

**UNIVERSIDADE DE BRASÍLIA**  
**Faculdade de Ciências de Saúde**  
**Programa de Pós-Graduação em Odontologia**



Dissertação de Mestrado

**Uso da rede neural *Transformer* em diagnóstico por imagem na Odontologia:  
uma Revisão de Escopo**

**Mayra Cristina Ribeiro de Lima**

Brasília-DF,

2024

**Mayra Cristina Ribeiro de Lima**

**Uso da rede neural *Transformer* em diagnóstico por imagem na Odontologia:  
uma Revisão de Escopo**

Dissertação apresentada ao Programa de Pós-Graduação em Odontologia da Faculdade de Ciências da Saúde da Universidade de Brasília, como requisito parcial para obtenção do título de Mestre em Odontologia.

Orientador: Prof. Dr. André Ferreira Leite

Brasília, 2024

**Mayra Cristina Ribeiro de Lima**

**Uso da rede neural *Transformer* em diagnóstico por imagem na Odontologia:  
uma Revisão de Escopo**

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre em Odontologia, pelo Programa de Pós-Graduação em Odontologia da Faculdade de Ciências da Saúde da Universidade de Brasília.

Data da defesa: 29/05/2024

Banca examinadora:

---

Prof. Dr. André Ferreira Leite (Orientador)

---

Profa. Dra. Fabiana Tolentino de Almeida

---

Professora Dra. Cristine Miron Stefani

Brasília, 2024

*Dedico este trabalho a Deus, que é minha força todos os dias e que me trouxe até aqui. Dedico também aos meus avós, que já estão com o Pai e que certamente estão felizes com a conclusão dessa etapa da minha vida.*

## AGRADECIMENTOS

Ao meu orientador **Prof. Dr. André Ferreira Leite**, por ter sido um pai na Radiologia Odontológica para mim. Todo respeito e admiração a ele. A **Profa. Dra. Cristine Miron Stefani**, por ter aceitado embarcar nesse desafio comigo e por ter sido essencial na construção desse trabalho, sendo sempre solícita e contribuindo de forma brilhante com seu conhecimento.

A **Profa. Dra. Nilce Santos de Melo** por ter acreditado em mim e não me deixado desistir. Ao **Prof. Dr. Adriano de Almeida de Lima** por ter participado de forma tão especial da construção desse trabalho.

Ao **Prof. Dr. Ruben Pauwels**, que aceitou prontamente participar desse estudo.

À **Profa. Dra. Cristine Miron Stefani**, por aceitar meu convite para mais um trabalho científico, agora como banca examinadora, mesmo diante de tantas demandas acadêmicas.

À minha família, em especial aos meus pais, **Reinaldir Xavier de Lima** e **Lúcias Fátima Ribeiro de Lima**, que sempre me alicerçaram em oração e que sempre patrocinaram os meus sonhos com amor. Aos meus irmãos, **Bruno Henrique Ribeiro de Lima**, **Tiago Henrique Ribeiro de Lima** e **Igor Henrique Ribeiro de Lima**, que foram, juntamente com meus pais, minha base durante todo o meu processo de formação até aqui, me entregando todo suporte necessário para viver este momento. Aos meus primos(as) e tios(as), que me olharam com carinho e oraram por mim. Ao meu sobrinho e amor da minha vida, **Heitor Neiva de Lima**, que é a quem sempre buscarei dar exemplo de que a Educação salva e abre portas.

Ao meu namorado, **Gustavo Henrique Vanuncio da Silva**, que aguentou todos os meus momentos de estresse, medo e ansiedade durante esse desafio. A ele todo meu carinho, respeito e amor.

Aos meus amigos, os quais não citarei nomes para não ser injusta com alguém. Mas a eles minha gratidão por torcerem e acreditarem em mim. Obrigada por acompanharem cada passo dado até aqui e por não me deixarem desistir.

Aos meus colegas de mestrado, em especial ao **Josué Miguel**, por compartilhar comigo todas as experiências ao longo dessa fase, desde o processo seletivo, e por ter me apoiado e ajudado sempre.

À **Universidade de Brasília (UnB)** por ter me aberto as portas para realizar o meu maior sonho até aqui.

## RESUMO

**Introdução:** As ferramentas de inteligência artificial (IA) são utilizadas de forma crescente na área da odontologia, com potencial de revolucionar a prática clínica. Atualmente, as redes neurais convolucionais (CNNs) são muito utilizadas como algoritmos de visão computacional para detecção e classificação de doenças em imagens como a tomografia computadorizada e a radiografia panorâmica. Também têm sido aplicadas para segmentação de estruturas nestas imagens e em modelos preditivos. No entanto, mais recentemente as redes *transformers*, muito usadas para processamento natural de linguagem, passaram a ser utilizadas também para tarefas em imagens, com potencial de performance superior às CNNs. **Objetivo:** Esta revisão de escopo tem como objetivo avaliar a aplicação da Rede neural *Transformer* para diagnóstico de alterações dentárias e na região do complexo maxilofacial em exames de imagem mais usados na odontologia. **Metodologia:** Foi realizada uma busca nas bases de dados LILACS, Embase, PubMed/MEDLINE, SCOPUS, *Web of Science* e *IEEE Xplore*. Também foi realizada pesquisa adicional na literatura cinzenta, incluindo *Google Scholar* e *Proquest Dissertation & These*. Os termos de pesquisa incluíram termos livres, descritores MeSH, além de termos controlados disponíveis nos Descritores em Ciências da Saúde (DeCS). Para seleção e administração das referências foram utilizados os aplicativos Mendeley e Rayyan. Os critérios de inclusão foram: estudos que realizaram exames de pacientes com alterações dentárias e na região do complexo maxilomandibular, que usaram Rede Neural *Transformer* para diagnóstico e que tratavam de diagnóstico por imagem em Odontologia. Ensaio clínico, estudos observacionais e Revisões sistemáticas foram elegíveis para o estudo. **Resultados:** Foram encontrados no total 5.182 estudos, sendo incluídos 11 estudos ao final. Desses 11 artigos analisados, 8 empregaram a arquitetura *Transformer* em tarefas de segmentação. O padrão de referência incluiu avaliação de especialistas por meio da anotação manual. O número total do conjunto de dados foi de 39.221, não sendo possível quantificar o total de dados utilizados para teste, treinamento e validação pela falta de informação em alguns estudos. Os estudos confirmaram, por meio dos resultados das métricas utilizadas, que o uso da rede neural aqui discutida foi favorável em suas diferentes aplicações. **Conclusão:** O uso da rede neural *Transformer* representa uma ferramenta potencial com excelentes resultados para aplicação em diagnóstico por imagem em odontologia. Os dados obtidos nesse estudo indicam que os modelos baseados em *Transformer* frequentemente se beneficiam da combinação com outras arquiteturas, como as Redes Neurais Convolucionais, resultando em maior sucesso nos resultados. É fundamental mencionar que, embora haja espaço para melhorias, esta tecnologia já representa um significativo avanço da IA na odontologia.

**Palavras-chave:** Revisão de escopo; Rede neural *Transformer*; Diagnóstico por imagem; Odontologia.

## ABSTRACT

**Introduction:** Artificial intelligence (AI) tools are increasingly being used in dentistry, with the potential to revolutionize clinical practice. Currently, convolutional neural networks (CNNs) are widely used as computer vision algorithms for detecting and classifying diseases in images, such as computed tomography and panoramic radiography. They have also been applied to segment structures in these images and in predictive models. Recently, however, transformer networks, which are widely used in natural language processing, have also been applied to image analysis tasks, with the potential to outperform CNNs. **Objective:** The aim of this scoping review is to assess the application of the Transformer neural network for diagnosing dental and maxillofacial abnormalities in the most used dental imaging exams. **Methodology:** A search was conducted in the LILACS, Embase, PubMed/MEDLINE, SCOPUS, Web of Science, and IEEE Xplore databases. Additional research was also conducted in the grey literature, including Google Scholar and Proquest Dissertation & These. The search terms included free terms, (MeSH) descriptors, as well as controlled terms available in the Health Sciences Descriptors (DeCS). The Mendeley and Rayyan applications were used to select and manage the references. The Mendeley and Rayyan applications were used to select and manage the references. The inclusion criteria were: examinations of patients with hard tissue alterations in the jaws and face, studies that used Neural Network Transformer for Diagnosis, and studies that dealt with diagnostic imaging in Dentistry. Clinical trials, observational studies, and systematic reviews were eligible for the study. **Results:** A total of 5,182 studies were found, of which 11 studies were included at the end. Of these 11 articles analyzed, 8 employed the Transformer architecture in segmentation tasks. The reference standard included expert evaluation through manual annotation. The total number of the dataset was 39,221, and it was not possible to quantify the total data used for testing, training and validation due to the lack of information in some studies. The studies confirmed, through the results of the metrics used, that the use of the neural network discussed here was favorable in its different applications. **Conclusion:** The use of the Transformer neural network represents a potential tool with excellent results for application in diagnostic imaging in dentistry. The data obtained in this study indicate that Transformer-based models often benefit from combining with other architectures, such as Convolutional Neural Networks, resulting in greater success in the results. It is essential to mention that, although there is room for improvement, this technology already represents a significant advancement of AI in dentistry.

**Keywords:** Scoping review; Neural transformer network; Diagnostic imaging; Dentistry.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Subconjuntos dentro da Inteligência artificial	12
Figura 2 - Fluxograma da estratégia de busca e seleção dos estudos	22
Figura 3 - Número de estudos selecionados de acordo com os países de origem	22
Figura 4 - Número de estudos selecionados de acordo com os exames utilizados	23
Figura 5 - Arquiteturas encontradas nos estudos selecionados	23



## LISTA DE ABREVIATURAS

ACC	Acurácia
A. L	André Leite
ASSD	<i>Average Symmetric Surface Distance</i> (Distância média da superfície simétrica)
AUC	<i>Area Under the Curve</i> (Área sob a curva)
BW	<i>Bitewing</i>
CNN	<i>Convolutional neural network</i> (Rede neural convolucional)
DeCS	Descritores em Ciências da Saúde
DSC	<i>Dice Similarity Coefficient</i> (Coeficiente de similaridade de dados)
FN	<i>False Negative</i> (falso negativo)
FP	<i>False Positive</i> (falso positivo)
HD95	<i>95% Hausdorff Distance</i> (Distância Hausdorff 95%)
IA	Inteligência Artificial
IoU	<i>Intersection over Union</i> (Intersecção sobre União)
JB1	<i>Joanna Briggs Institute</i> (Instituto Joanna Briggs)
JI	<i>Jaccard Index</i> (Índice Jaccard)
J.M	Josué Miguel

MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
MSE	<i>Mean Square Error</i> (Erro quadrático médio)
MeSH	<i>Medical Subject Headings</i>
M.L	Mayra Lima
OSF	<i>Open Science Framework</i>
PBL	<i>Periodontal Bone Loss</i> (Perda Óssea Periodontal)
PLN	Processamento de Linguagem Natural
RP	Radiografia Panorâmica
RPA	Radiografia Periapical
TAB	<i>Teeth Attention Block</i> (Bloco de atenção aos dentes)
TN	<i>True Negative</i> (verdadeiro negativo)
TP	<i>True Positive</i> (verdadeiro positivo)
TCFC	Tomografia Computadorizada de Feixe Cônico

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>12</b>
1.1	OBJETIVOS	15
<b>2</b>	<b>METODOLOGIA</b>	<b>16</b>
2.1	PROTOCOLO E REGISTRO	16
2.2	DESENHO DO ESTUDO E CRITÉRIO DE ELEGIBILIDADE	16
2.3	ESTRATÉGIA DE BUSCA	17
2.4	SELEÇÃO DOS ESTUDOS	19
2.5	COLETA DE DADOS	20
<b>3</b>	<b>RESULTADOS</b>	<b>21</b>
3.1	SELEÇÃO DE ESTUDOS	21
3.2	CARACTERÍSTICA DOS ESTUDOS	22
3.3	SÍNTESE DOS RESULTADOS	36
<b>4</b>	<b>DISCUSSÃO</b>	<b>37</b>
<b>5</b>	<b>LIMITAÇÕES</b>	<b>41</b>
<b>6</b>	<b>FUTUROS ESTUDOS</b>	<b>42</b>
<b>7</b>	<b>CONCLUSÃO</b>	<b>43</b>
	<b>REFERÊNCIAS</b>	<b>44</b>
	<b>PRESS RELEASE</b>	<b>48</b>
	<b>APÊNDICES</b>	<b>49</b>
	<b>ANEXO</b>	<b>57</b>

## 1 INTRODUÇÃO

O crescente acúmulo de informações, dados e conhecimento promoveu o desenvolvimento de novas tecnologias capazes de lidar com tarefas complexas em diversos campos, inclusive na área da saúde. Dentro dessa perspectiva, técnicas computacionais como as ferramentas de Inteligência Artificial (IA) oferecem novas oportunidades para diagnosticar, categorizar e prever doenças bucais, planejar tratamentos e avaliar resultados, minimizando o erro humano [1].

A inteligência artificial (IA) é a capacidade de máquinas simularem a inteligência humana para realizar tarefas específicas. O aprendizado de máquina (ML), um subcampo da IA, utiliza algoritmos para identificar padrões estatísticos nos dados e realizar previsões. As redes neurais, modelos matemáticos não lineares, representam a abordagem de ML mais utilizada em visão computacional, sendo formadas por neurônios artificiais organizados em camadas. As redes neurais profundas, ou "aprendizagem profunda," são capazes de identificar hierarquias de padrões complexos, detectando bordas, formas e padrões em imagens [2].

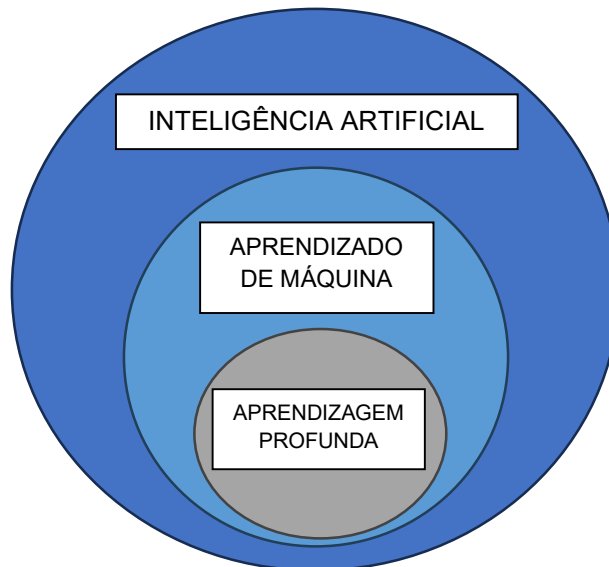


Figura 1 – Subconjuntos dentro da Inteligência artificial. Fonte: do próprio autor.

