



Universidade do Estado do Rio de Janeiro

Centro Biomédico

Instituto de Biologia Roberto Alcântara Gomes

Larissa Aparecida Vaz Oliveira

**Detecção automática do canal mandibular em tomografias
computadorizadas de feixe cônico**

Rio de Janeiro

2022

Larissa Aparecida Vaz Oliveira

Deteccção automática do canal mandibular em tomografias computadorizadas de feixe cônico

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Saúde, Medicina Laboratorial e Tecnologia Forense, da Universidade do Estado do Rio de Janeiro.

Orientador: Prof. Dr. José Firmino Nogueira Neto

Coorientador: Prof. Dr. Nelson Massini

Rio de Janeiro

2022

CATALOGAÇÃO NA FONTE
UERJ/REDE SIRIUS/BIBLIOTECA CB-A

O48 Oliveira, Larissa Aparecida Vaz.
Detecção automática do canal mandibular em tomografias
computadorizadas de feixe cônico / Larissa Aparecida Vaz Oliveira. – 2022.
52 f.

Orientador: Prof. Dr. José Firmino Nogueira Neto.
Coorientador: Prof. Dr. Nelson Massini

Dissertação (Mestrado) - Universidade do Estado do Rio de Janeiro,
Instituto de Biologia Roberto Alcântara Gomes. Programa de Pós-Graduação
em Saúde, Medicina Laboratorial e Tecnologia Forense.

1. Tomografia computadorizada de feixe cônico – Métodos – Teses. 2. Canal
mandibular – Anatomia & histologia. 3. Inteligência artificial – Aplicações
médicas – Teses. 4. Automatização – Teses. I. Nogueira Neto, José Firmino. II.
Massini, Nelson. III. Universidade do Estado do Rio de Janeiro. Instituto de
Biologia Roberto Alcântara Gomes. IV. Título.

CDU 616.314

Bibliotecário: Felipe Caldonazzo
CRB7/7341

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação,
desde que citada a fonte.

Assinatura

Data

Larissa Aparecida Vaz Oliveira

Deteccção automática do canal mandibular em tomografias computadorizadas de feixe cônico

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Saúde, Medicina Laboratorial e Tecnologia Forense, da Universidade do Estado do Rio de Janeiro.

Aprovada em 07 de dezembro de 2022.

Coorientador: Prof. Dr. Nelson Massini

Faculdade de Ciências Médicas - UERJ

Banca Examinadora: _____

Prof. Dr. José Firmino Nogueira Neto (Orientador)

Faculdade de Ciências Médicas - UERJ

Prof. Dr. Marcelo Daniel Brito Faria

Faculdade de Odontologia – UERJ

Prof. Dr. Bruno Santos de Barros Dias

Universidade Federal do Rio de Janeiro

Rio de Janeiro

2022

DEDICATÓRIA

Dedico esta dissertação primeiramente a Deus que sempre está ao meu lado, me dando forças para prosseguir, mesmo quando o caminho se apresenta difícil. Aos meus pais, Hamilton de Freitas Oliveira e Angélica Maria Coelho Vaz, os quais com todo amor, sempre me incentivam, apoiam e não me deixam desistir.

AGRADECIMENTOS

A Deus por me permitir realizar sonhos.

Aos meus pais que são grandes incentivadores na busca pelo aprendizado e excelência profissional. Educação começa em casa e aprendemos pelo exemplo.

Ao meu orientador Prof. Dr. José Firmino, o qual admiro pela persistência, sempre no trabalho árduo e bem-feito.

Ao Profs. Drs. Marcelo Daniel Faria Brito e Luciana Bastos que incansavelmente me ajudam, me incentivam e me inspiram tanto profissionalmente quanto pessoalmente.

A colaboradora Maira Moran, a qual contribuiu ativamente com seus conhecimentos e esteve ao meu lado durante todos os processos desse programa.

Ao Prof. Dr. Elcio Carneiro que desde o início se mostrou presente me oferecendo amparo e incentivo para o meu crescimento profissional.

A todos os professores, do curso do Mestrado Profissional em Saúde Medicina Laboratorial e Tecnologia Forense, que de tantas formas contribuíram para a minha formação.

Aos queridos colegas do mestrado que me mostraram que sozinha não se chega a lugar nenhum.

A todos que direta ou indiretamente fizeram parte da minha trajetória até aqui!

Nós somos aquilo que fazemos repetidamente. Excelência, então, não é um modo de agir, mas um hábito.

Aristóteles

RESUMO

OLIVEIRA, Larissa Aparecida Vaz. *Detecção automática do canal mandibular em tomografias computadorizadas de feixe cônico*. 2022. 52 f. Dissertação (Mestrado em Saúde, Medicina Laboratorial e Tecnologia Forense) – Instituto de Biologia Roberto Alcântara Gomes, Rio de Janeiro, 2022.

O canal mandibular é um conduto ósseo localizado no interior da mandíbula que transporta o feixe neurovascular alveolar inferior. Vários métodos disponíveis na literatura implementam a segmentação do canal, sendo estes métodos manuais ou baseados em aprendizado profundo, que são demorados ou demandam uma grande quantidade de dados, respectivamente. Neste trabalho, apresentamos um método computacional semiautomático para segmentação do canal mandibular em tomografias computadorizadas baseado em processamento de sinal. O método inicia-se com o corte axial localizado 10 mm acima da base da mandíbula, onde a mandíbula é bem delimitada, sendo possível definir um arco que a descreva. São obtidos cortes parassagitais, no qual o canal mandibular pode ser detectado como uma estrutura circular usando a transformação de Hough. Como o canal não é a única estrutura circular em tais planos, o usuário seleciona a estrutura referente ao canal, e a partir desta semente, a estrutura tridimensional do canal é definida, usando o algoritmo de crescimento de região em cada um dos cortes oblíquos. Neste estudo, o método proposto foi aplicado a 25 Tomografias computadorizadas de feixe cônico (TCFCs) de diferentes pacientes (21 mulheres e 4 homens com idades entre 11 e 75 anos). Os volumes resultantes foram avaliados visualmente por especialistas, que observaram como apropriado é o volume obtido. Além disso, uma avaliação estatística também apontou a proximidade dos volumes obtidos pelos métodos e os definidos por especialistas (IoU médio: 0.79). A avaliação visual dos especialistas e a avaliação estatística demonstraram a precisão dos resultados alcançados pelo método. A segmentação apresentada neste trabalho consiste numa solução robusta, no sentido que os volumes obtidos são próximos estatisticamente dos volumes reais, além de inovar ao superar os principais desafios dos métodos anteriores: tempo, tamanho do banco de dados e experiência do operador.

Palavras-chave: Tomografia computadorizada. Canal mandibular. Automatização. Inteligência artificial.

ABSTRACT

OLIVEIRA, Larissa Aparecida Vaz. Automatic detection of the mandibular canal in cone-beam computed tomography. 2022. 52 f. 2022. 52 f. Dissertação (Mestrado em Saúde, Medicina Laboratorial e Tecnologia Forense) – Instituto de Biologia Roberto Alcântara Gomes, Rio de Janeiro, 2022.

The mandibular canal is a bony conduit located inside the mandible that carries the inferior alveolar neurovascular bundle. Several methods available in the literature implement channel segmentation, these being manual methods or based on deep learning, which are time consuming or demand a large amount of data, respectively. In this work, we present a semiautomatic computational method for segmentation of the mandibular canal in CT scans based on signal processing. The method begins with an axial cut located 10 mm above the base of the mandible, where the mandible is well delimited, making it possible to define an arc that describes it. Parasagittal slices are obtained, in which the mandibular canal can be detected as a circular structure using the Hough transformation. As the channel is not the only circular structure in such planes, the user selects the structure referring to the channel, and from this seed, the three-dimensional structure of the channel is defined, using the region growth algorithm in each of the oblique slices. In this study, the proposed method was applied to 25 Cone Beam Computed Tomography (CBCT) scans of different patients (21 women and 4 men aged between 11 and 75 years). The resulting volumes were visually evaluated by specialists, who noted how appropriate the volume obtained was. In addition, a statistical evaluation also pointed out the proximity of the volumes obtained by the methods and those defined by specialists (average IoU: 0.79). The specialists' visual evaluation and the statistical evaluation demonstrated the accuracy of the results achieved by the method. The segmentation presented in this work consists of a robust solution, in the sense that the volumes obtained are statistically close to the real volumes, in addition to innovating by overcoming the main challenges of previous methods: time, database size and operator experience.

Keywords: Computed Tomography. Mandibular canal. Automation. Artificial intelligence

LISTA DE FIGURAS

Figura 1 –	Seleção de corte axial inicial; 10 mm acima da base da mandíbula.....	19
Figura 2 –	Etapa inicial: limitarização. Área de interesse (região branca) > 1300.....	20
Figura 3 –	Exemplo da segunda etapa remoção de ruído que ocorre por meio de operações morfológicas.....	21
Figura 4 –	Ilustra o terceiro passo da esqueletização que consiste em encolher a imagem até que a área de interesse tenha 1 pixel de largura.....	21
Figura 5 –	Ilustra o terceiro passo da esqueletização que consiste em encolher a imagem até que a área de interesse tenha 1 voxel de largura.....	22
Figura 6 –	Exemplificação dos polígonos e áreas mencionadas.....	23
Figura 7 –	Obtenção dos cortes para localização do canal.....	25
Figura 8 –	Demonstração das estruturas circulares encontradas pelo software.....	26
Figura 9 –	Representação da equação da circunferência.....	27
Figura 10 –	Representação da matriz acumuladora usada para calcular a transformada de Hough.....	28
Figura 11 –	Seleção das sementes.....	28
Figura 12 –	Volume final da estrutura.....	29
Figura 13 –	Método comparativo da segmentação do canal.....	30
Figura 14 –	Representação dos volumes obtidos pelo método e especialista.....	31

LISTA DE TABELAS

Tabela 1 –	Valores em escala de cinza e em Hounsfield para diferentes materiais e em diferentes aparelhos.....	14
Tabela 2 –	Informações dos pacientes que compõe o dataset de avaliação do método de definição do arco	17
Tabela 3 –	Informações dos pacientes que compõe o dataset de avaliação do método de segmentação do canal mandibular	24
Tabela 4 –	Comparação entre o padrão ouro e os arcos obtidos por M2: DTW e IoU.....	32
Tabela 5 –	Comparação entre o padrão ouro e os volumes obtidos pelo método proposto (IoU).....	34
Tabela 6 –	Comparação entre o tempo de execução (em segundos) do método proposto (separado por passos) e o tempo de execução do método 3D-UNet para cada paciente (média e desvio padrão em 20 testes)	35

LISTA DE ABREVIATURAS E SIGLAS

CM	Canal Mandibular
IA	Inteligência Artificial
NAI	Nervo Alveolar Inferior
TC	Tomografia Computadorizada
TCFC	Tomografia Computadorizada de Feixe Cônico
TCMD	Tomografia Computadorizada Multidetectores
UH	Unidade Hounsfield

SUMÁRIO

	INTRODUÇÃO.....	12
1	OBJETIVOS.....	16
1.1	Geral.....	16
1.2	Específicos.....	16
2	MATERIAIS E MÉTODOS.....	17
2.1	Definição do arco.....	17
2.1.1	<u>Conjunto de dados.....</u>	18
2.1.2	<u>M2 – Método Definição do arco.....</u>	19
2.1.3	<u>Avaliação da qualidade metodológica do arco.....</u>	22
2.2	Segmentação do canal mandibular.....	24
2.2.1	<u>Conjunto de dados.....</u>	24
2.2.2	<u>Método – Segmentação do canal.....</u>	25
2.2.3	<u>Avaliação da qualidade metodológica do canal.....</u>	29
3	RESULTADOS.....	32
3.1	Resultados da definição do arco.....	32
3.2	Resultados da segmentação do canal mandibular.....	33
4	DISCUSSÃO.....	37
	CONCLUSÃO.....	39
	REFERÊNCIAS.....	40
	ANEXO – Dental arch definition in computer tomographs using two semi-automatic methods (artigo publicado).....	43

INTRODUÇÃO

O canal mandibular é um conduto ósseo localizado no interior da mandíbula, começando no forame mandibular e terminando no forame mental. A referida estrutura transporta o feixe neurovascular alveolar inferior composto por vasos linfáticos, veia, artéria alveolar inferior e o nervo alveolar inferior (NAI), que é o responsável pelo controle do sistema sensorial da região mandibular incluindo os dentes, gengiva e lábio inferior. Na maioria das vezes o CM apresenta-se como uma estrutura única, entretanto pode conter diversas variações como as denominadas: canal mandibular bífido, trifido e canal retromolar.⁽¹⁻⁴⁾

Procedimentos cirúrgicos e restauradores fazem parte da rotina do cirurgião-dentista⁽³⁾. A extração dos terceiros molares é um dos procedimentos mais realizados em cirurgia oral, uma das complicações mais comuns é o dano ao NAI⁽⁵⁾. Assim como os implantes orais que vem sendo utilizados rotineiramente, demandando análise pré-cirúrgica criteriosa⁽³⁾. Já a osteotomia sagital do ramo é um procedimento cirúrgico da ortognática que visa a correção de deformidades da mandíbula e devido ao curso e posição do canal mandibular o NAI corre grande risco de lesões durante o procedimento^(6, 7).

