


UNIVERSIDADE FEDERAL DO PARANÁ

BRUNA CRISTINE DIAS

DESEMPENHO DE REDES NEURAIS CONVOLUCIONAIS NA CLASSIFICAÇÃO  
DE LESÕES CARIOSAS EM SUPERFÍCIES OCLUSAIS DE CRIANÇAS COM  
DENTIÇÃO MISTA

CURITIBA

2025



BRUNA CRISTINE DIAS

DESEMPENHO DE REDES NEURAIS CONVOLUCIONAIS NA CLASSIFICAÇÃO  
DE LESÕES CARIOSAS EM SUPERFÍCIES OCLUSAIS DE CRIANÇAS COM  
DENTIÇÃO MISTA

Dissertação de Mestrado apresentada ao curso de  
Pós-Graduação em Odontologia, Setor de  
Ciências da Saúde, Universidade Federal do  
Paraná, como requisito à obtenção do título de  
Mestre em Odontologia, área de concentração:  
Odontopediatria.

Orientadora: Profa. Dra. Luciana Reichert  
Assunção Zanon

Coorientador: Prof. Dr. Lucas Ferrari de Oliveira

CURITIBA  
2025

Dias, Bruna Cristine

Desempenho de redes neurais convolucionais na classificação de lesões cáries em superfícies oclusais de crianças com dentição mista [recurso eletrônico] / Bruna Cristine Dias. – Curitiba, 2025.

1 recurso online : PDF

Dissertação (mestrado) – Programa de Pós-Graduação em Odontologia. Setor de Ciências da Saúde, Universidade Federal do Paraná, 2025.

Orientador: Profa. Dra. Luciana Reichert Assunção Zanon

Coorientador: Prof. Dr. Lucas Ferrari de Oliveira

1. Cárie dentária. 2. Dentição mista. 3. Inteligência artificial. 4. Redes neurais convolucionais. 5. Aprendizagem profunda. I. Zanon, Luciana Reichert Assunção. II. Oliveira, Lucas Ferrari de. III. Universidade Federal do Paraná. IV. Título.

CDD 617.67



MINISTÉRIO DA EDUCAÇÃO  
SETOR DE CIÊNCIAS DA SAÚDE  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ODONTOLOGIA -  
40001016065P8

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ODONTOLOGIA da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **BRUNA CRISTINE DIAS**, intitulada: **Desempenho de redes neurais convolucionais na classificação de lesões cariosas em superfícies oclusais de crianças com dentição mista**, sob orientação da Profa. Dra. **LUCIANA REICHERT ASSUNÇÃO ZANON**, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua **APROVAÇÃO** no rito de defesa.

A outorga do título de mestra está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 11 de Setembro de 2025.

Assinatura Eletrônica

18/09/2025 16:27:57.0

DAVID MENOTTI GOMES

Presidente da Banca Examinadora

Assinatura Eletrônica

19/09/2025 11:31:12.0

JULIANA FELTRIN DE SOUZA CAPARROZ

Avallador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

18/09/2025 17:11:52.0

LUCIANA REICHERT ASSUNÇÃO ZANON

Orientador - Avallador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

## **DEDICATÓRIA**

Dedico este trabalho aos meus pais, Silvane e Marcos, que sempre foram minha base, meu exemplo e meu maior apoio em todas as escolhas da minha vida.

Ao meu irmão, Eduardo, por estar presente com amor e cuidado, oferecendo colo e conforto nos momentos em que mais precisei.

Ao meu noivo, Christhyan, meu companheiro de todos os dias, por caminhar ao meu lado com paciência, carinho e incentivo.

À minha família e aos meus amigos, que são parte essencial da minha história e da realização deste sonho.

E, com gratidão e respeito, a todos os profissionais que atuam na saúde pública e na ciência no Brasil, lutando diariamente para tornar o conhecimento e o cuidado acessíveis a todos.

## **AGRADECIMENTOS**

À Universidade Federal do Paraná, minha casa acadêmica desde a graduação, deixo meu reconhecimento e gratidão. Foi nesta instituição pública, gratuita e de excelência que iniciei minha trajetória na Odontologia e onde agora tenho o privilégio de conquistar o título de mestre.

À minha orientadora, Profa. Dra. Luciana Reichert Assunção Zanon, minha admiração e gratidão. Tive o imenso privilégio de ser sua orientanda em projetos de extensão, em duas iniciações científicas durante a graduação e, atualmente, no mestrado. Obrigada por toda dedicação, paciência e pela confiança depositada em mim ao longo desses anos de convivência e aprendizado.

Ao meu coorientador, Prof. Dr. Lucas Ferrari, por aceitar o desafio de orientar uma aluna de outro departamento, contribuindo de forma única para a integração entre a Odontologia e a Informática. Seu comprometimento e confiança foram fundamentais para que este trabalho fosse possível.

Aos professores do Programa de Pós-Graduação em Odontologia da UFPR, agradeço pelos ensinamentos e pelas valiosas contribuições acadêmicas. Deixo meu especial reconhecimento aos professores Dr. Fabian Fraiz, Dra. Juliana Feltrin e Dr. José Vítor Menezes, cuja dedicação e exemplo profissional me inspiram profundamente.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro concedido por meio da bolsa de estudos, que auxiliou a execução desta pesquisa.

Às alunas de iniciação científica, Luiza Grieshaber e Eduarda Fagherazzi, pelo auxílio durante a coleta e execução da pesquisa, demonstrando dedicação e companheirismo ao longo desse processo.

Às escolas municipais de Curitiba, que gentilmente abriram suas portas e permitiram a realização das fotografias que tornaram este estudo viável.

Ao colega do mestrado em Informática, Mateus Ferreira, meu colega de pesquisa, agradeço por compartilhar comigo essa jornada, tornando-a mais leve, produtiva e enriquecedora.

Aos meus colegas de mestrado e a todos os participantes da pesquisa, obrigada pela colaboração, paciência e apoio ao longo de cada etapa.

Aos meus amigos, que estiveram presentes com carinho, incentivo e compreensão, tornando o percurso mais leve e cheio de bons momentos.

À minha família, meu porto seguro, agradeço por todo amor, cuidado e torcida.

Ao meu irmão, Eduardo, obrigada por ser colo, afeto e café quentinho nos momentos em que mais precisei.

Aos meus pais, Silvane e Marcos, por todo auxílio, incentivo e apoio incondicional em cada escolha da minha vida. Amo vocês profundamente e tenho orgulho imenso de ser sua filha.

Ao meu noivo Christhyan, pelo companheirismo, pela paciência e pelo apoio constante em todos os momentos, e por todo amor sempre. Sua presença foi essencial para que eu conseguisse superar os desafios destes dois anos e chegasse até aqui.

À Deus, por iluminar meus caminhos, fortalecer minha perseverança e colocar ao meu lado pessoas tão especiais que tornaram esta jornada possível.

A todos que, de alguma forma, direta ou indiretamente, contribuíram para a realização deste trabalho, deixo meu profundo agradecimento. Cada gesto, cada palavra de incentivo e cada apoio recebido foram fundamentais para que eu chegasse até aqui.

## RESUMO

A cárie dentária é uma das doenças bucais mais prevalentes, especialmente na fase da dentição mista, devido à imaturidade do esmalte em dentes em erupção, bem como às dificuldades de acesso às superfícies oclusais durante a escovação dentária. O uso do aprendizado profundo, especialmente através de redes neurais convolucionais (CNNs), tem se mostrado promissor no auxílio da detecção de lesões cáries. Este estudo avaliou o desempenho do aprendizado profundo na detecção e classificação de lesões cáries em superfícies oclusais em crianças com dentição mista. Um total de 2.495 fotografias foram realizadas em ambiente escolar com 211 crianças de oito anos de idade. Os elementos dentários e as diferentes condições clínicas nas superfícies oclusais, incluindo lesões cáries, opacidades e restaurações, foram demarcadas e classificadas com o auxílio do software *Computer Vision Annotation Tool* (CVAT), desenvolvido na linguagem *Python*. A classificação das lesões cáries e detecção dos defeitos de desenvolvimento de esmalte foi realizada por meio do índice *International Caries Detection and Assessment System* (ICDAS) e pelo critério proposto por Ghanim, respectivamente, por duas examinadoras calibradas, por meio de três etapas, que incluíram atividades teóricas, exercício de calibração – em que 33 fotografias contendo superfícies oclusais dentárias com diferentes escores do ICDAS foram comparados ao padrão ouro (doutora em Odontopediatria e experiente em estudos epidemiológicos) – e análise estatística, obtendo resultado de Kappa ponderado de concordância intra-examinadores e interexaminadores ( $>95\%$  e  $K \geq 0,802$ ). Por meio de um *script* em linguagem Python, foram realizadas as categorizações dos escores do ICDAS em: Hígido (escore 0), lesões iniciais (escores 1-3) e lesões moderadas/severas (escores 4-6). As imagens foram divididas em bases de treinamento (80%), teste (10%) e validação (10%). Diferentes CNNs foram avaliadas, incluindo YOLOv11, U-Net e ConvNext, individualmente e de forma combinada (*ensemble*). O desempenho dos modelos foi avaliado por meio das métricas de acurácia, precisão, sensibilidade e F1 score. Do total de imagens avaliadas, 945 foram incluídas na base para a detecção e segmentação dos dentes posteriores e 1655 para a classificação das lesões cáries. Em relação à segmentação e detecção de dentes posteriores irrompidos e em erupção, a YOLOv11 apresentou precisão de 0,967 e sensibilidade de 0,938 na

detecção de dentes posteriores, identificando 96,1% dos dentes permanentes parcialmente irrompidos. A U-Net alcançou precisão de 0,953 e sensibilidade de 0,951, detectando 78,4% dos dentes em erupção. Para a classificação das lesões cariosas, a CNN YOLOv11 apresentou maior proporção de verdadeiros positivos para superfícies hígidas (93,2%) e menor para lesões iniciais (70,6%) e moderadas/severas (66,7%). Na CNN ConvNext, as proporções de detecções corretas foram semelhantes entre as três classes, sendo 84,7% para superfícies hígidas, 82,4% para lesões iniciais e 83,3% para lesões moderadas/severas. O ensemble entre as CNNs YOLOv11 e ConvNext, utilizando a abordagem *classwise*, apresentou o melhor desempenho, com proporções de classificações corretas de 93,2%, 84,3% e 83,3% para superfícies hígidas, iniciais e moderadas/severas, respectivamente. Em relação às métricas avaliadas, a YOLOv11 obteve acurácia média de 0,800, enquanto a ConvNext alcançou 0,810, apresentando desempenho superior, embora com maior número de falsos positivos. O *ensemble* entre as CNNs YOLOv11 e ConvNext, por sua vez, proporcionou os melhores resultados globais, com acurácia, precisão, sensibilidade e F1-score de 0,820, além da redução de proporção de falsos positivos entre superfícies hígidas e iniciais, e entre lesões iniciais e hígidas. Os achados evidenciam que o aprendizado profundo, por meio da utilização de estratégias de combinação das CNNs YOLOv11 e ConvNext, apresenta elevado potencial como ferramenta auxiliar na classificação de lesões cariosas em crianças com dentição mista. Estes resultados reforçam a contribuição do aprendizado profundo na identificação de diferentes graus de severidade de lesões cariosas, principalmente na classificação de lesões cariosas em estágio inicial, possibilitando intervenção precoce e a incorporação de tecnologias inovadoras na prática clínica em odontopediatria.

**Palavras-chave:** inteligência artificial; redes neurais convolucionais;

aprendizagem profunda; cárie dentária; dentição mista.

## ABSTRACT

Dental caries is one of the most prevalent oral diseases, particularly during the mixed dentition phase, due to the immaturity of enamel in erupting teeth and the difficulties in accessing occlusal surfaces during toothbrushing. The use of deep learning, especially through convolutional neural networks (CNNs), has shown promise in assisting the detection of carious lesions. This study evaluated the performance of deep learning in the detection and classification of carious lesions on occlusal surfaces in children with mixed dentition. A total of 2,495 photographs were obtained in a school setting from 211 eight-year-old children. Dental elements and different clinical conditions on occlusal surfaces, including carious lesions, opacities, and restorations, were annotated and classified using the Computer Vision Annotation Tool (CVAT), developed in Python. Carious lesions and developmental defects of enamel (DDE) were classified using the International Caries Detection and Assessment System (ICDAS) and the criteria proposed by Ghanim, respectively, by two calibrated examiners through a three-step process comprising theoretical activities, calibration exercises — where 33 photographs containing occlusal surfaces with different ICDAS scores were compared to the gold standard (a pediatric dentistry specialist with expertise in epidemiological studies) — and statistical analysis, yielding weighted Kappa values for intra- and inter-examiner agreement ( $>95\%$  and  $K \geq 0,802$ ). Using a Python script, ICDAS scores were categorized into: Sound (score 0), initial lesions (scores 1–3), and moderate/severe lesions (scores 4–6). Images were divided into training (80%), testing (10%), and validation (10%) datasets. Different CNNs were evaluated, including YOLOv11, U-Net, and ConvNext, both individually and in combination (ensemble). Model performance was assessed using accuracy, precision, sensitivity, and F1-score. Of the total images, 945 were included for the detection and segmentation of posterior teeth and 1,655 for caries classification. For segmentation and detection of erupted and erupting posterior teeth, YOLOv11 achieved a precision of 0,967 and sensitivity of 0,938, identifying 96,1% of partially erupted permanent teeth. U-Net achieved a precision of 0,953 and sensitivity of 0,951, detecting 78,4% of erupting teeth. For caries classification, YOLOv11 showed the highest proportion of true positives for sound surfaces (93,2%) and lower proportions for initial (70,6%) and moderate/severe lesions (66,7%). ConvNext demonstrated similar detection proportions across classes, with 84,7% for

sound surfaces, 82,4% for initial lesions, and 83,3% for moderate/severe lesions. The ensemble of YOLOv11 and ConvNext, using a classwise approach, yielded the best performance, with correct classification rates of 93,2%, 84,3%, and 83,3% for sound, initial, and moderate/severe surfaces, respectively. Regarding overall metrics, YOLOv11 achieved an average accuracy of 0,800, while ConvNext reached 0,810, showing superior performance though with more false positives. The YOLOv11 and ConvNext ensemble provided the best global results, with accuracy, precision, sensitivity, and F1-score of 0,820, along with a reduction in false positives between sound and initial surfaces and between initial and sound lesions. The findings demonstrate that deep learning, particularly through combined strategies using YOLOv11 and ConvNext, has strong potential as an auxiliary tool in the classification of carious lesions in children with mixed dentition. These results highlight the contribution of deep learning to identifying different severities of carious lesions, especially in the classification of early-stage lesions, enabling early intervention and the integration of innovative technologies into pediatric dentistry clinical practice.

**Keywords:** Artificial Intelligence; Convolutional Neural Networks; Deep Learning; Dental Caries; Mixed Dentition.

## LISTA DE FIGURAS

|                                                        |    |
|--------------------------------------------------------|----|
| FIGURA 1 – DIAGRAMA INTELIGÊNCIA ARTIFICIAL (IA) ..... | 8  |
| FIGURA 2 – FLUXOGRAMA CÓDIGO ICDAS .....               | 18 |
| FIGURA 3 – INTERFACE SOFTWARE CVAT .....               | 20 |
| FIGURA 4 – MARCAÇÕES REALIZADAS NO SOFTWARE CVAT ..... | 21 |
| FIGURA 5 – ARQUITETURA DA CNN YOLOV11 .....            | 22 |
| FIGURA 6 – ARQUITETURA DA CNN U-NET .....              | 23 |

## **LISTA DE TABELAS**

|                                                    |    |
|----------------------------------------------------|----|
| TABELA 1 – ESTUDOS QUE AVALIARAM ICDAS x CNN ..... | 13 |
|----------------------------------------------------|----|

## LISTA DE QUADROS

|                                                      |    |
|------------------------------------------------------|----|
| QUADRO 1 – CATEGORIAS UNIFICADAS ICDAS ICCMS™ .....  | 6  |
| QUADRO 2 – MÉTRICAS ESTATÍSTICAS DE DESEMPENHO ..... | 24 |

## LISTA DE ABREVIATURAS OU SIGLAS

|       |                                                          |
|-------|----------------------------------------------------------|
| CAAE  | - Certificado de Apresentação de Apreciação Ética        |
| CAD   | - Diagnóstico Assistido por Computador                   |
| CBCT  | - Tomografia Computadorizada de Feixe Cônico             |
| ceo-d | - Cariados, extraídos e obturados na dentição decídua    |
| CNN   | - <i>Convolutional Neural Networks</i>                   |
| CPO-D | - Cariados, Perdidos e Obturados na dentição permanente  |
| CVAT  | - <i>Computer Vision Annotation Tool</i>                 |
| DDE   | - Defeitos de Desenvolvimento de Esmalte                 |
| DL    | - <i>Deep Learning</i>                                   |
| EAPD  | - <i>European Academy of Paediatric Dentistry</i>        |
| FDI   | - Federação Dentária Internacional                       |
| FN    | - Falsos Negativos                                       |
| FP    | - Falsos Positivos                                       |
| HMI   | - Hipomineralização Molar-Incisivo                       |
| IA    | - Inteligência Artificial                                |
| IBM   | - International Business Machines Corporation            |
| ICDAS | - Sistema Internacional de Detecção e Avaliação de Cárie |
| ID    | - Número de identificação                                |
| ISO   | - <i>International Organization for Standardization</i>  |
| K     | - <i>Kappa value</i>                                     |
| ML    | - <i>Machine Learning</i>                                |
| OMS   | - Organização Mundial de Saúde                           |
| TP    | - Verdadeiros Positivos                                  |
| TN    | - Verdadeiros Negativos                                  |
| UFPR  | - Universidade Federal do Paraná                         |
| WHO   | - <i>World Health Organization</i>                       |

## SUMÁRIO

|          |                                         |           |
|----------|-----------------------------------------|-----------|
| <b>1</b> | <b>INTRODUÇÃO .....</b>                 | <b>01</b> |
| <b>2</b> | <b>OBJETIVOS .....</b>                  | <b>15</b> |
| 2.1      | Objetivo geral .....                    | 15        |
| 2.2      | Objetivos específicos .....             | 15        |
| <b>3</b> | <b>MATERIAL E MÉTODOS .....</b>         | <b>16</b> |
| <b>4</b> | <b>ARTIGO 1 .....</b>                   | <b>26</b> |
| <b>5</b> | <b>ARTIGO 2 .....</b>                   | <b>32</b> |
| <b>6</b> | <b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b> | <b>51</b> |
| <b>7</b> | <b>ANEXOS .....</b>                     | <b>60</b> |

|                                                                        |    |
|------------------------------------------------------------------------|----|
| ANEXO 1 - COMPROVANTE DE RECEPÇÃO À APRECIÇÃO AO COMITÊ DE ÉTICA ..... | 60 |
|------------------------------------------------------------------------|----|

|                                                                                           |    |
|-------------------------------------------------------------------------------------------|----|
| ANEXO 2 - CRITÉRIO DO SISTEMA INTERNACIONAL DE DETECÇÃO E AVALIAÇÃO DE CÁRIE (ICDAS)..... | 68 |
|-------------------------------------------------------------------------------------------|----|

|                                                                                                      |    |
|------------------------------------------------------------------------------------------------------|----|
| ANEXO 3 - CRITÉRIO CLÍNICO PARA CLASSIFICAÇÃO DOS DEFEITOS DE DESENVOLVIMENTO DO ESMALTE (DDE) ..... | 69 |
|------------------------------------------------------------------------------------------------------|----|

|                                                                                        |    |
|----------------------------------------------------------------------------------------|----|
| ANEXO 4 – NORMAS DE SUBMISSÃO DA REVISTA “ <i>CLINICAL ORAL INVESTIGATIONS</i> ” ..... | 70 |
|----------------------------------------------------------------------------------------|----|

## 1. INTRODUÇÃO

A cárie dentária é uma das doenças bucais mais prevalentes em todo o mundo (SELWITZ et al., 2007), podendo afetar ambas as dentições, decídua e permanente (PITTS et al., 2017). Embora seja uma doença multifatorial, ela é determinada pela presença de carboidratos fermentáveis no meio bucal, em especial a sacarose, e dependente da presença de biofilme dental, além de envolver interações entre hospedeiro, substrato e microrganismo (CONRAD, 2018; SELWITZ et al., 2007). O desenvolvimento e a progressão da doença são determinados pela disbiose na comunidade microbiana bucal e aumento de microrganismos acidogênicos e acidúricos em função da alta ingestão de açúcares e higiene bucal inadequada (PITTS et al., 2017). Os fatores protetores para o desenvolvimento da doença incluem a presença de flúor constante na cavidade bucal, escovação com dentifrício fluoretado duas vezes ao dia, além de uma dieta balanceada e função salivar normal (PITTS et al., 2017), enquanto os fatores de risco incluem higiene bucal inadequada, dieta rica em açúcares, altos níveis de bactérias cariogênicas, exposição insuficiente ao flúor, fluxo salivar inadequado, métodos inadequados de alimentação de lactentes, histórico prévio da doença e baixo nível socioeconômico (RAJA et al., 2025).

O conceito de "cárie dentária" refere-se ao processo de dissolução química das superfícies dentárias, resultante de atividades metabólicas que ocorrem no biofilme, ou placa bacteriana, que recobre a superfície dentária. Caso os métodos de controle da doença não sejam incorporados, ocorre a formação de lesões, que dependendo da gravidade, compromete diferentes estruturas e tecidos dentários. Clinicamente, as lesões podem apresentar diferentes padrões quanto à severidade e ao número de superfícies envolvidas. (FEJERSKOV et al., 2017).