O uso das imagens digitais na prática clínica, como as radiografias panorâmicas, aprimorou muito o desenvolvimento da IA na Radiologia Odontológica. Isto ocorreu porque as imagens radiográficas produzidas pela atenuação da radiação X pelos tecidos, como a radiografia panorâmica e a tomografia computadorizada de

feixe cônico (TCFC), são codificadas digitalmente e podem ser prontamente traduzidas em linguagem computacional [3]. Estes exames oferecem informações dentárias e da região maxilofacial. Assim, desempenham um papel fundamental na formulação de diagnósticos precisos, sendo determinantes na seleção do tratamento mais adequado e no prognóstico do paciente.

As redes neurais buscam melhorar ainda mais o processo diagnóstico por meio de tarefas como detecção, classificação e segmentação nas imagens combinado com a supervisão do clínico. Estas tarefas podem ser demoradas na prática clínica, sujeitas a erros e influenciadas pela variação tanto do observador quanto entre observadores. Neste sentido, a automação de processos baseada em modelos de IA pode auxiliar na redução destes erros, aumentando a reprodutibilidade, a acurácia na interpretação dos exames, melhorando a qualidade do tratamento e gerando redução de custos e de tempo na prática odontológica. Atualmente, as abordagens de IA em Radiologia Odontológica são predominantemente baseadas em redes neurais convolucionais (CNNs), com aplicações na detecção de cárie, osteoporose, doenças periapicais e periodontais, aplicações ortodônticas, detecção de patologias e traumas na região do complexo maxilofacial [4, 5].

As CNNs capturam relações entre pixels adjacentes em imagens, mantendo algum grau de invariância à rotação e translação. Essas características fazem com que as CNNs sejam úteis para tarefas como classificação, segmentação e detecção de objetos. Em 2017, a estrutura das redes *Transformer*, que assim como as CNNs, está inserido dentro do aprendizado profundo (imagem 1), obteve sucesso no processamento de linguagem natural (PLN) [6]. Ela se tornou popular com o a introdução do ChatGPT (*Generative Pre-Trained Transformer*) em 2022 [7], que utiliza um mecanismo de autoatenção para identificar relações entre quaisquer pontos do texto na sequência de entrada. No *Vision Transformer (ViT)*, essa abordagem foi adaptada para visão computacional. As imagens são divididas em pequenos blocos (*patches*), considerados como *tokens* que formam a sequência de entrada. Portanto, estas redes exploram relações em toda a imagem, podendo ser utilizada para tarefas diagnósticas em radiologia [8].

Embora as CNNs historicamente sejam consideradas como a principal arquitetura para modelos de IA de visão computacional, as redes *transformers* podem superar as CNNs para execução de tarefas como segmentação de imagens, detecção e classificação de alterações em imagens médicas. Isto se deve à capacidade de

capturar dependências de longo alcance nos *pixels* das imagens, por não serem restritas à estrutura fixa das CNNs, com maior capacidade de flexibilidade e generalização. No entanto, dependem de maior quantidade de dados e poder computacional para treinamento efetivo [9-11]. Alguns autores já consideram estes algoritmos *transformers* como o estado da arte para análise de imagens médicas [11].

Tendo em vista as vantagens e desvantagens supracitadas das redes *transformers* em relação às CNNs para execução de tarefas em imagens médicas, torna-se necessário investigar o potencial de uso das redes *transformers* em radiologia odontológica.

## 1.1 OBJETIVOS

Esta revisão de escopo tem como objetivo geral avaliar a aplicação das redes neurais Transformer no diagnóstico por imagem de alterações dentárias e na região maxilofacial, por meio de uma análise dos estudos disponíveis na literatura.

## 2 METODOLOGIA

Esta revisão de escopo foi realizada de acordo com *Preferred Reporting Items for Systematic Reviews and Meta-Analyses extension for Scoping Reviews (PRISMA ScR): Checklist and Explanation* [12], detalhada no Anexo 1.

### 2.1 PROTOCOLO E REGISTRO

O protocolo foi adaptado com base nos parâmetros do *Preferred Reporting Items for Systematic Reviews and Meta-Analyses Protocols* (PRISMA-P) [13] e nas orientações do manual do *Joanna Briggs Institute* (JBI) [14]. Foi registrado no *Open Science Framework* (OSF) [15] no dia 20 de novembro de 2023 (<https://osf.io/qmds3/>).

### 2.2 DESENHO DO ESTUDO E CRITÉRIO DE ELEGIBILIDADE

O objetivo desta revisão de escopo foi responder à seguinte pergunta focada “Quais são as possíveis aplicações da rede neural *Transformer* para diagnóstico por imagem de alterações dentárias e da região maxilofacial?”

Os critérios de inclusão foram definidos pela estratégia PCC – em que a população (P) incluiu pessoas com alterações dentárias e na região maxilofacial; Conceito (C): Rede Neural *Transformer* para Diagnóstico; Contexto (C): Diagnóstico por imagem em Odontologia.

Ensaio clínico (randomizados ou não), estudos observacionais e Revisões sistemáticas foram elegíveis para o estudo.

Os critérios de exclusão foram: 1) estudos *ex vivo*; 2) estudos que utilizam outros tipos de redes neurais que não o *Transformer*; 3) diagnóstico por imagem fora da área da odontologia; 4) utilização de exames para acompanhamento e não para diagnóstico; 5) estudos não humanos, capítulos de livros, pareceres, cartas e resumos de conferências.



## 2.3 ESTRATÉGIA DE BUSCA

Foram desenvolvidas estratégias de buscas específicas para as bases: LILACS, Embase, PubMed/MEDLINE, SCOPUS, *Web of Science*, e *IEEE Xplore*. Foi realizada pesquisa adicional na literatura cinzenta, incluindo *Google Scholar* e *Proquest Dissertation & These*.

Os termos de pesquisa incluíram termos livres, descritores do *Medical Subject Headings* (MeSH), além de termos controlados disponíveis nos Descritores em Ciências da Saúde (DeCS). O apêndice 1 resume a estratégia de busca utilizada para cada base de dados.

Quadro 1 - Estratégia de busca PubMed

<b>PubMed</b>	<pre>(((("dental health services"[MeSH Terms] OR ("dental"[All Fields] AND "health"[All Fields] AND "services"[All Fields]) OR "dental health services"[All Fields] OR "dental"[All Fields] OR "dentally"[All Fields] OR "dentals"[All Fields]) OR ("dentistry"[MeSH Terms] OR "dentistry"[All Fields]) OR ("neck"[MeSH Terms] OR "neck"[All Fields]) OR ("head"[MeSH Terms] OR "head"[All Fields]) OR "buccal"[All Fields] OR "buccally"[All Fields] OR ("mouth"[MeSH Terms] OR "mouth"[All Fields] OR "oral"[All Fields]) OR ("jaw"[MeSH Terms] OR "jaw"[All Fields] OR "jaws"[All Fields]) OR ("maxilla"[MeSH Terms] OR "maxilla"[All Fields] OR "maxillae"[All Fields] OR "maxillas"[All Fields]) OR ("mandible"[MeSH Terms] OR "mandible"[All Fields] OR "mandibles"[All Fields]) OR ("tooth"[MeSH Terms] OR "teeths"[All Fields] OR "tooth"[All Fields] OR "teeth"[All Fields] OR "tooths"[All Fields]) OR ("intraoral"[All Fields] OR "intraorally"[All Fields]) OR ("face"[MeSH Terms] OR "face"[All Fields] OR "facial"[All Fields] OR "facials"[All Fields]) OR ("intraoral"[All Fields] OR "intraorally"[All Fields] OR "intra-oral"[All Fields] OR "intra oral"[All Fields]) OR ("periapical"[All Fields] OR "periapically"[All Fields] OR "periapicals"[All Fields]) OR ("extraoral"[All Fields] OR "extraorally"[All Fields] OR "extra-oral"[All Fields] OR "extra oral"[All Fields]) OR ("radiography, bitewing"[MeSH Terms] OR ("radiography"[All Fields] AND "bitewing"[All Fields]) OR "bitewing radiography"[All Fields]) OR ("radiography, dental, digital"[MeSH Terms] OR ("radiography, panoramic"[MeSH Terms] OR ("radiography"[All Fields] AND "panoramic"[All Fields]) OR "panoramic radiography"[All Fields] OR ("panoramic"[All Fields] AND "radiographies"[All Fields]) OR "panoramic radiographies"[All Fields] OR "Pantomography" OR "Pantomographies" OR "Orthopantomography" OR "Orthopantomographies")) AND (("chatgpt" OR ("transformer"[All Fields]OR "transformers"[All Fields]))))</pre>	<b>308</b>
---------------	---	------------

	<p>AND (("diagnostic imaging"[MeSH Subheading] OR ("diagnostic"[All Fields] AND "imaging"[All Fields]) OR "diagnostic imaging"[All Fields]) OR ("radiography"[MeSH Terms] OR "radiography"[All Fields] OR "radiographies"[All Fields] OR "radiographys"[All Fields]) OR ("radiography, dental"[MeSH Terms]) OR ("image"[All Fields] OR "imaged"[All Fields] OR "imager"[All Fields] OR "imagers"[All Fields] OR "images"[All Fields] OR "imaging"[All Fields] OR "imagings"[All Fields]) OR ("diagnostic imaging"[MeSH Subheading] OR ("diagnostic"[All Fields] AND "imaging"[All Fields]) OR "diagnostic imaging"[All Fields]) OR ("cone beam computed tomography"[MeSH Terms] OR ("cone beam"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "cone beam computed tomography"[All Fields] OR ("cone"[All Fields] AND "beam"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "CBCT"[All Fields] OR ("cone"[All Fields] AND "beam"[All Fields] AND "ct"[All Fields] AND "scan"[All Fields]) OR "cone beam ct scan"[All Fields] OR ("volume"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "volume computed tomography"[All Fields]) OR ("tomography, spiral computed"[MeSH Terms] OR ("tomography"[All Fields] AND "spiral"[All Fields] AND "computed"[All Fields]) OR "spiral computed tomography"[All Fields] OR ("volumetric"[All Fields] AND "ct"[All Fields]) OR "volumetric ct"[All Fields] OR ("cone"[All Fields] AND "beam"[All Fields] AND "cat"[All Fields] AND "scan"[All Fields]) OR "cone beam cat scan"[All Fields]) OR ("magnetic resonance imaging"[MeSH Terms] OR ("magnetic"[All Fields] AND "resonance"[All Fields] AND "imaging"[All Fields]) OR "magnetic resonance imaging"[All Fields] OR ("magnetic"[All Fields] AND "resonance"[All Fields] AND "images"[All Fields]) OR "magnetic resonance images"[All Fields] OR ("nmr"[All Fields] AND "imaging"[All Fields]) OR "nmr imaging"[All Fields] OR ("nmr"[All Fields] AND "tomography"[All Fields]) OR "nmr tomography"[All Fields] OR ("mr"[All Fields] AND "tomography"[All Fields]) OR "mr tomography"[All Fields] OR ("steady"[All Fields] AND "state"[All Fields] AND "free"[All Fields] AND "precession"[All Fields] AND "mri"[All Fields]) OR "steady state free precession mri"[All Fields] OR "Zeugmatography"[All Fields] OR ("magnetization"[All Fields] AND "transfer"[All Fields] AND "contrast"[All Fields] AND "imaging"[All Fields]) OR "magnetization transfer contrast imaging"[All Fields] OR ("mri"[All Fields] AND ("scan"[All Fields] OR "scans"[All Fields])) OR "mri scan"[All Fields] OR "mri scans"[All Fields] OR ("proton"[All Fields] AND "spin"[All Fields] AND "tomography"[All Fields]) OR "proton spin tomography"[All Fields] OR ("functional"[All Fields] AND "mri"[All Fields]) OR "functional mri"[All Fields] OR "fMRI"[All Fields] OR ("spin"[All Fields] AND "echo"[All Fields] AND ("imaging"[All Fields] OR "imagings"[All Fields])) OR "spin echo imaging"[All Fields]) OR ("multidetector computed tomography"[MeSH Terms] OR ("multidetector"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "multidetector computed tomography"[All Fields] OR "computed tomography multidetector"[All Fields] OR</p>	
--	--	--

	("multisection"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "multisection computed tomography"[All Fields] OR "dual-energy ct"[All Fields] OR "multidetector row ct"[All Fields] OR (("perfusable"[All Fields] OR "perfusate"[All Fields] OR "perfusates"[All Fields] OR "perfuse"[All Fields] OR "perfused"[All Fields] OR "perfuses"[All Fields] OR "perfusing"[All Fields] OR "perfusion"[MeSH Terms] OR "perfusion"[All Fields] OR "perfusions"[All Fields]) AND ("ct"[All Fields])) OR "perfusion ct"[All Fields] OR ("multislice"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "multislice computed tomography"[All Fields] OR "multidetector row computed tomography"[All Fields])	
--	--	--

Todas as buscas foram realizadas no dia 16 de janeiro de 2024. Após realização da busca, as referências foram importadas para o *software* de gerenciamento de referência *Mendeley Referencer Manager*. No mesmo *software*, procedeu-se a remoção dos estudos duplicados. Em seguida, os arquivos sem estudos duplicados foram importados para o aplicativo online Rayyan QCRI (*Qatar Computing Research Institute*, Doha, Qatar) [16], havendo nova checagem de possíveis duplicatas.

## 2.4 SELEÇÃO DOS ESTUDOS

A seleção dos estudos foi realizada em duas fases, utilizando o aplicativo online supracitado Rayyan QCRI [16]. Na fase inicial, títulos e resumos dos estudos elegíveis foram avaliados de forma independente por dois revisores (M.L. e J.M.), e todos os estudos que não atendiam aos critérios de inclusão foram identificados e excluídos. Na segunda fase, os artigos relevantes foram revisados integralmente pelos mesmos dois revisores, também de forma independente. Estudos que não atendiam aos critérios de inclusão foram excluídos. Em ambas as fases, inconsistências foram resolvidas por consenso entre os revisores. Nos casos em que não houve consenso, o coordenador (A.L.) foi consultado para resolver os conflitos.

## 2.5 COLETA DE DADOS

A extração dos dados foi realizada por dois revisores independentes (M.L. e J.M.) utilizando uma tabela específica para extração de dados (Tabela 1). As discordâncias foram resolvidas por consenso ou, em caso de desacordo, o coordenador (A.L.) foi consultado.

Os seguintes dados foram extraídos: características do estudo (autor(es), ano, país e tipo de estudo), tarefa diagnóstica, padrão de referência, modalidade de imagem, modelo de rede neural, tamanho do conjunto de dados (treinamento/validação/teste) e métricas de acurácia.

Após a conclusão da extração individual e simultânea, as tabelas passaram por verificação cruzada entre os revisores (M.L. e J.M.). Após resolução de conflitos, os dados foram unificados na Tabela 1.

