

Redes Neurais Convolucionais Aplicadas à Odontologia: Revisão Sistemática da Literatura

Maria Isabelly de Brito Rodrigues¹, Raila Moura de Sousa,
Bruno Vicente Alves de Lima², Iallen Gabio de Sousa Santos¹

¹Instituto Federal de Educação, Ciência e Tecnologia (IFPI)
Av. Rio dos Matos, s/n – Germano, 64260-000 – Piripiri – PI – Brasil

²Instituto Federal de Educação, Ciência e Tecnologia (IFMA)
Av. Antônio Guimarães, S/N - Olho D'Aguinha, Coelho Neto - MA, 65620-000 – Brasil

isabellybrt77@gmail.com, railamouraodonto@gmail.com

brunovicente.lima@ifma.edu.br, iallen@ifpi.edu.br

Abstract. *This paper presents a systematic mapping of the use of convolutional neural networks (CNNs) in dentistry, focusing on clinical applications based on image exams from 2015 to 2025. Over 2,600 articles from the Scopus database were analyzed, filtered, and categorized by CNN architectures, tasks (classification, segmentation, detection), image types, and clinical purposes. The results show a significant growth in scientific output, highlighting segmentation tasks and tomographic image use. The most used architectures were generic CNNs, YOLO, ResNet, and VGG.*

Resumo. *Este artigo apresenta um mapeamento sistemático sobre o uso de redes neurais convolucionais na odontologia, com foco em aplicações clínicas a partir de exames de imagem entre 2015 e 2025. A análise abrangeu 2.600 documentos da base Scopus, sendo filtrados e categorizados por arquiteturas utilizadas, tarefas (classificação, segmentação e detecção), tipos de imagem e aplicações odontológicas. Os resultados mostram crescimento expressivo da produção científica, com destaque para tarefas de segmentação e uso de imagens tomográficas. As arquiteturas mais frequentes foram CNN genérica, YOLO, ResNet e VGG.*

1. Introdução

O avanço das redes neurais convolucionais (CNNs) revolucionou a análise de imagens médicas na última década, especialmente no apoio ao diagnóstico automatizado. As CNNs são uma classe de algoritmos de aprendizado profundo que se destacam pela capacidade de extrair, de forma automática, características relevantes diretamente das imagens, sendo amplamente utilizadas em áreas como radiologia, dermatologia, oftalmologia e odontologia [Litjens et al. 2017].

Na odontologia, aplicações baseadas em CNNs têm demonstrado resultados promissores em tarefas como detecção de cáries, análise de radiografias panorâmicas e periapicais, segmentação de canais radiculares, apoio a planejamentos ortodônticos e avaliação de lesões ósseas [Singh et al. 2020]. Esses avanços contribuem para diagnósticos mais precisos, redução de erros clínicos e maior eficiência nos processos assistenciais. No entanto, o uso efetivo dessas tecnologias ainda enfrenta desafios relacionados

à padronização das imagens, à qualidade dos dados disponíveis e à generalização dos modelos desenvolvidos [Lundervold and Lundervold 2019]. Diante desse contexto, torna-se necessário compreender como a pesquisa científica tem se desenvolvido ao longo do tempo nesse domínio específico. Assim, este artigo tem como objetivo principal responder à seguinte questão: Como tem evoluído a produção científica sobre o uso de redes neurais convolucionais com aplicações odontológicas ao longo dos últimos 10 anos?

Para isso, foi conduzido um mapeamento sistemático da literatura, utilizando a base de dados Scopus e diferentes estratégias de busca que englobam os principais termos relacionados à odontologia, diagnóstico por imagem e aprendizado profundo. A análise compreendeu o período de 2015 a 2025 e incluiu a unificação, limpeza e categorização dos dados, permitindo uma visão panorâmica sobre tendências, arquiteturas utilizadas, tarefas mais frequentes, tipos de imagem explorados e aplicações clínicas. O restante deste trabalho está estruturado da seguinte forma: a Seção 2 apresenta os fundamentos teóricos relacionados às CNNs e suas aplicações odontológicas; a Seção 3 descreve a metodologia do mapeamento sistemático; na Seção 4 são discutidos os principais resultados obtidos; e, por fim, a Seção 5 apresenta as considerações finais e perspectivas futuras da pesquisa.