A doença cárie é o processo dinâmico de desequilíbrio no biofilme, e a lesão de cárie é a sua manifestação, ou seja, o sinal clínico visível desse processo de desmineralização. A lesão é a consequência do processo da doença (FEJERSKOV et al., 2017). A lesão de cárie indica também a atividade da doença cárie, em que as características visuais da lesão — como a opacidade, a textura da superfície e a localização — podem ser usadas para determinar se a lesão está ativa ou inativa (ISMAIL et al., 2007; PITTS et al., 2004).

O estágio inicial da lesão cariosa pode ser identificado como uma lesão de mancha branca, sinalizando o primeiro sinal clínico da doença no esmalte dentário. Neste estágio, a lesão é passível de ser remineralizada através de fluoretos, no entanto, se não for controlada, pode progredir em profundidade e extensão, levando à cavitação (MAGALHÃES, 2021).

A cárie dentária afeta negativamente a qualidade de vida dos indivíduos, particularmente quando atinge o complexo dentino-pulpar. Essa condição pode provocar dor, comprometer a função e a estética dental, além de demandar intervenções mais complexas de tratamento (MAGALHÃES, 2021). Uma vez que a doença é difícil de ser controlada, representa um desafio para a saúde pública globalmente (PERES, et al., 2019). Além disso, existem algumas especificidades nos diferentes ciclos de vida que apresentam desafios e que resultam em fatores de risco para a doença, como a fase da dentição mista (RAJA et al., 2025).

A dentição mista representa o período de transição da dentição decídua para a dentição permanente e geralmente ocorre entre os seis e 12 anos de idade (RAJA et al., 2025). A troca de dentes decíduos pelos sucessores permanentes pode dificultar a higiene bucal, em razão da diferença de altura entre os dentes já presentes e aqueles em processo de erupção, gerando áreas de difícil acesso à escovação (SHI et al., 2016). Além disso, crianças nessa faixa etária podem não ter a compreensão ou habilidade para uma escovação eficaz, especialmente nos dentes posteriores (LYNCH, 2013).

As superfícies oclusais são especialmente propensas ao desenvolvimento de lesões cariosas, devido à sua macromorfologia com a presença de fóssulas, sulcos e fissuras, que facilitam o acúmulo do biofilme que pode permanecer por períodos prolongados se não houver uma higiene bucal adequada (FEJERSKOV et al., 2017). Estas superfícies são também mais suscetíveis à doença nos estágios iniciais de erupção devido à ausência de maturação pós-eruptiva do esmalte e dificuldades no controle do biofilme nesta fase (CARVALHO, 2014; CARVALHO et al., 2016).

O exame radiográfico é principal método auxiliar para detecção e diagnóstico de cárie dentária. Enquanto o exame visual tátil constitui a base do diagnóstico clínico, sendo fundamental para a detecção de lesões iniciais em superfícies dentária livres, como faces oclusais, vestibulares e palatinas/linguais, o exame radiográfico, principalmente a radiografia interproximal, é indispensável para a

identificação de lesões em áreas proximais clinicamente inacessíveis (FEJERSKOV et al., 2017).

Os avanços no diagnóstico da doença cárie têm o objetivo da detecção dos estágios iniciais da doença, por serem irreversíveis, além de melhor assertividade no planejamento clínico (AL SAFFAN, 2023). O exame radiográfico é indiscutivelmente um importante auxílio na detecção das lesões cariosas, especialmente naquelas que atingem as superfícies interproximais (RODRIGUES et al., 2025). No entanto, é um método com limitações na detecção dos estágios iniciais de desmineralização do esmalte dentário (SCWENDICKE et al., 2015).

Com o passar do tempo, outras técnicas, consideradas mais avançadas, foram incorporadas como auxiliares à detecção das lesões cariosas. Outros exames, como Transiluminação por Fibra Óptica de Imagem Digital mostram maior sensibilidade na visualização de lesões incipientes (ASTVALDSDÓTTIR et al., 2012). Técnicas elétricas e de impedância apresentam desempenho promissor para diferenciar tecidos dentais afetados, principalmente em superfícies proximais (AL SAFFAN, 2023; MACEY et al., 2021). A fluorescência induzida por laser, exemplificada pelo DIAGNOdent, pode ser utilizada como ferramenta não invasiva para a detecção quantitativa da desmineralização, e como método auxiliar ao exame visual (OLMEZ, 2006). Tecnologias emergentes, como a radiometria fotométrica infravermelha, são estudadas por sua especificidade na diferenciação tecidual (AL SAFFAN, 2023). Ainda, a análise de biomarcadores salivares tem demonstrado potencial significativo para o diagnóstico precoce e personalizado da doença, por meio da associação entre proteínas salivares e risco e progressão da doença cárie (HAVSED et al., 2024). No entanto, os métodos citados apresentam algumas limitações, como a necessidade de treinamento especializado para correta interpretação dos resultados e o elevado custo dos equipamentos, fatores que podem restringir sua aplicabilidade em contextos clínicos rotineiros. (RECHMANN et al., 2021).

Por outro lado, apesar dos avanços das técnicas como auxiliares na detecção de lesões cariosas, o exame visual continua sendo o método padrão-ouro, por meio da inspeção visual-tátil durante o exame clínico (GOMEZ, 2015. ZHANG, 2022 PRETTY et al., 2013; TAKAMORI et al., 2001). Por meio dele, o profissional é capaz de observar todos os parâmetros que devem ser julgados na lesão, tais como

localização, estimativa da profundidade, integridade da superfície ou perda de estrutura (cavidade), potencial de retenção de biofilme, coloração e textura, sendo esses três últimos importantes sinalizadores da atividade da doença (GIMENEZ et al., 2015).

Como a experiência do examinador pode influenciar os resultados do exame visual-tátil, índices clínicos têm sido recomendados para a avaliação de lesões cariosas, proporcionando uma padronização na classificação dessas lesões (ISMAIL et al., 2004). A utilização de um índice contribui para aumentar a precisão do método visual, como demonstrado em uma revisão sistemática, que analisou estudos sobre a acurácia desse método, tanto em condições *in vitro* quanto *in vivo* (GIMENEZ et al., 2015).


O índice mais amplamente utilizado em estudos epidemiológicos é o índice da Organização Mundial da Saúde (OMS) que se baseia no número de dentes cariados, perdidos por cárie e obturados ou pelos mesmos parâmetros considerando a superfície dentária. Na dentição permanente, o número de dentes afetados é calculado pelo CPO-D, sendo o resultado da soma de seus três componentes: número de dentes cariados (C), número de dentes perdidos devido à cárie (P) e aqueles que receberam tratamento restaurador (O). Já a versão adaptada para a dentição decídua, o ceo-d, segue o mesmo princípio, diferenciando-se apenas pela utilização de letras minúsculas, representando respectivamente os dentes cariados (c), extraídos (e) e obturados (o) (OMS, 1997).

Nos últimos anos, o *International Caries Detection and Assessment System* (ICDAS) também tem sido proposto para a detecção de lesões de cárie. O índice foi construído por um grupo de especialistas em cariologia, que uniram suas habilidades e conhecimentos com o objetivo de desenvolver um sistema de classificação para a avaliação destas lesões. Este sistema foi projetado para ser aplicado de maneira universal, abrangendo áreas como prática clínica, estudos epidemiológicos, pesquisa científica e ensino acadêmico (ISMAIL et al., 2007; PITTS et al., 2004). O ICDAS é o sistema mais acurado para o diagnóstico de cárie oclusal pois sua classificação clínica apresenta alta correlação com a profundidade histológica da lesão, permitindo detectar desde a desmineralização inicial do esmalte até a cavitação na dentina (ISMAIL et al., 2007; PITTS et al., 2004).

O sistema ICDAS classifica as lesões cariosas em uma escala variando de 0 a 6, considerando a progressão da desmineralização e a integridade da estrutura dentária. Cada escore é definido como (ISMAIL et al., 2007):

- **0:** Hígido (sem sinais de cárie após a secagem da superfície).
- **1:** Primeira alteração visual no esmalte (visível apenas após secagem da superfície, restrita ao interior de uma fóssula ou sulco).
- **2:** Alteração visual distinta no esmalte (visível em esmalte úmido, sem necessidade de secagem).
- **3:** Descontinuidade localizada do esmalte (sem sinais clínicos visuais de envolvimento da dentina).
- **4:** Sombreamento escurecido subjacente da dentina (sinal de cárie em dentina).
- **5:** Cavidade distinta com dentina visível (envolvendo menos da metade da superfície dentária).
- **6:** Cavidade extensa e distinta com dentina visível (envolvendo mais da metade da superfície dentária).

O Scores do ICDAS com as categorias unificadas, segundo o *The International Caries Classification and Management System (ICCMS™)* de 2015, são divididas entre superfícies hígidas (código 0), cárie em estágio inicial (códigos 1 e 2), cárie em estágio moderado (códigos 3 e 4) e cárie em estágio extenso/severo (códigos 5 e 6). Esta divisão está exemplificada no quadro 1.

| Definição das categorias unificadas de cárie segundo o ICCMS™ |                                                                    |                                                                                     |                                                                                                                                                                                                                                                                                                                                                                                                                                                                    |
|---------------------------------------------------------------|--------------------------------------------------------------------|-------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Categoria de cárie                                            | <b>Superfícies Híidas</b><br>(ICDAS™ Código 0)                     |    | Superfícies dentárias híidas não apresentam evidência de cárie visível (ou alteração no esmalte) quando visualizadas limpas e após secagem com ar por 5 segundos.<br><i>(Superfícies com defeitos de desenvolvimento de esmalte, como hipomineralização do esmalte — incluindo fluorose —, desgaste dentário, abrasão e erosão, e manchas extrínsecas ou intrínsecas são registradas como híidas)</i>                                                              |
|                                                               | <b>Cárie em estágio inicial</b><br>(Códigos ICDAS™ 1 e 2)          |    | Alterações iniciais visíveis no esmalte como lesão branca ou marrom, opaca, característica de cárie, mas que não apresentam evidência de cavitação ou sombra de dentina subjacente não compatível com a aparência clínica de esmalte híido. Quando visível apenas em esmalte após secagem por 5 segundos (ICDAS™ código 1 ou em esmalte úmido (ICDAS™ código 2).                                                                                                   |
|                                                               | <b>Cárie em estágio moderado</b> (Códigos ICDAS™ 3 e 4)            |  | Lesão branca ou marrom com descontinuidade localizada em esmalte, sem exposição de dentina visível (ICDAS™ código 3), ou um sombreamento em dentina subjacente (ICDAS™ código 4) que se originou da superfície que está sendo avaliada.<br><i>(Para confirmar a descontinuidade do esmalte, pode-se usar suavemente a sonda esférica OMS sobre a área — uma descontinuidade limitada é detectada se a ponta cair na microcavidade/descontinuidade do esmalte.)</i> |
|                                                               | <b>Cárie em estágio extenso / severo</b><br>(Códigos ICDAS™ 5 e 6) |  | Cavidade com <b>dentina visível</b> , sendo até 50% da superfície avaliada (ICDAS™ código 5) ou mais de 50% da superfície avaliada (ICDAS™ código 6).<br><i>(A sonda OMS pode confirmar se a cavidade atinge a dentina.)</i>                                                                                                                                                                                                                                       |

Quadro 1 – Escores do ICDAS com as categorias unificadas, segundo o *The International Caries Classification and Management System (ICCMS™)*, de 2015.

O Índice da OMS (CPO-D/ceo-d) e o ICDAS diferem entre si, principalmente em sua metodologia, nível de detalhamento e aplicabilidade. Enquanto o índice da OMS é um método epidemiológico simplificado, sem distinguir a severidade das

lesões (OMS, 1997), o ICDAS adota uma abordagem mais detalhada, categorizando as lesões em sete estágios progressivos, desde esmalte hígido até cavidades extensas envolvendo dentina e polpa (ISMAIL et al., 2007).

Embora a padronização do exame clínico por meio de critérios bem definidos ofereça vantagens significativas, a precisão do índice ICDAS está diretamente relacionada à experiência profissional do examinador e à realização de treinamentos e calibração prévios (ISMAIL et al., 2007). Sendo assim, considerando a complexidade clínica dos diferentes estágios das lesões cariosas, o diagnóstico dessas condições pode representar um desafio aos cirurgiões-dentistas, especialmente aqueles com menor experiência clínica (BARZOTTO et al., 2018; RIGO et al., 2015).


Nos últimos anos, a Inteligência Artificial (IA), tem sido proposta para facilitar o processo de tomada de decisão para diferentes condições em saúde (PARK et al., 2022), trazendo vantagens como menor custo operacional e maior acessibilidade em comparação à outras tecnologias (SCHWENDICKE et al., 2021).

A IA evoluiu do conceito de IA forte, que busca replicar a cognição humana, para a IA fraca, focada na resolução de problemas específicos por meio de algoritmos e aprendizado de máquina (HWANG et al., 2019; PARK, 2018). Enquanto a IA forte visa a autonomia no raciocínio e tomada de decisões, a IA fraca se restringe a tarefas como reconhecimento de padrões e análise de dados. Esse avanço permitiu sua aplicação na odontologia, otimizando diagnósticos, previsões de tratamento e personalização do atendimento (HWANG et al., 2019; MUPPARAPU et al., 2018).

A Inteligência Artificial (IA) é o campo abrangente da ciência da computação que visa simular a inteligência humana em máquinas (HWANG et al., 2019), dentro do qual o Aprendizado de Máquina (em inglês: *machine learning*; ML) representa um subconjunto focado no desenvolvimento de algoritmos que permitem aos sistemas aprenderem padrões a partir de dados, sem programação explícita (MUPPARAPU et al., 2018). Dentro do ML, o Aprendizado Profundo (em inglês: *deep learning*; DL) surge como uma abordagem avançada que emprega redes neurais profundas para modelar representações hierárquicas e extrair características complexas de grandes volumes de dados (PARK et al., 2022). Especificamente, as Redes Neurais Convolucionais (CNNs) constituem uma classe de DL projetada para processar

dados estruturados espacialmente, como imagens, utilizando camadas convolucionais para capturar padrões locais e aprimorar a extração de características relevantes, permitindo avanços significativos em tarefas como reconhecimento de objetos, visão computacional e análise de vídeos (LECUN et al., 2015).

A relação hierárquica entre estes termos pode ser verificada na Figura 1.



**Figura 1** – Diagrama ilustrativo da relação hierárquica entre Inteligência Artificial (IA), Aprendizado de Máquina ou *Machine Learning* (ML), Aprendizado Profundo ou *Deep Learning* (DL), e Redes neurais convolucionais ou *Convolutional Neural Networks* (CNN).

O DL, resultado da aprendizagem a partir de dados rotulados, permite a extração automatizada de características e a geração de modelos de algoritmos treináveis (SCHMIDHUBER, 2015). Nos últimos anos, DL tem apresentado contribuições significativas para a análise de imagens médicas (CHAN et al., 2020; LITJENS et al., 2017; MAZUROWSKI et al., 2019; SAHINER et al., 2019).

Assim, enquanto o aprendizado de máquina, utiliza algoritmos a partir da extração de dados (HWANG et al., 2019; MUPPARAPU et al., 2018), o aprendizado profundo utiliza as redes neurais convolucionais (CNNs), também conhecidas *ConvNets*, para processar imagens mais complexas devido à sua capacidade de extrair múltiplas características em camadas de filtros abstraídos (HWANG et al.,

2019). Essas redes são projetadas para explorar padrões e estruturas dentro das imagens, independentemente de suas localizações específicas, por meio de camadas convolucionais que operam de maneira hierárquica e não linear (LECUN et al., 2015; YU, 2013). As CNNs utilizam múltiplas camadas de neurônios convolucionais para analisar características de baixo nível, como bordas e texturas, até características mais complexas e específicas da imagem, tornando-se altamente eficazes na análise de dados visuais (HWANG et al., 2019; LECUN et al., 2015).

As CNNs têm demonstrado um avanço em visão computacional, incluindo o reconhecimento de objetos, faces, atividades, bem como rastreamento, mapeamento e localização tridimensional (SKLAN et al., 2015).

Assim, técnicas computacionais avançadas, baseadas em algoritmos, têm sido aplicadas para extrair informações relevantes a partir de imagens, uma prática amplamente consolidada em outras áreas, como o reconhecimento facial em câmeras digitais (LECUN et al., 2015; PRINCE, 2012). Essas aplicações operam por meio da extração e classificação de características estruturais, considerando parâmetros como forma, iluminação e distribuição de cor (SHAPIRO; STOCKMAN, 2000).

No contexto das imagens médicas, o aprendizado profundo tem contribuído significativamente no diagnóstico assistido por computador (CAD) com consequente aprimoramento na caracterização e estadiamento de doenças, previsão de prognósticos e estimativa de riscos em múltiplas modalidades de imagem (CHAN et al., 2020). As aplicações mais comuns do CAD com o aprendizado profundo incluem a diferenciação entre condições patológicas e padrões normais, a diferenciação entre lesões benignas e malignas e a previsão de riscos diferenciados – alto ou baixo – do desenvolvimento de câncer. Além disso, esses métodos têm sido aplicados à segmentação e classificação de órgãos e tumores de variadas naturezas, assim como na análise de alterações dimensionais ou texturais de tumores. Essas últimas aplicações, em particular, têm contribuído para a avaliação precisa da resposta ao tratamento, assim como para a previsão de prognósticos e a detecção de possíveis recorrências (CHAN et al., 2020).

Nos últimos anos, a Odontologia tem acompanhado o avanço da Inteligência Artificial (IA) com crescente interesse, especialmente devido à aplicação dessas ferramentas no diagnóstico e na prática clínica (HWANG et al., 2019). Técnicas

computacionais avançadas, baseadas em algoritmos, têm sido aplicadas para extrair informações relevantes a partir de imagens, uma prática amplamente consolidada em outras áreas, como o reconhecimento facial em câmeras digitais (PRINCE, 2012; LECUN et al., 2015). Essas aplicações operam por meio da extração e classificação de características estruturais, considerando parâmetros como forma, iluminação e distribuição de cor (SHAPIRO; STOCKMAN, 2000).

A Odontologia se apresenta como uma área particularmente promissora para a aplicação de técnicas de Inteligência Artificial (IA), devido ao papel central das imagens odontológicas em todas as etapas do tratamento – desde a triagem inicial até o planejamento e a execução do tratamento. A prática odontológica frequentemente integra múltiplas imagens de uma mesma região anatômica de um paciente, complementadas por informações detalhadas realizadas em anamnese, incluindo histórico médico e odontológico, condições sistêmicas e uso de medicamentos. Muitas condições dentárias, como lesões cariosas, lesões apicais e perda óssea periodontal, apresentam alta prevalência na população, reforçando a necessidade de ferramentas diagnósticas aprimoradas (SCHWENDICKE et al., 2020).

A aplicação das CNNs representa um avanço significativo, especialmente como método auxiliar ao diagnóstico de doenças e alterações bucais. Por meio da automatização da extração e classificação de padrões dentários em imagens clínicas e radiográficas, essas redes têm o potencial de fornecer informações úteis e objetivas para os cirurgiões-dentistas, melhorando a precisão diagnóstica e otimizando a tomada de decisões clínicas (LECUN et al., 2015; LITJENS et al., 2017). A utilização dessas ferramentas pode abranger desde a detecção de lesões cariosas e anomalias estruturais até a avaliação de padrões associados a doenças periodontais, lesões ósseas e tumores, contribuindo para um manejo mais eficiente dos pacientes (HWANG et al., 2019).

Além do diagnóstico e detecção de padrões de anormalidade, a IA pode também ser utilizada na detecção de estruturas bucais de normalidade como padrões anatômicos, localização do forame apical, análise da morfologia radicular e identificação precisa de pontos cefalométricos, aspectos essenciais para o planejamento clínico e cirúrgico (KHANAGAR et al., 2021).

De acordo com uma recente revisão sistemática, nos últimos 10 anos, vários estudos foram publicados na detecção de alterações bucais utilizando exames de imagem odontológicos (ALHARBI et al., 2024). Alguns estudos incluem a utilização de exames extrabuciais como tomografia computadorizada de feixe cônico (CBCT) (MIKI et al., 2017; WIDIASRI et al., 2022; XIE et al., 2023), radiografias cefalométricas laterais (ARIK et al., 2017; SEO et al., 2023; SONG et al., 2020) e radiografias panorâmicas (ALBAHBAH et al., 2016; JADER et al., 2018; MURAMATSU et al., 2021; MURESAN et al., 2020; TUZOFF et al., 2019). Já outras pesquisas utilizam exames intrabuciais como radiografias interproximais (AYHAN et al., 2024; CANTU et al., 2020; CHAVES et al., 2024; LEE et al., 2021; SRIVASTAVA et al., 2017) e radiografias periapicais (CHEN et al., 2019; LEE et al., 2018; ZHANG et al., 2018).

O número de modelos de IA para a detecção de lesões cariosas a partir de fotografias orais aumentou de forma ascendente nos últimos anos. Uma revisão sistemática de 2023 detectou nas bases de dados dezenove estudos que utilizaram IA na detecção de lesões de cárie dentária em fotografias intrabuciais (MOHARRAMI et al., 2023). Outra revisão sistemática publicada em 2024 (ALHARBI et al., 2024), observou oito estudos que utilizaram fotografias intrabuciais, sendo dois deles avaliando a detecção de lesões cariosas (KÜHNISCH et al., 2022; ZHANG et al., 2022). Além destes estudos presentes nas revisões sistemáticas, outros 13 estudos publicados a partir de 2016, também utilizaram imagens intrabuciais para a detecção de lesões cariosas (ADNAN et al., 2024; DING et al., 2021; FRENKEL et al., 2024; KANG et al., 2024; KUHNISCH et al., 2022; LI et al., 2021; LIU et al., 2024; MEHDIZADEH et al., 2024; MOUTSELOS et al., 2019; PARK et al., 2022; XIONG et al., 2024; YOON et al., 2024; ZHANG et al., 2022).