A identificação precisa do CM, previamente as cirurgias citadas acima é extremamente importante para o planejamento correto e minimização das complicações mais comuns: prejuízo somatosensoriais, sangramentos e hematomas^(1, 8). O leito cirúrgico deve ser avaliado por exame visual, palpação e pelas modalidades imaginológicas disponíveis. Hoje, tem-se muitas opções de imagem, contudo a tomografia computadorizada de feixe cônico (TCFC) em relação a radiografia panorâmica destaca-se por fornecer imagens tridimensionais que proporcionam visualização de estruturas anatômicas, incluindo a localização, forma e relação com as estruturas adjacentes⁽³⁾.

A TCFC produz imagens tridimensionais com alta resolução e precisão para a análise das estruturas ósseas maxilomandibulares e é amplamente utilizada na odontologia. A TCFC supera os erros de sobreposição, distorção e ampliação das radiografias panorâmicas e intraorais bidimensionais⁽⁹⁾. O volume da TCFC é reconstruído usando imagens de projeção obtidas de diferentes ângulos com um feixe em forma de cone e armazenadas como uma série de imagens axiais⁽¹⁰⁾. No entanto, na prática, existem alguns desafios associados à

segmentação do canal mandibular a partir de imagens de TCFC, como densidade imprecisa e grande quantidade de ruído⁽⁹⁾.

Na tomografia computadorizada (TC), a Unidade Hounsfield (UH) é proporcional ao grau de atenuação dos raios X e é alocada a cada voxel para mostrar a imagem que representa a densidade do tecido. A escala Hounsfield fornece um esquema padrão para dimensionar os coeficientes de atenuação reconstruídos em sistemas médicos de TC. Em TCFCs, o grau de atenuação dos raios X é mostrado em cinza escala (valor de voxel). Embora os fabricantes de TCFC e fornecedores de software apresentem escalas de cinza como UHs, é importante notar que essas medidas não são UHs verdadeiras. Até o momento, os fabricantes de sistemas TCFC odontológicos não utilizaram um sistema padrão para dimensionar os níveis de cinza que representam os valores reconstruídos. Na ausência de tal sistema, é difícil interpretar os níveis de cinza ou comparar os valores resultantes de diferentes máquinas⁽¹¹⁾.

Os resultados do estudo de Mah et. al.⁽¹¹⁾ indicaram uma forte relação linear entre as escalas de cinza em TCFC e UH em TC. Nesse estudo, para estudar a relação entre os níveis de cinza e propriedades de atenuação, considerou-se diferentes materiais em um phantom dentário 3D. A Tabela 1 mostra os valores na escala para diferentes materiais em diferentes aparelhos TCFC.

Tabela 1 – Valores em escala de cinza e em Hounsfield para diferentes materiais e em diferentes aparelhos

Tecido/ material	Asahi Alphard 3030 80 kV 5 mA	Hitachi CB MercuRay 120 kV 10 mA	Imaging Sciences i- Cat Next Generation 120 kV 5 mA	Imtec Iluma 120 kV 3.8 mA 0.3 mm voxel	Morita Veraview Epochs 70 kV 3 mA	NewTom VG 110 kV 1 mA	Planmeca ProMax 3D 82 kV 10 mA	Sirona Galileos 85 kV 35 mAs	Soredex Scanora 3D 85 kV 15 mA	Philips Brilliance 64 CT 120 kV 300 mA	Toshiba Aquilion CT 120 kV 300 mA
	Valor médio em escala de cinza										
Alumínio	2864	1453.6	862.9	2138.5	2335.2	2402	1751.7	1958.9	1288	2178	2595.4
Osso exterior	2425.4	1001.8	363.4	1324	1733.1	1389.2	1165.8	1504.9	897.2	1212.6	1698.9
Osso interior	723.5	148.4	-374.5	217.9	403	-86.5	-86	657.6	98.5	257.7	328.2
PMMA	213.3	-40.2	-489	96.6	49	-362.1	-368.2	522.2	-72.5	123.9	126.5
Músculo	185.5	-81.9	-527.2	12.3	45.8	-404.8	-380.9	479.3	-101.5	8.7	40.2
Água	161.5	-115.2	-533.3	6.2	27.7	-456.7	-394.2	464.6	-144.1	26.6	48
Adiposo	-89.1	-239.2	-611.6	-123.6	-147.1	-643.9	-532.5	362.6	-266.7	-115.2	-120.5
Ar	-991.9	-906.1	-1000	-957.8	-723.6	-839.5	-840.4	-32.3	-746.3	-805.5	-1073
	Valor correspondente em escala Hounsfield										
Alumínio	2962.1	2436.0	2534.1	2262.3	3381.7	2500.2	3285.3	2402.9	2103.6	2197.8	2534.2
Osso exterior	2441.3	1735.4	1633.3	1405.4	2507.2	1621.9	2395.9	1677.2	1534.4	1220.4	1648.4
Osso interior	616.8	411.8	302.5	241.6	575.3	342.2	495.7	322.8	371.0	253.7	294.1
PMMA	69.9	119.3	96.0	114.0	61.1	103.2	67.3	106.3	121.9	118.2	94.8
Músculo	40.1	54.6	27.1	25.3	56.5	66.2	48.1	37.8	79.7	1.6	9.6
Água	14.3	3.0	16.1	18.9	30.2	21.2	27.9	14.3	17.6	19.7	17.3
Adiposo	-254.3	-189.3	-125.1	-117.7	-223.7	-141.1	-182.1	-148.8	-161.0	-123.8	-149.2
Ar	-998.9	-998.9	-826.4	-995.4	-1061.1	-310.8	-649.4	-780.0	-859.6	-822.7	-1090.4

Fonte: Adaptado de Mah et. al ⁽¹¹⁾.

No estudo de Razi et al.⁽¹²⁾, essa relação entre valores na escala Hounsfield e valores de cinza em TCFC's é mensurada através de um experimento no qual uma cabeça de uma ovelha é escaneada com três aparelhos TCFCs e um aparelho CT. Para o TCFC Newtom VG, a equação da regressão encontrada para essa relação foi $HU = 14,621 + 1,088 \times \text{escala de cinza}$ ($R^2 = 0,997$). Para Scanora Soredex a equação da regressão foi $HU = -24,052 + 1,146 \times \text{escala de cinza}$ ($R^2 = 0,989$). No Planmeca, a equação da regressão foi $HU = -61,098 + 1,178 \times \text{escala de cinza}$ ($R^2 = 0,979$).

Neste trabalho, esse aspecto foi considerado, de forma que os valores usados no método de definição do arco estão expressos em valores de cinza de TCFCs.

Conforme mencionado anteriormente, a TCFC é o principal exame de imagem utilizado para detectar o canal mandibular do paciente. Na literatura tem-se disponível vários métodos publicados de segmentação do CM, porém, em sua maioria se apresentam como métodos demorados e imprecisos. Por conta do baixo contraste da estrutura em relação aos tecidos adjacentes a visualização se mostra complexa, por este fator a segmentação automática torna-se um desafio⁽¹³⁾.

No que tange análise e processamento de imagens médicas, as técnicas computacionais mais sofisticadas disponíveis atualmente empregam inteligência artificial (IA). A IA é um amplo domínio que combina a ciência e a engenharia do desenvolvimento de sistemas e máquinas inteligentes que podem realizar funções cognitivas humanas complexas, como resolução de problemas, reconhecimento de estrutura e palavras e tomada de decisão. A IA se integrou ao nosso cotidiano direta e indiretamente por meio de assistência digital (Siri da Apple, Google Now, Alexa da Amazon, Cortana da Microsoft...), anúncios, filtragem de e-mail, respostas inteligentes, detecção automática e outros campos essenciais, como medicina, onde está em desenvolvimento contínuo. O aprendizado de máquina, uma subdivisão da IA, permite que os algoritmos aprendam e prevejam padrões de dados, enquanto o aprendizado profundo permite esse processo usando dados brutos maiores⁽¹⁴⁾.

O trabalho visa incentivar a comunidade científica a aprofundar soluções para as tarefas de segmentação do canal mandibular. Vários métodos disponíveis na literatura implementam a segmentação do canal, sendo eles métodos manuais ou baseados em aprendizado profundo, que são demorados ou demandam uma grande quantidade de dados, respectivamente. Neste trabalho, apresentamos um método computacional automático preciso e rápido para segmentação do canal mandibular em tomografias computadorizadas de feixe cônico baseado em processamento de sinais, formado por duas etapas principais: definição do arco e segmentação de canal em cortes parassagitais.

1 OBJETIVOS

1.1 Geral

Este estudo tem como objetivo avaliar e desenvolver os métodos de diagnóstico por imagens de TCFC de mandíbula. Desenvolver um software capaz de detectar automaticamente o canal mandibular de maneira simplificada e com o máximo de precisão afim de otimizar tempo nos laudos radiográficos e sendo útil na tomada de decisão médica, nos planejamentos para execução correta e segura de procedimentos invasivos.

1.2 Específicos

Os objetivos específicos são:

- a) Criar bancos de dados: Definição do arco e localização do canal;
- b) Apresentar métodos para definição do arco;
- c) Apresentar método para localização do Canal;
- d) Realizar interface simplificada para execução e apresentação dos métodos;

2 MATERIAIS E MÉTODOS

O processo de encontrar o canal mandibular proposto neste trabalho consiste em duas etapas principais: definição do arco e segmentação do canal. Como parte do processo de identificação do canal mandibular na TCFC, os especialistas tendem a definir cortes parassagittais em que essa estrutura pode ser mais facilmente visualizada. Esses cortes são definidos como perpendiculares a curva que denota o arco do paciente. Nesse sentido, a definição do arco consiste em uma primeira etapa no processo de detecção do canal mandibular ^(15,16,17). A segunda etapa consiste em encontrar a região correspondente ao canal mandibular em cada um dos cortes parassagittais obtidos a partir do arco definido na etapa anterior. O Comitê de Ética em Pesquisa correspondente aprovou este estudo (CAAE, registrado no Ministério da Saúde do Brasil sob o número 24279314100005259).

