

LUIZ GUILHERME KASPUTIS ZANINI

**IDENTIFICAÇÃO, CLASSIFICAÇÃO E
VISUALIZAÇÃO DE CÁRIES EM IMAGENS DE
TOMOGRAFIA COMPUTADORIZADA DE FEIXE
CÔNICO**

São Paulo
2022

LUIZ GUILHERME KASPUTIS ZANINI

**IDENTIFICAÇÃO, CLASSIFICAÇÃO E
VISUALIZAÇÃO DE CÁRIES EM IMAGENS DE
TOMOGRAFIA COMPUTADORIZADA DE FEIXE
CÔNICO**

Trabalho apresentado à Escola Politécnica
da Universidade de São Paulo para obtenção
do Título de Engenheiro de Computação.

São Paulo
2022

LUIZ GUILHERME KASPUTIS ZANINI

**IDENTIFICAÇÃO, CLASSIFICAÇÃO E
VISUALIZAÇÃO DE CÁRIES EM IMAGENS DE
TOMOGRAFIA COMPUTADORIZADA DE FEIXE
CÔNICO**

Trabalho apresentado à Escola Politécnica
da Universidade de São Paulo para obtenção
do Título de Engenheiro de Computação.

Orientadora:

Fátima de Lourdes dos Santos Nunes
Marques

São Paulo
2022

AGRADECIMENTOS

Gostaria de agradecer aos meus pais, por possibilitarem eu desenvolver esse projeto, me apoiando nesse grande desafio.

Gostaria de agradecer ao irmão Leonardo Yuri Kasputis Zanini, que me auxiliou na revisão de artigos, escritas e incentivou a cursar o pré-mestrado.

Também gostaria de agradecer Professora Fátima de Lourdes dos Santos Nunes Marques pela mentoria, sem seu apoio esse projeto não teria se tornado realidade.

Este trabalho foi realizado com apoio do Itaú Unibanco S.A. por meio do Programa de Bolsas Itaú (PBI), vinculado ao Centro de Ciência de Dados da Escola Politécnica da Universidade de São Paulo.

“Eu acredito que às vezes são as pessoas
que ninguém espera nada que fazem as
coisas que ninguém consegue imaginar.”

-- Alan Turing

RESUMO

As cáries dentárias constituem um problema de saúde pública e seu diagnóstico precoce aumenta as chances de tratamento com sucesso. O presente trabalho tem como objetivo detectar no texto para usar detecção em vez de identificação cáries e classificá-las, além de oferecer a visualização tridimensional das mesmas. A abordagem utilizou técnicas de processamento de imagem para segmentar e detectar cáries no volume tridimensional. A partir dos resultados obtidos na etapa de processamento de imagens foi desenvolvido um método computacional que efetua a extração de características relacionadas ao formato do dente e à lesão. Foram utilizados os algoritmos: *Support Vector Machine* (SVM), *Random Forest* (RF) e *XGBoost* para a classificação. O melhor resultado obtido entre os algoritmos de aprendizado de máquina foi de 97,07% de acurácia e 96,58% de F1-score com um conjunto de dados de testes, utilizando o algoritmo *XGBoost*. Por fim, para exposição dos resultados obtidos foi desenvolvido um método de reconstrução do dente em um ambiente tridimensional interativo, o qual pode ser utilizado para fins didáticos.

Palavras-Chave – Detecção de cáries, Processamento de imagens, Aprendizado de Máquina, Segmentação dentária, Segmentação cáries, Tomografia Computadorizada de Feixe Cônico e Visualização 3D.

ABSTRACT

Dental caries is a public health problem and its early diagnosis increases the chances of successful treatment. The present work aims to detect in the text to use detection instead of identifying caries and classify them, in addition to offering a three-dimensional view of them. The approach used image processing techniques to segment and detect caries in the three-dimensional volume. Based on the results obtained in the image processing stage, a computational method was developed to extract characteristics related to the shape of the tooth and the lesion. The following algorithms were used: *Support Vector Machine* (SVM), *Random Forest* (RF) and *XGBoost* for classification. The best result obtained among the machine learning algorithms was 97.07% accuracy and 96.58% F1-score with a test dataset, using the *XGBoost* algorithm. Finally, to expose the results obtained, a tooth reconstruction method was developed in an interactive three-dimensional environment, which can be used for didactic purposes.

Keywords – Caries Detection, Image Processing, Machine Learning, Tooth Segmentation, Caries Segmentation, Cone Beam Computed Tomography and 3D Visualization.