No entanto, antes que o método de aprendizado profundo possa detectar as lesões cariosas, é imperioso, que ocorra a detecção do elemento dentário (CHEN et al., 2019; TUZOFF et al., 2019; ZHANG et al., 2018). Esta fase permite a delimitação precisa das estruturas dentárias, minimizando a interferência de ruídos provenientes de tecidos moles, artefatos clínicos e áreas não relevantes da imagem (LIAN et al., 2021). A implementação da segmentação dentária como etapa preliminar para detecção de lesões cariosas revela-se determinante para a padronização metodológica, reprodutibilidade dos achados das soluções baseadas em inteligência

artificial como método auxiliar ao diagnóstico odontológico (PARK et al., 2022). No entanto, apenas dois estudos relataram a segmentação dentária como etapa prévia para detecção de lesões cariosas (PARK, 2022; ASCI, 2024; YOON, 2024). Por outro lado, o reconhecimento das superfícies dentárias pode ser desafiador em função das variações de padrões como é o caso da dentição mista.

No caso da identificação das lesões cariosas por algoritmos de CNNs treinados a partir dos escores do ICDAS, as principais dificuldades ocorrem em razão de variações mais sucintas, especialmente em estágios iniciais das lesões (escores 1 e 2). Estudos que analisaram o desempenho de CNNs, como Mask R-CNN e VGG-16, utilizando os escores do índice, reportaram desafios na distinção entre ausência de cárie (ICDAS 0) e lesões iniciais (ICDAS 1-3), devido à pouca diferenciação visual dessas alterações e à variação na qualidade das imagens (MOUTSELOS et al., 2019; ZHANG et al., 2022). Por outro lado, estudos que focaram em lesões de estágios mais avançados (ICDAS 4-6), relataram maior precisão, sugerindo que os estágios iniciais demandam maior sensibilidade do modelo (KANG et al., 2024; PARK et al., 2022). Além disso, a escassez de imagens de alta qualidade para os primeiros estágios do ICDAS, aliada à dificuldade em reduzir ambiguidades diagnósticas apenas com imagens fotográficas, pode impactar negativamente no desempenho das CNNs (KÜHNISCH et al., 2022; MEHDIZADEH et al., 2024).

Até o presente momento, nove estudos utilizaram fotografias intraorais para compor a base de imagens, e o índice ICDAS como critério para a detecção de lesões de cárie. Dentre estes, um estudo utilizou fotografias de dentes extraídos (PORTELLA et al., 2023).

A Tabela 1 apresenta um sumário dos estudos que utilizaram o ICDAS como critério para a detecção de lesões cariosas através de algoritmos de CNNs.

**Tabela 1:** Estudos que utilizaram o critério ICDAS para detectar lesões cariosas utilizando inteligência artificial, e o algoritmo de CNN utilizado.

| Autor             | Ano  | Forma de avaliação do ICDAS | Método de obtenção das imagens | n     | CNN                                                                                                  |
|-------------------|------|-----------------------------|--------------------------------|-------|------------------------------------------------------------------------------------------------------|
| Moutselos et al.  | 2019 | 0,1,2,3,4,5 e 6             | Câmera intraoral               | 88    | Mask R-CNN                                                                                           |
| Zhang et al.      | 2020 | 4,5 e 6                     | Smartphones                    | 1.000 | SSD-MobileNetV2, Faster R-CNN (ResNet50)                                                             |
| Kühnisch et al.   | 2022 | 0, 1-3, 4-6                 | Câmera profissional            | 2.417 | MobileNetV2                                                                                          |
| Park et al.       | 2022 | 4,5 e 6                     | Câmera intraoral               | 2.348 | Faster R-CNN, ResNet-18                                                                              |
| Zhang et al.      | 2022 | 0,1,2,3,4,5 e 6             | Câmeras comuns                 | 3.932 | VGG-16                                                                                               |
| Mehdizadeh et al. | 2024 | 3,4,5 e 6                   | Imagens intraorais coloridas   | 1.022 | VGG-16, ResNet-50, Inception-v3                                                                      |
| Portella et al.   | 2023 | 0 e 2                       | Câmera profissional            | 2.481 | VGG-19                                                                                               |
| Kang et al.       | 2024 | 4,5 e 6                     | Câmera intraoral               | 2.682 | ResNet-50, Inception-v3, and Inception-ResNet-v2. The model was pre-trained on the COCO 2017 dataset |
| Xiong et al.      | 2024 | 3,4,5 e 6                   | Câmeras comuns                 | 1.020 | ToothNet (baseado em YOLOX multitarefa)                                                              |

Como exposto anteriormente, a dentição mista pode representar uma fase de maior risco ao desenvolvimento de lesões cariosas (RAJA et al., 2025). Ao nosso conhecimento, apenas um estudo avaliou o desempenho de CNNs a partir de fotografias de pacientes nesta fase. No entanto, a pesquisa também incluiu imagens de outras fases de desenvolvimento, como decídua e permanente, e não discriminou os resultados em função de cada fase (GHORBANI et al., 2025). Essa limitação evidencia uma lacuna metodológica importante, uma vez que, crianças em fase de

dentição mista apresentam diferentes padrões com a presença, além de dentes decíduos, de dentes permanentes em diferentes estágios de erupção.

Assim, apesar do crescente interesse nos modelos de IA para o reconhecimento de padrões de normalidade e alterações dentárias, o conhecimento ainda é limitado na detecção de lesões cáries, especialmente na fase de dentição mista.

## **2. OBJETIVOS**

### **2.1 Objetivo geral**

Reconhecer padrões dentários em situações de normalidade e com lesões cariosas em fotografias intrabucais, utilizando modelos de aprendizado profundo em crianças com dentição mista.

### **2.2 Objetivos específicos**

- Avaliar o desempenho de diferentes redes neurais convolucionais (CNNs) na segmentação e detecção de dentes;
- Analisar o desempenho de diferentes redes neurais convolucionais (CNNs) na detecção e classificação de diferentes graus de gravidades de lesões cariosas.

### 3. MATERIAL E MÉTODOS

#### *Aspectos Éticos*

Este projeto foi apreciado e aprovado pelo Comitê de Ética em Pesquisa em Seres Humanos do Setor de Ciências da Saúde da Universidade Federal do Paraná (UFPR) em 20 de novembro de 2019 (Parecer nº: 3.715.610/ Número do Certificado de Apresentação de Apreciação Ética (CAEE): 25001219.5.0000.0102) (ANEXO 1).

#### *Amostra e critérios de elegibilidade*

Foram incluídas 211 crianças de ambos os sexos, com 8 anos de idade, completos ou incompletos (visto que nesta idade os primeiros molares permanentes estão em fase de erupção ou totalmente irrompidos), por amostragem de conveniência, matriculadas na rede pública de ensino do município de Curitiba, Paraná. Foram excluídas as crianças que não possuíam pelo menos um primeiro molar permanente irrompido no momento do exame, com sinais fenotípicos de síndromes e aquelas que apresentassem alguma condição que impedisse a realização das fotografias intrabucais.

Para compor a base de imagens foram incluídos dentes decíduos e permanentes hígidos ou com lesões de cárie. Dentes com outras condições como, defeitos de desenvolvimento de esmalte, exceto fluorose, restaurações ou selantes também foram incluídos. Foram excluídos dentes com menos de 75% da coroa irrompida, em situações de raiz residual ou com componentes ortodônticos.

#### *Fotografias odontológicas intrabucais*

As fotografias foram obtidas de cada criança seguindo um protocolo padronizado, registrando os dentes posteriores de cada quadrante em diferentes angulações, a fim de aumentar a variabilidade das imagens. Para as tomadas fotográficas, foi utilizada uma câmera profissional (Canon EOS Rebel T6l®), com flash circular (Canon Macro Ring Lite MR-14ex®) e lente macro (Ultrasonic®). A padronização das fotografias foi obtida por meio da configuração da câmera, sendo

a velocidade do obturador de 1/160, abertura do diafragma em f25 e ISO em 200. As fotografias foram realizadas por visão indireta ou com o auxílio de espelho cristal para a reflexão de imagem. As crianças foram acomodadas em cadeiras escolares e foram utilizados afastadores e espelhos bucais. As fotografias foram realizadas por uma cirurgiã-dentista previamente treinada para execução das fotografias intrabucais. Todos os equipamentos de proteção individual necessários foram utilizados.

As imagens foram analisadas por duas examinadoras independentes, as quais foram previamente calibrados para o exame de cárie dentária através do índice ICDAS (ISMAIL et al., 2007) (ANEXO 2), e pelo índice proposto por Ghanim et al (2015) (ANEXO 3) para a avaliação dos defeitos de desenvolvimento de esmalte (DDE). Em caso de discordância entre os examinadores, a definição era realizada por um terceiro avaliador experiente em pesquisas epidemiológicas, considerado o padrão ouro.

As fotografias foram codificadas por um número de identificação (ID) e avaliados quanto à presença de lesões cariosas, utilizando o segundo código do critério do Sistema Internacional de Detecção e Avaliação de Cárie (ICDAS) e baseado nos critérios propostos por Ismail et al., 2007 (Figura 2). As superfícies foram classificadas de acordo com o segundo código do ICDAS em: 0 - hígido (sem sinais de cárie após a secagem da superfície); 1 - primeira alteração visual no esmalte (visível apenas após secagem da superfície, restrita ao interior de uma fóssula ou sulco); 2 - alteração visual distinta no esmalte (visível em esmalte úmido, sem necessidade de secagem); 3 - descontinuidade localizada do esmalte (sem sinais clínicos visuais de envolvimento da dentina); 4 - sombreamento escurecido subjacente da dentina (sinal de cárie em dentina); 5 - cavidade distinta com dentina visível (envolvendo menos da metade da superfície dentária); 6 - cavidade extensa e distinta com dentina visível (envolvendo mais da metade da superfície dentária). Devido à dificuldade de secagem da superfície dentária em ambiente escolar, o escore 1 (alteração visível após secagem da superfície) não foi incluído.




Figura 2 – Fluxograma de codificação das lesões de cárie segundo o “*International Caries Detection and Assessment System*” (ICDAS), de 2007.

Os defeitos de desenvolvimento do esmalte (DDE) foram classificados de acordo com índice de Ghanim (GHANIM et al., 2015) em hipomineralização, hipoplasia do esmalte, opacidades difusas, opacidades demarcadas e outros defeitos de esmalte, como amelogenese imperfeita

### Calibração dos examinadores

A análise das lesões cariosas e dos defeitos de desenvolvimento de esmalte foram classificados por duas examinadoras calibradas. Para ambas as condições, o processo de calibração foi realizado por meio de etapas teóricas e práticas.

Previamente à coleta, duas examinadoras foram calibradas, por meio de etapas teóricas e práticas. A calibração foi composta por três etapas, que incluíram atividades teóricas, exercício de calibração e análise estatística. Um total de 33 fotografias contendo superfícies oclusais dentárias com diferentes escores do ICDAS foram comparados ao padrão ouro (examinadora experiente em estudos epidemiológicos). Todo o processo foi guiado por uma examinadora de referência (doutora em Odontopediatria e experiente em estudos epidemiológicos), tendo duração de duas semanas.

- a) Primeira etapa: teórica, com oito horas de duração. Consistiu na apresentação dos critérios dos índices ICDAS (ISMAIL et al., 2007);
- b) Segunda etapa: calibração propriamente dita. Nesta etapa, foram examinadas 33 fotografias odontológicas, por cada examinadora e pela examinadora padrão, a fim de avaliar a reprodutibilidade intra e interexaminadores; as fotografias foram classificadas duas vezes por cada examinadora, com intervalo de uma semana entre as análises.
- c) Terceira etapa: análise dos resultados. Nesta etapa, os valores de Kappa ponderado de concordância intraexaminador foram ( $\geq 0,875$ ) e interexaminadores ( $\geq 0,904$ ), consideradas concordâncias ótimas (LANDIS, KOCH, 1977).

Semelhantemente, os mesmos examinadores foram calibrados para a detecção de defeitos de desenvolvimento de esmalte de acordo com o índice proposto por Ganhim et al. (2015) a partir de 30 fotografias com manifestações distintas de DDEs. Os resultados também foram comparados a um examinador de referência e analisados pelo teste de kappa. Os resultados indicaram concordância intra-examinador  $\geq 0,802$  e inter-examinador  $\geq 0,880$ , também considerados concordâncias ótimas (LANDIS, KOCH, 1977).

#### *Banco de imagens*

Um total de 2.495 fotografias intraorais foram obtidas. As superfícies oclusais foram classificadas com base no segundo código do sistema *International Caries Detection and Assessment System* (ICDAS). Em superfícies onde foram identificados diferentes níveis de gravidade de lesões cariosas, cada lesão foi individualmente demarcada e rotulada conforme a classificação proposta neste estudo.

Todas as imagens obtidas foram incluídas no processo de análise, independentemente de sua nitidez. Para as fotografias com menor qualidade visual, a marcação foi realizada com o suporte de uma imagem de referência nítida da mesma superfície oclusal, a fim de garantir precisão na identificação das áreas de interesse. Dentes que apresentaram defeitos de desenvolvimento de esmalte (DDE), como hipoplasia e opacidade demarcada, foram categorizados separadamente. No entanto, dentes com opacidade difusa (fluorose) nas superfícies oclusais foram excluídos da classificação, devido à semelhança de suas características com o

escore 2 do ICDAS, o que poderia comprometer o treinamento do algoritmo nesta fase do estudo

### *Análise das imagens*

Para o processo de anotação e rotulação das superfícies oclusais, utilizou-se o software Computer Vision Annotation Tool (CVAT), desenvolvido na linguagem Python. As superfícies oclusais foram analisadas e marcadas utilizando técnica de segmentação. A interface do programa CVAT pode ser observada na figura 3.





Figura 3 – Interface do software CVAT, utilizado para marcação das imagens.

Inicialmente, cada elemento dentário foi demarcado e rotulados como: “Dente”. Dentes que apresentavam tecido gengival recobrindo parte da coroa, por processo eruptivo ou destruição por lesão cariosa foram também demarcados com base em sua superfície visível na imagem.

Em seguida, as lesões cariosas foram classificadas de acordo com os escores do ICDAS: “ICDAS 0”, “ICDAS 2”, “ICDAS 3”, “ICDAS 4”, “ICDAS 5” ou “ICDAS 6”. As opacidades demarcadas e hipoplasias foram rotuladas como “DDE”, para obter um diagnóstico diferencial entre as lesões de cárie e defeitos de desenvolvimento de esmalte. Restaurações, selantes, biofilme e restos de alimentos foram marcados como “outros”. As marcações e rotulações realizadas no CVAT podem ser observadas na Figura 4.




**Figura 4** - Marcação e rotulações das superfícies dentárias de acordo com os diferentes rótulos propostos no estudo utilizando o *Software* CVAT. A marcação em amarelo corresponde ao escore 2 do ICDAS, a marcação em vermelho corresponde ao escore 3 e a marcação em verde, ao escore 5 do ICDAS.

### *Convolutional Neural Networks (CNNs)*

#### *YOLOv11*


A CNN YOLOv11 segue o paradigma *one-stage* para detecção de objetos, composto por três módulos principais: *backbone*, responsável pela extração de características; *neck*, que realiza a fusão multi-escala; e *head*, que efetua a previsão de caixas delimitadoras e classes em tempo real. Essa estrutura possibilita elevada velocidade de inferência com desempenho competitivo em termos de acurácia (WENG et al., 2025). Estudos recentes em aplicações industriais e médicas relatam que a YOLOv11 aprimora a detecção em cenários complexos, mostrando-se adequada para tarefas que exigem predição rápida e confiável (KANG et al., 2023). Ainda, a YOLOv11 é capaz de detectar objetos por uma única passagem por segmentações sobrepostas na imagem analisada (KANG et al., 2023). A estrutura da rede pode ser observada na figura 5 (WENG et al., 2025)



**Figura 5** – Arquitetura do modelo YOLOv11 (WENG et al., 2025)

### U-Net

A U-Net possui uma arquitetura em “U”, em que o caminho do codificador captura características globais quanto locais da imagem, realizando a reconstrução da imagem segmentada (RONNEBERGER et al., 2015). A U-Net é uma rede totalmente convolucional, com um caminho de contração (*contracting path*) para captação do contexto e um caminho de expansão (*expansive path*) que possibilita localização precisa, integrando *skip connections* entre camadas simétricas (RONNEBERGER et al., 2015). Além disso, o modelo é eficiente no treinamento com bases de dados pequenas, graças ao uso de *data augmentation* e da estratégia de *overlap-tile* (RONNEBERGER; FISCHER; BROX, 2015). A arquitetura da rede U-Net está disponível na figura 6 (RONNEBERGER et al., 2015).



**Figura 6** – Representação da arquitetura da CNN U-Net (RONNEBERGER et al., 2015)

## ConvNext

A ConvNext representa uma modernização das CNNs, mantendo convoluções, mas incorporando decisões arquitetônicas inspiradas em *Vision Transformers*. Entre suas características estão convoluções *depthwise*, blocos *inverted bottleneck*, uso de kernels grandes e normalização (LayerNorm) em cada bloco. Essa arquitetura alcança desempenho competitivo em classificação no ImageNet e em tarefas de detecção e segmentação quando utilizada como *backbone* em frameworks como o Mask R-CNN (LIU et al., 2022).

## Treinamento

Para garantir que a rede atinja um bom poder de generalização e evitar o *overfitting*, que ocorre quando o modelo se ajusta excessivamente aos dados de treinamento (SIVAKUMAR et al., 2024), as imagens foram divididas em base de treinamento (80%), base de teste (10%) e validação (10%). O treinamento ocorreu com uma parte da base e a cada iteração o modelo foi avaliado na base de validação. Após o término do treinamento-validação, o modelo foi testado na base de testes que possui imagens desconhecidas do classificador.

Para a segmentação e a detecção dos elementos dentários, duas CNNs foram testadas: YOLOv11 e U-net, sendo que a segunda não realiza a detecção de dentes individualmente.

Para a classificação das lesões cariosas, as duas CNNs testadas foram YOLOv11 e ConvNext pois obtiveram resultados de precisão e sensibilidade considerados ótimos na fase de detecção e segmentação dos dentes, como etapa prévia para classificação das lesões cariosas.

### Métricas de Desempenho e Precisão

O desempenho das CNNs foi avaliado de acordo com a acurácia, a precisão, a sensibilidade, especificidade e F1-score. O quadro 1 apresenta um resumo dos indicadores estatísticos de desempenho (ALHARBI et al., 2024).

Quadro 1 – Indicadores de métricas estatísticas de desempenho.

| Métrica                        | Fórmula                                                                                             | Definição                                                                                                                                                          |
|--------------------------------|-----------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Acurácia                       | $\frac{TP^a + TN^b}{TP + TN + FP^c + FN^d}$                                                         | Proporção entre o número de classificações corretas (verdadeiros positivos e verdadeiros negativos) e o total de imagens avaliadas. Indica o percentual de acertos |
| Precisão                       | $\frac{TP}{TP + FP}$                                                                                | Proporção entre os verdadeiros positivos e o total de casos classificados como positivos pela CNN.                                                                 |
| Sensibilidade                  | $\frac{TP}{TP + FN}$                                                                                | Proporção entre as segmentações corretas e o total de segmentações realizadas. Indica se o modelo é capaz de detectar amostras positivas.                          |
| Especificidade                 | $\frac{TN}{TN + FP}$                                                                                | Proporção de verdadeiros negativos que o modelo prevê corretamente.                                                                                                |
| F1-score (Coeficiente de Dice) | $2 \cdot \frac{\text{precisão} \cdot \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}}$ | Média harmônica entre precisão e sensibilidade                                                                                                                     |

### *Cálculo das métricas*

Para o cálculo das métricas foram utilizados testes de diagnóstico incluindo acurácia, precisão, sensibilidade, especificidade e F1-score.

### *Artigos científicos*

Este trabalho resultou em dois artigos científicos “Detecção e segmentação dentária em faces oclusais de dentição mista utilizando aprendizado profundo”, no estilo *Brief report* (Artigo 1) e “Classificação de diferentes graus de severidade de lesões cáries na dentição mista utilizando aprendizado profundo.” (Artigo 2). Ambos os artigos foram formulados conforme às normas e instruções da revista “*Clinical Oral Investigations*”, disponível no anexo 4.

## ARTIGO 1

### **Detecção e segmentação dentária em faces oclusais de dentição mista utilizando aprendizado profundo**

#### ***Resumo***

A inteligência artificial com o uso das redes neurais convolucionais (CNNs) tem mostrado uma alternativa promissora para a identificação de padrões de normalidade e doenças bucais, incluindo a detecção de lesões cariosas. O objetivo deste estudo foi avaliar a detecção e segmentação de dentes posteriores em crianças em fase inicial de dentição mista. Um total de 945 imagens de dentes posteriores de crianças em fase de dentição mista foram obtidas em ambiente escolar. As imagens foram divididas em conjuntos de bases de treinamento e teste. As CNNs YOLOv11 e U-Net foram comparadas quanto ao desempenho de precisão e sensibilidade, além da proporção de detecção de dentes em fase de erupção. YOLOv11 obteve precisão de 0,967 e sensibilidade de 0,938, detectando 96,1% do total de dentes permanentes parcialmente irrompidos. U-Net, por sua vez, apresentou precisão de 0,953 e sensibilidade de 0,951, detectando 78,4% dos dentes em erupção. Ambas as redes apresentaram alta precisão na detecção e segmentação dos dentes posteriores. No entanto, a rede YOLOv11 obteve melhor desempenho na detecção de dentes em erupção, mostrando seu potencial para estudos que envolvam crianças com dentição mista.

