnóstico inicial, permitindo validar o funcionamento integrado da solução proposta.

RESULTADOS E DISCUSSÃO

Desempenho da arquitetura YOLO11

Após a etapa de treinamento, a arquitetura YOLO11 apresentou evolução consistente das métricas de desempenho ao longo das épocas, evidenciando adequada convergência do processo de aprendizagem.

As curvas apresentadas na Figura 3 demonstram redução progressiva das funções de perda (*Box Loss*, *Classification Loss* e *Distribution Focal Loss*), indicando que o modelo aprimorou simultaneamente sua capacidade de localizar e classificar os traumatismos dentários. Além disso, observou-se crescimento gradual das métricas Precision, Recall, mAP@0.50 e mAP@0.50:0.95, que atingiram estabilidade nas últimas épocas de treinamento, sem indícios significativos de sobreajuste (*overfitting*).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 3. Curvas de treinamento da arquitetura YOLO11

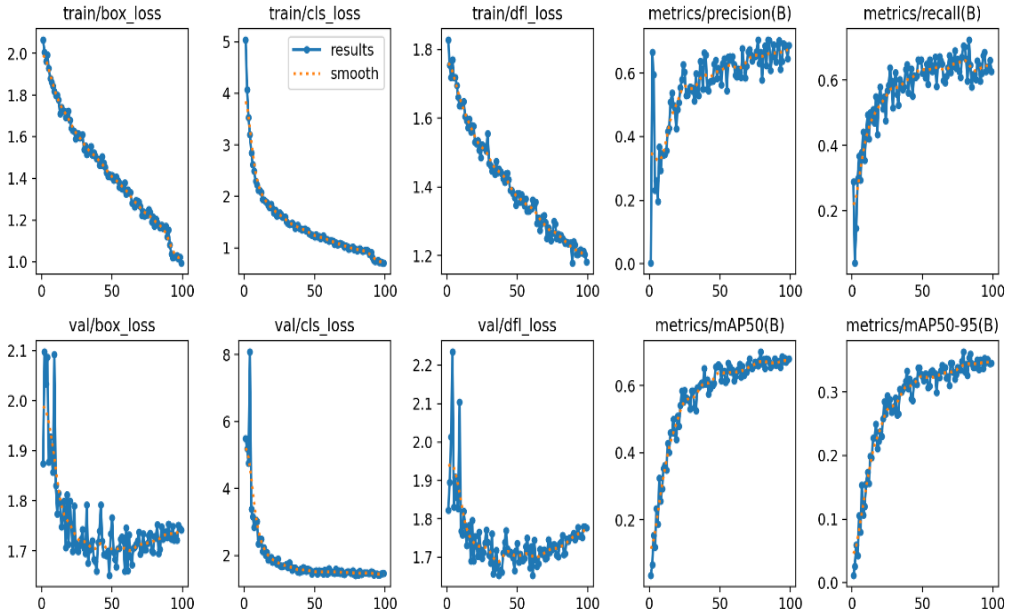

Fonte: Elaboração própria (2026).

A caracterização do conjunto de dados evidenciou uma distribuição relativamente equilibrada entre as quatro classes de traumatismos dentários consideradas na pesquisa, reduzindo possíveis vieses durante o treinamento do modelo. A análise das caixas delimitadoras demonstrou predominância de objetos de pequenas dimensões distribuídos em diferentes regiões das imagens, característica que representa um desafio para modelos de detecção de objetos e reforça a necessidade da utilização de estratégias capazes de melhorar a localização de pequenas lesões.

A curva Precision–Recall, apresentada na Figura 4, demonstrou desempenho satisfatório da arquitetura para todas as classes avaliadas. A classe Fratura Pulpar apresentou o maior valor de *Average Precision* (AP = 0,778), seguida por Avulsão (AP = 0,718) e Fratura Dentinária (AP = 0,679). Em contrapartida, a classe Fratura de Esmalte apresentou o menor desempenho (AP = 0,592), resultado que pode ser atribuído à maior similaridade visual entre esse tipo de lesão e outras categorias presentes na base de dados. O modelo alcançou mAP@0.50 de 69,20%, demonstrando desempenho consistente para a tarefa proposta.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 4. Curvas Precision–Recall das classes de traumatismos dentários

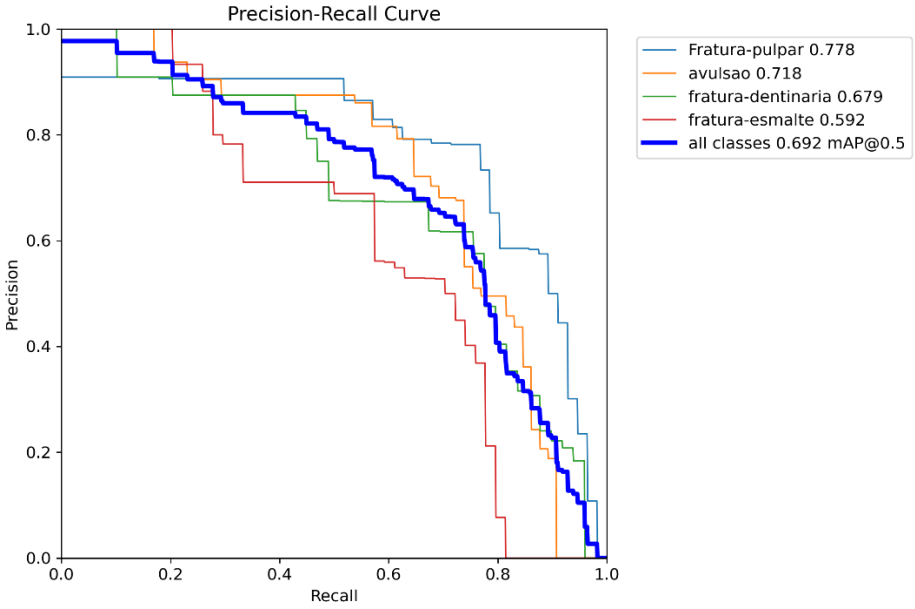

Fonte: Elaboração própria (2026).

