

Faculdade de Medicina Dentária da Universidade do Porto

Mestrado Integrado em Medicina Dentária

U. PORTO

 **FACULDADE DE
MEDICINA DENTÁRIA**
UNIVERSIDADE DO PORTO

Inteligência Artificial em Medicina Dentária: o Futuro do Diagnóstico em Ortodontia

Pedro Miguel Ribeiro da Silva

Porto, 2021

Faculdade de Medicina Dentária da Universidade do Porto

Mestrado Integrado em Medicina Dentária

Autor: Pedro Miguel Ribeiro da Silva
pedro.ribeiro.silva22@gmail.com

Orientador: Prof. Doutor Saúl Matos de Castro
scastro@fmd.up.pt

Coorientadora: Prof. Doutora Maria João Ponces
mponces@fmd.up.pt

Porto, 2021

ÍNDICE

Índice de figuras	III
Resumo	IV
Abstract	V
Lista de abreviaturas	VI
Introdução	7
Materiais e métodos	9
Desenvolvimento	11
Aplicações da Inteligência Artificial em Ortodontia	11
Aplicações da Inteligência Artificial nas outras áreas médico-dentárias	14
Imagiologia	14
Cirurgia	15
Dentisteria Operatória	17
Endodontia	17
Medicina Dentária Forense	18
Medicina Oral	19
Oclusão	20
Periodontologia	21
Limitações da Inteligência Artificial	22
Conclusão	24
Referências	25
Anexos	31

ÍNDICE DE FIGURAS

Figura 1 - Esquema representativo do processo de seleção de artigos para a elaboração da revisão bibliográfica.	10
Figura 2 - Imagem ilustrativa dos 80 pontos cefalométricos (46 esqueléticos e 32 em tecidos moles) identificados – in Automated identification of cephalometric landmarks: Part 1—Comparisons between the latest deep-learning methods YOLOV3 and SSD.	13
Figura 3 - Resultado da segmentação em corte contendo 2º molar. Da esquerda para a direita, exemplo dado aos modelos (A), resultado de segmentação com CNN SegNet (B), resultado de segmentação com CNN 2D U-Net (C) e resultado da segmentação pela CNN 3D U-Net (D) in Automatic mandibular canal detection using a deep convolutional neural network.	16
Figura 4 - Exemplo da medição do volume de lesão pelo modelo de IA. In Evaluation of artificial intelligence for detecting	18
Figura 5 - Imagem ilustrativa do trabalho de Kim e colaboradores. (Topo) Radiografias obtidas e consideradas como input. (Meio) zonas de perda óssea assinaladas por especialistas como output. (Fundo) representação dos mapas de ativação da CNN DentNet utilizada – in DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs.	22

RESUMO

Introdução: A Inteligência Artificial corresponde à tentativa da mimetização do pensamento e cognição humanos e serve-se de várias ferramentas, como a aprendizagem automática para desenvolver modelos capazes de levar a cabo tarefas que até então seriam, exclusivamente, cumpridas por humanos.

Materiais e métodos: Esta revisão bibliográfica foi realizada com pesquisa na base de dados PubMed e teve como objetivo identificar as principais aplicações, incluindo vantagens e limitações, da aplicação da inteligência artificial na prática clínica de Medicina Dentária.

Desenvolvimento: A literatura mostra que a principal aplicação da inteligência artificial na medicina dentária diz respeito à análise de imagens com recurso a redes neuronais convolucionais (radiografia e fotografia) para auxiliar processos de diagnóstico de patologias e elaboração de planos de tratamento, tais como deteção de cáries, lesões quísticas, relações entre estruturas anatómicas para a preparação de intervenções cirúrgicas e, especialmente na Ortodontia, na identificação de pontos e nas análises cefalométricas para a definição de planos de tratamento. A principal limitação da inteligência artificial prende-se com a necessidade de utilização de grandes centros de informação que contenham dados de vários institutos e até de regiões, para se obterem modelos com boa capacidade de generalização. Ao longo desta monografia serão elencadas as aplicações da inteligência artificial na ortodontia e nas restantes áreas médico-dentárias, bem como as suas limitações.

Conclusão: A Inteligência Artificial tem o potencial para ser uma valiosa ferramenta nas mãos do médico dentista fornecendo alternativas mais rápidas e eficazes para uma panóplia de métodos tradicionais de diagnóstico e de elaboração de planos de tratamentos.

Palavras-chave: Inteligência Artificial; Aprendizagem Automática; Medicina Dentária; Ortodontia; Redes Neuronais Convolucionais.

ABSTRACT

Introduction: Artificial Intelligence (AI) is the attempt to mimic human thought and cognition through several tools, such as Machine Learning (ML), to develop algorithms capable of carrying out tasks that, until then, would be performed exclusively by humans.

Materials and Methods: This review was performed using the PubMed database and aimed to identify the main applications, including advantages and limitations, of AI application in dentistry's practice.

Results: The literature shows that the main application of AI in dentistry is in image analysis using CNNs (radiography and photography) to support pathology diagnosis and treatment planning processes, such as caries detection, cystic lesions, relationships between anatomical structures for the preparation of surgical interventions and, especially in orthodontics, in the identification of cephalometric points and analyses for the definition of treatment plans. The main limitation of AI is the need to use large information centers containing data from several institutes and even regions to obtain models with good generalization capabilities. Throughout this paper we will list the applications of artificial intelligence in orthodontics and other dentistry's areas, as well as its limitations.

Conclusion: Artificial Intelligence has the potential to be a valuable tool in the hands of the dentist by providing faster and more effective alternatives to a panoply of traditional methods of diagnosis and treatment planning.

Keywords: Artificial Intelligence; Machine Learning; Dentistry; Orthodontics; Convolutional Neural Networks.

LISTA DE ABREVIATURAS

ATM - Articulação Temporomandibular

BRONJ - Osteonecrose Induzida por Bifosfonatos

CBCT - Cone-Beam Computed Tomography / Tomografia Computorizada de Feixe Cônico

CNN – Convolution Neural Networks / Redes Neurais Convolucionais

DL - Deep learning

IA – Inteligência artificial / Artificial Intelligence

ML – Aprendizagem Automática / Machine Learning

NAI - Nervo Alveolar Inferior

NILT – Near-Infrared Light Transillumination

NN - Rede Neuronal / neural network

OSCC – Oral Squamous Cell Carcinoma / Carcinoma Oral de Células Escamosas

PNN - Probabilistic Neural Network / Rede Neuronal Probabilística

INTRODUÇÃO

A Inteligência artificial (IA) refere-se à capacidade de produzir e/ou utilizar máquinas que conseguem imitar o raciocínio e comportamento humanos. Consiste, aproveitando-se da evolução tecnológica em termos de hardware e software de computadores, no uso de sistemas de IA para processar grandes conjuntos de dados e informação de modo a conseguir revelar formas de comportamento humano e até interagir com as pessoas, melhorando assim a qualidade de vida individual, moldando a sociedade atual. ^{1, 2}

As primeiras formas de implementação da IA foram assumindo a possibilidade de que toda a inteligência humana era passível de ser totalmente digitalizada, replicada e aplicada em computadores e máquinas. Na década de 1970 previa-se já o fim das carreiras médicas provocadas pela IA. No entanto, o desenvolvimento da IA tem vindo a ser severamente limitado por um lado pelas capacidades finitas de armazenamento e processamento presentes nos computadores baseados em sistemas de *bits*, e por outro pela grande complexidade da cognição humana. ³

Aprendizagem Automática (*Machine Learning* – ML) é um campo da IA no qual são aplicados algoritmos para conseguir aprender padrões estatísticos intrínsecos nos dados existentes, os quais permitem fazer previsões em novos dados adquiridos. Um dos tipos mais conhecidos de ML são as redes neuronais ou redes neuronais artificiais (*neural network* – NN) e apresentam melhores resultados que os outros algoritmos de ML, principalmente quando aplicadas em dados complexos como imagens ou linguagem. A base de qualquer NN é o neurónio artificial, que resulta de um modelo matemático não linear inspirado no neurónio humano. Servindo-se de empilhamento e encadeamento de vários destes “neurónios” formam-se camadas que vão usar uma série de operações matemáticas para desenvolver e formar uma rede que vai ter como objetivo cumprir uma determinada tarefa como por exemplo a classificação de imagens. “*Deep learning*” (DL) diz, assim, respeito a NN com muitas camadas de profundidade e que são particularmente úteis na análise de imagens, sendo capazes de representar as imagens em várias das suas características como limites, formas e outros padrões macroscópicos. Desde que alimentadas com dados suficientes estas NN conseguem associar a um qualquer *input* um *output* (por exemplo, a uma imagem de um dente cariado – *input* – fazer corresponder “dente cariado” – *output*). Para isto, estes algoritmos de ML são assim treinados com grandes bases de dados, e os pares de *input* e *output* vão sendo analisados ao longo de toda a NN e em cada fase são analisados os resultados ou *output* que, naquele momento, a NN previa para aquele *input* e comparados com o valor real. Ou seja, os algoritmos vão sendo otimizados de forma a minimizar o erro de previsão que corresponde à diferença entre o *output* dado ao algoritmo como verdadeiro e o *output* previsto por ele. ⁴⁻⁶

Com esta capacidade de análise e previsão de imagens, a IA tem potencial para detetar patologias, mas também identificar estruturas anatómicas em imagens médicas com exatidão semelhante e/ou superior aos profissionais

de saúde. Desse modo, pode tornar-se um bom aliado na prática clínica de Medicina Dentária, tendo em conta todos os métodos complementares de diagnóstico com recurso a imagens usados na área, nomeadamente, o uso de telerradiografias como ferramenta de diagnóstico em casos ortodônticos, de cirurgia ortognática e de análise do crescimento e desenvolvimento craniofaciais.^{7, 8}

Com todo este potencial, a IA tem vindo a despertar o interesse da comunidade científica, surgindo cada vez mais potenciais aplicações para a mesma nas várias áreas da Medicina Dentária, nomeadamente, Ortodontia⁸⁻²⁰, Imagiologia²¹⁻²⁵, Cirurgia²⁶⁻³¹, Dentisteria Operatória^{6, 32-35}, Endodontia³⁶⁻⁴¹, Ciências Forenses⁴²⁻⁴⁶, Medicina Oral⁴⁷⁻⁵⁴, Oclusão^{55, 56} e Periodontologia⁵⁷⁻⁶¹.