**Palavras-Chave:** Inteligência Artificial; Redes Neurais Convolucionais; Dentição Mista.

## **Introdução**

A dentição mista é considerada uma fase de risco para o desenvolvimento da cárie dentária, especialmente em sua fase inicial, que é caracterizada pela erupção do primeiro molar permanente. A macromorfologia das superfícies oclusais dos dentes posteriores e a dificuldade de higienização, além da imaturidade pós-eruptiva do esmalte dentário, faz com que o desenvolvimento de lesões cariosas sejam frequentes nesta fase [1, 2].

Nos últimos anos, a inteligência artificial (IA), especialmente o aprendizado profundo (AP), tem sido empregada como auxílio no diagnóstico de padrões de normalidade e alterações dentárias [3] por meio das redes neurais convolucionais (CNNs). As CNNs têm sido apontadas como uma alternativa promissora na detecção e segmentação de dentes em imagens odontológicas, sendo as radiografias o método de obtenção de imagens mais utilizado entre os estudos [3]. A literatura é escassa no reconhecimento de superfícies dentárias por meio de fotografias intraorais, sendo que ao nosso conhecimento, apenas um estudo avaliou o desempenho das CNNs em imagens de dentição mista [4].

Uma vez que crianças em fase de dentição mista podem apresentar padrões dentários distintos, é importante o conhecimento da CNN mais apropriada para identificar elementos dentários, incluindo dentes decíduos e permanentes, em diferentes posições e fases de erupção e esfoliação [4].

O objetivo deste estudo é avaliar comparativamente duas CNNs na detecção e segmentação de dentes posteriores em crianças em fase inicial de dentição mista.

## **Material e métodos**

### **Aspectos éticos**

O estudo foi aprovado pelo Comitê de Ética em Pesquisa em Seres Humanos do Setor de Ciências da Saúde da Universidade Federal do Paraná (UFPR) (Nº: 25001219.5.0000.0102). Todos os participantes, incluindo seus responsáveis legais, autorizaram a participação no estudo. Este estudo segue o *Checklist for Artificial Intelligence in Medical Imaging* (CLAIM) [5].

### **Amostra**

Foram incluídas 211 crianças de ambos os sexos, com 8 anos de idade, completos ou incompletos, através de amostragem de conveniência.

Participaram do estudo crianças com ao menos um primeiro molar permanente irrompido, excluindo-se aquelas com limitações que impedissem a realização de fotografias. Foram considerados dentes decíduos ou permanentes totalmente ou parcialmente irrompidos, hígidos ou com alterações como cárie, defeitos de esmalte ou restaurações. Dentes com menos de 75% da coroa irrompida, com componentes ortodônticos e raízes residuais foram excluídos.

#### *Fotografias odontológicas intrabucais*

As fotografias foram realizadas em ambiente escolar, sob iluminação artificial, por uma pesquisadora treinada. As fotografias foram obtidas de cada criança seguindo um protocolo padronizado, registrando os dentes posteriores de cada quadrante em diferentes angulações, a fim de aumentar a variabilidade das imagens. Utilizou-se câmera profissional (Canon EOS Rebel T6l®) com flash macro e lente Ultrasonic®, padronizada em 1/160 de obturador, f/25 de abertura e ISO 200. As imagens foram feitas por visão indireta, com auxílio de espelho cristal para fotografia odontológica modelo IB-02 e afastadores bucais.

#### *Marcação das imagens e treinamento das CNNs*

Foram analisadas 945 fotografias intrabucais, com os dentes posteriores demarcados por uma pesquisadora especialista em Odontopediatria, utilizando o software CVAT (Figura 1). Todas as imagens, independentemente da nitidez, foram incluídas. Naquelas de menor qualidade, foi utilizada uma imagem nítida de referência da mesma superfície para garantir maior precisão das marcações.




Figura 1 - Marcação de dente utilizando o software CVAT.

As 945 imagens intrabucais foram divididas entre treinamento (n = 760) e validação (n = 185). Para a identificação dos dentes, utilizaram-se as CNNs YOLOv11, que detecta objetos em uma única passagem [6], e U-Net, cuja

arquitetura em “U” captura e reconstrói características da imagem segmentada [7] (Figura 2). A comparação entre os modelos considerou os valores precisão e sensibilidade, além da proporção de detecção de dentes permanentes em fase de erupção.




Figura 2 - Reconhecimento dos dentes sendo a predição (A), e o reconhecimento pelas redes YOLOv11 (B) e U-Net (C).

### **Resultados**

Os valores de precisão para as redes YOLOv11 e U-net foram de 0,967 e 0,953, respectivamente. Já os valores de sensibilidade foram de 0,938 e 0,951 para YOLOv11 e U-net, respectivamente. A base de imagens totalizou 51 dentes permanentes parcialmente irrompidos, sendo 46 (96,1%) e 40 (78,4%) detectados pelas CNNs YOLOv11 e U-Net, respectivamente.

### **Discussão**

A utilização de CNNs na detecção de padrões de normalidade e alterações dentárias utilizando fotografias intrabucais é um assunto ascendente [8]. No entanto, pesquisas voltadas para a dentição mista ainda são limitadas, com dois estudos anteriores utilizando radiografias panorâmicas [9, 10], e apenas uma pesquisa com fotografias intraorais visando a detecção e segmentação de dentes [4].

Uma revisão sistemática conduzida por Alharbi et al. (2024) [3] destacou os avanços das redes neurais convolucionais (CNNs) na detecção e segmentação de

elementos dentários, com ênfase em arquiteturas como Faster R-CNN, U-Net e YOLO. O Faster R-CNN, ao integrar uma rede de proposta de região (RPN) com uma rede de detecção, tem demonstrado alta eficiência na identificação de estruturas dentárias. A U-Net é amplamente reconhecida por sua precisão e rapidez na segmentação, enquanto os modelos YOLO se destacam pela detecção em tempo real com elevada confiabilidade [3]. No presente estudo, a rede YOLOv11 apresentou valores ligeiramente superiores de precisão e levemente inferiores de sensibilidade em comparação à U-Net.

Embora o estudo de Ghorbani et al. (2025) [4] tenha alcançado precisão de 95,72% na segmentação e detecção de dentes com a CNN YOLOv8, não houve discriminação dos resultados considerando somente fotografias na dentição mista. No presente estudo, a YOLOv11 apresentou melhor desempenho na detecção de dentes parcialmente irrompidos. Estes achados reforçam o potencial das CNNs, especialmente a YOLO na detecção e segmentação de estruturas dentárias na prática odontológica, sendo importante a condução de mais estudos nesta temática.

### ***Conclusão***

Este estudo demonstrou o potencial das redes neurais convolucionais (CNNs), na detecção e segmentação de dentes posteriores em crianças com dentição mista, com destaque para a rede YOLOv11 pela alta precisão na identificação de dentes parcialmente irrompidos.

### **Referências:**

1. CARVALHO JC. Caries process on occlusal surfaces: evolving evidence and understanding. *Caries Res.* 2014, v. 48, n. 4, p. 339-346.
2. Carvalho JC, Dige I, Machiulskiene V, Qvist V, Bakhshandeh A, Fatturi-Parolo C, Maltz M. Occlusal caries: biological approach for its diagnosis and management. *Caries Res.* 2016;50(6):527-42.
3. Alharbi SS, Alhasson HF. Exploring the applications of artificial intelligence in dental image detection: a systematic review. *Diagnostics (Basel).* 2024;14(21):2442.
4. Ghorbani Z, Mirebeigi-Jamasbi SS, Hassannia Dargah M, Nahvi M, Hosseinihah Manshadi SA, Akbarzadeh Fathabadi Z. A novel deep learning-based model for automated tooth detection and numbering in mixed and permanent dentition in occlusal photographs. *BMC Oral Health.* 2025;25(1):455.
5. Mongan Moy JL, Kahn CE (2020) Checklist for artificial intelligence in medical imaging (CLAIM): a Guide for authors and reviewers. *Radiol Artif Intell* 2(2):e200029.
6. Kang CH, Kim SY. Real-time object detection and segmentation technology: an analysis of the YOLO algorithm. *JMST Adv.* 2023; 5:69-76.
7. Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation. In: Navab N, Hornegger J, Wells W, Frangi A, editors. *Medical image computing and computer-assisted intervention – MICCAI 2015.* MICCAI 2015. Lecture Notes in Computer Science. Cham: Springer; 2015. p. 234-41.
8. Moharrami M, Heidar S, Malek H, et al. Detecting dental caries on oral photographs using artificial intelligence: a systematic review. *Oral Dis.* 2024;30(4):1765-83.
9. Asci E, Kilic M, Celik O, et al. A deep learning approach to automatic tooth caries segmentation in panoramic radiographs of children in primary dentition, mixed dentition, and permanent dentition. *Children (Basel).* 2024;11(6):690.
10. Mine Y, Iwamoto Y, Okazaki S, et al. Detecting the presence of supernumerary teeth during the early mixed dentition stage using deep learning algorithms: a pilot study. *Int J Paediatr Dent.* 2022;32(5):678-85.

## ARTIGO 2

### Classificação de diferentes graus de severidade de lesões cariosas na dentição mista utilizando aprendizado profundo

#### Resumo

A detecção dos estágios iniciais das lesões cariosas é essencial para a implementação de tratamentos minimamente invasivos, especialmente na fase da dentição mista, período de maior vulnerabilidade ao desenvolvimento da doença. Este estudo avaliou o desempenho de redes neurais convolucionais (CNNs) na classificação de lesões cariosas em imagens intraorais de crianças com oito anos de idade, utilizando o segundo código do índice *International Caries Detection and Assessment System* (ICDAS). A amostra incluiu 1.655 imagens de dentes posteriores, divididas em conjuntos de treinamento/validação (80%) e teste (20%). Os escores do ICDAS foram categorizados em três classes: hígido (escore 0), lesões iniciais (escores 1, 2 e 3) e lesões moderadas ou severas (escores 4,5 e 6). As CNNs YOLOv11 e ConvNext foram treinadas independentemente e combinadas por diferentes estratégias de *ensemble*. O desempenho dos modelos foi avaliado pela acurácia, precisão, sensibilidade e F1-score. A YOLOv11 apresentou médias de acurácia de 0,80, precisão de 0,81, sensibilidade de 0,80 e F1-score de 0,80, sem variação entre as rodadas (DP=0,00), destacando-se na classificação de superfícies híginas (sensibilidade: 0,932). A ConvNext, por sua vez, obteve médias de acurácia de 0,81, precisão de 0,81, sensibilidade de 0,81 e F1-score de 0,80 (DP=0,02), porém com maior número de falsos positivos entre superfícies híginas e lesões iniciais. O *ensemble* alcançou o melhor desempenho global, com médias de acurácia, precisão, sensibilidade e F1-score de 0,820 (DP=0,03). Esses achados evidenciam o potencial da integração de CNNs como ferramenta complementar na classificação de lesões cariosas em crianças com dentição mista.

#### Palavras-chave

Aprendizagem profunda; Redes neurais convolucionais; Cárie dentária; Dentição mista.

## Introdução

A cárie dentária é uma das doenças bucais mais prevalentes em todo o mundo [1], podendo afetar ambas as dentições, decídua e permanente [2]. A fase inicial da dentição mista, que se inicia por volta dos seis anos de idade, representa um período de maior vulnerabilidade ao desenvolvimento de lesões cariosas. Esse risco se deve, em grande parte, à dificuldade de higienização adequada — especialmente em dentes posteriores — e à imaturidade do esmalte dentário recém-erupcionado [3,4]. A identificação dos primeiros sinais clínicos da doença é essencial, pois permite a adoção de intervenções minimamente invasivas, com foco no controle da progressão da lesão e na promoção da saúde bucal a longo prazo [5].

Para padronizar o diagnóstico e a detecção de lesões cariosas, diversos índices clínicos têm sido propostos, sendo um dos mais adotados entre os estudos, aquele proposto pela Organização Mundial da Saúde (OMS) [6]. No entanto, este índice, baseado no número de dentes cariados, restaurados ou perdidos por cárie, é considerado de baixa sensibilidade uma vez que não é capaz de discriminar os estágios iniciais da doença, o que pode impactar na adoção de estratégias de tratamento menos invasivas [7].

Em 2005, um grupo de pesquisadores ligados a instituições acadêmicas, organizações de saúde pública e sociedades científicas, elaboraram um novo método para a detecção de lesões cariosas, o *International Caries Detection and Assessment System* (ICDAS) [8]. Na sua versão mais aprimorada, o ICDAS II [9] destaca-se por ser um índice sensível, capaz de identificar os estágios iniciais das lesões cariosas, além de permitir a avaliação da atividade da lesão. Essa abordagem detalhada é fundamental para a Odontologia de Mínima Intervenção, permitindo um diagnóstico inicial e a aplicação de tratamentos menos invasivos [10]. No entanto, a aplicação do ICDAS exige treinamento e experiência clínica do profissional, o que pode levar a variações interobservador e limitar sua utilização em larga escala [11]. Essa limitação impulsiona a busca por métodos complementares e mais objetivos para auxiliar na detecção de lesões cariosas.

Recentemente, os avanços em inteligência artificial (IA), particularmente o aprendizado de máquina (ML) e o aprendizado profundo (DL), têm demonstrado

grande potencial para o diagnóstico de diferentes condições em saúde [12]. No contexto odontológico, o uso de redes neurais convolucionais (CNNs), um tipo específico de DL, representa um avanço significativo na análise automatizada de imagens [13, 14]. As CNNs, ou ConvNets, destacam-se por sua capacidade de processar imagens de alta complexidade por meio de camadas convolucionais hierárquicas, que extraem e refinam características desde elementos básicos, como bordas e texturas, até padrões mais complexos e específicos [15, 16].

A utilização de CNNs tem sido promissora no auxílio à detecção de lesões cariosas a partir de imagens odontológicas, incluindo radiografias [17] e fotografias intrabuciais [18, 19]. No caso da utilização de fotografias, as pesquisas ainda são incipientes, sendo que, ao nosso conhecimento, apenas um estudo avaliou a detecção de lesões cariosas em fotografias intraorais em crianças com dentição mista [20]. Este aspecto revela uma lacuna importante, não somente pelo fato de ser este um período com maior risco ao desenvolvimento da doença [21], como também em razão dos diferentes padrões desta fase, com a presença concomitante de dentes decíduos e permanentes em diferentes estágios de desenvolvimento. Além disso, a pesquisa realizada por Ghorbani et al., 2025 [20] também incluiu outras fases de desenvolvimento das dentições, não discriminando os resultados inerentes de cada fase.

Assim, o objetivo deste estudo foi analisar o desempenho de diferentes redes neurais convolucionais (CNNs) na classificação de diferentes estágios de lesões cariosas em crianças com dentição mista.

## ***Material e métodos***

### ***Aspectos éticos***

O estudo foi aprovado pelo Comitê de Ética em Pesquisa em Seres Humanos do Setor de Ciências da Saúde da Universidade Federal do Paraná (UFPR) (Nº: 25001219.5.0000.0102). Todos os participantes, incluindo seus responsáveis legais, autorizaram a participação no estudo.

### *Amostra*

Foram incluídas 211 crianças de ambos os sexos, com 8 anos de idade, completos ou incompletos, por meio de amostragem de conveniência. Participaram do estudo crianças com ao menos um primeiro molar permanente irrompido, excluindo-se aquelas com limitações que impedissem a realização de fotografias. Foram considerados dentes decíduos ou permanentes totalmente ou parcialmente irrompidos, hígidos ou com alterações como cárie, defeitos de esmalte ou restaurações. Dentes com menos de 75% da coroa irrompida, com componentes ortodônticos e raízes residuais foram excluídos.

### *Fotografias odontológicas intrabucais*

As fotografias foram realizadas em ambiente escolar, sob iluminação artificial, por uma pesquisadora treinada. As fotografias foram obtidas de cada criança seguindo um protocolo padronizado, registrando os dentes posteriores de cada quadrante em diferentes angulações, a fim de aumentar a variabilidade das imagens. Utilizou-se câmera profissional (Canon EOS Rebel T6l®) com flash macro e lente Ultrasonic®, padronizada em 1/160 de obturador, f/25 de abertura e ISO 200. As imagens foram feitas por visão indireta, com auxílio de espelho cristal para fotografia odontológica modelo IB-02 e afastadores bucais.

### *Calibração dos examinadores*

A análise das condições clínicas dos dentes de cada imagem foi realizada por duas examinadoras calibradas para a detecção de lesões cariosas e defeitos de desenvolvimento de esmalte segundo os critérios do ICDAS [8] de Ganhim et al (2015) [23], respectivamente. O processo de calibração para ambos os índices foi realizado por meio de etapas teóricas e práticas. Os resultados da análise das examinadoras foram comparados ao padrão ouro (examinador experiente em estudos epidemiológicos). Os valores de Kappa ponderado de concordância intra-examinador foram  $\geq 0,802$  e inter-examinadores  $\geq 0,880$ , consideradas concordâncias ótimas [24].

### *Marcação das imagens*

As imagens foram analisadas por dois pesquisadores calibrados, profissionais na área de Odontopediatria, utilizando o software Computer Vision Annotation Tool (CVAT), desenvolvido na linguagem Python. Todas as imagens, independentemente da nitidez, foram incluídas. Naquelas de menor qualidade, foi utilizada uma imagem nítida de referência da mesma superfície para garantir maior precisão das marcações.

As superfícies oclusais dos dentes posteriores foram demarcadas utilizando a técnica de segmentação.

Inicialmente, cada elemento dentário foi demarcado e rotulado em: “Dente”. Dentes que apresentavam tecido gengival recobrindo parte da coroa, por processo eruptivo ou destruição por lesão cáriosa, foram também demarcados com base em sua superfície visível na imagem.

Em seguida, as lesões cárias foram demarcadas e classificadas de acordo com os escores do ICDAS: “ICDAS 0”, “ICDAS 2”, “ICDAS 3”, “ICDAS 4”, “ICDAS 5” ou “ICDAS 6”. As opacidades demarcadas e hipoplasias foram rotuladas como “DDE”. Restaurações, selantes, biofilme e restos de alimentos foram classificados como “outros”. As imagens foram analisadas por dois examinadores independentes, os quais foram previamente calibrados para o exame de cárie dentária através do índice ICDAS [8], e pelo índice proposto por Ghanim et al. (2015) [23] para a avaliação dos defeitos de desenvolvimento de esmalte (DDE). Em caso de discordância entre os examinadores, a definição era realizada por um terceiro avaliador experiente em pesquisas epidemiológicas, considerado o padrão ouro.

Após as marcações no software CVAT as imagens receberam novos rótulos para realizar o treinamento das CNNs. Os rótulos que indicavam superfícies com ICDAS 2, 3, 4, 5 ou 6 foram nomeados como “C2”, “C3”, “C4”, “C5” e “C6”, respectivamente. Superfícies sem marcações de lesões de cárie (ICDAS 0) foram nomeadas para “Hígido”. Superfícies oclusais que apresentavam mais de um escore foram nomeadas com o maior escore do ICDAS presente na superfície oclusal do dente. Em seguida, por meio de um script em linguagem Python, foram realizadas as junções das classes em: Hígido (escore 0), Inicial (escores 1-3) e moderado/severo (escores 4-6).

Após as renomeações dos rótulos, foi realizada a segmentação dos dentes em uma única imagem. Os dentes foram separados por *bounding box* para realizar a detecção dos elementos dentários. Posteriormente, foi realizada extração dos dentes que foram marcados com a forma poligonal no software CVAT, permanecendo cada dente delimitado por um fundo preto. Este processo está demonstrado na figura 1.




Figura 1 – (A) Fotografia intraoral do lado inferior esquerdo, com as marcações realizadas no software CVAT. (B) Dentes separados por *Bounding boxes*. (C) Dentes delimitados por fundo preto.

### *Base de imagens*

As imagens foram divididas em base de treinamento (80%), base de teste (10%) e validação (10%). O treinamento ocorreu com uma parte da base e a cada interação o classificador foi testado na base de validação. Após o término do treinamento-validação, o classificador foi testado na base de testes, que possui imagens desconhecidas pelo mesmo. As três imagens com variações de angulações de cada quadrante de cada participante foram incluídas na mesma etapa – treinamento, teste ou validação –, evitando sua duplicação em duas fases distintas, o que garante que nenhuma imagem usada para avaliar o desempenho final do modelo tivesse sido vista durante o treinamento ou durante a validação.

### *Treinamento das CNNs*

As redes neurais convolucionais YOLOv11 e ConvNext foram treinadas de forma independente, cada uma em cinco execuções distintas, com o objetivo de reduzir a variabilidade dos resultados e permitir a análise comparativa do desempenho entre as CNNs. Para o desenvolvimento, utilizou-se a linguagem de programação Python, em conjunto com bibliotecas e *frameworks* de apoio amplamente empregados em aplicações de, como Ultralytics, PyTorch, scikit-learn, Pandas, Seaborn e Matplotlib.