As curvas individuais de Precision, Recall e F1-Score possibilitaram identificar o limiar de confiança mais adequado para utilização do modelo durante a inferência. Observou-se que o melhor equilíbrio entre precisão e sensibilidade foi obtido para um limiar de confiança de aproximadamente 0,267, correspondente a um F1-Score de 0,67, valor adotado como referência para a operação do sistema desenvolvido.

A Tabela 2 apresenta a síntese das principais métricas obtidas durante o treinamento da arquitetura YOLO11. O modelo convergiu na 79ª época, alcançando Precision de 66,58%, Recall de 70,52%, mAP@0.50 de 69,20% e mAP@0.50:0.95 de 36,35%, resultados que evidenciam o potencial da arquitetura para aplicações de detecção automática de traumatismos dentários em imagens clínicas.

A matriz de confusão permite analisar o comportamento do modelo YOLO11n na identificação das classes de traumatismos dentários consideradas no estudo. A matriz apresenta, nas linhas, as classes preditas pelo modelo e, nas colunas, as classes verdadeiras. Os resultados evidenciam que o modelo apresentou maior número de acertos nas classes avulsão, com 52 verdadeiros positivos, fratura pulpar, com 44 verdadeiros positivos, fratura dentinária, com 35, **e** fratura de esmalte, com 31. Entretanto, também foram observadas ocorrências relevantes de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

classificações incorretas e de detecções atribuídas à classe *background*, indicando que parte das lesões presentes nas imagens não foi corretamente localizada ou classificada pelo modelo.

Figura 5. Matriz de confusão

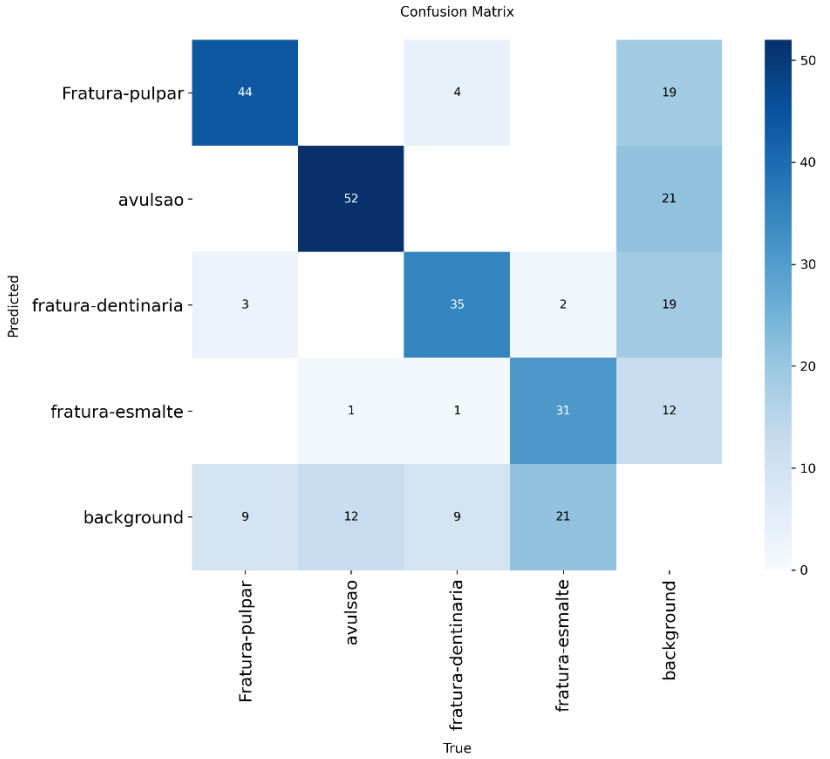

Fonte: Elaboração própria (2026).

Os resultados derivados da matriz indicam que a avulsão apresentou o melhor equilíbrio entre Precision e Recall, com F1-Score de 75,36%, além do maior Recall entre as classes avaliadas, de 80,00%. A classe fratura pulpar também apresentou desempenho satisfatório em termos de sensibilidade, alcançando Recall de 78,57%. Por outro lado, a fratura dentinária apresentou Precision de 59,32%, evidenciando maior ocorrência relativa de falsos positivos. A maior limitação foi observada na classe fratura de esmalte, cujo Recall foi de apenas 57,41%, indicando que uma parcela considerável dos casos verdadeiros dessa classe não foi corretamente detectada.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 6. Matriz de confusão normalizada

