

DETECÇÃO DE CÁRIE AO REDOR DE RESTAURAÇÕES EM RADIOGRAFIAS INTERPROXIMAIAS COM INTELIGÊNCIA ARTIFICIAL

EDUARDO TROTA CHAVES¹; VITOR HENRIQUE DIGMAYER ROMERO²;
FAUSTO MEDEIROS MENDES³; MAXIMILIANO SÉRGIO CENCI⁴; GIANA DA
SILVEIRA LIMA⁵

¹*Universidade Federal de Pelotas – eduardo.chaves@radboudumc.nl*

²*Universidade Federal de Pelotas – vitor.digmayerromero@radboudumc.nl*

³ *Universidade de São Paulo – fmmendes@usp.br*

⁴*Universidade Federal de Pelotas / RadboudUMC – cencims@gmail.com*

⁵*Universidade Federal de Pelotas – gianalima@gmail.com*

1. INTRODUÇÃO

Lesões de cárie ao redor de restaurações, ou cárie secundária, representam uma das principais causas de falha de restaurações. Este tipo de lesão ocorre em áreas adjacentes às restaurações dentárias (BROUWER et al., 2016). A detecção precisa de cárie secundária colabora para longevidade das restaurações (SIGNORI et al., 2018). Embora os métodos tradicionais de diagnóstico utilizem inspeção visual complementada por radiografias, a acurácia do diagnóstico de cárie secundária permanece limitada, especialmente em comparação com a detecção de cárie primária (BROUWER et al., 2016; SIGNORI et al., 2018a).

Recentemente, o uso de inteligência artificial (IA), especialmente técnicas de aprendizado profundo (*deep learning*), tem mostrado potencial para melhorar a detecção de lesões cariosas (SCHWENDICKE et al., 2022). No entanto, a maior parte das pesquisas nessa área tem se concentrado apenas na detecção de cárie primária, tornando a detecção de lesões secundária de cárie um campo a ser explorado. O presente estudo apresenta algoritmo baseado em aprendizagem profunda (*deep learning*) para detectar lesões de cárie primária e secundária em radiografias interproximais.

2. METODOLOGIA

Este estudo transversal foi desenhado para desenvolver e avaliar um algoritmo de inteligência artificial (IA) que detecte lesões de cárie em radiografias interproximais. O estudo seguiu as diretrizes éticas internacionais, como a Declaração de Helsinque, e o checklist para o uso de IA em pesquisas odontológicas (SCHWENDICKE et al., 2021). Além disso, o uso de dados foi aprovado pelo Comitê de Ética CMO Arnhem-Nijmegen, sob o número de arquivo CMO 2015-1565, garantindo a conformidade com as normas éticas internacionais.

Foram utilizadas radiografias interproximais de uma rede de sete clínicas odontológicas na Holanda, resultando em um total de 425 radiografias de 383 pacientes, com idades entre 15 e 88 anos. Os dados foram coletados de pacientes atendidos em consultas regulares entre janeiro de 2015 e janeiro de 2017, sendo incluídos aqueles que apresentavam ao menos uma restauração em dentes posteriores devido a cárie secundária ou outros defeitos restauradores, como falta de material ou contato proximal inadequado. As imagens utilizadas nesse estudo foram previamente apresentadas em estudos anteriores (SIGNORI et al., 2018b). As imagens foram cegadas e convertidas para o formato JPEG.

As radiografias foram incluídas com base em sua qualidade, excluindo imagens com angulação inadequada ou distorção significativa. As radiografias

selecionadas incluíam restaurações em dentes posteriores que apresentavam cárie secundária, falta de material, ou contatos proximais insatisfatórios.

O padrão de referência para a identificação das lesões de cárie foi realizado em três etapas. Inicialmente, dois estudantes de pós-graduação anotaram as lesões de cárie primária e secundária de forma pixelizada, utilizando a plataforma Darwin (V7 Labs, Londres, Reino Unido). Essas anotações foram revisadas por dois doutorandos, e, em seguida, um grupo de especialistas (incluindo pesquisadores com expertise em cárie ao redor de restaurações), ajustando os possíveis falsos positivos e negativos.

