



CATOLICA
FACULDADE DE MEDICINA DENTÁRIA

UISEU

**SEGMENTAÇÃO TRIDIMENSIONAL DO
CANAL MANDIBULAR COM INTELIGÊNCIA
ARTIFICIAL
- estudo experimental -**

Dissertação apresentada à Universidade Católica Portuguesa
para obtenção do grau de Mestre em Medicina Dentária

Vitalie Rosca

Viseu, 2025



CATOLICA
FACULDADE DE MEDICINA DENTÁRIA

UIP
VISEU

**SEGMENTAÇÃO TRIDIMENSIONAL DO
CANAL MANDIBULAR COM INTELIGÊNCIA
ARTIFICIAL**

- estudo experimental -

Dissertação apresentada à Universidade Católica Portuguesa
para obtenção do grau de Mestre em Medicina Dentária

Vitalie Rosca

Orientador: Prof. Doutor André Correia

Coorientadora: Prof^a. Doutora Catarina Fonseca

Viseu, 2025

Membros do Júri das Provas Públicas

Presidente: Doutora Raquel Monteiro Marques da Silva, Professora Associada da Faculdade de Medicina Dentária do Centro Regional de Viseu da Universidade Católica Portuguesa.

Arguente: Doutora Patrícia Alexandra Barroso da Fonseca, Professora Auxiliar da Faculdade de Medicina Dentária do Centro Regional de Viseu da Universidade Católica Portuguesa.

Orientador: Doutor André Ricardo Maia Correia, Professor Associado da Faculdade de Medicina Dentária do Centro Regional de Viseu da Universidade Católica Portuguesa.

Data das provas públicas: 09/07/2025

Classificação: 16 valores

“Sem querer crer as coisas vão ao sítio, deixamos de tentar controlar
e a vida surpreende com os seus próprios arranjos, tudo que tens de fazer,
é tentar mais uma vez”

--Vitalie Rosca

DEDICATÓRIA

Aos meus **Pais**,
Por tudo o que são para mim,
Por tudo o que fizeram e continuam a fazer,
Pelo que me deram sem pedir nada em troca,
E por cada oportunidade que me permitiu chegar até aqui,
Com **eterna gratidão**.

AGRADECIMENTOS

Ao meu orientador, **Prof. Doutor André Correia**, pela forma próxima, exigente e sempre disponível com que me guiou. Aprendi muito consigo, não só sobre o tema deste trabalho, mas também sobre dedicação e profissionalismo. Muito obrigado por tudo, Professor!

À minha coorientadora, **Prof^a. Doutora Catarina Fonseca**, pela ajuda constante, pelo valioso conhecimento e experiência partilhados e pela incansável disponibilidade ao longo de todo este percurso. A sua presença foi fundamental. Muito obrigada, Professora!

Ao **Prof. Doutor Tiago Marques**, por toda a ajuda ao longo do caminho, pelos “desenrasques”, pela paciência em explicar os programas e como tudo funcionava e pela constante disponibilidade. Agradeço sinceramente por tudo, Professor!

À **Prof^a. Doutora Joana Fialho**, pela colaboração fundamental na análise estatística deste estudo e pela sua disponibilidade e prontidão em ajudar. Muito obrigado, Professora!

A todos os **docentes** e ao **peçoal auxiliar**, pelo contributo ao longo da minha formação, pela dedicação, profissionalismo e palavras de incentivo que marcaram este percurso. A todos, o meu sincero agradecimento!

A todos os **colegas** que me ajudaram a fazer esta investigação, em especial ao Hélio, à Mariana e à Maria Garcia, pelo apoio e pela colaboração demonstrada ao longo deste trabalho.

À minha **família**, pelo amor incondicional, pelo apoio constante e por estarem sempre presentes nos momentos mais desafiantes. Ao meu **irmão** e à minha **irmã**, pelo companheirismo, pelas palavras de incentivo e por nunca me deixarem esquecer o que realmente importa. E, por fim à minha **namorada**, pelo carinho, pela paciência e por me acompanhar de perto em cada etapa deste percurso, foste essencial.

A **todos**, o meu mais sincero obrigado.

RESUMO

Introdução: a identificação do canal mandibular é essencial para o planeamento seguro de procedimentos cirúrgicos em implantologia. A Inteligência Artificial (IA) tem sido proposta como ferramenta de apoio para a segmentação anatómica automatizada, mas a sua precisão requer validação.

Objetivo: avaliar a precisão da segmentação tridimensional do canal mandibular por IA, comparando-a com a segmentação manual realizada por médicos dentistas júnior (MDJ) e com uma referência traçada por um operador experiente (*gold standard* – GS).

Materiais e Métodos: foram analisados 10 exames de tomografia computadorizada de feixe cónico (CBCT). Cada exame foi segmentado manualmente por três MDJ, automaticamente por IA e por um operador sénior (GS). As segmentações foram convertidas em modelos STL e comparadas no *software Geomagic Control X*, através da métrica *Root Mean Square* (RMS). Os dados foram analisados estatisticamente com ANOVA e testes *post hoc* utilizando o programa SPSS, versão 28 (IBM Corp.), com um nível de significância de $\alpha = 0,05$.

Resultados: a IA obteve valores médios de RMS inferiores aos das segmentações manuais em ambos os lados da mandíbula (direito: 0,7623; esquerdo: 0,8658), apresentando menor variabilidade (desvio padrão reduzido). Houve diferenças estatisticamente significativas entre as segmentações manuais e a IA ($p < 0,001$), e entre os diferentes operadores humanos.

Conclusão: a IA demonstrou maior precisão e consistência na segmentação do canal mandibular em comparação com os MDJ, aproximando-se mais da segmentação de referência (GS). A IA pode representar uma ferramenta clínica fiável no planeamento de cirurgia de colocação de implantes, promovendo padronização e segurança.

Palavras-chave: inteligência artificial, canal mandibular, nervo alveolar inferior, tomografia computadorizada de feixe cónico.

ABSTRACT

Introduction: identification of the mandibular canal is critical for safe surgical planning in implant dentistry. Artificial Intelligence (AI) has been proposed as a tool for automated anatomical segmentation, but its accuracy requires validation.

Objective: to evaluate the accuracy of three-dimensional mandibular canal segmentation using AI, compared with manual segmentation by junior dentists (JD) and a reference drawn by an experienced operator (gold standard – GS).

Materials and Methods: ten cone-beam computed tomography (CBCT) scans were analyzed. Each scan was segmented manually by three junior dentists (JD), automatically by artificial intelligence (AI), and by a senior operator (gold standard – GS). The segmentations were converted into STL models and compared using Geomagic Control X software, based on the Root Mean Square (RMS) metric. Statistical analysis was performed using ANOVA and post hoc tests in SPSS software, version 28 (IBM Corp.), with a significance level of $\alpha = 0.05$.

Results: AI segmentation showed lower mean RMS values than manual segmentations on both mandibular sides (right: 0.7623; left: 0.8658) and demonstrated lower variability (reduced standard deviation). Statistically significant differences were found between AI and manual methods ($p < 0.001$), and among human operators.

Conclusion: AI demonstrated higher precision and consistency in mandibular canal segmentation compared to JD, being closer to the reference (GS). AI may serve as a reliable clinical tool in implant planning, enhancing standardization and safety.

Keywords: artificial intelligence, mandibular canal, inferior alveolar nerve, cone-beam computed tomography

ÍNDICE

1	INTRODUÇÃO	1
1.1	ANATOMIA MANDIBULAR	3
1.2	A IMPORTÂNCIA DA IDENTIFICAÇÃO DO CANAL MANDIBULAR EM MEDICINA DENTÁRIA	4
1.3	EXAMES COMPLEMENTARES PARA IDENTIFICAÇÃO DO CANAL MANDIBULAR	6
1.3.1	TOMOGRAFIA COMPUTADORIZADA DE FEIXE CÔNICO (CBCT).....	8
1.4	SOFTWARES DE PLANEAMENTO DE IMPLANTES.....	9
1.4.1	IA NA SEGMENTAÇÃO DO CANAL MANDIBULAR	11
1.5	JUSTIFICAÇÃO, OBJETIVOS E HIPÓTESES NULAS.....	13
2	MATERIAIS E MÉTODOS	15
2.1	DESENHO DE ESTUDO E AMOSTRA	17
2.2	AQUISIÇÃO DE DADOS	17
2.3	DESENHO DO ESTUDO	18
2.4	PROCEDIMENTOS DE SEGMENTAÇÃO	18
2.5	ANÁLISE DOS DADOS RECOLHIDOS	20
2.6	ANÁLISE ESTATÍSTICA	21
3	RESULTADOS	23
3.1	NERVO ALVEOLAR INFERIOR DIREITO	25
3.1.1	ESTATÍSTICA DESCRITIVA – SM AGRUPADOS	27
3.1.2	ANÁLISE INFERENCIAL – SM AGRUPADOS.....	28
3.1.3	ESTATÍSTICA INFERENCIAL – SM EM SEPARADO	29
3.1.4	ANÁLISE INFERENCIAL – SM EM SEPARADO	30
3.2	NERVO ALVEOLAR INFERIOR ESQUERDO	31
3.2.1	ESTATÍSTICA DESCRITIVA – SM AGRUPADOS	33
3.2.2	ANÁLISE INFERENCIAL – SM AGRUPADOS.....	34
3.2.3	ESTATÍSTICA INFERENCIAL – SM EM SEPARADO	35
3.2.4	ANÁLISE INFERENCIAL – SM EM SEPARADO	36
4	DISCUSSÃO	39
4.1	LIMITAÇÕES DO ESTUDO	45
4.2	PERSPETIVAS FUTURAS	46
5	CONCLUSÃO	49
6	BIBLIOGRAFIA	52

Lista de abreviaturas, siglas e acrónimos

FMD-UCP – Faculdade de Medicina Dentária da Universidade Católica Portuguesa

IA – Inteligência Artificial

MDJ – Médicos Dentistas Júnior

GS – *Gold Standard*

CBCT – Tomografia Computorizada de Feixe Cónico.