2.1 Definição do arco

Tabela 2 – Informações dos pacientes que compõe o dataset de avaliação do método de definição do arco

ID do paciente	Idade	Região coberta pelo exame	Espaçamento Dos Cortes (mm)
1	57	Mandíbula	0.2
2	46	Mandíbula	0.2
3	21	Mandíbula	0.2
4	43	Mandíbula	0.2
5	26	Mandíbula	0.125
6	29	Maxila e mandíbula	0.2
7	53	Mandíbula	0.2
8	36	Crânio total	0.2
9	21	Mandíbula	0.2

10	11	Mandíbula	0.2
11	33	Mandíbula	0.2
12	25	Mandíbula	0.2
13	15	Maxila e mandíbula	0.2
14	21	Mandíbula	0.2
15	29	Mandíbula	0.2
16	25	Mandíbula	0.2
17	29	Mandíbula	0.2
18	35	Mandíbula	0.2
19	69	Mandíbula	0.2
20	75	Mandíbula	0.2
21	51	Mandíbula	0.2
22	36	Mandíbula	0.2
23	33	Mandíbula	0.2
24	43	Mandíbula	0.2
25	44	Mandíbula	0.2

Fonte: A autora, 2022.

2.1.1 Conjunto de dados


As TCFCs utilizadas neste trabalho foram adquiridas na Policlínica Piquet Carneiro, polo de saúde vinculado à Universidade do Estado do Rio de Janeiro, com um tomógrafo computadorizado Cone Beam iCat®. Os dados utilizados neste estudo consistem em um conjunto de 25 exames de TCFC de 25 pacientes diferentes: 21 mulheres e 4 homens. Dentre eles tomografias de crânio total ou da região mandibular. Idade 11 a 75 anos com desvio padrão de 15,52 pounds. Os dados foram anonimizados, para que os pacientes não pudessem

ser identificados. Todos esses exames abrangem pelo menos parte da região mandibular, mas alguns não são focados especificamente nela. As informações do conjunto de dados estão resumidas acima na Tabela 2. Essas diferenças se devem à falta de dados disponíveis, o que, por um lado, pode ser considerado uma limitação. Por outro lado, utilizar dados com características diferentes promove uma avaliação mais robusta, uma vez que os métodos propostos são testados considerando diferentes cenários.

2.1.2 M2 – Método Definição do arco

A primeira parte do método proposto consiste em definir um arco que delimite a mandíbula, a partir do qual são obtidos cortes parassagittais nos quais se detecta o canal mandibular. Para a definição do arco, é selecionado um corte axial. O corte localizado 10mm acima da base da mandíbula é inicialmente selecionado para ser utilizado neste processo de definição como demonstrado na Figura 1.

Figura 1 – Seleção de corte axial inicial; 10 mm acima da base da mandíbula



Fonte: A autora, 2022.

Posteriormente é realizada a binarização que neste método seleciona os voxels acima de 1300, na figura 2 observa-se o *foreground* e os demais compondo o *background*. Operações morfológicas são aplicadas para retirada de ruído e finalmente uma esqueletização é aplicada para definição do arco^(18, 19).

Figura 2 – Etapa inicial: limitarização. Área de interesse (região branca) > 1300



Fonte: A autora, 2022.

A definição do arco a partir deste corte é realizada seguindo três etapas:

A etapa inicial deste método consiste em uma operação de limiarização, que resulta em uma imagem binária (em dois tons, geralmente preto e branco para facilitar a visualização). Nesta imagem binária, os pontos/voxels considerados como área de interesse (região em branco) são aqueles com valores acima de 1300 na escala de tons de cinza TCFC. Desta forma, toda a região mandibular, entre outras áreas, é destacada em branco. Pontos abaixo desse limite são considerados como plano de fundo (em preto).

Em seguida, na segunda etapa é realizada a limpeza do ruído, por meio de operações morfológicas (*dilation, filling e opening*).


Figura 3 – Exemplo da segunda etapa remoção de ruído que ocorre por meio de operações morfológicas



Fonte: A autora, 2022.


Por fim, na terceira etapa, a esqueletização (transformação da imagem até que a área de interesse tenha 1 voxel de largura) é aplicada a essa imagem binária e processada para definir o arco.

Figura 4 –Ilustra o terceiro passo da esqueletização que consiste em encolher a imagem até que a área de interesse tenha 1 voxel de largura



Fonte: A autora, 2022.

Figura 5– Exemplo do arco resultante obtido pelo método proposto, em azul, comparado anotação do especialista, em verde.



Fonte: A autora, 2022.


2.1.3 Avaliação da qualidade metodológica do arco

Para avaliação do método de definição automática do arco, um especialista analisou o corte axial definido pelo método (10mm acima da base da mandíbula) e traçou a arcada dentária nesse corte. Esse processo foi realizado para os exames de todos os pacientes. As arcadas definidas pelo especialista foram comparadas com as arcadas obtidas pelo método. Essa comparação foi realizada por meio de duas métricas Dynamic Time Warping (DTW) e Intersecção sobre União (IoU)⁽²⁰⁾. O DTW é uma medida de similaridade entre séries temporais (conjunto de dados com ordem específica, independentemente da quantidade). O IoU compara as áreas dos polígonos cujos vértices são denotados pela sequência de pontos que compõem o arco. Quanto à similaridade, o valor ótimo e máximo para IoU é 1, o que denota

que a área de interseção dos dois polígonos é idêntica à área definida por sua união, ou seja, os polígonos são iguais⁽²¹⁻²³⁾.

A Figura 6 exemplifica os polígonos e áreas mencionados. A Figura 6a mostra o polígono definido pelo arco mandibular obtido através do Método M2, e a Figura 6b mostra o polígono definido pelo padrão ouro. O índice Jaccard/IoU consiste em calcular a divisão da área de sobreposição (Figura 6c) de duas regiões consideradas pela área resultante da união dessas duas regiões (Figuras 6d).

Figura 6 – Exemplificação dos polígonos e áreas mencionadas



Legenda: Polígono definido pelo arco obtido por M2 (em azul) (a), polígono definido pelo arco definido pelo especialista (em vermelho) (b), interseção entre as áreas dos polígonos a e b (em roxo) (c), e união das áreas dos polígonos a e b (em amarelo) (d).

Fonte: A autora, 2022.

Desta forma, este trabalho compara o arco anotado pelo especialista com os arcos obtidos pelos métodos propostos calculando o IoU de seus polígonos correspondentes, quanto maior o valor de IoU, mais semelhantes são os arcos. Um valor de IoU baixo denota que a interseção cobre uma pequena parte da área de união, ou seja, uma parte significativa dos polígonos não coincide, indicando uma grande disparidade. Observa-se que o IoU é bastante sensível aos pontos que limitam inferiormente o arco (primeiro e último ponto).

2.2 Segmentação do canal mandibular

2.2.1 Conjunto de dados

De forma similar à etapa anterior, as TCFCs utilizadas nessa fase também foram adquiridas na Policlínica Piquet Carneiro com um tomógrafo Cone Beam iCat®. Assim, para a avaliação do método da segmentação do canal mandibular foi selecionado um conjunto de 20 exames do mesmo banco de dados de TCFC utilizados na primeira etapa: 17 mulheres e 3 homens. Dentre eles tomografias de crânio total ou da região mandibular. Idade 11 a 71 anos com desvio padrão de 19,05 pounds. As informações do conjunto de dados usado estão resumidas na Tabela 3.

Tabela 3 – Informações dos pacientes que compõe o *dataset* de avaliação do método de segmentação do canal mandibular


ID do paciente	Idade
1	38
2	40
3	67
4	17
5	68
6	39
7	71
8	23
9	20
10	11
11	43
12	26
13	29
14	50
15	21
16	11
17	33
18	25
19	15
20	57

Fonte: A autora, 2022.

2.2.2 Método – segmentação do canal

A partir do arco definido como na etapa anterior, são obtidos cortes parassagittais, nos quais o canal mandibular pode ser facilmente detectado visualmente como uma estrutura circular. Para esta próxima etapa, os cortes parassagittais obtidos são apresentados ao usuário através da interface, que é mostrada nesta figura, e o usuário navega entre eles, selecionando um deles em que o canal esteja claramente visível.

Figura 7 – Obtenção dos cortes para localização do canal




Nota: São obtidos planos transversais, perpendiculares ao arco. Canal mandibular: estrutura circular; O usuário usa a interface e seleciona um dos planos em que o canal é claramente visível.

Fonte: Autora, 2022

Então, para cada corte parassagittal, o software indica estruturas circulares que potencialmente poderiam fazer parte do canal, como pode-se verificar na Figura 8. Tais estruturas são detectadas automaticamente usando a transformação de Hough. Esse processo define uma representação na forma de parâmetros que representam uma forma geométrica que se deseja encontrar em uma imagem do espaço digital (x,y). Entretanto, observa-se que o canal não é a única estrutura circular nos planos transversais considerados.

Figura 8 – Demonstração das estruturas circulares encontradas pelo software




Nota: O software indica estruturas circulares detectadas usando a transformação de Hough; Nota-se que o canal não é a única estrutura circular no plano.

Fonte: Autora, 2022

A transformação de Hough (TH) ^(24,25) é um método de reconhecimento de formas em imagens digitais. A TH foca em formas parametrizáveis, ou seja, que possuam uma equação conhecida para sua construção. Neste trabalho foi considerando o círculo, já que a forma parametrizável que mais se aproxima da aparência que o canal assume em imagens transversais. Círculos podem ser descritos através de uma equação paramétrica, conforme mostrado na Figura 9.

Figura 9 – Representação da equação da circunferência




Fonte: A autora, 2022.

A ideia da TH é mapear a imagem, no caso deste trabalho o corte transversal, que consiste em uma matriz bidimensional, para uma representação de parâmetros no espaço n -dimensional, em que n é o número de parâmetros que descrevem a curva que se deseja encontrar na imagem. Para isto, esta representação de parâmetros é discretizada e representada na forma de uma matriz n -dimensional de inteiros, chamada de matriz acumuladora, em que cada posição da matriz corresponde a um conjunto de parâmetros de uma curva.

Assim, para a detecção de círculo considerando sua equação polar, varia-se os seguintes parâmetros: a coordenada de centro (x,y) e o raio r . Dessa forma temos uma matriz tridimensional conforme a Figura 10. Em cada posição da matriz verifica-se o círculo correspondente, ou seja o círculo definido pelo centro e raio correspondentes à posição na matriz. Por exemplo, a posição $(0,0,1)$ correspondente ao círculo de raio 1 cujo centro está na posição $(0,0)$ na imagem transversal. Para cada um desses círculos, seus pontos, obtido através da equação, são comparados com as coordenadas da imagem. Caso uma coordenada corresponda a um ponto de objeto (ponto branco), a célula na matriz acumuladora correspondente aos parâmetros desse círculo é incrementada em uma unidade. Ao final desse processo as posições da matriz com os valores mais altos correspondem ao conjunto de parâmetros dos círculos que melhor se encaixam na imagem.


Figura 10 – Representação da matriz acumuladora usada para calcular a transformada de Hough



Fonte: Adaptada de⁽²¹⁾.

Dessa forma, esse processo indica os círculos mais visíveis na imagem. Entretanto, observa-se que o canal não é a única estrutura circular nos cortes considerados. Dessa forma, é solicitada a interação do usuário: o usuário seleciona a estrutura referente ao canal clicando sobre ela (Figura 11). A partir desse círculo selecionado pelo usuário, denominado semente, é definida a estrutura tridimensional do canal, selecionando para cada projeção transversal o círculo mais próximo do círculo do canal de seu vizinho imediato, de forma interativa.