Tendo por base o crescente interesse na área, torna-se pertinente questionar quais as aplicações da IA na Medicina Dentária. O objetivo desta revisão bibliográfica é, então, identificar as aplicações, bem como as limitações e os principais obstáculos no uso da IA na prática da Medicina Dentária, principalmente no que ao diagnóstico diz respeito e muito em particular na área da ortodontia.

MATERIAIS E MÉTODOS

Para o desenvolvimento desta revisão bibliográfica, e de forma que a escolha dos artigos fosse adequada ao objetivo do estudo, procedeu-se à seleção de artigos em 4 fases: identificação; análise; elegibilidade e inclusão.

Na fase de identificação, recorreu-se à base de dados PubMed durante o período compreendido entre os dias 20 e 23 de maio do presente ano. Foram utilizadas como palavras-chave as palavras “artificial intelligence dentistry” e “artificial intelligence orthodontics”. Apenas foram tidos em conta artigos publicados entre o ano de 2016 e o ano de 2021, opção escolhida na base de dados PubMed utilizando o filtro “últimos 5 anos”.

Dos 600 artigos obtidos, 547 foram relativos à pesquisa com a palavra-chave “artificial intelligence dentistry” e 53 relativos à pesquisa através da palavra-chave “artificial intelligence orthodontics”.

Após a eliminação de 35 artigos duplicados, atingiu-se um total de 565 artigos.

Na segunda fase, com a leitura do título foram eliminados 346 artigos, passando assim o total para 219 artigos. Posteriormente, com a leitura do resumo de cada artigo individualmente, foram eliminados 110 artigos, perfazendo, nesta fase, um total de 109.

Na terceira fase, após aplicados os critérios de exclusão, eliminaram-se 35 artigos, passando assim a serem tidos em conta 74 artigos.

Os critérios de exclusão foram a indisponibilidade do resumo e/ou do artigo integral, estar escrito numa língua que não o português e o inglês, cartas ao editor, artigos de opinião, artigos que não cumpriam com o objetivo desta revisão, assim como artigos em que a inteligência artificial é utilizada como método de investigação e não como parte integrante da solução proposta para a problemática do estudo.

Por fim, após toda a triagem referida anteriormente, foram incluídos 74 artigos, que vão ao encontro do objetivo desta revisão bibliográfica e que serão tidos em conta para o desenvolvimento da mesma.

Este processo de seleção, incluindo os critérios de eliminação de artigos utilizados em cada fase, está presente no esquema apresentado abaixo (Fig.1).

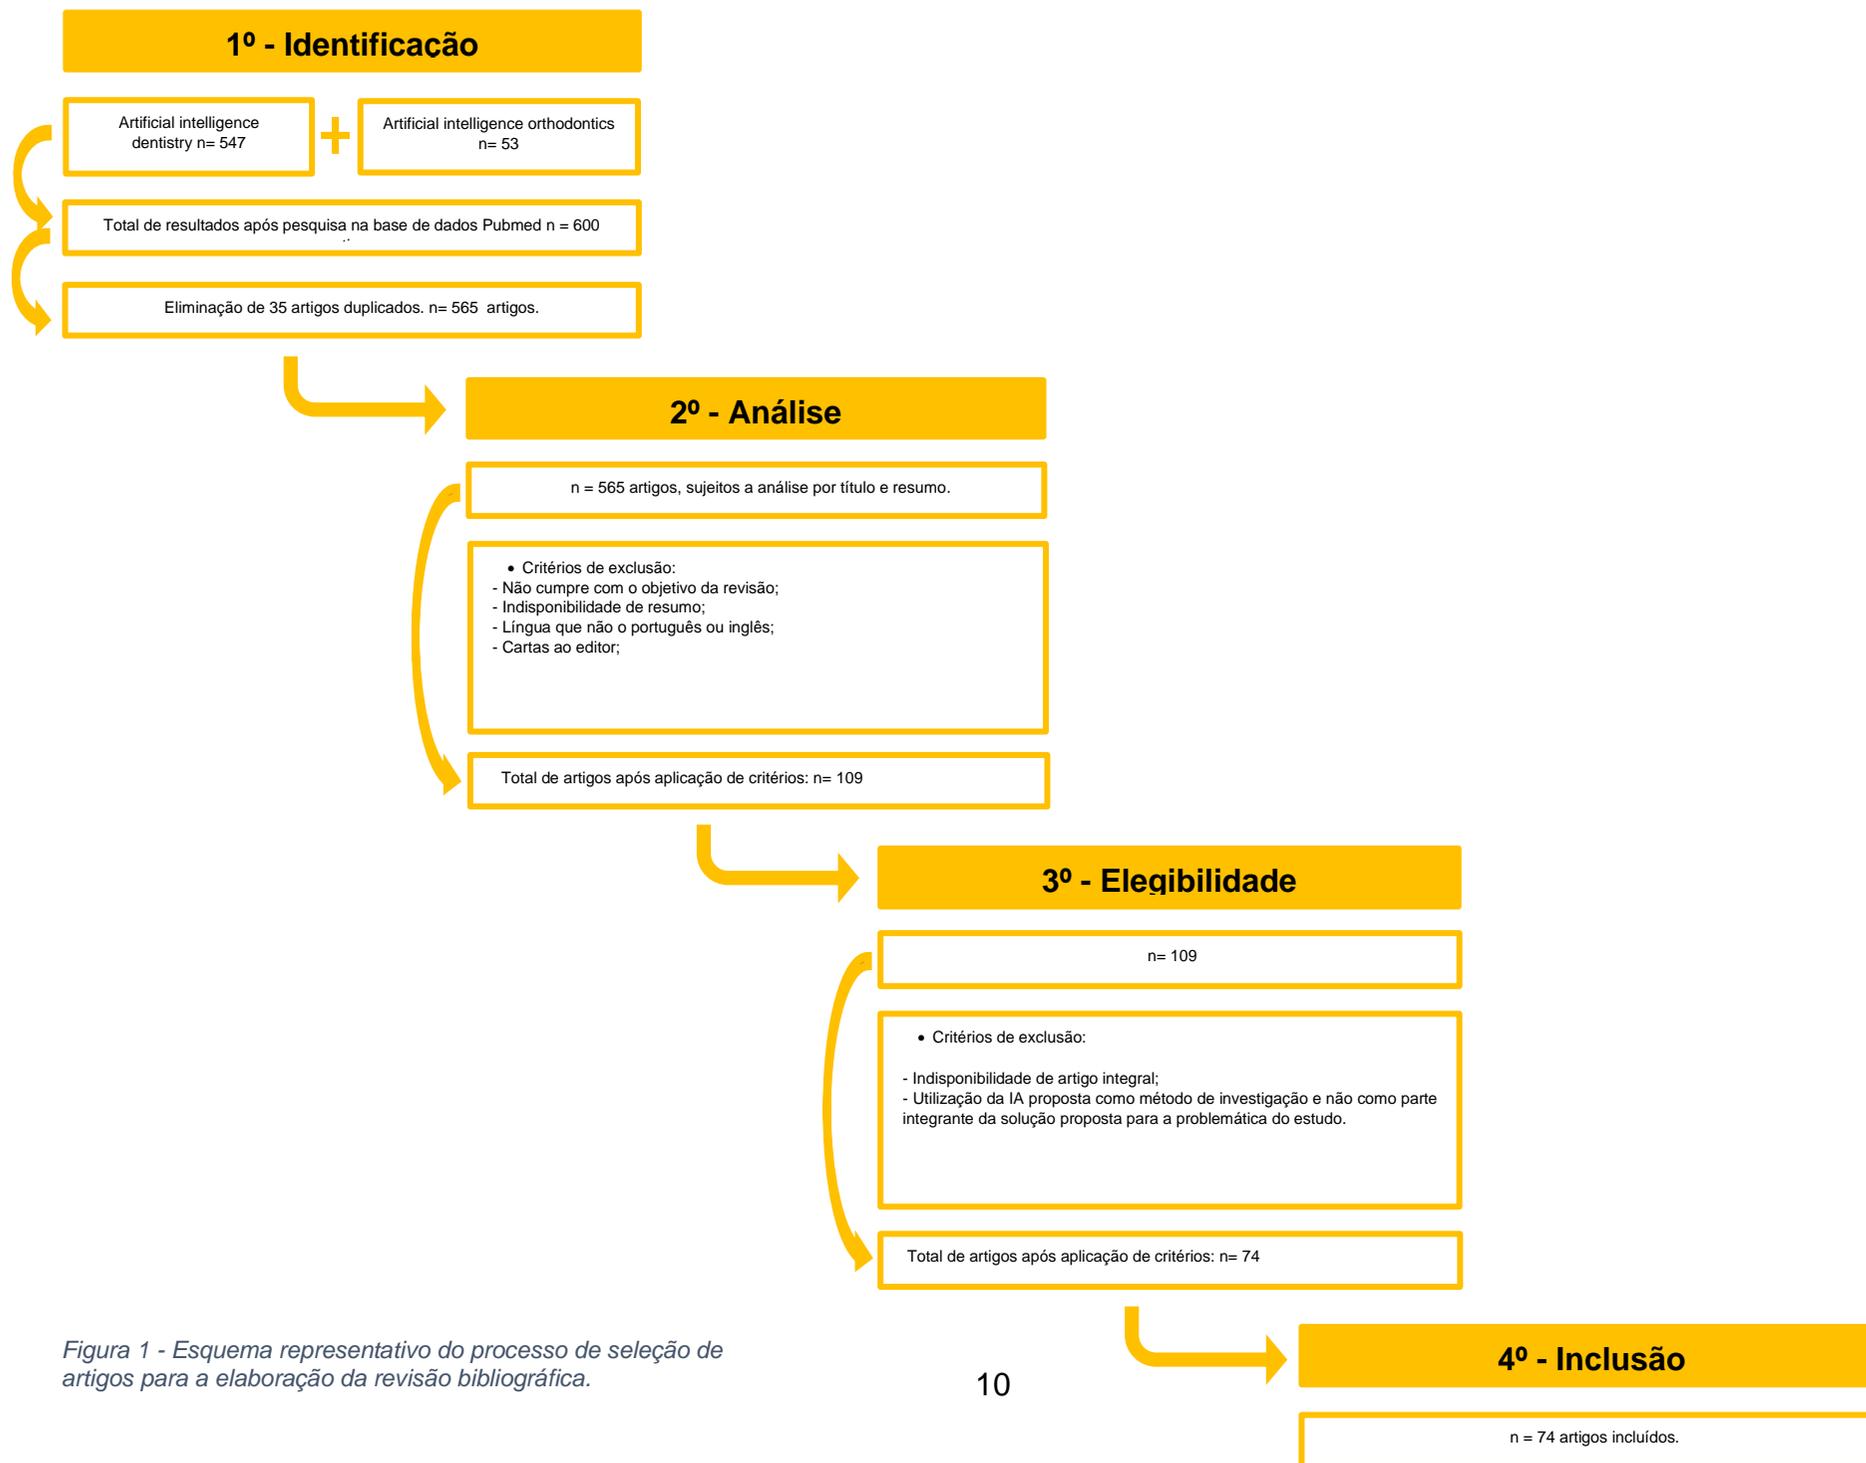


Figura 1 - Esquema representativo do processo de seleção de artigos para a elaboração da revisão bibliográfica.