STL – *Standard Tessellation Language*

RMS – *Root Mean Square*

NAI – Nervo Alveolar Inferior

2D – Bidimensionais

3D – Tridimensionais

TC – Tomografia Computadorizada

DICOM – *Digital Imaging and Communications in Medicine*

CNNs – *Convolutional Neural Networks* (Redes Neurais Convolucionais)

1 INTRODUÇÃO

1.1 Anatomia mandibular

A mandíbula é o maior osso e o único osso móvel do crânio humano, possuindo uma estrutura complexa e de importância fundamental. É constituída pelo corpo da mandíbula, em forma de “U” ou ferradura, projetado no sentido ântero-posterior, terminando em ângulos gónicos bilaterais nas suas extremidades posteriores. A partir destes ângulos, os ramos da mandíbula estendem-se verticalmente em direção à articulação. Esta articulação, denominada articulação temporomandibular, é bilateral e permite uma ampla gama de movimentos, facilitados pelos músculos adjacentes. Entre as suas funções principais, destaca-se a oclusão dentária com a maxila. Em conjunto, mandíbula e maxila permite a abertura da cavidade oral, sendo a sua sincronização essencial para funções vitais como a fala, a mastigação e a execução de diversas expressões faciais.^(1, 2)

O corpo da mandíbula integra o processo alveolar, que constitui a porção mais superior desta estrutura. Este processo aloja os dentes e curva-se superior e medialmente em direção à linha média. Posteriormente à dentição, o processo alveolar afunila-se na região do triângulo retromolar, fundindo-se com a face lingual do ramo mandibular para formar a crista temporal. Na face bucal ao processo alveolar, a porção anterior do processo coronoide une-se ao corpo da mandíbula, originando a linha oblíqua. Entre a crista temporal e a linha oblíqua localiza-se a fossa retromolar. Na superfície interna, ou lingual, da mandíbula, destaca-se a linha milo-hioideia, uma crista óssea que serve de ponto de inserção para o músculo milo-hioideu. Abaixo desta linha encontra-se a fossa submandibular, uma concavidade onde se localiza a glândula submandibular. Por sua vez, superiormente à linha milo-hioideia, a glândula sublingual assenta numa concavidade de menor dimensão, designada por fossa sublingual.⁽³⁾

O canal mandibular é um canal ósseo situado na porção esponjosa da mandíbula. Este percorre de forma oblíqua, um trajeto descendente e anterior ao longo do ramo mandibular, continuando depois horizontalmente para a frente, no corpo da mandíbula, geralmente próximo dos ápices das raízes dos molares. O canal tem início no foramen mandibular, localizado na face lingual do ramo

mandibular, e termina no foramen mentoniano, situado na face vestibular do corpo mandibular, entre as regiões do canino e dos pré-molares. Na sua extremidade anterior, o canal estende-se para além do foramen mentoniano e curva-se posteriormente, formando a chamada alça anterior, um reflexo da morfologia característica deste canal. Ao longo do seu percurso, o canal acompanha a placa cortical lingual, situado no terço inferior do corpo mandibular. No final do trajeto, divide-se em dois ramos: o canal mentoniano e o canal incisivo. O canal mentoniano curva-se posteriormente, superiormente e lateralmente, emergindo através do foramen mentoniano; já o canal incisivo prossegue em direção aos dentes incisivos. Anatomicamente, o canal mandibular apresenta margens corticais parcialmente ossificadas, o que dificulta a sua diferenciação em relação às estruturas adjacentes nas imagens radiográficas.⁽⁴⁻⁶⁾

1.2 A importância da identificação do canal mandibular em Medicina Dentária

A correta identificação e localização do canal mandibular reveste-se de extrema importância em Medicina Dentária, especialmente no âmbito de cirurgias e tratamentos que envolvem a região mandibular.

Em condições normais, a mandíbula humana possui um único canal mandibular de cada lado, apresentando-se bilateralmente, estendendo-se desde o foramen mandibular até ao foramen mentoniano.^(5, 7) No interior deste canal encontram-se os componentes do feixe neurovascular alveolar inferior, responsável pelo fornecimento de sensibilidade e irrigação sanguínea da mandíbula. Estes componentes estão dispostos, da posição superior para a inferior, da seguinte forma: veia, artéria e nervo.

O nervo alveolar inferior (NAI) é um ramo do nervo mandibular, a terceira divisão do nervo trigémeo. Este nervo inerva os molares e pré-molares inferiores, bem como as áreas gengivais adjacentes. O seu prolongamento anterior, o ramo incisivo, estende-se até aos dentes caninos e incisivos. O nervo mentoniano, por sua vez, é o maior ramo terminal do NAI, emergindo pelo foramen mentoniano

para inervar a pele da região mentoniana. Os restantes ramos distribuem-se pela pele do lábio inferior, mucosa e gengiva, alcançando a zona posterior do segundo pré-molar.^(6, 7)

O canal mandibular pode apresentar variações anatómicas significativas entre indivíduos. Uma das variações mais comuns é a presença de um canal bífido ou canal duplo, em que o canal principal se divide em dois ramos distintos, ambos transportando o NAI. Esta bifurcação pode ser completa ou parcial, dificultando a administração eficaz da anestesia local e aumentando o risco de lesões nervosas durante procedimentos cirúrgicos. A bifurcação ocorre com maior frequência na região dos molares, embora possa surgir em qualquer ponto do trajeto do canal. Em situações mais raras, observa-se a presença de um canal trifido, com três ramos derivados do canal principal.^(8, 9)

Outra variação anatómica relevante é o canal retromolar, que representa uma ramificação do canal mandibular direcionada para a região retromolar, nas proximidades dos molares inferiores. A presença deste canal pode dificultar procedimentos como extrações ou colocação de implantes na região posterior da mandíbula, especialmente devido à proximidade com o NAI, podendo originar complicações como dor ou parestesia. Estas variações são geralmente atribuídas a anomalias no processo de fusão dos nervos que constituem o NAI durante o desenvolvimento embrionário.^(8, 9)

O NAI é uma estrutura de elevada relevância clínica, que deve ser cuidadosamente considerada em procedimentos dentários realizados a jusante do foramen mentoniano. A sua proximidade com os ápices radiculares dos dentes posteriores inferiores aumenta o risco de lesão durante intervenções como tratamentos endodônticos, extrações (particularmente dos terceiros molares), cirurgias periapicais, ortognáticas e a colocação de implantes. Lesões neste nervo podem originar dor neuropática e perda sensorial parcial ou total na região mentoniana.^(5, 6, 10)

As complicações intraoperatórias mais frequentes nestes contextos são os acidentes hemorrágicos. Contudo, também se registam distúrbios sensoriais

associados a lesões do NAI, quer por trauma direto, quer por compressão secundária a hematomas resultantes de hemorragia da artéria alveolar inferior. De salientar que, na maioria dos casos, a artéria localiza-se medial em relação à veia, e o NAI encontra-se inferior aos vasos alveolares inferiores. Assim, a parestesia transitória pode ser consequência da compressão nervosa por um hematoma. Embora, na maioria das situações, a parestesia dos lábios e da gengiva regrida com o tempo, em casos mais graves pode tornar-se irreversível.^(5, 6, 10)

A colocação de implantes dentários, frequentemente motivada por razões estéticas e funcionais, reforça a importância de uma identificação rigorosa do canal mandibular, de forma a evitar danos no NAI. Um conhecimento aprofundado da anatomia do canal mandibular e das suas variações é essencial durante cirurgias dentárias, particularmente na implantologia.⁽⁷⁾

Nesta área, a proximidade do NAI às zonas de colocação de implantes exige a utilização de exames de imagem de elevada precisão, como a tomografia computadorizada de feixe cónico (CBCT). Este tipo de exame permite minimizar os riscos e melhorar os resultados clínicos, através da adoção de estratégias cirúrgicas mais seguras e eficazes.^(3, 6, 11)

1.3 Exames complementares para identificação do canal mandibular

A descoberta dos raios X por Wilhelm Conrad Roentgen, em 1895, marcou um avanço crucial na história da Medicina, tendo rapidamente sido aplicada à Medicina Dentária, onde permitiu a observação não invasiva das estruturas internas da cavidade oral e maxilofacial.⁽¹²⁾ Desde então, a imagiologia tem evoluído significativamente, disponibilizando atualmente um conjunto de exames complementares essenciais para a identificação e avaliação do canal mandibular, nomeadamente técnicas bidimensionais (2D) e tridimensionais (3D).⁽¹³⁾

As técnicas 2D incluem a radiografia intraoral, a cefalométrica e, sobretudo, a radiografia panorâmica ou ortopantomografia. Já as técnicas 3D compreendem

a tomografia computadorizada (TC) e, mais recentemente, a tomografia computadorizada de feixe cônico (CBCT). A ortopantomografia e a CBCT têm sido particularmente relevantes na identificação do canal mandibular, bem como no diagnóstico, planeamento e monitorização de procedimentos cirúrgicos e reabilitadores, como a colocação de implantes.^(13, 14)

A radiografia panorâmica, desenvolvida por Yrjö Paatero na década de 1950 e popularizada internacionalmente na década de 1960, revelou-se uma ferramenta particularmente útil ao permitir a visualização integral da mandíbula. A sua ampla adoção deve-se à simplicidade do exame, baixo custo, acessibilidade e reduzida exposição à radiação. O seu contributo para a Medicina Dentária tem sido relevante, nomeadamente no rastreio de lesões, avaliação de dentes inclusos, fraturas mandibulares e planeamento de extrações dentárias.⁽¹⁵⁻¹⁷⁾

Nas últimas décadas, a transição da radiografia panorâmica baseada em filme para a versão digital trouxe inúmeras vantagens, como a aquisição de imagem em tempo real, eliminação de processos químicos de revelação, redução da dose de radiação e a possibilidade de manipulação digital da imagem para melhor definição de contraste e nitidez. No entanto, esta técnica apresenta limitações, como a sobreposição de estruturas anatómicas e distorções geométricas que podem comprometer a precisão diagnóstica em determinadas situações clínicas.⁽¹⁵⁻¹⁷⁾

A tomografia computadorizada de feixe cônico (CBCT) veio superar muitas dessas limitações ao permitir a obtenção de imagens tridimensionais com elevada resolução espacial. Este exame adquire múltiplas projeções radiográficas através de um feixe cônico de raios X que gira em torno do paciente, produzindo um conjunto de dados volumétricos que podem ser reconstruídos nos planos axial, sagital e coronal. Esta capacidade de visualização multiplanar permite uma análise detalhada da morfologia óssea, da posição do canal mandibular e da sua relação com as estruturas dentárias adjacentes.⁽¹⁵⁻¹⁷⁾

O CBCT apresenta-se como uma técnica imagiológica particularmente adequada para a avaliação da região craniofacial, oferecendo imagens de elevada nitidez das estruturas ósseas. Além disso, uma das suas principais vantagens reside no facto de as imagens serem já corrigidas para ampliação, o que permite a obtenção de medições altamente precisas. Desta forma, o CBCT surge como um exame complementar que potencia a eficácia da radiografia panorâmica, assumindo-se como uma ferramenta de grande valor no diagnóstico, identificação e planeamento de intervenções em Medicina Dentária.⁽¹⁵⁻¹⁷⁾

Em suma, a evolução das técnicas de imagiologia tem permitido uma abordagem mais segura, precisa e personalizada na prática clínica em Medicina Dentária, sendo a escolha do exame dependente da complexidade do caso, da área anatómica em estudo e do tipo de intervenção planeada. A correta interpretação destes exames, aliada ao conhecimento anatómico aprofundado, constitui uma ferramenta imprescindível para o sucesso dos procedimentos clínicos e para a minimização de riscos ao paciente.