O algoritmo utilizado foi baseado em uma rede neural convolucional (CNN) chamada Mask-RCNN, com sistema de suporte Swin-Transformer. Simplificando, o algoritmo analisa as radiografias e identifica as áreas onde pode haver cárie, gerando uma espécie de “máscara” para marcar as áreas problemáticas. Esse modelo é amplamente utilizado em IA para identificar objetos em imagens e foi ajustado para detectar tanto cárie primárias quanto secundárias (HE et al., 2017). Durante o treinamento, foram feitas modificações nas imagens, como espelhamento e recorte, para aumentar a diversidade dos dados e melhorar a robustez do modelo, conforme recomendado pela literatura (CHAVES et al., 2024; KARAKUŞ et al., 2024).

Após o treinamento (80% das imagens), o modelo realizou a predição das lesões em radiografias de teste (20% das imagens), que o modelo não teve acesso às anotações dos especialistas. A confiança nas detecções foi determinada pela interseção sobre união (Intersection over Union - IoU) entre as anotações do algoritmo e as de referência. Para avaliar o desempenho do algoritmo, utilizamos a curva FROC (Curva de Características Operacionais do Receptor de Resposta Livre). Essa curva mede a sensibilidade do modelo (capacidade de detectar cárie) em relação ao número de falsos positivos (erros onde o modelo detecta cárie, mas não há). Outras métricas, como precisão e F1-score, também foram usadas para avaliar a eficácia do modelo.

3. RESULTADOS E DISCUSSÃO

Foram analisadas 2.550 restaurações em pré-molares e molares, para a detecção de cárie. O algoritmo foi eficaz na distinção entre lesões primárias e secundárias. O desempenho do algoritmo foi avaliado pela área sob a curva FROC, que atingiu **0,804** para a detecção de cárie secundária e **0,806** para cárie primária. Isso mostra que o desempenho foi muito semelhante na detecção de ambos os tipos de lesões. As métricas de desempenho mostraram que o algoritmo atingiu uma sensibilidade média de **0,702** e uma precisão de **0,754** para cárie secundária, com um F1-score de **0,719**. Para cárie primária, a sensibilidade foi de **0,742**, a precisão de **0,676**, e o F1-score de **0,689**. Isso indica que o algoritmo foi ligeiramente mais eficaz na detecção de cárie secundária, com maior precisão, mas menor sensibilidade em comparação com as lesões de cárie primária (Figura 1).

O algoritmo cometeu alguns erros de classificação. Em 11 casos, cárie secundária foi classificada como cárie primária, e em 7 casos, cárie primária foi identificada como cárie secundária. Também foram observados falsos positivos, que ocorrem quando áreas sem cárie foram erroneamente identificadas como cárie. A maioria desses falsos positivos foi causada por pequenas falhas de adaptação nas restaurações, que o algoritmo interpretou como cárie. Foram observados alguns falsos negativos, especialmente em lesões iniciais. No entanto, esses erros são menos preocupantes do ponto de vista clínico, já que as lesões iniciais de cárie muitas vezes não requerem tratamento imediato (Figura 2).