DESENVOLVIMENTO

Aplicações da Inteligência Artificial em Ortodontia

Kök e col. ¹⁴ testaram os algoritmos *k-nearest neighbors*, *Naive Bayes*, *decision tree*, *artificial neural networks*, *support vector machine*, *random forest*, e *logistic regression* na determinação da idade de pacientes compreendida entre os 8 e os 17 anos de idade em 6 estádios de desenvolvimento através da identificação de 19 pontos nas 2^a, 3^a e 4^a vértebras cervicais e de várias medições entre eles. Os autores concluíram que, apesar de não ter sido o algoritmo mais exato a determinar nenhum dos estádios, por ser o mais consistente no conjunto dos testes, e com resultados minimamente satisfatórios nos testes individuais, o modelo mais indicado para esta aplicação será o baseado nas *artificial neural networks*. Num outro estudo ¹³ realizado pelos mesmo autores, foram avaliados vários modelos feitos com base em NN e foi desenvolvido um modelo que ao utilizar 32 medidas lineares entre 27 pontos de referências nas vértebras cervicais atingiu valores de exatidão de 0.9427 ao classificar o estádio de desenvolvimento e crescimento numa de seis fases e identificam a necessidade de se desenvolverem mais estudos para se atingir um sistema de apoio à tomada de decisão totalmente automático.

Kim e col. ¹⁹ propuseram-se a desenvolver um modelo baseado numa rede neuronal convolucional (CNN – *Convolutional Neural Network*) com o objetivo de fazer identificação automática de 23 pontos cefalométricos em imagens bidimensionais de cefalometria posteroanterior obtidas através de imagens tridimensionais conseguidas através de Tomografia Computorizada de Feixe Cônico (CBCT – *Cone-Beam Computed Tomography*). O modelo desenvolvido apresentou uma distância média ao valor de referência (identificação manual por um especialista) de $2.23\text{mm} \pm 2.02\text{mm}$ o que ultrapassa aquilo que os autores defendem como valor aceitável para a distância média que seria 2mm. Apesar disso, o sistema apresenta uma repetibilidade perfeita, sem diferenças entre testes, ao passo que a repetibilidade intra-operador na identificação manual aponta um erro médio de $1.31\text{mm} \pm 0.94\text{mm}$. Os mesmos autores propuseram, então, uma abordagem diferente em que utilizaram apenas projeções laterais de CBCT e projeções laterais de CBCT com intensidade máxima (o que permite obter uma imagem com maior contraste entre estruturas) e, ao analisar a identificação de 15 pontos, também com uma CNN desenvolvida para o efeito, concluíram não existirem diferenças estatisticamente significativas entre o modelo desenvolvido e os valores de referência (também obtidos por identificação manual por um especialista) e que o erro médio dos modelos quando comparado com os valores de referência foi de $1.03\text{mm} \pm 1.29\text{mm}$ ²⁰.

Com o uso de radiografias cefalométricas laterais foi possível desenvolver um sistema baseado num algoritmo de DL personalizado para a marcação de pontos cefalométricos. Este sistema, treinado com mais de 2000 radiografias de dois institutos diferentes, inclui uma aplicação em *browser* que pode ser utilizado em equipamentos sem requisitos mínimos de hardware exigentes e consegue

um erro médio de apenas $1.37\text{mm} \pm 1.79\text{mm}$ quando comparado com o *gold standard*, aqui definido como a média entre dois especialistas em ortodontia ¹⁵. Silva e col. ⁸ propuseram um modelo baseado em arquiteturas de CNN que conseguem a análise cefalométrica de Arnett, identificando 66 pontos cefalométricos e 10 medições lineares e angulares e que não apresenta diferenças estatisticamente significativas quando comparado com um especialista. Kunz e col. ¹⁶ apresentaram um modelo, também baseado em CNN, que ao analisar 12 pontos cefalométricos em telerradiografias laterais não apresenta diferenças estatisticamente significativas em comparação com o *gold standard* (média de 12 especialistas) e que as diferenças existentes não aparentam qualquer implicação clínica. Enquanto isso, Kim e col. ¹⁸, num modelo que também utiliza uma CNN desenvolvida para o efeito, referem que este deve apenas ser utilizado como método de rastreio, e não como ferramenta única de diagnóstico apesar do erro global médio do mesmo ser de $1.37\text{mm} \pm 0.98\text{mm}$, apresenta em alguns pontos erros superiores a 3.0mm.

Meriç e Naoumova ⁶² fizeram a comparação entre três métodos diferentes, já comercializados, para conseguir traçados cefalométricos, traçado manual mas computadorizado, traçado assistido por software e traçado automatizado com uso de IA, concluindo que este último necessita ainda de ser melhorado para ser utilizado com confiança, mas que apesar disso, quando esse traçado é alvo de correção manual é comparável com os restantes modelos e apresenta grandes vantagens em termos do tempo necessário para concluir o processo.

Ainda no que diz respeito à cefalometria, Lee e col. ¹⁷ apresentam um abordagem verdadeiramente diferente aos demais autores, no sentido em que propõe um modelo cuja habilidade preditiva não é utilizada para localizar, categoricamente, os pontos cefalométricos, mas antes definir regiões de confiança para a localização desses pontos e, assim, tornar-se uma ferramenta que, ao invés de procurar eliminar, por completo, estas tarefas em ortodontia, procura antes, tornar-se uma ferramenta cuja utilização permite uma análise cefalométrica mais rápida e que exige menos por parte do ortodontista.

Park e col. ⁶³ compararam a exatidão de dois métodos de ML (as CNN's YOLOV3 e SSD) para a identificação automática de 80 pontos cefalométricos (Figura 2). Foram utilizadas 1311 telerradiografias (1028 para treinar os modelos e 283 para os testar, sendo esta seleção aleatória), cujos pontos cefalométricos foram identificados manualmente por um ortodontista com 28 anos de experiência. Os autores comprovaram a superioridade da CNN YOLOV3 tanto no que diz respeito à exatidão (significativamente melhor em 38 dos 80 pontos, sendo que nos restantes pontos cefalométricos não se verificaram diferenças estatisticamente significativas entre as duas CNN's) como ao tempo necessário para o fazer (tempo médio por imagem de 0,05 segundos para a YOLOV3 e de 2,89 segundos para a SSD). Num estudo subsequente ⁶⁴, os mesmos autores fizeram a comparação entre a CNN YOLOV3 e dois observadores humanos, um especialista em ortodontia com 28 anos de experiência e um profissional com pouca experiência na identificação de pontos cefalométricos, tendo este último repetido a tarefa ao fim de três meses. Foram utilizadas as mesmas 283

radiografias de teste, indicadas no estudo anterior. Os autores concluíram então que a variabilidade intra-operador havia sido de $0,97\pm 1,03\text{mm}$, enquanto que o sistema de IA não apresentou quaisquer diferenças ao repetir a análise das imagens. Para além disso, não foram encontradas diferenças estatisticamente

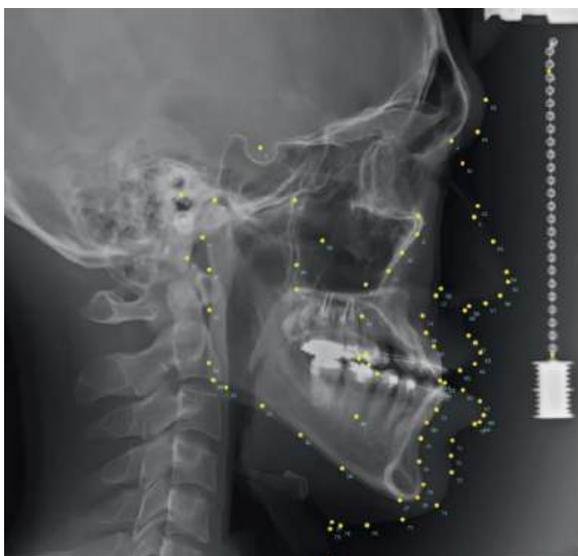


Figura 2 - Imagem ilustrativa dos 80 pontos cefalométricos (46 esqueléticos e 32 em tecidos moles) identificados – in Automated identification of cephalometric landmarks: Part 1— Comparisons between the latest deep-learning methods YOLOV3 and SSD.

significativas entre a IA e os humanos, levando à conclusão de que a IA consegue ser tão precisa, mas mais consistente, que os humanos.

Ferreira A.⁶⁵ propôs um programa informático com o objetivo de auxiliar a decisão clínica em casos limite como o da extração ou não de dentes. Li e col.⁶⁶ desenvolveram, com um objetivo semelhante, um modelo baseado numa CNN que consegue prever o plano de tratamento ortodôntico, incluindo a decisão entre extração ou não de dentes (exatidão de 94.0%, sensibilidade de 94.6% e especificidade de 93.8%), quais os padrões de extração (exatidão de 84.2%) e, até, padrões de ancoragem para movimentos dentários (exatidão de 92.8%). Os autores concluíram que este modelo pode ser uma mais-valia para auxiliar ortodontistas menos experientes a definir planos de tratamento.

Kim e col.⁹ investigaram a utilização de várias CNN's com diferentes profundidades (ou seja, diferente número de camadas) para verificar a influência que esta diferença fundamental entre arquiteturas de modelos diferentes poderá ter na determinação da necessidade de cirurgia ortognática com análise de radiografias cefalométricas. Utilizaram as CNN's ResNet-18, ResNet-34, ResNet-50 e ResNet-101 (em que o número é representativo do número de camadas presentes) e obtiveram valores de exatidão de 93.80%, 93.60%, 91.13% e 91.33%, respetivamente e concluíram que o aumento de camadas não é benéfico para a previsão, mas que as CNN's podem ser utilizadas com sucesso para ajudar no processo de decisão. Shin e col.¹¹ testaram a CNN ResNet-34 para a possibilidade de determinar a necessidade de tratamento com cirurgia ortognática com análise de telerradiografias laterais e posteroanteriores e atingiram, com o modelo proposto, a exatidão, a sensibilidade e a especificidade de 0.954, 0.844 e 0.993, respetivamente, concluindo que a mesma pode ser utilizada para este efeito. Jeong e col.¹⁰ conseguiram, também com a utilização de uma CNN (VGG19), desenvolver um modelo capaz de determinar a

necessidade de cirurgia ortognática analisando apenas os perfis de tecidos moles em fotografias extra-orais (perfil direito e frontal), atingindo 0.893, 0.912 e 0.867 de exatidão, precisão e sensibilidade, respectivamente e concluíram, assim, ter desenvolvido um modelo que pode ser utilizado aquando do diagnóstico ortodôntico.