1.3.1 Tomografia computadorizada de feixe cónico (CBCT)

A tomografia computadorizada de feixe cónico (CBCT) tem vindo a assumir um papel cada vez mais central na imagiologia aplicada à Medicina Dentária, impulsionada tanto pelo avanço tecnológico como pelo aumento da oferta de equipamentos por parte dos fabricantes. Esta técnica imagiológica tridimensional tem sido amplamente adotada para o planeamento cirúrgico de implantes dentários, bem como para a identificação de patologias, análise da morfologia e disponibilidade óssea, e mapeamento de estruturas anatómicas relevantes.⁽¹⁸⁾

O CBCT permite ao clínico visualizar o canal mandibular com maior precisão e fiabilidade, graças à sua capacidade de produzir imagens tridimensionais de elevada resolução. Radiograficamente, o canal mandibular apresenta-se como uma estrutura radiolúcida, frequentemente delimitada por bordos corticais radiopacos bem definidos. A visibilidade do canal é, no entanto, influenciada por diversos fatores, como a idade do paciente, a região anatómica

da mandíbula, e eventuais alterações patológicas ou cirúrgicas. Em cortes coronais, o canal surge como um pequeno círculo, diferenciável da medula óssea trabecular circundante pela presença de uma linha radiopaca, a parede cortical do canal mandibular.^(11, 13, 16, 19)

A identificação clara do canal mandibular e das suas estruturas associadas é imprescindível para o planeamento seguro de procedimentos dentários invasivos, como extrações, colocação de implantes e tratamentos ortodônticos. Variações anatómicas do canal, assim como alterações provocadas por lesões inflamatórias, infecciosas, neoplásicas, iatrogénicas ou idiopáticas, podem colocar em risco o NAI e resultar em complicações neurossensitivas graves, como parestesia ou dor neuropática. Deste modo, a CBCT destaca-se como o exame imagiológico de eleição para a avaliação precisa do canal mandibular.^(11, 18)

No contexto de prevenção de danos ao NAI durante a colocação de implantes, têm sido sugeridas várias diretrizes. Por exemplo, optar por anestesia infiltrativa local em vez de bloqueios nervosos ou anestesia geral permite ao paciente perceber precocemente qualquer sintoma indicativo de lesão nervosa. Além disso, recomenda-se a incorporação de uma zona de segurança entre o trajeto do nervo e o local de inserção do implante. Esta margem de segurança deve ser, idealmente, de 1 a 2 mm, podendo atingir até 6 mm na região anterior à emergência do foramen mentoniano. A consideração do fator de ampliação da imagem é igualmente fundamental para compensar as limitações inerentes às radiografias bidimensionais e garantir a precisão na medição das distâncias.⁽¹⁶⁾

1.4 Softwares de planeamento de implantes

O planeamento adequado da colocação de implantes dentários é um fator determinante para a segurança e sucesso do tratamento. A avaliação minuciosa das estruturas anatómicas, nomeadamente do canal mandibular e do nervo alveolar inferior (NAI), é essencial para evitar lesões neurossensitivas e outras complicações. Uma abordagem cuidadosa nesta fase permite não só preservar

a integridade das estruturas neurovasculares, como também otimizar os resultados clínicos e melhorar significativamente a experiência do paciente.

Nas últimas décadas, o desenvolvimento de *softwares* de planeamento de cirurgia de colocação de implantes, assistido por computador, aliado aos avanços em inteligência artificial (IA), tem revolucionado o campo da implantologia. Estas ferramentas digitais têm vindo a tornar os procedimentos mais precisos, eficientes e previsíveis, reduzindo erros humanos e promovendo uma prática clínica mais segura e personalizada.⁽²⁰⁻²²⁾

O planeamento digital acelerou e aperfeiçoou as etapas envolvidas na reabilitação oral com implantes. Este fluxo de trabalho requer a obtenção de dados anatómicos detalhados tanto dos tecidos duros como dos tecidos moles da cavidade oral, frequentemente adquiridos através de exames de tomografia computadorizada de feixe cónico (CBCT). As imagens geradas são normalmente armazenadas em formato DICOM, o qual pode ser convertido para o formato STL por meio de softwares de modelação 3D. Esta conversão é fundamental para a integração com outros dados obtidos por scanners intraorais, permitindo a sobreposição precisa de imagens (integração dos ficheiros DICOM e STL).⁽²⁰⁻²²⁾

Estes softwares desempenham um papel central na integração dos dados imagiológicos, no planeamento do tratamento e no desenho de guias cirúrgicas personalizadas. Permitem, por exemplo, a segmentação anatómica detalhada do NAI e outras estruturas relevantes, possibilitando uma abordagem cirúrgica mais segura. Após a importação, segmentação e registo dos dados, procede-se ao planeamento da posição virtual dos implantes, com base nas exigências da reabilitação protética. Esta configuração protética ideal considera a posição desejada da prótese implanto-suportada, o perfil de emergência do pilar protético, a morfologia dentária, bem como os contactos oclusais e proximais.⁽²⁰⁻²²⁾

Com estas informações, os implantes podem ser posicionados virtualmente sobre cortes transversais e modelos tridimensionais reconstruídos a partir das

imagens CBCT, garantindo uma correspondência anatômica e funcional precisas. Entre as inovações mais relevantes no campo da imagiologia dentária destaca-se a utilização da inteligência artificial (IA) para a segmentação automatizada do canal mandibular, uma funcionalidade cada vez mais integrada nos *softwares* modernos de planeamento, que facilita significativamente a visualização e a tomada de decisões clínicas.⁽²⁰⁻²²⁾

1.4.1 IA na segmentação do canal mandibular

A segmentação do canal mandibular consiste no processo de identificação e delineamento desta estrutura em imagens obtidas por tomografia, nomeadamente por tomografia computadorizada convencional (CT) ou tomografia computadorizada de feixe cónico (CBCT). A segmentação precisa do canal é essencial para a prática clínica, dado que o seu trajeto aloja o nervo alveolar inferior (NAI), responsável pela inervação sensitiva da mandíbula, dentes inferiores, lábio inferior e tecidos moles adjacentes. A integridade desta estrutura deve ser preservada durante procedimentos cirúrgicos e reabilitadores para evitar complicações neurossensitivas.^(23, 24)

Nos últimos anos, a inteligência artificial (IA), com especial destaque para os algoritmos de aprendizagem automática (*machine learning*) e aprendizagem profunda (*deep learning*), tem-se afirmado como uma ferramenta poderosa para a segmentação automática ou semiautomática do canal mandibular. Estes algoritmos são capazes de analisar grandes volumes de dados imagiológicos com rapidez e elevada precisão, executando tarefas que, tradicionalmente, exigiriam tempo e intervenção manual por parte de profissionais especializados. A segmentação automática por IA baseia-se no treino de modelos de *deep learning* para identificar com exatidão a morfologia do canal mandibular em imagens de CBCT. Este processo de treino é suportado por conjuntos de dados anotados, imagens tomográficas de alta resolução em que o canal mandibular foi previamente segmentado manualmente por especialistas. Através desta informação, os modelos aprendem a reconhecer padrões imagiológicos associados à anatomia do canal, tornando-se, posteriormente, capazes de

realizar segmentações em novas imagens, de forma autónoma. Os algoritmos de segmentação mais utilizados neste contexto baseiam-se em redes neuronais convolucionais (CNNs), uma classe de algoritmos de *deep learning* particularmente eficazes na análise de imagens médicas. As CNNs são capazes de identificar, com elevada precisão, os limites anatómicos do canal mandibular, mesmo em casos com variações morfológicas significativas, presença de artefactos ou qualidade de imagem comprometida. A integração da IA na Medicina Dentária representa um avanço notável em termos de precisão diagnóstica, segurança clínica e eficiência operacional. Para além de permitir uma segmentação mais fiável do canal mandibular, a IA contribui para a redução do erro humano, a automatização de tarefas repetitivas e a melhoria do fluxo de trabalho clínico, permitindo que os profissionais se concentrem em decisões terapêuticas mais estratégicas. A aplicação de IA neste domínio não só potencia melhores resultados clínicos, como também representa uma evolução promissora na personalização dos cuidados de saúde oral.^(13, 19, 22, 25-33)

Apesar dos avanços promissores, os sistemas de segmentação por IA ainda necessitam de validação científica robusta e padronizada. Estudos multicêntricos, com grandes amostras e heterogeneidade anatómica, são necessários para garantir a fiabilidade dos algoritmos antes da sua integração em protocolos clínicos de rotina. Questões éticas e regulamentares também devem ser consideradas, nomeadamente quanto à transparência dos modelos e à supervisão humana obrigatória na interpretação dos resultados.⁽²⁹⁻³¹⁾

1.5 Justificação, objetivos e hipóteses nulas

A identificação precisa do nervo alveolar inferior (NAI) em contexto de implantologia assume um papel crucial na prevenção de complicações intraoperatórias e na salvaguarda da integridade neurossensitiva do paciente. A sua estreita proximidade com as zonas frequentemente envolvidas na colocação de implantes dentários impõe a necessidade de uma avaliação anatómica rigorosa e personalizada. A inexistência de um planeamento adequado pode resultar em lesões iatrogénicas do NAI, associadas a consequências clínicas como parestesia, dor neuropática e insucesso do tratamento reabilitador.

Dada esta realidade, torna-se essencial explorar e validar novas abordagens tecnológicas que melhorem a eficiência, a precisão e a segurança dos procedimentos clínicos. Entre estas, destaca-se a segmentação tridimensional do canal mandibular assistida por inteligência artificial (IA), que tem demonstrado elevado potencial na automatização e melhoria da qualidade da análise imagiológica. A utilização de algoritmos de IA pode reduzir o tempo necessário para o planeamento cirúrgico e minimizar a variabilidade interindividual, contribuindo para um diagnóstico mais padronizado e fiável.