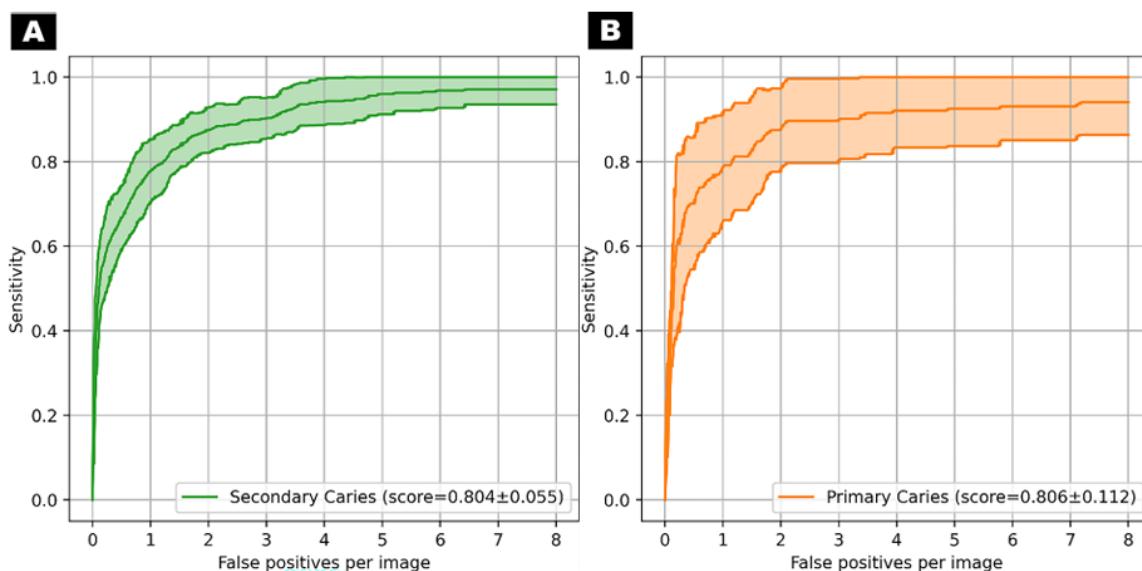


Figura 1. Curvas de características operacionais do receptor de resposta livre (FROC) para detecção de lesões de cárie secundárias (A) e primárias (B), determinadas para cada dobraria de teste e os resultados foram agregados para mostrar a variabilidade na eficácia. Imagem adaptada (CHAVES et al., 2024).

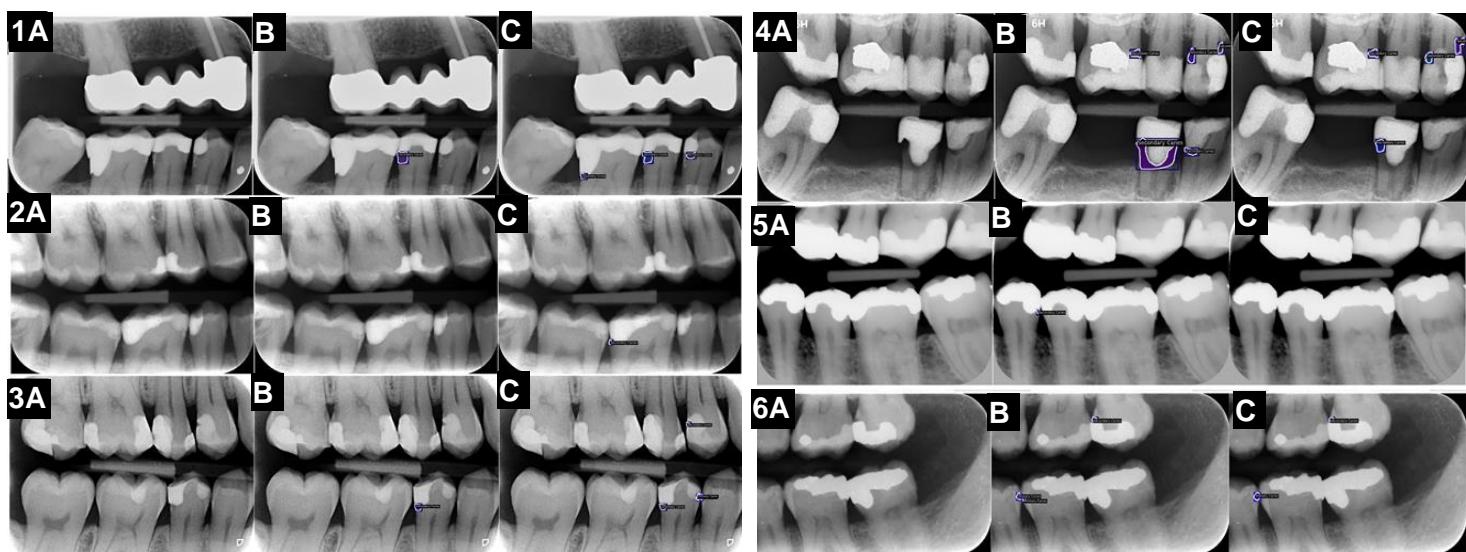


Figura 2. O painel representa os casos falsos-positivos (1, 2 e 3) e falsos-negativos (4, 5 e 6). Da esquerda para a direita, as linhas mostram: a imagem sem as anotações (A); as decisões do padrão de referência (B) e as previsões do modelo (C). Imagem adaptada (CHAVES et al., 2024).

Os resultados do estudo demonstram que o algoritmo baseado em redes neurais convolucionais (CNN) foi eficaz tanto na detecção de cárie primária quanto secundárias, com áreas sob a curva FROC superiores a 0,8 para ambos os tipos de lesões. Essa precisão é comparável a outros sistemas já desenvolvidos para detectar cárie em radiografias interproximais. A habilidade do algoritmo de distinguir entre cárie primária e secundária, mesmo com a complexidade causada pela radiopacidade dos materiais restauradores, representa um avanço significativo no campo de diagnóstico automatizado. Estudos anteriores indicam que essa tarefa é particularmente difícil, especialmente em superfícies restauradas, onde a visualização de lesões pode ser obscurecida por materiais como resinas compostas e amálgama (BROUWER et al., 2016; SIGNORI et al., 2018a).