Stehrer e col. ¹² propuseram-se a desenvolver um modelo de ML capaz de determinar, *a priori*, a perda sanguínea de um paciente submetido a cirurgia ortognática. Este modelo foi desenvolvido com base no algoritmo *random forest* (RF) e utilizou vários aspetos como idade, sexo, peso, altura, tipo de intervenção, medicação administrada, tempo de cirurgia e anestesia, tipo de anestesia, entre outros e conseguiu uma variação média de 7.4 ± 172.3 mL entre o valor previsto de perda sanguínea e o valor corresponde à perda efetiva de sangue e concluíram que se trata de um resultado favorável que permite usar o modelo em contexto clínico.

Aplicações da Inteligência Artificial nas outras áreas médico-dentárias

Imagiologia

O preenchimento de odontogramas e fichas clínicas com base na interpretação e análise de radiografias, sejam elas periapicais, bite-wing, ou ortopantomografias, é ainda uma atividade morosa e que, com a agitação do dia-a-dia clínico, pode ficar para segundo plano levando à inexistência de registos digitalizados e atualizados.

Neste campo, a IA começa, desde já, a surgir como uma aliada do Médico Dentista estando já a ser desenvolvidas aplicações da mesma que permitem a deteção e numeração de dentes para preenchimento automático de odontogramas com a análise de radiografias periapicais ²⁵, ortopantomografias ^{21, 22, 67}, incluindo a deteção de dentes decíduos em crianças ²³. Para além disso é ainda possível empregar o uso da IA no desenvolvimento de algoritmos que conseguem, ao analisar uma ortopantomografia, detetar e classificar as restaurações encontradas em 11 classes diferentes com exatidão global de 93,6% ²⁴.

Lahoud e col. ⁶⁸ demonstram até a utilidade da IA para o tratamento de imagens tridimensionais como é o caso das imagens de CBCT, provando a maior rapidez dos métodos de segmentação de dentes individuais de forma automática (0,5 minutos \pm 8,6 segundos), quando comparados com a segmentação manual (6,6 minutos \pm 76.2 segundos) e com exatidão comparável com as dos técnicos de radiologia experientes.

Cirurgia

No que à Cirurgia diz respeito são várias as potenciais aplicações da IA como parte integrante do diagnóstico, do processo de decisão e planeamento de tratamento e na previsão de complicações no período pós-operatório.

É frequente a inexistência de registos médico-dentários atualizados e que identifiquem o fabricante e modelo do sistema de implantes utilizado em determinada reabilitação. Este problema torna-se ainda mais complexo quando associado à enormíssima quantidade de diferentes sistemas de implantes. Neste sentido, são vários os estudos que, utilizando a análise de ortopantomografias e/ou radiografias periapicais com recurso a CNN, comprovam a utilidade destas ferramentas na identificação de sistemas de implantes conseguindo boas taxas de exatidão na identificação de entre 3 até 11 sistemas diferentes em simultâneo. Apesar disso todos os autores identificam a mesma limitação: a necessidade de criação de uma base de dados massiva que inclua radiografias de todos os sistemas de implantes já comercializados para conseguir avaliar-se a performance dos sistemas de IA numa solução completa e verdadeiramente útil para a aplicação na prática clínica quotidiana. ⁶⁹⁻⁷⁴

Lee e col. ⁷⁵ mostraram resultados de exatidão aceitáveis para a deteção de fraturas de implantes e respetiva classificação (horizontal e vertical circunscritas ao pilar; vertical além do pilar; horizontal superiormente ao pilar) utilizando CNN's e evidenciaram melhores resultados na análise de radiografias periapicais em detrimento das ortopantomografias. No entanto, apesar do moderado sucesso do sistema desenvolvido, os autores indicaram a necessidade de mais estudos para validação do mesmo.

Orhan e col. ²⁶ relativamente aos terceiros molares conseguiram provar o uso das CNN's na análise de vários aspetos como posição e relação espacial com as estruturas anatómicas adjacentes na deteção, com bons níveis de exatidão, de terceiros molares impactados em imagens de CBCT e defendem o contínuo desenvolvimento e aperfeiçoamento destes sistemas para se atingir a aplicabilidade clínica.

Kuwada e col. ²⁷ conseguiram detetar dentes supranumerários impactados na região incisiva da maxila e concluíram que as CNN's *DetectNet* e *AlexNet* apresentam potencial de aplicação clínico e que a primeira pode, inclusive, ser utilizada para, além de detetar, classificar estas anormalidades anatómicas.

Vinayahalingam e col. ²⁸ conseguiram resultados minimamente satisfatórios na identificação da posição de terceiros molares inferiores e do Nervo Alveolar Inferior (NAI) em ortopantomografias com o recurso a CNN's, facilitando assim o trabalho do Médico Dentista num dos procedimentos mais repetidos em cirurgia e com complicações, por vezes, graves, por lesão do NAI. Apesar disto defendem a necessidade de melhorar a exatidão do modelo desenvolvido antes da sua viabilidade para uso clínico. Fukuda e col. ³⁰

comprovaram que não existem diferenças estatisticamente significativas quando se usam CNN's que usam segmentos de imagem maiores (e por consequência um número total de segmentos a analisar inferior) no que à exatidão da detecção da relação espacial entre terceiros molares inferiores e o NAI diz respeito. A vantagem do uso deste tipo de CNN's é a de se conseguirem resultados semelhantes mesmo quando são utilizados computadores com mais limitações ao nível do hardware em termos de capacidade de processamento de informação. Kwak e col. ²⁹ procuraram desenvolver e comparar modelos com recurso a arquiteturas diferentes de CNN's para a detecção e segmentação do percurso do NAI em imagens de CBCT – 2D U-Net, 3D U-Net e SegNet. O modelo baseado na arquitetura 3D U-Net, difere dos restantes principalmente por ser o único capaz de trabalhar a imagem em três dimensões, e é aquele que apresenta os melhores resultados (Figura 3). Porém esta arquitetura apresenta requisitos mínimos de hardware muito altos o que poderá inviabilizar a aplicação deste sistema no dia-a-dia clínico. Apesar disto, os resultados das CNN's

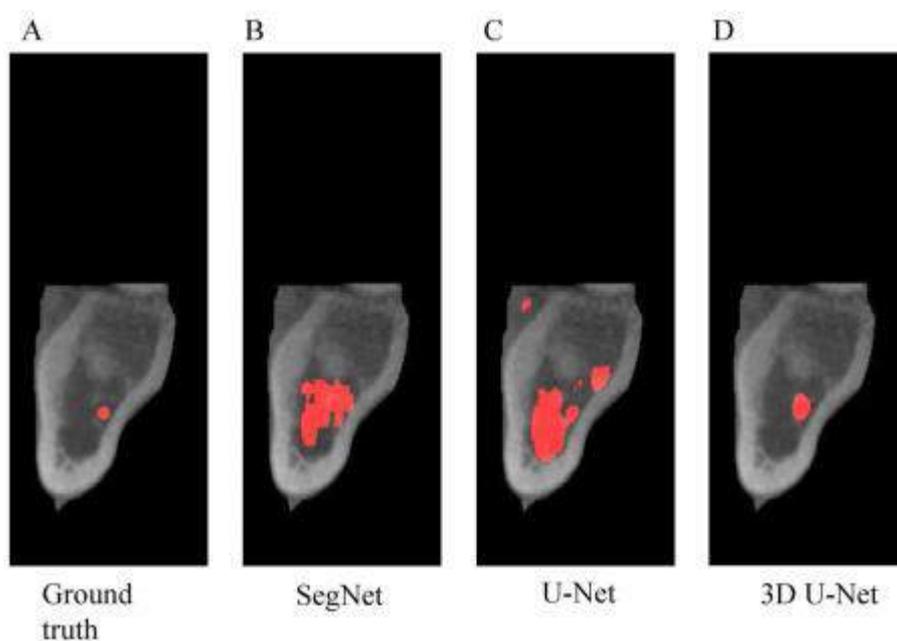


Figura 3 - Resultado da segmentação em corte contendo 2º molar. Da esquerda para a direita, exemplo dado aos modelos (A), resultado de segmentação com CNN SegNet (B), resultado de segmentação com CNN 2D U-Net (C) e resultado da segmentação pela CNN 3D U-Net (D) in Automatic mandibular canal detection using a deep convolutional neural network.

bidimensionais (que obtêm a imagem bidimensional através de uma projeção da imagem tridimensional obtida pelo CBCT) são satisfatórios e, caso consigam ser aperfeiçoados, poderão ser a escolha de eleição para a integração da IA no dia-a-dia clínico em termos de diagnóstico e planeamento.

Existem também possíveis aplicações da IA com recurso a ML para a previsão de ocorrência de complicações pós-operatórias. Zhang e col. ⁷⁶ mostraram a previsão de tumefação após extração de terceiros molares inferiores impactados com uso de algoritmo que recorre a informações como sexo, idade, nível de higiene oral e tamanho e posicionamento do dente na mandíbula, entre outros. Já Kim e col. ³¹ mostraram que modelos de ML são

superiores a métodos estatísticos convencionais quando se pretende conseguir uma previsão de ocorrência de osteonecrose induzida por bifosfonatos (BRONJ - Bisphosphonate-Related Osteonecrosis of the Jaws) associada a extrações dentárias.

Dentisteria Operatória

Askar e col.³² testaram a aplicação de uma CNN (SqueezeNet) para fazer detecção e classificação de lesões brancas nos dentes através da análise de fotografias intraorais e conseguiram obter modelos com performance satisfatória para detetar estas lesões, especialmente as lesões de fluorose. Apesar disso apontaram como limitação dos modelos a instabilidade provocada pela pequena quantidade de informação usada para treinar e testar os mesmos.