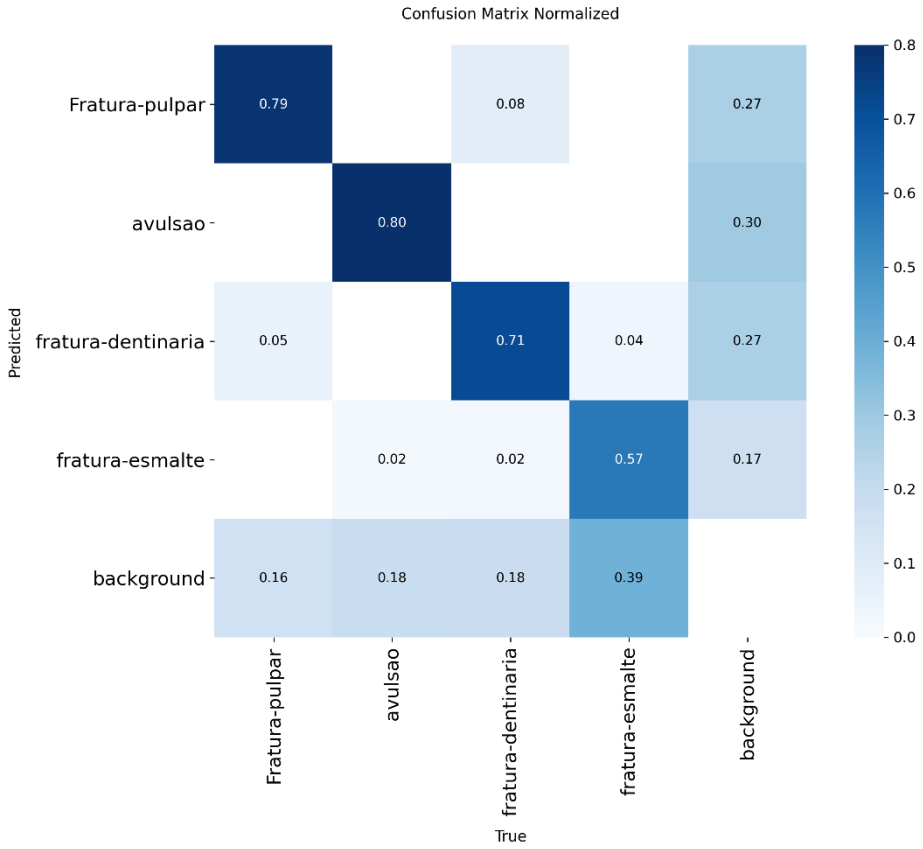

Fonte: Elaboração própria (2026).

Discussão do modelo de visão computacional

Os resultados obtidos neste estudo demonstram que a arquitetura YOLO11 apresentou desempenho consistente para a identificação automática de traumatismos dentários, alcançando Precision de 66,58%, Recall de 70,52%, mAP@0.50 de 69,20% e F1-Score de 0,67. Esses indicadores evidenciam a capacidade do modelo em localizar e classificar diferentes tipos de traumatismos dentários, mantendo estabilidade durante o processo de treinamento e adequada capacidade de generalização para imagens não utilizadas na etapa de aprendizagem.

A convergência estável observada durante o treinamento, associada à redução contínua das funções de perda e à evolução das métricas de desempenho, indica que o modelo foi capaz de aprender características discriminantes das diferentes categorias de lesões sem apresentar

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

indícios significativos de sobreajuste. Esse comportamento demonstra a robustez da arquitetura YOLO11 para aplicações de detecção de objetos em imagens odontológicas.

De forma semelhante, Sarıoğlu *et al.* (2026) verificaram que arquiteturas como YOLO11 e YOLO12 apresentam resultados promissores na identificação automática de traumatismos dentários, reforçando o potencial dessas abordagens para aplicações clínicas.

Tabela 2. Síntese dos resultados obtidos pela arquitetura YOLO11

Métrica	Resposta
Arquitetura	YOLO11n
Número de Classes	4
Resolução das imagens	640 x 640 pixels
Melhor época	79
Precision	66,58%
Recall	70,52%
mAP@0.50	69,20%
mAP@0.50:0.95	36,35%
Melhor F1-Score	0,67
Limiar de confiança ótimo	0,267
Tempo de treinamento	24,2 min
Modelo final	best.pt

Fonte: Elaboração própria (2026).

A análise dos falsos negativos (FN) é particularmente relevante neste estudo, uma vez que a não identificação de um traumatismo dentário pode ser mais crítica do que a geração de uma detecção incorreta. Na matriz de confusão foram identificados 12 falsos negativos para fratura pulpar, 13 para avulsão, 14 para fratura dentinária e 23 para fratura de esmalte, totalizando 62 ocorrências de não detecção correta entre as quatro classes. A classe fratura de esmalte apresentou a maior quantidade de falsos negativos, correspondendo a 23 casos entre 54 ocorrências verdadeiras da classe. Desse total, 21 casos foram classificados como *background* e dois foram confundidos com fratura dentinária. Dessa forma, aproximadamente 42,59% dos casos verdadeiros de fratura de esmalte não foram corretamente identificados, resultando em Recall de 57,41%. Esse comportamento indica uma limitação importante na capacidade do modelo de localizar e distinguir alterações associadas a essa classe.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Para a fratura pulpar, foram observados 12 falsos negativos, sendo nove classificados como *background* e três como fratura dentinária. Na classe avulsão, 13 casos não foram corretamente identificados, dos quais 12 foram classificados como *background* e um apresentou outra classificação. Para a fratura dentinária, foram registrados 14 falsos negativos, incluindo nove casos classificados como *background*, três como fratura pulpar e dois como fratura de esmalte. Esses resultados mostram que uma parcela relevante dos falsos negativos não corresponde necessariamente à confusão entre duas classes de traumatismos, mas à ausência de uma detecção considerada válida pelo modelo, representada pela classificação como *background*.

Esse comportamento é relevante para a aplicação pretendida, pois um falso negativo significa que uma lesão presente na imagem pode deixar de ser sinalizada pelo sistema. Por esse motivo, os resultados devem ser interpretados com cautela, principalmente considerando que a aplicação proposta está relacionada à orientação inicial em situações de traumatismo dentário. A natureza potencialmente urgente desses casos reforça a necessidade de análise específica dos falsos negativos.