Assim, o presente estudo visa investigar o desempenho da segmentação 3D do canal mandibular por IA e compará-lo com o traçado manual convencional, recorrendo a um *software* específico de planeamento de implantes. Esta comparação permitirá avaliar a viabilidade da integração da IA no planeamento clínico corrente.

O objetivo principal do presente estudo é:

- Avaliar a precisão da segmentação tridimensional do canal mandibular por inteligência artificial (IA), em imagens radiográficas obtidas por CBCT, comparando-a com a segmentação manual convencional, realizada num *software* de planeamento de implantes.

Como objetivos secundários foram definidos os seguintes:

- Analisar a influência do nível de experiência do operador na execução do traçado do canal mandibular.
- Explorar o potencial da IA para reduzir a variabilidade na segmentação entre operadores com diferentes graus de experiência.

Perante os objetivos enunciados, foram então definidas as seguintes hipóteses nulas:

- H_0 (1): Não existe diferença significativa na precisão da segmentação do canal mandibular entre o traçado manual e os algoritmos de segmentação baseados em IA.
- H_0 (2): Não existe diferença significativa na precisão do traçado do canal mandibular entre médicos dentistas com diferentes níveis de experiência.

2 MATERIAIS E MÉTODOS

2.1 Desenho de Estudo e Amostra

O presente estudo experimental, foi desenvolvido na Faculdade de Medicina Dentária da Universidade Católica Portuguesa de Viseu (FMD-UCP).

A amostra foi constituída por 10 CBCTs de pacientes da clínica dentária universitária (já incluídos na base de dados do *software* imagiológico disponível na instituição), e seleccionados de forma aleatória. Foram utilizados os seguintes critérios de inclusão/exclusão para a referida seleção.

Crítérios de inclusão: presença de imagens tomográficas de uma mandíbula completa, desde o buraco mandibular até à protuberância mentoniana no sentido postero-anterior e bilateral.

Crítérios de exclusão: exames imagiológicos que contenham artefactos radiológicos / ruído significativos e patologias que afetem o trajeto do canal mandibular bilateralmente.

Os ficheiros dos exames imagiológicos seleccionados foram descarregados e guardados em formato *Digital Imaging and Communications in Medicine* (DICOM), resolução original 0,40mm e *bit depth* 12.

Estes dados foram recolhidos pelo orientador (investigador responsável do projeto “Aplicação de tecnologias digitais na reabilitação oral”, aprovado pelo CES como projeto n.º 201, e integrado na plataforma de investigação “Precision Dental Medicine” do Centro de Investigação Interdisciplinar em Saúde) e cedidos de forma anonimizada ao autor deste trabalho.

2.2 Aquisição de dados

Todos os exames CBCT foram realizados, no mesmo equipamento (Planmeca ProMax 3D Classic) com parâmetros padronizados (60-90 kV, 1-14 mAs, 9-37 s, FOV 8 ou 11 × 8 cm.).

Os dados CBCT foram guardados como arquivo DICOM e, posteriormente, importados para um *software* de planeamento de cirurgia de colocação de

implantes *coDiagnostiX*, 10.6, *Dental Wings* (Institut Straumann AG, Switzerland). Antes de serem importados para o *software* de planeamento, os dados imagiológicos não foram processados.

2.3 Desenho do Estudo

Os CBCT foram avaliados por três grupos de estudo:

1. **Grupo Controlo (GC / Gold Standard / GS):** que compreende um médico dentista “sénior” (MDS), com 5 a 10 anos de experiência em interpretação de CBCT e uso do *software coDiagnostiX®* (Institut Straumann AG, Switzerland);
2. **Grupo Segmentação Manual (GSM):** que é composto por três médicos dentistas recém pós-graduados ou em pós-graduação na FMD-UCP (médico dentista “júnior” – MDJ) e com compreensão e treino básico no *software coDiagnostiX®* (Institut Straumann AG, Switzerland);
3. **Grupo Segmentação IA (SAI):** que inclui os mesmos três médicos dentistas do Grupo Segmentação Manual.

2.4 Procedimentos de Segmentação

Para a avaliação da segmentação do NAI, foram aplicados três métodos distintos: inicialmente, o MDS (ou GS) do Grupo Controlo realizou a segmentação manual do nervo alveolar inferior bilateralmente, no *software coDiagnostiX®* (Institut Straumann AG, Switzerland), em todos os 10 exames com o diâmetro de traçado preferido. Em seguida, cada um dos três MDJ do Grupo Segmentação Manual realizou a segmentação manual do nervo alveolar inferior bilateralmente nos mesmos exames imagiológicos, sem utilizar a ferramenta de IA. Posteriormente, o Grupo Segmentação IA, que é constituído pelos mesmos MDJ, realizou a segmentação do nervo alveolar inferior bilateralmente nos mesmos exames que segmentaram manualmente, mas desta vez utilizando a ferramenta de IA do *software* acima mencionado.




Imagem 1: exemplo de segmentação manual do canal mandibular




Imagem 2: utilização da ferramenta de IA para segmentação das estruturas anatômicas




Imagem 3: revisão da segmentação automática por IA




Imagem4: segmentação automática em modelo 3D

2.5 Análise dos dados recolhidos

Para cada um dos métodos de segmentação avaliados serão exportados dois arquivos STL (*Standard Tessellation Language* - STL) por CBCT: um para o canal mandibular direito e um para o canal esquerdo da mandíbula, preservando as coordenadas originais / iniciais.⁽⁷⁾




Imagem 5: exportação dos arquivos STL

A comparação tridimensional entre as diferentes segmentações (manual, por inteligência artificial e a segmentação de referência realizada pelo médico sénior, considerada como padrão ouro) foi realizada no *software* de metrologia *Geomagic Control X* (v.2023). A avaliação das diferenças foi efetuada com base na sobreposição volumétrica global dos modelos e no cálculo do *Root Mean Square* (RMS), permitindo quantificar as discrepâncias entre os métodos de segmentação.⁽⁷⁾




Imagem 6: comparação 3D entre as segmentações

As tabelas foram construídas no *software* Microsoft Excel® (Microsoft Corp., Redmond, WA, USA) a partir dos dados obtidos nas comparações tridimensionais realizadas no *Geomagic Control X* (v.2023). Posteriormente, os dados foram importados para o programa SPSS, versão 28 (IBM Corp.) para análise estatística descritiva e inferencial do NAI Direito e Esquerdo.

2.6 Análise Estatística

A análise estatística foi conduzida considerando a distribuição dos dados. Inicialmente, a normalidade foi verificada por meio do teste *Shapiro-Wilk*. Em função dos resultados, foram aplicados métodos estatísticos paramétricos para os dados com uma distribuição normal, e não paramétricos para os dados que não apresentavam distribuição normal.

Para os dados com distribuição normal, utilizou-se análise de variância (ANOVA) para identificar possíveis diferenças globais entre os grupos. Quando a ANOVA indicou significância estatística, foram realizadas análises *post hoc* por meio de comparação múltiplas par a par (*pairwise*), utilizando o teste de *Scheffé*, adequado para controlar o erro tipo I (falsos positivos) em múltiplas comparações.

Nos casos em que os dados não apresentavam distribuição normal, foi aplicado o teste de *Kruskal-Wallis* como alternativa não paramétrica à *ANOVA*. Havendo significância nesse teste global, realizaram-se comparações *post hoc* par a par (*pairwise*), com aplicação da correção de *Bonferroni* para ajuste do nível de significância.

O nível de significância adotado para os testes globais foi de $\alpha = 0,05$. Todas as análises estatísticas foram realizadas utilizando o *software* SPSS, versão 28 (IBM Corp.).

3 RESULTADOS

Os resultados a seguir apresentados foram divididos entre o nervo alveolar inferior direito e no nervo alveolar inferior esquerdo, para mais fácil compreensão.

Na tabela 1 estão descritas as siglas que ajudam a compreender as tabelas apresentadas nesta secção.

Tabela 1: Descrição das siglas

Descrição
NAI = Nervo Alveolar Inferior (direito ou esquerdo)
RMS = <i>Root Mean Square</i>
10 casos clínicos = linhas de 1 a 10
G = Operador de nome "G."
H = Operador de nome "H."
L = Operador de nome "L."
AI = inteligência artificial
GS = <i>Gold Standard</i>
SM = Segmentação Manual

3.1 Nervo Alveolar Inferior Direito

Os resultados da sobreposição volumétrica entre os grupos Segmentação “AI” e o “GS” estão descritos na Tabela 2.

Tabela 2 - Comparação entre Grupo Segmentação AI e Gold Standard – NAI direito

Caso Clínico (NAI direito)	RMS (AI vs GS)
1	0,9777
2	0,4692
3	0,8134
4	0,9370
5	0,8352
6	0,6022
7	0,6380
8	0,6763
9	0,9447
10	0,7293

Os resultados da sobreposição volumétrica entre os diferentes operadores do Grupo “SM” e o “GS” estão descritos na Tabela 3.

Tabela 3 - Comparação entre Gold Standard e Grupo Segmentação Manual - NAI direito

Caso Clínico (NAI direito)	RMS (GS vs SM-G)	RMS (GS vs SM-H)	RMS (GS vs SM-L)
1	0,9723	0,9329	0,9978
2	0,8959	0,4060	0,5161
3	0,9527	0,9879	0,9493
4	1,2303	1,0619	1,1968
5	1,2674	1,3427	1,3591
6	1,2343	0,6905	0,8106
7	1,3602	0,5854	0,9062
8	0,9321	1,1520	1,1700
9	1,4322	1,0335	1,3221
10	1,4819	1,0625	1,2256

Os resultados da sobreposição volumétrica entre os diferentes operadores do grupo “SM” e o grupo segmentação “AI” estão descritos na Tabela 4.

Tabela 4 - Comparação entre Grupo Segmentação AI e Grupo Segmentação Manual - NAI direito

Caso Clínico (NAI direito)	RMS (AI vs SM-G)	RMS (AI vs SM-H)	RMS (AI vs SM-L)
1	1,2033	0,2521	1,0029
2	0,6494	0,0603	0,3678
3	0,6015	0,9087	0,8169
4	0,5118	0,5536	0,2831
5	0,7383	0,3624	1,4968
6	0,9902	0,0548	0,4501
7	1,2549	0,0505	0,4369
8	0,7054	0,3698	0,7835
9	0,7653	0,1743	0,6106
10	0,9384	0,4441	0,4972

Inicialmente, os dados das segmentações manuais (SM) foram agrupados, sendo posteriormente realizada a mesma análise considerando cada operador manual de forma individual.