### 3 RESULTADOS

#### 3.1 SELEÇÃO DE ESTUDOS

A busca resultou em um total de 5.182 estudos, sendo 5.078 advindos das bases de dados e 104 da literatura cinzenta, assim distribuídos: 308 estudos da Pubmed, 380 estudos da Embase, 2.161 estudos da Scopus, 1.153 estudos da *Web of Science*, 04 estudos da Lilacs, 1.072 da *IEEE Xplore*, 03 estudos da ProQuest, e os 101 primeiros estudos do Google Scholar foram considerados pela equipe. Após a remoção dos artigos duplicados, 3.278 estudos das bases de dados e 104 da literatura cinzenta foram mantidos para a etapa seguinte, realizada no Rayyan. Durante a fase 1, os estudos foram triados novamente para eliminação de possíveis duplicatas, sendo 122 artigos considerados duplicados e, portanto, deletados. Os 3.260 estudos restantes foram então submetidos a uma avaliação dos títulos e resumos. Destes, 3.244 foram excluídos, por não seguirem os critérios de inclusão desta revisão.

Ao final, 16 estudos atenderam aos critérios de elegibilidade e foram incluídos para avaliação completa na fase seguinte. Assim, na fase 2, após a leitura completa e avaliação dos 16 artigos recuperados, considerando os critérios de inclusão, 5 artigos foram excluídos. Ao fim, 11 artigos preencheram os critérios de elegibilidade e foram incluídos na revisão [17-27].

Na figura 2 está representado o fluxograma com o processo de identificação, inclusão e exclusão de estudos. Os 5 estudos excluídos, com os motivos da exclusão encontram-se no apêndice 2.

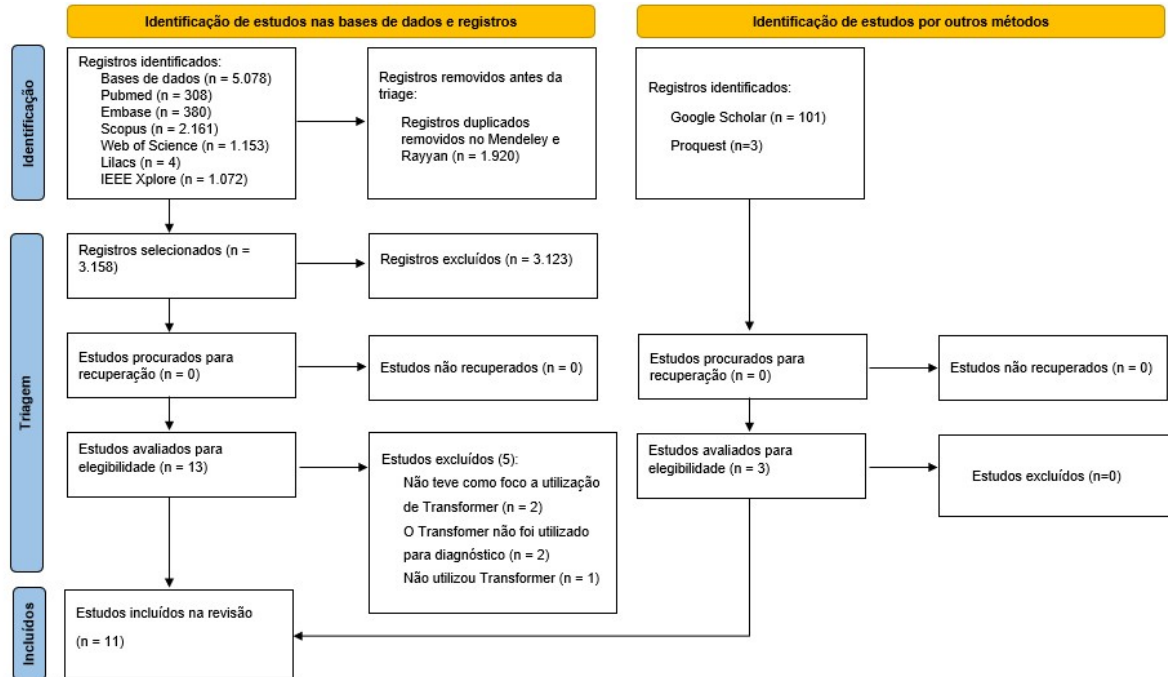


Figura 2 – Fluxograma da estratégia de busca e seleção dos estudos

### 3.2 CARACTERÍSTICA DOS ESTUDOS

A Tabela 1 resume as características dos 11 artigos incluídos. Esses foram publicados entre 2017 e 2023. O padrão de referência incluiu avaliação de especialistas por meio da anotação manual. O número total do conjunto de dados foi de 38.838, não sendo possível quantificar o total de dados utilizados para teste, treinamento e validação pela falta de informação em alguns estudos, pois apenas 3 estudos apresentaram todas as informações quanto a essa divisão [18, 21, 25].

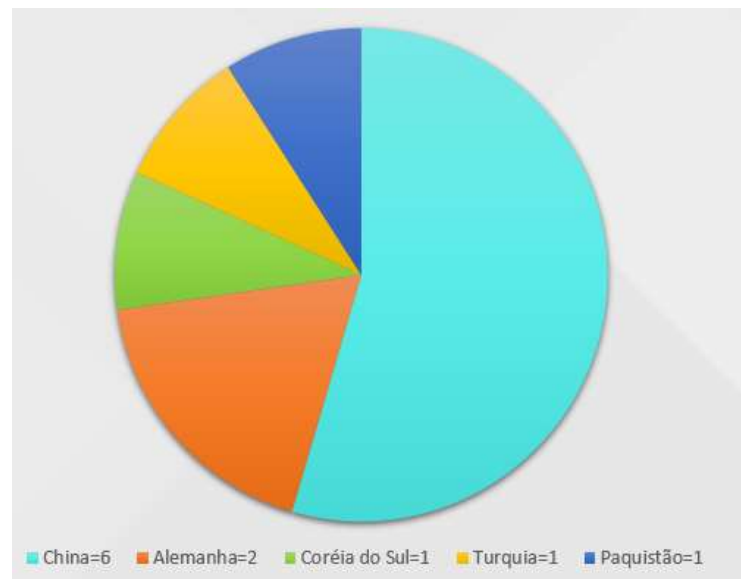


Figura 3 – Número de estudos selecionados de acordo com os países de origem. Fonte: do próprio autor.



Figura 4 – Número de estudos selecionados de acordo com os exames utilizados. Fonte: do próprio autor.

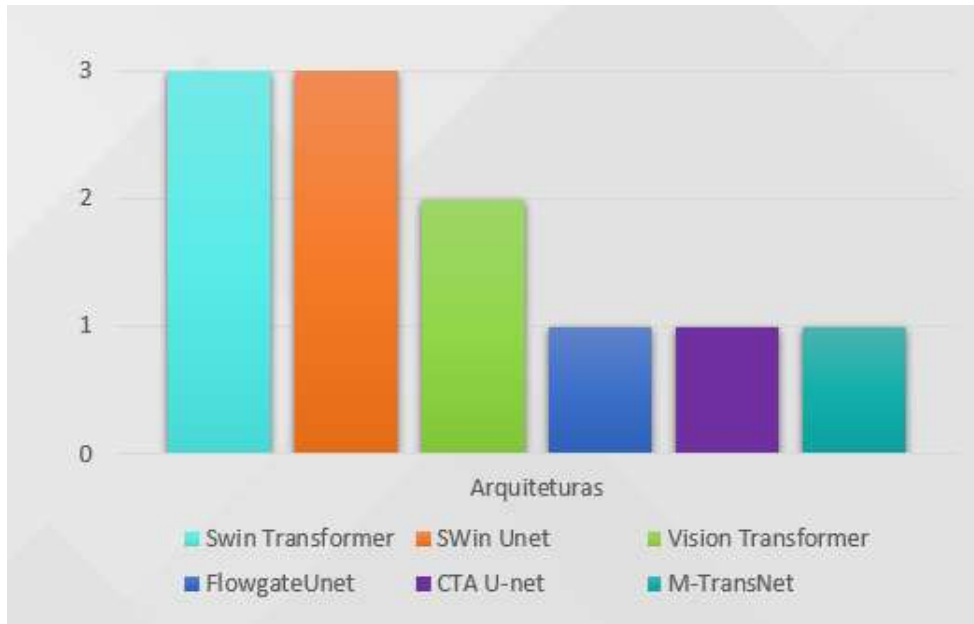


Figura 5 – Arquiteturas encontradas nos estudos selecionados [17-27]

O estudo de Vinayahalingam et al. (2022) teve como objetivo detectar automaticamente fraturas mandibulares em radiografias panorâmicas (RP). No total, 1624 RP contendo fraturas foram anotadas manualmente e rotuladas como referência. Uma abordagem de aprendizado profundo, baseada no *Swin-Transformer* e no *Faster R-CNN*, foi treinada e validada em RP tanto com quanto sem fraturas. Posteriormente, o algoritmo treinado foi testado em um conjunto de 149 RP com fraturas e 171 RP sem fraturas. O método proposto obteve como métricas: F1-Score de 0,947, uma Área Sob a Curva (AUC) de 0,977, um *Recall* de 0,960, uma precisão (PS) de 0,935 e uma curva de evocação de precisão (AP) de 0,963. O estudo concluiu que essa abordagem é promissora para a detecção automática de fraturas em RP, podendo reduzir erros de diagnóstico [23].

O estudo de Lv et al. (2023) buscou superar os desafios relacionados à segmentação do canal mandibular, propondo uma abordagem totalmente automatizada que emprega uma arquitetura baseada em *Transformer* juntamente com a perda *cl-Dice*, garantindo que o modelo se concentre na conectividade do canal mandibular. A abordagem alcançou métricas de desempenho superiores a métodos existentes, com um *Dice score* de 0,844, *Click score* de 0,961, Interseção sobre União (IoU) de 0,731 e *Distância Hausdorff* (HD95) de 2,947 mm, validando assim a eficácia da proposta [18].



Outro estudo propôs uma rede para segmentação dentária em tomografia computadorizada de feixe cônico (TCFC) chamada *FlowgateUNet* aprimorada, que utiliza o *FlowFormer*, uma versão adaptada da rede *Transformer*. Comparado a outro modelo, o *FlowgateUNet* melhorou o coeficiente de similaridade de dados (DSC) em 1% no conjunto de dados de imagens dentárias de CBCT e em 0,7% no conjunto de dados de microTC dentária, alcançando um bom desempenho. No entanto, há espaço para melhorias, pois, de acordo com as métricas de avaliação obtidas nos experimentos, o *FlowgateUNet* foi inferior a algumas outras redes nos valores de HD95 [17].

Em outro estudo, a *SWin-Unet* foi utilizada para segmentação dentária em radiografia panorâmica. A *SWin-Unet* é uma arquitetura codificadora-decodificadora em forma de U baseada em transformador, com conexões *skip*. Seu desempenho foi avaliado usando as seguintes métricas: F1-Score = 0,6372, IoU = 0,4689 e Acurácia (ACC) = 0,8852. Comparada com *U-Net*, *Link-Net* e FPN, a *SWin-Unet* apresentou desempenho significativamente superior no conjunto de dados de segmentação dentária. Esses resultados sugerem que a *SWin-Unet* pode ser uma ferramenta viável para a segmentação em radiografias panorâmicas, com grande potencial para aplicação clínica [19].

Para a segmentação de lesões de cárie em radiografias periapicais foi proposta uma rede *transformer* combinando diferentes recursos de redes convolucionais, um formato de U. A similaridade dos dados e a precisão da classificação de pixels foram calculadas para avaliar o comportamento da rede. Os resultados experimentais obtiveram uma similaridade média de dados de 0,7487 e uma precisão média de classificação de *pixels* de 0,7443 no conjunto de dados de teste, superando redes comparadas, como *UNet*, *Trans-UNet* e *Swin-UNet* [20].

Uma pesquisa realizada em 2023 apresentou uma nova técnica de aprendizagem profunda para diagnóstico mais preciso de cáries em radiografias panorâmicas (RP) de crianças. Foi introduzido um transformador *Swin*, comparado aos métodos de redes neurais convolucionais (CNN) de última geração usados para o diagnóstico de cáries. Um *Swin Transformer* aprimorado foi proposto para identificar diferenças entre os dentes, o que pode contribuir para diagnósticos mais precisos. Um banco de dados de RP de crianças com um total de 6.028 dentes foi construído e rotulado. O *Swin Transformer* apresentou melhor desempenho diagnóstico comparado aos métodos CNN tradicionais, e sua versão aprimorada superou o *Swin*

*Transformer* original em acurácia, precisão, recall, F1 e área sob a curva, com valores de 0,8557, 0,8832, 0,8317, 0,8567 e 0,9223, respectivamente. No entanto, ao comparar o método proposto com dois profissionais, verificou-se maior precisão no diagnóstico de cáries apenas nos primeiros e segundos molares decíduos, indicando que o método pode ser útil, mas ainda precisa ser aprimorado [21].

Para resolver problemas relacionados à segmentação de imagens devido à morfologia variada dos dentes, um estudo propôs um novo modelo de segmentação que combina uma estrutura M-Net com *Swin Transformers* e *Teeth Attention Block* (TAB). O TAB utiliza um mecanismo de atenção exclusivo que foca nas estruturas dentárias complexas, destacando elementos essenciais em radiografias panorâmicas e garantindo segmentação precisa. O modelo teve uma pontuação de ACC de 0,9726, comparável a outros modelos, mas superou-os no Coeficiente de Dados (0,9102) e Índice Jaccard (JI) (0,8501). Isso demonstrou sua capacidade de distinguir verdadeiros positivos enquanto minimizava falsos positivos e negativos. As pontuações de precisão (0,8046), *recall* (0,9389) e especificidade (0,9730) forneceram mais evidências. Portanto, os autores concluíram que o mecanismo de atenção do TAB destaca com rigor as estruturas dentárias, resultando em segmentações altamente precisas [25].

Um estudo realizado em 2023 usou dados de tomografia computadorizada de feixe cônico (TCFC) de 200 pacientes para desenvolver uma rede *UNet* com arquitetura *CNN-Transformer*, que combina as vantagens de ambas as tecnologias. O componente CNN extrai eficientemente características locais, enquanto o *Transformer* captura dependências de longo alcance. Um novo método de modelagem de imagem mascarada foi introduzido para pré-treinar simultaneamente os módulos CNN e *Transformer*. O método proposto apresentou um desempenho superior, com um DSC de 87,12%, IoU de 78,90%, HD95 de 0,525 mm e Distância Média de Superfície Simétrica (ASSD) de 0,199 mm. Ele ofereceu uma abordagem mais eficiente para a segmentação automática e precisa de imagens de TCFC dentárias [19].