Uma das opções para a utilização da IA na detecção e diagnóstico de cárie é a utilização de algoritmos desenvolvidos em CNN's com análise de radiografias periapicais, que apesar de resultados promissores necessitam de melhorias nos modelos e na qualidade das bases de dados utilizadas para os treinar e testar³³. A outra opção surge da utilização de fotografia em proximidade a iluminação infravermelha (NILT – Near-Infrared Light Transillumination) para treinar e testar CNN's e, assim, desenvolver algoritmos que possam ser utilizados para auxiliar o médico dentista no processo de decisão³⁵. No entanto a utilização de imagens recolhidas *in vitro* limita a exatidão dos resultados³⁴.

Schwendicke e col.⁶ demonstram uma boa relação custo-benefício na utilização da IA na detecção de cáries, associado à maior sensibilidade na detecção precoce e, assim, a utilização de tratamentos não restauradores da cárie. Esta relação custo-benefício está, por isso, dependente desse mesmo tratamento não restaurador, tal como a aplicação tópica de verniz de flúor.

Endodontia

No que toca à endodontia, a mais simples aplicação da IA surge da necessidade da correta identificação do número de raízes e canais dos dentes sujeitos a tratamentos endodônticos radicais, tendo-se já demonstrado que as CNN's (AlexNet e GoogLeNet) são igualmente, ou até mais exatas, a identificar o número de raízes de primeiros molares mandibulares em radiografias panorâmicas, quando comparados com radiologistas com mais de vinte anos de experiência a analisar as mesmas radiografias e utilizadas imagens de CBCT como o *gold standard*. Apesar disto, o sucesso dos algoritmos ainda não é semelhante ao de um radiologista ou médico dentista a analisar um CBCT e, como tal, são necessários mais avanços na tecnologia de forma a poder ser viável a sua aplicação clínica.³⁷

A IA também pode ser utilizada para detetar fraturas verticais da raiz, desta feita com recurso a uma rede neuronal probabilística (PNN - *Probabilistic Neural Network*), que corresponde a uma técnica de ML em que há implementação de um algoritmo estatístico designado como método de Kernel

para a análise discriminante (*kernel discriminant analysis*), e que se apresenta bastante eficaz para o efeito quando utilizada em segmentos de imagens de CBCT e com menos sucesso com a utilização de radiografias periapicais, havendo, no entanto, a necessidade de testar a viabilidade da sua aplicação clínica com a utilização de imagens de CBCT completas da totalidade do crânio³⁹. Também para este uso, as técnicas de ML mais comuns como os modelos de CNN apresentam também um forte potencial de aplicabilidade clínica mesmo quando se utilizam radiografias panorâmicas e não apenas as imagens de CBCT ⁴⁰.

Endres e col. ³⁸, mostraram que não existem diferenças estatisticamente significativas entre o algoritmo de ML desenvolvido para detetar lesões radiolúcidas apicais em ortopantomografias quando comparado com o diagnóstico médio de vinte e quatro médicos dentistas experientes. Orhan e col.⁴¹, provaram a inexistência de diferenças estatisticamente significativas entre a segmentação e volumetria manuais de lesões periapicais em CBCT's por radiologistas e a mesma tarefa concluída pela CNN U-Net (Figura 4). Ekert e col. ³⁶ demonstraram que utilizando uma CNN, ainda que com pequenas quantidades de informação como treino, é possível obter resultados muito promissores ao detetar e distinguir lesões apicais em ortopantomografias, mesmo quando lhes é pedido que classifiquem as lesões entre inexistente, incerta com espessamento de ligamento periodontal e existente mas salientam, apesar disso, a necessidade de melhor a sensibilidade do modelo antes da sua aplicação clínica.

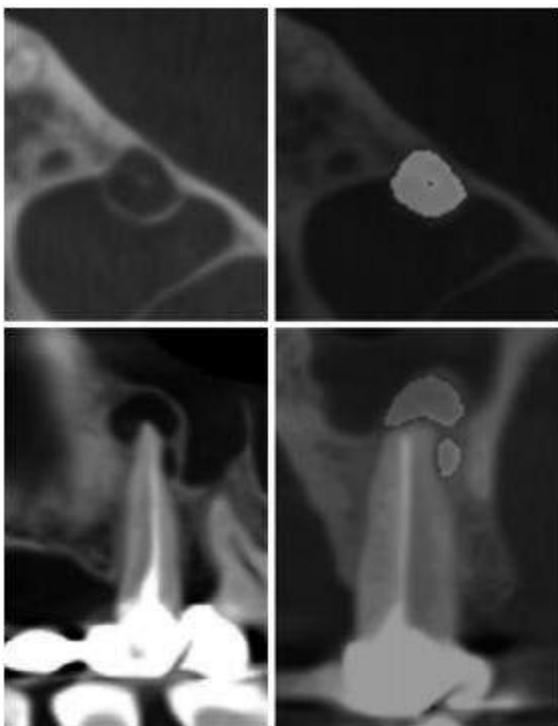


Figura 4 - Exemplo da medição do volume de lesão pelo modelo de IA. In *Evaluation of artificial intelligence for detecting*

Medicina Dentária Forense

Merdietio Boedi e col. ⁷⁷ mostraram que o uso de uma CNN (DenseNet201) associado à segmentação completa do terceiro molar,

eliminando das imagens tecidos e estruturas circundantes, garante níveis de performance semelhantes à observação por profissionais quando se trata de determinar os estágios de desenvolvimento dentários para a determinação da idade de indivíduos.

Miki e col. ⁴² propuseram a utilização de um modelo baseado na CNN AlexNet que consegue, através de imagens de CBCT, classificar os dentes nos diversos tipos e, assim, ser utilizado para preenchimento automático de odontogramas que podem ser de elevada utilidade para identificação forense. Muramatsu e col. ⁴⁴ utilizaram um método baseado numa CNN diferente, a DetectNet, com base na GoogLeNet, que apenas com a análise de ortopantomografias consegue, também, elevados valores de exatidão no que toca à deteção e classificação dentária, com conseguinte preenchimento automático de odontogramas.

Porém, é possível ir-se ainda mais longe e tentar a implementação da IA e do ML em sistemas de identificação automática de indivíduos: Matsuda e col. ⁴³ serviram-se da CNN VGG16 para desenvolver um algoritmo que, através de emparelhamento simples entre ortopantomografias e a informação do indivíduo correspondente, consegue numa fração de segundo identificar o indivíduo, mas saliente serem necessários mais testes de validação antes da possível implementação deste método em acidentes e desastres de larga escala no futuro. Sathya B. e Neelaveni R. ⁴⁵ propuseram um método que, também com a análise de ortopantomografias por uma CNN, neste caso a AlexNet, recorre a deteção e identificação dos dentes presentes nas imagens e a medições entre esses dentes para conseguir entre uma e cinco imagens potencialmente correspondentes, acelerando assim o processo de identificação. Fan e col. ⁴⁶ conseguiram o desenvolvimento de um método (utilizando a CNN DENT-net) que para além da deteção, classificação e medição de distâncias entre dentes, fá-lo também com as restantes estruturas anatómicas presentes nas ortopantomografias com é o caso da mandíbula e maxila e consegue resultados minimamente satisfatórios que carecem, contudo, de confirmação final por um especialista.

Medicina Oral

No diagnóstico de achados radiológicos radiolúcidos, os algoritmos de ML conseguem atingir níveis de sucesso comparáveis aos do diagnóstico manual por especialistas, sendo já possível, a sua aplicação como método de rastreio rápido ⁴⁸. Arijji e col. ⁴⁹ conseguiram elevados níveis de sensibilidade com a CNN DetectNet ao distinguir várias lesões radiolúcidas (ameloblastomas, queratoquistos odontogénicos e quistos dentígeros) com mais de 10mm de diâmetro em ortopantomografias. Kwon e col. ⁵⁰ numa estratégia muito semelhante, mas a empregar a arquitetura de CNN YOLO-V3, garantiram bons níveis de sensibilidade, especificidade e exatidão mesmo quando comparado com especialistas. Yang e col. ⁵¹, em mais um estudo muito semelhante aos anteriores, deste feita com recurso à CNN YOLO-V2, concluíram que estes

sistemas podem ser úteis na detecção automática e precoce destas patologias, o que pode levar à diminuição da morbidade associada às mesmas.

Lee e col.⁴⁷ propuseram-se a desenvolver um modelo, com base na CNN GoogLeNet Inception-v3, que fosse capaz de detetar e diagnosticar três tipos de lesões quísticas odontogénicas (queratoquistos, quistos dentígeros e quistos periapicais) com análise a imagens de CBCT e ortopantomografias. Apesar dos resultados minimamente satisfatórios, principalmente no uso de CBCT's, os autores referem que o uso exclusivo de análise de imagens radiológicas, mesmo quando analisado por IA, não apresenta exatidão suficiente quando comparado com o diagnóstico que recorre a análise histológica.

No que diz respeito ao cancro oral, consequência dos números brutais de mortalidade, existe também muito interesse em estudar aplicações da IA que possam acelerar o diagnóstico e/ou auxiliar processos de decisão no planeamento de tratamento. Jubair e col.⁷⁸ propuseram um modelo desenvolvido com base na CNN pré-treinada EfficientNet-B0 que consegue analisar fotografias intraorais de lesões suspeitas e fazer a sua distinção entre lesões malignas ou potencialmente malignas e benignas. Com valores de exatidão, especificidade e sensibilidade de 85,0%, 84,5% e 86,7%, respetivamente, e com a possibilidade de ser implementado em dispositivos com memória e capacidade de processamento limitados, este modelo pode ser uma boa alternativa para rastreio e detecção precoce do cancro oral.

Também na avaliação do prognóstico pode ser introduzida a IA. Neste caso deixamos de utilizar a IA com métodos de ML de análise exclusiva de imagens, mas passam a ser utilizados modelos de ML de análise de texto e de variáveis associadas ao prognóstico dos pacientes com Carcinoma Oral de Células Escamosas (OSCC – *Oral Squamous Cell Carcinoma*) tais como idade, sexo e estágio de desenvolvimento dos tumores, entre outros. Estes modelos conseguem melhores resultados que os métodos estatísticos clássicos e podem ajudar a guiar os clínicos ao longo do tratamento da doença, assim como ajudar a evitar tratamentos desnecessários^{52, 53}. Estes modelos podem também ser aplicados para prever, com melhor exatidão, o risco de recorrência em casos de carcinoma do bordo da língua⁵⁴.

Oclusão

Choi e col.⁵⁵ mostraram que a utilização de uma CNN (Inception-v3, neste caso) a analisar ortopantomografias atinge resultados de exatidão e precisão superiores aos de um radiologista experiente no que concerne à detecção de osteoartrite da Articulação Temporomandibular (ATM), sendo estes resultados semelhantes aos de um radiologista a analisar imagens de CBCT. Os autores indicam que a ferramenta desenvolvida poderá ser uma mais-valia para o diagnóstico de osteoartrite da ATM em clínicas pequenas onde não estão

presentes sistemas de CBCT e/ou radiologistas experientes que possam ajudar no diagnóstico desta patologia.