### *YOLOv11*

A YOLOv11 (You Only Look Once, versão 11) é uma rede neural convolucional voltada para tarefas de detecção de objetos em tempo real. Seu diferencial está na arquitetura unificada, que realiza simultaneamente a detecção e a classificação de regiões de interesse em uma única etapa, reduzindo o tempo de processamento e aumentando a eficiência. Essa característica a torna especialmente adequada para aplicações que demandam rapidez e precisão, como a análise de imagens clínicas.

### *ConvNext*

A ConvNext é uma rede neural convolucional baseada em uma adaptação do design de transformadores visuais (*Vision Transformers*), porém preservando a estrutura tradicional das CNNs. Seu desenvolvimento teve como objetivo modernizar a arquitetura convolucional, incorporando avanços de eficiência e escalabilidade observados em modelos recentes de aprendizado profundo. Essa CNN apresenta desempenho em tarefas de classificação de imagens.

### *Ensemble*

O *ensemble* consiste em uma abordagem de aprendizado de máquina que combina as previsões de diferentes modelos, com o objetivo de aumentar a robustez e o desempenho do processo de classificação [25, 26, 27]. No presente estudo, após o treinamento individual das CNNs YOLOv11 e ConvNext, foram testadas quatro estratégias de ensemble: (i) média ponderada, atribuindo peso 0,6 para ConvNext e 0,4 para YOLOv11; (ii) média geométrica; (iii) média harmônica; e (iv)

classwise, na qual a decisão final da classificação foi ajustada conforme o desempenho específico de cada CNN em cada classe.

### *Métricas de Desempenho e Precisão*

O desempenho das CNNs foi avaliado de acordo com acurácia, precisão, sensibilidade, especificidade e F1-score [17].

## **Resultados**

### *Características da base de dados*

Um total de 1.655 imagens de dentes com fundo preto foi incluído no estudo. Destas, 1.527 imagens foram destinadas ao conjunto de treinamento/validação e 128 ao conjunto de teste. De acordo com os critérios do ICDAS, a base de dados foi composta por 479 superfícies híginas (ICDAS 0), 655 lesões iniciais (ICDAS 1–3) e 521 lesões moderadas/severas (ICDAS 4–6) (Tabela 1). Os conjuntos foram cuidadosamente organizados de modo a evitar duplicação de imagens entre treinamento/validação e teste.

**Tabela 1** – Distribuição de fotografias de dentes com fundo preto das fotografias intraorais nos conjuntos de dados de treinamento/validação e teste de acordo com o agrupamento das classes baseado nos critérios do ICDAS.

| ICDAS                 | Base de treinamento |           |       | Base de teste | Total da base |
|-----------------------|---------------------|-----------|-------|---------------|---------------|
|                       | Treino              | Validação | Total |               |               |
| Hígido (0)            | 350                 | 70        | 420   | 59            | 479           |
| Inicial (1-3)         | 533                 | 71        | 604   | 51            | 655           |
| Moderado/Severo (4-6) | 424                 | 79        | 503   | 18            | 521           |
| Total                 | 1.307               | 220       | 1.527 | 128           | 1.655         |

### *Desempenho das CNNs e ensemble*

Foram realizadas cinco rodadas independentes de treinamento para as CNNs YOLOv11, ConvNext-Base e para a abordagem ensemble. Os resultados das médias entre as cinco rodadas considerando acurácia, precisão, sensibilidade e F1-score estão descritos na Tabela 2.

**Tabela 2** – Métricas das CNNs YOLOv11, ConvNext e *ensemble* para a classificação de lesões de cárie de acordo com agrupamento de classes baseado nos critérios do ICDAS.

| CNNs            | Métricas* |      |          |      |               |      |          |      |
|-----------------|-----------|------|----------|------|---------------|------|----------|------|
|                 | Acurácia  |      | Precisão |      | Sensibilidade |      | F1-Score |      |
|                 | Média     | DP   | Média    | DP   | Média         | DP   | Média    | DP   |
| <b>YOLOv11</b>  | 0,800     | 0,00 | 0,810    | 0,00 | 0,800         | 0,00 | 0,800    | 0,00 |
| <b>ConvNext</b> | 0,810     | 0,02 | 0,810    | 0,02 | 0,810         | 0,02 | 0,800    | 0,02 |
| <b>Ensemble</b> | 0,820     | 0,03 | 0,820    | 0,03 | 0,820         | 0,03 | 0,820    | 0,03 |


DP= desvio padrão

\*Calculadas após cinco rodadas independentes

Os resultados da matriz de confusão das CNNs YOLOv11, ConvNext e do ensemble encontram-se na Figura 2. Para a CNN YOLOv11, observou-se maior proporção de verdadeiros positivos para superfícies hígidas (93,2%) e menor para lesões iniciais (70,6%) e moderadas/severas (66,7%). Houve uma proporção de classificações incorretas de 25,5% entre lesões iniciais e hígidas e de 33,3% entre lesões moderadas/severas e iniciais (Figura 2A).

Na CNN ConvNext, as proporções de detecções corretas foram semelhantes entre as três classes: 84,7% para superfícies hígidas, 82,4% para lesões iniciais e 83,3% para lesões moderadas/severas. Consequentemente, os valores de classificações incorretas também foram próximos, sendo 10,2% entre superfícies hígidas e iniciais e 16,7% entre lesões moderadas/severas e iniciais (Figura 2B).

O ensemble entre as CNNs YOLOv11 e ConvNext, utilizando a abordagem *classwise*, apresentou o melhor desempenho, com proporções de classificações corretas de 93,2%, 84,3% e 83,3% para superfícies hígidas, iniciais e moderadas/severas, respectivamente. Em comparação à CNN ConvNext isoladamente, essa estratégia reduziu a proporção de falsos positivos entre superfícies hígidas e iniciais (de 10,2% para 1,7%) e entre lesões iniciais e hígidas (de 17,6% para 15,7%), reduziu a proporção de falsos positivos entre superfícies hígidas e iniciais (de 10,2% para 1,7%) e entre lesões iniciais e hígidas (de 17,6% para 15,7%), mantendo a mesma taxa de classificações incorretas entre lesões moderadas/severas e iniciais (16,7%) (Figura 2C).



**Figura 2** – Matriz de confusão referente às CNNs Yolov11 (A.), ConvNext (B.), e utilizando o *ensemble* entre as duas redes (C.)

## Discussão

A cárie dentária é a condição bucal mais comum da infância, especialmente na dentição mista [21]. A identificação dos estágios iniciais das lesões cariosas permite a realização de tratamentos minimamente invasivos, preservando ao máximo a estrutura dentária sadia e evitando a progressão das lesões, bem como intervenções restauradoras mais complexas ou extrações [10]. Apesar dos avanços na aplicação das CNNs para a detecção de lesões cariosas a partir de imagens intraorais, apenas um estudo incluiu fotografias de dentes em fase de dentição mista [20]. Este é o primeiro estudo que avaliou o desempenho de diferentes CNNs na classificação de diferentes estágios de lesões cariosas exclusivamente em fotografias em crianças com dentição mista.

A base de dados utilizada neste estudo foi composta por 1.655 imagens, organizadas de forma a evitar duplicações entre os conjuntos de

treinamento/validação e teste, além de garantir equilíbrio entre as classes hígido, inicial e moderado/severo, o que contribuiu para a consistência da análise. Em comparação a estudos anteriores que também avaliaram o desempenho de CNNs na detecção de lesões cariosas por meio do ICDAS, observa-se que algumas pesquisas utilizaram bases menores, como 88 imagens [28] e 1.020 imagens [29]. Por outro lado, outros trabalhos recorreram a amostras mais amplas, variando entre 2.417 e 3.932 imagens [30, 31, 32]. Ainda assim, a base empregada neste estudo mostrou-se suficientemente robusta para o treinamento e validação das diferentes CNNs, assegurando a confiabilidade dos resultados e sua comparabilidade com a literatura existente.

O presente estudo também demonstrou a estabilidade e o desempenho das redes por meio de múltiplos treinamentos, essencial para testar a validade dos resultados obtidos [33]. Neste sentido, foram conduzidas cinco rodadas independentes de treinamento para cada arquitetura testada. Estudos anteriores que avaliaram o desempenho de CNNs na detecção de lesões cariosas, utilizando o índice ICDAS, relataram apenas uma rodada de treino [28, 29, 32, 34, 35, 36], o que pode limitar a avaliação da robustez dos modelos. Ao nosso conhecimento, apenas os estudos de Kühnisch et al. (2022) [30] e Park et al (2022) [37] empregaram múltiplos treinamentos em uma das fases metodológicas com quatro e cinco rodadas, respectivamente.

Outro aspecto que merece ser discutido refere-se aos critérios de elegibilidade das imagens. O presente estudo incluiu fotografias com outras condições, como opacidades e restaurações dentárias. Estratégias semelhantes foram observadas em outros estudos que também consideraram a inclusão de imagens com defeitos de desenvolvimento de esmalte, restaurações e presença de saliva, removendo apenas imagens duplicadas ou desfocadas em seus conjuntos de dados [36, 37]. Em contrapartida, outros trabalhos excluíram dentes com DDE, restaurações ou selantes, visando maior padronização das [28, 30], o que pode comprometer a reprodutibilidade e generalização dos resultados para situações clínicas mais próximas do real [38].

A CNN YOLOv11 apresentou desempenho consistente, com métricas estáveis de acurácia, sensibilidade e F1-score de 0,800 e precisão de 0,810. Ainda, destacou-se pelo elevado acerto na classificação de superfícies hígdas, porém

mostrou maior dificuldade na diferenciação entre lesões iniciais e híginas, bem como entre lesões severas e iniciais. Esses achados corroboram a literatura, que aponta a similaridade visual entre estágios iniciais e superfícies híginas como um dos principais desafios para sistemas automatizados de diagnóstico [28, 32]

Por outro lado, a CNN ConvNext obteve médias superiores de acurácia e sensibilidade comparado à YOLOv11, ainda que acompanhadas de maior variabilidade entre os treinamentos, indicando sensibilidade potencialmente maior para detectar diferentes padrões da lesão, mas com menor robustez em replicações. As métricas apresentadas por esta CNN apresentaram valor de 0,810 na acurácia, sensibilidade e precisão, e F1-score de 0,800. Embora tenha obtido melhor desempenho na classificação das lesões iniciais e moderadas/severas, esse ganho ocorreu ao custo de um número maior de falsos positivos entre superfícies híginas e iniciais (10,2%). Essa diferença pode estar relacionada às características arquiteturais da ConvNext, baseada em avanços recentes em visão computacional, capazes de capturar padrões mais sutis nas imagens, mas também mais propensa a sobreposição entre classes adjacentes [39]

Já o *ensemble* entre as CNNs YOLOv11 e ConvNext, com a abordagem *classwise*, proporcionou o melhor desempenho global, com acurácia, precisão, sensibilidade e F1-score ponderados de 0,820. Este modelo apresentou uma redução expressiva nos falsos positivos entre superfícies híginas e iniciais (de 10,2% para 1,7%), além de melhora na classificação das lesões iniciais (redução de erros de 17,6% para 15,7%). Esses resultados sugerem que a combinação de arquiteturas complementares pode reduzir as limitações observadas em modelos isolados, reforçando o potencial do *ensemble* como estratégia de aprimoramento na detecção e classificação automatizada de lesões cáries [25]. Ademais, abordagens híbridas podem oferecer resultados mais equilibrados e com aplicações clínicas em comparação com a utilização de CNNs isoladas [25]. Apesar de um leve aumento da variabilidade (desvio padrão = 0,03), o *ensemble* demonstrou maior robustez e equilíbrio entre as métricas, sendo a abordagem mais eficiente do estudo.

Semelhantemente, Kang et al. (2024) [36] também empregaram a técnica de *ensemble* para a detecção de lesões cáries em fotografias intraorais. Neste estudo, a estratégia consistiu na média das probabilidades obtidas a partir da validação cruzada em cinco partes para cada modelo, aplicada tanto em

classificadores *end-to-end* quanto em modelos de detecção de objetos. A justificativa apresentada pelos autores reforça a importância de se considerar múltiplos modelos para gerar sistemas mais robustos e precisos, explorando os pontos fortes de cada arquitetura e atenuando suas limitações [25, 26, 27].

Do ponto de vista clínico, a melhora no reconhecimento de lesões iniciais é particularmente relevante, uma vez que a detecção dos estágios iniciais da doença possibilita intervenções menos invasivas e favorece abordagens preventivas [40]. A boa performance das CNNs, sobretudo na classificação de lesões iniciais no *ensemble*, reforça a aplicabilidade da inteligência artificial como ferramenta complementar no diagnóstico e detecção de lesões cariosas [37]. Estudos publicados na literatura que utilizaram a combinação de modelos, como observado no presente estudo, têm demonstrado aumento na confiabilidade das predições [25].

O presente estudo apresenta limitações que devem ser consideradas. Primeiramente, apesar da inclusão de outras condições clínicas como opacidades, restaurações e presença de biofilme, dentes com opacidade difusa (fluorose) não foram incluídos. Além disso, embora fotografias de menor nitidez não foram excluídas, a utilização de uma câmera profissional permite uma maior padronização das imagens comparado à equipamentos fotográficos mais simples. Ademais, a ausência de validação histológica, considerada o padrão-ouro para o diagnóstico de cárie, representa uma limitação, visto que a avaliação das lesões foi baseada exclusivamente em dados clínicos e foram avaliadas fotografias intraorais. Pesquisas futuras que incorporem imagens provenientes de diferentes contextos clínicos e equipamentos fotográficos são sugeridas. Além disso, a inclusão de outras faixas etárias com diferentes estágios da dentição mista também deve ser considerada em futuras abordagens.

Apesar dessas limitações, o presente estudo apresenta resultados relevantes que contribuem para o avanço da aplicação da inteligência artificial no reconhecimento de lesões cariosas em crianças com dentição mista. O emprego de um *ensemble* entre duas CNNs mostrou desempenho satisfatório na identificação de diferentes graus de severidade das lesões, indicando que a combinação de modelos pode superar limitações individuais de cada arquitetura. Essa abordagem se mostra especialmente promissora no contexto da dentição mista, em que a heterogeneidade das superfícies dentárias e a coexistência de dentes decíduos e permanentes

aumentam a complexidade diagnóstica. Além disso, a utilização dessa ferramenta pode otimizar o tempo do exame clínico e reduzir a subjetividade da avaliação visual, que é fortemente influenciada pela experiência e pelo desempenho do examinador [41]. Ao fornecer maior padronização diagnóstica e apoiar a tomada de decisão clínica, os resultados aqui apresentados reforçam o potencial da inteligência artificial como aliada em programas de saúde bucal infantil e em contextos de prática clínica e de saúde pública.

## **Conclusão**

Entre as CNNs avaliadas neste estudo, a YOLOv11 apresentou desempenho estável e reprodutível. A ConvNext mostrou médias ligeiramente superiores em acurácia e sensibilidade, com variabilidade moderada entre rodadas. Por outro lado, o *ensemble* entre as duas redes proporcionou o melhor equilíbrio entre as métricas, confirmando a vantagem da combinação de modelos, incluindo maior robustez e aplicabilidade clínica na classificação de lesões cariosas em crianças com dentição mista.

## Referências

1. Selwitz RH, Ismail AI, Pitts NB. Dental caries. *Lancet*. 2007;369(9555):51–59. doi:10.1016/S0140-6736(07)60031-2.
2. Ismail AI, Pitts NB, Tellez M, et al. The International Caries Classification and Management System (ICCMS™): an example of a caries management pathway. *BMC Oral Health*. 2015;15 Suppl 1:S9.
3. Kassebaum NJ, Smith AGC, Bernabé E, et al. Global, regional, and national prevalence, incidence, and disability-adjusted life years for oral conditions for 195 countries, 1990–2015: a systematic analysis for the Global Burden of Diseases, Injuries, and Risk Factors. *J Dent Res*. 2017;96(4):380–387. doi:10.1177/0022034517693566.
4. Petersen PE. Global policy for improvement of oral health in the 21st century—implications to oral health research of World Health Assembly 2007, World Health Organization. *Community Dent Oral Epidemiol*. 2009;37(1):1–8. doi:10.1111/j.1600-0528.2008.00448.x.
5. Marinho VC, Higgins JP, Logan S, Sheiham A. Fluoride varnishes for preventing dental caries in children and adolescents. *Cochrane Database Syst Rev*. 2002;(3):CD002279. doi:10.1002/14651858.CD002279.
6. World Health Organization. *Oral Health Surveys: Basic Methods*. 4th ed. Geneva: WHO; 1997.
7. Gimenez T, Piovesan C, Braga MM, et al. Visual inspection for caries detection: a systematic review and meta-analysis. *J Dent Res*. 2015;94(7):895–904. doi:10.1177/0022034515586763.
8. Ismail AI, Sohn W, Tellez M, et al. The International Caries Detection and Assessment System (ICDAS): an integrated system for measuring dental caries. *Community Dent Oral Epidemiol*. 2007;35(3):170–178. doi:10.1111/j.1600-0528.2007.00347.x.
9. Pitts NB, Ekstrand KR; ICDAS Foundation. International Caries Detection and Assessment System (ICDAS) and its International Caries Classification and Management System (ICCMS)—methods for staging of the caries process and enabling dentists to manage caries. *Community Dent Oral Epidemiol*. 2013;41(1):e41–e52. doi:10.1111/cdoe.12025.

10. Ericson D. What is minimally invasive dentistry. *Oral Health Prev Dent.* 2004;2 Suppl 1:287–292.
11. Shoaib L, Deery C, Ricketts DN, Nugent ZJ. Validity and reproducibility of ICDAS II in primary teeth. *Caries Res.* 2009;43(6):442–448. doi:10.1159/000258551.
12. Chan HP, Samala RK, Hadjiiski LM, Zhou C. Deep learning in medical image analysis. *Adv Exp Med Biol.* 2020;1213:3–21.
13. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Sci Dent.* 2019;49(1):1–7. doi:10.5624/isd.2019.49.1.1.
14. Mupparapu M, Wu CW, Chen YC. Artificial intelligence, machine learning, neural networks, and deep learning: futuristic concepts for new dental diagnosis. *Quintessence Int.* 2018;49(9):687–688. doi:10.3290/j.qi.a41107.
15. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature.* 2015;521(7553):436–444. doi:10.1038/nature14539.
16. Deng L, Yu D. Deep learning: methods and applications. *Found Trends Signal Process.* 2013;7:197–387.
17. Alharbi SS, Alhasson HF. Exploring the applications of artificial intelligence in dental image detection: a systematic review. *Diagnostics (Basel).* 2024;14(21):2442.
18. Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent.* 2018;77:106–111. doi:10.1016/j.jdent.2018.07.015.
19. Negi S, Mathur A, Tripathy S, et al. Artificial intelligence in dental caries diagnosis and detection: an umbrella review. *Clin Exp Dent Res.* 2024;10(4):e70004. doi:10.1002/cre2.70004.
20. Ghorbani Z, Mirebeigi-Jamasbi SS, Hassannia Dargah M, et al. A novel deep learning-based model for automated tooth detection and numbering in mixed and permanent dentition in occlusal photographs. *BMC Oral Health.* 2025;25(1):455.
21. Raja M, Nazzal H, Cyprian FS, et al. Association of salivary proteins with dental caries in children with mixed dentition: a systematic review. *Eur Arch Paediatr Dent.* 2025;26(4):617–631. doi:10.1007/s40368-024-00994-4.

22. Mongan Moy JL, Kahn CE. Checklist for artificial intelligence in medical imaging (CLAIM): a guide for authors and reviewers. *Radiol Artif Intell.* 2020;2(2):e200029.
23. Ghanim A, Elfrink M, Weerheijm K, et al. A practical method for use in epidemiological studies on enamel hypomineralisation. *Eur Arch Paediatr Dent.* 2015;16(3):235–246. doi:10.1007/s40368-015-0178-8.
24. Landis JR, Koch GG. The measurement of observer agreement for categorical data. *Biometrics.* 1977;33(1):159–174. Ismail, A.I., Pitts, N.B., Tellez, M. et al. The International Caries Classification and Management System (ICCMS™) An Example of a Caries Management Pathway. *BMC Oral Health* 15 (Suppl 1), S9 (2015).
25. Ganaie M, Hu M, Malik A, et al. Ensemble deep learning: a review. *Eng Appl Artif Intell.* 2022;115:105151. doi:10.1016/j.engappai.2022.105151.
26. Mohammed A, Kora R. A comprehensive review on ensemble deep learning: opportunities and challenges. *J King Saud Univ Comput Inf Sci.* 2023;35(2):757–774. doi:10.1016/j.jksuci.2023.01.014.
27. Yang Y, Lv H, Chen N. A survey on ensemble learning under the era of deep learning. *Artif Intell Rev.* 2023;56(6):5545–5589.
28. Moutselos K, Berdouses E, Oulis C, Maglogiannis I. Recognizing occlusal caries in dental intraoral images using deep learning. In: *Conf Proc IEEE Eng Med Biol Soc. Berlin: IEEE; 2019. p. 1617–1620.* doi:10.1109/EMBC.2019.8856553.
29. Xiong Y, Zhang H, Zhou S, et al. Simultaneous detection of dental caries and fissure sealant in intraoral photos by deep learning: a pilot study. *BMC Oral Health.* 2024;24(1):553. doi:10.1186/s12903-024-04254-1.
30. Kühnisch J, Meyer O, Hesenius M, et al. Caries detection on intraoral images using artificial intelligence. *J Dent Res.* 2022;101(2):158–165. doi:10.1177/00220345211032524.
31. Portella PD, de Oliveira LF, Ferreira MFC, et al. Improving accuracy of early dental carious lesions detection using deep learning-based automated method. *Clin Oral Investig.* 2023;27(12):7663–7670. doi:10.1007/s00784-023-05355-x.