LISTA DE FIGURAS

1	Corte axial e sagital do dente, imagens retiradas do <i>dataset</i> com parceira Faculdade de Odontologia de Bauru (FOB) da Universidade de São Paulo .	13
2	Anatomia do dente, principais estruturas dentárias (WHITE, 2015)	17
3	Dentes com manchas brancas (MATOS; TURBINO; MATSON, 1998)	18
4	Exemplos de dentes com contendo cáries com classificação ICDAS (Pitts et al., 2017)	19
5	Exemplo de radiografia interproximal (WHITE, 2015)	19
6	Exame TCFC, emissão de radiação por meio de um formato cônico (WHITE, 2015)	21
7	Tamanho do voxel (WHITE, 2015)	22
8	Etapas de construção da TCFC (WHITE, 2015)	22
9	TCFC com a indicação de cárie destacada na região circular branca (Tyn-dall; Rathore, 2018)	24
10	Exemplo de validação cruzada com 5 <i>folds</i>	30
11	Exemplos de dentes com diferentes pontuações com base na Classificação Internacional de Detecção de Cárie (ICDAS): (A) imagens sem demarcação de cáries; (B) imagens com segmentação manual de cáries (região vermelha).	41
12	Visão geral da abordagem desenvolvida. : A) Representação das imagens 3D TCFC; B) Extração de cárie considerando as concavidades. C) Extração de cárie considerando a descontinuidade do esmalte dentário. D) Técnica de correção e combinação das máscaras geradas nas etapas anteriores.	42
13	Segmentação das estruturas dentárias. A) Representação de um exame TCFC. B) Aplicação do filtro gaussiano. C) Separação inicial das estruturas dentárias utilizando limiarização multimodal. D) Aplicação da região de crescimento na polpa do dente F) Aplicação da operação morfológica no esmalte. E) Representação final da estrutura S_t	43

14	Distribuição de pixels de um TCFC. Para este gráfico ilustrativo, considerou-se <i>pixels</i> maiores que cem para a visualização, pois a representação destes seria impossível devido aos valores desbalanceados.	44
15	Dentes A, B, C, com visualização coronal, respectivamente, com escores ICDAS de 1, 2 e 4. A região escura ao redor da região marrom-amarelada corresponde ao material vascular pulpar do dente.	45
16	Exemplo de segmentação de um dente: volume 3D representando as estruturas esmalte do dente, dentina e polpa do dente.	46
17	Extração de cárie por concavidades. A) Estruturas segmentadas. B) Pontos gerados pelo algoritmo para delimitação de área C) Região gerada pelo método <i>convexhull</i> D) Aplicação da região de crescimento. F) Geração de máscara	46
18	Segmentação de cárie por falha de esmalte. A) Entrada de S_t para a técnica B) Subtração de regiões. C) Aplicação do filtro mediano D) Resultado final da técnica.	48
19	Correção de falsos sinais de cárie. A) Corresponde à região antes de aplicar a técnica de correção. B) Regra aplicada ao dente.	49
20	Sequência de técnicas correspondendo ao treinamento dos modelos de aprendizado supervisionado.	50
21	Pipeline com reconstrução do modelo, a visualização corresponde a última etapa	54
22	Sistema com modelo reconstruído do dente.	55
23	Aplicação da técnica de rotação no ambiente <i>Unity</i> , rotação em dois eixos. As setas em vermelhos correspondem ao movimento feito com o mouse.	57
24	Aplicação de renderização, controle da renderização do modelo 3D em diferentes eixos.	58
25	Controle da segmentação, separando os três tecidos principais: polpa do dente, dentina e esmalte.	59
26	Curva ROC gerada a partir de dois protocolos, Alta resolução (HR) e Alta Fidelidade (HF). O retângulo preto corresponde a pontos com $scale = 0,91$ em HF e $scale = 0,92$ em HR.	60

27	Métrica de desempenho: sensibilidade dos algoritmos SVM, RF e XGBoost.	67
28	Métrica de desempenho: precisão dos algoritmos SVM, RF e XGBoost. . .	68
29	Métrica de desempenho: especificidade dos algoritmos SVM, RF e XGBoost.	69

