

INSTITUTO UNIVERSITÁRIO EGAS MONIZ

MESTRADO INTEGRADO EM MEDICINA DENTÁRIA

INTELIGÊNCIA ARTIFICIAL EM RADIOLOGIA DENTÁRIA

Trabalho submetido por

Max Jean Gérard MARTIN

para a obtenção do grau de Mestre em Medicina Dentária

junho de 2024

INSTITUTO UNIVERSITÁRIO EGAS MONIZ

MESTRADO INTEGRADO EM MEDICINA DENTÁRIA

INTELIGÊNCIA ARTIFICIAL EM RADIOLOGIA DENTÁRIA

Trabalho submetido por

Max Jean Gérard MARTIN

para a obtenção do grau de Mestre em Medicina Dentária

Trabalho orientado por

Profª Doutora Alexandra Pinto Rodrigues

e coorientado por

Profª Doutora Inês Caldeira Fernandes

junho de 2024

DEDICATÓRIA

À ceux qui ne sont plus parmi nous aujourd'hui,

Mais que je n'oublierai jamais,

Une partie de ce que je suis devenu vous revient.

Pépé et Mémé Bretagne

AGRADECIMENTOS

Je tiens tout d'abord à remercier mes parents, qui ont toujours été présents pour moi. C'est grâce à vous que j'en suis ici aujourd'hui. Merci d'avoir toujours cru en moi et de m'avoir soutenu dans tout ce que j'ai voulu entreprendre. Je vous aime.

À mes frères et sœurs, Noa, Gayané, et Sévan, malgré la distance, nous sommes toujours plus proche, et pour qui j'apporte beaucoup d'amour, et ça éternellement.

Je tiens également à remercier mes grands-parents, qui m'ont constamment apporté leur amour et soutien. Chacun à leur manière, ils ont contribué à mon éducation et forgé mon caractère, je vous aime fort.

A toi Agathe pour ton amour au quotidien, ma plus belle rencontre ici. J'ai beaucoup de chance d'être à tes côtés et j'espère que c'est que le début d'une grande et belle aventure, je t'aime.

A tout mes amis, avec qui j'ai passé de magnifiques moments ici et que je n'oublierai jamais

Au box 47 et à ma surtout à ma binôme et amie Nour avec qui j'ai pu passer deux années de clinique incroyable.

Quero também agradecer ao Instituto Egas Moniz por estes 5 anos felizes, que me permitiu formar-me para a profissão de dentista que sempre quis exercer

Gostaria também de agradecer a este magnífico país, Portugal, que se tornou a minha segunda casa para sempre.

Finalmente, quero agradecer à Professora Doutora Alexandra Pinto Rodrigues, por me ter dado a oportunidade de ter a sua orientação, pela disponibilidade, apoio e contribuição que foram determinantes para o desenvolvimento e a conclusão deste trabalho.

RESUMO

O objetivo desta revisão de literatura é pesquisar os avanços tecnológicos recentes no campo da Inteligência artificial (IA) e aplicá-los à radiologia dentária. Essa pesquisa abrange a descoberta de novas metodologias, técnicas e aplicações que podem revolucionar a forma como os profissionais de saúde dentária diagnosticam e tratam os pacientes.

Ao mesmo tempo, é imperativo avaliar os benefícios que a IA pode trazer para a radiologia dentária. O aumento da precisão nos diagnósticos, a redução de erros humanos, a maior rapidez na interpretação de imagens e a otimização dos recursos de saúde estão entre os principais potenciais benefícios (Khanagar et al., 2021).

Outro objetivo essencial é identificar os desafios que acompanham a integração da IA na radiologia dentária. Entre esses desafios, as questões éticas desempenham um papel proeminente.

A proteção da privacidade dos pacientes, a gestão de possíveis preconceitos nos modelos de IA e a necessidade de regulamentações apropriadas são preocupações importantes.

A formação dos profissionais de saúde dentária é também um objetivo crucial deste trabalho. É essencial preparar dentistas e auxiliares dentários para a utilização eficaz da IA.

Essa formação abrange a compreensão dos conceitos de IA, a capacidade de interpretar corretamente os resultados dos sistemas de IA e a sensibilização para questões éticas (Schwendicke et al., 2020).

Finalmente, o objetivo global deste trabalho é contribuir para a compreensão do impacto da IA na radiologia dentária. Compartilhando informações e reflexões importantes, visa facilitar a transição para uma utilização mais ampla e eficaz dessa tecnologia, garantindo ao mesmo tempo uma abordagem ética e responsável.

Palavras-Chave: Radiologia dentária; Inteligência artificial; Medicina dentária; Diagnóstico

ABSTRACT

The aim of this literature review is to explore recent technological advances in the field of artificial intelligence (AI) and apply them to dental radiology. This exploration encompasses the discovery of new methodologies, techniques and applications that could revolutionize the way dental health professionals diagnose and treat patients.

At the same time, it is imperative to evaluate the benefits that AI can bring to dental radiology. Increased diagnostic accuracy, reduced human error, faster image interpretation and optimization of healthcare resources are among the main potential benefits (Khanagar et al., 2021).

Another essential objective is to identify the challenges that accompany the integration of AI into dental radiology. Among these challenges, ethical issues play a prominent role. Protecting patient privacy, managing possible bias in AI models and the need for appropriate regulations are important concerns.

The training of dental health professionals is also a crucial objective of this work. It is essential to prepare dentists and dental assistants for the effective use of AI.

This training covers an understanding of AI concepts, the ability to correctly interpret the results of AI systems and awareness of ethical issues (Schwendicke et al., 2020).

Finally, the overall aim of this work is to contribute to understanding the impact of AI on dental radiology. By sharing important information and reflections, it aims to facilitate the transition to a wider and more effective use of this technology, while ensuring an ethical and responsible approach.

Key words: Dental radiology; Artificial intelligence; Dentistry; Diagnostic

RÉSUMÉ

L'objectif de cette revue littéraire est d'explorer les récentes avancées technologiques dans le domaine de l'intelligence artificielle (IA) et de les appliquer à la radiologie dentaire. Cette exploration comprend la découverte de nouvelles méthodologies, techniques et applications qui pourraient révolutionner la façon dont les professionnels de la santé dentaire diagnostiquent et traitent les patients.

Parallèlement, il est impératif d'évaluer les avantages que l'IA peut apporter à la radiologie dentaire. L'augmentation de la précision du diagnostic, la réduction des erreurs humaines, l'interprétation plus rapide des images et l'optimisation des ressources de santé figurent parmi les principaux avantages potentiels (Khanagar et al., 2021).

Un autre objectif essentiel est d'identifier les défis qui accompagnent l'intégration de l'IA en radiologie dentaire. Parmi ces défis, les questions éthiques jouent un rôle prépondérant.

La protection de la vie privée des patients, la gestion des biais possibles dans les modèles d'IA et la nécessité d'une réglementation appropriée sont des préoccupations importantes. La formation des professionnels de la santé dentaire est également un objectif crucial de ce travail. Il est essentiel de préparer les dentistes et les assistants dentaires à l'utilisation efficace de l'IA.

Cette formation porte sur la compréhension des concepts de l'IA, la capacité à interpréter correctement les résultats des systèmes d'IA et la sensibilisation aux questions éthiques (Schwendicke et al., 2020).

Enfin, l'objectif global de ce travail est de contribuer à la compréhension de l'impact de l'IA sur la radiologie dentaire. En partageant des informations et des réflexions importantes, il vise à faciliter la transition vers une utilisation plus large et plus efficace de cette technologie, tout en garantissant une approche éthique et responsable.

Mots clés : Radiologie dentaire ; Intelligence artificielle ; Dentisterie ; Diagnostic

ÍNDICE

I.	Introdução	15
II.	Fundamentos da Radiologia Dentária.....	19
2.1	Princípios Básicos da Radiologia Dentária.....	19
2.2	Importância das Imagens Dentárias.....	19
2.3	Técnicas Bidimensionais.....	19
2.3.1	Radiografias Intraorais.....	19
2.3.1.1	Radiografias Periapicais.....	20
2.3.1.2	Radiografias Interproximais (<i>Bite-Wings</i>).....	20
2.3.1.3	Radiografias Oclusais.....	20
2.3.2	Radiografias Extra Oraís.....	21
2.3.2.1	Radiografia Panorâmica.....	21
2.3.2.2	Teleradiografia de Perfil.....	22
2.4	Técnicas Tridimensionais.....	22
2.4.1	Tomografia Computorizada de Feixe Cônico.....	22
2.4.2	Imagem por Ressonância Magnética	23
2.4.3	Scanner 3D.....	24
2.6	Limitações da Interpretação Humana e Erros Técnicos em Imagens Dentárias...	24
III.	Benefícios e Aplicações da Inteligência Artificial na Radiologia Dentária...29	
3.1	Generalidades.....	29

3.1.1	O <i>Big Data</i> em Imagem Médica.....	30
3.1.2	Origem e Desenvolvimento.....	30
3.1.3	<i>Machine Learning</i>	32
3.1.4	<i>Deep Learning</i>	33
3.1.5	<i>Convolutional Neural Network (CNN)</i>	34
3.1.6	DICOM.....	37
3.1.7	Principais Tarefas dos Algoritmos de IA Baseados em Imagem.....	38
3.2	Aplicações Clínicas De IA.....	39
3.2.1	Endodontia.....	39
3.2.2	Ortodontia.....	41
3.2.3	Periodontologia.....	42
3.2.4	Oclusão.....	43
3.2.5	Prostodontia.....	44
3.2.6	Implantologia.....	46
3.2.7	Dentisteria.....	49
3.2.7.1	Deteção e Segmentação.....	49
3.2.7.2	Cárie Dentária.....	50
3.2.8	Cirurgia.....	49
3.2.9	Deteção de Quistos e Tumores.....	52
3.2.10	Medicina Dentária Forense.....	55

3.2.10.1	Mordidas e Inteligência Artificial.....	55
3.2.10.2	Morfologia Mandibular e Inteligência Artificial.....	56
3.2.10.3	Determinação do Sexo e Inteligência Artificial.....	56
3.2.10.4	Estimativa de Idade e Inteligência Artificial.....	57
IV.	Desafios e Preocupações.....	61
4.1	Limitações da IA.....	62
4.1.1	Insuficiência de Dados de Imagem para Treino.....	62
4.1.2	Interpretação.....	63
4.1.3	<i>Overfitting</i>	63
4.2	Questões Éticas e Regulatórias.....	64
4.3	Legislação de IA na Europa.....	65
4.4	Potência de Computação.....	66
4.5	Desenvolvimento Sustentável.....	66
4.6	Integração nos Fluxos de Trabalho Clínicos.....	67
4.7	Compreender a IA e Manter o Controle da Decisão.....	67
V.	Conclusão	69
VI.	Bibliografia	71

ÍNDICE DE FIGURAS

Figura 1. Radiografia periapical dos dentes 46,47,48.

Figura 2. Radiografia interproximal dos 1º e 4º quadrantes.

Figura 3. Radiografia Oclusal dos dentes anteriores superiores.

Figura 4. Ortopantomografia.

Figura 5. Teleradiografia de perfil.

Figura 6. Radiografia CBCT.

Figura 7. IRM de diferentes indicações em endodontia, adaptado de (Flügge et al., 2023).

Figura 8. Scanner 3D, adaptado de (Hou et al., 2022).

Figura 9. Exemplos de utilitários de processamento de imagens por IA generativa, adaptado de (Katsumata, 2023).

Figura 10. O *Big Bang* dos grandes dados, adaptado de (Gaudiaut, 2021).

Figura 11. Inteligência artificial através do tempo, adaptado de (Santos, 2024).

Figura 12. Tipos de Aprendizado de Máquina, adaptado de (Maia, 2021).

Figura 13. Diferenças entre Inteligência artificial, *Machine Learning* e *Deep Learning*, adaptado de (Lavagnoli, 2023).

Figura 14. Estrutura simplificada de uma rede neural convolucional, adaptado de (Barbosa et al., 2021).

Figura 15. Diferença entre *machine learning* e *deep learning* para classificação de patologias periapicais, adaptado de (Putra et al., 2022).

Figura 16. Tarefas mais comuns de visão por computador com um exemplo de reconhecimento de lesões de cárie dentária, adaptado de (Putra et al., 2022).

Figura 17. Ilustrando as principais tarefas impulsionadas por IA com um exemplo da lesão periapical de um primeiro pré-molar superior esquerdo mostrado em imagens de CBCT, adaptado de (Hung et al., 2022).

Figura 18. As diferentes formas do côndilo mandibular, adaptado de (Kale et al., 2023).

Figura 19 . Ilustração do impacto da inteligência artificial no registo da relação maxilo-mandibular, adaptado de (Ducret et al., 2022).

Figura 20. Modelo *Sparse Octree* adaptado de (Zhang et al., 2019).

Figura 21. Aplicação da Inteligência Artificial para implantes dentários, adaptado de (Lerner et al., 2020).

Figura 22. Exemplo dos mapas de ativação de classes das cinco redes de classificação para quatro tipos de implantes, adaptado de (Heo et al., 2021).

Figura 23. Segmentação da estrutura anatômica , adaptado de (Katsumata, 2023).

Figura 24. Detecção automática de regiões e segmentação de dentes na radiografia panorâmica, adaptado de (Katsumata, 2023).

Figura 25. Detecção automática de cárie dentária, adaptado de (Heo et al., 2021).

Figura 26. Variação de densidades ao longo dos contornos do dente, adaptado de (Kale et al., 2023).

Figura 27. Detecção automática de queratoquisto odontogénico, adaptado de (Heo et al., 2021).

Figura 28. Utilização de redes neuronais convolucionais para o estadiamento dentário, adaptado de (Pauwels, 2020).

Figura 29. Exemplo de uma solução de inteligência artificial para analisar e segmentar radiografias dentárias panorâmicas, adaptado de (empresa Allisone).

Figura 30. Representação esquemática do funcionamento dos modelos de Inteligência Artificial e Grad-CAM e a sua ação sobre os dentes, adaptado de (Agrawal and Nikhade, 2022; Inani et al., 2024).

LISTA DE ABREVIATURAS

IA: inteligência artificial

CBCT: Tomografia computadorizada de feixe cônico

IRM: Imagem por Ressonância Magnética

DL: *Deep Learning*

ML: *Machine learning*

CNN: *Convolutional neural network*

DICOM: *Digital Imaging and Communications in Medicine*

CAD: computer-aided design

CAM: computer-aided manufacturing

ATM: articulação temporomandibular

SVA: *Shape Variation Analyzer*

RMM: relação maxilo-mandibular

S-Octree: *Sparse Octree*

TMM: terceiros molares mandibulares

NAI: nervo alveolar inferior

CM: canal mandibular

VPP: Valor Preditivo Positivo

QO: queratoquistos odontogênicos

CE: Conformidade europeia

FDA: *Food and Drug Administration*

I- Introdução

A história da radiologia dentária remonta ao final do século XIX, quando a descoberta revolucionária dos raios-X transformou o campo médico. Wilhelm Conrad Roentgen, um físico alemão, descobriu acidentalmente os raios-X em 1895 durante experiências com tubos de raios catódicos. A sua descoberta abriu novas perspectivas em várias disciplinas médicas, incluindo a medicina dentária. (Różyło-Kalinowska, 2020)

Pouco tempo após a revelação de Roentgen, os profissionais dentários reconheceram o potencial dos raios-X para diagnosticar e tratar os problemas dentários. Edmund Kells introduziu a radiografia na medicina dentária em 1896, apenas alguns meses após a descoberta dos raios-X por Wilhelm Conrad Roentgen. Kells foi um dos pioneiros dos cuidados de saúde modernos. A sua introdução da radiografia na medicina dentária desempenhou um papel importante na evolução do campo e teve um impacto duradouro nos cuidados dentários (Jacobsohn et al., 2013).

O trabalho de Kells não foi isento de desafios. Na época, a compreensão da segurança relacionada à radiação era limitada, e as medidas de proteção eram rudimentares. Infelizmente, Kells sofreu problemas de saúde relacionados com a significativa exposição aos raios-X durante as suas experiências pioneiras. No entanto, as suas contribuições foram cruciais para demonstrar o potencial diagnóstico dos raios-X na medicina dentária (Jacobsohn et al., 2013).

O trabalho de Kells lançou as bases para a integração da radiografia na prática clínica. As suas primeiras experiências e documentação abriram caminho para avanços posteriores em radiologia dentária, eventualmente levando ao desenvolvimento de práticas mais seguras e à ampla utilização dos raios-X como ferramenta de diagnóstico em medicina dentária (Jacobsohn et al., 2013).

À medida que a compreensão da tecnologia de raios-X se aprofundava, os dentistas começaram a integrar a radiografia nas suas práticas. No início do século XX, melhorias em máquinas de raios-X e tecnologia de filmes permitiram a obtenção de imagens dentárias mais precisas e detalhadas. A capacidade de visualizar lesões de cárie,

perda óssea e outros problemas dentários transformou o processo de diagnóstico e o planejamento de tratamento (Różyło-Kalinowska, 2020).

Ao longo das décadas, os avanços na radiologia dentária continuaram a evoluir. Na década de 1920, aventais e colimadores de chumbo foram introduzidos para minimizar a exposição à radiação de pacientes e profissionais odontológicos. Os anos 1950 viram o aparecimento de radiografias panorâmicas, oferecendo uma visão mais ampla das estruturas orais em uma única imagem. A radiografia digital emergiu no final do século XX, substituindo os métodos tradicionais baseados em filmes. Essa transição não apenas reduziu a exposição à radiação, mas também ofereceu resultados imediatos e facilidade de armazenamento e recuperação de registros de pacientes. A tomografia computadorizada de feixe cônico (CBCT), uma técnica de imagem 3D, melhorou ainda mais as capacidades diagnósticas da radiologia dentária no século XXI, permitindo um plano de tratamento mais preciso em casos complexos (Różyło-Kalinowska, 2020).

Hoje, a radiologia dentária desempenha um papel crucial nos cuidados dentários de rotina, facilitando a detecção precoce de problemas orais e auxiliando em vários procedimentos dentários. As inovações tecnológicas garantem ao profissional acesso a ferramentas de imagem avançadas, contribuindo para a melhoria dos resultados para os pacientes e para a evolução geral da medicina dentária (Agrawal & Nikhade, 2022).

Paralelamente a esses desenvolvimentos em radiologia dentária, a inteligência artificial emergiu como uma força transformadora no campo da saúde. Há muitos anos que os cientistas trabalham incansavelmente para avançar na inteligência artificial. Foi em 1956 que John McCarthy apresentou esse campo chamado de "quarta revolução industrial", que utiliza tecnologia da computação para imitar o pensamento crítico, a tomada de decisões e o comportamento inteligente semelhante ao humano (Tandon et al., 2020).

Na informática, a IA é o estudo de um suporte inteligente, ou de qualquer máquina que compreenda seu ambiente e aja de maneira a maximizar suas chances de alcançar seus objetivos. O termo "IA" é usado quando o computador imita funções analíticas, como aprendizagem e resolução de problemas (Deshmukh, 2018).

As técnicas de IA demonstraram excelentes capacidades para reconhecer padrões de dados importantes, o que levou a uma intensa experimentação dessas técnicas no campo da saúde. Foi demonstrado que a IA melhora a eficiência e a precisão dos dados, da mesma forma que os especialistas médicos, e de forma mais rápida e econômica (Aminoshariae et al., 2021).