32. Zhang X, Liang Y, Li W, et al. Development and evaluation of deep learning for screening dental caries from oral photographs. *Oral Dis*. 2022;28:173–181.
33. Bouthillier X, Delaunay P, Bronzi M, et al. Accounting for variance in machine learning benchmarks. *arXiv*. 2021. doi:10.48550/arXiv.2103.03098.
34. Zhang Y, Liao H, Xiao J, et al. A smartphone-based system for real-time early childhood caries diagnosis. In: *Lect Notes Comput Sci*. Springer; 2020. p. 233–242.
35. Mehdizadeh M, Estai M, Vignarajan J, et al. A deep learning-based system for the assessment of dental caries using colour dental photographs. *Stud Health Technol Inform*. 2024;310:911–915. doi:10.3233/SHTI231097.
36. Kang S, Shon B, Park EY, et al. Diagnostic accuracy of dental caries detection using ensemble techniques in deep learning with intraoral camera images. *PLoS One*. 2024;19(9):e0310004. doi:10.1371/journal.pone.0310004.
37. Park EY, Cho H, Kang S, et al. Caries detection with tooth surface segmentation on intraoral photographic images using deep learning. *BMC Oral Health*. 2022;22:573. doi:10.1186/s12903-022-02589-1.
38. Colliot O, Thibeau-Sutre E, Burgos N. Reproducibility in machine learning for medical imaging. In: Colliot O, editor. *Machine Learning for Brain Disorders*. New York: Humana; 2023. Chapter 21. doi:10.1007/978-1-0716-3195-9\_21.
39. Karacan MH, Yücebas SC. A deep learning model with attention mechanism for dental image segmentation. In: *Int Congr Hum-Comput Interact Optim Robot Appl (HORA)*. Ankara: IEEE; 2022. p. 1–4. doi:10.1109/HORA55278.2022.9800072.
40. Perrone BR, Bottesini VC, Duarte DA. Minimal intervention dentistry: what is its clinical application and effectiveness in different continents? A scoping review. *J Conserv Dent Endod*. 2024;27(2):134–139. doi:10.4103/JCDE.JCDE\_274\_23.
41. Soares GG, Souza PR, Purger FPC, Vasconcellos AB, Ribeiro AA. Métodos de detecção de cárie. *Rev Bras Odontol*. 2012;69(1):84–89.

## CONSIDERAÇÕES FINAIS

O presente estudo demonstrou que o aprendizado profundo, por meio de diferentes arquiteturas de redes neurais convolucionais (CNNs), apresenta potencial relevante para a detecção de dentes e a classificação de lesões cariosas em crianças na fase de dentição mista. A rede YOLOv11 obteve elevado desempenho na detecção de dentes posteriores, especialmente permanentes parcialmente irrompidos, enquanto a U-Net mostrou resultados consistentes na segmentação dentária. Na etapa de classificação das lesões cariosas, a ConvNext apresentou desempenho superior em relação às redes isoladas, e a combinação em ensemble entre YOLOv11 e ConvNext proporcionou os melhores índices globais de acurácia, sensibilidade, precisão e F1-score.

Os achados reforçam a aplicabilidade da inteligência artificial como ferramenta auxiliar ao diagnóstico odontológico, particularmente na identificação dos diferentes estágios de severidade da cárie dentária em populações infantis. A utilização de índices clínicos internacionalmente reconhecidos e a padronização metodológica adotada conferem robustez e reprodutibilidade aos resultados, permitindo avanços tanto em pesquisa quanto em aplicações práticas.

Entretanto, algumas limitações devem ser consideradas. A amostra foi restrita a uma única faixa etária, e a qualidade variável das imagens fotográficas pode ter influenciado o desempenho dos modelos, sobretudo na diferenciação entre superfícies híginas e lesões iniciais. Tais fatores indicam a necessidade de estudos adicionais que explorem diferentes faixas etárias, maior diversidade populacional e ampliação da base de imagens.

Conclui-se que o aprendizado profundo apresenta resultados promissores na detecção de lesões cariosas em crianças com dentição mista. A consolidação dessa tecnologia poderá contribuir para o diagnóstico clínico, o planejamento terapêutico e o desenvolvimento de ferramentas de triagem, representando um avanço significativo na prática clínica em odontopediatria.

## REFERÊNCIAS BIBLIOGRÁFICAS

ADNAN, N.; FAIZAN AHMED, S. M.; DAS, J. K.; et al. Developing an AI-based application for caries index detection on intraoral photographs. *Scientific Reports*, v. 14, n. 1, p. 26752, 2024. DOI: 10.1038/s41598-024-78184-x.

ALBAHBAH, A. A.; EL-BAKRY, H. M.; ABD-ELGAHANY, S. Detection of caries in panoramic dental X-ray images using back-propagation neural network. *International Journal of Electron. Commun. Comput. Eng.*, v. 7, p. 250, 2016.

ALHARBI, S. S.; ALHASSON, H. F. Exploring the Applications of Artificial Intelligence in Dental Image Detection: A Systematic Review. *Diagnostics (Basel)*, v. 14, n. 21, p. 2442, 2024. DOI: 10.3390/diagnostics14212442.

AL SAFFAN, A. D. Current Approaches to Diagnosis of Early Proximal Carious Lesion: A Literature Review. *Cureus*, v. 15, n. 8, e43489, 2023. DOI: 10.7759/cureus.43489.

ARIK, S. Ö.; IBRAGIMOV, B.; XING, L. Fully automated quantitative cephalometry using convolutional neural networks. *Journal of Medical Imaging*, v. 4, p. 014501, 2017.

ASTVALDSDÓTTIR, A.; AHLUND, K.; HOLBROOK, W. P.; DE VERDIER, B.; TRANÆUS, S. Approximal Caries Detection by DIFOTI: In Vitro Comparison of Diagnostic Accuracy/Efficacy with Film and Digital Radiography. *International Journal of Dentistry*, 2012. DOI: 10.1155/2012/326401.

AYHAN, B.; AYAN, E.; BAYRAKTAR, Y. A novel deep learning-based perspective for tooth numbering and caries detection. *Clinical Oral Investigations*, v. 28, p. 178, 2024.

BARZOTTO, I.; RIGO, L. Clinical decision making for diagnosis and treatment of dental enamel injuries. *Journal of Human Growth and Development*, v. 28, n. 2, p. 189–198, 2018.

CANTU, A. G.; GEHRUNG, S.; KROIS, J.; CHAURASIA, A.; ROSSI, J. G.; GAUDIN, R.; ELHENNAWY, K.; SCHWENDICKE, F. Detecting caries lesions of different radiographic extension on bitewings using deep learning. *Journal of Dentistry*, v. 100, p. 103425, 2020.

CHAVES, E. T.; VINAYAHALINGAM, S.; VAN NISTELROOIJ, N.; XI, T.; ROMERO, V. H. D.; FLÜGGE, T.; SAKER, H.; KIM, A.; DA SILVEIRA LIMA, G.; LOOMANS, B.;

et al. Detection of caries around restorations on bitewings using deep learning. *Journal of Dentistry*, 2024, p. 104886.

CHAN, H. P.; SAMALA, R. K.; HADJIISKI, L. M.; ZHOU, C. Deep Learning in Medical Image Analysis. In: *Advances in Experimental Medicine and Biology*, v. 1213, p. 3–21, 2020.

COMMISSION ON ORAL HEALTH, RESEARCH & EPIDEMIOLOGY. A review of the developmental defects of enamel index (DDE Index). Report of an FDI Working Group. *International Dental Journal*, v. 42, n. 6, p. 411-426, 1992.

CONRADS, G.; ABOUT, I. Pathophysiology of Dental Caries. *Monographs in Oral Science*, v. 27, p. 1–10, 2018. DOI: 10.1159/000487826.

COSTA, F. S.; SILVEIRA, E. R.; PINTO, G. S.; NASCIMENTO, G. G.; THOMSON, W. M.; DEMARCO, F. F. Developmental defects of enamel and dental caries in the primary dentition: A systematic review and meta-analysis. *Journal of Dentistry*, v. 60, p. 1–7, 2017.

DENG, L.; YU, D. Deep Learning: Methods and Applications. *Foundations and Trends in Signal Processing*, v. 7, p. 197–387, 2013. DOI: 10.1561/20000000039.

DING, B.; ZHANG, Z.; LIANG, Y.; et al. Detection of dental caries in oral photographs taken by mobile phones based on the YOLOv3 algorithm. *Annals of Translational Medicine*, v. 9, n. 21, p. 1622, 2021. DOI: 10.21037/atm-21-4805.

FEJERSKOV, O.; NYVAD, B.; KIDD, E. *Cárie Dentária: Fisiopatologia e Tratamento*. 3. ed. Rio de Janeiro: Santos, 2017. ISBN 9788527731799.

FRENKEL, E.; NEUMAYR, J.; SCHWARZMAIER, J.; et al. Caries detection and classification in photographs using an artificial intelligence-based model – an external validation study. *Diagnostics (Basel)*, v. 14, n. 20, p. 2281, 2024. doi:10.3390/diagnostics14202281.

GHANIM, A.; ELFRINK, M.; WEERHEIJM, K.; MARIÑO, R.; MANTON, D. A practical method for use in epidemiological studies on enamel hypomineralisation. *Eur Arch Paediatr Dent*, v. 16, n. 3, p. 235-246, 2015. doi:10.1007/s40368-015-0178-8.

GHANIM, A.; MANTON, D.; MARIÑO, R.; MORGAN, M.; BAILEY, D. Prevalence of demarcated hypomineralisation defects in second primary molars in Iraqi children. *Int J Paediatr Dent*, v. 23, n. 1, p. 48-55, 2013.

GHORBANI, Z.; MIREBEIGI-JAMASBI, S.S.; HASSANNIA DARGAH, M.; NAHVI, M.; HOSSEINIKHAH MANSHADI, S.A.; AKBARZADEH FATHABADI, Z. A novel deep learning-based model for automated tooth detection and numbering in mixed and permanent dentition in occlusal photographs. *BMC Oral Health*, v. 25, n. 1, p. 455, 2025.

GIMENEZ, T.; PIOVESAN, C.; BRAGA, M.M.; RAGGIO, D.P.; DEERY, C.; RICKETTS, D.N.; et al. Visual inspection for caries detection: a systematic review and meta-analysis. *J Dent Res*, v. 94, n. 7, p. 895-904, 2015.

GOMEZ, J. Detection and diagnosis of the early caries lesion. *BMC Oral Health*, v. 15, n. 1, 2015. doi:10.1186/1472-6831-15-S1-S3.

HAVSED, K.; CARDA-DIÉGUEZ, M.; ISAKSSON, H.; et al. Salivary Proteins and Metabolites as Caries Biomarkers in Adolescents. *Caries Res*, v. 58, n. 6, p. 573-588, 2024. doi:10.1159/000540090.

HWANG, J.J.; JUNG, Y.H.; CHO, B.H.; HEO, M.S. An overview of deep learning in the field of dentistry. *Imaging Sci Dent*, v. 49, n. 1, p. 1-7, 2019. doi:10.5624/isd.2019.49.1.1.

ISMAIL, A.I. Visual and visuo-tactile detection of dental caries. *J Dent Res*, v. 83, Spec No C, p. C56-C66, 2004.

ISMAIL, A.I. The International Caries Detection and Assessment System (ICDAS): an integrated system for measuring dental caries. *Community Dent Oral Epidemiol*, v. 35, p. 170–178, 2007.

ISMAIL, A.I.; PITTS, N.B.; TELLEZ, M.; et al. The International Caries Classification and Management System (ICCMS™): An Example of a Caries Management Pathway. *BMC Oral Health*, v. 15, Suppl 1, S9, 2015. doi:10.1186/1472-6831-15-S1-S9.

JADER, G.; FONTINELI, J.; RUIZ, M.; ABDALLA, K.; PITHON, M.; OLIVEIRA, L. Deep instance segmentation of teeth in panoramic X-ray images. In: *Proceedings of the Conference on Graphics, Patterns and Images (SIBGRAPI)*, Parana, Brazil, 29 October–1 November 2018. p. 400–407.

KANG, C.H.; KIM, S.Y. Real-time object detection and segmentation technology: an analysis of the YOLO algorithm. *JMST Adv*, v. 5, p. 69-76, 2023.

KANG, S.; SHON, B.; PARK, E.Y.; JEONG, S.; KIM, E.K. Diagnostic accuracy of dental caries detection using ensemble techniques in deep learning with intraoral

camera images. *PLoS One*, v. 19, n. 9, e0310004, 2024. doi:10.1371/journal.pone.0310004.

KHATTAK, O.; HASHEM, A.S.; ALQARNI, M.S.; et al. Deep Learning Applications in Dental Image-Based Diagnostics: A Systematic Review. *Healthcare (Basel)*, v. 13, n. 12, p. 1466, 2025. doi:10.3390/healthcare13121466.

KÜHNISCH, J.; MEYER, O.; HESENIUS, M.; HICKEL, R.; GRUHN, V. Caries detection on intraoral images using artificial intelligence. *J Dent Res*, v. 101, p. 158–165, 2022.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159–174, 1977.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. doi:10.1038/nature14539.

LEE, J.H.; KIM, D.H.; JEONG, S.N.; CHOI, S.H. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent*, v. 77, p. 106–111, 2018.

LEE, S.; OH, S.I.; JO, J.; KANG, S.; SHIN, Y.; PARK, J.W. Deep Learning for Early Dental Caries Detection in Bitewing Radiographs. *Sci Rep*, v. 11, p. 16807, 2021.

LI, R.Z.; ZHU, J.X.; WANG, Y.Y.; et al. *Zhonghua Kou Qiang Yi Xue Za Zhi*, v. 56, n. 12, p. 1253–1260, 2021. doi:10.3760/cma.j.cn112144-20210712-00323.

LIAN, L.; ZHU, T.; ZHU, F.; ZHU, H. Deep learning for caries detection and classification. *Diagnostics*, v. 13, n. 11, p. 1672, 2021.

LITJENS, G.; et al. A survey on deep learning in medical image analysis. *Medical Images Analysis*, v. 42, p. 60–88, 2017.

LIU, Z.; LIN, Y.; CAO, Y.; HUANG, H.; WEI, Y.; ZHANG, Z.; LIN, S.; GUO, B. A convnet for the 2020s. In: *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 2022. p. 11976–11986. doi:10.1109/CVPR52688.2022.01168.

LIU, Y.; CHENG, Y.; SONG, Y.; CAI, D.; ZHANG, N. Oral screening of dental calculus, gingivitis and dental caries through segmentation on intraoral photographic images using deep learning. *BMC Oral Health*, v. 24, n. 1, p. 1287, 2024. doi:10.1186/s12903-024-05072-1.

LYNCH, R. J. The primary and mixed dentition, post-eruptive enamel maturation and dental caries: a review. *International Dental Journal*, v. 63, suppl. 2, p. 3-13, 2013. doi:10.1111/idj.12076.

MACEY, R.; WALSH, T.; RILEY, P.; et al. Electrical conductance for the detection of dental caries. *Cochrane Database Syst Rev*, v. 3, n. 3, CD014547, 2021. doi:10.1002/14651858.CD014547.

MAGALHÃES, A.C. *Cariologia: da base à clínica*. Barueri: Manole, 2021. E-book. ISBN 9786555764246.

MAZUROWSKI, M.A.; BUDA, M.; SAHA, A.; BASHIR, M.R. Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *J Magn Reson Imaging*, v. 49, n. 4, p. 939–954, 2019.

MEHDIZADEH, M.; ESTAI, M.; VIGNARAJAN, J.; et al. A Deep Learning-Based System for the Assessment of Dental Caries Using Colour Dental Photographs. *Stud Health Technol Inform*, v. 310, p. 911–915, 2024. doi:10.3233/SHTI231097.

MIKI, Y.; MURAMATSU, C.; HAYASHI, T.; ZHOU, X.; HARA, T.; KATSUMATA, A.; FUJITA, H. Classification of teeth in cone-beam CT using deep convolutional neural network. *Comput Biol Med*, v. 80, p. 24–29, 2017.

MOHARRAMI, M.; FARMER, J.; SINGHAL, S.; et al. Detecting dental caries on oral photographs using artificial intelligence: A systematic review. *Oral Dis*, v. 30, n. 4, p. 1765–1783, 2024. doi:10.1111/odi.14659.

MOUTSELOS, K.; BERDOUSES, E.; OULIS, C.; MAGLOGIANNIS, I. Recognizing Occlusal Caries in Dental Intraoral Images Using Deep Learning. In: *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Berlin, Germany, 2019. p. 1617–1620. doi:10.1109/EMBC.2019.8856553.

MUPPARAPU, M.; WU, C.W.; CHEN, Y.C. Artificial intelligence, machine learning, neural networks, and deep learning: Futuristic concepts for new dental diagnosis. *Quintessence Int*, v. 49, n. 9, p. 687–688, 2018. doi:10.3290/j.qi.a41107.

MURESAN, M.P.; BARBURA, A.R.; NEDVSCHI, S. Teeth Detection and Dental Problem Classification in Panoramic X-Ray Images using Deep Learning and Image Processing Techniques. In: *16th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP)*, Cluj-Napoca, Romania, 3–5 September 2020. p. 457–463.

OLMEZ, A.; TUNA, D.; OZNURHAN, F. Clinical evaluation of diagnodent in detection of occlusal caries in children. *J Clin Pediatr Dent*, v. 30, n. 4, p. 287–291, 2006.

PARK, E.Y.; CHO, H.; KANG, S.; et al. Caries detection with tooth surface segmentation on intraoral photographic images using deep learning. *BMC Oral Health*, v. 22, 573, 2022. doi:10.1186/s12903-022-02589-1.

PARK, W.J.; PARK, J.B. History and application of artificial neural networks in dentistry. *Eur J Dent*, v. 12, n. 4, p. 594–601, 2018. doi:10.4103/ejd.ejd\_325\_18.

PERES, M.A.; MACPHERSON, L.M.D.; WEYANT, R.J.; et al. Oral diseases: a global public health challenge. *Lancet*, v. 394, n. 10194, p. 249–260, 2019. doi:10.1016/S0140-6736(19)31146-8.

PITTS, N.B.; ZERO, D.T.; MARSH, P.D.; et al. Dental caries. *Nat Rev Dis Primers*, v. 3, 17030, 2017. doi:10.1038/nrdp.2017.30.

PORTELLA, P.D.; DE OLIVEIRA, L.F.; FERREIRA, M.F.C.; DIAS, B.C.; DE SOUZA, J.F.; ASSUNÇÃO, L.R.D.S. Improving accuracy of early dental carious lesions detection using deep learning-based automated method. *Clin Oral Investig*, v. 27, n. 12, p. 7663–7670, 2023. doi:10.1007/s00784-023-05355-x.

PRETTY, I.A.; ELLWOOD, R.P. The caries continuum: opportunities to detect, treat and monitor the re-mineralization of early caries lesions. *J Dent*, v. 41, Suppl 2, S12–S21, 2013. doi:10.1016/j.jdent.2010.04.003.

PRINCE, S.J.D. *Computer Vision: Model, Learning and Inference*. Cambridge: Cambridge University Press, 2012.

RAJA, M.; NAZZAL, H.; CYPRIAN, F.S.; MATOUG-ELWERFELLI, M.; DUGGAL, M. Association of salivary proteins with dental caries in children with mixed dentition: a systematic review. *Eur Arch Paediatr Dent*, 2025. doi:10.1007/s40368-024-00994-4.

RECHMANN, P.; LIOU, E.J.W.; FEATHERSTONE, J.D.B. Performance of laser fluorescence devices in detecting caries lesions in permanent teeth: A systematic review and meta-analysis. *J Dent*, v. 109, 103655, 2021.

RIGO, L.; LODI, L.; GARBIN, R.R. Diagnóstico diferencial de fluorose dentária por discentes de odontologia. *Einstein (São Paulo)*, v. 13, n. 4, p. 547–554, 2015.

RODRIGUES, N.; MARTINEZ-RUS, F.; MIGUEL-CALVO, A.; PRADIÉS, G.; SALIDO, M.P. Accuracy Assessment of Human and Artificial Intelligence-Assisted Bitewing Radiography and Near-Infrared Reflectance Imaging-Based Methods for

Interproximal Caries Detection: A Histological Validation. *Caries Res*, 2025. doi:10.1159/000546644.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: convolutional networks for biomedical image segmentation. In: NAVAB, N.; HORNEGGER, J.; WELLS, W.; FRANGI, A., eds. *Medical image computing and computer-assisted intervention – MICCAI 2015*. Cham: Springer, 2015. p. 234–241.

SAHINER, B.; PEZESHK, A.; HADJIISKI, L.M.; WANG, X.; DRUKKER, K.; CHA, K.H.; SUMMERS, R.M.; GIGER, M.L. Deep learning in medical imaging and radiation therapy. *Med Phys*, v. 46, n. 1, p. e1–e36, 2019.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. *Neural Networks*, v. 61, p. 85–117, 2015.

SCHWENDICKE, F.; ROSSI, J.G.; GÖSTEMEYER, G.; et al. Cost-effectiveness of Artificial Intelligence for Proximal Caries Detection. *J Dent Res*, v. 100, n. 4, p. 369–376, 2021. doi:10.1177/0022034520972335.

SCHWENDICKE, F.; TZSCHOPPE, M.; PARIS, S. Radiographic caries detection: A systematic review and meta-analysis. *J Dent*, v. 43, n. 8, p. 924–933, 2015. doi:10.1016/j.jdent.2015.02.009.