Para cada situação, verificaram-se os pressupostos de normalidade da variável RMS e de homogeneidade das variâncias através do teste de *Shapiro-Wilk* (o valor de p não tenho, pois, a Prof. Joana não mandou). Quando estes se confirmavam, aplicava-se o teste paramétrico ANOVA (Análise de Variância), com o objetivo de identificar diferenças nas médias entre grupos. Na ausência de cumprimento desses pressupostos, seria utilizado o teste não paramétrico de Kruskal-Wallis. No entanto, em ambos os cenários (SM agrupados e SM separados), os pressupostos foram cumpridos, permitindo a aplicação do teste ANOVA.

3.1.1 Estatística Descritiva – SM Agrupados

A tabela 5 apresenta os valores descritivos do RMS obtidos nas comparações entre as segmentações manuais agrupadas (SM), a inteligência artificial (IA) e o *gold standard* (GS). Estes valores estão representados também no Gráfico 1. Note-se uma média de valores mais baixa no grupo “SM vs AI”. No entanto, o menor desvio padrão verifica-se no grupo “AI vs GS”.

Tabela 5 - Estatística descritiva dos valores de RMS (NAI Direito)

Grupos	n	Valores da estatística descritiva para o <i>Root Mean Square</i> (RMS)	
SM vs GS	30	Média	1,04890
		Desvio Padrão	0,26794
AI vs GS	10	Média	0,76230
		Desvio Padrão	0,16786
SM vs AI	30	Média	0,61120
		Desvio Padrão	0,36241

O grupo “SM vs AI” apresentou um valor médio de RMS inferior, o que parece indicar melhor concordância na segmentação do NAI. No entanto o desvio padrão é maior, indicando maior variabilidade nos resultados. Aliás, o alto *outlier* que se visualiza no gráfico 1 reforça essa variabilidade. Neste grupo verifica-se, portanto, casos de alta similaridade e casos de grande divergência.




Gráfico 1: BoxPlot comparativo dos valores de RMS

3.1.2 Análise Inferencial – SM Agrupados

O teste ANOVA aplicado revelou um valor de $p < 0,001$, valor inferior ao nível de significância definido ($\alpha = 0,05$). Assim, rejeita-se a hipótese nula de igualdade das médias, concluindo-se que os valores de RMS diferem significativamente entre os grupos comparados (“SM vs GS” vs “AI vs GS” vs “SM vs AI”).

Para identificar entre quais grupos ocorrem essas diferenças, foram realizadas comparações múltiplas com o teste de *Scheffé*, utilizando o RMS como variável dependente.

Tabela 6 - Comparação Múltipla (teste de *Scheffé*)

Grupos		Valor-p (Sig.)
SM vs GS	AI vs GS	0,041
	SM vs AI	<0,001

Verificou-se que o valor de RMS na comparação **SM vs GS** é significativamente superior aos valores de **AI vs GS** e **SM vs AI**, e em particular com este último grupo.

3.1.3 Estatística Inferencial – SM em Separado

Nesta etapa, as segmentações manuais foram analisadas de forma individual por operador, permitindo avaliar a variação entre os diferentes profissionais. Se a normalidade da amostra é simétrica (aproximada distribuição normal), usa-se média para a tendência central e desvio padrão para a dispersão. Enquanto a normalidade da amostra é não simétrica, com *outliers*, a tendência central é a mediana e a dispersão é o desvio interquartil.

Tabela 7 - Estatística descritiva por operador (NAI Direito)

Grupos	n	Valores da estatística descritiva para o Root Mean Square (RMS)	
SM-G vs GS	10	Média	1,17590
		Desvio Padrão	0,22039
SM-H vs GS	10	Média	0,92550
		Desvio Padrão	0,28267
SM-L vs GS	10	Média	1,04540
		Desvio Padrão	0,26078
AI vs GS	10	Média	0,76230
		Desvio Padrão	0,16786
SM-G vs AI	10	Média	0,83590
		Desvio Padrão	0,25192
SM-H vs AI	10	Média	0,32310
		Desvio Padrão	0,27018
SM-L vs AI	10	Média	0,67460
		Desvio Padrão	0,36603

No gráfico 2 é visível a comparação dos valores de RMS entre os diferentes grupos de “SM vs GS”, “AI vs GS” e “SM vs AI”. Onde é possível destacar o grupo “SM-H vs AI” como aquele que apresentou valores de RMS mais baixos, ou seja, aquele em que as segmentações mais se aproximaram. Por outro lado, todos os grupos de “SM vs GS” apresentaram valores de RMS mais elevados, ou seja, indicando uma maior diferença nas segmentações.




Gráfico 2 - BoxPlot comparativo por operador

3.1.4 Análise Inferencial – SM em Separado

A aplicação do teste ANOVA voltou a revelar um valor de $p < 0.001$, sendo o nível de significância definido ($\alpha = 0,05$). indicando diferenças estatísticas significativas entre grupos. Para saber entre que grupos se verificaram essas diferenças, procedeu-se novamente às comparações múltiplas utilizando o teste de *Scheffé*. Os resultados com diferenças estatisticamente significativas encontram-se descritos na Tabela 8.

Tabela 8 - Comparação Múltipla entre operadores, AI e GS (teste de Scheffé)

Grupos		Valor-p (Sig.)
SM-H vs AI	SM-G vs GS	<0,001
	SM-H vs GS	0,001
	SM-L vs GS	<0,001
	AI vs GS	0,048
	SM-G vs AI	0,010
SM-L vs AI	SM-G vs GS	0,013

Interpretando os resultados, todas as segmentações manuais, “SM-G”, “SM-H” e “SM-L” vs GS, apresentaram valores de RMS significativamente

diferentes do grupo “SM-H vs AI”, assim como os grupos “SM-L vs AI” em comparação com o grupo “SM-G vs GS”.

A segmentação por “SM-H vs AI” comparada com “AI vs GS” também apresentou uma diferença significativa, embora com um valor de p mais elevado (0,048), sugerindo uma discrepância menor.

As comparações entre os operadores e a AI revelam que a AI se diferencia de todos os operadores com significância estatística, com o menor valor de RMS observado na comparação “SM-H vs AI” com “SM-G vs GS” e “SM-L vs GS” ($p < 0,001$).

Estes resultados indicam que o grupo “SM-H vs AI” foi o que obteve valores de RMS mais baixos e significativamente diferentes dos outros grupos. O grupo “AI vs GS” não obteve praticamente diferenças significativas na comparação com os restantes grupos (com exceção da comparação com o grupo “SM-H vs AI” que apresentou um valor de p de 0,048), assim como os restantes grupos entre si.

3.2 Nervo Alveolar Inferior Esquerdo

Os resultados da sobreposição volumétrica entre os grupos de segmentação “AI vs GS” estão descritos na Tabela 9

Tabela 9 - Comparação entre Grupo Segmentação AI e Gold Standard – NAI esquerdo

Caso Clínico (NAI esquerdo)	RMS (AI vs GS)
1	1,4601
2	1,2981
3	1,0748
4	0,7539
5	0,7198
6	0,6508
7	0,8630
8	0,6943
9	0,6136
10	0,5292

Os resultados da sobreposição volumétrica entre os diferentes operadores do grupo “SM vs GS” estão descritos na Tabela 10

Tabela 10 - Comparação entre Gold Standard e Grupo Segmentação Manual - NAI esquerdo

Caso Clínico (NAI esquerdo)	RMS (GS vs SM-G)	RMS (GS vs SM-H)	RMS (GS vs SM-L)
1	1,8055	1,5695	1,4757
2	1,7310	1,4746	1,6828
3	1,3972	1,2179	1,0503
4	1,2814	1,2229	1,1971
5	2,1287	0,8487	1,7134
6	1,2037	0,9811	0,8937
7	1,2109	1,0191	1,1064
8	1,3612	0,9103	1,1878
9	1,1663	0,7548	0,9482
10	1,1045	0,6976	1,6131

Os resultados da sobreposição volumétrica entre os diferentes operadores do grupo “SM vs AI” estão descritos na Tabela 11.

Tabela 11 - Comparação entre Grupo Segmentação AI e Grupo Segmentação Manual - NAI esquerdo

Caso Clínico (NAI esquerdo)	RMS (AI vs SM-G)	RMS (AI vs SM-H)	RMS (AI vs SM-L)
1	1,2640	0,2645	0,7537
2	0,9416	0,3962	0,5549
3	0,7994	0,9237	0,7204
4	1,0827	0,7421	0,3596
5	1,8533	0,3702	1,6758
6	1,0676	0,3132	0,4766
7	0,6780	0,3185	0,4255
8	0,7106	0,1814	0,3878
9	0,9680	0,1419	0,4344
10	0,8703	0,4624	1,5960

Tal como no lado direito, numa primeira fase, os dados das segmentações manuais (SM) foram agrupados e, posteriormente, analisados separadamente por operador. Para cada agrupamento, foram verificados os pressupostos de normalidade da variável RMS e de homogeneidade das variâncias. Quando

estes pressupostos foram satisfeitos, aplicou-se o teste paramétrico ANOVA; caso contrário, recorreu-se ao teste não paramétrico de Kruskal-Wallis. No presente caso, a análise com os SM agrupados permitiu a utilização do teste ANOVA, enquanto, para os SM em separado, foi necessário recorrer ao teste de Kruskal-Wallis.

3.2.1 Estatística Descritiva – SM Agrupados

A tabela 12 apresenta os valores descritivos de RMS para as comparações entre as “SM” agrupadas, a “AI” e o “GS”.

Tabela 12 -Estatística descritiva dos valores de RMS (NAI Esquerdo)

Grupos	n	Valores da estatística descritiva para o Root Mean Square (RMS)	
SM vs GS	30	Média	1,26520
		Desvio Padrão	0,33982
AI vs GS	10	Média	0,86580
		Desvio Padrão	0,31094
SM vs AI	30	Média	0,72450
		Desvio Padrão	0,44118

No gráfico 3 é visível a comparação dos valores de RMS entre “SM vs GS”, “AI vs GS” e “SM vs AI”. O grupo “SM vs GS” teve os valores médios mais elevados de RMS, indicando maior discrepância em relação ao “GS”. O grupo “AI vs GS” apresentou menor desvio padrão, indicando maior proximidade da AI em relação ao “GS” do que a segmentação manual.

O grupo “SM vs AI” apresentou mediana mais baixa que SM vs GS, mas semelhante à AI vs GS. Um *outlier* aparece indicando que há casos com maior discrepância entre SM e AI.