Figura 11 – Seleção das sementes




Nota: O usuário seleciona a estrutura referente ao canal (semente); A estrutura tridimensional do canal é definida; Para cada projeção transversal: Seleciona o círculo mais próximo iterativamente; Os círculos obtidos são agregados para criar uma estrutura tridimensional.

Fonte: Autora, 2022.

Por fim, os círculos obtidos são agregados para criar uma estrutura tridimensional (Figura 12) e os pontos que pertencem a essa estrutura são destacados na visão tridimensional do exame.

Figura 12 – Volume final da estrutura



Nota: Em verde temos os volumes alcançados pelo método.
Fonte: A autora, 2022.


2. 2.3 Avaliação da qualidade metodológica do canal

A primeira avaliação dos canais obtidos através do método foi uma avaliação qualitativa visual por parte de um especialista humano. Para tal avaliação, o especialista humano observou os volumes obtidos, e analisou se eles se aproximavam visualmente aos canais reais observados nos exames.

Para avaliação numérica quantitativa do método de segmentação do canal, um único especialista em radiologia oral avaliou usou o software *InVesalius*⁽²⁶⁾ e visualizou os cortes axiais, sagitais e coronais e apontou nesses cortes a região correspondente ao canal mandibular. Para isso, o especialista utilizou a ferramenta “Definição de região de interesse”, conforme a Figura 13. A ferramenta consiste em um círculo que deve ser posicionado na região desejada através do cursor. O raio do círculo pode ser ajustado conforme necessário. A interação com o usuário ao usar essa ferramenta do *Invesalius* é semelhante à interação realizada no software que implementa o método proposto, desenvolvido em parceria com o

Instituto de Computação da Universidade Federal Fluminense - UFF. O diferencial do software desenvolvido nesse trabalho é já oferecer ao usuário áreas circulares candidatas à região do canal, sem que seja necessário ajustar o diâmetro do círculo, bem como definir sua posição. Tais tarefas são feitas de forma completamente manual no Invesalius durante a definição dos canais pelo especialista, que serão usados como método para comparação com os canais obtidos com o software proposto.

Figura 13 – Método comparativo da segmentação do canal



Nota: Tela do software Invesalius usado na definição manual do canal (padrão ouro). Aba lateral: ferramenta seleção de região de interesse.

Fonte: A autora, 2022.


Essa comparação é realizada usando a versão 3D da métrica Intersecção sobre União (IoU). Nesse caso, o IoU compara os volumes definidos manualmente pelo especialista (padrão ouro) e os volumes obtidos através do método. De forma similar ao cálculo 2D, para o IoU 3D, o valor ótimo e máximo para a similaridade apontado pelo IoU é 1, o que denota que a intersecção dos dois volumes é idêntica sua união, ou seja, os volumes são iguais. Nota-se que para o IoU 3D, os pontos que definem os volumes são denotados através de três coordenadas (x,y,z) ao invés de duas (x,y).

Desta forma, para avaliar a performance do método proposto, considerando a similaridade entre o canal anotado pelo especialista e os canais obtidos pelo método, calcula-se o IoU, quanto maior o valor de IoU, mais semelhantes são os volumes. De forma semelhante ao IoU 2D usado na avaliação dos arcos, para o IoU 3D um valor de IoU baixo

também denota que a interseção cobre uma pequena parte da de união, ou seja, uma parte significativa dos volumes não coincide, indicando uma grande disparidade.

A Figura 14 exemplifica os volumes mencionados. A Figura 14a simboliza uma parte do volume obtido através do método proposto, e a Figura 14b simboliza uma parte do volume definido como padrão ouro. O IoU consiste em calcular a divisão do volume denotado pela sobreposição (Figura 14c) dos dois volumes pelo volume resultante da união desses dois volumes (Figura 14d).

Figura 14 – Representação dos volumes obtidos pelo método e especialista



Legenda: Representação de volume obtido por método proposto (em azul) (a), Representação de volume definido pelo especialista (em vermelho) (b), interseção entre os volumes a e b (em roxo) (c) e união dos volumes a e b (em amarelo) (d).

Fonte: A autora, 2022.

3 RESULTADOS

3.1 Resultados da definição do arco

Na Tabela 4 são apresentados os valores de medição da proximidade entre os arcos encontrados pelo método desenvolvido e os arcos definidos pelo especialista.

Tabela 4 – Comparação entre o padrão ouro e os arcos obtidos por M2: DTW e IoU

ID do paciente	DTW	IoU
1	1.220	0.826
2	1.736	0.760
3	1.147	0.768
4	0.818	0.826
5	0.748	0.766
6	0.645	0.684
7	0.558	0.817
8	2.208	0.947
9	6.603	0.868
10	1.134	0.565
11	0.971	0.880
12	0.776	0.869
13	1.646	0.393
14	1.154	0.733
15	1.628	0.931
16	0.952	0.931
17	1.987	0.692
18	0.868	0.872
19	3.248	0.931

20	0.907	0.656
21	0.865	0.953
22	1.106	0.745
23	0.830	0.682
24	0.876	0.349
25	1.032	0.445
Média	1.427	0.755
Desvio padrão	1,231	0,170

Fonte: Autora, 2022

Como mencionado anteriormente, a qualidade do resultado do método depende muito do corte axial selecionado como entrada (Y).

3.2 Resultados da segmentação do canal mandibular

Conforme detalhado na seção 2, a partir das arcadas obtidas pelo método M2, os cortes parassagittais foram extraídos e através deles as regiões do canal mandibular, as quais foram agregadas para formação de volumes que definem o canal no exame. Esses volumes foram avaliados estatisticamente, também baseado no IoU. Na tabela 5, estão listados os valores de IoU obtidos entre os volumes definidos pelo método proposto e os volumes de padrão ouro correspondentes. Para fins de comparação, a Tabela 5 também inclui os valores de IoU dos volumes obtidos pelo do método 3D-UNet, que é atualmente o estado da arte para este problema.

Tabela 5 – Comparação entre o padrão ouro e os volumes obtidos pelo método proposto (IoU)

ID do canal (Paciente e lado direito e esquerdo)	3D-UNet	Método proposto
1D	0,824	0,813
1E	0,701	0,709
2D	0,751	0,748
2E	0,731	0,729
3D	0,792	0,903
3E	0,698	0,769
4D	0,782	0,768
4E	0,702	0,742
5D	0,609	0,643
5E	0,79	0,783
6D	0,866	0,866
6E	0,837	0,93
7D	0,874	0,992
7E	0,579	0,601
8D	0,666	0,719
8E	0,689	0,717
9D	0,86	0,837
9E	0,706	0,703
10D	0,88	0,975
10E	0,825	0,843
11D	0,871	0,861
11E	0,717	0,798
12D	0,75	0,808
12E	0,641	0,64
13D	0,689	0,725
13E	0,825	0,936
14D	0,633	0,671
14E	0,738	0,754
15D	0,724	0,716
15E	0,785	0,852
16D	0,828	0,914
16E	0,684	0,743
17D	0,632	0,625
17E	0,818	0,869
18D	0,684	0,665
18E	0,881	0,919
19D	0,849	0,891
19E	0,776	0,79
20D	0,753	0,847
20E	0,751	0,775
Média	0,755	0,79
Desvio padrão	0,081	0,098

Legenda: Representação da divisão da mandíbula de cada paciente em lado direito (D) e Esquerdo E.

Fonte: A autora, 2022.

O tempo de execução do método, ou seja, quanto tempo é necessário para obter o volume 3D referente ao canal através do método proposto aqui, assim como o tempo de execução do método 3D-UNet pode ser encontrado na Tabela 6, para fins de comparação.

Tabela 6 – Comparação entre o tempo de execução (em segundos) do método proposto (separado por passos) e o tempo de execução do método 3D-UNet para cada paciente (média e desvio padrão em 20 testes)

	Método proposto					
ID do canal	Definição de arco		Criação de estrutura 3D a partir da semente		3D-UNet (passo único)	
	Média	Desvio padrão	Média	Desvio padrão	Média	Desvio padrão
1D	1,121	0,065	5,457	0,018	24,922	0,88
1E	0,961	0,084	3,925	0,029	24,248	0,907
2D	0,878	0,143	5,424	0,002	12,897	0,408
2E	1,118	0,058	3,231	0,022	12,793	0,698
3D	1,039	0,077	3,307	0,016	21,894	1,042
3E	0,981	0,110	3,92	0,026	21,875	0,966
4D	0,947	0,075	3,797	0,014	17,093	0,954
4E	1,079	0,017	3,392	0,002	16,959	0,976
5D	0,963	0,090	5,054	0,005	24,935	1,177
5E	0,966	0,105	3,62	0,021	24,909	1,268
6D	0,91	0,034	4,726	0,003	18,768	1,195
6E	0,939	0,158	5,127	0,002	18,909	0,423
7D	0,933	0,026	5,469	0,022	12,194	0,331
7E	0,961	0,020	3,425	0,022	12,259	0,769
8D	1,011	0,003	3,714	0,024	31,672	1,062
8E	0,892	0,014	5,341	0,024	31,282	1,215
9D	0,889	0,070	5,423	0,007	16,909	0,509
9E	1,054	0,028	4,685	0,027	16,908	0,932
10D	1,029	0,030	4,395	0,032	12,166	0,915
10E	0,92	0,138	5,089	0,014	12,032	0,897
11D	1,097	0,009	3,517	0,014	16,079	0,994
11E	1,032	0,088	4,302	0,002	15,947	0,606
12D	0,923	0,041	5,480	0,012	15,965	0,871
12E	1,019	0,121	3,254	0,014	15,902	1,143
13D	0,884	0,057	3,212	0,016	19,689	1,092
13E	1,012	0,003	4,149	0,006	19,520	1,189
14D	0,965	0,115	4,399	0,011	27,913	1,264
14E	0,938	0,034	4,674	0,032	28,124	0,778

15D	0,93	0,079	5,034	0,02	12,755	0,948
15E	0,927	0,040	4,172	0,009	12,838	1,041
16D	0,973	0,134	5,515	0,035	15,065	1,163
16E	0,951	0,086	3,897	0,017	15,201	0,770
17D	1,024	0,097	3,847	0,025	16,019	0,809
17E	0,885	0,073	5,085	0,012	15,847	0,415
18D	1,094	0,048	4,595	0,011	13,463	0,981
18E	1,065	0,138	3,176	0,013	13,708	0,659
19D	0,908	0,104	3,759	0,003	16,524	0,503
19E	1,057	0,147	5,325	0,04	16,779	1,056
20D	1,118	0,152	3,378	0,018	28,079	0,904
20E	1,028	0,072	4,773	0,033	27,978	1,287

Fonte: A autora, 2022.

4 DISCUSSÃO

Em relação ao método de definição da arcada M2 bone slice, inicialmente apresentado na fase anterior da pesquisa, este foi estendido e automatizado. Os novos passos incluíram a obtenção de cortes transversais e a detecção de arcada foi avaliada através de duas métricas: DTW e IoU, e teve resultados adequados. Na etapa anterior do trabalho desenvolvemos um outro método M1 – Teeth slice. Entretanto devido ao baixo desempenho, foi decidida a sua exclusão e aprimoramento de M2. O motivo dos resultados inferiores de M1 pode ter sido causado pela presença de artefatos nos exames utilizados nos experimentos, principalmente artefatos metálicos, o que levou à inclusão de ruído na área de primeiro plano da imagem binária, uma vez que artefatos criam região com voxels cujo valor de intensidade é na mesma gama de câmaras dentárias.

Para a definição do arco, é selecionado um corte axial. Neste trabalho foi padronizado que inicialmente será selecionado o corte 10mm acima da base da mandíbula. Porém os usuários podem optar por utilizar outro corte que for julgado mais adequado.