Nishiyama e col. ⁵⁶ provaram a utilidade do uso de sistemas de ML para a detecção de fraturas do côndilo mandibular com a análise de ortopantomografias, tendo o modelo desenvolvido com auxílio da CNN AlexNet atingido valores de estatística C superiores a 0,85 o que indica um bom compromisso entre sensibilidade e especificidade.

Periodontologia

You e col. ⁷⁹ mostraram o interesse do uso da IA para a detecção da presença de placa bacteriana em dentes decíduos com recurso à CNN DeepLabV3+ utilizada para analisar fotografias intraorais. Os autores indicam a possível utilização por parte dos pais, ou cuidadores, para controlo da higiene oral das crianças, uma vez que o modelo desenvolvido apresenta resultados aceitáveis para uso clínico mesmo com utilização de imagens de baixa resolução.

A IA pode ser utilizada também para detetar e classificar dentes periodontalmente comprometidos com a análise de ortopantomografias com recurso a CNN's ⁵⁷ e até ser capaz de, entre estes, conseguir identificar os dentes que apresentam indicação de extração ⁵⁸.

Alalharith e col. ⁸⁰ mostraram um modelo com potencial para detetar, precocemente, casos de periodontite ao conseguir sinalizar sinais de inflamação gengival com análise de fotografias intraorais em pacientes ortodônticos através da CNN ResNet-50. No entanto, apesar dos resultados encorajadores, os autores revelam que esta solução não pode ser exclusivamente utilizada para o diagnóstico de periodontite uma vez que apenas analisa um dos vários aspetos necessários ao diagnóstico da patologia.

Kim e col. ⁵⁹ mostraram o uso da CNN DentNet para conseguir um modelo que consegue detetar a perda de osso periodontal (Figura 5) com uma performance superior à dos médicos dentistas, com recurso à análise de ortopantomografias e concluíram que a ferramenta permitirá reduzir tempo e carga de trabalho no diagnóstico da periodontite. Krois e col. ⁶⁰, com uma CNN desenvolvida especialmente para o efeito, conseguiram também, apesar da quantidade limitada de ortopantomografias utilizadas, um algoritmo que apresenta resultados semelhantes aos dos médicos dentistas experientes para a medição da perda óssea. Chang e col. ⁶¹ foram um pouco mais longe e, para além da detecção e medição da perda óssea nas radiografias panorâmicas,

conseguiram, com uso da CNN ResNet-101, desenvolver um algoritmo que faz, também, a identificação e classificação do estadio da doença periodontal.



Figura 5 - Imagem ilustrativa do trabalho de Kim e colaboradores. (Topo) Radiografias obtidas e consideradas como input. (Meio) zonas de perda óssea assinaladas por especialistas como output. (Fundo) representação dos mapas de ativação da CNN DentNet utilizada – in DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs.

Cha e col.⁸¹ conseguiram a implementação de uma CNN para a medição de perda óssea associada a implantes com recurso à análise de radiografias periapicais e não foram encontradas diferenças estatisticamente significativas entre o modelo proposto e os médicos dentistas, concluindo que o modelo proposto pode ser utilizado para a avaliação da peri-implantite.

Limitações da Inteligência Artificial

A principal limitação da IA prende-se com a inexistência de grandes bases de dados (sendo que modelos desenvolvidos com pequenas bases de dados originam casos de *overfitting*, em que o modelo acaba por quase como que memorizar as imagens e ou características e perde a capacidade de inferir sobre novos conjuntos de dados) e com a qualidade das mesmas, seja em relação à qualidade efetiva de radiografias e/ou fotografias, ao detalhe de informação associado às mesmas e aos casos em si, ou até à legenda ou rotulamento de patologias identificadas nas imagens^{31, 69}. Ainda em relação às bases de dados, outra limitação diz respeito à baixa variabilidade das mesmas, refletindo, na grande maioria das vezes, características que podem ser específicas a uma determinada região e limitando, assim a capacidade de generalização dos modelos desenvolvidos e o mesmo se aplica em relação aos equipamentos de radiologia, uma vez que os modelos desenvolvidos com imagens obtidas num único equipamento, normalmente correspondente a um hospital e/ou universidade, também apresentam dificuldades em ser aplicados em imagens obtidas noutros equipamentos^{18, 47, 70, 72}.

Uma outra limitação da IA prende-se com o facto de os algoritmos desenvolvidos gerarem uma previsão sem mostrar, de forma clara e concisa, quais os aspetos considerados para chegar àquele resultado, o que é essencial na área da saúde, e obriga, por isso, a implementação de softwares anexos que permitem uma interpretação dos modelos e que também gastam recursos computacionais gerando, por isso, atrasos na obtenção de resultados ^{31, 69}.

Para além disso, uma vez que os modelos imitam o comportamento humano, por serem desenvolvidos com base na informação que lhes é cedida como exemplo, vão refletir toda e qualquer dificuldade de diagnóstico que os profissionais considerados como exemplo apresentem. Para além das dificuldades dos profissionais, também as questões mais polémicas e com menos consenso em toda a comunidade científica vão ser difíceis de generalizar, uma vez que quando a variabilidade entre examinadores é grande, a exatidão dos modelos vai diminuir, ou seja, a generalização da aplicação de modelos específicos de IA está dependente da concordância de toda a comunidade científica, ou pelo menos grande parte, em relação ao aspeto a analisar pelo modelo em questão. ^{9, 17, 19}

CONCLUSÃO

No que diz respeito à ortodontia, em que a análise radiológica ainda corresponde a uma das mais morosas, e difíceis, tarefas no que ao diagnóstico diz respeito, e tendo em conta os bons resultados, tanto em termos de exatidão, como em termos de eficiência de tempo, a IA tem tudo para se afirmar como parte integrante do futuro do diagnóstico nesta área.

Em relação às restantes áreas da medicina dentária, conseguimos concluir que a IA tem o potencial de surgir como alternativa viável, exata e eficaz aos métodos tradicionais de análise de imagiologia, seja para deteção de cáries, preenchimento automático de odontogramas, identificação de pessoas no âmbito das ciências forenses, identificação e classificação de relações anatómicas em contexto de preparação para procedimentos cirúrgicos e até na previsão de complicações pós-operatórias. Para além disso, a IA promete conseguir também a deteção de fraturas verticais da raiz, lesões quísticas odontogénicas, avaliação de nível de perda óssea e auxiliar no diagnóstico da periodontite, entre outras possíveis aplicações já elencadas neste trabalho.

Assim, e apesar das limitações associadas à implementação da IA em contexto clínico, é possível concluir que esta tem potencial para se tornar uma aliada do médico dentista, na medida em que permitirá acelerar processos de análise radiográfica, diagnóstico e elaboração e acompanhamento de planos de tratamento e, ainda, melhorar o prognóstico de alguns tratamentos, assim como diminuir os custos de outros.

Posto isto, são necessários estudos que, entre outras melhorias e correções, proponham a criação de grandes bases de dados internacionais, num esforço conjunto da comunidade científica e que permitam, assim, ultrapassar as barreiras mais imediatas da aplicação da IA na Medicina Dentária, como a dificuldade na generalização dos modelos desenvolvidos. Para além disso, são também necessários estudos que avaliem a viabilidade da aplicação da IA artificial em contexto clínico.

REFERÊNCIAS

1. Chen YW, Stanley K, Att W. Artificial intelligence in dentistry: current applications and future perspectives. *Quintessence Int.* 2020;51(3):248-57.
2. Hung K, Yeung AWK, Tanaka R, Bornstein MM. Current Applications, Opportunities, and Limitations of AI for 3D Imaging in Dental Research and Practice. *Int J Environ Res Public Health.* 2020;17(12).
3. Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. *J Dent Res.* 2021;100(3):232-44.
4. Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. *J Dent Res.* 2020;99(7):769-74.
5. Corbella S, Srinivas S, Cabitza F. Applications of deep learning in dentistry. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020.
6. Schwendicke F, Rossi JG, Göstemeyer G, Elhennawy K, Cantu AG, Gaudin R, et al. Cost-effectiveness of Artificial Intelligence for Proximal Caries Detection. *J Dent Res.* 2021;100(4):369-76.
7. Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: A scoping review. *J Dent.* 2019;91:103226.
8. Silva TP, Hughes MM, Menezes LDS, de Melo MFB, Takeshita WM, Freitas PHL. Artificial intelligence-based cephalometric landmark annotation and measurements according to Arnett's analysis: can we trust a bot to do that? *Dentomaxillofac Radiol.* 2021:20200548.
9. Kim YH, Park JB, Chang MS, Ryu JJ, Lim WH, Jung SK. Influence of the Depth of the Convolutional Neural Networks on an Artificial Intelligence Model for Diagnosis of Orthognathic Surgery. *J Pers Med.* 2021;11(5).
10. Jeong SH, Yun JP, Yeom HG, Lim HJ, Lee J, Kim BC. Deep learning based discrimination of soft tissue profiles requiring orthognathic surgery by facial photographs. *Sci Rep.* 2020;10(1):16235.
11. Shin W, Yeom HG, Lee GH, Yun JP, Jeong SH, Lee JH, et al. Deep learning based prediction of necessity for orthognathic surgery of skeletal malocclusion using cephalogram in Korean individuals. *BMC Oral Health.* 2021;21(1):130.
12. Stehrer R, Hingsammer L, Staudigl C, Hunger S, Malek M, Jacob M, et al. Machine learning based prediction of perioperative blood loss in orthognathic surgery. *J Craniomaxillofac Surg.* 2019;47(11):1676-81.
13. Kök H, İzgi MS, Acilar AM. Determination of growth and development periods in orthodontics with artificial neural network. *Orthod Craniofac Res.* 2020.
14. Kök H, Acilar AM, İzgi MS. Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Prog Orthod.* 2019;20(1):41.