Desenvolvendo soluções para diferentes problemas clínicos, facilitando assim o trabalho dos médicos, a inteligência artificial tem o potencial de revolucionar as disciplinas médicas e dentárias. As aplicações da inteligência artificial na indústria ainda não são comuns. No entanto, o desenvolvimento dessas tecnologias teve impacto em todas as áreas da medicina dentária, incluindo a classificação e detecção de diferentes patologias. Portanto, esta revisão visa apresentar a literatura científica sobre radiologia e as aplicações da inteligência artificial em todas as áreas, para diagnóstico, tomada de decisões clínicas e previsão de terapia bem-sucedida, bem como para identificar os limites atuais do uso da inteligência artificial.

II- Fundamentos da Radiologia Dentária

2.1 Princípios Básicos da Radiologia Dentária

A radiologia dentária é uma técnica de imagem médica que utiliza raios-X para produzir imagens das estruturas dentárias e maxilofaciais. Os aparelhos de radiologia dentária são projetados para produzir raios-X de baixa energia, o que permite obter imagens detalhadas enquanto minimiza a exposição à radiação. A radiologia dentária oferece uma variedade de técnicas de imagem para auxiliar os profissionais dentários no diagnóstico e tratamento de problemas dentários (Lam & Mallya, 2018).

2.2 Importância das Imagens Dentárias

As imagens dentárias são uma componente essencial dos cuidados prestados aos pacientes. Permitem ao profissional identificar muitas condições que de outra forma poderiam passar despercebidas e visualizar condições que não podem ser identificadas clinicamente. Um exame bucodentário sem imagens dentárias limita o profissional ao que pode ser visto clinicamente, os dentes e os tecidos moles. Através das imagens dentárias, o dentista pode obter uma vasta gama de informações sobre os dentes e os ossos que os suportam. A detecção é uma das utilizações mais importantes das imagens dentárias. Permitem detetar muitas doenças e condições dentárias que não apresentam sinais ou sintomas clínicos e geralmente só são descobertas através da imagem dentária (Iannucci et al., 2021).

2.3 Técnicas Bidimensionais

2.3.1 Radiografias Intraorais

Estas são todas as técnicas de imagem da esfera oral cuja aquisição é feita por um sensor (digital ou analógico) colocado na boca do paciente. O recetor das radiações está localizado na cavidade oral (Whaites, 2020).

2.3.1.1 Radiografias Periapicais

As radiografias periapicais são radiografias intraorais bidimensionais de um dente ou grupo de dentes centradas numa área dentária (anterior ou posterior, mandibular ou maxilar) consistindo numa projeção radiográfica em duas dimensões numa pequena película e permitindo visualizar a estrutura dentária na sua totalidade (coroa, raiz, ápice), o seu ambiente periodontal (ligamento periodontal, osso alveolar) e as estruturas anatómicas adjacentes (pavimento do seio, foramen mentoniano, nervo alveolar inferior) (figura 1) (Różyło-Kalinowska, 2020).




Figura 1. Radiografia periapical dos dentes 46,47,48.

2.3.1.2 Radiografias Interproximais (*Bite-Wings*)

As radiografias interproximais são radiografias intraorais bidimensionais de um grupo de dentes centradas numa área posterior por um feixe com trajeto coronário ou inter-oclusal (pré-molar ou molar, maxilar e mandibular) vertical ou horizontal e permitindo visualizar de forma mais precisa a estrutura coronária do dente/grupo de dentes e os seus antagonistas (figura 2) (Whaites, 2020).




Figura 2. Radiografia interproximal dos 1º e 4º quadrantes.

2.3.1.3 Radiografias Oclusais

As radiografias do tipo mordida oclusal são radiografias intraorais bidimensionais, num eixo horizontal, de um grupo de dentes e centradas nas faces oclusais maxilares ou mandibulares destes (figura 3) (Whaites, 2020).



Figura 3. Radiografia Oclusal dos dentes anteriores superiores.

2.3.2 Radiografias Extra Oraís

As radiografias extra orais são radiografias tiradas a partir do exterior da boca, permitindo ver toda a boca (Whaites, 2020).

2.3.2.1 Radiografia Panorâmica

A ortopantomografia ou panorâmica dentária é uma radiografia extra oral bidimensional das arcadas dentárias, estruturas anatómicas ósseas e articulares adjacentes (osso alveolar, osso basal, ramo mandibular, processo coronoide, côndilo, articulação temporo-mandibular, canal mandibular do nervo alveolar inferior e foramen mentoniano de emergência, seios maxilares, fossas nasais) (figura 4). Esta radiografia é não só rápida, mas também expõe os pacientes a menos radiação do que as técnicas tradicionais. É particularmente útil para avaliar o alinhamento dos dentes, anomalias de crescimento e para planejar tratamentos ortodônticos ou cirúrgicos. É também frequentemente utilizada em exames de rotina, avaliações pré-operatórias e para monitorizar a evolução dos tratamentos dentários. Oferece uma perspectiva global da cavidade oral, permitindo aos dentistas fornecer cuidados precisos e personalizados (Różyło-Kalinowska, 2020).




Figura 4. Ortopantomografia.

2.3.2.2 Teleradiografia de Perfil

A teleradiografia de perfil é uma radiografia bidimensional de todo o esqueleto craniano (esqueleto cefálico, massa facial, base do crânio e maxilares) e parte da coluna cervical. Geralmente é usada para avaliar a relação entre os maxilares, superior e inferior, e os dentes, bem como para planejar tratamentos ortodônticos (figura 5) (Whaites, 2020).



Figura 5. Teleradiografia de perfil.

2.4 Técnicas Tridimensionais

As técnicas "tridimensionais" são métodos de imagem baseados no registo de informações e sua aquisição em 3 dimensões (Whaites, 2020).

2.4.1 Tomografia Computorizada de Feixe Cônico

A Tomografia computadorizada de feixe cônico (CBCT) é uma técnica de imagem em três dimensões que permite produzir imagens detalhadas das estruturas dentárias e maxilofaciais (figura 6). O CBCT é geralmente usado para avaliar dentes, raízes, ossos e seios. Também é usado para planejar tratamentos com implantes e cirurgias orais. Antes dos anos 90, as radiografias dentárias eram exclusivamente usadas em formatos 2D, como radiografias panorâmicas (Kaasalainen et al., 2021).

Em 1998, P. Mozzo introduziu uma nova tomografia computadorizada conhecida como CBCT, que se destaca pela baixa dosagem de raios-X e sua adequação à imagem dento-maxilo-facial. Seu principal atrativo era fornecer imagens 3D. O CBCT tornou-se um instrumento essencial na medicina dentária contemporânea, confirmando o seu compromisso como modalidade de imagem não invasiva que facilita a visualização de tecidos ósseos e moles no domínio maxilofacial. No geral, o CBCT transformou o campo

da medicina oral ao melhorar a precisão do diagnóstico e os resultados terapêuticos, enquanto atenua a exposição dos pacientes à radiação (Mozzo et al., 1998).




Figura 6. Radiografia CBCT.

2.4.2 Imagem por Ressonância Magnética (IRM)

A imagem por ressonância magnética é uma técnica de imagem que utiliza campos magnéticos e ondas de rádio para produzir imagens detalhadas dos tecidos moles da boca e da cabeça (figura 7). A IRM é geralmente usada para avaliar tumores, infecções e lesões nervosas. Ela pode fornecer cortes em duas ou três dimensões. Uma das aplicações mais comuns é o diagnóstico das patologias dos discos da articulação temporo-mandibular. Esta técnica não utiliza radiação ionizante e, portanto, não causa irradiação. A IRM pode ser uma alternativa ao CBCT em imagiologia dentária, mas seu campo de aplicação em medicina dentária é restrito, sendo mais comum e relevante no campo de atuação de especialistas de estomatologia ou dos médicos otorrinolaringologia devido ao seu alto custo (Husain et al., 2022).



Figura 7. IRM de diferentes indicações em endodontia, adaptado de (Flügge et al., 2023).

2.4.3 Scanner 3D

O scanner 3D intraoral é uma tecnologia relativamente recente na medicina dentária, mas tem-se tornado cada vez mais popular com o avanço das tecnologias digitais. Permite capturar imagens tridimensionais do interior da boca dos pacientes, substituindo as impressões dentárias tradicionais em alginato, ou em elastômeros (figura 8). Esta tecnologia oferece uma alternativa mais precisa e confortável. O scanner 3D intraoral serve para várias finalidades. É usado para obter impressões digitais precisas, necessárias especialmente para o fabrico de próteses dentárias personalizadas, como coroas ou pontes. Além disso, facilita o planeamento de tratamentos dentários, permitindo aos dentistas visualizar com precisão a estrutura dentária do paciente. Também é útil para acompanhar a evolução da dentição de um paciente ao longo do tempo, especialmente no contexto de tratamentos ortodônticos. As imagens digitais capturadas pelo scanner são usadas para projetar e fabricar próteses dentárias personalizadas, incluindo restaurações estéticas como facetas dentárias. Esta tecnologia versátil oferece benefícios em termos de precisão, conforto para os pacientes e planeamento de tratamento, contribuindo assim para a melhoria dos cuidados dentários e dos resultados clínicos (Oliveira et al., 2023).

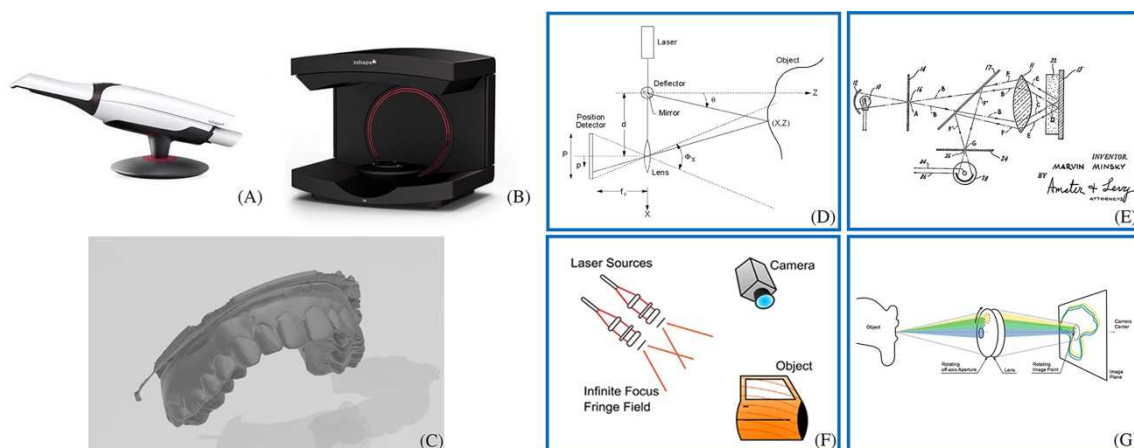


Figura 8. (A) Scanner intraoral, (B) scanner extraoral, (C) impressão digital de scanner intraoral ou extraoral. Princípio de quatro tecnologias ópticas sem contato. (D) Princípio da triangulação, princípio confocal da microscopia (E), princípio de funcionamento da interferometria da franja do acordeão (F), e princípio ativo da amostragem de Wavefront. (G), adaptado de (Hou et al., 2022).

2.5 Limitações da Interpretação Humana e Erros Técnicos em Imagens Dentárias

Na radiologia, como em qualquer outra especialidade médica, a prática diária apresenta um risco intrínseco de erros humanos que podem ter consequências perigosas para o paciente. Em particular, a interpretação das imagens médicas requer habilidades e

conhecimentos adquiridos após uma longa formação devido à dificuldade em reconhecer a presença de aspetos patológicos. Infelizmente, a causa mais comum de ações judiciais por negligência médica contra um dentista é um erro no processo de diagnóstico (Busardò et al., 2015).

É importante lembrar que a radiologia é uma atividade complementar essencial, no cerne da avaliação diagnóstica do paciente. A medicina dentária é uma das profissões de saúde que tem a responsabilidade de tomar decisões e interpretar radiografias visando a escolha terapêutica subsequente. Portanto, o dentista está familiarizado com as radiografias, uma ferramenta inestimável para tratar adequadamente os pacientes, fornecendo informações essenciais para o diagnóstico de doenças dentárias, como lesões de cárie, perda óssea periodontal, patologia peri apical e outras condições orais. Além disso, muitos tratamentos dentários dependem completamente da radiologia intra e/ou extra oral e são impossíveis de realizar corretamente sem ela, como a endodontia ou a cirurgia de implantes (Zangari, 2016).

A deteção e a discriminação de uma anomalia numa imagem radiográfica envolvem processos perceptivos (reconhecimento de uma diferença ou alteração na aparência) e cognitivos (compreensão do significado dessas alterações). O clínico deve primeiro detetar uma anomalia numa radiografia, e depois caracterizá-la, para chegar a um diagnóstico. No entanto, este processo é complexo e vários fatores, como a complexidade das radiografias, os conhecimentos clínicos e as competências técnicas em radiografia dentária, a pressão do tempo, a formação em análise radiográfica, a experiência clínica e a carga cognitiva, conduzem a erros de interpretação e de diagnóstico. Devido à complexidade analítica, os erros de diagnóstico e de interpretação radiográfica são quase inevitáveis na prática diária (Hegde et al., 2023).

Problemas técnicos com o próprio aparelho radiográfico, como problemas de calibração, mau funcionamento do detetor ou defeitos óticos, podem afetar a qualidade das imagens produzidas. Erros também podem ocorrer durante o processamento digital das imagens radiográficas, como distorções de contraste, artefactos de compressão ou erros de reconstrução, o que pode alterar a fidelidade da imagem em relação à anatomia real. Problemas também podem advir de movimentos involuntários do paciente, o que pode comprometer o diagnóstico informado da radiografia. Os artefactos, especialmente

aqueles provenientes do processamento da imagem e de vários materiais dentários, podem ter um impacto significativo na precisão do diagnóstico. Estudos têm mostrado que o processamento da imagem pode introduzir artefactos que imitam uma patologia, especialmente em margens de contraste elevado, o que pode levar a intervenções desnecessárias (Brettle & Carmichael, 2011).

A tomografia de feixe cónico em medicina dentária, embora útil, também pode apresentar artefactos que degradam a qualidade da imagem e a tornam inutilizável para fins diagnósticos (Hegde et al., 2023).

Neste contexto, a inteligência artificial oferece um potencial considerável para auxiliar os clínicos no processo de diagnóstico de patologias a partir de imagens radiográficas. Os algoritmos de IA podem ser treinados em vastos conjuntos de dados de imagens radiográficas anotadas, permitindo-lhes reconhecer padrões e características associadas a diferentes patologias com alta precisão (Putra et al., 2022).

Os algoritmos podem ser usados para detetar automaticamente anomalias ou sinais precoces de patologias em radiografias dentárias, ajudando assim os dentistas a identificar mais rapidamente áreas de interesse. Uma vez detetada uma anomalia, a IA pode fornecer análises adicionais para ajudar a caracterizar a natureza e a gravidade da patologia, fornecendo informações adicionais para o diagnóstico. Os sistemas de IA podem fornecer recomendações ou sugestões sobre o caso clínico, ajudando os dentistas a tomar decisões mais informadas e a evitar erros de diagnóstico devido a informações incompletas ou a preconceitos cognitivos (Putra et al., 2022).

Além dos benefícios mencionados anteriormente, a inteligência artificial também pode desempenhar um papel crucial na melhoria das imagens dentárias, reduzindo o ruído e os artefactos. Os algoritmos de IA podem ser treinados para reconhecer padrões de ruído em imagens radiográficas dentárias e filtrá-los de forma eficaz, melhorando assim a clareza da imagem e facilitando a interpretação pelos dentistas. Os algoritmos de *deep learning* podem ser usados para aumentar a resolução das imagens radiográficas dentárias, permitindo uma visualização mais detalhada das estruturas anatómicas e das patologias, mesmo em condições onde a qualidade da imagem inicial é limitada. Eles também podem ser usados para corrigir distorções geométricas ou efeitos de desfoque em

imagens radiográficas, garantindo assim uma representação mais fiel das estruturas dentárias e periodontais (figura 9) (Katsumata, 2023).

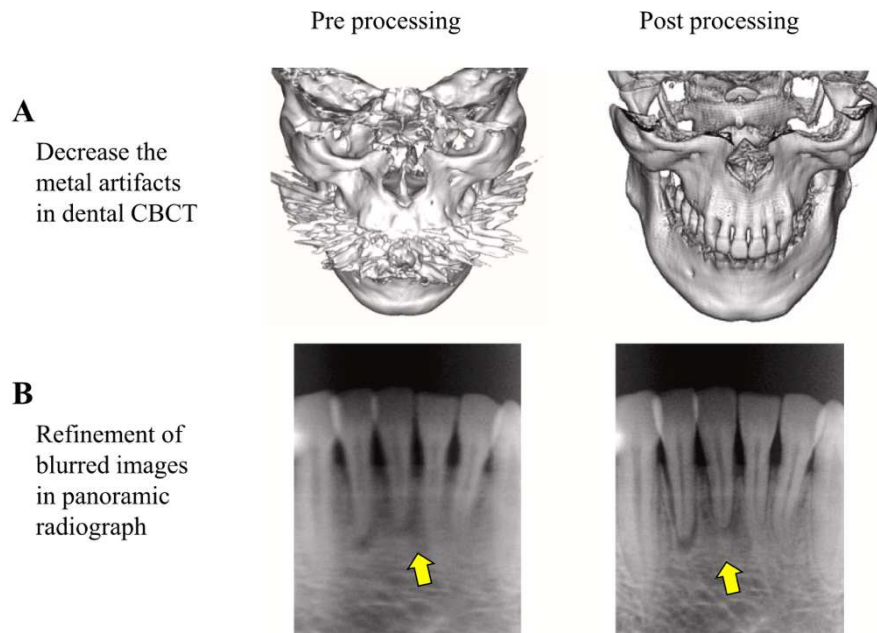


Figura 9. Exemplos de utilitários de processamento de imagens por IA generativa, adaptado de (Katsumata, 2023).

Ao integrar essas capacidades de melhoria de imagem com as funcionalidades de detecção e caracterização de patologias, a IA oferece uma ferramenta poderosa para ajudar os dentistas a diagnosticar de forma mais precisa e eficaz as condições dentárias nos pacientes, melhorando assim a qualidade global dos cuidados dentários (Putra et al., 2022).

III- Benefícios e Aplicações da Inteligência Artificial na Radiologia Dentária

3.1 Generalidades

A inteligência artificial abrange um vasto conceito que combina um conjunto de teorias e técnicas para desenvolver máquinas capazes de imitar a inteligência humana. No campo da medicina, os algoritmos utilizados são principalmente baseados no *deep learning* (LeCun et al., 2015).

Esses algoritmos dependem de um banco de dados contendo muitas situações anotadas por especialistas, como a presença ou ausência de um quisto numa radiografia panorâmica. Através do treino, um modelo matemático é refinado para determinar com precisão se uma situação é saudável ou patológica. Este treino envolve a apresentação repetida dos dados ao algoritmo, que se esforça para minimizar os erros de previsão ajustando a sua vasta gama de parâmetros. Após o treino, o algoritmo adquire a capacidade de anotar novos dados de forma independente. Os avanços significativos realizados por esses algoritmos na última década revolucionaram diversos domínios que utilizam vastos bancos de dados, e alguns desses algoritmos de IA agora estão agora a ser implementados na prática médica (Topol, 2019).