A classe fratura de esmalte apresentou AP de 0,592, constituindo uma das principais limitações observadas no desempenho do modelo. Embora o valor indique capacidade de identificação da classe, o resultado demonstra que a discriminação e a localização dessas ocorrências ainda apresentam limitações. Essa interpretação é reforçada pela matriz de confusão, na qual a classe apresentou apenas 31 verdadeiros positivos contra 23 falsos negativos. A análise conjunta do AP e da matriz de confusão permite observar que a principal dificuldade não está exclusivamente na geração de falsos positivos. Na realidade, o problema mais expressivo para essa classe está relacionado à **não detecção dos casos verdadeiros**, uma vez que 23 das 54 ocorrências verdadeiras não foram corretamente identificadas. O Recall de 57,41% evidencia essa limitação de sensibilidade.

Uma possível explicação para esse comportamento está relacionada à dificuldade de diferenciação visual da fratura de esmalte em relação às demais categorias e ao *background*, especialmente quando as alterações são pequenas ou apresentam baixo contraste na imagem. Entretanto, essa interpretação deve ser considerada como uma hipótese relacionada ao comportamento observado, uma vez que não foi realizado um estudo específico de ablação ou de análise das características visuais responsáveis pelos erros. Por essa razão, o AP de 0,592 deve ser interpretado com prudência, não sendo adequado classificar o desempenho do modelo como plenamente robusto.

O modelo apresentou mAP@0.50 de 69,20%, enquanto o mAP@0.50:0.95 foi de 36,35%. A diferença entre essas duas métricas é relevante para a interpretação do desempenho. O

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

mAP@0.50 avalia a detecção considerando um limiar de interseção sobre união (*Intersection over Union* — IoU) de 0,50, enquanto o mAP@0.50:0.95 considera múltiplos limiares de IoU, tornando a avaliação mais rigorosa tanto em relação à detecção quanto à precisão da localização das caixas delimitadoras. Essa redução indica que, embora o modelo consiga identificar as classes com desempenho razoável sob o critério de IoU = 0,50, seu desempenho diminui significativamente quando são exigidas localizações mais precisas. Portanto, o resultado sugere uma limitação na precisão espacial das detecções, além da própria capacidade de classificação. Dessa maneira, o mAP@0.50:0.95 de 36,35% deve ser considerado uma evidência de que ainda existem limitações importantes na localização das regiões correspondentes aos traumatismos. Esse resultado, juntamente com o AP de 0,592 obtido para a classe fratura de esmalte, evidencia limitações na localização e na discriminação das lesões. Assim, os resultados devem ser apresentados de maneira prudente, sem classificá-los como desempenho elevado ou plenamente robusto.

Outro aspecto relevante corresponde ao limiar de confiança (*confidence threshold*) de 0,267, utilizado para determinar quais detecções seriam consideradas válidas pelo sistema. Esse valor é relativamente baixo e permite que detecções com menor nível de confiança sejam mantidas durante a inferência. A utilização de um limiar reduzido pode produzir um efeito de compromisso entre Recall e Precision. Ao diminuir o threshold, o modelo tende a reter uma quantidade maior de possíveis detecções, o que pode contribuir para a identificação de casos que seriam descartados com um limiar mais elevado. Entretanto, essa estratégia também pode aumentar a quantidade de detecções incorretas, contribuindo para a ocorrência de falsos positivos. Dessa forma, o threshold de 0,267 pode ter contribuído para a manutenção de detecções de menor confiança e, consequentemente, para o número de falsos positivos observado na matriz.

Para demonstrar essa relação de maneira experimental, seria necessário realizar uma análise de sensibilidade do threshold, comparando diferentes valores, por exemplo, 0,20, 0,267, 0,30, 0,40 e 0,50, e avaliando o comportamento de Precision, Recall, F1-Score e número de falsos positivos e falsos negativos. Cabe destacar que o limiar de 0,267 é relativamente baixo e que seu possível efeito sobre o aumento de falsos positivos deve ser considerado na interpretação dos resultados.

De maneira geral, os resultados demonstram que o modelo apresentou capacidade de identificar as quatro classes de traumatismos dentários, com desempenho particularmente favorável para avulsão, que apresentou 52 verdadeiros positivos e Recall de 80,00%. Entretanto, a análise detalhada da matriz evidencia limitações importantes, principalmente na fratura de esmalte, que apresentou 23 falsos negativos, Recall de 57,41% e AP de 0,592. A quantidade de falsos

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

negativos classificados como *background* também indica que parte das lesões presentes nas imagens não foi suficientemente identificada pelo modelo.

A diferença entre o mAP@0.50 de 69,20% e o mAP@0.50:0.95 de 36,35% reforça a existência de limitações na precisão da localização das regiões detectadas. Da mesma forma, o threshold de 0,267 representa uma escolha que pode favorecer maior sensibilidade, mas potencialmente aumentar a ocorrência de falsos positivos. Assim, os resultados devem ser interpretados como evidência de viabilidade experimental da abordagem, e não como comprovação de desempenho clínico ou de capacidade de diagnóstico autônomo.

Nesse sentido, o modelo deve ser caracterizado como uma ferramenta experimental de apoio à identificação inicial ou triagem, e não como substituto da avaliação profissional. O estudo ainda não realizou validação clínica prospectiva, comparação sistemática com cirurgiões-dentistas ou validação em população externa.

Além do desempenho quantitativo da arquitetura YOLO11, também foi avaliado o funcionamento integrado do sistema proposto, contemplando a comunicação entre os diferentes módulos da aplicação e a geração automática das respostas ao usuário. Os resultados dessa avaliação são apresentados na seção seguinte.