Um estudo realizado na Alemanha em 2023 avaliou cinco redes transformers de visão computacional (*ViT-base/ViT-large* do *Google*, *BEiT-base/BEiT-large* da *Microsoft*, e *DeiT-base* do *Facebook/Meta*) para a detecção automatizada de perda óssea periodontal (PBL). O conjunto de dados, composto por 21.819 radiografias periapicais das regiões superior/inferior e anterior/posterior, foi avaliado por dentistas

calibrados para PBL. Os valores gerais de precisão diagnóstica (ACC) e área sob a curva (AUC) variaram entre 83,4% e 85,2%, e entre 0,899 e 0,918, respectivamente. O desempenho diagnóstico variou conforme a região anatômica. Nas regiões inferiores anteriores, os valores de ACC foram de 94,1% a 96,7%, e os de AUC, de 0,944 a 0,970. Nas regiões superiores anteriores, os valores de ACC variaram entre 86,7% e 90,2%, e os de AUC entre 0,948 e 0,958. Nas regiões inferiores posteriores, a precisão diagnóstica ficou entre 85,6% e 87,2% (ACC) e entre 0,913 e 0,937 (AUC). Nas regiões superiores posteriores, os valores foram de 78,1% a 81,0% (ACC) e de 0,851 a 0,875 (AUC) [24].

Apesar de incluído nesta revisão, um estudo utilizou redes neurais convolucionais e *transformer* para segmentação dentária em radiografias panorâmicas e interproximais. O método proposto alcançou valores acima de 90% nas métricas de acurácia, precisão, *recall*, pontuação F1 e especificidade em imagens de *Bitewing* [26]. No entanto, há carência de dados relacionados ao modelo desenvolvido neste estudo.

Por fim, um artigo desenvolveu um algoritmo *transformer* para segmentação dentária em radiografias panorâmicas, com desempenho superior a outros modelos considerados estado da arte. Como métricas, os autores obtiveram AUC= 97,25; Especificidade= 97,65; Precisão= 95,13; *Recall*= 93,92; F1= 93,4 [27].

Tabela 1 – Resumo das características descritivas dos estudos incluídos (continua)

Autor, Ano e País	Tipo de estudo	Tamanho do conjunto de dados (Treinamento, validação e Teste)	Modelo de rede neural	Tarefa diagnóstica	Modalidade de imagem	Padrão de Referência	Métricas de acurácia
Cao D, Cai B, Liu M; 2023. China [17]	Experimental	1º conjunto: 1833 (20% para teste e 80% para treinamento) 2º conjunto: 10.136 (20% para teste e 80% para treinamento) 3º conjunto: 30 (12 para teste e 18 para treinamento) Validação: N/I	<i>FlowgateUnet</i>	Segmentação de dentes	TCFC e MicroTC	N/I	TCFC: DSC=90.69 e HD95=2.49  MicroTC: DSC=83.86 HD95=17.10
Chen Z, Chen S, Hu F; 2023. China [19]	Experimental	45 (divisão: N/I)	<i>CTA U-net</i>	Segmentação de imagens odontológicas no geral	TCFC	Anotação manual	DSC = 0.8712, IoU = 0.789, HD95 = 0.525mm e ASSD = 0.199mm
Dujic H, et al; 2023. Alemanha [24]	Experimental	21.819 (18.819 para treinamento e 3.000 para teste)	<i>Vision Transformer (ViT-Base, ViT-Large, BEiT-</i>	Detecção de perda óssea periodontal	RPA	Anotação manual	Mandíbula anterior (variação): ACC = 94.1 para ViT-

Autor, Ano e País	Tipo de estudo	Tamanho do conjunto de dados (Treinamento, validação e Teste)	Modelo de rede neural	Tarefa diagnóstica	Modalidade de imagem	Padrão de Referência	Métricas de acurácia
		Validação: N/I	<i>Base, BEiT-Large e DeiT-Base)</i>				<p><i>base a 96.7 para BeiT-base e BeiT-large; Sensibilidade = 97.2 para ViT-base a 99.2 para BeiT-large; Especificidade = 60.0 para DeiT-base a 84.0 para BeiT-base; PPV = 96.0 para DeiT-base a 98.4 para BeiT-large; NPV = 69.6 para ViT-base a 90.0 para BeiT-large; e AUC = 0.944 para ViT-base a 0.970 para DeiT-base.</i></p> <p>Mandíbula posterior (variação): ACC = 85.6 para ViT-large a 87.2 para BeiT-large; Sensibilidade = 89.2 para ViT-large a 92.3</p>

Autor, Ano e País	Tipo de estudo	Tamanho do conjunto de dados (Treinamento, validação e Teste)	Modelo de rede neural	Tarefa diagnóstica	Modalidade de imagem	Padrão de Referência	Métricas de acurácia
							<p>para <i>BeiT-large</i>; Especificidade = 75.9 para <i>BeiT-base</i> a 78.6 para <i>ViT-base</i>; PPV = 88.9 para <i>BeiT-base</i> a 90.0 para <i>ViT-base</i>; NPV = 77.4 para <i>ViT-large</i> a 82.5 para <i>BeiT-large</i>; e AUC = 0.913 para <i>ViT-large</i> a 0.937 para <i>ViT-base</i>.</p>
							<p>Maxila anterior (variação): ACC = 86.7 para <i>DeiT-base</i> a 90.2 para <i>ViT-base</i>; Sensibilidade = 93.3 para <i>DeiT-base</i> a 95.8 para <i>BeiT-base</i>; Especificidade = 73.7 para <i>BeiT-base</i> e <i>BeiT-large</i> a 81.8 para <i>ViT-base</i>,</p>

Autor, Ano e País	Tipo de estudo	Tamanho do conjunto de dados (Treinamento, validação e Teste)	Modelo de rede neural	Tarefa diagnóstica	Modalidade de imagem	Padrão de Referência	Métricas de acurácia
							<p>PPV = 85.8 para <i>BeiT-large</i> a 89.7 para <i>ViT-base</i>; NPV = 87.2 para <i>DeiT-base</i> a 91.3 para <i>BeiT-base</i>; e AUC = 0.948 para <i>ViT-large</i> a 0.958 para <i>ViT-base</i>.</p>
							<p>Maxila posterior (variação): ACC = 78.1 para <i>ViT-large</i> a 81.0 para <i>ViT-base</i>; Sensibilidade = 81.6 para <i>ViT-large</i> a 87.5 para <i>BeiT-large</i>; Especificidade = 63.0 para <i>BeiT-large</i> a 70.3 para <i>ViT-large</i>; PPV = 84.0 para <i>BeiT-large</i> a 86.3 para <i>ViT-base</i>; NPV = 63.4 para <i>ViT-large</i> a 69.6 para <i>BeiT-large</i>;</p>

Autor, Ano e País	Tipo de estudo	Tamanho do conjunto de dados (Treinamento, validação e Teste)	Modelo de rede neural	Tarefa diagnóstica	Modalidade de imagem	Padrão de Referência	Métricas de acurácia
							e AUC = 0.851 para <i>ViT-large</i> a 0.875 para <i>ViT-base</i> .
<b>Ghafoor A, Moon SY, Lee B; 2017. Coreia do Sul [25]</b>	Experimental	540 (70% para treinamento, 15% para validação e 15% para teste)	<i>M-Net, Swin Transformers</i> e TAB	Segmentação de dentes	RP	Anotação manual	ACC = 0.9727, DSC = 0.9102, JI = 0.8501, Precisão = 0.8046, <i>Recall</i> = 0.9389 e Especificidade = 0.9730
<b>Kanwal M, et al. 2023. Paquistão [27]</b>	Experimental	543 (500 para treinamento e 43 para validação) Teste: N/I	<i>M-TransNet</i>	Segmentação de dentes	RP	Anotação manual	ACC = 97.25, Especificidade = 97.65, Precisão = 95.13, <i>Recall</i> = 93.92, F1 = 93.47
<b>Kaya MC; 2023. Turquia [26]</b>	Experimental	1º conjunto – 120 BW (40 para treinamento, 40 para teste e 40 para validação).	<i>FastFCN, U-net, Swin Unet</i> e <i>TransUnet</i>	Segmentação de dentes	RP e BW	Anotação manual	RP: ACC = 0.967, Precisão = 0.967,



Autor, Ano e País	Tipo de estudo	Tamanho do conjunto de dados (Treinamento, validação e Teste)	Modelo de rede neural	Tarefa diagnóstica	Modalidade de imagem	Padrão de Referência	Métricas de acurácia
		2º conjunto – 1500 RP (divisão: N/I)					<i>Recall</i> = 0.967, <i>Especificidade</i> = 0.975, <i>F1</i> = 0.967  <i>BW: ACC</i> = 0.908, <i>Precisão</i> = 0.909, <i>Recall</i> = 0.908, <i>Especificidade</i> = 0.907, <i>F1</i> = 0.908
Lv, Jinxuan et al; 2023. China [18]	Experimental	91 (68 para treinamento, 8 para validação e 15 para teste)	Swin-UNetR	Segmentação do canal mandibular	TCFC	N/I	<i>Dice score</i> = 0.844, <i>Click score</i> = 0.961, <i>IOU</i> = 0.731 e <i>HD95</i> = 2.947mm
Sheng C, et al; 2023. China [22]	Experimental	100 (90 para treinamento e 10 para teste) Validação: N/I	SWin Unet	Segmentação de dentes	RP	Anotação manual	<i>F1</i> = 0,6372, <i>IoU</i> = 0,4689 e <i>ACC</i> = 0,8852

Autor, Ano e País	Tipo de estudo	Tamanho do conjunto de dados (Treinamento, validação e Teste)	Modelo de rede neural	Tarefa diagnóstica	Modalidade de imagem	Padrão de Referência	Métricas de acurácia
Vinayahalingam S, et al; 2022. Alemanha [23]	Experimental	1º conjunto: 1624 (1310 para treinamento, 165 para validação e 149 para teste) 2º conjunto: 4780 (Divisão aleatória)	Swin Transformer e R-CNN	Diagnóstico de fratura mandibular	RP	Anotação manual	Precisão = 0,935, F1 = 0,947, AUC = 0,977, AP = 0,963 e Recall = 0,960
Ying S, et al; 2022. China [20]	Experimental	153 (113 para treinamento e 40 para teste) Validação: N/I	Rede em forma de U (Vision Transformer, Convolução dilatada e fusão de pirâmide de recursos)	Segmentação de cárie	RPA	Anotação manual	Similaridade = 0.7487 e Precisão = 0.7443
Zhou X, et al; 2023. China [21]	Experimental	304 (244 para treinamento, 30 para validação e 30 para teste)	Swin Transformer	Diagnóstico de cárie	RP	Anotação manual	ACC = 0.8557, Precisão = 0.8832, Recall = 0.8317, F1 = 0.8567 e AUC = 0.9223

**N/I:** Não informado; **RP:** Radiografia Panorâmica; **RPA:** Radiografia Periapical; **TC:** Tomografia Computadorizada **TCFC:** Tomografia Computadorizada de Feixe Cônico; **ACC:** Acurácia; **AUC:** area under curve; **PPV:** Valor preditivo positivo; **NPV:** Valor preditivo negativo **CNN:** Convolutional Neural Network; **ASSD:**

*Average Symmetric Surface Distance; **AUC**: Área sob a curva; **BW**: Bitewing; **DSC**: Dice Similarity Coefficient; **HD95**: 95% Hausdorff Distance; **IoU**: Intersection over Union; **Jl**: Jaccard Index; **PBL**: Periodontal Bone Loss; **TAB**: Teeth Attention Block; **AP**: Precision-recall curve*

(conclusão)

### 3.3 SÍNTESE DOS RESULTADOS

O conjunto de dados foi composto por um total de 38.838 imagens, sendo elas radiografias panorâmicas, radiografias periapicais, radiografias *bitewing* (BW) e tomografias computadorizadas (TC), sendo elas (TCFC e MicroTC). Cinco estudos utilizaram apenas radiografias panorâmicas [21, 22, 23, 25, 27], um estudo utilizou radiografia panorâmica (RP) e BW [26]. Dois estudos utilizaram radiografias periapicais [20, 24] e três estudos utilizaram TC [17, 18, 19], sendo que um deles utilizou TCFC e MicroTC [17]. Os estudos não citaram características de sexo ou idade dos pacientes, pois a maioria mostra que as imagens foram anonimamente selecionadas. Apenas um estudo [21] relatou que utilizou radiografias panorâmicas de crianças.

Quanto aos modelos *Transformer* utilizados, *Swin Transformer* [21, 23, 25], *SWin Unet* [18, 22, 26], *FlowgateUnet* [17], *Vision Transformer* [20, 24, 25], *CTA Unet* [19] e *M-TransNet* [27] foram possíveis de serem observados.

As métricas de acurácia mais utilizadas foram Precisão, presente em sete estudos [20-23, 25-27], seguida de acurácia em seis estudos [21, 22, 24-27]. Cinco estudos utilizaram o F1 Score [21-23, 26, 27], três usaram AUC [21, 23, 24], enquanto sensibilidade foi utilizada em dois [24, 26] e especificidade em quatro [24-27]. Além disso, outras métricas como *Recall* também foram encontradas [21, 23, 25-27]. A precisão variou entre 96,7% [26] e 74,4% [20], embora esses valores não sejam diretamente comparáveis devido à diversidade de exames e tarefas diagnósticas.

Em nove estudos [19-27], a anotação manual foi utilizada como padrão de referência, com profissionais experientes (*experts*) realizando as codificações nas imagens para treinamento, porém, na maior parte dos estudos, não foi observado a especificação de quem eram os *experts*, não sendo possível saber o nível de experiência real de tais profissionais. Em dois estudos [17, 18], não houve menção ao padrão de referência.

Quanto à tarefa diagnóstica, a maioria dos estudos usou as redes *Transformer* para segmentação [17-20, 22, 25-27]. Entre os que não empregaram segmentação, um focou na detecção de perda óssea periodontal [24], enquanto outro na identificação de sinais de cárie em imagens odontológicas [21]. Uma pesquisa abordou o uso dessa arquitetura no diagnóstico de fraturas mandibulares [23].

## 4 DISCUSSÃO

Esta revisão de escopo é a primeira a explorar sistematicamente as aplicações das redes *Transformer* na radiologia odontológica. Embora as redes neurais convolucionais tenham sido amplamente consideradas como o estado da arte em algoritmos de visão computacional na área, as redes *Transformer* demonstram grande potencial para superar a performance dessas técnicas na análise de imagens médicas. Ao capturar relações globais nas imagens e revelar padrões complexos, os modelos *Transformer* podem oferecer avanços significativos para diagnósticos mais precisos e eficientes na saúde, incluindo na radiologia odontológica. No entanto, até recentemente, o estado da arte para a análise de imagens médicas e odontológicas era dominado pelas redes neurais convolucionais. Isso explica o baixo número de artigos encontrados, totalizando 11 estudos que utilizaram redes *Transformer* para tarefas diagnósticas em radiografias panorâmicas, tomografias computadorizadas e periapicais. Esta característica também justifica o fato de os artigos incluídos serem bastante recentes, reforçando o potencial que as redes *Transformer* têm de se tornarem o algoritmo de visão computacional de escolha para a análise de imagens médicas.