No campo da medicina dentária, há um aumento significativo na pesquisa privada e universitária sobre o uso de IA. Isso deve-se principalmente ao potencial da IA para melhorar a eficiência e segurança das decisões clínicas, proporcionando assim cuidados de melhor qualidade a uma população mais ampla. Esses esforços de pesquisa inicialmente concentraram-se na visão computacional, que permite que as máquinas entendam e manipulem imagens. Esse avanço abre caminho para a automação de várias tarefas, como processamento de imagens e anotação, com uma confiabilidade relatada comparável à dos clínicos experientes, melhorando assim a repetibilidade (Mörch et al., 2021).

Além disso, o processamento automático de linguagem natural, que permite que as máquinas interpretem o significado de um texto escrito ou falado, está sendo explorado. Embora ainda esteja nos seus estágios iniciais, essa abordagem é promissora

na medicina dentária, pois permite extrair automaticamente informações específicas de registos médicos digitais (Chen et al., 2021).

3.1.1 O *Big Data* em Imagem Médica

Os avanços tecnológicos atuais abriram novas perspetivas em vários domínios, incluindo o da saúde, melhorando assim os processos de diagnóstico e tratamento dos pacientes. Este avanço é acompanhado por uma explosão espetacular no volume de dados, aumentando 25 vezes em apenas 10 anos (figura 10) (Gaudiaut, 2021).

Esta abundância de dados agora constitui agora, um desafio importante no campo da saúde. Com efeito, as informações provenientes de resultados médicos e análises dos pacientes poderiam desempenhar um papel crucial na personalização dos tratamentos, no desenvolvimento de sistemas de auxílio ao diagnóstico, bem como na tomada de decisões clínicas e na identificação de fatores de risco e ameaças à saúde (Putra et al., 2022).




Figura 10. O *Big Bang* dos grandes dados Volume estimado de dados digitais criados ou replicados por ano a nível mundial em zettaoctets, adaptado de (Gaudiaut, 2021).

3.1.2 Origem e Desenvolvimento

A inteligência artificial desempenha um papel cada vez mais predominante na nossa vida quotidiana, integrada nos nossos sistemas de computação, navegação e em muitos outros domínios. No entanto, definir a IA não é uma tarefa fácil, pois isso implicaria, desde logo, definir a inteligência em si mesma: "Todo problema sem uma solução algorítmica conhecida é, a priori, um problema de IA", bem como o seu processo de aprendizagem. A IA consiste num conjunto de algoritmos destinados a encontrar soluções para problemas específicos (Ahmad et al., 2022).

A Figura nº 11 ilustra o aparecimento da IA com as ideias de Alan Turing sobre a possibilidade de uma máquina pensante e os conceitos semelhantes de Warren Weaver, que imaginava que tarefas relacionadas à inteligência humana poderiam ser realizadas por máquinas. O uso da IA continua a progredir, especialmente no campo da imagem médica (Santos, 2024).

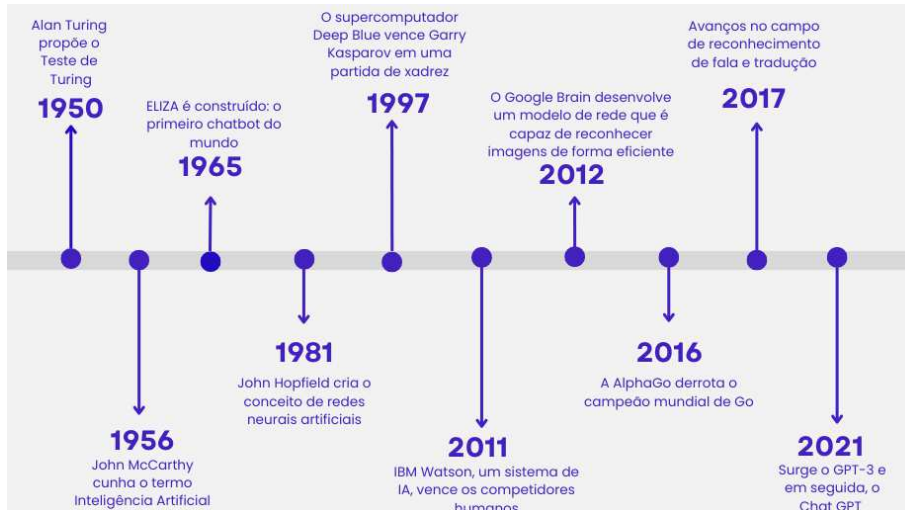


Figura 11. Inteligência artificial através do tempo, adaptado de (Santos, 2024).

Em 1957, o algoritmo mais antigo de IA foi desenvolvido para o reconhecimento de "padrões". No entanto, foi apenas na década de 2010 que o pleno potencial dessas redes foi explorado graças ao *Big Data* e ao processamento massivamente paralelo (L. Bastien, 2023).

A IA está intimamente ligada aos avanços tecnológicos significativos dos últimos anos, com a considerável melhoria no desempenho dos computadores (lei de Moore), permitindo assim o desenvolvimento de novas técnicas (Lundstrom & Alam, 2022).

A IA é fundamentalmente baseada no conceito de aprendizagem, desempenhando um papel essencial na melhoria do desempenho. A aprendizagem é crucial para a IA, permitindo que o sistema se adapte aos dados. Por outras palavras, com a chegada de novas consultas e dados (como a deteção de uma lesão de cárie numa imagem), a IA deve fornecer resultados confiáveis. Em caso de não conformidade com as expectativas, é essencial notificar esses erros para que a IA possa aprender com eles. Assim, em futuras consultas semelhantes, ela será mais eficaz (Y. Chen et al., 2020).

A IA pode ser vista como uma convergência entre matemática, ciência da computação e ciências cognitivas. Embora esse conceito possa parecer futurista, esses sistemas têm sido desenvolvidos há décadas, com várias abordagens como IA por redes neurais, aprendizagem por reforço, etc. (Katsumata, 2023).

3.1.3 Machine Learning

O *machine learning*, um ramo da inteligência artificial, visa capacitar as máquinas a aprender com dados sem uma programação explícita. Baseia-se no uso de técnicas computacionais para permitir que os sistemas melhorem ao longo do tempo, tirando lições diretamente dos dados (Shaveta, 2023).

Três abordagens principais estruturam a aprendizagem da máquina: supervisionada, não supervisionada e por reforço (figura 12).

A aprendizagem supervisionada envolve treinar um modelo num conjunto de dados rotulados, onde cada exemplo de treino está associado a uma saída desejada. O modelo aprende a prever saídas para novas entradas com base nos exemplos fornecidos durante o treino (Kotsiantis, 2007). Por exemplo, no caso da radiologia dentária, um modelo pode ser treinado para detetar automaticamente lesões de cárie em radiografias dentárias usando conjuntos de dados onde cada imagem é rotulada com a localização e a gravidade das lesões de cárie (Hung et al., 2022).

Ao contrário da aprendizagem supervisionada, a aprendizagem não supervisionada não requer rótulos para os dados de treino. Os modelos de aprendizagem não supervisionada buscam descobrir estruturas, relacionamentos ou padrões intrínsecos nos dados (Shaveta, 2023). Por exemplo, no campo da radiologia dentária, a aprendizagem não supervisionada pode ser usada para agrupar automaticamente radiografias dentárias semelhantes com base em características comuns, sem a necessidade de rótulos prévios (Hung et al., 2022).

Na aprendizagem por reforço, um agente de aprendizagem interage com um ambiente e aprende a tomar decisões recebendo recompensas ou penalidades com base nas ações. O objetivo é maximizar as recompensas acumuladas ao longo do tempo (Mendonça et al., 2024). Por exemplo, no campo da radiologia dentária, a aprendizagem por reforço pode ser usado para melhorar a segmentação automática das estruturas

dentárias nas imagens radiográficas, ajustando dinamicamente as decisões tomadas pelo sistema com base nos resultados obtidos (Hung et al., 2022).



Figura 12. Tipos de Aprendizado de Máquina, adaptado de (Maia, 2021).

3.1.4 Deep Learning

O *deep learning* (DL) é uma tecnologia computacional que desencadeou o desenvolvimento de aplicações de inteligência artificial. O DL é um método de aprendizagem da máquina que aplica redes neurais. Uma rede neural é um conjunto de algoritmos com modelos matemáticos que imitam as redes de neurónios no cérebro e tem sido amplamente estudado desde o século XX (Katsumata, 2023).

O *deep learning*, um ramo do *machine learning*, baseia-se no uso de redes neurais artificiais, que, semelhantes ao cérebro humano, são organizadas em várias camadas (figura 13). Essas redes processam dados de entrada, transformando-os sucessivamente por meio dessas camadas para produzir resultados. Uma característica chave dessa abordagem é a sua capacidade de aprender com os dados que processa, o que geralmente requer grandes conjuntos de dados para um treino eficaz. Portanto, recursos computacionais poderosos são necessários para esse processamento (Lee et al., 2017).

Ao analisar grandes conjuntos de imagens anotadas com informações sobre a presença ou ausência de tumores, os algoritmos podem aprender a identificar essas anomalias com uma precisão crescente ao longo do tempo. Essa melhoria de desempenho é alcançada pela experiência, à medida que o sistema é exposto a mais dados e aprimora as suas capacidades de análise (Ahmad et al., 2022).

Ao contrário de uma abordagem tradicional onde cada caso deve ser programado individualmente, o *deep learning* permite que a IA crie os seus próprios algoritmos ao aprender com os dados. Durante esse processo de aprendizagem, métricas de desempenho, como taxas de sucesso, são estabelecidas comparando os resultados da IA com os dos especialistas humanos. Uma vez que o sistema atinge um nível de desempenho considerado satisfatório pelos avaliadores, é considerado estabilizado e pode ser implantado para tarefas reais (Ahmad et al., 2022).

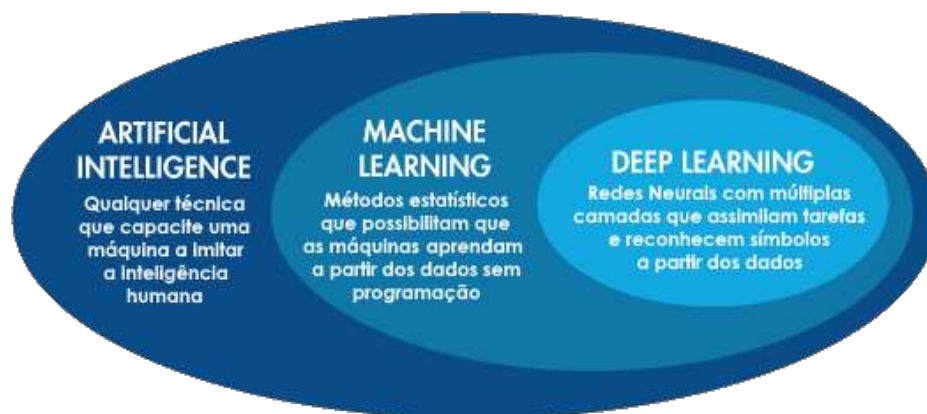


Figura 13. Diferenças entre Inteligência artificial, *Machine Learning* e *Deep Learning*, adaptado de (Lavagnoli, 2023).

O DL demonstrou a sua utilidade na análise e processamento de imagens, processamento de linguagem natural, análise preditiva e controle de sistemas de computador. Além disso, espera-se que a IA seja usada em muitas aplicações odontológicas. Entre os vários métodos de DL, a classificação, detecção de região (objeto) e segmentação são frequentemente aplicadas a imagens diagnósticas (Hung et al., 2022)..

3.1.5 *Convolutional Neural Network (CNN)*

Os *Convolutional neural network*, ou “redes neurais convolucionais” são redes neurais artificiais avançadas e profundas que aprendem representações de características internas e generalizam características de problemas de imagem, processamento de linguagem natural e reconhecimento de voz (Manaswi, 2018).

As CNNs são compostas por neurónios artificiais organizados em camadas de convolução, conectados por sinapses associadas a uma matriz de convolução. Essas redes aplicam filtros às imagens de entrada, movendo-os sobre pequenas seções para produzir mapas de ativação (Pajankar & Joshi, 2022).

O termo "rede neural artificial" surgiu em 1943, no entanto, foi apenas na década de 2010 que o potencial total dessas redes começou a ser explorado devido ao aparecimento do *Big Data* e do processamento massivamente paralelo (Gaudiaut, 2021).

As redes neurais artificiais têm a capacidade de facilitar o *deep learning*. Essas redes são alimentadas por bases de dados, incluindo imagens médicas, que servem como dados de entrada. Em seguida, os neurónios de entrada transmitem esses dados para camadas intermediárias, também conhecidas como camadas ocultas, e então para as camadas de saída. Se um resultado diferente da realidade for obtido, a rede passa por uma adaptação automática realizada por meios matemáticos. Uma aprendizagem eficaz é obtida por meio da repetição desses processos, sendo que a rede é considerada confiável quando pode interpretar com precisão novos dados, como imagens. A experiência desempenha um papel fundamental na aprendizagem autónoma (figura 14) (Ahmad et al. 2022).

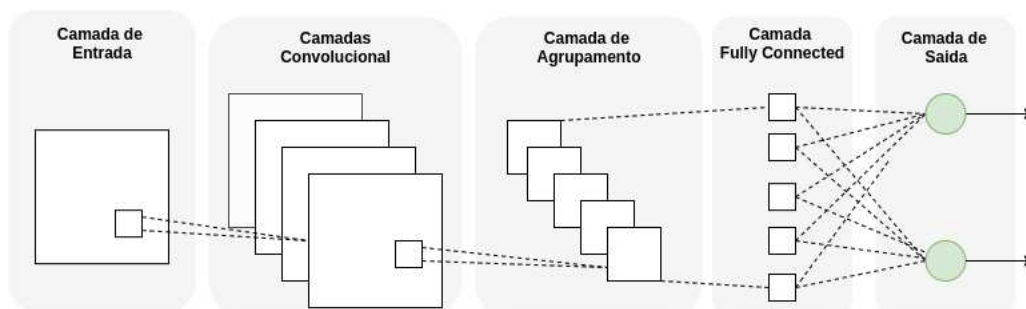


Figura 14. Estrutura simplificada de uma rede neural convolucional, adaptado de (Barbosa et al., 2021).

O estabelecimento de uma rede significativa é realizado por meio da interconexão de neurónios numa camada oculta, onde as informações convergem. É possível ter mais de uma centena de camadas ocultas compostas por um número variável de neurónios. Portanto, cenários complexos podem ser simulados com uma infinidade de conexões. Para utilizar essas redes desenvolvidas, é necessário empregar modelos matemáticos sofisticados em conjunto com um poder computacional significativo. É precisamente por isso que o componente de hardware dos dispositivos de imagem precisa ser eficiente. Frequentemente, múltiplos processadores são usados em paralelo para operar esse tipo de sistema (Ahmad et al. 2022).

As redes neurais convulsionais são usadas para reconhecimento de imagens, recebendo-as num formato de matriz e submetendo-as a duas operações essenciais: filtragem para detetar formas e contornos, e simplificações para extrair informações cruciais. Supõe-se que essa metodologia se inspire no funcionamento do olho e no processamento da informação visual. A camada inicial recebe os dados brutos, de forma análoga à retina do olho. Os recetores visuais recebem dados brutos na forma de raios de luz, que serão então analisados nas camadas neurais profundas do cérebro. Isso destaca o profundo interesse desta técnica para a inteligência artificial (figura 15) (Dejasmin, 2019).

Para ilustrar o funcionamento no contexto, vamos usar o exemplo de uma imagem em tons de cinza, onde um valor é atribuído a cada pixel, 0 representando preto e 1 representando branco. No caso de 1000 pixels, é possível ter 1000 neurónios de entrada, correspondendo a 1000 valores. Cada neurónio recebe um valor numérico que depende das suas conexões da entrada e dos seus pesos associados. Portanto, as informações são propagadas de uma camada para outra, eventualmente alcançando a camada final. Na camada de saída, cada neurónio apresenta um nível de ativação, indicando a percentagem de probabilidade de a imagem médica corresponder a um cenário específico. No início do treino, os resultados obtidos podem ser muito diferentes dos resultados esperados. No entanto, por meio do processo de aprendizagem, torna-se possível corrigir essas disparidades, permitindo que a rede interprete com precisão uma imagem sem cometer erros, e até mesmo analisar imagens desconhecidas. Se o treino foi eficaz, os resultados serão consistentes com as expectativas. Por exemplo, se a imagem analisada representar um tumor (o resultado esperado) e o resultado obtido identificar a presença de um tumor nos pixels correspondentes, o resultado é considerado positivo. Vale ressaltar que a IA continua aprendendo, mesmo quando implantada num equipamento de imagem, e em caso de interpretação incorreta, os radiologistas podem relatar o erro ao sistema (L. Bastien, 2023).

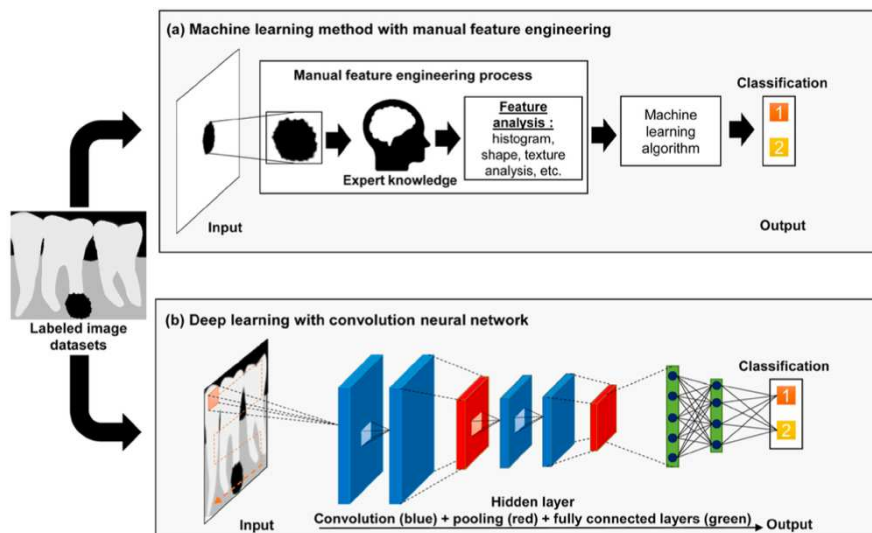


Figura 15. Diferença entre *machine learning* e *deep learning* para classificação de patologias periapicais. (a) ML confia no conhecimento do perito para executar a extração da característica das lesões periapicais nas imagens. As características mais robustas são alimentadas no classificador ML para fazer uma previsão precisa; e (b) DL, representado pela rede neural de convolução, pode executar simultaneamente a extração de recursos e a seleção para a classificação de tarefas, levando vários *Layers* ocultos que podem aprender automaticamente os recursos relevantes das imagens, adaptado de (Putra et al., 2022).

3.1.6 DICOM

O DICOM, abreviação de *Digital Imaging and Communications in Medicine* (ou comunicação de imagens digitais em medicina), é um conjunto de normas para tratamento, armazenamento e transmissão de informação médica num formato eletrónico, estruturando um protocolo (Burgess, 2015).