2. Referencial Teórico

2.1. Classificação dos Exames de Diagnóstico em Odontologia

Os exames de imagem na área da saúde são fundamentais para detectar doenças, localizar lesões e acompanhar o estado clínico dos pacientes. Na odontologia, a radiografia se destaca como uma ferramenta eficaz para a visualização das estruturas dentárias e da região maxilofacial, possibilitando a identificação de cáries, infecções ósseas, alterações nas raízes dentárias e outras condições bucais [Baldan et al. 2021]. As radiografias odontológicas são imagens bidimensionais geradas por projeções de sombras, cujas tonalidades variam conforme a densidade das estruturas atravessadas pelos raios X. Regiões mais escuras, denominadas radiolúcidas, indicam tecidos de baixa densidade que permitem maior passagem da radiação, como ocorre nas cáries dentárias. Em contrapartida, áreas claras, chamadas radiopacas, correspondem a estruturas densas que absorvem ou bloqueiam os raios X, como as restaurações metálicas. A distinção entre essas tonalidades é essencial para a correta análise e interpretação diagnóstica [Brasil. Ministério da Saúde 2011].

Para fins diagnósticos, os exames radiográficos na odontologia são classificados em intraorais e extraorais, conforme a posição do filme ou sensor em relação ao paciente. As radiografias intraorais, que possuem o filme colocado dentro da cavidade bucal, oferecem uma visão detalhada dos dentes e das estruturas adjacentes. Entre seus principais tipos, destacam-se a radiografia periapical, utilizada para avaliar a estrutura completa do dente, incluindo raiz e osso de suporte; a interproximal ou bite-wing, indicada para identificar lesões de cárie interproximal e monitorar a perda óssea coronária [White and Pharoah 2015]. Já as radiografias extraorais são realizadas com o filme posicionado externamente à cavidade oral, sendo indicadas para a avaliação de estruturas maiores, como maxilares, articulações temporomandibulares e seios da face. Dentre essas, a radiografia panorâmica é amplamente utilizada para planejamentos ortodônticos, cirúrgicos e para a avaliação geral das arcadas dentárias. A Tomografia Computadorizada de Feixe Cônico (TCFC) representa uma evolução da tomografia computadorizada con-

vencional (TC). Essa tecnologia possibilita a obtenção de imagens tridimensionais precisas das estruturas anatômicas dessa área, proporcionando maior detalhamento e qualidade diagnóstica [Nasseh and Al-Rawi 2018].

2.2. Arquiteturas de Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNNs) são projetadas para processar dados com estrutura de grade, como imagens, utilizando camadas convolucionais, camadas de pooling e camadas totalmente conectadas. O uso dessas redes na odontologia vem crescendo em diversas tarefas de diagnóstico por imagem. A Tabela 1, descreve algumas das principais arquiteturas identificadas na literatura entre 2015 e 2025, juntamente com suas aplicações, características e relevância para o contexto odontológico.

Tabela 1. Principais arquiteturas de CNN em aplicações odontológicas

Arquitetura	Descrição resumida	Aplicações odontológicas	Referências
CNN Genérica	Pilha de camadas convolucionais, pooling e fully-connected. Simples de implementar e treinar.	Classificação básica de radiografias (cárie vs. saudável).	[LeCun et al. 2015]
ResNet	Redes profundas com atalhos que evitam o gradiente desvanecido e permitem treinar dezenas de camadas.	Deteção de lesões em radiografias panorâmicas e CBCT.	[He et al. 2016]
U-Net	Arquitetura em formato de “U” com caminho de contração e expansão, e conexões laterais para preservar detalhes espaciais.	Segmentação de estruturas anatômicas (raíz, polpa) em imagens periapicais.	[Ronneberger et al. 2015]
YOLO	Rede de detecção em tempo real que divide a imagem em grades e prevê bounding boxes e classes simultaneamente.	Localização rápida de cáries e corpos estranhos em radiografias panorâmicas.	[Redmon et al. 2016]
VGGNet	Pilha de pequenas convoluções (3×3) com muitas camadas; simples, porém pesada computacionalmente.	Classificação refinada de patologias; extração de características para análises posteriores.	[Litjens et al. 2017]
EfficientNet	Ajusta escala de profundidade, largura e resolução de forma eficiente, alcançando alta acurácia com menos parâmetros.	Classificação e triagem de imagens de tomografia para planejamento de implantes.	[Tan and Le 2019]
DenseNet	Conexões densas entre camadas, onde cada camada recebe as saídas de todas as anteriores, promovendo reutilização de características.	Deteção de cistos e tumores, com foco na identificação de padrões sutis.	[Huang et al. 2017]
MobileNet	Utiliza convoluções separáveis em profundidade, sendo leve e otimizada para dispositivos móveis.	Aplicativos de triagem odontológica em dispositivos com baixa capacidade computacional.	[Howard et al. 2017]
Inception	Blocos com múltiplas convoluções de diferentes tamanhos que extraem características em várias escalas.	Classificação multicategoria e diferenciação entre tipos de lesões.	[Szegedy et al. 2015]