15. Kim H, Shim E, Park J, Kim YJ, Lee U, Kim Y. Web-based fully automated cephalometric analysis by deep learning. *Comput Methods Programs Biomed.* 2020;194:105513.
16. Kunz F, Stellzig-Eisenhauer A, Zeman F, Boldt J. Artificial intelligence in orthodontics : Evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *J Orofac Orthop.* 2020;81(1):52-68.
17. Lee JH, Yu HJ, Kim MJ, Kim JW, Choi J. Automated cephalometric landmark detection with confidence regions using Bayesian convolutional neural networks. *BMC Oral Health.* 2020;20(1):270.
18. Kim J, Kim I, Kim YJ, Kim M, Cho JH, Hong M, et al. Accuracy of automated identification of lateral cephalometric landmarks using cascade convolutional neural networks on lateral cephalograms from nationwide multi-centers. *Orthod Craniofac Res.* 2021.
19. Kim MJ, Liu Y, Oh SH, Ahn HW, Kim SH, Nelson G. Evaluation of a multi-stage convolutional neural network-based fully automated landmark identification system using cone-beam computed tomographysynthesized posteroanterior cephalometric images. *Korean J Orthod.* 2021;51(2):77-85.
20. Kim MJ, Liu Y, Oh SH, Ahn HW, Kim SH, Nelson G. Automatic Cephalometric Landmark Identification System Based on the Multi-Stage Convolutional Neural Networks with CBCT Combination Images. *Sensors (Basel).* 2021;21(2).
21. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, et al. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol.* 2019;48(4):20180051.
22. Mahdi FP, Motoki K, Kobashi S. Optimization technique combined with deep learning method for teeth recognition in dental panoramic radiographs. *Sci Rep.* 2020;10(1):19261.
23. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, et al. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofac Radiol.* 2021:20200172.
24. Abdalla-Aslan R, Yeshua T, Kabla D, Leichter I, Nadler C. An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020;130(5):593-602.
25. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, et al. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep.* 2019;9(1):3840.
26. Orhan K, Bilgir E, Bayrakdar IS, Ezhov M, Gusarev M, Shumilov E. Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans. *J Stomatol Oral Maxillofac Surg.* 2020.
27. Kuwada C, Arijji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, et al. Deep learning systems for detecting and classifying the presence of impacted

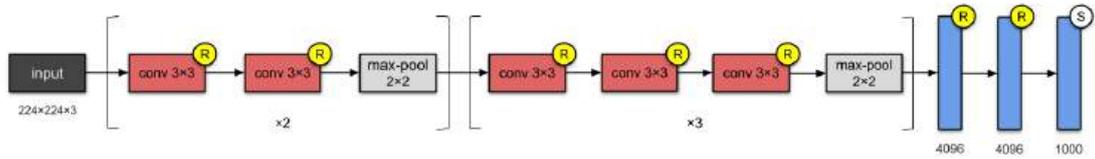
- supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020;130(4):464-9.
28. Vinayahalingam S, Xi T, Bergé S, Maal T, de Jong G. Automated detection of third molars and mandibular nerve by deep learning. *Sci Rep.* 2019;9(1):9007.
 29. Kwak GH, Kwak EJ, Song JM, Park HR, Jung YH, Cho BH, et al. Automatic mandibular canal detection using a deep convolutional neural network. *Sci Rep.* 2020;10(1):5711.
 30. Fukuda M, Arijji Y, Kise Y, Nozawa M, Kuwada C, Funakoshi T, et al. Comparison of 3 deep learning neural networks for classifying the relationship between the mandibular third molar and the mandibular canal on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020;130(3):336-43.
 31. Kim DW, Kim H, Nam W, Kim HJ, Cha IH. Machine learning to predict the occurrence of bisphosphonate-related osteonecrosis of the jaw associated with dental extraction: A preliminary report. *Bone.* 2018;116:207-14.
 32. Askar H, Krois J, Rohrer C, Mertens S, Elhennawy K, Ottolenghi L, et al. Detecting white spot lesions on dental photography using deep learning: A pilot study. *J Dent.* 2021;107:103615.
 33. Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent.* 2018;77:106-11.
 34. Holtkamp A, Elhennawy K, Cejudo Grano de Oro JE, Krois J, Paris S, Schwendicke F. Generalizability of Deep Learning Models for Caries Detection in Near-Infrared Light Transillumination Images. *J Clin Med.* 2021;10(5).
 35. Schwendicke F, Elhennawy K, Paris S, Friebertshäuser P, Krois J. Deep learning for caries lesion detection in near-infrared light transillumination images: A pilot study. *J Dent.* 2020;92:103260.
 36. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, et al. Deep Learning for the Radiographic Detection of Apical Lesions. *J Endod.* 2019;45(7):917-22.e5.
 37. Hiraiwa T, Arijji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol.* 2019;48(3):20180218.
 38. Endres MG, Hillen F, Salloumis M, Sedaghat AR, Niehues SM, Quatela O, et al. Development of a Deep Learning Algorithm for Periapical Disease Detection in Dental Radiographs. *Diagnostics (Basel).* 2020;10(6).
 39. Johari M, Esmaeili F, Andalib A, Garjani S, Saberhari H. Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofac Radiol.* 2017;46(2):20160107.
 40. Fukuda M, Inamoto K, Shibata N, Arijji Y, Yanashita Y, Kutsuna S, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiol.* 2020;36(4):337-43.

41. Orhan K, Bayrakdar IS, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *Int Endod J.* 2020;53(5):680-9.
42. Miki Y, Muramatsu C, Hayashi T, Zhou X, Hara T, Katsumata A, et al. Classification of teeth in cone-beam CT using deep convolutional neural network. *Comput Biol Med.* 2017;80:24-9.
43. Matsuda S, Miyamoto T, Yoshimura H, Hasegawa T. Personal identification with orthopantomography using simple convolutional neural networks: a preliminary study. *Sci Rep.* 2020;10(1):13559.
44. Muramatsu C, Morishita T, Takahashi R, Hayashi T, Nishiyama W, Arijji Y, et al. Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi-sized input data. *Oral Radiol.* 2021;37(1):13-9.
45. B S, R N. Transfer Learning Based Automatic Human Identification using Dental Traits- An Aid to Forensic Odontology. *J Forensic Leg Med.* 2020;76:102066.
46. Fan F, Ke W, Wu W, Tian X, Lyu T, Liu Y, et al. Automatic human identification from panoramic dental radiographs using the convolutional neural network. *Forensic Sci Int.* 2020;314:110416.
47. Lee JH, Kim DH, Jeong SN. Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral Dis.* 2020;26(1):152-8.
48. Poedjiastoeti W, Suebnukarn S. Application of Convolutional Neural Network in the Diagnosis of Jaw Tumors. *Healthc Inform Res.* 2018;24(3):236-41.
49. Arijji Y, Yanashita Y, Kutsuna S, Muramatsu C, Fukuda M, Kise Y, et al. Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2019;128(4):424-30.
50. Kwon O, Yong TH, Kang SR, Kim JE, Huh KH, Heo MS, et al. Automatic diagnosis for cysts and tumors of both jaws on panoramic radiographs using a deep convolution neural network. *Dentomaxillofac Radiol.* 2020;49(8):20200185.
51. Yang H, Jo E, Kim HJ, Cha IH, Jung YS, Nam W, et al. Deep Learning for Automated Detection of Cyst and Tumors of the Jaw in Panoramic Radiographs. *J Clin Med.* 2020;9(6).
52. Kim DW, Lee S, Kwon S, Nam W, Cha IH, Kim HJ. Deep learning-based survival prediction of oral cancer patients. *Sci Rep.* 2019;9(1):6994.
53. Chu CS, Lee NP, Adeoye J, Thomson P, Choi SW. Machine learning and treatment outcome prediction for oral cancer. *J Oral Pathol Med.* 2020;49(10):977-85.
54. Alabi RO, Elmusrati M, Sawazaki-Calone I, Kowalski LP, Haglund C, Coletta RD, et al. Machine learning application for prediction of locoregional recurrences in early oral tongue cancer: a Web-based prognostic tool. *Virchows Arch.* 2019;475(4):489-97.

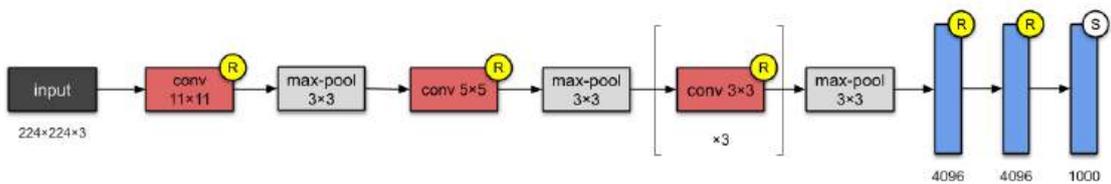
55. Choi E, Kim D, Lee JY, Park HK. Artificial intelligence in detecting temporomandibular joint osteoarthritis on orthopantomogram. *Sci Rep.* 2021;11(1):10246.
56. Nishiyama M, Ishibashi K, Arijji Y, Fukuda M, Nishiyama W, Umemura M, et al. Performance of deep learning models constructed using panoramic radiographs from two hospitals to diagnose fractures of the mandibular condyle. *Dentomaxillofac Radiol.* 2021:20200611.
57. Thanathornwong B, Suebnukarn S. Automatic detection of periodontal compromised teeth in digital panoramic radiographs using faster regional convolutional neural networks. *Imaging Sci Dent.* 2020;50(2):169-74.
58. Lee JH, Kim DH, Jeong SN, Choi SH. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci.* 2018;48(2):114-23.
59. Kim J, Lee HS, Song IS, Jung KH. DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs. *Sci Rep.* 2019;9(1):17615.
60. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep Learning for the Radiographic Detection of Periodontal Bone Loss. *Sci Rep.* 2019;9(1):8495.
61. Chang HJ, Lee SJ, Yong TH, Shin NY, Jang BG, Kim JE, et al. Deep Learning Hybrid Method to Automatically Diagnose Periodontal Bone Loss and Stage Periodontitis. *Sci Rep.* 2020;10(1):7531.
62. Meriç P, Naoumova J. Web-based Fully Automated Cephalometric Analysis: Comparisons between App-aided, Computerized, and Manual Tracings. *Turk J Orthod.* 2020;33(3):142-9.
63. Park JH, Hwang HW, Moon JH, Yu Y, Kim H, Her SB, et al. Automated identification of cephalometric landmarks: Part 1-Comparisons between the latest deep-learning methods YOLOV3 and SSD. *Angle Orthod.* 2019;89(6):903-9.
64. Hwang HW, Park JH, Moon JH, Yu Y, Kim H, Her SB, et al. Automated identification of cephalometric landmarks: Part 2- Might it be better than human? *Angle Orthod.* 2020;90(1):69-76.
65. Ferreira A. *Compensação, descompensação e camuflagem ortodôntica : Casos limite.* Porto: Universidade do Porto; 1997.
66. Li P, Kong D, Tang T, Su D, Yang P, Wang H, et al. Orthodontic Treatment Planning based on Artificial Neural Networks. *Sci Rep.* 2019;9(1):2037.
67. Lee JH, Han SS, Kim YH, Lee C, Kim I. Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020;129(6):635-42.
68. Lahoud P, EzEldeen M, Beznik T, Willems H, Leite A, Van Gerven A, et al. Artificial Intelligence for Fast and Accurate 3-Dimensional Tooth Segmentation on Cone-beam Computed Tomography. *J Endod.* 2021;47(5):827-35.