Um aspeto crucial a ser considerado diz respeito à padronização dos dados de imagem no formato DICOM. A tecnologia DICOM permite padronizar os formatos de imagem e meta dados, garantindo assim a compatibilidade e interoperabilidade entre os diferentes sistemas de imagem dentária. Isso permite o armazenamento, transmissão e recuperação eficientes de imagens dentárias, facilitando uma integração suave com registos médicos eletrónicos e outros ecossistemas digitais de saúde (Burgess, 2015).

As funcionalidades de recuperação de imagens com base nos meta dados do DICOM permitem o acesso fácil a imagens dentárias específicas com base em informações relevantes, melhorando assim a eficiência do fluxo de trabalho. Mais especificamente, esses dados devem ser provenientes da mesma modalidade de imagem e apresentar uma variabilidade mínima. Sem essa padronização, a confiabilidade dos

resultados de diferentes modelos de IA seria seriamente comprometida, assim como a confiança que os radiologistas depositam na solução (Caffery et al., 2021).

3.1.7 Principais Tarefas dos Algoritmos de IA Baseados em Imagem

A aplicação de IA pode ser estendida a todas as áreas da saúde que envolvem conjuntos de dados extensos. A imagem médica abrange dados diversos e volumosos, oferecendo potenciais benefícios significativos para os pacientes, justificando assim a integração da IA (Ahmad et al., 2022).

Atualmente, a maioria dos algoritmos inteligentes baseados em imagens dentárias foi desenvolvida para tarefas automatizadas de detecção, segmentação e classificação (figura16) (Putra et al., 2022).

A tarefa de detecção visa identificar a posição do objeto de interesse nas imagens. Uma série de algoritmos de detecção de objetos começa gerando propostas de regiões com caixas delimitadoras retangulares que contêm o objeto rotulado, e então, calculando as características da imagem, classificam-nas em diferentes categorias de objetos (Zhao et al., 2019).

LeNet, AlexNet, ZFNet, GoogLeNet/Inception, VGG Net, DenseNet e ResNet são modelos CNN pré-treinados populares que são amplamente utilizados como base para desenvolver algoritmos inteligentes personalizados para tarefas relacionadas com a detecção de objetos (Do et al., 2020).

A tarefa de segmentação visa delimitar o contorno do objeto de interesse nas imagens. A segmentação de objetos a partir de imagens radiográficas 2D/3D foi realizada com base na avaliação de cada pixel/voxel na região de interesse e na atribuição de cada pixel/voxel a diferentes classes. Algoritmos inteligentes personalizados para tarefas relacionadas à segmentação geralmente são construídos com base em U-Net e Mask-RCNN (Do et al., 2020).

A tarefa de classificação visa atribuir os objetos de interesse identificados a diferentes categorias pré-definidas, analisando as diferenças entre as características extraídas de diferentes objetos nas imagens. Os classificadores comumente usados para

classificação binária incluem regressão logística, *k-nearest neighbors*, árvores de decisão, *random forest*, *support vector machine* (SVM) e *naive Bayes* (Putra et al., 2022).




Figura 16. Tarefas mais comuns de visão por computador com um exemplo de reconhecimento de lesões de cárie dentária, adaptado de (Putra et al., 2022).

Os algoritmos inteligentes desenvolvidos para tarefas de detecção e segmentação geralmente são treinados com dados de imagens rotuladas com anotações manuais precisas dos objetos alvo em imagens 2D/3D. Para os algoritmos desenvolvidos para a classificação automática de diferentes objetos em imagens, a anotação manual de diferentes objetos usando diferentes etiquetas geralmente é necessária (Hung et al., 2022).

3.2 Aplicações Clínicas de IA

3.2.1 Endodontia

A avaliação endodôntica envolve a avaliação de vários aspectos relacionados com os canais radiculares e patologias periapicais. Foram desenvolvidos algoritmos de IA personalizados para aplicações endodônticas, incluindo detecção automática de patologias periapicais, fraturas radiculares e determinação do comprimento de trabalho. Esses algoritmos utilizam diferentes modalidades de imagem, como radiografias periapicais e imagens CBCT, para diagnóstico e medição precisos (Hung et al., 2022).

Orhan et al. (2020) buscaram segmentar lesões periapicais num modelo baseado em *deep learning* e demonstraram alta confiabilidade (92,8%) na detecção correta de lesões periapicais.

Os modelos desenvolvidos por Johari et al. (2016) baseado num CNN para detetar fraturas radiculares verticais em radiografias periapicais e CBCT alcançaram precisão máxima de 70% em radiografias periapicais e 96,6% em imagens CBCT (figura 17). Estudos mostraram que a IA aplicada às imagens CBCT oferece maior precisão do que às radiografias. No entanto, é importante notar que esses estudos se concentraram apenas em dentes de raiz única, não tratados com endodontia, exigindo mais pesquisas em dentes de raízes múltiplas com obturações endodônticas.

Algoritmos inteligentes também foram desenvolvidos para auxiliar na avaliação dos canais radiculares e determinação do comprimento de trabalho. Jeon et al. (2021) construíram um modelo baseado num CNN para prever canais em forma de C em molares mandibulares em radiografias panorâmicas, alcançando excelente desempenho diagnóstico com precisão de 95,1%, sensibilidade de 92,7% e especificidade de 97%.

Saghiri et al. (2012) desenvolveram um algoritmo inteligente baseado num CNN para classificar a relação entre a ponta da lima endodôntica e o foramen apical em três grupos (longo, curto e exato) em radiografias periapicais, alcançando maior precisão de classificação (96%) do que dois endodontistas (76%). O modelo proposto pode ser útil para determinar se a lima endodôntica alcança perfeitamente o comprimento de trabalho.

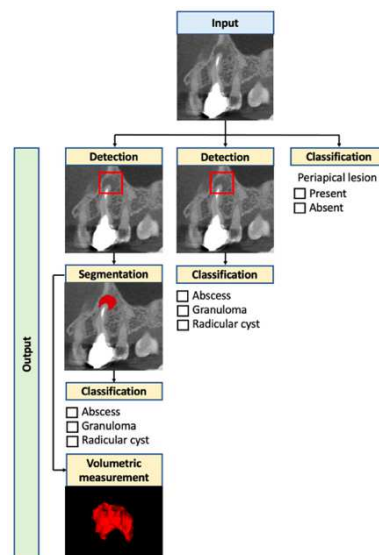


Figura 17. Ilustrando as principais tarefas impulsionadas por IA com um exemplo da lesão periapical de um primeiro pré-molar superior esquerdo mostrado em imagens de CBCT. A tarefa de detecção identifica as lesões periapicais presentes nas imagens e localiza as lesões identificadas. A tarefa de segmentação separa as lesões periapicais dos tecidos saudáveis adjacentes e permite a medição volumétrica

automatizada. A tarefa de classificação categoriza as lesões periapicais identificadas em grupos de abscesso, granuloma e quisto radicular, ou categoriza os casos de acordo com a presença ou ausência de uma lesão periapical, adaptado de (Hung et al., 2022).

3.2.2 Ortodontia

Um diagnóstico preciso, planejamento de tratamento e previsão de prognóstico são elementos cruciais para a implementação bem-sucedida de um tratamento ortodôntico. O uso de IA tem sido empregue para determinar a necessidade de extrações antes de iniciar o tratamento ortodôntico. Jung e Kim (2016) demonstraram uma taxa de precisão de 92% usando um sistema especializado de IA para determinar a necessidade de extração de dentes permanentes com base em teleradiografias de perfil. Os resultados do estudo sugerem que os modelos de IA são eficazes e precisos para prever a necessidade de extrações, sendo assim uma ferramenta valiosa de tomada de decisão clínica.

Muitos estudos têm sido realizados para demonstrar a aplicação de tecnologias de IA na identificação de pontos cefalométricos. J. Park et al. (2019) conduziram um estudo comparando a eficácia e precisão de algoritmos avançados de *deep learning* para a identificação automática de pontos cefalométricos em radiografias cefalométricas. Os resultados indicaram uma precisão excepcional na identificação de pontos cefalométricos, comparável à de avaliadores humanos qualificados, usando um algoritmo de IA especializado e um sistema de identificação automática baseado em *deep learning*, respectivamente.

Yu et al. (2020) obtiveram resultados excepcionais na classificação automatizada de estruturas esqueléticas com base em cefalometria lateral usando um modelo de IA. Os resultados dos estudos mencionados sugerem que esses sistemas estão a tornar-se uma opção viável para a identificação consistente de vários pontos cefalométricos.

Estabelecer um diagnóstico e plano de tratamento precisos desempenha um papel essencial no sucesso da cirurgia ortognática. A tecnologia de IA contribui ativamente para melhorar a precisão e exatidão dos profissionais de medicina dentária. Choi et al. (2019) apresentaram a aplicação de um novo modelo de IA para determinar a adequação de intervenção cirúrgica ou não cirúrgica com base em teleradiografias de perfil. O sistema mostrou-se altamente eficaz, alcançando uma taxa de sucesso diagnóstico de 96% na

distinção entre casos que necessitam de intervenção cirúrgica e aqueles que não necessitam. Esse modelo mostrou resultados promissores, oferecendo assim a capacidade de diagnosticar casos que requerem cirurgia ortognática.

A idade de um doente nem sempre indica o estágio de desenvolvimento do seu corpo. Por conseguinte, é necessário criar vários indicadores de maturação do esqueleto. A identificação do crescimento e desenvolvimento, juntamente com a avaliação dos estágios de maturação do esqueleto, tem sido usada para antecipar o início do desenvolvimento pubertário, determinar a taxa de crescimento e, especialmente, avaliar o potencial de crescimento e desenvolvimento residual de um indivíduo. Esses parâmetros são geralmente determinados por radiografias da mão e do punho, análises cefalométricas e avaliação dos estágios de maturação da vértebra cervical (Khanagar, Al-Ehaideb, et al., 2021).

A tecnologia de IA também tem sido usada para determinar o crescimento e desenvolvimento com base nos estágios das vértebras cervicais. Kök et al. (2019) demonstraram uma precisão média de 77,02% usando algoritmos de IA para avaliar o crescimento e desenvolvimento com base nos estágios das vértebras cervicais quando aplicados a teleradiografias de perfil.

3.2.3 Periodontologia

A doença periodontal é uma das condições orais mais comuns observadas na população humana. É amplamente reconhecido que a natureza progressiva da doença periodontal contribui significativamente para a perda prematura de dentes em adultos. (Lee et al., 2018)

Muitas pesquisas foram realizadas para validar o uso da tecnologia de inteligência artificial na detecção e prognóstico de doenças periodontais. Num estudo conduzido por Lee et al. (2018), um sistema de diagnóstico assistido por computador foi introduzido, aproveitando um sofisticado algoritmo de CNN para identificar e prever condições periodontais nos dentes. Os resultados demonstraram uma taxa de precisão preditiva razoavelmente alta de 78,9%.

Da mesma forma, Yauney et al. (2019) utilizaram um quadro de IA baseado num CNN para estabelecer uma correlação entre uma saúde periodontal inadequada e implicações de saúde sistémica mais amplas, sugerindo que a IA é promissora para processos de diagnóstico automatizado e poderia ser uma ferramenta valiosa para a deteção precoce de diversas doenças.

Além disso, Krois et al. (2019) usaram CNN para identificar casos de perda óssea periodontal através da análise de radiografias dentárias panorâmicas. Os resultados dessa pesquisa refletiram de perto aqueles obtidos de avaliações de especialistas, destacando o potencial desse sistema para racionalizar os procedimentos de diagnóstico dos profissionais de medicina dentária.

3.2.4 Oclusão

A osteoartrite da articulação temporomandibular (ATM) é uma doença degenerativa de origem desconhecida, caracterizada pela progressiva degeneração da cartilagem, perda óssea subsequente e remodelação do osso subcondral. Uma técnica não invasiva como o *Shape Variation Analyzer* (SVA) ajuda-nos a detetar e analisar mudanças na forma da osteoartrite. O SVA classifica modelos tridimensionais (3D) de variações de tipos de côndilos usando redes neurais. A análise é baseada na aparência normal, curvatura e medição de distâncias para obter valores médios e características dos diferentes tipos de côndilos. As características usadas para a análise são puramente geométricas e permitem classificar os côndilos em seis grupos. Os seis grupos são os seguintes: 1 = sobre crescimento, 2 = próximo do normal, 3 = degeneração-1, 4 = degeneração-2, 5 = degeneração-3 e 6 = degeneração-4 (figura 18) (Kale et al., 2023).




Figura 18. As diferentes formas do côndilo mandibular, adaptado de (Kale et al., 2023).

Esta é uma ferramenta recente que permite analisar a variação da forma do côndilo na osteoartrite da ATM. Trabalhos futuros devem permitir que os dentistas insiram dados clínicos na rede neural que ajudará a analisar de forma mais eficaz o processo da doença, correlacionando-o com as mudanças morfológicas no SVA (De Dumast et al., 2018).

3.2.5 Prostodontia

As próteses parciais removíveis suportadas por dentes ou implantes são uma opção de tratamento menos invasiva e mais econômica para reabilitar dentes em falta. O desenho dos diferentes aspectos de uma prótese parcial removível é uma etapa importante na fabricação de uma prótese. Um modelo de auxílio à decisão clínica que aplica raciocínio baseado numa base de próteses muito vasta mostrou-se capaz de propor o desenho de próteses removíveis individualizadas. No entanto, esse modelo baseia as suas recomendações no exemplo mais provável do banco de dados. Dado que os contextos clínicos variam constantemente, é necessário manter alguma dúvida sobre os seus resultados (Y. Chen et al., 2020).

Da mesma forma, foram desenvolvidos algoritmos de inteligência artificial para facilitar o desenho de próteses dentárias fixas. No caso das próteses dentárias fixas, a estrutura dentária original será digitalizada e um software será usado para avaliar e propor outras opções de tratamento. Um sistema de IA em prótese fixa ainda está em desenvolvimento. A principal característica da IA é a sua capacidade de analisar e

aprender com os milhões de coroas aprovadas por médicos na base de dados, que é regularmente enriquecida na nuvem. O computador avalia como cada restauração é construída para alcançar uma função ideal, com base na oclusão perfeita, contatos e margens adaptados a cada caso, aprendendo com desenhos de coroas bem-sucedidas (figura 19) (Singi et al., 2022).




Figura 19 . Ilustração do impacto da inteligência artificial no registo da relação maxilo-mandibular (RMM). (a) O registo inicial mostra contactos demasiado fortes em certos dentes posteriores. Após a utilização de uma solução de inteligência artificial, (b) a RMM é otimizada, adaptado de (Ducret et al., 2022).

A linha marginal da preparação do dente tem um impacto significativo na adaptação marginal da coroa ou prótese. Dos métodos anteriores, a extração da linha marginal baseia-se principalmente na interação manual, que é complicada e por vezes ineficaz. Zhang et al. (2019) conduziram uma pesquisa sobre modelos de *deep learning* para extrair as linhas marginais com precisão. Este estudo envolveu 380 modelos de preparo dentário. Para extrair os dados, um modelo de CNN, chamado *Sparse Octree* (S-Octree), foi usado. Com a ajuda do procedimento de preparo dentário, foi criada uma nuvem de pontos esparsa com etiquetas. Para o estudo, uma estrutura octree com oito profundidades foi criada. Os dados foram divididos em três conjuntos: treino, validação e teste. Os modelos CNN foram construídos rotulando os preparos dentários. Métodos de retroprojeção e extração de limites foram usados no estudo, e uma linha de preparo dentário foi extraída para superar as desvantagens da prática manual. A precisão média alcançada foi de 97,43%. Essa precisão aumentada demonstrou a capacidade da IA de superar erros manuais, tornando-a uma alternativa viável a ser adotada (figura 20).

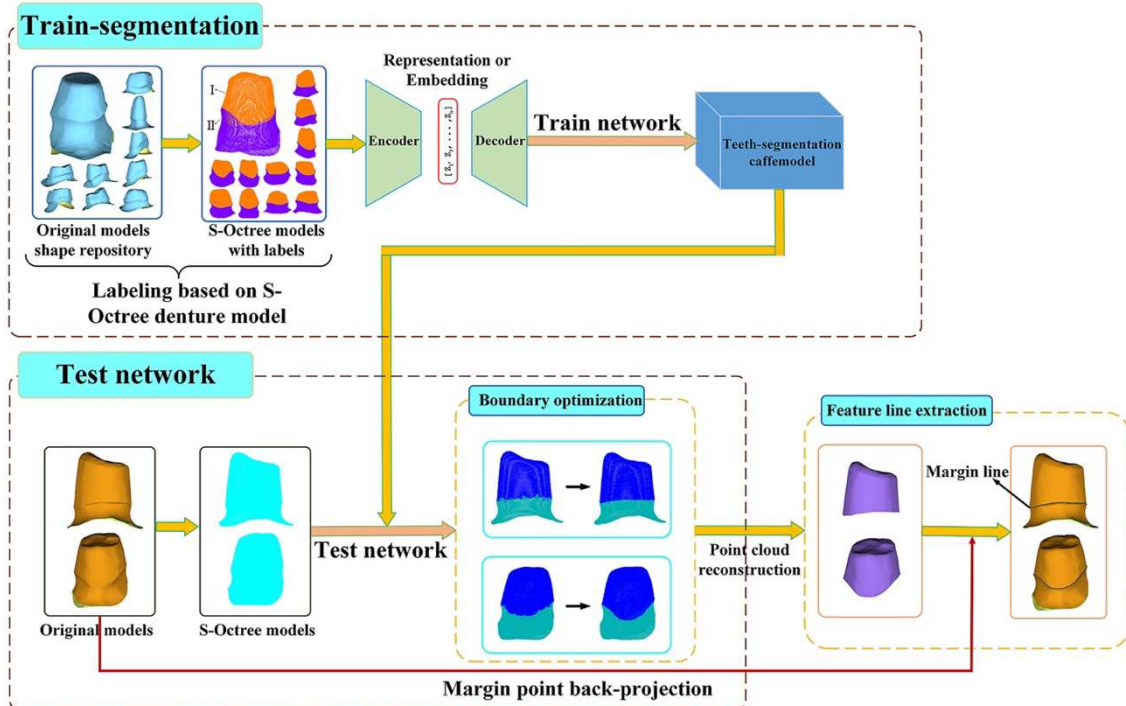


Figura 20. Modelo *Sparse Octree*. O modelo de rede toma como entrada a nuvem de pontos de preparação dentária baseada na octree esparsa e gera uma previsão de etiquetas, a que se segue a otimização dos limites, a reconstrução da nuvem de pontos e a retroprojeção para obter o resultado, adaptado de (Zhang et al., 2019).

3.2.6 Implantologia

Os planos de tratamento para implantes dentários podem ser bem-sucedidos quando a imagem da CBCT e os scanners intraorais são combinados. A aplicação de IA na implantologia oferece a oportunidade de combinar os dois e desenvolver futuras próteses (Y. Chen et al., 2020).

Para determinar de forma consistente e automática a localização precisa do canal mandibular para cirurgias de implante dentário, especialistas do Centro Finlandês de Inteligência Artificial, do Instituto Alan Turing, da Planmeca e do Hospital Universitário de Tampere propuseram um novo modelo. Ao aplicar o reconhecimento de objetos baseado em DL, sistemas de implantes podem ser detetados a partir de radiografias panorâmicas. A IA foi implementada na medicina dentária de implantes para detetar tipos de implantes a partir de radiografias periapicais e panorâmicas (Alshadidi et al., 2023).