Em justificativa ao número menor de exames utilizados na segunda etapa está a dificuldade do especialista eleito demarcar todos os volumes, uma vez que não foi encontrado outros especialistas para colaboração.

Em alguns casos as discordâncias entre o DTW e IoU são devido ao tamanho da área de diferença entre os polígonos gerados que não correspondem necessariamente a área de interesse do estudo. Observa-se que o IoU é bastante sensível aos pontos que limitam inferiormente o arco (primeiro e último ponto). Dessa forma pequenas diferenças nesses pontos interferem na precisão das comparações e não significando necessariamente a discrepância em região de interesse anatômico.

Em relação à segunda etapa, de definição do volume do canal mandibular, os volumes resultantes foram inicialmente avaliados visualmente por especialistas, que observaram a adequação do volume obtido. A avaliação dos especialistas demonstrou a precisão dos resultados alcançados pelo método.

Conforme já detalhado anteriormente neste texto, há atualmente métodos sofisticados baseados em aprendizado profundo para segmentação do canal mandibular. Entre eles, destaca-se o método 3D-UNet, proposto por ⁽²⁷⁾, que atualmente pode ser considerado estado da arte para o problema, devido a excelente qualidade dos volumes por ele obtidos ⁽²⁷⁾. Assim,

para fins de comparação, este trabalho considerou o método 3D-Unet como um referencial. Ao observar a qualidade dos volumes obtidos por ambos métodos para o dataset considerado neste estudo, observa-se que os valores de IoU encontram-se muito próximos. Nota-se que o desempenho do método aqui proposto é sutilmente inferior ao método 3D-UNet, o que demonstra quão desafiantes são os casos que compõe o dataset deste estudo. Por outro lado, o método proposto neste trabalho alcança valores de IoU significativamente altos, próximo ao estado da arte, o que demonstra o bom desempenho do método proposto e a qualidade dos volumes obtido por ele.

Ao avaliar o tempo total de execução dos métodos, observa-se o maior atrativo do método aqui proposto em comparação a outros métodos de segmentação de canal mandibular vistos na literatura. Apesar da qualidade dos volumes obtidos pelo 3D-UNet estar bem próxima da que foi obtido neste trabalho, o tempo de execução é significativamente maior, o que pode ser considerado uma grande desvantagem em contextos de saúde como considerado neste trabalho. Além disso, o método aqui proposto não depende de uma fase de treinamento, como os métodos de aprendizado profundo entre eles o 3D-UNet. Isso não só diminui o tempo de implementação da solução, como também isenta da necessidade de um grande dataset para alcançar bons resultados. Tal vantagem é significativa, já que em contextos como o tratado aqui os dados, especialmente os anotados, são escassos⁽²⁸⁾.

Este trabalho abordou a segmentação 3D do canal mandibular. Ressalta-se a importância de anotações em nível de voxel para a tarefa, o qual foi uma das contribuições do trabalho, reunindo um novo conjunto de dados com rótulos de granulação fina. Resultados experimentais confirmam a grande relevância de anotações 3D de alta qualidade.

Como ganho secundário do método, destaca-se o passo intermediário de definição do arco, o qual pode ser utilizado não só dentro do processo de segmentação do canal, mas também em outros contextos como geração de imagens panorâmicas a partir de TCFCs.

Por fim, ao analisar visualmente os volumes obtidos, é possível observar que a região de maior dificuldade para a segmentação é a área que caracteriza o trabeculado ósseo, sendo essa região a de maior discrepância entre o volume obtido e o método de referência. Tal fenômeno já era esperado, já que estudos de radiologia odontológica já haviam apontado a dificuldade de definir o canal mandibular nessas regiões mesmo por especialistas humanos.

CONCLUSÃO

A segmentação apresentada neste trabalho consiste numa solução robusta, no sentido que os volumes obtidos são próximos estatisticamente dos volumes reais (média IoU: 0,79), além de inovar ao superar os desafios dos métodos anteriores, i.e., exigindo participação mínima do usuário, otimizando o tempo, e não dependendo de um grande conjunto de dados para sua implementação (como os métodos de aprendizado profundo).

Como ganho secundário do método, destaca-se o passo intermediário de definição do arco, o qual pode ser utilizado não só dentro do processo de segmentação do canal, mas também em outros contextos como geração de imagens panorâmicas a partir de TCFCs.

Foi alcançado o desenvolvimento do software capaz de detectar automaticamente o canal mandibular de maneira simplificada e com o máximo de precisão afim de otimizar tempo nos laudos radiográficos e sendo útil na tomada de decisão médica, nos planejamentos para execução correta e segura de procedimentos invasivos.

REFERÊNCIAS

1. Sukovic P. Cone beam computed tomography in craniofacial imaging: Cone beam CT in craniofacial imaging. *Orthodontics & Craniofacial Research*. 2003;6(1):31–36
2. White SC, Pharoah MJ. *Oral radiology: principles and interpretation*. Amsterdam: Elsevier, 2009.
3. Braun S, Hnat WP, Fender DE, Legan HL. The form of the human dental arch. *Angle Orthod*. 1998;68(1):29–36.
4. Zhu S, Fang H, Zhang D (2021). An Algorithm for Automatically Extracting Dental Arch curve. *Journal of Physics: Conference Series*. 2021;2082:012018. doi:10.1088/1742-6596/2082/1/012018
5. Sa-ing V, Wangkaoom K, Thongvigitmanee SS. Automatic dental arch detection and panoramic image synthesis from CT images. In: 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, Osaka. 2013;p 6099–6102.
6. Chanwimaluang T, S Sotthivirat S, Sinthupinyo W. Automated dental arch detection using computed tomography images. In: 9th International Conference on Signal Processing. IEEE, Beijing, China, 2008.
7. Gao H, Chae O. Automatic Tooth Region Separation for Dental CT Images. In: Third International Conference on Convergence and Hybrid Information Technology. IEEE, Busan, Korea, 2008. p.897–901.
8. Luo T, Shi C, Zhao X, et al. Automatic Synthesis of Panoramic Radiographs from Dental Cone Beam Computed Tomography Data. *PLoS ONE*. 2016; 11:e0156976. DOI: 10.1371/journal.pone.0156976
9. Fouda SM, Ellakany P, Madi M, Zakaria O, Al-Harbi FA, El Tantawi M. Do Morphological Changes in the Anterior Mandibular Region Interfere with Standard Implant Placement? A Cone Beam Computed Tomographic Cross-Sectional Study. *ScientificWorldJournal*. 2020;2020:8861301.
10. Kwak GH, Kwak EJ, Song JM, Park HR, Jung YH, Cho BH, Hui P, Hwang JJ. Automatic mandibular canal detection using a deep convolutional neural network. *Sci Rep*. ;10(1):5711. DOI: 10.1038/s41598-020-62586-8.
11. Mah P, Reeves TE, McDavid WD. Deriving Hounsfield units using grey levels in cone beam computed tomography. *Dentomaxillofacial Radiology*. 2010;39(6):323–35.
12. Razi T, Niknami M, Alavi Ghazani F. Relationship between Hounsfield Unit in CT Scan and Gray Scale in CBCT. *Journal of Dental Research*. *Dental Clinics: Dental Prospects*. 2014;8(2): 107–110.

13. Papakosta TK, Savva AD, Economopoulos TL, et al. An automatic panoramic image reconstruction scheme from dental computed tomography images. *Dentomaxillofacial Radiology*. 2017; 46:20160225. DOI: 10.1259/dmfr.20160225
14. Issa J, Olszewski R, Dyszkiewicz-Konwińska 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):560.
15. Yun Z, Yang S, Huang E, et al. Automatic reconstruction method for high-contrast panoramic image from dental cone-beam CT data. *Computer Methods and Programs in Biomedicine* 2019;175:205–214. DOI:10.1016/j.cmpb.2019.04.024
16. ZouH, Tan Q. Research of dental arch curve extraction and application. In: 2012 IEEE International Conference on Information and Automation. IEEE, Shenyang, China; 2012.p 455–457.
17. Serra J (1994) Morphological filtering: An overview. *Signal Processing* 38:3–11. [https://doi.org/10.1016/0165-1684\(94\)90052-3](https://doi.org/10.1016/0165-1684(94)90052-3)
18. Lee TC, Kashyap RL, Chu CN. Building Skeleton Models via 3-D Medial Surface Axis Thinning Algorithms. *CVGIP: Graphical Models and Image Processing*. 1994; 56:462–478. <https://doi.org/10.1006/cgip.1994.1042>
19. Efrat A, Fan Q, Venkatasubramanian S. Curve Matching, Time Warping, and Light Fields: New Algorithms for Computing Similarity between Curves. *J Math Imaging Vis*. 2007; 27:203–216. DOI:10.1007/s10851-006-0647-0
20. Bansal S, Kamper H, Goldwater S, Lopez A. Weakly supervised spoken term discovery using cross-lingual side information. In: 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, New Orleans, LA, pp 5760–5764
21. Shokoohi-Yekta M, Hu B, Jin H, et al. Generalizing DTW to the multi-dimensional case requires an adaptive approach. *Data Min Knowl Disc*. 2017; 31:1–31. DOI:10.1007/s10618-016-0455-0
22. Meert W, Hendrickx K, Craenendonck TV. wannesm/dtaidistance v2.0.0. Zenodo; 2020.
23. Lin T-Y, Maire M, Belongie S, et al. Microsoft COCO: Common Objects in Context; 2014.
24. Azevedo E, Conci A. *Computação gráfica: teoria e prática*. Elsevier; 2003.
25. Macedo MM. *Detecção e extração de redes vasculares usando transformada de Hough* Tese (Doutorado em Ciência da Computação) - Universidade de São Paulo, São Paulo; 2012.
26. De Moraes TF, Amorim PH, Azevedo FS, da Silva JV. InVesalius: an open-source imaging application. *Computational vision and medical image processing: Vipimage*. 2011;28:405-8.

27. 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.
28. Moran MBH, Faria MDB, Bastos LF, Giraldi GA, Conci A. Combining Image Processing and Artificial Intelligence for Dental Image Analysis: Trends, Challenges, and Applications. In: Johri P, Diván MJ, Khanam R, Marciszack M, Will A, editors. *Trends and Advancements of Image Processing and Its Applications*. Cham: Springer International Publishing; 2022; p. 75–105. (EAI/Springer Innovations in Communication and Computing). DOI:10.1007/978-3-030-75945-2_4

ANEXO – Dental arch definition in computer tomographs using two semi-automatic methods (artigo publicado)

Medical & Biological Engineering & Computing
<https://doi.org/10.1007/s11517-022-02684-z>

ORIGINAL ARTICLE



Dental arch definition in computed tomographs using two semi-automatic methods

Larissa Aparecida Vaz Oliveira¹ · Maira Beatriz Hernandez Moran^{1,2} · Marcelo Daniel Brito Faria^{1,3} ·
 Luciana Freitas Bastos¹ · Gilson Giralddi⁴ · Luiz Antonio Ribeiro da Rosa⁵ · José Firmino Nogueira Neto⁶ · Aura Conci²

Received: 23 January 2022 / Accepted: 17 September 2022
 © International Federation for Medical and Biological Engineering 2022

Abstract

Computed tomography is a widely used image examination in dental imaging that provides an accurate location of oral structures and features, including the dental arch, which is an important anatomical feature. This study proposes two new semi-automatic methods for arch definition in CTs, with minimal user effort. This study includes 25 CT examinations. The first method is based on the teeth pulps, and the second one is based on the whole mandible. The methods use thresholding and morphological operations to obtain the arches. The evaluation process includes two different metrics DTW and IoU. For both metrics, the initial results of M1 were very low, but the average performance of M2 can be considered high. The analysis showed that changing the input improves the M1 results substantially. The promising results presented here suggest that these methods can be used as auxiliary tools for the proposed task.