Gráfico 3 - BoxPlot Comparativo dos valores de RMS

3.2.2 Análise Inferencial – SM Agrupados

O teste ANOVA revelou um valor de $p < 0,001$, inferior ao nível de significância adotado ($\alpha = 0,05$), permitindo rejeitar a hipótese nula de igualdade das médias. Conclui-se, assim, que existem diferenças estatisticamente significativas entre os grupos. Para identificar quais comparações apresentam essas diferenças, recorreu-se ao teste de *Scheffé*.

Tabela 13 - Comparação Múltipla (teste de *Scheffé*)

Grupos		Valor-p (Sig.)
SM vs GS	AI vs GS	0,022
	SM vs AI	<0,001

Os resultados mostram que os valores de RMS da comparação “SM vs GS” é significativamente superior aos dos grupos “AI vs GS” e “SM vs AI”. Igual ao lado direito como representado na tabela 6.

3.2.3 Estatística Inferencial – SM em Separado

Nesta etapa, as segmentações manuais foram analisadas individualmente, com o objetivo de avaliar a variação entre diferentes operadores.

Tabela 14 - Estatística descritiva por operador (NAI Esquerdo)

Grupos	n	Valores da estatística descritiva para o <i>Root Mean Square</i> (RMS)	
SM-G vs GS	10	Mediana	1,3213
		Desvio interquartil (IQR)	0,5600
SM-H vs GS	10	Mediana	1,0001
		Desvio interquartil (IQR)	0,4600
SM-L vs GS	10	Mediana	1,1925
		Desvio interquartil (IQR)	0,6100
AI vs GS	10	Mediana	0,7369
		Desvio interquartil (IQR)	0,4900
SM-G vs AI	10	Mediana	0,9548
		Desvio interquartil (IQR)	0,3500
SM-H vs AI	10	Mediana	0,3444
		Desvio interquartil (IQR)	0,2900
SM-L vs AI	10	Mediana	0,5157
		Desvio interquartil (IQR)	0,5500

No gráfico 4 é visível a comparação dos valores de RMS entre os diferentes operadores de “SM vs GS”, “AI vs GS” e “SM vs AI”. Novamente os grupos “SM-H vs AI” e “SM-L vs AI” apresentam os valores mais baixos de RMS (embora com alguns *outliers* relevantes). Por outro lado, todos os grupos de “SM vs GS” apresentam valores de RMS mais elevados.




Gráfico 4 - BoxPlot Comparativo por operador

3.2.4 Análise Inferencial – SM em Separado

Uma vez que os pressupostos para ANOVA não foram cumpridos, aplicou-se o teste de Kruskal-Wallis. O resultado mostrou um valor de $p < 0,001$, levando à rejeição da hipótese nula, ou seja, as distribuições de RMS são significativamente diferentes entre os grupos.

Cada linha testa a hipótese nula de que as distribuições das duas amostras são iguais. As significâncias assintóticas foram calculadas para um teste bilateral com nível de significância de $\alpha = 0,05$. Na tabela 15 são apenas apresentados os resultados das comparações que tiveram resultados estatisticamente significativos, ou seja, com um valor de $p < 0,05$.

Tabela 15 – Comparações múltiplas por método Kruskal-Wallis com correção de Bonferroni.

Amostra 1 - Amostra 2	Valor-p (Sig.)	Valor-p (Sig.) Ajustado
SM-H vs AI - AI vs GS	0,030	0,621
SM-H vs AI - SM-G vs AI	0,003	0,053
SM-H vs AI - SM-H vs GS	<0,001	0,015*
SM-H vs AI - SM-L vs GS	<0,001	0,000*
SM-H vs AI - SM-G vs GS	<0,001	0,000*
SM-L vs AI - SM-L vs GS	0,004	0,075
SM-L vs AI - SM-G vs GS	<0,001	0,008*
AI vs GS - SM-G vs GS	0,004	0,084

* valores significativos após correção / ajuste.

A aplicação da correção de Bonferroni aos pares de comparações múltiplas identificadas no teste de Kruskal-Wallis tem como objetivo ajustar os valores de significância para reduzir o risco de erro do tipo I, que aumenta quando múltiplos testes são realizados simultaneamente. Após esta correção, os resultados mantêm-se estatisticamente significativos em diversas comparações.

A tabela 15 evidencia com *, quatro comparações com valores de p ajustados $< 0,05$, o que confirma diferenças estatisticamente mais robustas entre os grupos:

“SM-H vs AI” – “SM-H vs GS” ($p=0,015$) *

Esta comparação revela que a discrepância de RMS entre “SM-H e AI” difere significativamente daquela observada entre “SM-H e GS”, sendo mais aproximada à AI.

SM-H vs AI – SM-L vs GS ($p=0,000$) *

A diferença significativa entre estas duas comparações indica que a variação de RMS entre SM-H e AI não é apenas uma questão de técnica, mas está também relacionada com o desempenho relativo de outros operadores manuais em relação ao “GS”. O operador H teve melhor desempenho (RMS mais próximo da AI), enquanto o SM-L se distanciou mais da AI, reforçando a ideia de heterogeneidade interoperador (variabilidade entre os operadores).

SM-H vs AI – SM-G vs GS ($p=0,000$) *

Esta comparação destaca um contraste ainda mais marcado entre os resultados do grupo “SM-H vs AI” com o grupo “SM-G vs GS”. O RMS mais elevado de “SM-G vs GS” (1,4390) sugere uma maior discrepância individual em relação ao gold standard, e comparativamente à segmentação manual do operador “H vs AI”.

SM-L vs AI – SM-G vs GS ($p=0,008$) *

Esta diferença estatística confirma novamente que os valores de RMS da segmentação manual do operador “G” comparativamente ao “GS” são bastante diferentes (superiores) às segmentações de outros operadores vs “AI”.

No gráfico 5, olhando rapidamente para o diagrama podemos identificar 4 diferenças entre grupos através das linhas azuis.

SM-H vs AI (10,10) tem o *rank* médio mais baixo, indicando desempenho superior (maior similaridade).

SM-G vs GS (56,10) e SM-L vs GS (50,20) possuem os *rank*s mais altos, indicando piores desempenhos nestas comparações.

AI vs GS possui bom desempenho (*rank* médio baixo), sem diferenças estatísticas fortes na maioria das comparações, indicando consistência, mas não equivalência total ao GS.

Comparações por Método Pairwise de Comparativo




Gráfico 5 - Comparações Múltiplas Pairwise com Conexões por Significância

(Componentes do gráfico: nós (pontos/labels): cada nó representa uma comparação específica entre dois métodos; número ao lado do nó: é o rank médio da comparação (quanto menor, melhor desempenho relativo); linhas conectando os nós: representam as comparações estatísticas entre os pares de condições. Cores das linhas (legenda "Adj. Sig."): Azul-claro (<0,05): a diferença entre os dois nós conectados é estatisticamente significativa. Verde-escuro (>= 0,05): a diferença não é significativa.)

4 DISCUSSÃO

A presente investigação teve como objetivo central avaliar a precisão das segmentações do nervo alveolar inferior (NAI) em tomografias computadorizadas de feixe cónico (CBCT), comparando segmentações manuais realizadas por médicos dentistas júnior (MDJ) com segmentações automatizadas produzidas por algoritmos de inteligência artificial (IA). Como referência para análise comparativa, foi utilizado um *gold standard* (GS), estabelecido com base na segmentação realizada por um médico dentista sénior (MDS) com experiência consolidada. Para aferir o grau de discrepância entre as segmentações, recorreu-se à métrica Root Mean Square (RMS), amplamente validada na literatura para a quantificação de diferenças volumétricas entre estruturas tridimensionais.⁽⁷⁾

De forma a facilitar a interpretação dos resultados, a análise foi realizada separadamente para os lados direito e esquerdo do nervo alveolar inferior (NAI), respeitando a assimetria anatômica frequentemente observada nesta estrutura neurovascular. Esta abordagem metodológica permitiu uma leitura mais precisa das variações associadas a cada hemisfério mandibular e contribuiu para a robustez analítica do estudo. Esta separação lateral visa ainda reforçar a clareza dos resultados, permitindo avaliar com maior detalhe o impacto da experiência do operador e da automação por inteligência artificial (IA) na precisão da identificação do canal mandibular, uma estrutura de elevada relevância clínica no planeamento de implantes dentários, sobretudo quando são utilizados *softwares* com recursos de IA integrados.⁽³⁴⁾ O presente trabalho insere-se, assim, num contexto clínico e tecnológico particularmente atual, marcado pelo crescimento exponencial da aplicação de soluções digitais assistidas por IA na implantologia moderna.

As hipóteses nulas propostas foram ambas rejeitadas à luz dos resultados obtidos. Em primeiro lugar, verificaram-se diferenças estatisticamente significativas entre os métodos de segmentação manual e automatizada, contrariando a premissa de que ambos teriam desempenhos equivalentes. Em segundo lugar, as segmentações manuais também apresentaram variabilidade significativa em função do nível de experiência do operador, o que reforça a

importância da formação e da maturidade clínica na precisão dos traçados anatômicos.

Os resultados revelaram que a segmentação do NAI realizada pela inteligência artificial se aproximou mais da GS do que das dos MDJ, refletindo maior consistência com o padrão de referência.

Verificou-se também uma considerável variabilidade nas segmentações entre os próprios MDJ, especialmente quando comparadas com a do operador experiente. Este achado sublinha o impacto da experiência e do domínio anatômico na qualidade da segmentação manual: operadores mais experientes tendem a produzir delineamentos mais precisos e reproduzíveis, enquanto a menor familiaridade dos MDJ com a morfologia tridimensional do NAI se traduziu em maiores desvios.

Entre os MDJ, os operadores H e L destacaram-se pela maior proximidade aos resultados do GS, possivelmente refletindo maior empenho ou rigor na execução da tarefa. Em contrapartida, o desempenho do operador G foi menos consistente, o que pode estar associado a uma abordagem menos cuidadosa. Curiosamente, até mesmo o próprio GS poderá ter realizado a segmentação de forma relativamente célere, o que contribui para as discrepâncias observadas face à segmentação automática.

De forma geral, os dados sugerem que tanto a experiência clínica como o grau de atenção dedicado à tarefa influenciam significativamente a qualidade das segmentações manuais. Este padrão reforça a importância da curva de aprendizagem na interpretação anatômica de imagens tridimensionais, bem como a utilidade de ferramentas automáticas no apoio à padronização e à redução da variabilidade interobservador.