Quando tecnologias CAD/CAM padrão são aplicadas à colocação de próteses sobre implantes, vários problemas podem surgir. Erros de posicionamento, erros de

selamento e correções oclusais ou interproximais com um pilar podem todos contribuir para erros. Lerner et al. (2020) apresentaram um modelo de IA para reduzir esses erros. Este modelo de IA foi projetado para facilitar a criação de próteses sobre implantes com coroas monolíticas de zircónia. Utilizando um modelo de IA para facilitar a detecção das margens subgingivais dos pilares (figura 20). Dados de pacientes de 2016 a 2019 foram utilizados no estudo utilizando próteses implantares de zircónia nos dentes posteriores. O uso de um modelo de IA na produção de implantes de zircónia para dentes posteriores apresentou resultados promissores, com uma taxa de sobrevivência de 91% e uma taxa de sucesso de 93%. Os resultados do modelo de IA, revelando uma alta taxa de sobrevivência e sucesso, demonstraram a capacidade do modelo de ser integrado neste domínio (figura 21) (Lerner et al., 2020).

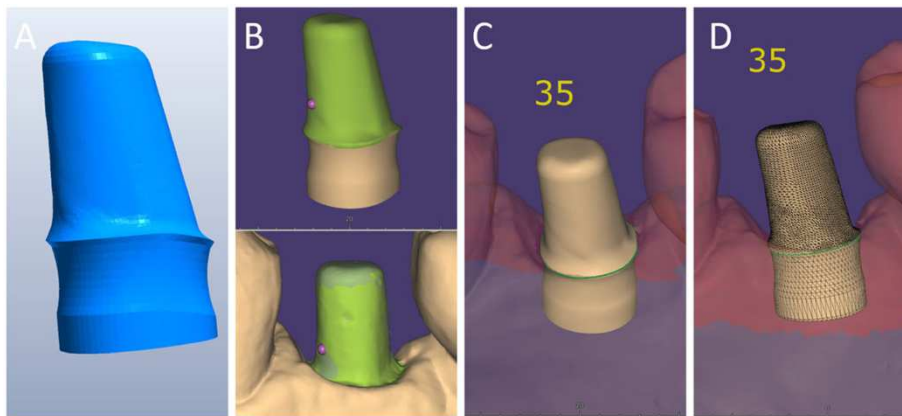


Figura 21. Aplicação da Inteligência Artificial para implantes dentários. (A) O ficheiro original do desenho CAD do pilar individual, que foi previamente guardado numa pasta dedicada, é recuperado pelo sistema. (B) O desenho CAD original do pilar é sobreposto na malha capturada intra-oralmente. (C) Deteção automática da linha de margem. (D) Detalhes do modelo CAD original, no qual as margens do pilar, embora subgingivais, estão claramente representadas e visíveis, adaptado de (Lerner et al., 2020).

Antes da intervenção cirúrgica propriamente dita, a IA contribuiu para o planeamento das operações em minúcia. A utilização de metodologias e tecnologias baseadas em pesquisa e clinicamente estabelecidas ajudará a padronizar a terapia implantar. Muitas vezes é necessário determinar quais os implantes dentários que foram colocados num paciente. Foi efetuado um estudo de redes neurais profundas para classificar os sistemas de implantes dentários. Foram avaliadas cinco modalidades de redes neuronais profundas e concluíram que a rede VGG16, com uma afinação fina, apresentou os melhores resultados na classificação de sistemas de implantes dentários (figura 22) (Heo et al., 2021).




Figura 22 . Exemplo dos mapas de ativação de classes das cinco redes de classificação para quatro tipos de implantes, adaptado de (Heo et al., 2021).

Após a aquisição de um scanner intraoral e CBCT, com base na espessura dos tecidos, tipo e espessura óssea, perfil de emergência e histórico médico do paciente, a IA combinará automaticamente os dois scans, projetará o futuro implante apropriado com o design adequado na posição ideal. Em seguida, a guia cirúrgico pode ser criada e o procedimento executado (Y. Chen et al., 2020).

Modelos preditivos de IA podem ser úteis noutras áreas da implantologia dentária. Primeiro, algoritmos de aprendizagem automática foram utilizados para desenvolver modelos preditivos focados em níveis ósseos e resultados clínicos individuais. Avaliando simultaneamente o sistema de implantes, dados dos pacientes e operações dos cirurgiões, uma rede neural artificial com otimização de pesquisa mimética produziu uma eficácia de 99,2% nas previsões de taxas de sucesso (Singi et al., 2022).

Em segundo lugar, a IA foi proposta para substituir a tecnologia atual na antecipação das propriedades mecânicas de um sistema de bio implante, reduzindo assim o custo elevado dos cálculos necessários para melhorar as variáveis de design do implante. A aplicação da IA na otimização dos riscos dos bio-implantes ainda precisa ser desenvolvida (Singi et al., 2022).

3.2.7 Dentisteria

3.2.7.1 Detecção e Segmentação

A tarefa de segmentação em *deep learning* é uma técnica que divide uma imagem em segmentos objetivos. Na segmentação semântica, os objetos a serem selecionados são distinguidos do fundo e de outros objetos usando cores diferentes. Na segmentação por instância, é possível identificar e separar instâncias individuais da mesma classe de objetos. Este procedimento pode ser adequado para identificar dentes em radiografias panorâmicas com uma visão clara (Umer et al., 2022).

A detecção e segmentação de regiões também podem ser consideradas técnicas complementares. No entanto, ao criar dados de anotação para preparar o conjunto de dados de treino, a segmentação é necessária para traçar com precisão o contorno do alvo, enquanto a detecção de região apenas cerca o alvo com um retângulo aproximado. A tarefa de segmentação geralmente é considerada mais apropriada do que a detecção de região para extrair estruturas anatômicas e lesões específicas e detalhadas.

A segmentação permite extrair estruturas anatômicas específicas e detalhadas, e lesões. Em radiografias panorâmicas, uma tarefa de segmentação é realizada para extrair o canal mandibular e o seio maxilar (figura 23) (Cha et al., 2021).

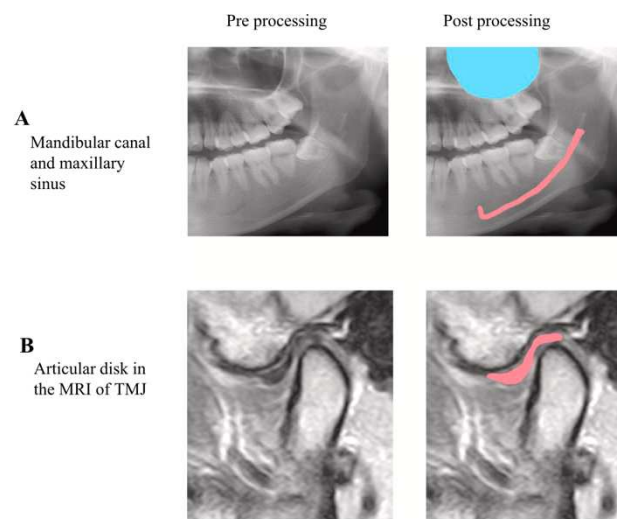


Figura 23. Segmentação da estrutura anatômica, adaptado de (Katsumata, 2023).

Um algoritmo de DL para a detecção automática de dentes em radiografias panorâmicas é considerado um avanço na prática dentária. Cada dente detectado é classificado de acordo com o seu estado patológico e tratamento, como a presença de

lesões de cárie, distúrbios de erupção, com tratamentos restauradores, protéticos ou endodônticos, e implantes dentários. Esta técnica é útil não só para diagnosticar a doença dentária de um paciente, mas também para obter automaticamente informações completas sobre a dentição do mesmo (Katsumata, 2023).

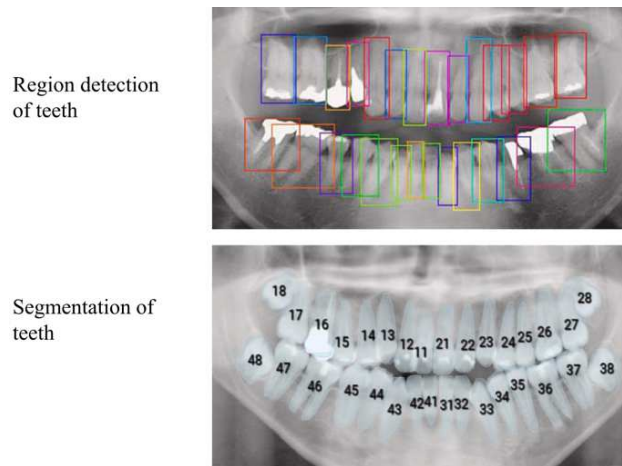


Figura 24. Detecção automática de regiões e segmentação de dentes na radiografia panorâmica, adaptado de (Katsumata, 2023).

3.2.7.2 Cárie Dentária

A IA pode fornecer uma capacidade adicional para reconhecer certas patologias, como lesões de cárie proximais que às vezes passam despercebidas a olho nu em radiografias devido ao ruído da imagem e/ou baixo contraste. Geetha et al. (2020) desenvolveram modelos de IA que podem ajudar os clínicos a identificar automaticamente lesões de cárie dentária em radiografias. Usando diversas técnicas de processamento de imagem seguidas por classificadores de *Machine Learning*, muitos estudos demonstraram resultados muito eficazes (precisão de 86 a 97%) na classificação de cárie dentária em radiografias.

J. Choi et al. (2016) propuseram um método de CNN baseado em *deep learning* não só para a classificação, mas também para a detecção de lesões de cárie dentaria em radiografias periapicais, e mostraram resultados promissores com uma combinação de várias técnicas de processamento de imagem com CNN para detetar lesões de cárie proximais.


Lee et al. (2018) aplicaram o método de *deep learning* por transferência de arquiteturas CNN profundas para a detecção automática de lesões cárie de dentária. A detecção automática de lesões de cárie dentária, especialmente em regiões proximais, é

útil, pois às vezes é difícil para os dentistas identificar lesões de cárie em algumas áreas devido à exposição desigual aos raios X, diferentes sensibilidades do sensor receptor e variabilidade natural na densidade ou espessura do dente (figura 25). Dados os resultados promissores, mais estudos são necessários para otimizar a aplicação da IA para a detecção e segmentação de lesões de cárie dentária em radiografias.



Figura 25. Detecção automática de cárie dentária. a. A cárie dentária está presente na caixa retangular da imagem (classificação). b. A cárie dentária é detectada na caixa quadrada (detecção). c. Uma cárie dentária é segmentada na imagem (segmentação), adaptado de (Heo et al., 2021).

Com o aparecimento da radiografia digital, os dentistas agora podem usar métodos avançados de reconhecimento de padrões para o diagnóstico de lesões cariosas incertas. O programa de detecção de lesões de cárie *Logicon* é um desses métodos que permite inspecionar uma lesão cariosa potencial para determinar sua extensão e a necessidade de tratamento. O programa permite o uso de uma zona, com a qual o dentista deve designar a região de interesse do dente suspeito de ter lesões de cárie dentária. O programa delimita a superfície do dente e define a junção dentina-esmalte. O programa é treinado para detectar mudanças na densidade do dente, que aparecem na forma de diferentes tons de cinza. A variação de densidades é determinada ao longo dos contornos do dente, paralelamente à junção dentina-esmalte e à superfície do dente. Um gráfico separado chamado "densidade do dente" é exibido com as mudanças ao longo de cada contorno do dente. A análise fornece detecção ao longo de vários contornos do dente, tanto no esmalte como na dentina. O programa automaticamente busca uma correlação entre os vales de densidade e a doença cariosa presente. Essa queda de densidade é destacada por pontos vermelhos no traçado de densidade, e as margens da queda de densidade também são destacadas em vermelho na imagem do dente (figura 26) (Kale et al., 2023).



— Radiolucency Outline

Figura 26. Variação de densidades ao longo dos contornos do dente. A seta preta mostra a junção dentino-esmalte, adaptado de (Kale et al., 2023).

3.2.8 Cirurgia

A extração cirúrgica dos terceiros molares mandibulares (TMM) impactados é um dos procedimentos cirúrgicos mais comuns. A lesão do nervo alveolar inferior (NAI), localizado dentro do canal mandibular (CM), não é incomum na prática clínica. Uma lesão do NAI pode resultar em anestesia ou disestesia permanente do lábio inferior ipsilateral e, portanto, afetar a qualidade de vida dos pacientes (Hung et al., 2022).

Como o risco de lesão do NAI está diretamente relacionado à proximidade anatômica do NAI e das raízes de um TMM, vários algoritmos inteligentes foram desenvolvidos para avaliar a relação entre os TMM e o CM. Fukuda et al. (2020) construíram três modelos CNN, usando respectivamente as arquiteturas VGG-16, AlexNet e GoogLeNet para classificar as relações entre os TMM e o CM em tipos de contato e não contato em radiografias panorâmicas. Os modelos CNN alcançaram altas performances de classificação com os valores AUC (Área Sob a Curva) mais altos variando de 0,88 a 0,93.

Liu et al. (2021) propuseram um modelo CNN para classificar a relação entre os TMM e os MC em imagens CBCT. O modelo proposto foi construído usando U-Nets para detecção e segmentação automática dos TMM e MC e usando ResNet-34 para classificar sua relação como separação, contato ou invaginação. Foi destacado que o modelo proposto deve ser aprimorado envolvendo outros fatores influentes (como direção

de impactação, profundidade de impactação e morfologia das raízes TMM) para uma avaliação mais aprofundada do nível de dificuldade e risco da extração TMM.

Yoo et al. (2021) desenvolveram um modelo CNN baseado na arquitetura ResNet-34 pré-treinada para prever a dificuldade da extração de TMM a partir de radiografias panorâmicas. A dificuldade de extração foi prevista com base no índice de dificuldade de Pederson, incluindo profundidade e angulação de um TMM e sua relação com o ramo da mandíbula. Precisoões favoráveis foram obtidas para classificação de profundidade (78,9%), relação com o ramo (82%) e angulação (90,2%), respectivamente. O modelo CNN proposto poderia ajudar cirurgiões orais a avaliar o nível de dificuldade da extração do TMM e facilitar a comunicação entre o paciente e o clínico. No entanto, esse modelo não permite avaliar a morfologia detalhada das raízes TMM. Seria desejável aprimorar ainda mais este modelo CNN para poder avaliar a morfologia das raízes (angulação transversal, dilaceração e curvatura parcial).

3.2.9 Detecção de Quistos e Tumores

O diagnóstico diferencial de lesões radio transparentes nas mandíbulas é um desafio para dentistas generalistas. Devido à semelhança nos resultados radiológicos em alguns quistos e tumores maxilofaciais, mesmo radiologistas experientes só podem fornecer diagnósticos provisórios em alguns casos complicados. Portanto, o desenvolvimento de algoritmos inteligentes para ajudar a diferenciar vários quistos e tumores da mandíbula é clinicamente válido (Heo et al., 2021).

Endres et al. (2020) desenvolveram um algoritmo inteligente baseado na arquitetura U-Net para detectar e segmentar lesões radio transparentes (infecções, granulomas, quistos e tumores) na mandíbula ou nos maxilares em radiografias panorâmicas. O algoritmo proposto superou 14 dos 24 cirurgiões orais e maxilofaciais, atingindo uma VPP (Valor Preditivo Positivo) de 67% e uma sensibilidade de 51%.

Poedjiastoeti e Suebnukarn (2018) construíram um modelo CNN usando o VGG-16 e uma técnica de *deep learning* de transferência para detectar automaticamente ameloblastomas e queratoquistos odontogénicos (QO) em radiografias panorâmicas. Este modelo CNN alcançou uma precisão de 83%, sensibilidade de 81,8% e especificidade de 83,3% com um tempo médio de diagnóstico de 38 segundos (figura 27).

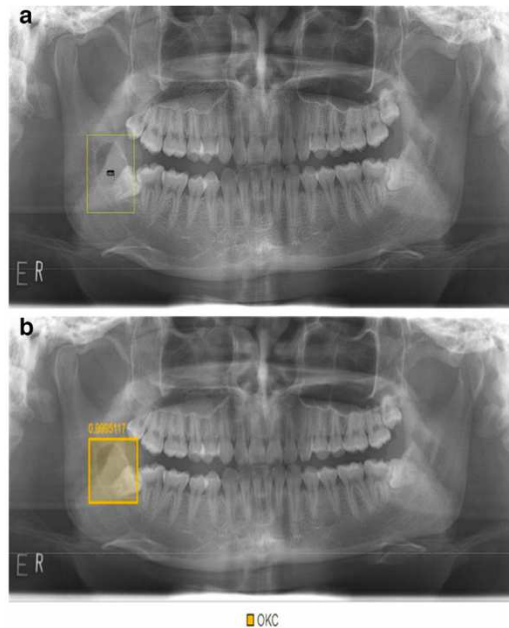


Figura 27. Detecção automática de QO. a. O queratoquisto odontogénico é identificado na zona posterior direita da mandíbula numa radiografia panorâmica. b. A lesão é detectada automaticamente utilizando o *deep learning*, adaptado de (Heo et al., 2021).

Ariji et al. (2019) desenvolveram um modelo CNN usando DetectNet para não apenas detetar, mas também classificar cinco lesões radio transparentes (ameloblastomas, QO, quistos dentígeros, quistos radiculares e quistos ósseos) na mandíbula em radiografias panorâmicas. Altas sensibilidades de deteção de quase 90% foram obtidas para todas as lesões, enquanto uma sensibilidade de classificação relativamente baixa de 13% foi observada para QO. A sobreposição das fossas nasais, seios maxilares e palato duro em radiografias panorâmicas complica o diagnóstico de lesões radio transparentes na maxila.

Lee et al. (2019) construíram modelos CNN usando a arquitetura GoogLeNet Inception v3 e técnicas de deteção automática de margens para detetar, segmentar e classificar três lesões radio transparentes (QO, quistos dentígeros e quistos radiculares) em radiografias panorâmicas e imagens de CBCT, respetivamente. O modelo baseado em CBCT obteve melhores desempenhos diagnósticos do que o modelo usando radiografias panorâmicas, provavelmente porque pode detetar com precisão os limites da lesão em 3D e extrair características quantitativas das unidades de voxel.

Alguns algoritmos de *deep learning* também foram desenvolvidos a partir de imagens de tomografia computadorizada com reforço de contraste para detecção de metástases em linfonodos cervicais em pacientes com cancro de boca/cabeça e pescoço. Esses algoritmos podem ajudar os clínicos a detetar precocemente metástases em linfonodos cervicais e, portanto, fornecer uma estratégia de tratamento personalizada que pode melhorar os resultados do tratamento (Ariji, Fukuda, et al., 2019).

3.2.10 Medicina Dentária Forense

A medicina dentária forense lida principalmente com a identificação de vítimas de desastres em massa, onde apenas a identificação visual apresenta erros significativos. O forense cuida dos restos dentários das vítimas e compara-os aos dados dentários da pessoa desaparecida, o que é frequentemente crucial para estimar a idade das vítimas. A identificação do sexo e a estimativa da idade são preocupações importantes ao se reconhecer uma vítima desses desastres, mas também ao estimar a idade cronológica de uma pessoa sem documentos. A IA é um avanço tecnológico que tem sido amplamente utilizado na medicina forense. Tem-se mostrado muito eficaz para estimar a idade biológica e prever o sexo de pessoas vivas e doentes. Apesar de um número limitado de estudos, foi relatado que o uso de IA na medicina forense está avançando além da prática convencional, o que pode ser atribuído à tecnologia automatizada com um mínimo de erros na identificação de padrões desconhecidos (Khanagar et al., 2021).