Keywords Dental arch · Tomography · Computer programs · Software tools

1 Introduction

Computed tomography (CT) is a widely used image examination in dental imaging. It is employed in the diagnosis and treatment of several oral conditions. Due to its tridimensional nature, this exam can be considered a complement

of bi-dimensional image examinations (intra and extra-oral radiographs) [1]. This exam provides an accurate location of anatomical structures, which is valuable information in implant site assessment, surgery planning, rapid prototyping, and cephalometric analysis, among others [2].

The dental arch is an important anatomical feature that is intrinsically related to the configuration of the oral anatomy and its structures, such as supporting bones, teeth, and oral musculature [3]. Several mathematical functions were proposed for modeling the dental arch's shape [3]. Defining the dental arch is essential in order to characterize the patient's anatomy and propose adequate treatments. Moreover, the arch definition consists of an intermediary step in the detection of several other anatomical structures, such as the alveolar bone, for example. This analysis is mostly performed visually by experts, who inspect image examinations, especially tomographs, in order to denote the dental arch. Since this is a manual process, it demands time and effort. In this way, the implementation of computational solutions that automatize this process, or at least part of it, would be helpful to support processes such as orthodontic treatment planning.

Previous works in the literature presented efforts to determine the dental arch in CTs' 3D exams. Zhu et. al. [4] present a method in which the first step consists of a selection of a range for the axial slices. The slices in this range mainly

✉ Maira Beatriz Hernandez Moran
 mbernandez@id.uff.br

¹ Núcleo de Radiologia Odontológica, Policlínica Piquet Carneiro, Universidade do Estado do Rio de Janeiro, Avenida Marechal Rondon, 381, Rio de Janeiro, RJ 20950-003, Brazil

² Instituto de Computação, Universidade Federal Fluminense, Av. Gal. Milton Tavares de Souza, s/n, Niterói, RJ 24210-346, Brazil

³ Faculdade de Odontologia, Universidade Federal do Rio de Janeiro, Av. Pedro Calmon, 550, Rio de Janeiro, RJ 21941-617, Brazil

⁴ Laboratório Nacional de Computação Científica, Av. Getúlio Vargas, 333, Petrópolis, RJ 25651-076, Brazil

⁵ Instituto de Radioproteção e Dosimetria, Comissão Nacional de Energia Nuclear, Rio de Janeiro, Brazil

⁶ Faculdade de Ciências Médicas, Universidade Do Estado Do Rio de Janeiro, Avenida Marechal Rondon, 381, Rio de Janeiro, RJ 20950-003, Brazil

contain the mandible. A statistical analysis determined the range, which was 140 to 240. The slices in this range had their values adjusted considering the histogram of a template CBCT data. The maximum intensity projection (MIP) is obtained from the adjusted slices and treated with a Gaussian filter. Then a segmentation of the dental arch area was performed. For that, the thresholding operation was applied to achieve a binary image, from which the arch is finally obtained by a skeletonization. In order to evaluate the proposed method, a visual evaluation was performed to analyze the results of applying the method to the 40 exams of different patients with the same dimensions ($480 \times 480 \times 320$). According to the authors, the method successfully extracted the dental arch. Nevertheless, visual inspection of results can be considered subjective. An exact measurement of results would be preferable. Another limitation of this method is that it is highly dependent on a specific exam specification, with a fixed number of slices, losing generalization, which denotes that it is not applicable to other cases that are not close to the considered dataset.

The method presented by Sa-Ing et al. [5] starts with a manual selection of the CT axial slice that would be used as input, which is then resized and treated with the morphological operations closing. Then, thresholding is performed to obtain a binary image. After that, hole filling is applied, followed by a morphological thinning to achieve an initial curve. The curve-fitting algorithm is applied to this curve to smoothen it and obtain the dental arch. In order to test the method, a visual assessment of the results was performed for 120 CT images, and four cases were presented in the article. The cases presented demonstrated good performance. Nevertheless, a visual assessment can be too subjective, as previously mentioned.

Chanwimaluang et al. [6] presented a method that includes thresholding, local entropy, and connected component labeling. The slice selection was not specified. The thresholding technique implemented in this method consists of the local entropy thresholding, which is calculated by defining a threshold value based on the second-order entropy of the co-occurrence matrix. The obtained binary image is treated with a connected component labeling in order to remove isolated pixels and a morphological dilation. After that, a thinning operation is performed, followed by a curve fitting to achieve the dental arch. The method's evaluation was performed considering 60 CT images (taken from 6 different data sets), varying in dimensions from 400×400 to 512×512 . The analysis of results was also performed by visually assessing the obtained curves.

Other works focus on other objectives, such as the generation of panoramic images from CT exams, so the arch definition is an intermediary step of their processes. In this way, their evaluation focuses on the generated panoramic images, not on the obtained arch.

Gao and Chae [7] proposed a method for the dental arch definition based on curve fitting as part of a tooth separation method. The process of dental arch definition in this work is performed in all axial slices of the exam, and the longest arch among all of them is selected as the final dental arch. In this way, for each axial slice, a region of interest is manually defined, consisting of a small rectangle containing all teeth regions. Then, thresholding is performed to obtain the binary image. A dilation is applied to this image to connect all teeth, followed by a hole-filling, resulting in a teeth area. To select among the teeth areas obtained from each of the processed slices, the method considers three constraints: maximal area, symmetry w.r.t the middle vertical line, and whether the top of the teeth region is above the middle horizontal line. After selecting the region that meets these constraints, thinning is performed to obtain the central curve of the teeth region, followed by a curve fitting considering a fourth-order polynomial curve to obtain the arch shape. It is important to highlight that the method presented in this work defines two different dental arches for upper and lower teeth. Since this work does not focus on the arch definition, the results of this step are not evaluated, only the final tooth region separation, which is the main objective of this work.

The work presented by Luo et al. [8] aims to obtain a panoramic-like image from a CBCT exam, and for that, it defines an intermediary step that defines the dental arch. For that, the MIP is obtained and then segmented using a threshold that is obtained by combining values extracted from a k-means++ clustering and a spatial threshold. After that, the least squares fitting (LSF) algorithm is used for fitting a parabola in the isolated dental area. The final arch is acquired by calculating the Hermite cubic spline function. Since the objective of this work is also to obtain a panoramic image from a CBCT, the obtained arches are not evaluated.

The method proposed by Papakosta et al. [9] defines preliminary dental arches for all slices and then uses these arches to define the final arch, similar to [7], in a process that demands high processing time. The first step of this method is using a training set to define a template polynomial, which describes the shape and curvature of a typical dental arch. In this work, pre-operative and post-operative acquisitions from 21 patients were used, and eight exams composed the training set. In these exams, the number of axial slices varied from 322 to 327, but the resolution of each axial slice was constant (400×400). Then an optional step was to apply a registration to align the pair of exams of each patient, correcting any possible brightness and contrast differences between them. Binary images were obtained using a threshold defined by the linear combination of the two parameters of a Gaussian function obtained by an iterative non-linear least squares fitting. Then the following morphological operations were applied: hole filling, closing, and thinning. Finally, the result of the thinning process is

modeled as a sixth-degree polynomial, which is compared to the template polynomial extracted from the training data set. This comparison is performed using the root mean square error (RMSE) so that curve that minimizes the RMSE metric is considered the dental arch. In this work, once more, the main objective was to obtain a panoramic image. Nevertheless, the arches achieved in the process were evaluated by comparing them with the mentioned template. However, since this template was also obtained computationally, the evaluation could be improved. It would be preferable to compare the arches with experts' annotations.

The method proposed by Yun et al. [10] initially generates a MIP image of the coronal slices. A threshold filter is applied to the coronal MIP image to obtain the mask image of the teeth. The threshold value T is calculated based on the image histogram, which is fitted by a Gaussian curve. The mean and standard deviation of this Gaussian function are combined to obtain T . Considering the area obtained in the resultant binary image, a range of axial slices is selected. Then, a MIP image of these axial slices is calculated. The resultant axial MIP is transformed into a binary image using the same thresholding process as the coronal MIP. After that, the axial MIP is treated with Gaussian smoothing, and skeletonization is applied to obtain an initial curve, from which using control points equally spaced are extracted. The final arch is achieved by generating a cubic spline curve from the control points. This method was applied to exams of 129 patients, with the number of slices ranging from 322 to 541 and dimension 512×512 per slice. Similar to the previously mentioned works, this work aims to obtain a panoramic image, so the dental arches' evaluation is performed only by visually inspecting these curves.

In the mentioned works, two scenarios were observed for result evaluation: (1) the evaluation of the obtained arches consisted of a visual assessment, and the authors observed very promising results; (2) the evaluation of the arches was omitted for being out of the work's scope, i.e., for not being the work's main objective. For works that included a visual evaluation of arches, even considering that the cases included in such articles demonstrated good visual results, an important limitation of these works is the lack of a numerical measurement to estimate the method's performance. On the other hand, one of the most interesting insights extracted from these works is the successful application of morphological operations for dental arch definition.

Other semi-automatic methods were also presented in the literature [11], but they require the manual selection of points to obtain the final arches, which demands a substantial effort from the users.

The main objective of our work is to implement computational solutions that partially automatize the dental arch detection in oral computed tomographs (CTs), overcoming the limitations of previous solutions, i.e., demanding

minimal user participation, not depending on a huge dataset for its implementation, and providing robustly evaluated results. For that, in this work, we propose two new semi-automatic methods for arch definition in CTs. In order to measure the quality of these new solutions, we propose the use of two different metrics in order to provide a more robust analysis of the methods' performance. In this way, this work presents a more complete evaluation in comparison with previous works in literature, which only present visual evaluations. Finally, along with the arch's definition itself, which is a significant contribution to the process of oral tomograph assessment, the proposed semi-automatic methods can be included in other processes, such as the generation of panoramic images from CT exams and the detection of different oral structures.

2 Materials and methods

2.1 Dataset

The correspondent Research Ethics Committee approved this study (CAAE, registered at the Brazilian Ministry of Health as 24,279,314,100,005,259). The CTs used in this work were acquired at Policlínica Piquet Carneiro, an institute associated with the State University of Rio de Janeiro, with a Xoran Technologies® Cone Beam CT scanner. The data used in this study consist of a set of 25 CT exams from 25 different patients: 21 women and 4 men. The data were anonymized, so the patients could not be identified. All of these exams cover at least part of the mandibular area, but some of them are not focused specifically on it. The dataset information is summarized in Table 1. These differences are due to the lack of available data, which on the one hand, can be considered a limitation. On the other hand, using data with different characteristics promotes a more robust evaluation since the proposed methods are tested considering different scenarios.

For all these exams, a ground truth/gold standard is established. The ground truth definition includes an expert who is an experienced dentist specialized in oral radiology. In this process, an auxiliary software tool developed by one of the authors was used. In this tool, the expert navigates toward the axial slices of each CBCT exam and selects one slice to perform the arch definition manually. This same slice (S_y) is used as the input of the proposed methods (see details in Sections 2.3 and 2.4). Using the visual interface, the user clicks on a sequence of points to define a dental arch in the selected axial slice. The arches manually defined by the expert for each exam are considered the ground truth in the evaluation.