2.3. Descrição dos Achados Radiográficos

As modalidades de diagnóstico radiográfico desempenham papel central na identificação e planejamento de diversos tratamentos odontológicos. A cárie dentária, por exemplo, é observada radiograficamente como área radiolúcida em radiografias *bite-wing* ou periapicais, permitindo avaliar a extensão da lesão e decidir pela restauração [Pereira et al. 2024]. Já o implante dentário exige planejamento tridimensional por meio da TCFC, que oferece informações detalhadas sobre a morfologia óssea e permite acompanhar a osseointegração e identificar complicações como a peri-implantite [Bornstein et al. 2016]. A ortodontia utiliza radiografias panorâmicas e TCFC para analisar a posição dentária e esquelética com precisão, enquanto a periodontia se beneficia da TCFC para avaliar defeitos ósseos complexos e padrões de perda óssea [Francis and Siu 2023].

Tumores e cistos odontogênicos aparecem em radiografias como imagens radiolúcidas uni ou multiloculares; a TCFC auxilia no diagnóstico diferencial e na definição da extensão tridimensional da lesão [Silva et al. 2014]. Em procedimentos protéticos, como próteses convencionais ou implantossuportadas, os exames radiográficos (panorâmica e CBCT) são essenciais para avaliar o suporte ósseo, o posicionamento dos implantes e eventuais reabsorções, garantindo a longevidade da reabilitação [Bornstein et al. 2016]. Anomalias dentárias, como dentes impactados, supranumerários ou microdontia, são frequentemente detectadas por radiografias panorâmicas e analisadas com auxílio da TCFC para planejamento cirúrgico ou ortodôntico. Finalmente, lesões periapicais crônicas, como granulomas ou cistos, são observadas como radioluscências apicais em radiografias periapicais, com a TCFC aprimorando o diagnóstico quanto à extensão e à estrutura interna da lesão [Pereira et al. 2024].

3. Metodologia

A presente pesquisa caracteriza-se como um mapeamento sistemático, de natureza bibliográfica, com abordagem quantitativa. As buscas foram realizadas na base de dados Scopus, utilizando três combinações distintas de palavras-chave para garantir uma cobertura abrangente da literatura científica. As estratégias de busca aplicadas foram:

1. ("convolutional neural network" OR CNN OR "deep learning" OR "redes neurais convolucionais") AND (dentistry OR odontologia OR dental) AND (diagnosis OR diagnostic OR radiograph* OR "image analysis" OR imagem)
2. ("convolutional neural network" OR CNN) AND (tooth OR teeth OR cariology OR caries) AND (classification OR detection OR segmentation)
3. ("deep learning" OR "aprendizado profundo") AND (radiography OR radiografia OR radiografias) AND (odontological OR dental OR odontologia)

A combinação dessas três consultas resultou em um total superior a 2.600 registros. Posteriormente, os resultados foram integrados em um único conjunto de dados. Duplicatas foram removidas cuidadosamente e as entradas foram filtradas com base no ano de publicação (2015 a 2025). Em seguida, realizou-se a limpeza de campos inconsistentes, correção de colunas mal formatadas e padronização dos termos utilizados. Foi utilizada a linguagem Python com as bibliotecas Pandas e Matplotlib para gerar gráficos e extrair métricas. As categorias analisadas incluíram: arquiteturas CNN mencionadas, tarefas realizadas, tipos de imagem utilizados e aplicações clínicas.