A principal vantagem dos modelos baseados em IA é que eles são projetados para identificar um indivíduo a partir de registos dentários, radiografias orais e moldes dentários. Esses modelos baseados em IA são principalmente projetados e desenvolvidos para superar a variabilidade na atribuição causada pelos olhos e mente humanos (De Tobel et al., 2017).

3.2.10.1 Mordidas e Inteligência Artificial

As mordidas são consideradas evidências cruciais em casos de agressões ou ataques sexuais, homicídios sexuais, estupros, abusos sexuais e maus-tratos infantis. A análise de mordidas humanas é um verdadeiro desafio para a medicina dentária forense. Um estudo investigou o uso de redes neurais artificiais para identificação de marcas de mordidas. Este estudo visava principalmente desenvolver um modelo altamente preciso e superar os preconceitos humanos durante o processo de identificação. Este modelo foi

treinado selecionando características específicas das marcas de mordida, após o que as redes treinadas deram um resultado razoável para a precisão da correspondência neste estudo inicial. Embora a rede neural usada para a identificação de mordidas não tenha alcançado um alto nível de precisão, isso mostra que essa abordagem tem potencial e precisa ser mais estudada para melhorar o seu desempenho. A aplicação e o treino com novas características podem ser necessários para melhorar o desempenho deste modelo. Os autores também afirmam que, neste estágio, a aplicação deste estudo não pode ser usada para identificar o crime (Balla et al., 2019).

3.2.10.2 Morfologia Mandibular e Inteligência Artificial

A previsão da forma da mandíbula é um elemento essencial da medicina forense, especialmente quando se trata de reconstruir o rosto de uma vítima sem o osso da mandíbula. A identificação de uma pessoa através de seus ossos, especialmente em desastres em massa, depende muito disso. A capacidade de prever a forma da mandíbula é uma ferramenta valiosa para melhorar a reconstrução facial (S. B. Khanagar, Vishwanathaiah, et al., 2021).

Niño-Sandoval et al. (2017) usaram um modelo de IA para prever a forma da mandíbula a partir de variáveis craniomaxilares em radiografias, alcançando alta precisão em pacientes das classes esqueléticas I, II e III usando técnicas de *deep learning* de máquina como CNN. O modelo demonstrou grande capacidade preditiva e pode ser crucial para a reconstrução facial.

3.2.10.3 Determinação do Sexo e Inteligência Artificial

Determinar o sexo de um indivíduo é de extrema importância, especialmente em cenários como desastres em massa, restos mortais e casos forenses. Os ossos esqueléticos, conhecidos por sua natureza robusta dentro do corpo humano, desempenham um papel crucial na identificação do sexo de uma pessoa. Esses ossos ajudam a distinguir o sexo de um indivíduo. Os dentes humanos, partes integrais do crânio humano, podem ser avaliados tanto em pessoas vivas quanto mortas. No caso da dentição permanente, as variações de acordo com o sexo existem principalmente devido às flutuações hormonais que influenciam o tamanho e a morfologia dos dentes. Entre os dentes, os caninos apresentam o mais alto nível de dimorfismo sexual em humanos. Além disso, os caninos são relativamente resistentes a problemas dentários como cáries e doenças periodontais,

garantindo a sua preservação na cavidade oral por longos períodos em comparação com outros dentes (S. B. Khanagar, Vishwanathaiah, et al., 2021)

um estudo de Patil et al. (2020) concentrou-se no uso de um modelo baseado em IA para a determinação do sexo. Este modelo em particular demonstrou uma precisão notável na determinação do sexo de um indivíduo usando radiografias panorâmicas. Uma análise comparativa foi realizada usando duas técnicas tradicionais de determinação do sexo, a análise discriminante e a regressão logística, que sempre apresentaram resultados louváveis nessa área. Esses métodos tradicionais foram comparados com redes neurais artificiais, mas os resultados do estudo indicaram a superioridade do modelo de IA sobre as duas outras técnicas.

3.2.10.4 Estimativa de Idade e Inteligência Artificial

A estimativa da idade é fundamental para determinar a idade cronológica de um indivíduo, especialmente em cenários envolvendo investigações forenses que requerem validação legal (Schmeling et al., 2016).

O processo de estimativa da idade de um indivíduo é principalmente realizado por profissionais qualificados usando imagens radiográficas da mão e do punho, bem como radiografias panorâmicas da mandíbula. É imperativo que a precisão e a consulta de especialistas sejam altamente especializadas ao realizar essa tarefa. Com o objetivo de estabelecer um método mais preciso e padronizado para avaliar a idade cronológica dos indivíduos, muitos sistemas automatizados usando inteligência artificial foram projetados para mitigar a subjetividade inerente aos observadores humanos (Mutasa et al., 2018).

Um estudo abrangente realizado por De Tobel et al. (2017) explorou o uso de um modelo baseado em inteligência artificial para determinar o estágio de desenvolvimento do terceiro molar inferior representado em radiografias panorâmicas (figura 28). O uso de uma abordagem de CNN de *deep learning* superou todos os métodos alternativos avaliados. O modelo demonstrou uma eficácia notável e, em comparação com avaliadores treinados, apresentou níveis de precisão comparáveis.



Figura 28. Utilização de redes neurais convolucionais para o estadiamento dentário. dez fases de desenvolvimento do terceiro molar humano utilizadas em medicina legal, adaptado de (Pauwels, 2020).

Os resultados desta pesquisa refletem os de um estudo realizado por Stern et al. (2017), no qual os pesquisadores detalharam a implementação de técnicas de estimativa automática de idade multifacetadas com base em dados de ressonância magnética para estender o limite de idade superior de 19 anos, geralmente associado à determinação da idade com base nos ossos da mão, para 25 anos ao integrar a avaliação dos dentes do siso e das clavículas. O desempenho desse modelo foi semelhante ao de radiologistas experientes.

Como parte de sua investigação, Vila-Blanco et al. (2020) descreveram o uso de duas técnicas totalmente automatizadas para avaliar a idade cronológica de um indivíduo com base em imagens de ortopantomografias. O método inicial (DAnet) envolveu uma via sequencial de CNN para previsão de idade, enquanto o segundo método (DASnet) introduziu uma via CNN adicional para previsão de sexo, aproveitando atributos específicos ao sexo para melhorar a precisão da estimativa de idade. Os resultados indicaram que o DASnet apresentou eficácia superior ao DAnet para todos os parâmetros. O DASnet demonstrou a capacidade de prever automaticamente com precisão a idade cronológica de um indivíduo, especialmente em jovens em desenvolvimento dentário.

Esses resultados são consistentes com um estudo realizado por De Back et al. (2019), no qual redes neurais convolutivas foram usadas para estimar a idade e a incerteza usando um conjunto de dados substancial de 12.000 radiografias panorâmicas dos

maxilares superior e inferior. Embora os resultados iniciais sejam promissores, os níveis de precisão ainda não são suficientes para justificar uma implementação de rotina.

IV- Desafios e Preocupações

Recentemente, várias empresas começaram a oferecer aplicações comerciais baseadas em algoritmos de visão por computador para medicina dentária (Mörch et al., 2021).

Este é o caso da DentalXRAI (Berlim, Alemanha, www.dentalxr.ai), que automatiza a interpretação de radiografias panorâmicas. Relu (Leuven, Bélgica, www.relu.eu), que automatiza a reconstrução de imagens dento-maxilo-faciais em três dimensões, é outro exemplo. Além disso, o WebCeph (Gyeonggi-do, Coreia do Sul, www.webceph.com) automatiza o posicionamento de imagens dento-maxilo-faciais, assim como imagens faciais cefalométricas. Ou ainda o Allisone (Paris, França, www.allisone.ia), que analisa ortopantomografias para ajudar os doentes a compreender o seu plano de tratamento (figura 29).

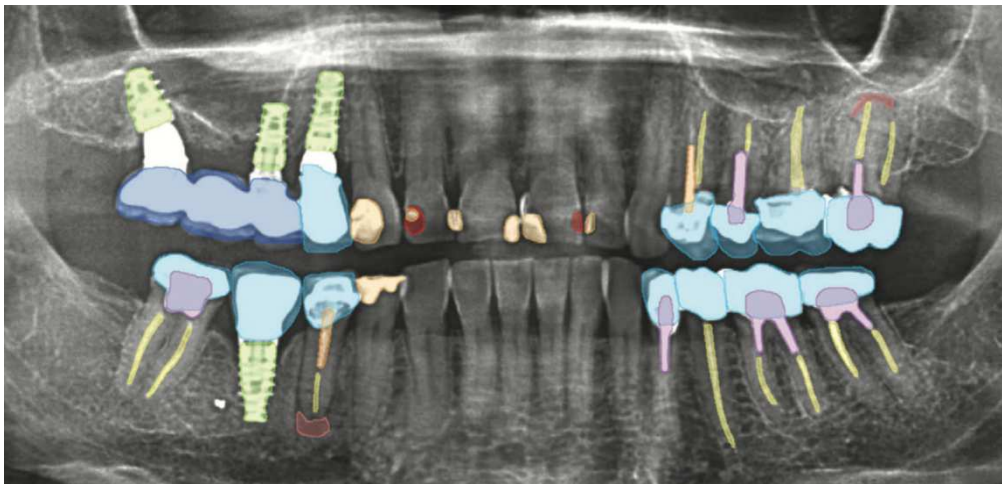


Figura 29. Exemplo de uma solução de inteligência artificial para analisar e segmentar radiografias dentárias panorâmicas. Aqui, o algoritmo pode identificar restaurações antigas e reconstruções protéticas, ou fornecer informações sobre a presença de lesões cariosas ou apicais, adaptado de (empresa Allisone).

No entanto, essas aplicações apresentam algumas limitações e não são amplamente utilizadas. Em primeiro lugar, elas podem ser consideradas como “*proof of concept*”. Portanto, o desenvolvimento de IA na medicina dentária enfrenta hoje vários desafios. Esses desafios dizem respeito principalmente à obtenção dos dados necessários para o desenvolvimento de algoritmos, à avaliação do desempenho dessas ferramentas, à compreensão de seu funcionamento e à exploração de suas aplicações clínicas (Mörch et al., 2021).

4.1 Limitações da IA

4.1.1 Insuficiência de Dados de Imagem para Treino

Os algoritmos de inteligência artificial estão intrinsecamente ligados aos dados usados para seu treino, o que geralmente limita a sua validade aos dados semelhantes aos presentes durante essa fase. Essa realidade expõe os algoritmos a um risco significativo de viés de amostragem, que pode ser mitigado pela construção de grandes bancos de dados internacionais representativos de diversos contextos clínicos e modalidades de aquisição. No entanto, a confidencialidade dos dados de saúde, especialmente preocupante em medicina dentária devido ao alto risco de identificação dos indivíduos, torna difícil a criação de tais bancos de dados (Rischke et al., 2022).

Para superar esses desafios, a abordagem de treino federado em vários locais pode ser considerada, onde os dados permanecem internos a cada local, mas os parâmetros do modelo de IA treinado são compartilhados para obter um algoritmo final representativo de vários locais. Apesar dessa solução promissora, ela requer uma infraestrutura e conhecimentos específicos ainda limitada nesse campo. A inclusão de viés adicional nos dados também deve ser considerada, uma vez que muitos algoritmos de *deep learning* podem apresentar viés étnicos ou de sexo (Rischke et al., 2022).

A anotação dos dados é um desafio importante nas aplicações de IA em medicina dentária, pois muitas vezes é difícil de ter um acesso a uma referência definitiva, frequentemente exigindo a intervenção de especialistas humanos para anotar os dados. A formação padronizada dos anotadores é crucial para reduzir as variações entre os operadores, mas esse processo custoso destaca a importância de compartilhar os dados anotados para evitar redundâncias desnecessárias. Uma abordagem complementar favorece a inclusão de dados relevantes para melhorar o desempenho do algoritmo, destacando que a quantidade de dados não é o único determinante, mas sim a heterogeneidade desses dados que é crucial para otimizar o desempenho dos algoritmos de IA (Schwendicke et al., 2022).

Por exemplo, um algoritmo de localização de pontos cefalométricos deve ser treinado em telerradiografias representativas de várias dismorfias dento-maxilo-faciais,

incluindo as mais raras de origem sistêmica, para garantir sua adaptabilidade a todas as situações clínicas (Schwendicke et al., 2022).

4.1.2 Interpretação

Compreender como os modelos CNN profundos tomam decisões e medir o nível de incerteza inerente ao processo decisivo são desafios persistentes atribuídos à natureza complexa do procedimento de aprendizagem. Nas camadas ocultas dos modelos CNN profundos, incluindo camadas convulsionais, de *pooling* e totalmente conectadas, o processo de aprendizagem ocorre e resulta no cálculo de características abstratas. Essas características derivadas das camadas ocultas incluem dados brutos que não são facilmente interpretáveis ou explicáveis, razão pela qual os CNN são considerados modelos de caixa preta. A geração de mapas de ativação da classe ponderados pelo gradiente (Grad-CAM) surge como uma técnica de atribuição usada para melhorar a compreensão do mecanismo de tomada de decisão dos modelos CNN (figura 30). Ao aproveitar o Grad-CAM, torna-se possível identificar características cruciais para a classificação durante a fase de aprendizagem e elucidar qualquer camada de um modelo CNN sem exigir modificações arquiteturais. A aplicação do Grad-CAM permite uma melhor compreensão do processo de tomada de decisão de um modelo CNN treinado (Zhang et al., 2021).

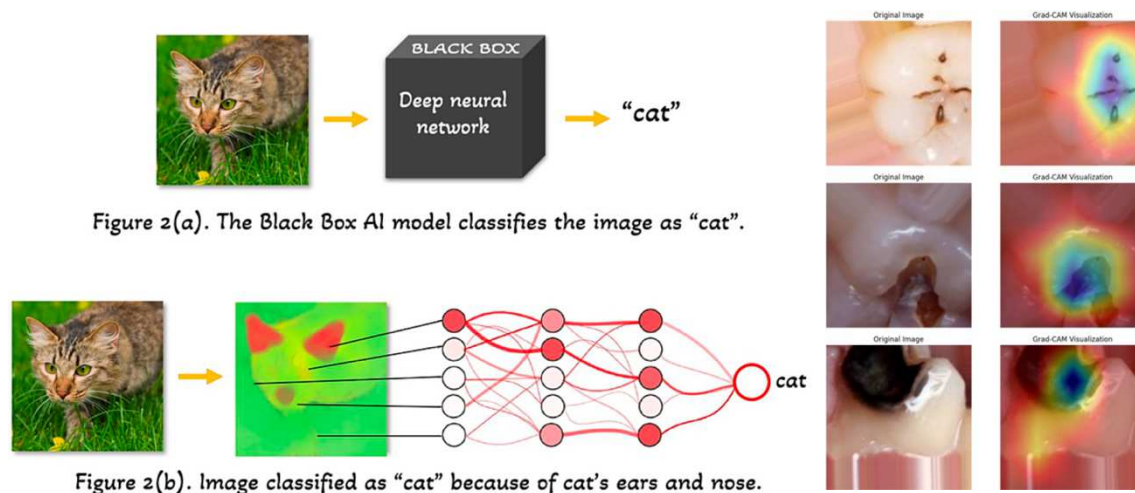


Figura 30. Representação esquemática do funcionamento dos modelos de Inteligência Artificial e Grad-CAM e a sua ação sobre os dentes, adaptado de (Agrawal and Nikhade, 2022; Inani et al., 2024).

4.1.3 Overfitting

O sobre ajuste é um problema comum encontrado no desenvolvimento de algoritmos de aprendizagem inteligente. A principal causa do sobre ajuste advém da

homogeneidade e da diversidade limitada dos dados de treino, o que leva os algoritmos a capturarem modelos estatísticos específicos a partir dos dados de treino, dificultando assim sua capacidade de generalização eficaz. Diversas recomendações foram propostas para atenuar o sobre ajuste (Hung et al., 2022).

Em primeiro lugar, o conjunto de dados de treino deve incluir dados que representem com precisão a condição alvo, com anotações fornecidas por vários especialistas. Em segundo lugar, os dados de treino devem apresentar uma heterogeneidade e diversidade significativas para melhorar as capacidades de generalização dos algoritmos em processo de aprendizagem. Além disso, o aumento dos dados é reconhecido como uma abordagem plausível para atenuar o sobre ajuste (Candemir et al., 2021).

Também, a incorporação de dados externos de várias instituições localizadas em diferentes áreas geográficas, para avaliar a eficácia dos algoritmos treinados, é imperativa para garantir sua abrangência e adequação às aplicações clínicas (Hung et al., 2022).

4.2 Questões Éticas e Regulatórias

Uma vez que o algoritmo de inteligência artificial foi submetido a um processo de treino, a sua avaliação torna-se imperativa usando dados de teste que nunca lhe foram apresentados anteriormente. Esta etapa crucial envolve uma comparação entre as previsões geradas pela IA e aquelas feitas por operadores humanos. A seleção criteriosa desses dados de teste é de grande importância, pois o desempenho do algoritmo depende estreitamente dela. As publicações atuais no campo da medicina dentária frequentemente sofrem de uma falta de bases de dados de teste, o que pode levar a resultados excessivamente otimistas e pouco generalizáveis (Mörch et al., 2021).

Para garantir uma generalização mais ampla do algoritmo e considerar a sua implantação clínica, é essencial que o conjunto de dados de teste seja diversificado e reflita da melhor forma possível as condições reais. Os critérios de avaliação idealmente devem ir além da simples medida de precisão, abrangendo aspetos mais diretamente relacionados aos problemas clínicos específicos do algoritmo (Schwendicke et al., 2020).

O processo de certificação de um algoritmo de *deep learning* para uso clínico atualmente segue a regulamentação de dispositivos médicos na Europa, incluindo a obtenção de uma marca CE, e nos Estados Unidos, pela aprovação da *Food and Drug Administration* (FDA) (Muehlematter et al., 2021).

O caminho regulatório é condicionado pelo nível de risco associado ao algoritmo, exigindo evidências substanciais de sua segurança, desempenho e confiabilidade. Algoritmos considerados de alto risco, exercendo uma influência significativa nas decisões clínicas, frequentemente requerem estudos clínicos demonstrando tanto a segurança quanto a eficácia desses dispositivos (Muehlematter et al., 2021).

O uso do DICOM em imagiologia dentária pode facilitar a implementação de algoritmos de inteligência artificial, permitindo uma análise e interpretação automatizadas de imagens dentárias. Os protocolos de desidentificação de DICOM podem contribuir para proteger a privacidade dos pacientes, removendo as informações de identificação das imagens dentárias, garantindo assim a conformidade com regulamentos de privacidade (Caffery et al., 2021).