69. Sukegawa S, Yoshii K, Hara T, Yamashita K, Nakano K, Yamamoto N, et al. Deep Neural Networks for Dental Implant System Classification. *Biomolecules*. 2020;10(7).
70. Hadj Saïd M, Le Roux MK, Catherine JH, Lan R. Development of an Artificial Intelligence Model to Identify a Dental Implant from a Radiograph. *Int J Oral Maxillofac Implants*. 2020;36(6):1077-82.
71. Takahashi T, Nozaki K, Gonda T, Mameno T, Wada M, Ikebe K. Identification of dental implants using deep learning-pilot study. *Int J Implant Dent*. 2020;6(1):53.
72. Lee JH, Kim YT, Lee JB, Jeong SN. A Performance Comparison between Automated Deep Learning and Dental Professionals in Classification of Dental Implant Systems from Dental Imaging: A Multi-Center Study. *Diagnostics (Basel)*. 2020;10(11).
73. Kim JE, Nam NE, Shim JS, Jung YH, Cho BH, Hwang JJ. Transfer Learning via Deep Neural Networks for Implant Fixture System Classification Using Periapical Radiographs. *J Clin Med*. 2020;9(4).
74. Lee JH, Jeong SN. Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs: A pilot study. *Medicine (Baltimore)*. 2020;99(26):e20787.
75. Lee DW, Kim SY, Jeong SN, Lee JH. Artificial Intelligence in Fractured Dental Implant Detection and Classification: Evaluation Using Dataset from Two Dental Hospitals. *Diagnostics (Basel)*. 2021;11(2).
76. Zhang W, Li J, Li ZB, Li Z. Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation. *Sci Rep*. 2018;8(1):12281.
77. Merdietio Boedi R, Banar N, De Tobel J, Bertels J, Vandermeulen D, Thevissen PW. Effect of Lower Third Molar Segmentations on Automated Tooth Development Staging using a Convolutional Neural Network. *J Forensic Sci*. 2020;65(2):481-6.
78. Jubair F, Al-Karadsheh O, Malamos D, Al Mahdi S, Saad Y, Hassona Y. A novel lightweight deep convolutional neural network for early detection of oral cancer. *Oral Dis*. 2021.
79. You W, Hao A, Li S, Wang Y, Xia B. Deep learning-based dental plaque detection on primary teeth: a comparison with clinical assessments. *BMC Oral Health*. 2020;20(1):141.
80. Alalharith DM, Alharthi HM, Alghamdi WM, Alsenbel YM, Aslam N, Khan IU, et al. A Deep Learning-Based Approach for the Detection of Early Signs of Gingivitis in Orthodontic Patients Using Faster Region-Based Convolutional Neural Networks. *Int J Environ Res Public Health*. 2020;17(22).
81. Cha JY, Yoon HI, Yeo IS, Huh KH, Han JS. Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs. *J Clin Med*. 2021;10(5).

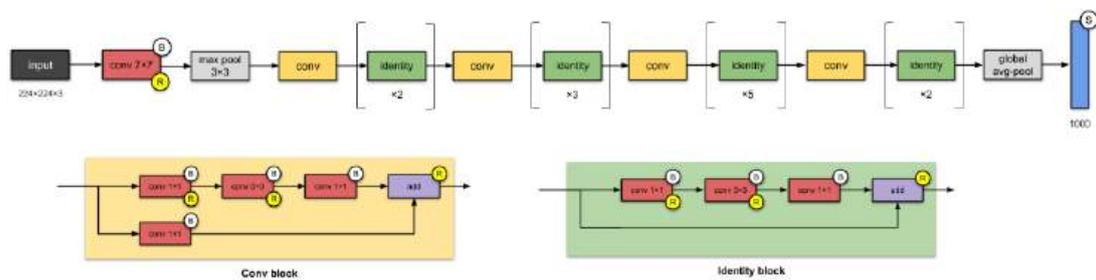
ANEXOS



Anexo 1 - Representação visual da CNN VGG-16 in <https://towardsdatascience.com/illustrated-10-cnn-architectures-95d78ace614d#c5a6>

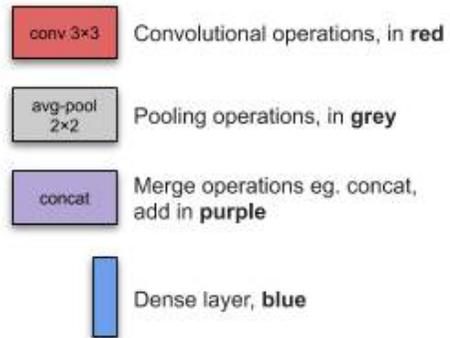


Anexo 2 - Representação visual da CNN AlexNet in <https://towardsdatascience.com/illustrated-10-cnn-architectures-95d78ace614d#c5a6>



Anexo 3 - Representação visual da CNN ResNet-50 in <https://towardsdatascience.com/illustrated-10-cnn-architectures-95d78ace614d#c5a6>

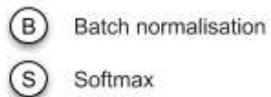
Layers



Activation Functions

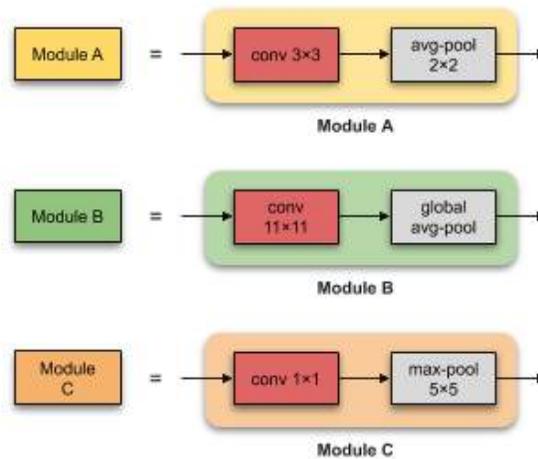


Other Functions

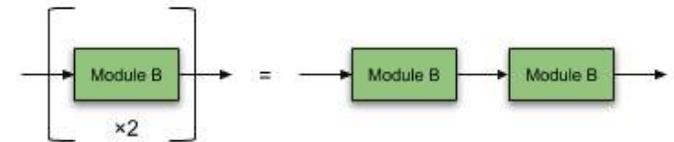


Modules/Blocks

Modules (groups of convolutional, pooling and merge operations), in **yellow, green, or orange**. The operations that make up these modules will also be shown.



Repeated layers or modules/blocks



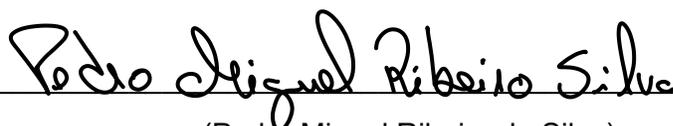
PARECER

Monografia/Relatório de Estágio

Declaro que o presente trabalho, no âmbito da Monografia/Relatório de Estágio, integrado no MIMD, da FMDUP, é da minha autoria e todas as fontes foram devidamente referenciadas.

Porto, 3 de julho de 2021

O estudante



(Pedro Miguel Ribeiro da Silva)

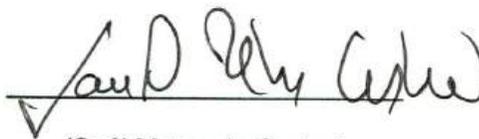
PARECER

(Entrega do Trabalho final da Monografia)

Informo que o Trabalho de Monografia/Relatório de Estágio desenvolvido pelo Estudante Pedro Miguel Ribeiro da Silva com o título: *"Inteligência Artificial em Medicina Dentária: o Futuro do Diagnóstico em Ortodontia"*, está de acordo com as regras estipuladas na FMDUP, foi por mim conferido e encontra-se em condições de ser apresentado em provas públicas.

Porto, 3 de julho de 2021

O orientador



(Saúl Matos de Castro)

PARECER

(Entrega do Trabalho final da Monografia)

Informo que o Trabalho de Monografia/Relatório de Estágio desenvolvido pelo Estudante Pedro Miguel Ribeiro da Silva com o título: *"Inteligência Artificial em Medicina Dentária: o Futuro do Diagnóstico em Ortodontia"*, está de acordo com as regras estipuladas na FMDUP, foi por mim conferido e encontra-se em condições de ser apresentado em provas públicas.

Porto, 3 de julho de 2021

Assinado por : **Maria João Felo Ponces Ramalhão**
Num. de identificação: 810430000 orientadora
Data: 2021.07.03 21:35:40 +0100



(Maria João Ponces)

DECLARAÇÃO

Mestrado Integrado em Medicina Dentária

Monografia/Relatório de Estágio

Identificação do autor

Nome completo: Pedro Miguel Ribeiro Silva

Nº identificação civil: 14757027

Nº Estudante: 201506229

Email institucional: up201506229@edu.fmd.up.pt

Email alternativo: pedro.ribeiro.silva22@gmail.com **Tlf/Tlm:** 918605715

Faculdade/Instituto: Faculdade de Medicina Dentária da Universidade do Porto

Identificação da publicação

Dissertação de Mestrado Integrado (Monografia) **Relatório de Estágio**

Título Completo

Inteligência Artificial em Medicina Dentária: o Futuro do Diagnóstico em Ortodontia

Orientador: Saúl Matos de Castro

Coorientador: Maria João Ponces

Palavras-chave: Inteligência Artificial; Aprendizagem Automática; Medicina Dentária; Ortodontia; Redes Neurais Convolucionais.

Autorizo a disponibilização imediata do texto integral no Repositório da U.Porto: (x)

Não autorizo a disponibilização imediata do texto integral no Repositório da U.Porto: (x)

Autorizo a disponibilização do texto integral no Repositório da U.Porto, com período de embargo, no prazo de:

6 meses: _____; 12 meses: _____; 18 meses: _____; 24 meses: _____; 36 meses: _____; 120 meses: _____;

Justificação para a não autorização imediata: _____

Data: 3 de julho de 2021

Assinatura: Pedro Miguel Ribeiro Silva