4. Resultados e Discussões

Os resultados mostram um crescimento expressivo das publicações entre 2015 e 2025, conforme demonstrado na Figura 1. Observa-se uma tendência de crescimento constante a partir de 2019, com aumentos significativos nos anos de 2020, 2022 e, principalmente, 2024, que apresenta o maior número de publicações até o momento. É importante destacar que os anos de 2015 e 2016 registraram número praticamente nulo de publicações relevantes sobre o tema, indicando que, nesse período, o uso de CNNs em odontologia ainda era incipiente ou pouco explorado na literatura científica. Por outro lado, o ano de 2025, cuja coleta de dados foi realizada até julho, já apresenta um volume considerável de publicações, sugerindo que, até o final do ano, essa quantidade deve crescer ainda mais. Por essa razão, a coluna correspondente a 2025 na Figura 1 é apresentada com uma tonalidade diferenciada, representando um dado ainda parcial.




Figura 1. Publicações por ano

Na Figura 2, observa-se que as arquiteturas mais utilizadas entre 2015 e 2025 foram as CNNs genéricas, seguidas por YOLO, ResNet e VGG. A menção frequente a "CNN" de forma genérica pode indicar o uso de arquiteturas personalizadas ou abordagens não especificadas nos artigos, evidenciando uma ampla adoção do conceito geral de redes convolucionais em estudos odontológicos. A presença de arquiteturas como ResNet e VGG, ambas amplamente validadas na literatura, sugere preferência por modelos clássicos e robustos, com bom desempenho em diagnósticos por imagem. Arquiteturas como Inception, VGG16, U-Net, MobileNet e DenseNet também aparecem no ranking, embora com menor frequência, demonstrando uma diversidade de abordagens em uso. A escolha por essas arquiteturas pode estar relacionada à natureza específica das tarefas e à disponibilidade de recursos computacionais em ambientes clínicos e acadêmicos.




Figura 2. Arquiteturas CNN mais utilizadas

A Figura 3 evidencia que a segmentação é a tarefa de deep learning mais abordada nos estudos entre 2015 e 2025, seguida por detecção e, por fim, classificação. A predo-

minância da segmentação reflete a importância dessa tarefa em aplicações odontológicas, como a separação de estruturas anatômicas em radiografias e delimitação de lesões. Especificamente, segmentar significa atribuir um rótulo a cada pixel da imagem, permitindo identificar com precisão regiões como cáries, canais radiculares, dentes ou lesões periapicais.

A detecção, por sua vez, envolve a localização de regiões específicas em uma imagem por meio de caixas delimitadoras (*bounding boxes*). Essa técnica é amplamente utilizada para identificar automaticamente estruturas como cáries, fraturas, canais radiculares ou terceiros molares impactados, permitindo destacar essas áreas em tempo real ou como pré-processamento para etapas posteriores. Por fim, a classificação consiste na atribuição de um rótulo global à imagem ou a uma região específica, como "dente saudável" ou "presença de cárie". Essa abordagem é especialmente útil em sistemas de apoio ao diagnóstico, onde o modelo deve distinguir entre condições clínicas diferentes com base em padrões visuais aprendidos. Embora tenha sido a tarefa menos abordada no período analisado, a classificação permanece essencial em diagnósticos automatizados e triagens clínicas, especialmente em cenários com limitação de dados anotados.




Figura 3. Tarefas de deep learning abordadas

Quanto à natureza das imagens utilizadas (Figura 4a), observa-se que as tomografias (CT, geral) foram as mais frequentes nos estudos analisados, seguidas por radiografias em geral e radiografias panorâmicas. As radiografias panorâmicas continuam tendo presença relevante, o que reflete sua ampla aplicação no diagnóstico odontológico geral e planejamento de tratamentos. A CBCT também aparece com destaque, sendo uma modalidade de imagem muito usada em implantodontia, ortodontia e cirurgia bucomaxilofacial, embora com frequência inferior às modalidades mencionadas anteriormente. Outros tipos de imagem, como radiografias periapicais e bitewing apresentam menor ocorrência nos estudos.

As aplicações clínicas mais frequentes identificadas nos estudos analisados (Figura 4b) foram, em ordem decrescente de ocorrência: detecção de cárie, seguida por implantes dentários, ortodontia e periodontia. A alta frequência da cárie como aplicação principal está relacionada à sua prevalência na população e à viabilidade de se automatizar o diagnóstico com redes neurais, favorecendo a triagem precoce e a redução de erros humanos. As áreas de implantes e ortodontia também se destacam, indicando que técnicas de aprendizado profundo vêm sendo aplicadas para planejar intervenções complexas com maior precisão, como a análise da densidade óssea e posicionamento de dentes. Já a periodontia aparece com relevância, especialmente em aplicações que envolvem a avaliação de tecidos de suporte dentário, com apoio de segmentações detalhadas. Outras aplicações, como análise de canais radiculares, tumores e cistos, fraturas dentárias e próteses, também são exploradas, embora em menor escala.