Avaliação da arquitetura do sistema inteligente

Durante os experimentos, o sistema demonstrou capacidade de executar automaticamente todas as etapas do fluxo de processamento. Inicialmente, o usuário enviou uma imagem clínica por meio do aplicativo Telegram, que atuou como interface de entrada da aplicação. Em seguida, o fluxo foi iniciado automaticamente pelo n8n, responsável pela orquestração das etapas de processamento, encaminhando a imagem para o serviço de inferência desenvolvido em FastAPI. O modelo YOLO11 realizou a identificação do traumatismo dentário e retornou a classe predita, a localização da lesão e o respectivo nível de confiança da inferência.

O agente inteligente desenvolvido neste trabalho foi implementado por meio de uma arquitetura integrada, utilizando a plataforma n8n como mecanismo de orquestração dos diferentes componentes da aplicação. O fluxo estabelece a comunicação entre o aplicativo de mensagens Telegram, o serviço responsável pelo processamento da imagem e o modelo de linguagem utilizado para geração das orientações ao usuário. O processamento é iniciado a partir do recebimento de uma mensagem contendo uma imagem no Telegram. O nó *Telegram Trigger* identifica a mensagem recebida e, posteriormente, o nó *Get a file* realiza a obtenção do arquivo de imagem associado à mensagem. A imagem obtida é então encaminhada para um serviço

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

externo por meio do nó *HTTP Request*, configurado para realizar uma requisição do tipo POST, utilizando o formato multipart/form-data para o envio do arquivo.

O serviço externo recebe a imagem e realiza o processamento computacional correspondente à etapa de visão computacional. A comunicação entre o fluxo n8n e esse serviço é realizada por meio de uma interface HTTP, disponibilizada durante o desenvolvimento por meio de um endpoint de acesso externo. Essa arquitetura permite separar a camada de automação e comunicação da camada responsável pela inferência do modelo de visão computacional.

Figura 7. Workflow desenvolvido na plataforma n8n para integração entre Telegram, FastAPI e LLM

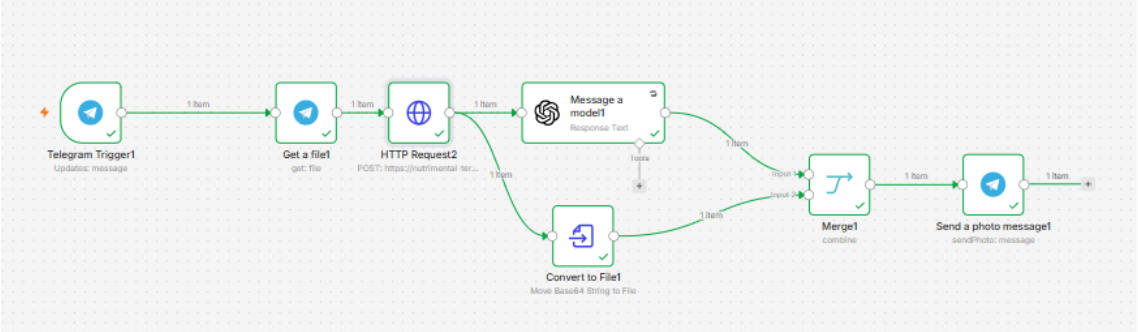

Fonte: Elaboração própria (2026).

Após o processamento da imagem, as informações resultantes são encaminhadas à etapa de geração textual. Para essa finalidade, foi utilizado o modelo de linguagem GPT-4o-mini, configurado no nó *Message a Model* do n8n. O modelo recebe as informações disponibilizadas pelo fluxo e é utilizado para estruturar a resposta em linguagem natural, tornando os resultados do processamento computacional mais compreensíveis ao usuário. Após a geração da resposta, o fluxo realiza a integração dos dados por meio do nó *Merge* e, posteriormente, utiliza o componente de comunicação do Telegram para encaminhar o resultado ao usuário. Dessa forma, o fluxo completo estabelece uma sequência de processamento composta pelo recebimento da imagem, obtenção do arquivo, encaminhamento para o serviço de visão computacional, processamento das informações, geração da resposta textual e retorno da informação ao usuário.

A avaliação da aplicação foi conduzida com o objetivo de verificar o funcionamento técnico do fluxo integrado desenvolvido, compreendendo o recebimento da imagem, o

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

processamento pelo modelo de visão computacional e a apresentação do resultado ao usuário. Dessa forma, os testes realizados nesta etapa tiveram caráter experimental e funcional, não sendo considerados uma validação clínica do sistema. As Figuras 8 e 9 apresentam exemplos do funcionamento da aplicação e demonstram a integração entre os componentes computacionais empregados, permitindo verificar a execução do fluxo proposto em condições controladas. Entretanto, a demonstração de funcionamento não permite, isoladamente, concluir quanto à segurança, usabilidade, efetividade ou aplicabilidade clínica da solução. Essa distinção é necessária, uma vez que a validação clínica exigiria avaliação estruturada em condições representativas do uso assistencial, com participação de profissionais habilitados e comparação dos resultados produzidos pelo sistema com um padrão de referência clínico.