Embora o desempenho geral tenha sido promissor, observou-se certa taxa de falsos positivos, especialmente em áreas de restaurações com falhas de adaptação, como bolhas de ar ou gaps. Esses falsos positivos podem levar a

tratamentos desnecessários, o que sugere que ajustes futuros no algoritmo são necessários para melhorar a especificidade sem comprometer a sensibilidade. Além disso, a taxa de falsos negativos, foi mais frequente em lesões iniciais, que são menos críticas do ponto de vista clínico. A inclusão de mais dados para treinar o algoritmo e a implementação de técnicas que aprimorem a detecção de lesões iniciais podem aumentar ainda mais a precisão do sistema (SIGNORI et al., 2018b; SCHWENDICKE et al., 2021).

4. CONCLUSÕES

Este estudo desenvolveu um algoritmo eficaz para detecção de cárie secundária em radiografias interproximais, apresentando alta acurácia e especificidade. O modelo se mostrou capaz em distinguir lesões primárias e secundárias, embora tenha apresentado alguns falsos positivos e dificuldade em detectar lesões iniciais. Esses resultados sugerem que o uso da inteligência artificial pode ser uma ferramenta útil para auxiliar no diagnóstico odontológico, ajudando os clínicos a tomar decisões mais informadas.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- BROUWER, F.; ASKAR, H.; PARIS, S.; SCHWENDICKE, F. Detecting Secondary Caries Lesions: A Systematic Review and Meta-analysis. **JOURNAL OF DENTAL RESEARCH**, v. 95, n. 2, p. 143–151, 2016.
- CAI, H.; CHEN, J.; LI, C.; WANG, J.; WAN, Q.; LIANG, X. Quantitative discoloration assessment of peri-implant soft tissue around zirconia and other abutments with different colours: A systematic review and meta-analysis. **Journal of dentistry**, v. 70, p. 110–117, mar. 2018.
- CHAVES, E. T.; VINAYAHALINGAM, S.; NISTELROOIJ, N. VAN; XI, T.; ROMERO, V. H. D.; FLÜGGE, T.; SAKER, H.; KIM, A.; SILVEIRA LIMA, G. DA; LOOMANS, B. Detection of caries around restorations on bitewings using deep learning. **Journal of Dentistry**, p. 104886, 2024.
- KARAKUŞ, R.; ÖZİÇ, M. Ü.; TASSOKER, M. AI-Assisted Detection of Interproximal, Occlusal, and Secondary Caries on Bite-Wing Radiographs: A Single-Shot Deep Learning Approach. **Journal of imaging informatics in medicine**, maio 2024.
- SCHWENDICKE, F.; CEJUDO GRANO DE ORO, J.; GARCIA CANTU, A.; MEYER-LUECKEL, H.; CHAURASIA, A.; KROIS, J. Artificial Intelligence for Caries Detection: Value of Data and Information. **Journal of Dental Research**, v. 101, n. 11, p. 1350–1356, 2022.
- SCHWENDICKE, F.; SINGH, T.; LEE, J. H.; GAUDIN, R.; CHAURASIA, A.; WIEGAND, T.; URIBE, S.; KROIS, J. Artificial intelligence in dental research: Checklist for authors, reviewers, readers. **Journal of Dentistry**, v. 107, n. February, 2021.
- SIGNORI, C.; GIMENEZ, T.; MENDES, F. M.; HUYSMANS, M. C. D. N. J. M.; OPDAM, N. J. M.; CENCI, M. S. Clinical relevance of studies on the visual and radiographic methods for detecting secondary caries lesions – A systematic review. **Journal of Dentistry**, v. 75, n. January, p. 22–33, 2018a.
- SIGNORI, C.; LASKE, M.; MENDES, F. M.; HUYSMANS, M.-C. D. N. J. M.; CENCI, M. S.; OPDAM, N. J. M. Decision-making of general practitioners on interventions at restorations based on bitewing radiographs. **Journal of dentistry**, v. 76, p. 109–116, set. 2018b.