SELWITZ, R.H.; ISMAIL, A.I.; PITTS, N.B. Dental caries. *Lancet*, v. 369, n. 9555, p. 51–59, 2007. doi:10.1016/S0140-6736(07)60031-2.

SEO, H.; HWANG, J.; JUNG, Y.H.; LEE, E.; NAM, O.H.; SHIN, J. Deep focus approach for accurate bone age estimation from lateral cephalogram. *J Dent Sci*, v. 18, p. 34–43, 2023.

SHAPIRO, L.; STOCKMAN, G. *Computer Vision*. Prentice Hall, 2000.

SIVAKUMAR, M.; PARTHASARATHY, S.; PADMAPRIYA, T. Trade-off between training and testing ratio in machine learning for medical image processing. *PeerJ Comput Sci*, v. 10, e2245, 2024. doi:10.7717/peerj-cs.2245.

SONG, Y.; QIAO, X.; IWAMOTO, Y.; CHEN, Y.W. Automatic cephalometric landmark detection on X-ray images using a deep-learning method. *Appl Sci*, v. 10, 2547, 2020.

SRIVASTAVA, M.M.; KUMAR, P.; PRADHAN, L.; VARADARAJAN, S. Detection of tooth caries in bitewing radiographs using deep learning. *arXiv*, 1711.07312, 2017.

SHI, W.; QIN, M.; CHEN, F.; XIA, B. Supragingival Microbial Profiles of Permanent and Deciduous Teeth in Children with Mixed Dentition. *PLoS One*, v. 11, n. 1, e0146938, 2016. doi:10.1371/journal.pone.0146938.

SOARES, G.G.; SOUZA, P.R.; PURGER, F.P.C.; VASCONCELLOS, A.B.; RIBEIRO, A.A. Métodos de detecção de cárie. *Rev Bras Odontol*, v. 69, n. 1, p. 84–89, 2012.

TAKAMORI, K.; HOKARI, N.; OKUMURA, Y.; WATANABE, S. Detection of occlusal caries under sealants by use of a laser fluorescence system. *J Clin Laser Med Surg*, v. 19, n. 5, p. 267–271, 2001. doi:10.1089/10445470152612008.

THYLSTRUP, A.; FEJERSKOV, O. Clinical appearance of dental fluorosis in permanent teeth in relation to histologic changes. *Community Dent Oral Epidemiol*, v. 6, n. 6, p. 315–328, 1978. doi:10.1111/j.1600-0528.1978.tb01173.x.

TIAN, Z.; YANG, F.; YANG, L.; WU, Y.; CHEN, J.; QIAN, P. An Optimized YOLOv11 Framework for the Efficient Multi-Category Defect Detection of Concrete Surface. *Sensors*, v. 25, n. 5, 1291, 2025. doi:10.3390/s25051291.

TUZOFF, D.V.; TUZOVA, L.N.; BORNSTEIN, M.M.; KRASNOV, A.S.; KHARCHENKO, M.A.; NIKOLENKO, S.I.; SVESHNIKOV, M.M.; BEDNENKO, G.B. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol*, v. 48, 20180051, 2019.

WEERHEIJM, K.L.; JÄLEVIK, B.; ALALUUSUA, S. Molar-incisor hypomineralisation. *Caries Res*, v. 35, n. 5, p. 390–391, 2001. doi:10.1159/000047479.

WENG, T.; NIU, X. Enhancing UAV Object Detection in Low-Light Conditions with ELS-YOLO: A Lightweight Model Based on Improved YOLOv11. *Sensors*, v. 25, n. 14, 4463, 2025. doi:10.3390/s25144463.

WHO. *Oral Health Surveys: Basic Methods*, 4th ed. Geneva: World Health Organization, 1997.

WIDIASRI, M.; ARIFIN, A.Z.; SUCIATI, N.; FATICAH, C.; ASTUTI, E.R.; INDRASWARI, R.; PUTRA, R.H.; ZA'IN, C. Dental-YOL: Alveolar Bone and Mandibular Canal Detection on Cone Beam Computed Tomography Images for Dental Implant Planning. *IEEE Access*, v. 10, p. 101483–101494, 2022.

XIE, R.; YANG, Y.; CHEN, Z. WITS: Weakly-supervised individual tooth segmentation model trained on box-level labels. *Pattern Recognit*, v. 133, 108974, 2023.

XIONG, Y.; ZHANG, H.; ZHOU, S.; et al. Simultaneous detection of dental caries and fissure sealant in intraoral photos by deep learning: a pilot study. *BMC Oral Health*, v. 24, 553, 2024. doi:10.1186/s12903-024-04254-1.

YOON, K.; JEONG, H.M.; KIM, J.W.; PARK, J.H.; CHOI, J. AI-based dental caries and tooth number detection in intraoral photos: Model development and performance evaluation. *J Dent*, v. 141, 104821, 2024. doi:10.1016/j.jdent.2023.104821.

ZHANG, K.; WU, J.; CHEN, H.; LYU, P. An effective teeth recognition method using label tree with cascade network structure. *Comput Med Imaging Graph*, v. 68, p. 61–70, 2018.

ZHANG, Y.; LIAO, H.; XIAO, J.; AL JALLAD, N.; LY-MAPES, O.; LUO, J. A smartphone-based system for real-time early childhood caries diagnosis. In: *Lecture Notes in Computer Science*, Springer, 2020. p. 233–242.

ZHANG, X.; LIANG, Y.; LI, W.; LIU, C.; GU, D.; SUN, W.; MIAO, L. Development and evaluation of deep learning for screening dental caries from oral photographs. *Oral Dis*, v. 28, p. 173–181, 2022.

## ANEXOS

### ANEXO 1 – COMPROVANTE DE RECEPÇÃO À APRECIÇÃO AO COMITÊ DE ÉTICA

UFPR - SETOR DE CIÊNCIAS  
DA SAÚDE DA UNIVERSIDADE  
FEDERAL DO PARANÁ -  
SCS/UFPR



#### PARECER CONSUBSTANCIADO DO CEP

##### DADOS DA EMENDA

**Título da Pesquisa:** RECONHECIMENTO AUTOMÁTICO DE PADRÕES DENTÁRIOS UTILIZANDO APRENDIZADO PROFUNDO

**Pesquisador:** LUCIANA REICHERT ASSUNÇÃO ZANON

**Área Temática:**

**Versão:** 6

**CAAE:** 25001219.5.0000.0102

**Instituição Proponente:** Programa de Pós-Graduação em Odontologia

**Patrocinador Principal:** Financiamento Próprio

##### DADOS DO PARECER

**Número do Parecer:** 6.823.137

##### Apresentação do Projeto:

O presente projeto pretende, por meio da utilização de fotografias clínicas intrabucais, classificar e caracterizar padrões dentários em CNN (Convolutional Neural Network), e assim contribuir para o estabelecimento desta metodologia e, conseqüentemente, no aumento da sua aplicabilidade. Segundo os pesquisadores, representa um avanço para a Odontologia, uma vez que o uso de CNN pode facilitar e auxiliar o diagnóstico de alterações dentárias.

Em emenda anterior, os pesquisadores pretendiam ampliar as análises e avaliar dentes de Bancos de dentes de duas universidades: UFPR e UEPG. As análises dos dentes seriam realizadas previamente ao exame dos escolares.

Desse modo, houve alteração em: local de realização de pesquisa, fontes de material de pesquisa, medidas de proteção ou minimização de qualquer risco eventual e cronograma.

Com essa alteração, houve mudança também no local de realização de pesquisa, devido a participação do Banco de Dentes da UEPG.

Foi submetida e aprovada emenda em 07/10/21 com o objetivo de incluir a possibilidade de divulgação de dados em plataforma digital de domínio público.

**Endereço:** Rua Padre Camargo, 285 - 1º andar

**Bairro:** Alto da Glória

**UF:** PR

**Município:** CURITIBA

**Telefone:** (41)3360-7259

**CEP:** 80.060-240

**E-mail:** cometica.saude@ufpr.br

UFPR - SETOR DE CIÊNCIAS  
DA SAÚDE DA UNIVERSIDADE  
FEDERAL DO PARANÁ -  
SCS/UFPR



Continuação do Parecer: 6.823.137

Nesta emenda, a pesquisadora solicita as seguintes alterações:

- 1A. Alteração da data de fim da pesquisa para julho de 2025
- 2A. Inclusão de amostras de crianças assistidas na clínica de Odontopediatria da Universidade Federal do Paraná.
- 3A. Inclusão de realização de radiografias dentárias em casos de superfícies oclusais com lesões cáries escore 4 e superfícies interproximais com lesões cáries a partir do escore 3 do ICDAS. Este exame será realizado somente nas crianças atendidas na clínica de Odontopediatria da UFPR.
- 4A. Inclusão da aluna de mestrado Bruna Cristine Dias na equipe de pesquisa, em substituição da aluna Paula Dresch Portella, que já defendeu sua tese de doutorado.

**Objetivo da Pesquisa:**

Os objetivos da pesquisa são os seguintes:

- Objetivo Geral:

Classificar os padrões dentários em situações de normalidade, de lesões cárie dentária e dos defeitos de desenvolvimento do esmalte (DDE) observados em fotografias intrabucais, por meio da utilização de metodologias de aprendizado profundo, buscando automatizar o processo de diagnóstico de alterações dentárias que acometem a saúde dental, permitindo assim, auxiliar o diagnóstico realizado pelos cirurgiões-dentistas.

- Objetivos Específicos:

- ✓ Observar o desempenho de uma arquitetura de Rede Neural pre-treinada para a classificação de estruturas dentárias, cárie e DDE;
- ✓ Analisar o comportamento da técnica de transferência de aprendizagem em CNNs para classificar blocos de fotografias intrabucais;
- ✓ Analisar o desempenho das Convolutional Neural Network (CNN) aplicadas ao contexto de detecção e classificação de fotografias odontológicas;
- ✓ Treinar e testar alguns modelos recentes de CNNs para detectar e classificar automaticamente os padrões dentários de normalidade, cárie e DDE em fotografias intrabucais inteiras.

**Endereço:** Rua Padre Camargo, 285 - 1º andar

**Bairro:** Alto da Glória

**CEP:** 80.060-240

**UF:** PR

**Município:** CURITIBA

**Telefone:** (41)3360-7259

**E-mail:** cometica.saude@ufpr.br

Página 02 de 08

Em notificação aprovada em 20/03/24, a pesquisadora principal relata que foram avaliados todos os dentes posteriores extraídos, decíduos e permanentes, pertencentes aos Bancos de Dentes Humanos (BDH) vinculados ao Curso de Odontologia da UFPR e ao Setor de Ciências Biológicas da Saúde da Universidade Estadual de Ponta Grossa (UEPG). Foram excluídos aqueles que apresentavam manchamentos extrínsecos ou intrínsecos na o-cariosos, ou tinham procedimentos restauradores, como selantes, restaurações e próteses, e endodônticos, como abertura coronária e material obturador aparente. Dentes com defeitos de desenvolvimento de esmalte foram incluídos, desde que não houvesse perda de estrutura dentária suficiente para prejudicar o exame clínico da cárie. Foram selecionados para o estudo 2.481 dentes (BDH- UFPR: 2.311; BDH-UEPG: 170), sendo 2.459 permanentes e 22 decíduos, com diferentes estágios de lesões de cárie dentária.

Após serem doados aos BDH, todos os dentes extraídos avaliados neste estudo foram submetidos a etapas de desinfecção, seleção, esterilização, limpeza mecânica com auxílio de água, escova e sabão e estocagem. No BDH-UFPR os dentes foram estocados e disponibilizados a seco, enquanto no BDH-UEPG em água destilada. No entanto, para a avaliação das lesões cariosas, todos os dentes encontravam-se na mesma condição, ou seja, completamente secos.

Todos os dentes extraídos foram identificados por um número (ID) e fixados em uma base de cera para a avaliação das superfícies oclusais, garantindo que os dentes permanecessem utilizáveis após a realização do presente estudo (FIGURA 1). O exame clínico foi realizado sob luz artificial, com o auxílio de lanterna de LED, acoplada à cabeça do examinador, e sonda exploradora de ponta romba, conforme preconizado pela Organização Mundial da Saúde (WHO, 2013). Os dentes extraídos fornecidos em meio aquoso pelo BDH- UEPG foram secos com gaze, antes serem examinados.

O exame clínico foi realizado por três examinadores calibrados, sendo a classificação final do índice averiguada por um quarto examinador (examinador de referência). Os dados foram tabulados no software SPSS (versão 20.0 IBM, Brasil).

#### **Avaliação dos Riscos e Benefícios:**

Os riscos e benefícios previstos inicialmente foram os seguintes:

Riscos:

**Endereço:** Rua Padre Camargo, 285 - 1º andar

**Bairro:** Alto da Glória

**UF:** PR

**Telefone:** (41)3360-7259

**Município:** CURITIBA

**CEP:** 80.060-240

**E-mail:** cometica.saude@ufpr.br

Os possíveis riscos envolvidos nessa pesquisa incluem constrangimento das crianças no momento do exame clínico e das fotografias. Estes riscos serão minimizados com a realização de apenas fotografias intrabuciais, preservando a identidade da criança. Caso a criança sinta algum desconforto durante o exame clínico, o mesmo poderá ser interrompido a qualquer momento. Em uma possível divulgação dos resultados, os nomes serão transformados em códigos, preservando-se o anonimato. As fotografias permanecerão armazenadas sob responsabilidade do pesquisador responsável, que manterá o sigilo dos dados obtidos.

**Benefícios:**

Após a avaliação do desempenho da CNN na detecção de alterações dentárias, esta metodologia poderá auxiliar os profissionais no diagnóstico de alterações dentárias, representando um importante avanço para a área. Do mesmo modo, os participantes estarão contribuindo para este avanço científico, visto que somente a partir da realização destas fotografias será possível o treinamento das redes de aprendizado profundo com uma nova fonte de dados, e, a longo prazo, também desfrutarão da utilização de CNN na Odontologia, já que implicará no aumento da assertividade diagnóstica.

Quanto aos dentes extraídos, não será utilizada nenhuma fonte de informações ou dados sobre os seus doadores, prevalecendo, assim, o anonimato.

Em emenda apresentada, os pesquisadores acrescentaram o seguinte: "Quanto aos dentes extraídos, não será utilizado nenhuma fonte de informações ou dados sobre os seus doadores, prevalecendo, assim, o anonimato."

Até o momento não foi relatada a ocorrência de riscos ou dificuldades éticas.

Nesta emenda, os pesquisadores acrescentaram o seguinte risco:

Os riscos referentes à radiografia intrabucal é a exposição dos participantes à radiação. Esse risco será minimizado pelo uso do avental de proteção de chumbo durante a realização do exame.

**Comentários e Considerações sobre a Pesquisa:**

Nesta emenda, solicita-se alteração da população do estudo e inclusão do seguinte grupo:

**Endereço:** Rua Padre Camargo, 285 - 1º andar

**Bairro:** Alto da Glória

**CEP:** 80.060-240

**UF:** PR

**Município:** CURITIBA

**Telefone:** (41)3360-7259

**E-mail:** cometica.saude@ufpr.br

UFPR - SETOR DE CIÊNCIAS  
DA SAÚDE DA UNIVERSIDADE  
FEDERAL DO PARANÁ -  
SCS/UFPR



Continuação do Parecer: 6.823.137

"crianças de 8 anos de idade assistidas na clínica de Odontopediatria da UFPR."  
Ao todo, pretende-se incluir mais 191 crianças da clínica de odontopediatria.

O recrutamento previsto para este grupo será o seguinte:

"No caso das crianças assistidas na clínica de Odontopediatria, serão fixados cartazes nas dependências da sala de espera convidando os responsáveis legais e suas crianças para participarem da pesquisa."

**Considerações sobre os Termos de apresentação obrigatória:**

Os termos foram apresentados.

**Recomendações:**

Não há.

**Conclusões ou Pendências e Lista de Inadequações:**

As solicitações desta emenda estão justificadas e podem ser aprovadas. O projeto apresenta relatórios parciais em dia.

**Considerações Finais a critério do CEP:**

01 - Solicitamos que sejam apresentados a este CEP, relatórios semestrais(a cada seis meses de seu parecer de aprovado) e final, sobre o andamento da pesquisa, bem como informações relativas às modificações do protocolo, cancelamento, encerramento e destino dos conhecimentos obtidos, através da Plataforma Brasil - no modo: NOTIFICAÇÃO. Para o próximo relatório, favor utilizar o modelo atualizado, (abril/22), de relatório parcial.

02 - Demais alterações e prorrogação de prazo devem ser enviadas no modo EMENDA. Lembrando que o cronograma de execução da pesquisa deve ser atualizado no sistema Plataforma Brasil antes de enviar solicitação de prorrogação de prazo. Emenda 2, ver modelo de carta em nossa página: [www.cometica.ufpr.br](http://www.cometica.ufpr.br) (obrigatório envio).

03 - Importante:(Caso se aplique): Pendências de Coparticipante devem ser respondidas pelo acesso do Pesquisador principal. Para projetos com coparticipante que também solicitam relatórios semestrais, estes relatórios devem ser enviados por Notificação, pelo login e senha

**Endereço:** Rua Padre Camargo, 285 - 1º andar

**Bairro:** Alto da Glória

**CEP:** 80.060-240

**UF:** PR

**Município:** CURITIBA

**Telefone:** (41)3360-7259

**E-mail:** [cometica.saude@ufpr.br](mailto:cometica.saude@ufpr.br)

**UFPR - SETOR DE CIÊNCIAS  
DA SAÚDE DA UNIVERSIDADE  
FEDERAL DO PARANÁ -  
SCS/UFPR**



Continuação do Parecer: 6.823.137

do pesquisador principal no CAAE correspondente a este coparticipante, após o envio do relatório à instituição proponente.

04 Inserir nos TCLE e TALE o número do CAAE e o número do parecer consubstanciado aprovado, para aplicação dos termos.

**Este parecer foi elaborado baseado nos documentos abaixo relacionados:**

| Tipo Documento                                            | Arquivo                                             | Postagem               | Autor                           | Situação |
|-----------------------------------------------------------|-----------------------------------------------------|------------------------|---------------------------------|----------|
| Informações Básicas do Projeto                            | PB_INFORMAÇÕES_BASICAS_2325765_E3.pdf               | 16/04/2024<br>16:15:04 |                                 | Aceito   |
| Outros                                                    | Declaracao_Compromisso_Equipe_Pesquisa.pdf          | 16/04/2024<br>16:13:03 | LUCIANA REICHERT ASSUNÇÃO ZANON | Aceito   |
| Outros                                                    | Carta_Pesquisador.pdf                               | 16/04/2024<br>10:26:04 | LUCIANA REICHERT ASSUNÇÃO ZANON | Aceito   |
| TCLE / Termos de Assentimento / Justificativa de Ausência | TCLE_ALTERADO_EMENDA_RESPONSAVEL_LEGAL_CLINICA.docx | 16/04/2024<br>10:25:45 | LUCIANA REICHERT ASSUNÇÃO ZANON | Aceito   |
| TCLE / Termos de Assentimento / Justificativa de Ausência | TCLE_ALTERADO_EMENDA_PAIS_CLINICA.docx              | 16/04/2024<br>10:25:32 | LUCIANA REICHERT ASSUNÇÃO ZANON | Aceito   |
| TCLE / Termos de Assentimento / Justificativa de Ausência | TALE_CLINICA.docx                                   | 16/04/2024<br>10:25:24 | LUCIANA REICHERT ASSUNÇÃO ZANON | Aceito   |
| Projeto Detalhado / Brochura Investigador                 | Projeto_Deep_Learning2024_emenda_clinica.docx       | 16/04/2024<br>10:25:10 | LUCIANA REICHERT ASSUNÇÃO ZANON | Aceito   |
| Outros                                                    | Declaracao_Servicos_envolvidos.pdf                  | 16/04/2024<br>10:24:10 | LUCIANA REICHERT ASSUNÇÃO ZANON | Aceito   |
| Outros                                                    | Carta_justificativa_emenda.pdf                      | 16/04/2024<br>10:23:20 | LUCIANA REICHERT ASSUNÇÃO ZANON | Aceito   |
| Outros                                                    | Carta_justificativa_emenda09_2021.docx              | 02/09/2021<br>17:08:54 | PAULA DRESCH PORTELLA           | Aceito   |
| Projeto Detalhado / Brochura Investigador                 | Projeto_DeepLearning_2021_2_emenda.doc              | 02/09/2021<br>17:08:05 | PAULA DRESCH PORTELLA           | Aceito   |