A redes *Transformer* já ocupam um espaço importante para diagnóstico em imagens médicas, onde diversos estudos em diferentes áreas da medicina mostram sua eficácia. Para exemplificar, um desses estudos que aborda o uso de *Transformer* busca melhorar o diagnóstico e o prognóstico do câncer de pulmão. Esse estudo conclui que os métodos utilizados são cada vez mais populares para a finalidade desejada [6].

Estudos mostram que a estrutura *Transformer* pode ser superior, mesmo com as CNNs ainda sendo dominantes no campo de visão computacional [28]. A estrutura CNN consegue captar a relação entre *pixels* adjacentes de uma imagem e manter certo grau de equivariância de rotação e de translação. Isso indica que as CNNs podem desempenhar seu papel de forma mais eficaz na etapa de aprendizagem de representação de imagens, obtendo melhores resultados em etapas subsequentes, como classificação ou outras tarefas como segmentação de imagens [29]. Em 2017, os *Transformers* alcançaram grande sucesso na área de processamento de linguagem natural. O kernel da CNN só pode capturar recursos locais; por outro lado,

o mecanismo de autoatenção do *Transformer* consegue capturar relações entre quaisquer dois pontos na sequência de entrada. O *Vision Transformer (ViT)* [30], por exemplo, faz modificações mínimas no *Transformer* utilizado em processamento de linguagem natural para adaptá-lo à visão computacional. No processamento de linguagem natural, o *Transformer* recebe como entrada uma frase na forma de uma sequência de *tokens*, onde cada *token* representa uma palavra na frase. Na visão computacional, o ViT divide a imagem em vários *patches*, e cada *patch* é considerado um *token*, formando a sequência de entrada. O ViT alcança os melhores resultados em diversas tarefas de *benchmark*. Com isso, surge um interesse crescente em utilizar *Transformers* em tarefas de processamento de imagens médicas [31].

A maior parte dos estudos reunidos nesta revisão é de 2023, seguidos pelos artigos publicados em 2022. Isso mostra o crescente interesse pelo tema e pelas diferentes formas de aplicação da arquitetura *Transformer* na Odontologia, não apenas para diagnóstico, foco desta revisão, mas também para a predição de cirurgias ortognáticas [32], acompanhamento e verificação de sucesso terapêutico em endodontia. [33].

Após o ano de 2017, quando os *Vision Transformers* foram propostos pela primeira vez, a arquitetura *Transformer* vem sendo empregada em medicina diagnóstica para diversos fins, principalmente em tarefas de segmentação. Na Odontologia não vem sendo diferente, já que a maior parte dos estudos aqui apresentados utilizou essa ferramenta também em tarefas de segmentação de imagens. *Vision Transformer*, *Swin Transformer*, *TransUnet* e *SwinUnet* são alguns dos modelos de aprendizagem profunda baseados em *Transformer* utilizados na maioria dos estudos encontrados. Modelos adaptados também foram explorados, podemos citar como exemplo o *FlowFormer* [17]. *TransUnet* foi a primeira tentativa de usar o *Transformer* em segmentação de imagens médicas [34].

Nesta revisão, dos 11 artigos analisados, oito empregaram a arquitetura *Transformer* em tarefas de segmentação. Cinco buscavam segmentar imagens de dentes, a fim de facilitar diagnósticos precisos e ajudar a desenvolver tratamentos eficazes [17, 22, 25, 26, 27]. Já um outro estudo teve como intenção a segmentação do canal mandibular para aumentar a taxa de sucesso dos procedimentos cirúrgicos odontológicos [18]. Outra pesquisa buscou a segmentação de imagens de cárie [20] e um último realizou segmentação de imagens odontológicas no geral, para ajudar na

visualização de morfologia radicular e por exemplo, limites entre as raízes e osso alveolar [19].

Muitos estudos utilizaram um modelo *Transformer* em combinação com Rede Neural Convolutiva (CNN) com a finalidade de aperfeiçoar as respostas desejadas, um estudo específico, que utiliza essa união em imagens médicas, justifica isso expondo que os transformadores de visão capturam efetivamente o contexto de longo alcance nos dados de entrada, enquanto as CNNs tendem a se destacar capturando dependências de curto alcance [6]. Pelo menos quatro dos estudos selecionados para essa revisão utilizou este método, uma vez que isso poderia colaborar de forma positiva para tais pesquisas [22, 23, 25, 27].

Cinco estudos utilizaram radiografias panorâmicas em suas modalidades de imagens como fonte de dados, apenas um dos estudos incluídos utilizou radiografias interproximais. Dois estudos utilizaram como dados imagens de radiografias periapicais e por fim, quatro outros estudos fizeram uso de imagens de tomografias computadorizadas, estando entre elas TCFC e MicroTC. Alguns estudos trouxeram características relacionadas ao tipo de imagem como limitante nos estudos, como por exemplo um estudo que traz que radiografias extra-orais, por exemplo a RP, pode apresentar ruídos [22]. Porém a RP é uma das radiografias mais utilizadas na prática clínica e que muitas vezes a segmentação pode ser positivamente aplicada a elas. Os modelos usados, baseados em arquitetura *Transformer* então, quando bem treinados, podem trazer benefícios para este fim.

Um dos estudos selecionados trouxe uma comparação entre o uso de CNN's e *Transformer* para diagnóstico de cárie infantil em RP e tiveram como conclusão de que existem vantagens na utilização desse tipo de aprendizagem profunda para esta finalidade, uma vez que o modelo utilizado superou todas as métricas de acurácia utilizadas para comparação com quatro métodos CNN [21]. Porém, é de entendimento odontológico que a radiografia panorâmica não é indicada para diagnóstico de lesões de cárie, tendo como indicação radiografias interproximal e periapical para devido fim. Logo, os resultados de tal estudo podem ser questionáveis.

Em se tratando de métricas de acurácia, já citadas anteriormente, é importante dizermos que muitas são as métricas para avaliação de resultados envolvendo a tecnologia aqui discutida. Diferentes métricas são aplicadas para diferentes modelos e finalidades. Alguns exemplos de métricas são: *F1 Score*, ACC, Precisão, *Recall*, entre outras. A métrica de Precisão foi a mais utilizada nos trabalhos desta revisão.

Ela busca visualizar, através de uma equação, quais os resultados são realmente verdadeiros, considerando resultados verdadeiros positivos (TP), verdadeiros negativos (TN), falsos positivos (FP) e falsos negativos (FN) [20]. A segunda métrica mais utilizada foi ACC, que representada por uma equação em que casos avaliados corretamente como TP e TN são divididos por casos totais (TP+TN+FN+FP).

É de grande relevância também salientarmos a importância da qualidade das imagens utilizadas, o que pode ajudar ou dificultar o treinamento dos modelos utilizados. Sabe-se que imagens odontológicas, mesmo sendo comuns na prática clínica, nem sempre estão disponíveis para a utilização em pesquisas, pois esbarram principalmente em questões éticas. Porém, o número de dados envolvendo imagens também se faz crucial, pois é necessário um número de dados adequado durante as etapas de treinamento, com o intuito de fornecer o máximo de informações possíveis com a devida qualidade.

Portanto, é possível observar que a utilização da inteligência artificial, especialmente da arquitetura *Transformer*, no diagnóstico de alterações dentárias e na região do complexo maxilomandibular, mostra-se promissora para a Radiologia Odontológica com base nos resultados apresentados aqui. Contudo, essa abordagem ainda é incipiente, visto que apenas 11 artigos foram selecionados e também apresenta limitações e desafios que necessitam de investigações mais profundas pela comunidade acadêmica. Entre eles, destaca-se a importância de estabelecer e padronizar as metodologias dos estudos, incluindo conceitos e terminologias utilizadas, além da necessidade de justificar o tamanho do conjunto de dados.



## 5 LIMITAÇÕES

Alguns estudos incluídos utilizaram um número pequeno de imagens para treinamento e para teste dos modelos propostos, podendo não ter apresentado variações importantes para uma tarefa diagnóstica. Também foram observados estudos que não expuseram informações como o número de dados presentes nas fases de treinamento ou teste, ou a forma de seleção desses dados para cada grupo. Além disso, alguns estudos não mencionaram o padrão de referência utilizado. A radiografia panorâmica foi utilizada para avaliação de lesão de cárie em um estudo, não sendo a radiografia ideal para tal fim. Deve-se ressaltar ainda a própria limitação das redes *transformers*, citadas em grande parte dos estudos, que necessitam de um volume maior de dados para treinamento, assim como maior capacidade computacional. Ainda assim, se tomarmos o exemplo de outras áreas, as redes *Vision Transformers* podem se tornar o estado da arte para estudos de visão computacional em Radiologia Odontológica em um breve futuro.

## 6 FUTUROS ESTUDOS

Com o avanço da inteligência artificial (IA), as pesquisas em saúde, incluindo a odontologia, têm se beneficiado significativamente dessa tecnologia em diversos campos. É esperado que um número crescente de estudos sobre IA em odontologia seja conduzido, focando no uso da Rede *Transformer* para diversas atividades diagnósticas por meio de exames de imagem. No entanto, é essencial que haja padronização na seleção de dados e uso de uma quantidade adequada desses dados para treinamento e testes. Dada a variedade de alterações morfológicas e os diferentes tipos de lesões que podem afetar os tecidos duros da face, seria extremamente útil a criação de um banco de dados público de exames de imagem. Esse recurso facilitaria pesquisas futuras, proporcionando uma rica fonte de informações para alimentar os sistemas de IA. Assim, a rede neural *Transformer* pode vir a ser considerada em um futuro breve, estado da arte.

## 7 CONCLUSÃO

A partir dos dados trazidos pelos estudos explorados, esta pesquisa concluiu que a rede neural *Transformer* é altamente promissora quando se trata de diagnóstico de alterações dentomaxilofaciais por meio de exames de imagem na Radiologia odontológica. Mesmo ainda não sendo uma realidade no dia a dia clínico, é uma grande possibilidade em se tornar.

Logo, os dados obtidos nesse estudo indicam que os modelos baseados em *Transformer* frequentemente se beneficiam da combinação com outras arquiteturas, como as Redes Neurais Convolucionais, resultando em maior sucesso nos resultados. É fundamental mencionar que, embora haja espaço para melhorias, esta tecnologia já representa um significativo avanço da IA na odontologia. Ela desempenha papéis cruciais em diversas áreas, incluindo a segmentação de imagens, a visualização de alterações significativas como a perda óssea associada à doença periodontal, o suporte ao diagnóstico pré-cirúrgico para o planejamento adequado de cirurgias, e até no diagnóstico de lesões de cárie em radiografias de dentes decíduos. Portanto, demonstra uma ampla aplicabilidade clínica.

## REFERÊNCIAS

1. Leite AF, Vasconcelos KF, Willems H, Jacobs R. Radiomics and Machine Learning in Oral Healthcare. *Proteomics Clin Appl*. 2020 May;14(3):e1900040.
2. Hung KF, Yeung AWK, Bornstein MM, Schwendicke F. Personalized dental medicine, artificial intelligence, and their relevance for dentomaxillofacial imaging. *Dentomaxillofac Radiol*. 2023 Jan 1;52(1):20220335.
3. Thrall JH, Li X, Li Q, Cruz C, Do S, Dreyer K, et al. Artificial intelligence and machine learning in radiology: opportunities, challenges, pitfalls, and criteria for success. *J Am Coll Radiol* 2018; 15(3 Pt B): 504–8.
4. Hartoonian S, Hosseini M, Yousefi I, Mahdian M, Ghazizadeh Ahsaie M. Applications of artificial intelligence in dentomaxillofacial imaging-a systematic review. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2024 Jan 3:S2212-4403(23)01566-3.
5. Pauwels R. A brief introduction to concepts and applications of artificial intelligence in dental imaging. *Oral Radiol*. 2021 Jan;37(1):153-160.
6. Ali H, Mohsen F, Shah Z. Improving diagnosis and prognosis of lung cancer using vision transformers: a scoping review. *BMC Med Imaging*. 2023 Sep 15;23(1):129.
7. ChatGPT General FAQ. (n.d.). [WWW Document]. Disponível em: <https://help.openai.com/en/articles/6783457-chatgpt-general-faq>.
8. Liu Z, Lin Y, Cao Y, Hu H, Wei Y, Zhang Z, Lin S, Guo B, 2021. Swin transformer: Hierarchical vision transformer using shifted windows, *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 10012–10022.
9. Papanastasiou G, Dikaios N, Huang J, Wang C, Yang G. Is Attention all You Need in Medical Image Analysis? A Review. *IEEE J Biomed Health Inform*. 2024 Mar;28(3):1398-1411.
10. Azad R, Kazerouni A, Heidari M, Aghdam EK, Molaei A, Jia Y, Jose A, Roy R, Merhof D. Advances in medical image analysis with vision Transformers: A comprehensive review. *Med Image Anal*. 2024 Jan;91:103000.

11. Liu Z, Lv Q, Yang Z, Li Y, Lee CH, Shen L. Recent progress in transformer-based medical image analysis. *Comput Biol Med.* 2023 Sep;164:107268.
12. Tricco AC, Lillie E, Zarin W, O'Brien KK, Colquhoun H, Levac D, et al. PRISMA Extension for Scoping Reviews (PRISMA-ScR): Checklist and Explanation. *Ann Intern Med.* 2 de outubro de 2018;169(7):467–73
13. PRISMA-P Group, Moher D, Shamseer L, Clarke M, Ghersi D, Liberati A, et al. Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. *Syst Rev.* Dezembro de 2015;4(1):1.
14. Peters MDJ, Godfrey CM, McInerney P, Soares CB, Khalil H, Parker D. The Joanna Briggs Institute reviewers' manual 2015: methodology for JBI scoping reviews [Internet]. 2015; [citado 2024 abr. 30] Disponível em: [http://joannabriggs.org/assets/docs/sumari/Reviewers-Manual\\_Methodology-for-JBI-Scoping-Reviews\\_2015\\_v2.pdf](http://joannabriggs.org/assets/docs/sumari/Reviewers-Manual_Methodology-for-JBI-Scoping-Reviews_2015_v2.pdf)
15. Foster ED, Deardorff A. Open Science Framework (OSF). *jmla* [Internet]. 4 de abril de 2017; 105(2). Disponível em: <http://jmla.pitt.edu/ojs/jmla/article/view/88>
16. Ouzzani M, Hammady H, Fedorowicz Z, Elmagarmid A. Rayyan—a web and mobile app for systematic reviews. *Syst Rev.* dezembro de 2016;5(1):210.
17. Cao D, Cai B, Liu M. FlowgateUNet: Dental CT image segmentation network based on FlowFormer and gated attention. *SIViP.* 2024 Mar;18(2):1175–82.
18. Lv J, Zhang L, Xu J, Li W, Li G, Zhou H. Automatic segmentation of mandibular canal using transformer based neural networks. *Front Bioeng Biotechnol.* 2023 Nov 17;11:1302524.
19. Chen Z, Chen S, Hu F. CTA-UNet: CNN-transformer architecture UNet for dental CBCT images segmentation. *Phys Med Biol.* 2023 Sep 7;68(17):175042.
20. Ying S, Wang B, Zhu H, Liu W, Huang F. Caries segmentation on tooth X-ray images with a deep network. *Journal of Dentistry.* 2022 Apr;119:104076.
21. Zhou X, Yu G, Yin Q, Yang J, Sun J, Lv S, et al. Tooth Type Enhanced Transformer for Children Caries Diagnosis on Dental Panoramic Radiographs. *Diagnostics.* 2023 Feb 12;13(4):689.