No contexto clínico, onde a precisão na identificação do NAI é crítica para evitar complicações, como lesões nervosas, os resultados obtidos revelam que a AI não só alcança segmentações mais próximas do GS, como também o faz de forma mais consistente e reproduzível, mesmo em regiões com elevada variabilidade anatômica.^(27, 34) Tal como defendido por Tahmaseb et al,⁽³⁴⁾ a identificação precisa do canal mandibular é uma etapa crítica do planeamento

cirúrgico de implantes, sobretudo em zonas posteriores da mandíbula, onde a proximidade entre as raízes dentárias e o canal neurovascular é frequentemente reduzida.^(23, 24, 34)

Os resultados obtidos apontam para um bom desempenho da segmentação automatizada do canal mandibular com a IA, o que é concordante com outros estudos que realizam investigações semelhantes com o *software* coDiagnostiX®.^(19, 27, 29, 30, 35, 36)

A inteligência artificial demonstrou ser uma alternativa eficaz e reproduzível. A IA obteve valores médios de RMS significativamente inferiores aos das segmentações manuais:

- No lado direito, o valor médio do RMS do grupo “AI vs GS” foi de 0,7623 e do grupo “AI vs SM” foi de 0,61120, enquanto o valor médio do RMS do grupo “SM vs GS” foi de 1,0489, ou seja, superior.
- No lado esquerdo, os valores foram de 0,8658 para o grupo “AI vs GS” e de 0,72450 para o grupo “SM vs AI”, enquanto o valor médio do RMS do grupo “SM vs GS” foi de 1,2652, ou seja, superior.

Esta tendência confirma-se também nos desvios padrão, que foram consistentemente mais baixos para a IA, traduzindo uma maior estabilidade nos seus resultados.

Estes achados são concordantes com outras investigações. Jaskari et al.⁽³⁵⁾ demonstraram que modelos de *deep learning* são capazes de realizar segmentações do canal mandibular com precisão comparável à de especialistas humanos. De igual modo, Lahoud et al. e Issa et al.^(19, 29) destacaram a viabilidade da segmentação automática para aplicações clínicas, defendendo que esta tecnologia pode reduzir o tempo de trabalho e minimizar erros humanos. Lim et al.⁽³⁰⁾ foram ainda mais além, ao evidenciar que os modelos baseados em AI podem superar operadores menos experientes, promovendo uma maior uniformidade entre casos.^(19, 29, 30, 35)

Importa, no entanto, salientar que o desempenho da IA não é isento de limitações. Os algoritmos atualmente utilizados baseiam-se, em larga medida, na deteção de bordos com maior densidade de osso cortical. Em casos de ausência parcial ou total de corticalização óssea, como frequentemente observado em anatomias complexas, em situações de reabsorção ou em pacientes mais idosos, a IA pode apresentar dificuldades em delinear com precisão os contornos do canal mandibular. Assim, embora a IA ofereça grande valor, a revisão humana continua recomendada, especialmente em casos clínicos limítrofes. Ainda assim, a tendência evolutiva dos algoritmos sugere melhorias contínuas, tornando a IA cada vez mais relevante como ferramenta de apoio no planeamento cirúrgico. (23, 24, 31)

Do ponto de vista estatístico, o teste ANOVA revelou diferenças significativas ($p < 0,001$) entre os grupos de segmentações. A análise por comparações múltiplas, através do teste de *Scheffé*, confirmou que a AI difere de forma significativa das segmentações manuais, com melhor desempenho. Ao considerar cada operador de forma individual, observou-se que todas as segmentações manuais (“SM-G”, “SM-H” e “SM-L”) apresentaram RMS significativamente diferentes do GS. Esta constatação reforça a dificuldade dos operadores menos experientes em replicar a segmentação de referência (*gold standard*) com elevado grau de precisão.

Particularmente relevante foi a comparação entre os grupos “SM-H vs AI” e “AI vs GS”. A análise estatística revelou uma diferença significativa entre os respetivos valores de RMS ($p = 0,048$), ainda que muito próxima do limiar convencional de significância ($\alpha = 0,05$). Este resultado indica que os valores de RMS entre a segmentação manual do operador H e a da AI foram significativamente diferentes dos valores entre a AI e o GS, o que, à primeira vista, pode parecer contraditório com a ideia de que a AI se aproxima do padrão de referência.

No entanto, uma análise mais atenta dos valores médios mostra que a SM-H foi a mais próxima da AI, com um RMS médio inferior ao do grupo AI vs GS, o que indica um elevado grau de concordância entre o operador H e o algoritmo.

Este dado é particularmente interessante, pois sugere que a segmentação feita pelo operador H não só foi rigorosa, como se alinhou mais com o desempenho do algoritmo do que o próprio GS, responsável pela referência utilizada.

Este achado pode refletir uma maior atenção e cuidado por parte do operador H na execução da tarefa, bem como a consistência interna do algoritmo, que, apesar de operar sobre variabilidade anatômica interindividual, manteve resultados robustos. Por outro lado, também poderá indicar que a segmentação GS, apesar de feita por um especialista, não está isenta de variações, especialmente se realizada num contexto de maior rapidez ou menor controlo de qualidade.

As combinações entre pares, como “SM-H vs AI” com “SM-G vs GS” ($p < 0,001$), ilustram de forma clara a amplitude da variabilidade entre operadores e destacam a superior estabilidade do modelo automatizado. O operador G, por exemplo, obteve o pior desempenho (média de RMS = 1,4390), reforçando a heterogeneidade na qualidade das segmentações manuais. Já o operador L, apesar de apresentar menor desvio em relação à AI, mostrou elevada variabilidade, o que compromete a sua fiabilidade clínica.

No lado esquerdo, os dados confirmaram a tendência observada: segmentações manuais com maior RMS (média = 1,2652; desvio padrão = 0,33982) e segmentações por AI com valores médios mais baixos (média = 0,8658) e desvio padrão reduzido (0,31094). Embora a AI tenha registado um valor máximo de RMS elevado (1,46), indicando limitação em casos pontuais, a sua consistência global foi superior.

Na comparação SM vs AI do lado esquerdo, a mediana foi próxima da mediana AI vs GS, o que poderia sugerir uma maior concordância. No entanto, o desvio padrão elevado (0,44118) e o intervalo de valores (0,14 a 1,85), (variação interquartil), revelaram uma elevada heterogeneidade nas segmentações manuais. O Gráfico 3 (da secção de Resultados desta dissertação) ilustra visualmente essa variabilidade, com *outliers* representativos de discrepâncias substanciais.

Para aprofundar a análise estatística, e dado que os pressupostos do teste ANOVA não foram cumpridos em todas as instâncias, recorreu-se ao teste de *Kruskal-Wallis*. Este teste não paramétrico confirmou diferenças significativas entre os grupos ($p < 0,001$), permitindo rejeitar novamente a hipótese nula. A análise de comparações múltiplas com correção de *Bonferroni* revelou quatro contrastes estatisticamente significativos, destacando, uma vez mais, a superior consistência da AI e reforçando a heterogeneidade do desempenho humano.

Embora o tempo de execução não tenha sido avaliado, estudos anteriores apontam que profissionais experientes tendem a demorar mais tempo, revendo cortes e perspetivas, enquanto MDJ trabalham mais rapidamente, porém com menor rigor. A AI, por sua vez, processa automaticamente ambos os canais mandibulares e outras estruturas dentárias em segundo plano, permitindo uma maior eficiência no fluxo de trabalho.⁽³⁶⁾

A variabilidade interindividual entre operadores humanos pode representar um risco real na prática clínica, especialmente em procedimentos que envolvem estruturas críticas. A utilização de AI pode mitigar esse risco, promovendo maior padronização das segmentações e, conseqüentemente, maior segurança para o paciente. Em ambientes com múltiplos operadores ou com diferentes níveis de formação, a AI pode assumir o papel de ferramenta de apoio e controlo de qualidade, promovendo uniformidade nos resultados.

4.1 Limitações do estudo

Dentro das limitações deste estudo, destaca-se em primeiro lugar a dimensão reduzida da amostra, composta por apenas 10 exames CBCT. Embora esta abordagem permitisse uma análise pormenorizada de cada caso, a generalização dos resultados fica comprometida, sendo desejável a inclusão de um maior número de casos em investigações futuras.

Adicionalmente, todos os exames foram realizados com o mesmo equipamento de tomografia (Planmeca ProMax 3D Classic) e processados num

único *software* (coDiagnostiX®), o que pode limitar a aplicabilidade dos resultados a outras marcas ou configurações de aquisição e processamento de imagem. A performance da inteligência artificial pode variar consoante os parâmetros técnicos dos aparelhos e a qualidade das imagens obtidas, o que justifica a necessidade de estudos multicêntricos com diferentes equipamentos e *software*.

Outro fator a considerar é que todos os operadores humanos pertencem à mesma instituição e partilham um grau de formação semelhante. Esta homogeneidade limita a avaliação da variabilidade real interobservador, já que em contextos clínicos reais é comum existirem diferenças mais marcadas nos níveis de experiência, formação e familiaridade com as ferramentas digitais.

Adicionalmente, o estudo focou-se apenas na segmentação do ramo principal do nervo alveolar inferior, não sendo incluídos canais acessórios, como o canal incisivo ou o canal retromolar, cuja identificação também pode ter impacto clínico relevante. A segmentação de estruturas mais complexas ou de contornos menos definidos (ex.: canais sem corticalização clara) poderá apresentar desafios acrescidos para a AI e não foi avaliada nesta investigação.

Por fim, o tempo de execução das segmentações não foi mensurado, o que poderia ter acrescentado uma dimensão prática à comparação entre métodos – especialmente no que se refere à eficiência e aplicabilidade clínica.

4.2 Perspetivas futuras

Com base nas limitações acima descritas, destacam-se várias direções promissoras para investigações futuras:

- Aumento da dimensão e heterogeneidade da amostra, incorporando pacientes de diferentes faixas etárias, graus de reabsorção óssea e anatomias variadas. Isto permitirá testar a robustez da AI perante casos mais complexos ou atípicos.

- Comparação entre diferentes *softwares* de planeamento e algoritmos de AI, idealmente desenvolvidos por distintos fabricantes e com bases de treino distintas. Tal permitiria aferir a consistência dos resultados em contextos técnicos variados.

- Integração de equipamentos de CBCT de diferentes marcas, com parâmetros de aquisição diversificados, para avaliar o desempenho da AI em condições clínicas reais, com diferentes qualidades de imagem.

- Inclusão de operadores de diferentes perfis de experiência clínica, como médicos dentistas em fases mais avançadas da carreira ou especialistas em imagiologia oral, para uma análise mais abrangente da variabilidade interobservador.