Figura 8. Envio da imagem clínica ao *software*

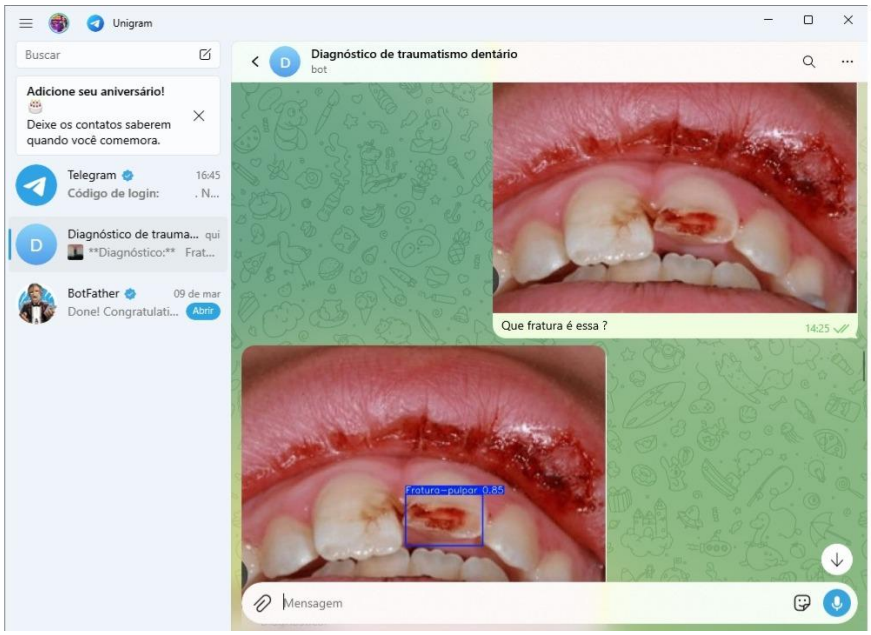

Fonte: Elaboração própria (2026).

Os testes experimentais evidenciaram estabilidade na comunicação entre os módulos da aplicação, permitindo que todas as etapas fossem executadas automaticamente, desde o recebimento da imagem até a geração da resposta ao usuário. A arquitetura apresentou funcionamento consistente durante sucessivas execuções, demonstrando a viabilidade da

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

integração entre Visão Computacional, serviços web e automação de processos para aplicações em saúde digital.

Após a conclusão da inferência, o sistema retornou automaticamente uma resposta contendo a imagem processada com a região do traumatismo identificada, a classe prevista pelo modelo e o nível de confiança associado à detecção. Essa funcionalidade demonstra que a arquitetura desenvolvida é capaz de transformar os resultados produzidos pelo modelo de Inteligência Artificial em informações organizadas e acessíveis ao usuário final, ampliando seu potencial de utilização em cenários de apoio ao diagnóstico inicial.

É importante destacar que o sistema desenvolvido não substitui a avaliação realizada por um cirurgião-dentista. Os resultados obtidos neste estudo foram provenientes de um ambiente experimental e não houve validação clínica prospectiva. Dessa forma, a ferramenta deve ser compreendida como um recurso de apoio à identificação inicial e à orientação do usuário, não como um instrumento autônomo de diagnóstico clínico.

Figura 9. Resposta gerada pelo software após a inferência

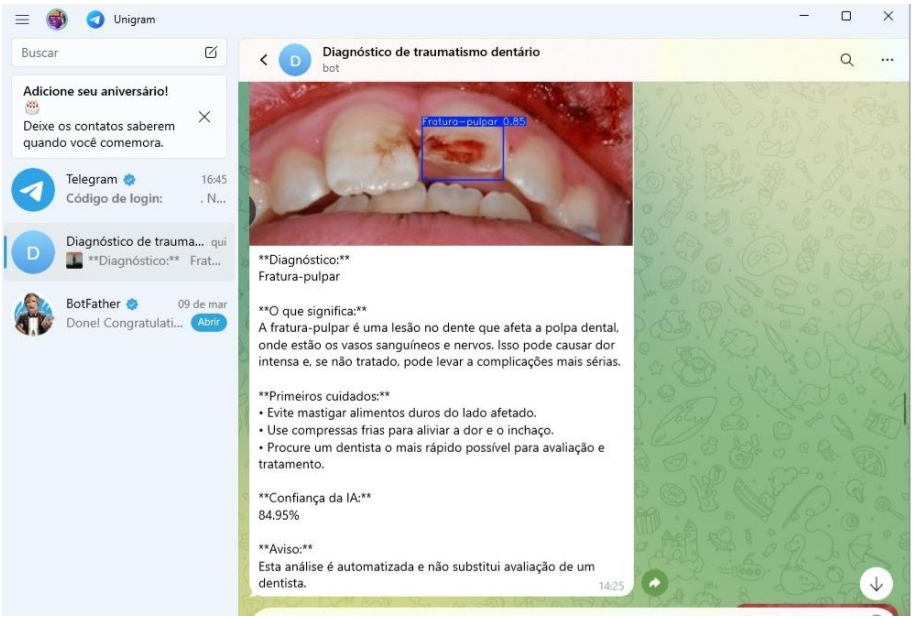

Fonte: Elaboração própria (2026).

Discussão dos resultados do sistema inteligente

Os resultados obtidos evidenciam que a principal contribuição deste trabalho não está restrita ao desenvolvimento de um modelo de detecção de objetos, mas na construção de uma arquitetura integrada capaz de automatizar todo o fluxo de processamento de imagens clínicas.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

A combinação entre a arquitetura YOLO11, o serviço FastAPI, a plataforma n8n e a interface via Telegram permitiu o desenvolvimento de um agente funcional, capaz de receber imagens, executar inferências e disponibilizar automaticamente os resultados ao usuário.

Na presente etapa, portanto, os resultados devem ser interpretados como evidências de viabilidade técnica e integração funcional, e não como evidências de desempenho clínico. A avaliação clínica do sistema constitui uma etapa posterior do projeto e deverá envolver protocolo específico, definição prévia dos critérios de sucesso, utilização de conjunto de imagens independente e representativo das condições de aplicação, além da comparação entre as respostas produzidas pelo sistema e a avaliação realizada por profissionais da área odontológica. Essa etapa também deverá contemplar a análise de erros, especialmente dos falsos negativos, considerando que a omissão de uma lesão pode apresentar consequências distintas da ocorrência de uma detecção incorreta. A ausência dessa avaliação no presente estudo constitui uma limitação e impede que o sistema seja caracterizado como ferramenta clinicamente validada ou como instrumento autônomo de diagnóstico.