22. Sheng C, Wang L, Huang Z, Wang T, Guo Y, Hou W, et al. Transformer-Based Deep Learning Network for Tooth Segmentation on Panoramic Radiographs. *J Syst Sci Complex*. 2023 Feb;36(1):257-72.
23. Vinayahalingam S, Van Nistelrooij N, Van Ginneken B, Bressen K, Tröltzsch D, Heiland M, et al. Detection of mandibular fractures on panoramic radiographs using deep learning. *Sci Rep*. 2022 Nov 15;12(1):19596.
24. Dujic H, Meyer O, Hoss P, Wölfle UC, Wülk A, Meusburger T, et al. Automated Detection of Periodontal Bone Loss on Periapical Radiographs by Vision Transformer Networks. *Diagnostics*. 2023 Nov 29;13(23):3562.
25. Ghafoor A, Moon SY, Lee B. Multiclass Segmentation Using Teeth Attention Modules for Dental X-Ray Images. *IEEE Access*. 2023;11:123891–903.
26. Kaya MC. Dental panoramic and bitewing X-ray image segmentation using u-net and transformer networks. MS thesis. Middle East Technical University, 2023.
27. Kanwal M, Ur Rehman MM, Farooq MU, Chae DK. Mask-Transformer-Based Networks for Teeth Segmentation in Panoramic Radiographs. *Bioengineering*. 2023 Jul 17;10(7):843.
28. Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. Attention is All you Need. *Advances in neural information processing systems*. 2017; 30.
29. Minaee S, Boykov Y, Porikli F, Plaza A, Kehtarnavaz N, Terzopoulos D. Image Segmentation Using Deep Learning: A Survey [Internet]. *arXiv*; 2020 [citado 13 de maio de 2024]. Disponível em: <http://arxiv.org/abs/2001.05566>
30. Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, et al. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale [Internet]. *arXiv*; 2021 [citado 13 de maio de 2024]. Disponível em: <http://arxiv.org/abs/2010.11929>
31. Gao S, Li X, Li X, Li Z, Deng Y. Transformer based tooth classification from cone-beam computed tomography for dental charting. *Computers in Biology and Medicine*. Setembro de 2022;148:105880.
32. Cheng M, Zhang X, Wang J, Yang Y, Li M, Zhao H, et al. Prediction of orthognathic surgery plan from 3D cephalometric analysis via deep learning. *BMC Oral Health*. 2023 Mar 18;23(1):161.

33. Li Y, Zeng G, Zhang Y, Wang J, Jin Q, Sun L, et al. AGMB-Transformer: Anatomy-Guided Multi-Branch Transformer Network for Automated Evaluation of Root Canal Therapy. *IEEE J Biomed Health Inform.* 2022 Apr;26(4):1684–95.
34. Chen J, Lu Y, Yu Q, Luo X, Adeli E, Wang Y, et al. TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation [Internet]. *arXiv*; 2021 [cited 2024 May 1]. Available from: <http://arxiv.org/abs/2102.04306>

## PRESS RELEASE

Na Radiologia Odontológica, os exames de imagem são essenciais para visualizar estruturas não observáveis durante o exame clínico. Além das radiografias bidimensionais convencionais, os cirurgiões-dentistas também têm à disposição exames tridimensionais, como a tomografia computadorizada de feixe cônico. Contudo, a análise manual desses exames pode ser demorada e sujeita a erros. Nesse contexto, a inteligência artificial (IA), especialmente os modelos de aprendizado profundo (deep learning), desempenha um papel crucial como auxiliar na detecção, classificação de doenças, segmentação de imagens e automação de processos do diagnóstico, funcionando como uma segunda opinião para os radiologistas. Essa automação é viável graças à compatibilidade das imagens geradas com a visão computacional. A partir daí, observou-se a possibilidade de uso de redes neurais convolucionais para auxiliar nas diversas tarefas diagnósticas. Mais recentemente, foram introduzidos na visão computacional as redes transformers, porém aparentemente ainda pouco explorada no campo da Radiologia quando comparada às redes neurais convolucionais. Uma revisão de escopo foi realizada para avaliar a aplicação dessas redes no diagnóstico de lesões dentárias e na região maxilofacial. A pesquisa abrangeu diversas bases de dados e literatura cinzenta, culminando na seleção de 11 artigos. Esses estudos, que utilizaram diferentes tipos de exames de imagem como Radiografia Panorâmica e Tomografia Computadorizada, demonstraram consistentemente os benefícios das redes neurais *Transformer*. Esta abordagem provou ser eficaz na identificação de várias condições, tornando-se uma ferramenta valiosa para o diagnóstico odontológico. Ao facilitar a detecção de lesões importantes, a rede neural Transformer se destaca como um recurso significativo na prática diagnóstica da Radiologia Odontológica, proporcionando resultados precisos e eficientes.



## APÊNDICES

### Apêndice 1 - Estratégia de busca em cada base de dado.

Bases de dados	Pesquisa (2024-01-16)	Referências (n)
<b>PubMed</b>	(((("dental health services"[MeSH Terms] OR ("dental"[All Fields] AND "health"[All Fields] AND "services"[All Fields]) OR "dental health services"[All Fields] OR "dental"[All Fields] OR "dentally"[All Fields] OR "dentals"[All Fields]) OR ("dentistry"[MeSH Terms] OR "dentistry"[All Fields]) OR ("neck"[MeSH Terms] OR "neck"[All Fields]) OR ("head"[MeSH Terms] OR "head"[All Fields]) OR "buccal"[All Fields] OR "buccally"[All Fields] OR ("mouth"[MeSH Terms] OR "mouth"[All Fields] OR "oral"[All Fields]) OR ("jaw"[MeSH Terms] OR "jaw"[All Fields] OR "jaws"[All Fields]) OR ("maxilla"[MeSH Terms] OR "maxilla"[All Fields] OR "maxillae"[All Fields] OR "maxillas"[All Fields]) OR ("mandible"[MeSH Terms] OR "mandible"[All Fields] OR "mandibles"[All Fields]) OR ("tooth"[MeSH Terms] OR "teeth"[All Fields] OR "tooth"[All Fields] OR "teeth"[All Fields] OR "teeths"[All Fields]) OR ("intraoral"[All Fields] OR "intraorally"[All Fields]) OR ("face"[MeSH Terms] OR "face"[All Fields] OR "facial"[All Fields] OR "facials"[All Fields]) OR ("intraoral"[All Fields] OR "intraorally"[All Fields] OR "intra-oral"[All Fields] OR "intra oral"[All Fields]) OR ("periapical"[All Fields] OR "periapically"[All Fields] OR "periapicals"[All Fields]) OR ("extraoral"[All Fields] OR "extraorally"[All Fields] OR "extra-oral"[All Fields] OR "extra oral"[All Fields]) OR ("radiography, bitewing"[MeSH Terms] OR ("radiography"[All Fields] AND "bitewing"[All Fields]) OR "bitewing radiography"[All Fields]) OR ("radiography, dental, digital"[MeSH Terms] OR ("radiography, panoramic"[MeSH Terms] OR ("radiography"[All Fields] AND "panoramic"[All Fields]) OR "panoramic radiography"[All Fields] OR ("panoramic"[All Fields] AND "radiographies"[All Fields]) OR "panoramic radiographies"[All Fields] OR "Pantomography" OR "Pantomographies" OR "Orthopantomography" OR "Orthopantomographies")) AND (("chatgpt") OR ("transformer"[All Fields] OR "transformers"[All Fields]))) AND (("diagnostic imaging"[MeSH Subheading] OR ("diagnostic"[All Fields] AND "imaging"[All Fields]) OR "diagnostic imaging"[All Fields]) OR ("radiography"[MeSH Terms] OR "radiography"[All Fields] OR "radiographies"[All Fields] OR "radiographys"[All Fields]) OR ("radiography, dental"[MeSH Terms] OR ("image"[All Fields] OR "imaged"[All Fields] OR "imager"[All Fields] OR "imagers"[All Fields] OR "images"[All Fields] OR "imaging"[All Fields] OR "imagings"[All Fields]) OR ("diagnostic imaging"[MeSH Subheading] OR ("diagnostic"[All Fields] AND "imaging"[All Fields]) OR "diagnostic imaging"[All Fields]) OR ("cone beam computed tomography"[MeSH Terms] OR ("cone	<b>308</b>

	<p>beam"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "cone beam computed tomography"[All Fields] OR ("cone"[All Fields] AND "beam"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "CBCT"[All Fields] OR ("cone"[All Fields] AND "beam"[All Fields] AND "ct"[All Fields] AND "scan"[All Fields]) OR "cone beam ct scan"[All Fields] OR ("volume"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "volume computed tomography"[All Fields] OR ("tomography, spiral computed"[MeSH Terms] OR ("tomography"[All Fields] AND "spiral"[All Fields] AND "computed"[All Fields]) OR "spiral computed tomography"[All Fields] OR ("volumetric"[All Fields] AND "ct"[All Fields]) OR "volumetric ct"[All Fields] OR ("cone"[All Fields] AND "beam"[All Fields] AND "cat"[All Fields] AND "scan"[All Fields]) OR "cone beam cat scan"[All Fields]) OR ("magnetic resonance imaging"[MeSH Terms] OR ("magnetic"[All Fields] AND "resonance"[All Fields] AND "imaging"[All Fields]) OR "magnetic resonance imaging"[All Fields] OR ("magnetic"[All Fields] AND "resonance"[All Fields] AND "images"[All Fields]) OR "magnetic resonance images"[All Fields] OR ("nmr"[All Fields] AND "imaging"[All Fields]) OR "nmr imaging"[All Fields] OR ("nmr"[All Fields] AND "tomography"[All Fields]) OR "nmr tomography"[All Fields] OR ("mr"[All Fields] AND "tomography"[All Fields]) OR "mr tomography"[All Fields] OR ("steady"[All Fields] AND "state"[All Fields] AND "free"[All Fields] AND "precession"[All Fields] AND "mri"[All Fields]) OR "steady state free precession mri"[All Fields] OR "Zeugmatography"[All Fields] OR ("magnetization"[All Fields] AND "transfer"[All Fields] AND "contrast"[All Fields] AND "imaging"[All Fields]) OR "magnetization transfer contrast imaging"[All Fields] OR ("mri"[All Fields] AND ("scan"[All Fields] OR "scans"[All Fields])) OR "mri scan"[All Fields] OR "mri scans"[All Fields] OR ("proton"[All Fields] AND "spin"[All Fields] AND "tomography"[All Fields]) OR "proton spin tomography"[All Fields] OR ("functional"[All Fields] AND "mri"[All Fields]) OR "functional mri"[All Fields] OR "fMRI"[All Fields] OR ("spin"[All Fields] AND "echo"[All Fields] AND ("imaging"[All Fields] OR "imagings"[All Fields])) OR "spin echo imaging"[All Fields] OR ("multidetector computed tomography"[MeSH Terms] OR ("multidetector"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "multidetector computed tomography"[All Fields] OR "computed tomography multidetector"[All Fields] OR ("multisection"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "multisection computed tomography"[All Fields] OR "dual-energy ct"[All Fields] OR "multidetector row ct"[All Fields] OR (("perfusable"[All Fields] OR "perfusate"[All Fields] OR "perfusates"[All Fields] OR "perfuse"[All Fields] OR "perfused"[All Fields] OR "perfuses"[All Fields] OR "perfusing"[All Fields] OR "perfusion"[MeSH Terms] OR "perfusion"[All Fields] OR "perfusions"[All Fields]) AND ("ct"[All Fields])) OR "perfusion ct"[All Fields] OR ("multislice"[All Fields] AND "computed"[All Fields] AND "tomography"[All Fields]) OR "multislice computed tomography"[All Fields] OR "multidetector row computed tomography"[All Fields]))</p>	
--	---	--

<p><b>Embase</b></p>	<p>('dental health services'/exp OR 'dental health services' OR ((('dental'/exp OR 'dental') AND ('health'/exp OR 'health') AND 'services') OR 'dental'/exp OR 'dental' OR 'dentally' OR 'dentals' OR 'dentistry'/exp OR 'dentistry' OR 'neck'/exp OR 'neck' OR 'head'/exp OR 'head' OR 'buccal' OR 'buccally' OR 'mouth'/exp OR 'mouth' OR 'oral' OR 'jaw'/exp OR 'jaw' OR 'jaws'/exp OR 'jaws' OR 'maxilla'/exp OR 'maxilla' OR 'maxillae' OR 'maxillas' OR 'mandible'/exp OR 'mandible' OR 'mandibles' OR 'tooth'/exp OR 'tooth' OR 'teeth' OR 'teeth'/exp OR 'teeth' OR 'tooths' OR 'intraoral' OR 'intraorally' OR 'intra-oral' OR 'intra oral' OR 'face'/exp OR 'face' OR 'facial' OR 'facials' OR 'periapical' OR 'periapically' OR 'periapicals' OR 'extraoral' OR 'extraorally' OR 'extra-oral' OR 'extra oral' OR 'bitewing radiography'/exp OR 'bitewing radiography' OR (('radiography'/exp OR 'radiography') AND 'bitewing') OR 'digital dental radiography'/exp OR 'digital dental radiography' OR 'panoramic radiography'/exp OR 'panoramic radiography' OR (('radiography'/exp OR 'radiography') AND 'panoramic') OR ('panoramic' AND 'radiographies') OR 'panoramic radiographies' OR 'pantomography'/exp OR 'pantomography' OR 'pantomographies' OR 'orthopantomography'/exp OR 'orthopantomographies') AND ('chatgpt'/exp OR 'chatgpt' OR 'transformer'/exp OR 'transformer' OR 'transformers') AND ('diagnostic imaging'/exp OR 'diagnostic imaging' OR (('diagnostic'/exp OR 'diagnostic') AND ('imaging'/exp OR 'imaging')) OR 'radiography'/exp OR 'radiography' OR 'radiographies' OR 'radiographys' OR 'dental radiography'/exp OR 'dental radiography' OR 'image'/exp OR 'image' OR 'imaged' OR 'imager'/exp OR 'imager' OR 'imagers' OR 'images' OR 'imaging'/exp OR 'imaging' OR 'imagings' OR 'cone beam computed tomography'/exp OR 'cone beam computed tomography' OR ('cone beam' AND 'computed' AND ('tomography'/exp OR 'tomography')) OR ('cone' AND 'beam' AND 'computed' AND ('tomography'/exp OR 'tomography')) OR 'cbct' OR ('cone' AND 'beam' AND ('ct'/exp OR 'ct') AND 'scan') OR 'cone beam ct scan' OR (('volume'/exp OR 'volume') AND 'computed' AND ('tomography'/exp OR 'tomography')) OR 'volume computed tomography'/exp OR 'volume computed tomography' OR 'spiral computed tomography'/exp OR 'spiral computed tomography' OR (('tomography'/exp OR 'tomography') AND 'spiral' AND 'computed') OR ('volumetric' AND ('ct'/exp OR 'ct')) OR 'volumetric ct'/exp OR 'volumetric ct' OR ('cone' AND 'beam' AND ('cat'/exp OR 'cat') AND 'scan') OR 'cone beam cat scan' OR 'magnetic resonance imaging'/exp OR 'magnetic resonance imaging' OR ('magnetic' AND ('resonance'/exp OR 'resonance') AND ('imaging'/exp OR 'imaging')) OR ('magnetic' AND ('resonance'/exp OR 'resonance') AND 'images') OR 'magnetic resonance images' OR (('nmr'/exp OR 'nmr') AND ('imaging'/exp OR 'imaging')) OR 'nmr imaging'/exp OR 'nmr imaging' OR (('nmr'/exp OR 'nmr') AND ('tomography'/exp OR 'tomography')) OR 'nmr tomography' OR (('mr'/exp OR 'mr') AND ('tomography'/exp OR 'tomography')) OR 'mr tomography' OR ('steady' AND ('state'/exp OR 'state') AND 'free' AND 'precession' AND ('mri'/exp OR 'mri')) OR 'steady state free precession mri'</p>	<p><b>380</b></p>
----------------------	--	-------------------