Figura 4. Distribuição dos tipos de imagem e aplicações clínicas em estudos analisados

5. Considerações Finais e Trabalhos Futuros

O presente mapeamento sistemático permitiu identificar tendências, arquiteturas e aplicações predominantes no uso de redes neurais convolucionais aplicadas à odontologia entre os anos de 2015 e 2025. Os resultados demonstram um aumento expressivo na produção científica, com foco principal em tarefas de segmentação e detecção aplicadas a imagens tomográficas e radiográficas. As arquiteturas mais utilizadas variam conforme a tarefa e os recursos computacionais disponíveis, com destaque para ResNet, YOLO, VGG, U-Net e modelos genéricos personalizados.

Apesar dos avanços tecnológicos e da crescente acurácia dos modelos de deep learning, é importante destacar que os exames de imagem, isoladamente, nem sempre são suficientes para determinar o diagnóstico definitivo de uma condição bucal. Na prática clínica, o cirurgião-dentista integra as informações obtidas por imagem com dados clínicos e sistêmicos do paciente, como histórico de doenças, presença de diabetes, tabagismo, uso de medicamentos, entre outros fatores relevantes.

Nesse sentido, como trabalho futuro, propõe-se o desenvolvimento de modelos híbridos que combinem as informações extraídas das imagens (por meio de CNNs) com dados clínicos adicionais, codificados em formato binário no vetor de características de uma rede neural do tipo perceptron multicamada (MLP). Essa abordagem multimodal poderá aumentar a precisão diagnóstica dos sistemas automatizados, permitindo maior personalização e contextualização dos resultados gerados. Além disso, espera-se que a integração de variáveis clínicas torne os modelos mais robustos e próximos da realidade do processo decisório adotado na odontologia baseada em evidências.

Referências

- Baldan, L. C. et al. (2021). Odontologia durante a pandemia de covid-19. *Vigilância Sanitária em Debate*, 9(1):36–46.
- Bornstein, M. M., Horner, K., and Jacobs, R. (2016). Use of cone beam computed tomography in implant dentistry: current concepts, indications and limitations for clinical practice and research. *Periodontology 2000*, 73(1):51–72.
- Brasil. Ministério da Saúde (2011). *Projeto SBBrasil 2010: pesquisa nacional de saúde bucal: resultados principais*. Ministério da Saúde, Brasília, DF.
- Francis, J. R. and Siu, T. L. (2023). Utility of cone beam imaging in periodontics and implant therapy. *Decisions in Dentistry*, ?(?):? Review article.

- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 770–778.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Huang, G., Liu, Z., van der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 4700–4708.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(7553):436–444.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42:60–88.
- Lundervold, A. S. and Lundervold, A. (2019). An overview of deep learning in medical imaging focusing on mri. *Zeitschrift für Medizinische Physik*, 29(2):102–127.
- Nasseh, I. and Al-Rawi, W. (2018). Cone beam computed tomography. *Dental Clinics of North America*, 62(3):361–391.
- Pereira, S. A., Corte-Real, A., Melo, A., Magalhães, L., Lavado, N., and Santos, J. M. (2024). Diagnostic accuracy of cone beam computed tomography and periapical radiography for detecting apical root resorption in retention phase of orthodontic patients: A cross-sectional study. *Journal of Clinical Medicine*, 13(5):1248.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)*, pages 779–788.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer.
- Silva, F. C. d., Bezerra, I. S. Q., Rebellato, N. L. B., and Lima, A. A. S. (2014). Cone beam computed tomography and applicability in dentistry – literature review. *Revista Sul-Brasileira de Odontologia*, 10(3):272–277.
- Singh, P. K. et al. (2020). Convolutional neural networks in oral and maxillofacial radiology: A review. *Imaging Science in Dentistry*, 50(3):169–175.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1–9.
- Tan, M. and Le, Q. V. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the 36th International Conference on Machine Learning*, pages 6105–6114.
- White, S. C. and Pharoah, M. J. (2015). *White & Pharoah: princípios de interpretação radiográfica*. Elsevier, Rio de Janeiro, 7 edition.