Table 1 Dataset information

Patient id	Age	Slice thickness	Region covered	Number of slices in exam (N)
1	57	0.2	Maxilla	320
2	46	0.2	Maxilla	238
3	21	0.2	Mandible	608
4	43	0.2	Mandible	320
5	26	0.125	Mandible	320
6	29	0.2	Maxilla and mandible	400
7	53	0.2	Mandible	320
8	36	0.3	Full head	256
9	21	0.2	Mandible	256
10	11	0.2	Mandible	304
11	33	0.2	Mandible	640
12	25	0.2	Mandible	272
13	15	0.2	Maxilla and mandible	336
14	21	0.2	Mandible	304
15	29	0.2	Mandible	304
16	25	0.2	Mandible	240
17	29	0.2	Mandible	448
18	35	0.2	Mandible	304
19	69	0.2	Mandible	192
20	75	0.2	Mandible	320
21	51	0.2	Mandible	320
22	36	0.2	Mandible	288
23	33	0.2	Mandible	272
24	43	0.2	Mandible	304
25	44	0.2	Mandible	304

2.2 M1–pulp-based method

Both methods presented in this work consist of semi-automatic computerized methods. In this sense, both methods include user participation in part of their process. This participation consists in selecting one slice, in which the arch is visible at most, i.e., the users choose the best axial slice, the one that they would use in their manual arch definition. Formally, a CT is an exam composed of N axial slices $S_1, S_2, S_3, \dots, S_N$, and the user selects a y -th slice S_y , where $1 < y < N$ (Fig. 1). Observe that N varies for every exam (Table 1) according to the resolution and slice thickness used in its acquisition. After this initial step, the methods follow different approaches.

The first method (M1) defines the dental arch based on the teeth pulp. For that, the m -th slice (S_m) is used as input, being $m = y - (0.14 * N)$, where y is the index of the slice S_y selected by the user. For example, consider patient 1's exam, which is composed of 320 axial slices ($N = 320$), and that the user

**Fig. 1** Example of axial slices, detail: y -th slice selected by the user

selected as the 280-th slice ($y = 280$), then $m = 280 - (0.14 * 320) \approx 235$. In this case, the input of M1 would be slice S_{235} . Each of M1's next steps is exemplified in Fig. 2.

After defining the input slice, M1 performs a binarization in S_m , using a thresholding procedure (Fig. 2a): the slice's pixels whose values are between 800 and 1300 denote the foreground (white area in Fig. 2a), and the pixels whose values are not in that range are considered background (black area in Fig. 2a). This range was selected empirically by testing different limits and observing to which anatomical structures these limits refer. The pixels that are in the lower half of the image are also considered as background. The limits of the foreground range were estimated considering the Hounsfield values described in previous studies for different types of tissues. We not only aimed to cover the pulp regions but also to exclude other tissues, such as soft tissues (denoted by the Hounsfield values below 700), and harder structures, such as the enamel (denoted by the Hounsfield values above 1700). In this way, the 800 and 1300 limit values were defined and tested empirically in order to ensure that the corrected regions (pulp) were covered.

After binarization, morphological operations [12] are applied to the binary image (Fig. 2b). Such operations consist of closing, with a square of side 5 as the structural element, followed by a dilation, using a square of side 3 as the structural element. In order to eliminate possible noise, all the foreground's connected regions with areas lower than 140 pixels are transformed into the background. Finally, the centroids of the resultant foreground areas are calculated, resulting in the points that define the arch.

Fig. 2 Results of each M1 steps. **a** Binarization **b** Morphological operations and resultant centroids (in red)





Fig. 3 Results of each M2 steps: **a** binarization, **b** morphological operations, and **c** skeletonization

2.3 M2-mandible-based method

The second method takes as the input slice that the user selected (S_y). Each of M2's step is exemplified in Fig. 3. A binary image is also obtained using a thresholding process, but in M2, the pixels considered as foreground are the ones with values above 1300. In this way, the foreground in this slice would cover harder tissues, like enamel and mandible borders. In other words, the whole mandibular region, among other areas, denotes the foreground (Fig. 3a).

The next step in M2 is a sequence of morphological operations (Fig. 3b): a dilation, using a square of side 10 as the structural element, a morphological flood-fill, and an opening (structural element is a square of size 20). The dilation operation aims to remove possible noise in the binary image, such as small regions disconnected from the mandible. The flood-fill unifies the entire region, filling all regions inside the mandible borders, resulting in a unique structure as the foreground. Then the opening

operation softens the borders of the obtained structure, removing filaments perpendicular to the main structure that could negatively affect the arch definition.

Finally, in order to obtain a curve that defines the arch, skeletonization [13] is applied to this image in order to define the final arch (Fig. 3c). Skeletonization provides an effective and compact representation of the topologic and geometric properties of the object by reducing its dimensionality, which is performed by shrinking the object (foreground) until the area of interest is 1-pixel wide. As a result, a 1-pixel wide curve denoting the center of the structure's shape is obtained. This curve is the arch provided by M2.

All image processing operations were performed using the *scikit image*¹ library for *Python*, which provides implementations of the skeletonization and all other morphological operations.

¹ <https://scikit-image.org/docs/stable/api/skimage.morphology.html>

2.4 Evaluation of the methods' performance

As mentioned in Section 2.2, the evaluation of the proposed methods considers the arches manually defined by the expert as the ground truth. In order to assess the results of the proposed methods, two different evaluations are performed for both methods. The first one evaluates how close are the curves that define the arches obtained by M1 and M2 from the ones denoted by an expert. This curve similarity can be measured by the dynamic time warping (DTW). In the DTW analysis, the curves/arches are described as ordered sequences of points that can be considered time series [14]. One of the main advantages of using DTW is its capacity to handle one-to-many alignments, i.e., it can properly find the similarity of 2-time series with different numbers of elements.


DTW is a widely employed approach for analyzing and measuring time series for different applications. It is commonly used in tasks such as clustering, classification, and similarity search, in which data can be represented as time series [15]. Nevertheless, DTW demands a reasonable computational effort due to its complexity [15].

Although DTW is mainly used in problems that involve single-dimensional data, it can be generalized for multi-dimensional cases [16]. Note that the data used in this work to define an arch is an ordered set of points, which can be described as a 2D time series due to its ordered nature. This work used the *dtai* package [17] Python implementation of multi-dimensional time series DTW, which is based on a dynamic programming approach.

In order to provide another measure to compare and evaluate the arches defined by the proposed methods, the Jaccard index, or Intersection over Union (IoU) [18], is also used in this analysis. The similarity analysis provided by IoU focuses on a geometric perspective in the sense that it compares the areas of the polygons whose vertex are denoted by the sequence of points that compose the arch. Concerning the similarity, the optimal and maximal value for IoU is 1, which denotes that the area of the intersection of the two polygons is identical to the area defined by their union, i.e., the polygons are equal.

Figure 4 exemplifies the mentioned polygons and areas. Figure 4a shows the polygon defined by the arch obtained through M2, and Fig. 4b shows the polygon defined by the

Fig. 4 Polygon defined by the arch obtained by M2 (in blue). **b** Polygon defined by the arch defined by the expert (in red). **c** Intersection between the areas of the polygons a and b (in purple). **d** Union of the areas of the polygons a and b (in yellow)



ground truth. The Jaccard index/IoU consists of calculating the division of the overlapping area (Fig. 4c) of two considered regions by the area resultant from the union of these same regions (Fig. 4d).

In this way, this work compares the arch annotated by the expert (ground truth) with the arches obtained by the proposed methods by calculating the IoU of their correspondent polygons; the higher the IoU value, the more similar are the arches. A low IoU value denotes that the intersection covers a small part of the union area, i.e., a significant part of the polygons does not match, indicating a large disparity.

3 Results

Table 2 presents the DTW and IoU values per patient for both M1 and M2 methods.

Table 2 Comparison between the arches obtained by M1 and M2 and the ground truth: Dynamic Time Warping (DTW) and Intersection over Union (IoU)

Patient ID	DTW		IoU	
	M1	M2	M1	M2
1	1.134	1.220	0.411	0.826
2	0.952	1.736	0.320	0.760
3	1.071	1.147	0.125	0.768
4	0.960	0.818	0.201	0.826
5	1.402	0.748	0.410	0.766
6	1.342	0.645	0.259	0.684
7	1.312	0.558	0.191	0.817
8	1.057	2.208	0.183	0.947
9	1.013	6.603	0.227	0.868
10	1.181	1.134	0.206	0.565
11	1.024	0.971	0.182	0.880
12	1.274	0.776	0.340	0.869
13	1.307	1.646	0.067	0.393
14	1.343	1.154	0.291	0.733
15	1.481	1.628	0.284	0.931
16	1.307	0.952	0.233	0.931
17	1.527	1.987	0.116	0.692
18	0.968	0.868	0.151	0.872
19	1.199	3.248	0.275	0.931
20	1.164	0.907	0.130	0.656
21	1.194	0.865	0.251	0.953
22	1.432	1.106	0.336	0.745
23	1.219	0.830	0.302	0.682
24	1.252	0.876	0.399	0.349
25	1.074	1.032	0.222	0.445
Mean	1.208	1.427	0.244	0.755
Standard deviation	0.166	1.231	0.093	0.170

The M1 method provided very low results (Table 2), which denotes that the arches obtained by M1 differ hugely from the ground truth. On the other hand, the average performance of M2 can be considered high based on the IoU values. However, in some cases, it also presents poor results. These cases for M2 are the exams whose patient IDs are 10, 13, 24, and 25.

The quality of the results of both methods highly depends on the slice selected as input (S_y). In order to identify which part of the methods, the automatic or manual/non-automatic part, promoted these poor results, M1 was applied to other slices. In this sense, if the results are better when applied to other slices of the same exams, one can imply that the manual slice selection (non-automatic part of the method) was inappropriate, negatively affecting the results. These new results are shown in Table 3.

As previously exposed in the Introduction section, to the best of our knowledge, the evaluation of methods proposed in previous works consisted of visual analysis of the obtained arches. In this way, Figs. 5 and 6 present five arches obtained for methods M1 and M2, respectively, for visual evaluation. Figure 5 shows an example of the resultant arch obtained by the M1 method (in blue) compared to the expert's annotation (in green).

Figure 6 shows an example of the resultant arch obtained by the M2 method (in blue) compared to the expert's annotation (in green).

4 Discussion

The arch definition in CT examinations can be considered an important task for the generation of panoramic images and the assessment of oral structures. Previous works [4–6] have proposed different methods for this task, but there is a lack of quantitative metric-based analyses to evaluate the performance of such methods. In this study, not only two new methods were proposed for this task but also an evaluation process was defined, including two different metrics, in order to provide a more robust analysis of the methods' performance.

Table 2 demonstrates that the results of the M2 method are substantially better for the considered cases based on the IoU metric. This low performance of M1 may be caused by the presence of artifacts in the exams used in the experiments, especially metal artifacts, due to the high X-ray absorption by high-density metallic objects, which led to the inclusion of noise in the foreground area of the binary image since artifacts create regions with pixels whose intensity values are in the same range of teeth pulps. The streaks resultant from the effect of the presence of metallic structures present values close to the anatomic structures used to define the arch. This can be observed by their similar white tones. In this way, regions affected by


Table 3 Comparison between the ground truth and the arches obtained by M1 using other slices as input

Patient ID	DTW	IoU
1	0.218	0.656
2	0.195	0.762
3	0.200	0.620
4	0.158	0.831
5	0.393	0.267
6	0.198	0.769
7	0.159	0.788
8	0.195	0.575
9	1.289	0.501
10	0.121	0.776
11	0.189	0.629
12	0.169	0.632
13	0.203	0.647
14	0.178	0.691
15	0.354	0.368
16	0.180	0.575
17	0.209	0.617
18	0.289	0.405
19	0.171	0.649
20	0.207	0.531
21	0.189	0.614
22	0.185	0.715
23	0.288	0.434
24	0.240	0.541
25	0.249	0.447
Mean	0.257	0.602
Standard deviation	0.224	0.141

artifacts are included in the binary image as foreground, leading to completely erroneous arches.