4.3 Legislação de IA na Europa

Os sistemas de IA usados em radiologia dentária devem garantir a segurança dos pacientes, respeitar os direitos fundamentais e alinhar-se aos valores da União Europeia, com ênfase na transparência e supervisão humana para prevenir abusos e garantir a confiabilidade. Antes que os sistemas de IA possam ser usados nos cuidados de saúde, incluindo a radiologia dentária, eles devem atender a rigorosos requisitos técnicos e regulatórios para evitar viés, garantir gestão de dados e permitir rastreabilidade e verificação dos resultados ao longo de seu ciclo de vida. Profissionais de saúde que utilizam IA em radiologia dentária devem informar os pacientes sobre o uso de tecnologias de IA e garantir que os sistemas de IA sejam explicáveis, o que significa que profissionais e pacientes podem entender o funcionamento da IA e o fundamento das suas decisões. A União Europeia está a trabalhar na criação de um mercado único para aplicativos de IA legais, seguros e confiáveis, incluindo no campo da radiologia dentária, para evitar a fragmentação do mercado e promover a inovação num ambiente seguro e ético. Um passo importante foi dado com a redação da Lei de Inteligência Artificial pela Comissão Europeia em abril de 2021 (Théard-Jallu, 2021).

4.4 Potência de Computação

O treino de modelos de IA em radiologia dentária frequentemente requer recursos consideráveis. Redes neurais profundas, como CNN, são comumente usadas para analisar imagens radiográficas dentárias. Esses modelos exigem grandes quantidades de dados de treino e computação intensiva para ajustar os milhões de parâmetros que os compõem. Quando esses modelos são implantados para uso em tempo real num ambiente clínico, a potência computacional necessária pode variar dependendo da complexidade do modelo e da rapidez exigida para o processamento de imagens. No caso da radiologia dentária, onde os prazos podem impactar nos cuidados aos pacientes, é crucial que a inferência seja feita rapidamente e com precisão. As limitações de potência de cálculo podem ser um obstáculo importante para a implantação de IA em radiologia dentária. Por esse motivo, as empresas de IA no processamento de radiografias tendem a recorrer a um sistema remoto na nuvem. Isso permite uma acessibilidade aumentada, os dados são acessíveis a partir de qualquer dispositivo com conexão à internet, facilitando a colaboração entre os membros da equipa e a consulta dos registos dos pacientes pelos próprios pacientes. Isso permite uma maior escalabilidade, pois a capacidade de armazenamento pode ser facilmente aumentada ou reduzida conforme necessário, adaptando-se ao crescimento da clínica e permite também uma redução de custos, pois a nuvem pode ser mais económica do que a compra e manutenção de servidores físicos no local (Hlávka, 2020).

4.5 Desenvolvimento Sustentável

Um aspeto subestimado até agora diz respeito à correlação entre inteligência artificial e promoção de medicina dentária sustentável, tanto nos processos de tomada de decisão relacionados ao cuidado quanto na promoção de soluções de IA sustentáveis (Mörch et al., 2021).

Questões cruciais como o custo de carbono dos algoritmos, a criação de desigualdades nos custos de software e o desperdício resultante da falta de abordagem colaborativa requerem a atenção de nossa comunidade para construir uma IA robusta, sustentável e equitativa. É por isso que alguns especialistas sugerem iniciar desde já uma integração da IA no currículo de formação em medicina dentária, com o objetivo de

melhorar a saúde oral até 2030, conforme recomendado pela Organização Mundial da Saúde (Hsu et al., 2022).

4.6 Integração nos Fluxos de Trabalho Clínico

A introdução de novos softwares de IA frequentemente requer treino do pessoal para garantir que compreendam como usar eficazmente as funcionalidades oferecidas. Os custos de treino podem variar dependendo da complexidade do software e do número de membros da equipa a serem treinados. É importante que o programa de IA possa integrar-se perfeitamente aos sistemas de informática existentes na clínica odontológica, como sistemas de gestão de clínicas ou sistemas de imagem radiográfica. Os programas de IA em radiologia dentária geralmente são oferecidos sob a forma de licenças ou assinaturas, com taxas iniciais e/ou taxas recorrentes. O custo dependerá de fatores como o número de usuários autorizados, as funcionalidades incluídas e a duração da assinatura. É importante considerar os custos de suporte técnico contínuo e atualizações de software para garantir o funcionamento adequado e a segurança do software de IA. O uso eficaz de softwares de IA pode exigir uma infraestrutura de tecnologia da informação robusta, incluindo computadores potentes e armazenamento de dados adequado. Os custos relacionados à aquisição e manutenção dessa infraestrutura também devem ser considerados (Ducret, Mörch, Richert, & Monsarrat, 2022).

4.7 Compreender a IA e Manter o Controlo da Decisão

Para garantir o uso seguro da inteligência artificial em saúde, diversas ferramentas estão sendo desenvolvidas para fortalecer a confiança nos algoritmos. Para melhor entender o mecanismo de "raciocínio" dos modelos de IA, surgiu recentemente o campo da "inteligência artificial explicável", que visa fornecer aos usuários informações sobre os elementos considerados pelo algoritmo para formular suas previsões (Ma et al., 2022).

Essas explicações permitem que os usuários analisem criticamente os resultados, identificando os elementos cruciais no processo decisório do algoritmo. É provável que, no futuro, os algoritmos tenham que obrigatoriamente fornecer tais explicações aos usuários para serem comercializados no campo da saúde o que levanta considerações éticas em torno da responsabilidade dos profissionais ao usar clinicamente soluções baseadas em IA (Schwendicke et al., 2020).

É essencial que o uso de algoritmos de IA não isente os operadores humanos de sua responsabilidade nas escolhas médicas, e precauções devem ser tomadas para evitar que o sistema se torne uma referência para clínicos pouco experientes (Mörch et al., 2021).

Um estudo recente descobriu que radiologistas menos experientes tinham mais probabilidade de seguir conselhos incorretos fornecidos por um algoritmo de IA do que seus colegas mais experientes. Mais amplamente, os quadros regulatórios e as implicações legais do uso de algoritmos ainda precisam ser esclarecidos, pois esses dispositivos podem dar origem a situações inéditas e lacunas legais (Ducret et al., 2022).

A maioria das informações fornecidas pelos algoritmos de IA em medicina dentária atualmente não são suficientes para tomar decisões clínicas complexas (Schwendicke et al., 2020).

Esses algoritmos atualmente automatizam algumas etapas do processo decisório, como interpretação de imagens, processamento de impressões óticas, detecção de lesões cáries ou avaliação da malignidade de lesões na mucosa orais. Embora esses elementos possam ajudar a economizar tempo ou facilitar o diagnóstico em caso de dúvida, ainda não são capazes de melhorar significativamente o tratamento dos pacientes. Pesquisas adicionais são necessárias para permitir que os algoritmos construam raciocínios complexos usando um maior número de elementos, a fim de auxiliar os profissionais nas suas decisões terapêuticas. Por exemplo, a interpretação de imagens poderia ser associada à análise de fatores de risco específicos do paciente, com base na leitura do prontuário médico e exames anteriores (Ducret et al., 2022).

Para entender o processo decisório dos algoritmos de IA e adotar uma abordagem crítica em relação às soluções técnicas propostas, os profissionais devem adquirir novas habilidades. A criação de unidades de ensino, tanto na formação inicial quanto na formação continuada, é essencial e urgente para permitir que os profissionais avaliem de forma informada os algoritmos de IA e se equipem com soluções robustas. Esses ensinamentos devem abranger pelo menos os princípios de funcionamento dos diferentes algoritmos de IA, bem como explicações sobre a construção e validação de um algoritmo de IA (Ducret et al., 2022).

V- Conclusão

A radiologia dentária, embora estabelecida há décadas, está a passar por uma transformação significativa graças à integração da inteligência artificial. A aplicação da IA na radiologia dentária abre perspectivas revolucionárias para o diagnóstico, a planificação dos tratamentos e a otimização dos cuidados aos pacientes (Y. Chen et al., 2020).

Os benefícios potenciais da IA neste campo são numerosos e variados. Um dos principais benefícios é a melhoria da precisão diagnóstica. Os algoritmos de *deep learning* são capazes de analisar radiografias dentárias com uma exatidão notável, detetando anomalias subtis muitas vezes invisíveis ao olho humano. Por exemplo, a IA pode identificar cáries, fraturas, infeções peri apicais e outras patologias com grande fiabilidade, reduzindo assim os riscos de erros humanos e aumentando a qualidade dos diagnósticos (Putra et al., 2022).

Além disso, a IA permite uma interpretação mais rápida das imagens radiográficas. Isto é particularmente benéfico em ambientes clínicos onde o tempo é um fator crucial. Os sistemas de IA podem fornecer análises instantâneas, permitindo aos dentistas tomarem decisões clínicas rápidas e informadas. Isto melhora não só a eficiência das consultas, mas também a satisfação dos pacientes graças a tempos de espera reduzidos e diagnósticos mais precisos (Putra et al., 2022).

A otimização dos recursos de saúde é outro campo onde a IA mostra um potencial significativo. Ao automatizar tarefas repetitivas e fornecer análises detalhadas das imagens, a IA permite aos profissionais de saúde concentrarem-se em aspetos mais complexos e subtis dos cuidados aos pacientes (Ahmad et al., 2022).

No entanto, a integração da IA na radiologia dentária não está isenta de desafios. As preocupações éticas, como a confidencialidade dos dados dos pacientes e a gestão de preconceitos nos algoritmos, devem ser cuidadosamente abordadas. A formação dos profissionais de saúde dentária é crucial para garantir uma utilização eficaz e ética das tecnologias de IA. Os dentistas devem ser formados para entender os conceitos

fundamentais da IA, interpretar corretamente os resultados gerados por esses sistemas, e estar conscientes das implicações éticas da sua utilização (Mörch et al., 2021).

Finalmente, a regulamentação e os standards devem evoluir para enquadrar a utilização da IA na radiologia dentária. É essencial estabelecer protocolos claros e normas de qualidade para garantir que os sistemas de IA são seguros e eficazes antes do seu lançamento em grande escala (Schwendicke et al., 2020).

Em conclusão, a aplicação da inteligência artificial na radiologia dentária representa um avanço significativo para o campo. Ao melhorar a precisão diagnóstica, acelerar os processos clínicos e otimizar os recursos, a IA tem o potencial de transformar a forma como os cuidados dentários são prestados. A rápida evolução da inteligência artificial no nosso campo requer uma compreensão aprofundada de como essas novas ferramentas transformarão gradualmente nossas práticas profissionais. Seja no contexto de tomada de decisões ou de comunicação com os pacientes, é imperativo reconhecer que esses avanços terão um impacto significativo. Diante dessa mudança, deparamo-nos com três escolhas fundamentais: rejeitar essas mudanças sob o risco de nos marginalizarmos, aceitá-las de forma eufórica sob o risco de desenvolver uma superconfiança, ou empreender o esforço de aprender a entender e avaliar essas ferramentas com a mesma precisão e reflexão que demonstramos habitualmente em nossa profissão (Dot et al., 2024).

IV- Bibliografia

- Agrawal, P., & Nikhade, P. (2022). Artificial intelligence in dentistry: past, present, and future. *Cureus*. <https://doi.org/10.7759/cureus.27405>
- Ahmad, H. H., Salih, M. a. H., Luangrath, A., Sede, T., & Zugaj, L. (2022). Intelligence artificielle et imagerie médicale. *dumas.ccsd.cnrs.fr*. <https://doi.org/10.34746/kbkc-cd39>
- Alshadidi, A. a. F., Alshahrani, A. A., Aldosari, L. I. N., Chaturvedi, S., Saini, R., Hassan, S. a. B., Cicciù, M., & Minervini, G. (2023). Investigation on the application of artificial intelligence in prosthodontics. *Applied Sciences (Basel)*, *13*(8), 5004. <https://doi.org/10.3390/app13085004>
- Aminoshariae, A., Kulild, J., & Nagendrababu, V. (2021). Artificial intelligence in Endodontics: current applications and future directions. *Journal of Endodontics*, *47*(9), 1352–1357. <https://doi.org/10.1016/j.joen.2021.06.003>
- Ariji, Y., Fukuda, M., Kise, Y., Nozawa, M., Yanashita, Y., Fujita, H., Katsumata, A., & Ariji, E. (2019). Contrast-enhanced computed tomography image assessment of cervical lymph node metastasis in patients with oral cancer by using a deep learning system of artificial intelligence. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology (Print)*, *127*(5), 458–463. <https://doi.org/10.1016/j.oooo.2018.10.002>
- Ariji, Y., Yanashita, Y., Kutsuna, S., Muramatsu, C., Fukuda, M., Kise, Y., Nozawa, M., Kuwada, C., Fujita, H., Katsumata, A., & Ariji, E. (2019). Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, *128*(4), 424–430. <https://doi.org/10.1016/j.oooo.2019.05.014>
- Balla, S. B., Lingam, S., Kotra, A., P, H. R., Karunakar, P., N, N. M., & Cameriere, R. (2019). New regression models for dental age estimation in children using third molar maturity index: A preliminary analysis testing its usefulness as reliable

- age marker. *Legal Medicine*, 39, 35–40. <https://doi.org/10.1016/j.legalmed.2019.06.003>
- Barbosa, G. N. N., Bezerra, G. M. G., Medeiros, D. S. V., Lopez, M. A., & Mattos, D. M. F. (2021). Segurança em Redes 5G: Oportunidades e Desafios em Detecção de Anomalias e Predição de Tráfego Baseadas em Aprendizado de Máquina. In *Minicursos do XXI Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais* (pp. 145–189). <https://doi.org/10.5753/sbc.7165.8.4>
- Brettle, D. S., & Carmichael, F. (2011). The impact of digital image processing artefacts mimicking pathological features associated with restorations. *British Dental Journal*, 211(4), 167–170. <https://doi.org/10.1038/sj.bdj.2011.676>
- Burgess, J. (2015). Digital DICOM in dentistry. *The Open Dentistry Journal*, 9(1), 330–336. <https://doi.org/10.2174/1874210601509010330>
- Busardò, F. P., Frati, P., Santurro, A., Zaami, S., & Fineschi, V. (2015). Errors and malpractice lawsuits in radiology: what the radiologist needs to know. *La Radiologia Medica*, 120(9), 779–784. <https://doi.org/10.1007/s11547-015-0561-x>
- Caffery, L. J., Rotemberg, V., Weber, J., Soyer, H. P., Malvey, J., & Clunie, D. A. (2021). The role of DICOM in artificial intelligence for skin disease. *Frontiers in Medicine (Lausanne)*, 7. <https://doi.org/10.3389/fmed.2020.619787>
- Candemir, S., Nguyen, X. V., Folio, L., & Prevedello, L. M. (2021). Training strategies for radiology deep learning models in data-limited scenarios. *Radiology. Artificial Intelligence*, 3(6). <https://doi.org/10.1148/ryai.2021210014>
- Cha, J., Yoon, H., Yeo, I., Huh, K., & Han, J. (2021). Panoptic segmentation on panoramic radiographs: Deep Learning-Based segmentation of various structures including maxillary sinus and mandibular canal. *Journal of Clinical Medicine*, 10(12), 2577. <https://doi.org/10.3390/jcm10122577>
- Chen, Q., Zhou, X., Wu, J., & Zhou, Y. (2021). Structuring electronic dental records through deep learning for a clinical decision support system. *Health Informatics Journal*, 27(1), 146045822098003. <https://doi.org/10.1177/1460458220980036>

- Chen, Y., Stanley, K., & Att, W. (2020). Artificial intelligence in dentistry: current applications and future perspectives. *Quintessence International*, *51*(3), 248–257. <https://doi.org/10.3290/j.qi.a43952>
- Choi, H., Jung, S., Baek, S., Lim, W. H., Ahn, S., Yang, I., & Kim, T. W. (2019). Artificial intelligent model with neural network machine learning for the diagnosis of orthognathic surgery. *Journal of Craniofacial Surgery*, *30*(7), 1986–1989. <https://doi.org/10.1097/scs.0000000000005650>
- Choi, J., Eun, H., & Kim, C. (2016). Boosting proximal dental caries detection via combination of variational methods and convolutional neural network. *Journal of Signal Processing Systems*, *90*(1), 87–97. <https://doi.org/10.1007/s11265-016-1214-6>
- De Back, W., Seurig, S., Wagner, S., Marré, B., Roeder, I., & Scherf, N. (2019). Forensic age estimation with Bayesian convolutional neural networks based on panoramic dental x-ray imaging. *MIDL 2019 Conf. Abstr. Pap.*
- De Dumast, P., Mirabel, C., Paniagua, B., Yatabe, M., Ruellas, A., Tubau, N., Styner, M., Cevidanes, L., & Prieto, J. (2018). SVA: Shape variation analyzer. *Carolina Digital Repository (University of North Carolina at Chapel Hill)*. <https://doi.org/10.17615/g3a1-qy63>
- De Tobel, J., Radesh, P., Vandermeulen, D., & Thevissen, P. (2017). An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. *PubMed*, *35*(2), 42–54. <https://pubmed.ncbi.nlm.nih.gov/29384736>
- Dejasmin, J. (2019, July 8). *Les réseaux de neurones convolutifs*. Le Meilleur De La Technologie Au Service De La Biodiversité. <https://www.natural-solutions.eu/blog/la-reconnaissance-dimage-avec-les-rseaux-de-neurones-convolutifs>
- Deshmukh, S. (2018). Artificial intelligence in dentistry. *Journal of the International Clinical Dental Research Organization*, *10*(2), 47. https://doi.org/10.4103/jicdro.jicdro_17_18

- Do, S., Song, K. D., & Chung, J. W. (2020). Basics of Deep Learning: A Radiologist's Guide to Understanding published radiology articles on deep learning. *Korean Journal of Radiology*, 21(1), 33. <https://doi.org/10.3348/kjr.2019.0312>
- Dot, G., Gajny, L., & Ducret, M. (2024). Les enjeux de l'intelligence artificielle en odontologie. *M S-medicine Sciences*, 40(1), 79–84. <https://doi.org/10.1051/medsci/2023199>
- Ducret, M., Mörch, C.-M., Richert, R., Castets-Renard, C., Arfeuille, A., Cussat-Blanc, S., Kémoun, P., Olivier, H., & Monsarrat, P. (2022). Intelligence artificielle en médecine orale : comprendre les enjeux éthiques et juridiques pour mieux s'y préparer. *L'Information Dentaire*, 48–53.
- Endres, M. G., Hillen, F., Salloumis, M., Sedaghat, A. R., Niehues, S. M., Quatela, O., Hanken, H., Smeets, R., Beck-Broichsitter, B., Rendenbach, C., Lakhani, K. R., Heiland, M., & Gaudin, R. (2020). Development of a deep learning algorithm for periapical disease detection in dental radiographs. *Diagnostics (Basel)*, 10(6), 430. <https://doi.org/10.3390/diagnostics10060430>
- Flügge, T., Groß, C., Ludwig, U., Schmitz, J., Nahles, S., Heiland, M., & Nelson, K. (2023). Dental MRI—only a future vision or standard of care? A literature review on current indications and applications of MRI in dentistry. *Dentomaxillo-facial Radiology/Dentomaxillofacial Radiology*, 52(4). <https://doi.org/10.1259/dmfr.20220333>
- Fukuda, M., Ariji, Y., Kise, Y., Nozawa, M., Kuwada, C., Funakoshi, T., Muramatsu, C., Fujita, H., Katsumata, A., & Ariji, E. (2020). Comparison of 3 deep learning neural networks for classifying the relationship between the mandibular third molar and the mandibular canal on panoramic radiographs. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology (Print)*, 130(3), 336–343. <https://doi.org/10.1016/j.oooo.2020.04.005>
- Gaudiaut, T. (2021, October 19). Le Big Bang du Big Data. *Statista Daily Data*. <https://fr.statista.com/infographie/17800/big-data-evolution-volume-donnees-numeriques-genere-dans-le-monde/>