Diferentemente de estudos que concentram suas análises exclusivamente no desempenho de modelos de aprendizado profundo, a solução proposta amplia a aplicação prática da Inteligência Artificial ao integrar diferentes tecnologias em uma arquitetura modular e escalável. Essa abordagem favorece futuras expansões do sistema, permitindo a incorporação de novos modelos de Visão Computacional, categorias adicionais de traumatismos dentários e diferentes interfaces de comunicação, sem alterações significativas na estrutura da aplicação.

A integração entre modelos de Inteligência Artificial e arquiteturas distribuídas representa uma tendência crescente na área da saúde digital, especialmente em aplicações voltadas ao apoio ao diagnóstico e à teleassistência. Nesse contexto, os resultados obtidos neste trabalho demonstram que a arquitetura desenvolvida constitui uma alternativa tecnicamente viável para automatizar o processamento de imagens odontológicas e disponibilizar suporte ao diagnóstico inicial de forma rápida e acessível.

Aspectos éticos, proteção de dados e segurança da informação

As imagens utilizadas no desenvolvimento do modelo foram obtidas a partir de fontes secundárias, incluindo a plataforma Roboflow, imagens disponibilizadas na internet, artigos científicos e bancos de dados ou repositórios específicos relacionados à temática dos traumatismos dentários. Não houve recrutamento ou participação direta de pacientes no desenvolvimento da pesquisa, bem como não foram recebidas imagens diretamente de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

pacientes, clínicas, hospitais ou cirurgiões-dentistas. Dessa forma, não houve coleta primária de imagens ou informações clínicas diretamente de participantes.

Durante a seleção das imagens utilizadas na composição do conjunto de dados, foram consideradas imagens que não apresentavam informações diretamente identificáveis dos indivíduos, tais como nome, número de prontuário, CPF ou outras informações pessoais associadas às fotografias. Assim, o conjunto utilizado no treinamento e na avaliação do modelo foi constituído a partir de imagens secundárias sem informações de identificação direta dos indivíduos representados.

O armazenamento do conjunto de imagens foi realizado utilizando a plataforma Roboflow, empregada também nas etapas de organização e anotação das imagens, e o Google Drive, utilizado para armazenamento dos arquivos relacionados ao dataset e ao desenvolvimento do projeto. O conjunto de imagens foi utilizado exclusivamente nas etapas relacionadas à organização dos dados, anotação, treinamento, validação e avaliação do modelo de visão computacional. Em relação à proteção de dados, a pesquisa adotou como princípio a utilização apenas das informações necessárias ao desenvolvimento do modelo, não sendo incorporados ao dataset dados pessoais adicionais relacionados aos indivíduos representados nas imagens. Considerando que fotografias odontológicas podem estar relacionadas a informações de saúde, a utilização de imagens secundárias foi realizada com atenção aos princípios de proteção de dados e à legislação brasileira aplicável, especialmente à Lei Geral de Proteção de Dados Pessoais (LGPD).

Ressalta-se ainda que o Telegram não foi utilizado como mecanismo de armazenamento ou processamento das imagens que compuseram o dataset. A aplicação desenvolvida utiliza a fotografia enviada pelo usuário como entrada para o modelo de visão computacional, que realiza a identificação da possível classe de traumatismo e fornece a resposta correspondente. Portanto, o fluxo de desenvolvimento do conjunto de dados permaneceu separado do fluxo de utilização da aplicação. Quanto aos aspectos relacionados ao licenciamento, as imagens utilizadas foram provenientes de diferentes fontes secundárias, sendo necessário considerar as condições de uso estabelecidas por cada fonte. Dessa forma, a utilização das imagens no contexto deste trabalho está vinculada às condições de disponibilização e uso dos respectivos repositórios, bancos de dados, artigos e plataformas empregados na composição do conjunto de dados. As imagens foram utilizadas para fins acadêmicos e de pesquisa, especificamente nas etapas de desenvolvimento e avaliação do modelo computacional.

CONSIDERAÇÕES FINAIS

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Este trabalho apresentou o desenvolvimento de um sistema computacional baseado em Visão Computacional para apoio à triagem e à avaliação inicial de traumatismos dentários, integrando técnicas de aprendizado profundo, detecção de objetos e automação de processos. A arquitetura desenvolvida possibilitou estabelecer um fluxo automatizado para o processamento de imagens odontológicas, desde o envio da imagem pelo usuário até a disponibilização dos resultados pelo sistema. Nesse contexto, os resultados obtidos demonstram a viabilidade técnica da solução proposta, não permitindo, entretanto, afirmar que o sistema esteja clinicamente validado ou que seja capaz de realizar diagnóstico odontológico autônomo.

Os resultados experimentais obtidos com a arquitetura YOLO11 demonstraram capacidade de identificação das classes de traumatismos dentários contempladas no conjunto de dados utilizado. Entretanto, o desempenho observado deve ser interpretado considerando as características e limitações da base de imagens empregada, especialmente seu tamanho, diversidade e distribuição entre as classes. A ocorrência de falsos positivos e falsos negativos evidencia que as predições do modelo estão sujeitas a erros, aspecto particularmente relevante em aplicações relacionadas à área da saúde. Dessa forma, os resultados apresentados devem ser compreendidos como uma avaliação experimental do comportamento do modelo nas condições estabelecidas neste estudo, e não como comprovação de eficácia diagnóstica.