	<p>OR 'zeugmatography' OR (('magnetization'/exp OR 'magnetization') AND ('transfer'/exp OR 'transfer') AND ('contrast'/exp OR 'contrast') AND ('imaging'/exp OR 'imaging')) OR 'magnetization transfer contrast imaging' OR (('mri'/exp OR 'mri') AND ('scan' OR 'scans')) OR 'mri scan' OR 'mri scans' OR (('proton'/exp OR 'proton') AND ('spin'/exp OR 'spin') AND ('tomography'/exp OR 'tomography')) OR 'proton spin tomography' OR ('functional' AND ('mri'/exp OR 'mri')) OR 'functional mri'/exp OR 'functional mri' OR 'fmri'/exp OR 'fmri' OR (('spin'/exp OR 'spin') AND ('echo'/exp OR 'echo') AND ('imaging'/exp OR 'imaging' OR 'imagings')) OR 'spin echo imaging'/exp OR 'spin echo imaging' OR 'multidetector computed tomography'/exp OR 'multidetector computed tomography' OR ('multidetector' AND 'computed' AND ('tomography'/exp OR 'tomography')) OR 'computed tomography multidetector' OR ('multisection' AND 'computed' AND ('tomography'/exp OR 'tomography')) OR 'multisection computed tomography' OR 'dual-energy ct'/exp OR 'dual-energy ct' OR 'multidetector row ct'/exp OR 'multidetector row ct' OR (('perfusable' OR 'perfusate' OR 'perfusates' OR 'perfuse' OR 'perfused' OR 'perfuses' OR 'perfusing' OR 'perfusion'/exp OR 'perfusion' OR 'perfusions') AND ('ct'/exp OR 'ct')) OR 'perfusion ct' OR ('multislice' AND 'computed' AND ('tomography'/exp OR 'tomography')) OR 'multislice computed tomography'/exp OR 'multislice computed tomography' OR 'multidetector row computed tomography'/exp OR 'multidetector row computed tomography')</p>	
<p><b>Scopus</b></p>	<p>TITLE-ABS-KEY ( ( "dental health services" OR "dental" OR "dentally" OR "dentals" OR "dentistry" OR "neck" OR "head" OR "buccal" OR "buccally" OR "mouth" OR "oral" OR "jaw" OR "jaws" OR "maxilla" OR "maxillae" OR "maxillas" OR "mandible" OR "mandibles" OR "tooth" OR "teeth" OR "teeth" OR "tooths" OR "intraoral" OR "intraorally" OR "intra-oral" OR "intra oral" OR "face" OR "facial" OR "facials" OR "periapical" OR "periapically" OR "periapicals" OR "extraoral" OR "extraorally" OR "extra-oral" OR "extra oral" OR "bitewing radiography" OR "digital dental radiography" OR "panoramic radiography" OR "panoramic radiographies" OR "pantomography" OR "pantomographies" OR "orthopantomography" OR "orthopantomographies" ) AND ( "chatgpt" OR "transformer" OR "transformers" ) AND ( "diagnostic imaging" OR "radiography" OR "radiographies" OR "radiographys" OR "dental radiography" OR "image" OR "imaged" OR "imager" OR "imagers" OR "images" OR "imaging" OR "imagings" OR "cone beam computed tomography" OR "cbct" OR "cone beam ct scan" OR "volume computed tomography" OR "spiral computed tomography" OR "volumetric ct" OR "cone beam cat scan" OR "magnetic resonance imaging" OR "magnetic resonance images" OR "nmr imaging" OR "nmr tomography" OR "mr tomography" OR "steady state free precession mri" OR "zeugmatography" OR "magnetization transfer contrast imaging" OR "mri scan" OR "mri scans" OR "proton spin tomography" OR "functional mri" OR "fmri" OR "spin echo imaging" OR "multidetector computed tomography" OR "computed tomography multidetector" OR</p>	<p><b>2161</b></p>

	"multisection computed tomography" OR "dual-energy ct" OR "multidetector row ct" OR "perfusion ct" OR "multislice computed tomography" OR "multidetector row computed tomography" ) )	
<b>Web of Science</b>	ALL=((("dental health services" OR "dental" OR "distally" OR "denials" OR "dentistry" OR "neck" OR "head" OR "buccal" OR "buccalis" OR "mouth" OR "oral" OR "jaw" OR "jaws" OR "maxilla" OR "maxillae" OR "maxillae" OR "mandible" OR "mandibles" OR "tooth" OR "tenths" OR "teeth" OR "toothy" OR "intraoral" OR "intraportally" OR "intra-oral" OR "intra oral" OR "face" OR "facial" OR "faciale" OR "periapical" OR "periapicaly" OR "periapical" OR "extraoral" OR "extradurally" OR "extra-oral" OR "extra oral" OR "bitewing radiography" OR "digital dental radiography" OR "panoramic radiography" OR "panoramic radiographies" OR "pantomograph" OR "pantomographie" OR "orthopantomographs" OR "orthopantomographic") (All Fields) and ("chatgpt" OR "transformer" OR "transformers") (All Fields) and ("diagnostic imaging" OR "radiography" OR "radiographies" OR "radiography" OR "dental radiography" OR "image" OR "imaged" OR "imager" OR "imagers" OR "images" OR "imaging" OR "imagings" OR "cone beam computed tomography" OR "CBCT" OR "cone beam ct scan" OR "volume computed tomography" OR "spiral computed tomography" OR "volumetric ct" OR "cone beam cat scan" OR "magnetic resonance imaging" OR "magnetic resonance images" OR "nmr imaging" OR "nmr tomography" OR "mr tomography" OR "steady state free precession mri" OR "zeugmatographic" OR "magnetization transfer contrast imaging" OR "mri scan" OR "mri scans" OR "proton spin tomography" OR "functional mri" OR "fMRI" OR "spin echo imaging" OR "multidetector computed tomography" OR "computed tomography multidetector" OR "multisection computed tomography" OR "dual-energy ct" OR "multidetector row ct" OR "perfusion ct" OR "multislice computed tomography" OR "multidetector row computed tomography") (All Fields))	<b>1153</b>
<b>Lilacs (Portuguese and Spanish)</b>	((("dental health services" OR "dental" OR "dentally" OR "dentals" OR "dentistry" OR "neck" OR "head" OR "buccal" OR "buccally" OR "mouth" OR "oral" OR "jaw" OR "jaws" OR "maxilla" OR "maxillae" OR "maxillas" OR "mandible" OR "mandibles" OR "tooth" OR "teeths" OR "teeth" OR "tooths" OR "intraoral" OR "intraorally" OR "intra-oral" OR "intra oral" OR "face" OR "facial" OR "facials" OR "periapical" OR "periapically" OR "periapicals" OR "extraoral" OR "extraorally" OR "extra-oral" OR "extra oral" OR "bitewing radiography" OR "digital dental radiography" OR "panoramic radiography" OR "panoramic radiographies" OR "Pantomography" OR "Pantomographies" OR "Orthopantomography" OR "Orthopantomographies" OR "serviços de saúde bucal" OR "servicios de salud dental" OR "odontologia" OR "odontologia" OR "pescoço" OR "cuello" OR "cabeça" OR "cabeza" OR "boca" OR "arcada osseodentária" OR "maxilares" OR "maxila" OR "maxilar" OR "mandíbula" OR	<b>4</b>

	<p>"dente" OR "diente" OR "face" OR "cara")) AND ((("transformer" OR "transformers" OR "ChatGPT") ) AND (("diagnostic imaging" OR "radiography" OR "radiographies" OR "radiographys" OR "dental radiography" OR "image" OR "imaged" OR "imager" OR "imagers" OR "images" OR "imaging" OR "imagings" OR "cone beam computed tomography" OR "CBCT" OR "cone beam ct scan" OR "volume computed tomography" OR "spiral computed tomography" OR "volumetric ct" OR "cone beam cat scan" OR "magnetic resonance imaging" OR "magnetic resonance images" OR "nmr imaging" OR "nmr tomography" OR "mr tomography" OR "steady state free precession mri" OR "Zeugmatography" OR "magnetization transfer contrast imaging" OR "mri scan" OR "mri scans" OR "proton spin tomography" OR "functional mri" OR "fMRI" OR "spin echo imaging" OR "multidetector computed tomography" OR "computed tomography multidetector" OR "multisection computed tomography" OR "dual-energy ct" OR "multidetector row ct" OR "perfusion ct" OR "multislice computed tomography" OR "multidetector row computed tomography" OR "radiografia interproximal" OR "radiografia de mordida lateral" OR "radiografia dentária digital" OR "radiografía dental digital" OR "radiografia panorâmica" OR "radiografia panorâmica" OR "radiografia" OR "radiografia" OR "radiografia dentária" OR "radiografia dental" OR "Tomografia computadorizada de feixe cônico" OR "tomografia computarizada de haz cónico" OR "tomografia computadorizada espiral" OR "tomografia computarizada espiral" OR "imageamento por ressonância magnética" OR "imagen por resonancia magnética" OR "tomografia computadorizada multidetectores" OR "tomografia computarizada multidetector")) )</p>	
<p><b>IEEE Explore</b></p>	<p>("dental health services" OR "dental" OR "dentally" OR "dentals" OR "dentistry" OR "neck" OR "head" OR "buccal" OR "buccally" OR "mouth" OR "oral" OR "jaw" OR "jaws" OR "maxilla" OR "maxillae" OR "maxillas" OR "mandible" OR "mandibles" OR "tooth" OR "teeths" OR "teeth" OR "tooths" OR "intraoral" OR "intraorally" OR "intra-oral" OR "intra oral" OR "face" OR "facial" OR "facials" OR "periapical" OR "periapically" OR "periapicals" OR "extraoral" OR "extraorally" OR "extra-oral" OR "extra oral" OR "bitewing radiography" OR "digital dental radiography" OR "panoramic radiography" OR "panoramic radiographies" OR "Pantomography" OR "Pantomographies" OR "Orthopantomography" OR "Orthopantomographies") AND ("chatgpt" OR "transformer" OR "transformers") AND ("diagnostic imaging" OR "radiography" OR "radiographies" OR "radiographys" OR "dental radiography" OR "image" OR</p>	<p><b>1072</b></p>

	<p>"imaged" OR "imager" OR "imagers" OR "images" OR "imaging" OR "imagings" OR "cone beam computed tomography" OR "CBCT" OR "cone beam ct scan" OR "volume computed tomography" OR "spiral computed tomography" OR "volumetric ct" OR "cone beam cat scan" OR "magnetic resonance imaging" OR "magnetic resonance images" OR "nmr imaging" OR "nmr tomography" OR "mr tomography" OR "steady state free precession mri" OR "Zeugmatography" OR "magnetization transfer contrast imaging" OR "mri scan" OR "mri scans" OR "proton spin tomography" OR "functional mri" OR "fMRI" OR "spin echo imaging" OR "multidetector computed tomography" OR "computed tomography multidetector" OR "multisection computed tomography" OR "dual-energy ct" OR "multidetector row ct" OR "perfusion ct" OR "multislice computed tomography" OR "multidetector row computed tomography")</p> <p>(searched in all metadata)</p>	
<b>Literatura cinzenta</b>		
<b>ProQuest</b>	<p>noft(("dental health services" OR "dental" OR "dentally" OR "dentals" OR "dentistry" OR "neck" OR "head" OR "buccal" OR "buccally" OR "mouth" OR "oral" OR "jaw" OR "jaws" OR "maxilla" OR "maxillae" OR "maxillas" OR "mandible" OR "mandibles" OR "tooth" OR "teeths" OR "teeth" OR "tooths" OR "intraoral" OR "intraorally" OR "intra-oral" OR "intra oral" OR "face" OR "facial" OR "facials" OR "periapical" OR "periapically" OR "periapicals" OR "extraoral" OR "extraorally" OR "extra-oral" OR "extra oral" OR "bitewing radiography" OR "digital dental radiography" OR "panoramic radiography" OR "panoramic radiographies" OR "Pantomography" OR "Pantomographies" OR "Orthopantomography" OR "Orthopantomographies") ) AND noft(("chatgpt" OR "transformer" OR "transformers") ) AND noft(("diagnostic imaging" OR "radiography" OR "radiographies" OR "radiographys" OR "dental radiography" OR "image" OR "imaged" OR "imager" OR "imagers" OR "images" OR "imaging" OR "imagings" OR "cone beam computed tomography" OR "CBCT" OR "cone beam ct scan" OR "volume computed tomography" OR "spiral computed tomography" OR "volumetric ct" OR "cone beam cat scan" OR "magnetic resonance imaging" OR "magnetic resonance images" OR "nmr imaging" OR "nmr tomography" OR "mr tomography" OR "steady state free precession mri" OR "Zeugmatography" OR "magnetization transfer contrast imaging" OR "mri scan" OR "mri scans" OR "proton spin tomography" OR "functional mri" OR "fMRI" OR "spin echo imaging" OR "multidetector computed tomography" OR "computed tomography multidetector" OR "multisection computed tomography" OR "dual-energy ct" OR "multidetector row ct" OR "perfusion ct" OR "multislice computed tomography" OR "multidetector row computed tomography") )</p>	<b>3</b>