- Geetha, V., Aprameya, K. S., & Hinduja, D. M. (2020). Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health Information Science and Systems*, 8(1). <https://doi.org/10.1007/s13755-019-0096-y>
- Hegde, S., Gao, J., Vasa, R., & Cox, S. (2023). Factors affecting interpretation of dental radiographs. *Dentomaxillofacial Radiology*, 52(2). <https://doi.org/10.1259/dmfr.20220279>
- Heo, M., Kim, J., Hwang, J., Han, S., Kim, J., Yi, W., & Park, I. (2021). Artificial intelligence in oral and maxillofacial radiology: what is currently possible? *Dento-maxillo-facial Radiology/Dentomaxillofacial Radiology*, 50(3). <https://doi.org/10.1259/dmfr.20200375>
- Hlávka, J. P. (2020). Security, privacy, and information-sharing aspects of healthcare artificial intelligence. In *Elsevier eBooks*(pp. 235–270). <https://doi.org/10.1016/b978-0-12-818438-7.00010-1>
- Hou, X., Xu, X., Zhao, M., Kong, J., Wang, M., Lee, E., Jia, Q., & Jiang, H. B. (2022). An overview of three-dimensional imaging devices in dentistry. *Journal of Esthetic and Restorative Dentistry*, 34(8), 1179–1196. <https://doi.org/10.1111/jerd.12955>
- Hsu, L., Huang, Y., & Chang, Y. (2022). The implementation of artificial intelligence in dentistry could enhance environmental sustainability. *Journal of Dental Sciences*, 17(2), 1081–1082. <https://doi.org/10.1016/j.jds.2022.02.002>
- Hung, K. F., Ai, Q. Y. H., Leung, Y. Y., & Yeung, A. W. K. (2022). Potential and impact of artificial intelligence algorithms in dento-maxillofacial radiology. *Clinical Oral Investigations*, 26(9), 5535–5555. <https://doi.org/10.1007/s00784-022-04477-y>
- Husain, A. A., Stadlinger, B., Winklhofer, S., Piccirelli, M., & Valdec, S. (2022). Magnetic resonance imaging for preoperative diagnosis in third molar surgery: a systematic review. *Oral Radiology*, 39(1), 1–17. <https://doi.org/10.1007/s11282-022-00611-4>

- Iannucci, J., Ms, J. I. D., & Howerton, L. J. (2021). *Dental radiography: Principles and Techniques*. Elsevier.
- Inani, H., Mehta, V., Bhavsar, D., Gupta, R. K., Jain, A., & Akhtar, Z. (2024). AI-enabled dental caries detection using transfer learning and gradient-based class activation mapping. *Journal of Ambient Intelligence & Humanized Computing/Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-024-04795-x>
- Jacobsohn, P. H., Kantor, M. L., & Pihlstrom, B. L. (2013). The X-ray in dentistry, and the legacy of C. Edmund Kells. *The Journal of the American Dental Association, 144*(2), 138–142. <https://doi.org/10.14219/jada.archive.2013.0092>
- Jeon, S., Yun, J., Yeom, H., Shin, W., Lee, J., Jeong, S., & Seo, M. S. (2021). Deep-learning for predicting C-shaped canals in mandibular second molars on panoramic radiographs. *Dentomaxillofacial Radiology, 50*(5), 20200513. <https://doi.org/10.1259/dmfr.20200513>
- Johari, M., Esmaeili, F., Andalib, A., Garjani, S., & Saberhari, H. (2016). A novel thresholding based algorithm for detection of vertical root fracture in nonendodontically treated premolar teeth. *Journal of Medical Signals and Sensors, 6*(2), 81. <https://doi.org/10.4103/2228-7477.181027>
- Johari, M., Esmaeili, F., Andalib, A., Garjani, S., & Saberhari, H. (2017). Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofacial Radiology, 46*(2), 20160107. <https://doi.org/10.1259/dmfr.20160107>
- Jung, S., & Kim, T. W. (2016). New approach for the diagnosis of extractions with neural network machine learning. *American Journal of Orthodontics and Dentofacial Orthopedics, 149*(1), 127–133. <https://doi.org/10.1016/j.ajodo.2015.07.030>
- Kaasalainen, T., Ekholm, M., Siiskonen, T., & Kortensniemi, M. (2021). Dental cone beam CT: An updated review. *Physica Medica, 88*, 193–217. <https://doi.org/10.1016/j.ejmp.2021.07.007>

- Kale, I., Mhapuskar, A., Jhavar, M., & Hiremutt, D. P. (2023). Artificial intelligence in oral medicine and oral radiology. *SRM Journal of Research in Dental Sciences*, 14(4), 199. https://doi.org/10.4103/srmjrds.srmjrds_106_23
- Katsumata, A. (2023). Deep learning and artificial intelligence in dental diagnostic imaging. *Japanese Dental Science Review*, 59, 329–333. <https://doi.org/10.1016/j.jdsr.2023.09.004>
- Khanagar, S., Al-Ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., Sarode, S. C., & Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Journal of Dental Sciences*, 16(1), 508–522. <https://doi.org/10.1016/j.jds.2020.06.019>
- Khanagar, S. B., Vishwanathaiah, S., Naik, S., Al-Kheraif, A. A., Divakar, D. D., Sarode, S. C., Bhandi, S., & Patil, S. (2021). Application and performance of artificial intelligence technology in forensic odontology – A systematic review. *Legal Medicine*, 48, 101826. <https://doi.org/10.1016/j.legalmed.2020.101826>
- Khanagar, S., Vishwanathaiah, S., Naik, S., Al-Kheraif, A. A., Divakar, D. D., Sarode, S. C., Bhandi, S., & Patil, S. (2021). Application and performance of artificial intelligence technology in forensic odontology – A systematic review. *Legal Medicine*, 48, 101826. <https://doi.org/10.1016/j.legalmed.2020.101826>
- Kök, H., Acılar, A. M., & İzgi, M. S. (2019). Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Progress in Orthodontics*, 20(1). <https://doi.org/10.1186/s40510-019-0295-8>
- Kotsiantis, S. (2007). Supervised Machine Learning: A review of classification techniques. *Informatica (Lithuanian Academy of Sciences)*, 31(3), 249–268. <https://dblp.uni-trier.de/db/journals/informaticaSI/informaticaSI31.html#Kotsiantis07>
- Krois, J., Ekert, T., Meinhold, L., Golla, T., Kharbot, B., Wittemeier, A., Dörfer, C. E., & Schwendicke, F. (2019). Deep learning for the radiographic detection of

- periodontal bone loss. *Scientific Reports*, 9(1). <https://doi.org/10.1038/s41598-019-44839-3>
- L, B. (2023, October 4). Réseau de neurones artificiels : qu'est-ce que c'est et à quoi ça sert ? *LEBIGDATA.FR*. <https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition>
- Lam, E. W., & Mallya, S. M. (2018). *White and Pharoah's Oral Radiology: Principles and Interpretation*. <http://libportal.umsha.ac.ir/site/catalogue/61095>
- Lavagnoli, S. (2023, September 19). O que é Deep Learning e Machine Learning? *OPENCADD*. <https://www.opencadd.com.br/blog/machine-learning-ou-deep-learning>
- LeCun, Y., Bengio, Y., & Hinton, G. E. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lee, J., Jun, S., Cho, Y., Lee, H., Kim, G. B., Seo, J. B., & Kim, N. (2017). Deep Learning in Medical Imaging: General Overview. *Korean Journal of Radiology*, 18(4), 570. <https://doi.org/10.3348/kjr.2017.18.4.570>
- Lee, J., Kim, D., & Jeong, S. (2019). Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral Diseases*, 26(1), 152–158. <https://doi.org/10.1111/odi.13223>
- Lee, J., Kim, D., Jeong, S., & Choi, S. (2018). Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *Journal of Periodontal & Implant Science*, 48(2), 114. <https://doi.org/10.5051/jpis.2018.48.2.114>
- Lerner, H., Mouhyi, J., Admakin, O., & Mangano, F. (2020). Artificial intelligence in fixed implant prosthodontics: a retrospective study of 106 implant-supported monolithic zirconia crowns inserted in the posterior jaws of 90 patients. *BMC Oral Health (Online)*, 20(1). <https://doi.org/10.1186/s12903-020-1062-4>
- Liu, M., Xu, Z., Mao, W., Li, Y., Zhang, X., Bai, H., Ding, P., & Fu, K. (2021). Deep learning-based evaluation of the relationship between mandibular third molar

- and mandibular canal on CBCT. *Clinical Oral Investigations*, 26(1), 981–991. <https://doi.org/10.1007/s00784-021-04082-5>
- Lundstrom, M., & Alam, M. A. (2022). Moore’s law: The journey ahead. *Science*, 378(6621), 722–723. <https://doi.org/10.1126/science.ade2191>
- Ma, J., Schneider, L., Lapuschkin, S., Achibat, R., Büttner, M., Krois, J., Schwendicke, F., & Samek, W. (2022). Towards trustworthy AI in dentistry. *Journal of Dental Research*, 101(11), 1263–1268. <https://doi.org/10.1177/00220345221106086>
- Maia, B. (2021, December 15). Tipos de Aprendizizado de Máquina #3 - Beatriz Maia - Medium. *Medium*. <https://beatrizmaiads.medium.com/tipos-de-aprendizado-de-m%C3%A1quina-3-9a9052173bc4>
- Manaswi, N. K. (2018). Convolutional neural networks. In *Apress eBooks* (pp. 91–96). https://doi.org/10.1007/978-1-4842-3516-4_6
- Mendonça, M. O. K., Netto, S. L., Diniz, P. S. R., & Theodoridis, S. (2024). Machine learning. In *Elsevier eBooks* (pp. 869–959). <https://doi.org/10.1016/b978-0-32-391772-8.00019-3>
- Mörch, C., Atsü, S. S., Cai, W., Li, X., Madathil, S., Liu, X., Mai, V., Tamimi, F., Dilhac, M., & Ducret, M. (2021). Artificial Intelligence and Ethics in Dentistry: A scoping review. *Journal of Dental Research*, 100(13), 1452–1460. <https://doi.org/10.1177/00220345211013808>
- Mozzo, P., Procacci, C., Tacconi, A., Martini, P. T., & Andreis, I. a. B. (1998). A new volumetric CT machine for dental imaging based on the cone-beam technique: preliminary results. *European Radiology*, 8(9), 1558–1564. <https://doi.org/10.1007/s003300050586>
- Muehlematter, U. J., Daniore, P., & Vokinger, K. N. (2021). Approval of artificial intelligence and machine learning-based medical devices in the USA and Europe (2015–20): a comparative analysis. *The Lancet Digital Health*, 3(3), e195–e203. [https://doi.org/10.1016/s2589-7500\(20\)30292-2](https://doi.org/10.1016/s2589-7500(20)30292-2)

- Mutasa, S., Chang, P. D., Ruzal-Shapiro, C., & Ayyala, R. S. (2018). MABAL: a Novel Deep-Learning Architecture for Machine-Assisted Bone Age Labeling. *Journal of Digital Imaging*, 31(4), 513–519. <https://doi.org/10.1007/s10278-018-0053-3>
- Niño-Sandoval, T. C., Pérez, S. V. G., González, F. A., Jaque, R. A., & Infante-Contreras, C. (2017). Use of automated learning techniques for predicting mandibular morphology in skeletal class I, II and III. *Forensic Science International*, 281, 187.e1-187.e7. <https://doi.org/10.1016/j.forsciint.2017.10.004>
- Oliveira, A., Jana, A., Subhash, H. M., Jacques, S. L., & Pierce, M. C. (2023). Using modern intraoral scanners for deep learning-assisted diagnostic solutions in dentistry. *Proc. SPIE 12363*. <https://doi.org/10.1117/12.2651291>
- Orhan, K., Bayrakdar, İ. Ş., Ezhov, M., Kravtsov, A., & Özyürek, T. (2020). Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *International Endodontic Journal*, 53(5), 680–689. <https://doi.org/10.1111/iej.13265>
- Pajankar, A., & Joshi, A. (2022). Convolutional neural networks. In *Apress eBooks* (pp. 261–284). https://doi.org/10.1007/978-1-4842-7921-2_14
- Park, J., Hwang, H., Moon, J., Yu, Y., Kim, H., Her, S., Srinivasan, G., Aljanabi, M. N. A., Donatelli, R. E., & Lee, S. (2019). Automated identification of cephalometric landmarks: Part 1—Comparisons between the latest deep-learning methods YOLOV3 and SSD. *Angle Orthodontist*, 89(6), 903–909. <https://doi.org/10.2319/022019-127.1>
- Patil, V., Vineetha, R., Vatsa, S., Shetty, D. K., Raju, A. R., Naik, N., & Malarout, N. (2020). Artificial neural network for gender determination using mandibular morphometric parameters: A comparative retrospective study. *Cogent Engineering*, 7(1), 1723783. <https://doi.org/10.1080/23311916.2020.1723783>
- Pauwels, R. (2020). A brief introduction to concepts and applications of artificial intelligence in dental imaging. *Oral Radiology*, 37(1), 153–160. <https://doi.org/10.1007/s11282-020-00468-5>

- Poedjiastoeti, W., & Suebnukarn, S. (2018). Application of convolutional neural network in the diagnosis of jaw tumors. *Healthcare Informatics Research*, 24(3), 236. <https://doi.org/10.4258/hir.2018.24.3.236>
- Putra, R. H., Doi, C., Yoda, N., Astuti, E. R., & Sasaki, K. (2022). Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillo-facial Radiology/Dentomaxillofacial Radiology*, 51(1). <https://doi.org/10.1259/dmfr.20210197>
- Rischke, R., Schneider, L., Müller, K., Samek, W., Schwendicke, F., & Krois, J. (2022). Federated learning in dentistry: chances and challenges. *Journal of Dental Research*, 101(11), 1269–1273. <https://doi.org/10.1177/00220345221108953>
- Różyło-Kalinowska, I. (2020). Imaging techniques in dental radiology. In *Springer eBooks*. <https://doi.org/10.1007/978-3-030-41372-9>
- Saghiri, M. A., García-Godoy, F., Gutmann, J. L., Lotfi, M., & Asgar, K. (2012). The reliability of artificial neural network in locating minor apical foramen: A Cadaver study. *Journal of Endodontics*, 38(8), 1130–1134. <https://doi.org/10.1016/j.joen.2012.05.004>
- Santos, T. (2024, January 23). Como funciona a Inteligência Artificial: conheça seu presente, passado e futuro - Mídia Market. *Mídia Market*. <https://midia.market/conteudos/consumo/como-funciona-a-inteligencia-artificial/>
- Schmeling, A., Dettmeyer, R., Ernst, R., Vieth, V., & Geserick, G. (2016). Forensic Age estimation: Methods, certainty, and the law. *Deutsches Arzteblatt International*. <https://doi.org/10.3238/arztebl.2016.0044>
- Schwendicke, F., De Oro, J. C. G., Ros, A. G. C., Meyer-Lueckel, H., Chaurasia, A., & Krois, J. (2022). Artificial intelligence for Caries Detection: Value of data and information. *Journal of Dental Research*, 101(11), 1350–1356. <https://doi.org/10.1177/00220345221113756>

- Schwendicke, F., Samek, W., & Krois, J. (2020). Artificial intelligence in dentistry: chances and challenges. *Journal of Dental Research*, *99*(7), 769–774. <https://doi.org/10.1177/0022034520915714>
- Shaveta. (2023). A review on machine learning. *International Journal of Science and Research Archive*, *9*(1), 281–285. <https://doi.org/10.30574/ijrsra.2023.9.1.0410>
- Singi, S. R., Sathe, S., Reche, A. R., Sibal, A., & Mantri, N. (2022). Extended arm of precision in prosthodontics: artificial intelligence. *Curēus*. <https://doi.org/10.7759/cureus.30962>
- Štern, D., Kainz, P., Payer, C., & Urschler, M. (2017). Multi-factorial Age Estimation from Skeletal and Dental MRI Volumes. In *Lecture Notes in Computer Science* (pp. 61–69). https://doi.org/10.1007/978-3-319-67389-9_8
- Tandon, D., Rajawat, J., & Banerjee, M. (2020). Present and future of artificial intelligence in dentistry. *Journal of Oral Biology and Craniofacial Research*, *10*(4), 391–396. <https://doi.org/10.1016/j.jobcr.2020.07.015>
- Théard-Jallu, C. (2021). Droit et éthique autour de l'intelligence artificielle, accélération en Europe et en France. *Actualités Pharmaceutiques*, *60*(611), 30–35. <https://doi.org/10.1016/j.actpha.2021.10.009>
- Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, *25*(1), 44–56. <https://doi.org/10.1038/s41591-018-0300-7>
- Umer, F., Habib, S., & Adnan, N. (2022). Application of deep learning in teeth identification tasks on panoramic radiographs. *Dentomaxillofacial Radiology*, *51*(5). <https://doi.org/10.1259/dmfr.20210504>
- Vila-Blanco, N., Carreira, M. J., Varas-Quintana, P., Balsa-Castro, C., & Tomás, I. (2020). Deep neural networks for chronological age estimation from OPG images. *IEEE Transactions on Medical Imaging*, *39*(7), 2374–2384. <https://doi.org/10.1109/tmi.2020.2968765>
- Whaites, E. (2020). *Essentials of dental radiography and radiology*. <http://ci.nii.ac.jp/ncid/BA62420031>

- Yauney, G., Rana, A., Wong, L. C., Javia, P., Müftü, A., & Shah, P. (2019). Automated process incorporating machine learning segmentation and correlation of oral diseases with systemic health. *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. <https://doi.org/10.1109/embc.2019.8857965>
- Yoo, J., Yeom, H., Shin, W., Yun, J. P., Lee, J. H., Jeong, S., Lim, H. J., Lee, J., & Kim, B. (2021). Deep learning based prediction of extraction difficulty for mandibular third molars. *Scientific Reports (Nature Publishing Group)*, *11*(1). <https://doi.org/10.1038/s41598-021-81449-4>
- Yu, H. J., Cho, S. R., Kim, M. J., Kim, W. H., Kim, J., & Choi, J. (2020). Automated Skeletal Classification with Lateral Cephalometry Based on Artificial Intelligence. *Journal of Dental Research*, *99*(3), 249–256. <https://doi.org/10.1177/0022034520901715>
- Zangari, F. (2016). Professional liability in dental radiology. *Journal of Medical Toxicology and Clinical Forensic Medicine*, *2*(1). <https://doi.org/10.21767/2471-9641.100016>
- Zhang, B., Dai, N., Tian, S., Fang, Y., & Yu, Q. (2019). The extraction method of tooth preparation margin line based on S-Octree CNN. *International Journal for Numerical Methods in Biomedical Engineering*, *35*(10). <https://doi.org/10.1002/cnm.3241>
- Zhang, Y., Hong, D., McClement, D. G., Oladosu, O., Pridham, G., & Slaney, G. (2021). Grad-CAM helps interpret the deep learning models trained to classify multiple sclerosis types using clinical brain magnetic resonance imaging. *Journal of Neuroscience Methods*, *353*, 109098. <https://doi.org/10.1016/j.jneumeth.2021.109098>
- Zhao, Z., Zheng, P., Xu, S., & Wu, X. (2019). Object Detection with Deep Learning: A review. *IEEE Transactions on Neural Networks and Learning Systems (Print)*, *30*(11), 3212–3232. <https://doi.org/10.1109/tnnls.2018.2876865>