Other factors that may affect M1's performance are edentulous patients and crowded teeth. In these cases, the patient's anatomical variation does not allow an appropriate definition of the arch. Since the main structure considered in M1 as the basis to define the arch is the teeth pulp when the teeth are not ideally positioned, the resultant arch is miscalculated, and its format does not approximate a normal dental arch curvature. For patients that present crowded teeth, the obtained arch follows the irregular pathway, resulting in a sinuous serrated format. On the other hand, and missing teeth would lead M1 to lose the level of detail in the arch, with parts being approximated by large straight lines, missing important arch curvatures. In this way, it might be interesting to include edentulous patients and crowded teeth as exclusion factors.

On the other hand, for the DTW metric, the M1 method appears to present a better performance considering the average value. Nevertheless, it is important to observe that the

**Fig. 5** Arches obtained by the M1 (in blue) and expert's annotation (in green)

standard deviation of DTW values for M2 is large. Moreover, when one analyzes the values by comparing M1 vs. M2 for each patient, it is perceptible that, in most cases, M2 achieved lower DTW distances. However, for cases 2, 8, 9, and 19, not only the M2 DTW distance was higher but also this difference was substantial, impacting the average value significantly.

Moreover, the manual/non-automatic part of M1 has a major impact on the results of this method. As demonstrated in Table 3, the results of M1 were substantially better, for both IoU and DTW, when the method was applied to other slices of the exams. This is due to the variations in the pulps' visibility from one slice to another. Low visibility of pulps




Fig. 6 Arches obtained by the M2 (in blue) and expert's annotation (in green)

in the selected slice has a similar effect on the resultant arch for the cases of edentulous patients, i.e., the lack of pulps in a certain region would determine a pathway that does not follow the mandibular shape, poorly affecting the curvature. In this sense, a more appropriate approach to define the slice to be used as input of M1 could be assessed in future works.

In some cases, the discrepancies between the DTW and IoU are due to the specificities of each of these metrics. It is observed that the IoU is quite sensitive to the points that limit the arch inferiorly (first and last points), which hugely impacts the generated polygons and does not necessarily correspond to the area of interest of the study. Thus, small

differences in these points interfere with the accuracy of the comparisons and do not necessarily mean a great discrepancy in the region of anatomical interest. This can be considered a limitation of the analysis presented here.

Regarding the visual analysis of the results, the arches obtained by M1 consisted of irregular, serrated curves (Fig. 5). On the other hand, the arches obtained by M2 consisted of regular curves closer to the ground truth (Fig. 6). In this way, the superiority of M2 can also be observed visually. Moreover, the obtained arches presented similar visual quality to the ones presented in previous related works. Unfortunately, the lack of public datasets restricts the comparison, preventing a more extensive assessment.

5 Conclusions

The arch definition in CT examinations is an important task for the generation of panoramic images and the assessment of oral structures. In this study, two new methods (M1 and M2) for arch definition in CTs are presented, in addition to a quantitative evaluation process including two different metrics. The initial results of M1 were very low, and the analysis performed showed that the manual/non-automatic part of M1 had a major negative impact on its results since the results of M1 were significantly better when the input manual selection was modified. The average performance of M2 can be considered high, even considering that, in some cases, it presents poor results. The promising results presented here suggest that these methods can be used as auxiliary tools for the proposed task. Future works include an automatic method to select the input slice and a more extensive evaluation of the proposed methods, including more cases.

Acknowledgements This work is supported by the Health Department of the State of Rio de Janeiro. A.C. is partially supported by MACC-INCT, CNPq Brazilian Agency (402,988/2016–7 and 305,416/2018–9) and FAPERJ (project SIADE-2). We would like to thank the Professional Master's program in Health, Laboratory Medicine and Forensic Technology at UERJ.

References

1. Sukovic P (2003) Cone beam computed tomography in craniofacial imaging: cone beam CT in craniofacial imaging. *Orthod Craniofac Res* 6:31–36. <https://doi.org/10.1034/j.1600-0544.2003.259.x>
2. White SC, Pharoah MJ (2009) *Oral radiology: principles and interpretation*. Mosby/Elsevier, St. Louis, Missouri
3. Braun S, Hnat WP, Fender DE, Legan HL (1998) The form of the human dental arch. *Angle Orthod* 68:29–36. [https://doi.org/10.1043/0003-3219\(1998\)068%3c0029:TFOTHD%3e2.3.CO;2](https://doi.org/10.1043/0003-3219(1998)068%3c0029:TFOTHD%3e2.3.CO;2)
4. Zhu S, Fang H, Zhang D (2021) An algorithm for automatically extracting dental arch curve. *J Phys: Conf Ser* 2082:012018. <https://doi.org/10.1088/1742-6596/2082/1/012018>

5. Sa-ing V, Wangkaom K, Thongvigitmanee SS (2013) Automatic dental arch detection and panoramic image synthesis from CT images. In: 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, Osaka, 6099–6102
6. Chanwimaluang T, Sotthivirat S, Sinthupinyo W (2008) Automated dental arch detection using computed tomography images. In: 2008 9th International Conference on Signal Processing. IEEE, Beijing, China, 737–740
7. Gao H, Chae O (2008) Automatic tooth region separation for dental CT images. In: 2008 Third International Conference on Convergence and Hybrid Information Technology. IEEE, Busan, Korea, 897–901
8. Luo T, Shi C, Zhao X et al (2016) Automatic synthesis of panoramic radiographs from dental cone beam computed tomography data. *PLoS One* 11:e0156976. <https://doi.org/10.1371/journal.pone.0156976>
9. Papakosta TK, Savva AD, Economopoulos TL et al (2017) An automatic panoramic image reconstruction scheme from dental computed tomography images. *Dentomaxillofacial Radiology* 46:20160225. <https://doi.org/10.1259/dmfr.20160225>
10. Yun Z, Yang S, Huang E et al (2019) Automatic reconstruction method for high-contrast panoramic image from dental cone-beam CT data. *Comput Methods Programs Biomed* 175:205–214. <https://doi.org/10.1016/j.cmpb.2019.04.024>
11. Zou H, Tan Q (2012) Research of dental arch curve extraction and application. In: 2012 IEEE International Conference on Information and Automation. IEEE, Shenyang, China, 455–457
12. Serra J (1994) Morphological filtering: an overview. *Signal Process* 38:3–11. [https://doi.org/10.1016/0165-1684\(94\)90052-3](https://doi.org/10.1016/0165-1684(94)90052-3)
13. Lee TC, Kashyap RL, Chu CN (1994) Building skeleton models via 3-D medial surface axis thinning algorithms. *CVGIP: Graphical Models Image Process* 56:462–478. <https://doi.org/10.1006/cgip.1994.1042>
14. Efrat A, Fan Q, Venkatasubramanian S (2007) Curve matching, time warping, and light fields: new algorithms for computing similarity between curves. *J Math Imaging Vis* 27:203–216. <https://doi.org/10.1007/s10851-006-0647-0>
15. Bansal S, Kamper H, Goldwater S, Lopez A (2017) Weakly supervised spoken term discovery using cross-lingual side information. 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, New Orleans, LA, pp 5760–5764
16. Shokoohi-Yekta M, Hu B, Jin H et al (2017) Generalizing DTW to the multi-dimensional case requires an adaptive approach. *Data Min Knowl Disc* 31:1–31. <https://doi.org/10.1007/s10618-016-0455-0>
17. Meert W, Hendrickx K, Craenendonck TV (2020) wannesm/dtaidistance v2.0.0. Zenodo
18. Lin T-Y, Maire M, Belongie S et al (2014) Microsoft COCO: common objects in context. In: Fleet D, Pajdla T, Schiele B, Tuytelaars T (eds) *Computer Vision – ECCV 2014*. Springer International Publishing, Cham, pp 740–755

Publisher's note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Springer Nature or its licensor holds exclusive rights to this article under a publishing agreement with the author(s) or other rightsholder(s); author self-archiving of the accepted manuscript version of this article is solely governed by the terms of such publishing agreement and applicable law.

Larissa Aparecida Vaz Oliveira is a Master's student in Health, Laboratory Medicine and Forensic Technology at Universidade Estadual do Rio de Janeiro (UERJ). She obtained a Bachelor in Odontology,

and a Specialization in Radiology and Oral Imaging at Universidade Federal do Rio de Janeiro (UFRJ). Her research interests are intelligent systems, radiology, and oral imaging.

Maira Beatriz Hernandez Moran is a Ph.D. student in the Computing Institute at Universidade Federal Fluminense (UFF). She obtained a Bachelor in Computer Science at Universidade Estadual do Norte Fluminense Darcy Ribeiro and a Master in Computing at UFF. Her research interests are image processing and analysis, artificial intelligence, and health information systems.

Marcelo Daniel Brito Faria holds a degree in Dentistry from Universidade Gama Filho, a Master in Dental Radiology, and a Ph.D. in Dental Radiology from Universidade Estadual de Campinas (Unicamp). He has his MBA in Executive Health from UFRJ and his MBA in Management and Public Innovation from UERJ. He is a Professor of Dental Radiology and Psychology applied to Dentistry at UERJ. He is also a Professor of Oral Radiology at UFRJ. His main research interest is dentistry, with an emphasis on radiology.

Luciana Freitas Bastos holds a degree in Dentistry from the Universidade do Grande Rio, a Master's degree in Social Dentistry from the UFF, and a Ph.D. in Dentistry from UFRJ. She is an Associate Professor at UERJ and Coordinator of the Dentistry Sector at Policlínica Piquet Carneiro. Her research interests are dentistry, public health, cariology, and psychology in dentistry.

Gilson Giraldo holds a degree in Mathematics from Pontifícia Universidade Católica de Campinas, a master's degree in Applied Mathematics from the Universidade Estadual de Campinas and a Ph.D. in Systems and Computer Engineering from UFRJ. He is currently Head Researcher at Laboratório Nacional de Computação Científica. His research interests are segmentation, image processing, statistical learning, and fluid animation.

Luiz Antonio Ribeiro da Rosa obtained Bachelor in Physics, a Master in Nuclear Engineering from UFRJ, a Ph.D. in Nuclear Physics from the Universidade de São Paulo, and a postdoc in Solid State Dosimetry applied to Medical Physics performed at GSF National Research Center for Environment and Health. He is currently a Researcher at the National Nuclear Energy Commission, working in the Division of Medical Physics of the Institute of Radioprotection and Dosimetry. He is a member of the Brazilian Association of Medical Physics, the Brazilian Physics Society and the Health Physics Society (USA). His research interests are solid state dosimetry, Monte Carlo modeling applied to medical physics and occupational radiological protection.

José Firmino Nogueira Neto is a Professor in the Department of Pathology, Medical Sciences Laboratory, and the Postgraduate Program in Health, Laboratory Medicine and Forensic Technology at UERJ. He has obtained a Bachelor of Photo-Pharmaceutical Biochemistry from Universidade Federal de Pernambuco, Specialization in Clinical Pathology, and Ph.D. in Clinical and Experimental Pathophysiology from UERJ. Member of the Brazilian Society of Clinical Analysis and has experience in auditing for Accreditation of Clinical Laboratories in organizations such as Bureau Veritas Quality International, among others.

Aura Conci obtained Bachelor of Civil Engineer from Universidade Federal do Espírito Santo, Master and Doctor in Civil Engineering from Pontifícia Universidade Católica do Rio de Janeiro. She is a Professor in the Computing Institute at UFF. She has coordinated and participated in several international projects funded by Erasmus+, among others. Her research interests are numerical methods and visual computing, computer graphics, image analysis, image processing, biomedical images, and pattern recognition.