<b>Google Scholar</b>	("jaw" OR "jaws" OR "maxilla" OR "maxillae" OR "maxillas" OR "mandible" OR "mandibles" OR "tooth" OR "teeths" OR "teeth" OR "tooths" OR "intraoral" OR "intraorally" OR "intra-oral" OR "intra oral") AND ("chatgpt" OR "transformer" OR "transformers") AND ("periapical" OR "periapically" OR "periapicals" OR "extraoral" OR "extraorally" OR "extra-oral" OR "extra oral" OR "bitewing radiography" OR "digital dental radiography" OR "panoramic radiography" OR "panoramic radiographs" OR "Pantomography" OR "Pantomographies" OR "Orthopantomography" OR "Orthopantomographs") "diagnostic imaging" OR "radiography" OR "radiographies" OR "radiographys" OR "dental radiography" OR "image" OR "imaged" OR "imager" OR "imagers" OR "images" OR "imaging" OR "imagings" OR "cone beam computed tomography" OR "CBCT" OR "cone beam ct scan" OR "volume computed tomography" OR "spiral computed tomography" OR "volumetric ct" OR "cone beam cat scan" OR "magnetic resonance imaging" OR "magnetic resonance images")	<b>101 primeiros ordenados por relevância</b>
-----------------------	---	---

## Apêndice 2 - estudos excluídos e motivos para exclusão

<b>Autor e ano</b>	<b>Razões para exclusão</b>
Almalki & Latecki, 2023	Não teve como foco a utilização de <i>Transformer</i>
Joo, Moon & Choi, 2023	Não utilizou <i>Transformer</i>
Ozsari et al., 2023	Não teve como foco a utilização de <i>Transformer</i>
Li et al., 2022	O <i>Transformer</i> não foi utilizado para diagnóstico
Cheng et al., 2023	O <i>Transformer</i> não foi utilizado para diagnóstico



## ANEXO

### Anexo 1 – Protocolo Registrado no OSF



#### SCOPING REVIEW PROTOCOL

REVIEW TITLE AND TIMESCALE		
<b>1. REVIEW TITLE</b>		
<i>Give the working title of the review. Identify the report as a scoping review.</i>		
Use of neural transformer network in diagnostic imaging in dentistry: a scoping review		
<b>2. ORIGINAL LANGUAGE TITLE</b> (somente preencher se for fazer a revisão em outro idioma que não o inglês)		
<i>For reviews in languages other than English, this field should be used to enter the title in the language of the review.</i>		
<b>3. ANTICIPATED OR ACTUAL START DATE</b>	<b>4. ANTICIPATED COMPLETION DATE</b>	<b>5. SEARCH DATE</b>
June 2023	May 2024	January 2023
STAGE OF REVIEW AT TIME OF THIS SUBMISSION		
<b>6. REVIEW STAGE</b>	<b>STARTED</b>	<b>COMPLETED</b>
Stage 1: identifying the research question	<input type="checkbox"/>	x
Stage 2: identifying relevant studies	<input type="checkbox"/>	x
Stage 3: study selection	<input type="checkbox"/>	x
Stage 4: charting the data	<input type="checkbox"/>	x
Stage 5: collating, summarizing, and reporting the results	<input type="checkbox"/>	x
REVIEW TEAM DETAILS		
<b>7. NAMED CONTACT / SALUTATION FOR CORRESPONDENCE</b>	<b>8. NAMED CONTACT EMAIL</b>	
Ms. Mayra Cristina Ribeiro de Lima	lima.mayra@aluno.unb.br	
<b>9. NAMED CONTACT ADDRESS</b>		
Quadra 302 Conjunto 6 Lote 1 Bloco B Apartamento 503, Samambaia Sul. Brasília, Distrito Federal.		
<b>10. NAMED CONTACT PHONE NUMBER</b>		
+55 61 984359438		

Template Scoping Review 2023. This protocol is based on Tricco et al. PRISMA Extension for Scoping Reviews (PRISMA ScR): Checklist and Explanation. *Ann Intern Med.* 2018;169:467–473 and Arksey H, O'Malley L: Scoping studies: towards a methodological framework. *Int J Social Res Method.* 2005, 8: 19-31.



11. ORGANIZATIONAL AFFILIATION OF THE REVIEW / WEBSITE ADDRESS
University of Brasilia / <a href="https://unb.br">https://unb.br</a>

12. REVIEW TEAM MEMBERS AND THEIR ORGANIZATIONAL AFFILIATIONS				
TITLE	NAME	AFFILIATION	CONTACT (E-MAIL)	CONTRIBUTIONS*
Professor, Dr, Mr., Ms., Miss, Mrs.	Complete name	Organizational affiliations of each member of the review team	Contact email of the authors	Contributions of the authors*
Ms.	Mayra Cristina Ribeiro de Lima	University of Brasilia	lima.mayra@aluno.unb.br	1R
Ms.	Josué Miguel de Oliveira	Rio de Janeiro State University	josuemoliv@gmail.com	2R
Dr.	Nathália Ferrare Pinto	University of Brasilia	nathaliaferrare@gmail.com	E
Dr.	Adriano de Almeida de Lima	University of Brasilia	adriano.lima@unb.br	E
Dr.	Nilce Santos de Melo	University of Brasilia	nilcesantasmelo@gmail.com	E
Dr.	Cristine Miron Stefani	University of Brasilia	cmstefani@unb.br	E
Dr.	Ruben Pauwels	University of Aarhus	ruben.pauwels@aias.au.dk	E
Dr.	André Ferreira Leite	University of Brasilia	andreleite@unb.br	C

\*1R=First reviewer (Study conceptualization and design/ Search and selection/ Data collection/ Data analysis/ Manuscript preparation). 2R=Second Reviewer (Search and selection/ Data collection/ Data analysis/ Manuscript preparation). 3R=Third Reviewer (Data analysis). E=Expert (Study conceptualization and design/ Data analysis). C=Coordinator (Study conceptualization and design/ Data analysis).

All authors: Review of the manuscript.

13. Funding sources/sponsors (grant number)
There will be no financial support for this scoping review.

Template Scoping Review 2023. This protocol is based on Tricco et al. PRISMA Extension for Scoping Reviews (PRISMA ScR): Checklist and Explanation. *Ann Intern Med.* 2018;169:467–473 and Arksey H, O'Malley L: Scoping studies: towards a methodological framework. *Int J Social Res Method.* 2005, 8: 19-31.



<b>14. Conflicts of interest</b>
There is no potential conflict of interest that could benefit the authors of this scoping review.

<b>15. Collaborators</b>
<i>Give the name and affiliation of any individuals or organizations who are working on the review but who are not listed as review team members.</i>
There will be no collaborators for this scoping review.

## REVIEW METHODS

<b>16. RESEARCH QUESTION</b>
<i>Inform details of each item for the acronym PCC (Population, Concept, Context). Inform the design of included studies. Inform the review question.</i>
Population: people with hard tissue alterations in the jaws and face.
Concept: Neural Transformer Network for diagnosis
Context: Dental imaging diagnosis
Studies: Clinical trials (randomized or not), observational studies and systematic reviews.
<b>QUESTION:</b> What are the possible applications of neural transformer network for imaging diagnosis of hard tissue alterations in the jaws and face?

<b>17. STRATEGY TO IDENTIFY RELEVANT STUDIES</b>
<i>State the sources that will be searched (electronic databases; reference lists; hand-searching of key journals; existing networks; relevant organizations; and conferences). Inform any restrictions (e.g., Language or publication period).</i>
We will do an electronic search in databases: LILACS, Embase, PubMed/MEDLINE, SCOPUS, Web of Science, and IEEE Xplore to identify relevant studies. Furthermore, a gray literature search will be done using Google Scholar and ProQuest (Dissertations and Thesis). No language, time, or other restrictions will be defined.

## 18. SEARCH STRATEGY FOR PUBMED

SEARCH	QUERY	RESULTS
#3		
#2		
#1		

## 19. CONDITION OR DOMAIN BEING STUDIED

*Template Scoping Review 2023. This protocol is based on Tricco et al. PRISMA Extension for Scoping Reviews (PRISMA ScR): Checklist and Explanation. Ann Intern Med. 2018;169:467–473 and Arksey H, O'Malley L: Scoping studies: towards a methodological framework. Int J Social Res Method. 2005, 8: 19-31.*



*Give a short description of the disease, condition, or healthcare domain being studied.*

Imaging exams are widely used in dentistry and medicine either for diagnostic or follow-up purposes. The generated images bear a resemblance to computer vision, so the status of Transformers in medical imaging is questioned. One of the benefits of Transformers is that they tend to have large effective receptive fields, which is very useful in diagnostic imaging where it is important to focus not only on the area of interest but also on the surrounding tissues and organs when diagnosing a condition.<sup>1</sup> Becoming an innovative option in diagnostic imaging in orofacial radiology.

## 20. STUDY SELECTION

*Give summary criteria for the inclusion and exclusion of studies in the review. The preferred format includes details of both inclusion and exclusion criteria.*

*Example: Inclusion: adults with schizophrenia (as diagnosed using any recognized diagnostic criteria).*

*Exclusion: adolescents (under 18 years of age) and elderly people (over 70).*

### Population

Inclusion: people with hard tissue alterations in the jaws and face.

Exclusion: ex vivo studies.

### Concept

Inclusion: Neural Transformer Network for diagnosis

Exclusion: Studies that use other types of neural network other than Transformer

### Context

Inclusion: Dental imaging diagnosis

Exclusion: Diagnostic imaging outside the field of dentistry; use of exams for follow-up and not for diagnosis.

### Studies

Inclusion: Clinical trials (randomized or not), observational studies, diagnostic test studies and systematic reviews.

Exclusion: Non-human studies, Book chapters, opinions, letters, and conference abstracts.

## 21. DATA ITEMS FOR EXTRACTION

*List and define all variables for which data will be sought and any assumptions and simplifications made.*

Study characteristics (author(s), year, country, and type of study), diagnostic task, reference test, imaging modality, neural network model, dataset size (training/validation/testing), accuracy metrics

## 22. CHARTING THE DATA

*State the process that will be used for selecting studies (e.g., two independent reviewers) through each phase of the review (i.e., titles and abstracts reading, full-text reading). Describe any planned method of extracting data from reports (e.g., piloting forms, done independently, in duplicate) and any processes for obtaining and confirming data from investigators.*

The selection of studies will be carried out in two phases. In phase 1, two researchers (1R and 2R) will independently examine potentially relevant study titles and select

Template Scoping Review 2023. This protocol is based on Tricco et al. PRISMA Extension for Scoping Reviews (PRISMA ScR): Checklist and Explanation. *Ann Intern Med.* 2018;169:467–473 and Arksey H, O'Malley L: Scoping studies: towards a methodological framework. *Int J Social Res Method.* 2005, 8: 19-31.



articles that appear to meet the inclusion criteria. The same reviewers will independently read the abstracts of all previously selected articles. In phase 2, the two researchers will independently read the full text of all selected articles and exclude studies that do not meet the inclusion criteria. Any disagreements in any of the three phases will be resolved by discussion and mutual agreement between the two reviewers. If a consensus cannot be reached, a third author (3R) will be involved in making a final decision.

### 23. STRATEGY FOR COLLATING, SUMMARIZING, AND REPORTING THE RESULTS

*Provide details of the planned synthesis, including a rationale for the methods selected.*

The first investigator (1R) will collect the data from the selected articles. The second author (2R) will crosscheck all retrieved information for analysis. Results will be presented narratively. Results will be organized into categories for comprehension improvement. Figures and tables will be used to better represent data tendencies.

<b>24. DATABASES</b> <input checked="" type="checkbox"/> PubMed <input checked="" type="checkbox"/> EMBASE <input type="checkbox"/> Cochrane <input checked="" type="checkbox"/> LILACS <input checked="" type="checkbox"/> Web of Science <input checked="" type="checkbox"/> Scopus <input type="checkbox"/> Science Direct <input type="checkbox"/> CINAHL <input type="checkbox"/> Livivo <input checked="" type="checkbox"/> Other: IEEE Xplore	<b>25. ADDITIONAL LITERATURE</b> <input checked="" type="checkbox"/> Google Scholar web search (specify if limitations applied) <input type="checkbox"/> Hand searches of bibliographies from included studies <input type="checkbox"/> Experts <input checked="" type="checkbox"/> ProQuest (Dissertation and Theses) <input type="checkbox"/> Other:
<b>26. DATA MANAGEMENT</b>	
<input type="checkbox"/> Endnote <input type="checkbox"/> Refworks <input checked="" type="checkbox"/> Mendeley	<input type="checkbox"/> Zotero <input type="checkbox"/> Covidence <input checked="" type="checkbox"/> Other: Rayyan

## REVIEW GENERAL INFORMATION

### 27. HEALTH AREA OF THE SCOPING REVIEW

Dentistry

### 28. KEYWORDS

*Template Scoping Review 2023. This protocol is based on Tricco et al. PRISMA Extension for Scoping Reviews (PRISMA ScR): Checklist and Explanation. Ann Intern Med. 2018;169:467–473 and Arksey H, O'Malley L: Scoping studies: towards a methodological framework. Int J Social Res Method. 2005, 8: 19-31.*



*Give words or phrases that best describe the review. Example: systematic review; meta-analysis; recurrence*

scoping review; neural transformer network; diagnostic imaging; dentistry.

#### OTHER

#### PREVIOUS REVIEWS ABOUT THE SAME SUBJECT

REFERENCE: LI, Jun et al. Transforming medical imaging with Transformers? A comparative review of key properties, current progresses, and future perspectives. **Medical image analysis**, p. 102762, 2023.

#### CITE 5 STUDIES THAT YOU READ (ABOUT THIS TOPIC) BEFORE PREPARING THIS PROTOCOL

GAO, Shen et al. Transformer based tooth classification from cone-beam computed tomography for dental charting. **Computers in Biology and Medicine**, v. 148, p. 105880, 2022.

LIAN, Chunfeng et al. Multi-task dynamic transformer network for concurrent bone segmentation and large-scale landmark localization with dental CBCT. In: **Medical Image Computing and Computer Assisted Intervention–MICCAI 2020: 23rd International Conference, Lima, Peru, October 4–8, 2020, Proceedings, Part IV 23**. Springer International Publishing, 2020. p. 807-816.

SHI, Changrong; XIAO, Yongshun; CHEN, Zhiqiang. Dual-domain sparse-view CT reconstruction with Transformers. **Physica Medica**, v. 101, p. 1-7, 2022.

WILLEMINK, Martin J.; ROTH, Holger R.; SANDFORT, Veit. Toward foundational deep learning models for medical imaging in the new era of transformer networks. **Radiology: Artificial Intelligence**, v. 4, n. 6, p. e210284, 2022.

YING, Shunv et al. Caries segmentation on tooth X-ray images with a deep network. **Journal of Dentistry**, v. 119, p. 104076, 2022.

#### References:

- 1- LI, Jun et al. Transforming medical imaging with Transformers? A comparative review of key properties, current progresses, and future perspectives. **Medical image analysis**, p. 102762, 2023.