**Endereço:** Rua Padre Camargo, 285 - 1º andar

**Bairro:** Alto da Glória

**CEP:** 80.060-240

**UF:** PR

**Município:** CURITIBA

**Telefone:** (41)3360-7259

**E-mail:** cometica.saude@ufpr.br

**UFPR - SETOR DE CIÊNCIAS  
DA SAÚDE DA UNIVERSIDADE  
FEDERAL DO PARANÁ -  
SCS/UFPR**



Continuação do Parecer: 6.823.137

|                                                                                   |                                                 |                        |                          |        |
|-----------------------------------------------------------------------------------|-------------------------------------------------|------------------------|--------------------------|--------|
| Outros                                                                            | Carta_ao_CEP_pendencias.docx                    | 10/06/2021<br>14:49:58 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | Declaracaoconcordancia_UEPG.pdf                 | 07/06/2021<br>11:50:12 | PAULA DRESCH<br>PORTELLA | Aceito |
| Projeto Detalhado /<br>Brochura<br>Investigador                                   | Projeto_DeepLearning_2021_emenda.doc            | 03/05/2021<br>12:26:37 | PAULA DRESCH<br>PORTELLA | Aceito |
| Declaração de<br>Manuseio Material<br>Biológico /<br>Biorepositório /<br>Biobanco | Declaracao_BDHUFPR_CEP.pdf                      | 03/05/2021<br>12:22:27 | PAULA DRESCH<br>PORTELLA | Aceito |
| Declaração de<br>concordância                                                     | CONCORDANCIA_BDH_UFPR_PROFa<br>Luciana.pdf      | 03/05/2021<br>12:21:26 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | Carta_justificativa_emenda.docx                 | 03/05/2021<br>12:19:45 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | Carta_ao_CEP_pendencias.pdf                     | 13/11/2019<br>16:58:52 | PAULA DRESCH<br>PORTELLA | Aceito |
| TCLE / Termos de<br>Assentimento /<br>Justificativa de<br>Ausência                | TCLE_Corrigido.docx                             | 13/11/2019<br>16:55:50 | PAULA DRESCH<br>PORTELLA | Aceito |
| Projeto Detalhado /<br>Brochura<br>Investigador                                   | Projeto_DeepLearning_CORRIGIDO_13<br>_11_19.doc | 13/11/2019<br>16:55:31 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | ServicoOdontopediatria.pdf                      | 05/11/2019<br>00:53:43 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | ServicoInf.pdf                                  | 01/11/2019<br>16:54:26 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | SMS_declaracaodeciencia.pdf                     | 29/10/2019<br>10:30:05 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | SMS_ausenciadecustos.pdf                        | 24/10/2019<br>16:23:41 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | SMS_requirimento.pdf                            | 24/10/2019<br>16:22:54 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | cartaaocpcerto.pdf                              | 24/10/2019<br>16:22:19 | PAULA DRESCH<br>PORTELLA | Aceito |
| Outros                                                                            | analisedomerito_certo.pdf                       | 24/10/2019<br>16:22:06 | PAULA DRESCH<br>PORTELLA | Aceito |
| TCLE / Termos de<br>Assentimento /<br>Justificativa de<br>Ausência                | TALE.docx                                       | 24/10/2019<br>14:54:13 | PAULA DRESCH<br>PORTELLA | Aceito |
| TCLE / Termos de<br>Assentimento /<br>Justificativa de<br>Ausência                | TCLE_certo.docx                                 | 24/10/2019<br>14:54:03 | PAULA DRESCH<br>PORTELLA | Aceito |

**Endereço:** Rua Padre Camargo, 285 - 1º andar

**Bairro:** Alto da Glória

**UF:** PR

**Município:** CURITIBA

**Telefone:** (41)3360-7259

**CEP:** 80.060-240

**E-mail:** cometica.saude@ufpr.br

**UFPR - SETOR DE CIÊNCIAS  
DA SAÚDE DA UNIVERSIDADE  
FEDERAL DO PARANÁ -  
SCS/UFPR**



Continuação do Parecer: 6.823.137

|                                           |                                         |                        |                                       |        |
|-------------------------------------------|-----------------------------------------|------------------------|---------------------------------------|--------|
| Declaração de Pesquisadores               | Declaracaodecompromisso.pdf             | 11/10/2019<br>23:41:54 | PAULA DRESCH<br>PORTELLA              | Aceito |
| Projeto Detalhado / Brochura Investigador | Projeto_DeepLearning_Final_07_10_19.doc | 07/10/2019<br>16:05:02 | LUCIANA<br>REICHERT<br>ASSUNÇÃO ZANON | Aceito |
| Outros                                    | AutorizacaoSME.pdf                      | 06/10/2019<br>18:36:29 | PAULA DRESCH<br>PORTELLA              | Aceito |
| Outros                                    | extratoprojeto.pdf                      | 04/10/2019<br>15:32:10 | PAULA DRESCH<br>PORTELLA              | Aceito |
| Outros                                    | CheckList.pdf                           | 04/10/2019<br>15:29:42 | PAULA DRESCH<br>PORTELLA              | Aceito |
| Folha de Rosto                            | Folhaderosto.pdf                        | 04/10/2019<br>15:22:43 | PAULA DRESCH<br>PORTELLA              | Aceito |

**Situação do Parecer:**

Aprovado

**Necessita Apreciação da CONEP:**

Não

CURITIBA, 14 de Maio de 2024

---

**Assinado por:  
IDA CRISTINA GUBERT  
(Coordenador(a))**

**Endereço:** Rua Padre Camargo, 285 - 1º andar

**Bairro:** Alto da Glória

**UF:** PR

**Município:** CURITIBA

**CEP:** 80.060-240

**Telefone:** (41)3360-7259

**E-mail:** cometica.saude@ufpr.br

**ANEXO 2 – CRITÉRIO DO SISTEMA INTERNACIONAL DE DETECÇÃO E  
AVALIAÇÃO DE CÁRIE (ICDAS)**

| <b>Código da Lesão de cárie</b> |                                                                       |
|---------------------------------|-----------------------------------------------------------------------|
| <b>0</b>                        | <b>Não há evidência de cárie</b>                                      |
| <b>1</b>                        | <b>Mudança inicial visível no esmalte</b>                             |
| <b>2</b>                        | <b>Mudança nítida visível no esmalte</b>                              |
| <b>3</b>                        | <b>Descontinuidade do esmalte devido à cárie, sem dentina visível</b> |
| <b>4</b>                        | <b>Sombreamento da dentina subjacente</b>                             |
| <b>5</b>                        | <b>Cavidade nítida com dentina visível</b>                            |
| <b>6</b>                        | <b>Cavidade extensa nítida com dentina visível</b>                    |

Nota: Segundo ISMAIL, et al., 2007.

## ANEXO 3 – CRITÉRIO CLÍNICO PARA CLASSIFICAÇÃO DOS DEFEITOS DE DESENVOLVIMENTO DO ESMALTE (DDE)

| Código | DDE                                        | Características                                                                                                                                                                                        |
|--------|--------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 0      | Sem DDE                                    | Superfície do esmalte sem alteração por DDE                                                                                                                                                            |
| 1      | DDE, sem HMI/HSMD                          | DDEs variados como no índice DDE-Modificado                                                                                                                                                            |
| 11     | Opacidade difusa                           | Opacidade difusa, sem limite definido                                                                                                                                                                  |
| 12     | Hipoplasia                                 | hipoplasia, redução da espessura do esmalte com bordas definidas e lisas                                                                                                                               |
| 13     | Amelogênese imperfeita                     | AI, têm simetria, todos os dentes são afetados/ pode ter taurodontism/mordida aberta/Historia familiar                                                                                                 |
| 14     | Hipomineralização não HMI/HSMD             | opacidade demarcadas como HMI/HSMD em outros dentes não HMI/HSMD, relacionado a causa local como trauma                                                                                                |
| 2      | Opacidade demarcada HMI/HSMD               | Opacidade demarcada envolvendo 1 molar permanente/ 2 molar decíduo                                                                                                                                     |
| 21     | Branca/creme/                              | Opacidade demarcada de coloração creme/branca                                                                                                                                                          |
| 22     | Amarela/marrom                             | Opacidade demarcada de coloração amarela/ marrom                                                                                                                                                       |
| 3      | Fratura pós-irruptiva/ Perda pós-irruptiva | Perda do esmalte pós-irruptiva, pode ter opacidade demarcada ao redor. Normalmente em pontas de cúspide ou superfície lisa. As bordas são irregulares e normalmente com opacidade demarcada ao redor . |
| 4      | Restauração atípica                        | Restauração com desenho atípico em relação a lesão cariosa                                                                                                                                             |
| 5      | Cavidade Atípica                           | Cavidade com desenho atípico em relação a lesão cariosa                                                                                                                                                |
| 6      | Perdido por HMI/HSMD                       | Suspeita da exodontia por HMI/HSMD quando os outros dentes apresentam algum sinal de HMI/HSMD                                                                                                          |
| 7      | Não registrado                             | dente com extensa perda da coroa, em que a causa da perda não pode ser determinada                                                                                                                     |
| A      | Não registrado                             | Menos de 1/3 de coroa visível                                                                                                                                                                          |

- DDE <1 mm é considerado sadio
- HMI: têm que ter em primeiro molar permanente
- HSMD: têm que ter em segundos molares decíduos

| Código da extensão | Extensão na superfície dentária                       |
|--------------------|-------------------------------------------------------|
| I                  | DDEs que envolve menos de 1/3 da superfície dentária  |
| II                 | DDEs que envolvem de 1/3 a 2/3 da superfície dentária |
| III                | DDEs que envolvem >2/3 da superfície dentária         |

- Na presença de vários DDE em uma superfície, soma-se a extensão de todos;

Nota: Segundo GHANIM, et al., 2015.

## **ANEXO 4 – CLINICAL ORAL INVESTIGATIONS – SUBMISSION GUIDELINES**

### **Instructions for Authors**

#### **Types of papers**

Papers may be submitted for the following sections:

- Research Article
- Reviews
- Brief Report – with up to 2000 words and up to two figures and/or tables
- Correspondence (Discussion paper)
- Debate (Letter to the Editor)
- Perspective (by Editor invitation only)

Perspective articles are focused articles on topics of interest to a broad audience, but are written from a personal viewpoint. They are intended to provide a forum to be more speculative than Reviews, but should remain balanced and are intended to cover timely and relevant topics. These articles are peer reviewed.

Limited to 1,500-3,000 words (excluding abstract, references and figure legends); Unstructured abstract 200 words; 4 tables/figures; 60 references

It is the general policy of this journal not to accept case reports and pilot studies.

#### **Editorial Procedure**

Clinical Oral Investigations operates a single-blind peer-review system, where the reviewers are aware of the names and affiliations of the authors, but the reviewer reports provided to authors are anonymous.

Submitted manuscripts will generally be reviewed by two or more experts who will be asked to evaluate whether the manuscript is scientifically sound and coherent, whether it duplicates already published work, and whether or not the manuscript is sufficiently clear for publication. The Editors will reach a decision based on these reports and, where necessary, they will consult with members of the Editorial Board.

#### **Summary of the editorial process**

- The author submits a manuscript and the Editorial Office performs an initial quality check on the manuscript to ensure that the paper is formatted correctly
- The manuscript receives a tracking number and Manuscripts are assigned to an Editor-in-Chief or a Section Editor for an initial editorial assessment. If the decision is not to send the manuscript for review, the Editor contacts the author with the decision.
- If the Editor decides the paper is within the Journal's remit, peer reviewers are selected and assigned. This can take some time dependent on the responsiveness and availability of the reviewers selected.
- Reviewers are given 14 days from acceptance to submit their reports. Once the required reports are submitted, the Associate Editor will give a recommendation or the Editor-in-Chief makes a final decision based on the comments received. The final decision is the sole responsibility of the Editors-in-Chief.

### **Manuscript Submission**

Submission of a manuscript implies: that the work described has not been published before; that it is not under consideration for publication anywhere else; that its publication has been approved by all co-authors, if any, as well as by the responsible authorities – tacitly or explicitly – at the institute where the work has been carried out. The publisher will not be held legally responsible should there be any claims for compensation.

### **Permissions**

Authors wishing to include figures, tables, or text passages that have already been published elsewhere are required to obtain permission from the copyright owner(s) for both the print and online format and to include evidence that such permission has been granted when submitting their papers. Any material received without such evidence will be assumed to originate from the authors.

### **Online Submission**

Please follow the hyperlink “Submit manuscript” and upload all of your manuscript files following the instructions given on the screen.

## Source Files

Please ensure you provide all relevant editable source files at every submission and revision. Failing to submit a complete set of editable source files will result in your article not being considered for review. For your manuscript text please always submit in common word processing formats such as .docx or LaTeX.

## Submitting Declarations

Please note that Author Contribution information and Competing Interest information must be provided at submission via the submission interface. Only the information submitted via the interface will be used in the final published version. Please make sure that if you are an editorial board member and also a listed author that you also declare this information in the Competing Interest section of the interface.

Please see the relevant sections in the submission guidelines for further information on these statements as well as possible other mandatory statements.

## Further Useful Information

The Springer Author Academy is a set of comprehensive online training pages mainly geared towards first-time authors. At this point, more than 50 pages offer advice to authors on how to write and publish a journal article.

## Title Page

The title page should include:

- The name(s) of the author(s)
- A concise and informative title
- The affiliation(s) and address(es) of the author(s)
- The e-mail address, telephone and fax numbers of the corresponding author

## Abstract

Please provide a structured abstract of 150 to 250 words which should be divided into the following sections:

- Objectives (stating the main purposes and research question)

- Materials and Methods
- Results
- Conclusions
- Clinical Relevance

These headings must appear in the abstract.

## **Keywords**

Please provide 4 to 6 keywords which can be used for indexing purposes.

## **Text**

### **Text Formatting**

Manuscripts should be submitted in Word.

- Use a normal, plain font (e.g., 10-point Times Roman) for text.
- Use italics for emphasis.
- Use the automatic page numbering function to number the pages.
- Do not use field functions.
- Use tab stops or other commands for indents, not the space bar.
- Use the table function, not spreadsheets, to make tables.
- Use the equation editor or MathType for equations.
- Save your file in docx format (Word 2007 or higher) or doc format (older Word versions).

Manuscripts with mathematical content can also be submitted in LaTeX. We recommend using [Springer Nature's LaTeX template](#).

## **Headings**

Please use no more than three levels of displayed headings.

## **Abbreviations**

Abbreviations should be defined at first mention and used consistently thereafter.

## **Footnotes**

Footnotes can be used to give additional information, which may include the citation of a reference included in the reference list. They should not consist solely of a reference citation, and they should never include the bibliographic details of a reference. They should also not contain any figures or tables.

Footnotes to the text are numbered consecutively; those to tables should be indicated by superscript lower-case letters (or asterisks for significance values and other statistical data). Footnotes to the title or the authors of the article are not given reference symbols.

Always use footnotes instead of endnotes.

## **Acknowledgments**

Acknowledgments of people, grants, funds, etc. should be placed in a separate section on the title page. The names of funding organizations should be written in full.

## **References**

### **Citation**

Reference citations in the text should be identified by numbers in square brackets. Some examples:

1. Negotiation research spans many disciplines [3].
2. This result was later contradicted by Becker and Seligman [5].
3. This effect has been widely studied [1-3, 7].

### **Reference list**

The list of references should only include works that are cited in the text and that have been published or accepted for publication. Personal communications and unpublished works should only be mentioned in the text.

The entries in the list should be numbered consecutively.

If available, please always include DOIs as full DOI links in your reference list (e.g. “<https://doi.org/abc>”).

- Journal article

Gamelin FX, Baquet G, Berthoin S, Thevenet D, Nourry C, Nottin S, Bosquet L (2009) Effect of high intensity intermittent training on heart rate variability in prepubescent children. Eur J Appl Physiol 105:731-738. <https://doi.org/10.1007/s00421-008-0955-8>

Ideally, the names of all authors should be provided, but the usage of “et al” in long author lists will also be accepted:

Smith J, Jones M Jr, Houghton L et al (1999) Future of health insurance. N Engl J Med 341:325–329

- Article by DOI

Slifka MK, Whitton JL (2000) Clinical implications of dysregulated cytokine production. *J Mol Med*. <https://doi.org/10.1007/s001090000086>

- Book

South J, Blass B (2001) *The future of modern genomics*. Blackwell, London

- Book chapter

Brown B, Aaron M (2001) The politics of nature. In: Smith J (ed) *The rise of modern genomics*, 3rd edn. Wiley, New York, pp 230-257

- Online document

Cartwright J (2007) Big stars have weather too. IOP Publishing PhysicsWeb. <http://physicsweb.org/articles/news/11/6/16/1>. Accessed 26 June 2007

- Dissertation

Trent JW (1975) *Experimental acute renal failure*. Dissertation, University of California

Always use the standard abbreviation of a journal's name according to the ISSN List of Title Word Abbreviations, see

[ISSN.org LTWA](http://www.issn.org/LTWA)

If you are unsure, please use the full journal title.

Authors preparing their manuscript in LaTeX can use the bibliography style file sn-basic.bst which is included in the [Springer Nature Article Template](#).

## Tables

- All tables are to be numbered using Arabic numerals.
- Tables should always be cited in text in consecutive numerical order.
- For each table, please supply a table caption (title) explaining the components of the table.
- Identify any previously published material by giving the original source in the form of a reference at the end of the table caption.
- Footnotes to tables should be indicated by superscript lower-case letters (or asterisks for significance values and other statistical data) and included beneath the table body.

## Color Art

- Color art is free of charge for online publication.
- If black and white will be shown in the print version, make sure that the main information will still be visible. Many colors are not distinguishable from one

another when converted to black and white. A simple way to check this is to make a xerographic copy to see if the necessary distinctions between the different colors are still apparent.

- If the figures will be printed in black and white, do not refer to color in the captions.
- Color illustrations should be submitted as RGB (8 bits per channel).

### **Figure Lettering**

- To add lettering, it is best to use Helvetica or Arial (sans serif fonts).
- Keep lettering consistently sized throughout your final-sized artwork, usually about 2–3 mm (8–12 pt).
- Variance of type size within an illustration should be minimal, e.g., do not use 8-pt type on an axis and 20-pt type for the axis label.
- Avoid effects such as shading, outline letters, etc.
- Do not include titles or captions within your illustrations.

### **Figure Numbering**

- All figures are to be numbered using Arabic numerals.
- Figures should always be cited in text in consecutive numerical order.
- Figure parts should be denoted by lowercase letters (a, b, c, etc.).
- If an appendix appears in your article and it contains one or more figures, continue the consecutive numbering of the main text. Do not number the appendix figures, "A1, A2, A3, etc." Figures in online appendices [Supplementary Information (SI)] should, however, be numbered separately.

### **Figure Captions**

- Each figure should have a concise caption describing accurately what the figure depicts. Include the captions in the text file of the manuscript, not in the figure file.
- Figure captions begin with the term Fig. in bold type, followed by the figure number, also in bold type.
- No punctuation is to be included after the number, nor is any punctuation to be placed at the end of the caption.
- Identify all elements found in the figure in the figure caption; and use boxes, circles, etc., as coordinate points in graphs.

- Identify previously published material by giving the original source in the form of a reference citation at the end of the figure caption.

### **Figure Placement and Size**

- Figures should be submitted within the body of the text. Only if the file size of the manuscript causes problems in uploading it, the large figures should be submitted separately from the text.
- When preparing your figures, size figures to fit in the column width.
- For large-sized journals the figures should be 84 mm (for double-column text areas), or 174 mm (for single-column text areas) wide and not higher than 234 mm.
- For small-sized journals, the figures should be 119 mm wide and not higher than 195 mm.

### **Permissions**

If you include figures that have already been published elsewhere, you must obtain permission from the copyright owner(s) for both the print and online format. Please be aware that some publishers do not grant electronic rights for free and that Springer will not be able to refund any costs that may have occurred to receive these permissions. In such cases, material from other sources should be used.

### **Accessibility**

In order to give people of all abilities and disabilities access to the content of your figures, please make sure that

- All figures have descriptive captions (blind users could then use a text-to-speech software or a text-to-Braille hardware)
- Patterns are used instead of or in addition to colors for conveying information (colorblind users would then be able to distinguish the visual elements)
- Any figure lettering has a contrast ratio of at least 4.5:1

### **Supplementary Information (SI)**

Springer accepts electronic multimedia files (animations, movies, audio, etc.) and other supplementary files to be published online along with an article or a book chapter. This feature can add dimension to the author's article, as certain information cannot be printed or is more convenient in electronic form.

Before submitting research datasets as Supplementary Information, authors should read the journal's Research data policy. We encourage research data to be archived in data repositories wherever possible.

### **Submission**

- Supply all supplementary material in standard file formats.
- Please include in each file the following information: article title, journal name, author names; affiliation and e-mail address of the corresponding author.
- To accommodate user downloads, please keep in mind that larger-sized files may require very long download times and that some users may experience other problems during downloading.

### **Audio, Video, and Animations**

- Aspect ratio: 16:9 or 4:3
- Maximum file size: 2 GB
- Minimum video duration: 1 sec
- Supported file formats: avi, wmv, mp4, mov, m2p, mp2, mpg, mpeg, flv, mxf, mts, m4v, 3gp

### **Text and Presentations**

- Submit your material in PDF format; .doc or .ppt files are not suitable for long-term viability.
- A collection of figures may also be combined in a PDF file.

### **Spreadsheets**

- Spreadsheets should be submitted as .csv or .xlsx files (MS Excel).

### **Specialized Formats**

- Specialized format such as .pdb (chemical), .wrl (VRML), .nb (Mathematica notebook), and .tex can also be supplied.

### **Collecting Multiple Files**

- It is possible to collect multiple files in a .zip or .gz file.

### **Numbering**

- If supplying any supplementary material, the text must make specific mention of the material as a citation, similar to that of figures and tables.
- Refer to the supplementary files as "Online Resource", e.g., "... as shown in the animation (Online Resource 3)", "... additional data are given in Online Resource 4".

- Name the files consecutively, e.g. “ESM\_3.mpg”, “ESM\_4.pdf”.

### **Captions**

- For each supplementary material, please supply a concise caption describing the content of the file.

### **Processing of supplementary files**

- Supplementary Information (SI) will be published as received from the author without any conversion, editing, or reformatting.

### **Accessibility**

In order to give people of all abilities and disabilities access to the content of your supplementary files, please make sure that

- The manuscript contains a descriptive caption for each supplementary material
- Video files do not contain anything that flashes more than three times per second (so that users prone to seizures caused by such effects are not put at risk)