- Avaliação da segmentação de estruturas adicionais, como os ramos acessórios do NAI (canal incisivo, canal retromolar, canal mentoniano), cuja correta identificação pode ser determinante em algumas intervenções cirúrgicas.

- Estudo do impacto clínico direto da segmentação por AI, por exemplo, avaliando a taxa de complicações pós-operatórias ou a precisão na colocação de implantes guiados com base em segmentações automáticas.

- Análise do tempo de execução de cada método de segmentação, contribuindo para a compreensão do equilíbrio entre precisão e eficiência, essencial na prática clínica contemporânea.

Estas perspetivas abrem caminho para a consolidação da inteligência artificial como ferramenta de apoio em implantologia, contribuindo para uma prática mais segura, padronizada e eficiente.

5 CONCLUSÃO

Dentro das limitações deste estudo, pode-se concluir que:

A segmentação tridimensional do canal mandibular com recurso a inteligência artificial (AI) demonstrou uma maior proximidade ao traçado de referência (gold standard) em comparação com as segmentações manuais realizadas por médicos dentistas júnior (MDJ), tanto no lado direito como no esquerdo da mandíbula.

Os valores médios de Root Mean Square (RMS) foram consistentemente inferiores no grupo “AI vs GS” em relação ao grupo “SM vs GS”, revelando uma maior precisão e estabilidade da AI.

Observou-se uma variabilidade significativa entre os operadores humanos, com diferenças estatísticas entre as segmentações realizadas por diferentes MDJ. Este achado permite concluir que o nível de experiência influencia diretamente a precisão da segmentação manual.

A AI revelou menor desvio padrão, indicando uma maior consistência e reprodutibilidade, independentemente das variações anatómicas ou da intervenção humana.

Assim, os dados obtidos neste estudo permitem rejeitar ambas as hipóteses nulas:

$H_0(1)$: foi identificada uma diferença significativa entre a segmentação do canal mandibular por IA e a segmentação manual, o que confirma a superioridade da IA em termos de precisão.

$H_0(2)$: foram encontradas diferenças significativas entre operadores com diferentes níveis de experiência, evidenciando que a segmentação manual está fortemente dependente da formação e maturidade clínica.

Conclui-se, portanto, que a inteligência artificial representa uma ferramenta válida e fiável para a segmentação do nervo alveolar inferior, com potencial para aumentar a segurança, a previsibilidade e a padronização no planeamento de implantes dentários. A sua integração em protocolos clínicos poderá representar um avanço importante na prática da medicina dentária digital, sobretudo em ambientes com operadores com menor experiência.

6 BIBLIOGRAFIA

1. Breeland G, Aktar A, Patel BC. Anatomy, Head and Neck, Mandible. StatPearls. Treasure Island (FL): StatPearls Publishing

Copyright © 2024, StatPearls Publishing LLC.; 2024.

2. Nguyen JD, Duong H. Anatomy, Head and Neck, Mandibular Foramen. StatPearls. Treasure Island (FL): StatPearls Publishing

Copyright © 2024, StatPearls Publishing LLC.; 2024.

3. Abrahams JJ, Frisoli JK, Dembner J. Anatomy of the jaw, dentition, and related regions. Semin Ultrasound CT MR. 1995;16(6):453-67.

4. Aksoy U, Aksoy S, Orhan K. A cone-beam computed tomography study of the anatomical relationships between mandibular teeth and the mandibular canal, with a review of the current literature. Microsc Res Tech. 2018;81(3):308-14.

5. Borghesi A, Bondioni MP. Unilateral triple mandibular canal with double mandibular foramen: cone-beam computed tomography findings of an unexpected anatomical variant. Folia Morphol (Warsz). 2021;80(2):471-5.

6. Yu SK, Lee MH, Jeon YH, Chung YY, Kim HJ. Anatomical configuration of the inferior alveolar neurovascular bundle: a histomorphometric analysis. Surg Radiol Anat. 2016;38(2):195-201.

7. Ntovas P, Marchand L, Finkelman M, Revilla-Leon M, Att W. Accuracy of artificial intelligence-based segmentation of the mandibular canal in CBCT. Clin Oral Implants Res. 2024;35(9):1163-71.

8. Nithya J, Aswath N. Assessing the Prevalence and Morphological Characteristics of Bifid Mandibular Canal Using Cone-Beam Computed Tomography - A Retrospective Cross-Sectional Study. J Clin Imaging Sci. 2020;10:30.

9. Okumuş Ö, Dumlu A. Prevalence of bifid mandibular canal according to gender, type and side. J Dent Sci. 2019;14(2):126-33.

10. Kovisto T, Ahmad M, Bowles WR. Proximity of the mandibular canal to the tooth apex. J Endod. 2011;37(3):311-5.

11. Leite GM, Lana JP, de Carvalho Machado V, Manzi FR, Souza PE, Horta MC. Anatomic variations and lesions of the mandibular canal detected by cone beam computed tomography. Surg Radiol Anat. 2014;36(8):795-804.

12. Amarnath GS, Kumar U, Hilal M, Muddugangadhar BC, Anshuraj K, Shruthi CS. Comparison of Cone Beam Computed Tomography, Orthopantomography with Direct Ridge Mapping for Pre-Surgical Planning to Place Implants in Cadaveric Mandibles: An Ex-Vivo Study. *J Int Oral Health*. 2015;7(Suppl 1):38-42.
13. Agbaje JO, de Castele EV, Salem AS, Anumendem D, Lambrichts I, Politis C. Tracking of the inferior alveolar nerve: its implication in surgical planning. *Clin Oral Investig*. 2017;21(7):2213-20.
14. Kaasalainen T, Ekholm M, Siiskonen T, Kortensniemi M. Dental cone beam CT: An updated review. *Phys Med*. 2021;88:193-217.
15. Angelopoulos C, Thomas SL, Hechler S, Parissis N, Hlavacek M. Comparison between digital panoramic radiography and cone-beam computed tomography for the identification of the mandibular canal as part of presurgical dental implant assessment. *J Oral Maxillofac Surg*. 2008;66(10):2130-5.
16. Gerlach NL, Meijer GJ, Maal TJ, Mulder J, Rangel FA, Borstlap WA, et al. Reproducibility of 3 different tracing methods based on cone beam computed tomography in determining the anatomical position of the mandibular canal. *J Oral Maxillofac Surg*. 2010;68(4):811-7.
17. MacDonald D, Telyakova V. An Overview of Cone-Beam Computed Tomography and Dental Panoramic Radiography in Dentistry in the Community. *Tomography*. 2024;10(8):1222-37.
18. Nasseh I, Al-Rawi W. Cone Beam Computed Tomography. *Dent Clin North Am*. 2018;62(3):361-91.
19. Lahoud P, Diels S, Niclaes L, Van Aelst S, Willems H, Van Gerven A, et al. Development and validation of a novel artificial intelligence driven tool for accurate mandibular canal segmentation on CBCT. *Journal of Dentistry*. 2022;116:103891.
20. Tanveer W, Ridwan-Pramana A, Molinero-Mourelle P, Forouzanfar T. Applications of CAD/CAM Technology for Craniofacial Implants Placement and Manufacturing of Auricular Prostheses-Systematic Review. *J Clin Med*. 2023;12(18).
21. Kern F, Kramer J, Wanner L, Wismeijer D, Nelson K, Flügge T. A review of virtual planning software for guided implant surgery - data import and

- visualization, drill guide design and manufacturing. BMC Oral Health. 2020;20(1):251.
22. Elgarba BM, Fontenele RC, Tarce M, Jacobs R. Artificial intelligence serving pre-surgical digital implant planning: A scoping review. J Dent. 2024;143:104862.
23. Hung KF, Ai QYH, Wong LM, Yeung AWK, Li DTS, Leung YY. Current Applications of Deep Learning and Radiomics on CT and CBCT for Maxillofacial Diseases. Diagnostics (Basel). 2022;13(1).
24. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry - A systematic review. J Dent Sci. 2021;16(1):508-22.
25. Jindanil T, Marinho-Vieira LE, de-Azevedo-Vaz SL, Jacobs R. A unique artificial intelligence-based tool for automated CBCT segmentation of mandibular incisive canal. Dentomaxillofac Radiol. 2023;52(8):20230321.
26. Leite AF, Vasconcelos KF, Willems H, Jacobs R. Radiomics and Machine Learning in Oral Healthcare. Proteomics Clin Appl. 2020;14(3):e1900040.
27. Oliveira-Santos N, Jacobs R, Picoli FF, Lahoud P, Niclaes L, Groppo FC. Automated segmentation of the mandibular canal and its anterior loop by deep learning. Sci Rep. 2023;13(1):10819.
28. Jarnstedt J, Sahlsten J, Jaskari J, Kaski K, Mehtonen H, Lin Z, et al. Comparison of deep learning segmentation and multigrader-annotated mandibular canals of multicenter CBCT scans. Sci Rep. 2022;12(1):18598.
29. Issa J, Olszewski R, Dyszkiewicz-Konwinska M. The Effectiveness of Semi-Automated and Fully Automatic Segmentation for Inferior Alveolar Canal Localization on CBCT Scans: A Systematic Review. Int J Environ Res Public Health. 2022;19(1).
30. Lim HK, Jung SK, Kim SH, Cho Y, Song IS. Deep semi-supervised learning for automatic segmentation of inferior alveolar nerve using a convolutional neural network. BMC Oral Health. 2021;21(1):630.
31. Wei X, Gu P, Hao Y, Wang J. Detection and characterization of anterior loop, accessory mental foramen, and lateral lingual foramen by using cone beam computed tomography. J Prosthet Dent. 2020;124(3):365-71.

32. 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.
33. Vinayahalingam S, Xi T, Berge S, Maal T, de Jong G. Automated detection of third molars and mandibular nerve by deep learning. *Sci Rep.* 2019;9(1):9007.
34. Tahmaseb A, Wismeijer D, Coucke W, Derksen W. Computer technology applications in surgical implant dentistry: a systematic review. *Int J Oral Maxillofac Implants.* 2014;29 Suppl:25-42.
35. Jaskari J, Sahlsten J, Jarnstedt J, Mehtonen H, Karhu K, Sundqvist O, et al. Deep Learning Method for Mandibular Canal Segmentation in Dental Cone Beam Computed Tomography Volumes. *Sci Rep.* 2020;10(1):5842.
36. Liu MQ, Xu ZN, Mao WY, Li Y, Zhang XH, Bai HL, et al. Deep learning-based evaluation of the relationship between mandibular third molar and mandibular canal on CBCT. *Clin Oral Investig.* 2022;26(1):981-91.