A integração entre YOLO11, FastAPI, n8n e Telegram possibilitou a implementação de um fluxo automatizado para comunicação, processamento das imagens e apresentação dos resultados ao usuário. Essa integração demonstra o funcionamento técnico da arquitetura proposta e a possibilidade de reunir diferentes componentes computacionais em uma aplicação destinada à triagem e avaliação inicial de traumatismos dentários. Entretanto, o funcionamento da aplicação e os resultados obtidos em ambiente experimental não constituem, isoladamente, uma validação clínica do sistema.

Entre as principais limitações deste estudo, destaca-se o tamanho e a composição do conjunto de dados utilizado, bem como a quantidade restrita de categorias de traumatismos dentários contempladas pelo modelo. Também deve ser considerada a possibilidade de ocorrência de falsos positivos e falsos negativos, que podem comprometer a interpretação das predições em determinadas situações. Outra limitação importante consiste na ausência de validação externa, uma vez que o desempenho do modelo não foi avaliado em bases independentes provenientes de diferentes instituições, populações ou condições de aquisição das imagens. Além disso, não foi realizada validação clínica prospectiva, com participação de pacientes e profissionais da Odontologia em condições reais de atendimento.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Diante dessas limitações, o sistema desenvolvido deve ser caracterizado como uma ferramenta de apoio à triagem e à avaliação inicial, não devendo ser considerado um sistema de diagnóstico autônomo ou substituto da avaliação realizada por um cirurgião-dentista. As respostas fornecidas pelo sistema devem ser interpretadas como informações de apoio, sendo necessária a avaliação profissional para confirmação do quadro clínico e definição da conduta adequada.

Como perspectivas para trabalhos futuros, pretende-se ampliar e diversificar o conjunto de dados, incorporando maior quantidade de imagens e novas categorias de traumatismos dentários, além de avaliar outras arquiteturas de detecção e segmentação. Também se propõe realizar validação externa e validação clínica prospectiva, permitindo avaliar a capacidade de generalização do modelo e seu comportamento em condições mais próximas da prática odontológica. Adicionalmente, pretende-se aprimorar o tratamento de casos que não estejam contemplados pelas classes previstas e desenvolver mecanismos para reduzir respostas inadequadas e minimizar os impactos de falsos positivos e falsos negativos.

Por fim, a arquitetura desenvolvida constitui uma prova de conceito de uma solução computacional para apoio à triagem e à avaliação inicial de traumatismos dentários, demonstrando a possibilidade de integrar Visão Computacional, processamento de imagens, modelo de linguagem e automação em um fluxo único. Entretanto, sua utilização em contexto clínico deverá estar condicionada à realização de estudos adicionais que avaliem sua segurança, desempenho e aplicabilidade, incluindo validações externas e clínicas, antes de qualquer utilização como ferramenta de apoio à tomada de decisão em situações reais.

AGRADECIMENTOS

Os autores gostariam de expressar seus sinceros agradecimentos à Universidade Aberta Capixaba (UnAC), programa do Governo do Estado do Espírito Santo ligado à Secti (Secretaria de Estado da Ciência, Tecnologia, Inovação e Educação Profissional), pelo apoio institucional e financeiro (T.O.1064/2023) que possibilitou a realização deste estudo. Agradecemos também ao Instituto Federal do Espírito Santo (Ifes) pela infraestrutura disponibilizada.

REFERÊNCIAS

FOUAD, A. F.; ABBOTT, P. V.; TSILINGARIDIS, G. *et al.* International Association of Dental Traumatology guidelines for the management of traumatic dental injuries: 2. Avulsion of permanent teeth. *Dental Traumatology*, Hoboken, v. 36, n. 4, p. 331–342, 2020. DOI: https://doi.org/10.1111/edt.12573.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

GBD 2021 ORAL DISORDERS COLLABORATORS. Trends in the global, regional, and national burden of oral conditions from 1990 to 2021: a systematic analysis for the Global Burden of Disease Study 2021. *The Lancet*, London, v. 405, n. 10482, p. 897–910, 2025. DOI: https://doi.org/10.1016/S0140-6736(24)02811-3.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge: MIT Press, 2016.

HUA, Y.; CHEN, R.; QIN, H. YOLO-DentSeg: A Lightweight Real-Time Model for Accurate Detection and Segmentation of Oral Diseases in Panoramic Radiographs. *Electronics*, v. 14, n. 4, art. 805, 2025.

HUANG, B.; ESTAI, M.; PUNGCHANCHAIKUL, P. *et al.* Mobile Health Assessment of Traumatic Dental Injuries Using Smartphone-Acquired Photographs: A Multicenter Diagnostic Accuracy Study. *Telemedicine and e-Health*, v. 30, n. 10, 2024.

LEVIN, L.; DAY, P. F.; HICKS, L. *et al.* International Association of Dental Traumatology guidelines for the management of traumatic dental injuries: General introduction. *Dental Traumatology*, Hoboken, v. 36, n. 4, p. 309–313, 2020. DOI: https://doi.org/10.1111/edt.12574.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2016, Las Vegas. *Proceedings […]*. Las Vegas: IEEE, 2016. p. 779–788.

RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 4. ed. Hoboken: Pearson, 2022.

SARIOĞLU, D.; GÜNER, Z.; MUTTEPE, S. N. *et al.* Comparative Performance of YOLO Models in the Automated Segmentation of Dental Traumas on Panoramic Radiographs. *Dental Traumatology*, v. 42, n. 3, p. 363–376, 2026. DOI: https://doi.org/10.1111/edt.70034.

TOPOL, E. *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. New York: Basic Books, 2019.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.