LISTA DE TABELAS

1	Fórmulas utilizadas para calcular as treze características de Haralick	27
2	Fórmulas utilizadas para calcular os momentos de Hu	28
3	Características calculadas pelo contorno da imagem	29
4	Tabela com hiperparâmetros do algoritmo SVM	53
5	Tabela com hiperparâmetros do algoritmo <i>Random Forest</i>	53
6	Tabela com hiperparâmetros do algoritmo <i>XGBoost</i>	53
7	Tabela com os resultados com o parâmetro <i>scale</i> = 0.92, utilizando o high resolution protocol	62
8	Tabela com os resultados com o parâmetro <i>scale</i> = 0.91, utilizando high fidelity protocol	62
9	Acurácia/F1-Score dos modelos utilizando quatro conjunto de dados. Foram extraídas características e comparadas com o uso de processamento de imagens e sem o uso de processamento de imagens, além disso com a técnica de redução de dimensionalidade (PCA).	63
10	Acurácia/F1-Score obtidos utilizando a validação cruzada estratificada sem o uso de processamento	63
11	Acurácia/F1-Score obtidos utilizando a validação cruzada estratificada sem o uso de processamento de imagens com PCA	64
12	Acurácia/F1-Score obtidos utilizando a validação cruzada estratificada . .	64
13	Acurácia/F1-Score obtidos utilizando a validação cruzada estratificada sem o uso de processamento de imagens	65

SUMÁRIO

1	Introdução	13
1.1	Motivação	14
1.2	Objetivos específicos	14
1.3	Justificativas	15
1.4	Organização do Documento	15
2	Conceitos Fundamentais	17
2.1	Exames para identificação da doença	18
2.1.1	Diagnóstico de cáries por imagens radiográficas	18
2.2	Identificação da cárie utilizando a TCFC	20
2.2.1	Digitalização da TCFC	20
2.2.2	Voxel	21
2.2.3	Construção da tomografia digital	22
2.2.4	Pontos fortes e considerações clínicas	23
2.2.5	Exemplos de imagens características de TCFC	23
2.3	Técnicas de processamento de imagens	24
2.3.1	Segmentação de imagens	24
2.3.2	Limiarização Multimodal	25
2.3.3	Morfologia matemática	25
2.3.4	Haralick Features	26
2.3.5	Momentos de Hu	27
2.3.6	Características relacionadas ao contorno da imagem	28
2.4	Aprendizado de máquina	29
2.4.1	Validação Cruzada <i>k-fold</i>	29

2.4.2	Support Vector Machine	30
2.4.3	Random forest	31
2.4.4	XGBoost	32
2.5	Métricas de avaliação	32
3	Revisão de literatura	35
3.1	Segmentação e detecção da cáries	35
3.2	Classificação da cárie	36
3.3	Modelos tridimensionais aplicados à Odontologia	36
3.4	Considerações Finais	37
4	Materiais e métodos	39
4.1	Tecnologias Utilizadas	39
4.1.1	Linguagem Python	39
4.1.2	Biblioteca OpenCV	39
4.1.3	Biblioteca Unity	40
4.1.4	Scikit-learn	40
4.1.5	Pydicom	40
4.2	Base de imagens utilizadas	41
4.3	Identificação de cáries	42
4.3.1	Segmentação de estruturas dos dentes	42
4.3.2	Extração de cáries por concavidades	46
4.3.3	Extração de cárie de esmalte por descontinuidade	48
4.3.4	Técnica de correção	49
4.4	Etapas de classificação das cáries	50
4.4.1	Uso de imagens para aprendizado de máquina	50
4.4.2	Normalização	51
4.4.3	Extração de características	51

4.4.4	Calibração de hiperparâmetros	52
4.4.5	Avaliação de modelos	54
4.5	Plataforma de visualização 3D interativa	54
4.5.1	Renderização do Modelo	54
4.5.2	Técnicas interativas	55
4.6	Discussões	56
5	Resultados	60
5.1	Processamento de imagens	60
5.2	Classificação ICDAS	62
5.2.1	Classificação sem o uso de processamento de imagens	63
5.2.2	Classificação sem o uso de processamento de imagens e PCA	64
5.2.3	Classificação com o uso de processamento de imagens	64
5.2.4	Classificação com uso de processamento de imagens e PCA	65
5.2.5	Métricas específicas multiclasse	65
6	Considerações Finais	70
	Referências	72

1 INTRODUÇÃO

A cárie dentária é uma afecção crônica e infecciosa que provoca a destruição dos tecidos dentários pela fermentação bacteriana de açúcares livres (Peres et al., 2019). O diagnóstico precoce é fundamental para o tratamento apropriado e a identificação tardia pode resultar em progressão do quadro causando intensa dor.

Um dos métodos mais comuns para o diagnóstico de cárie é uma inspeção visual direta (Piovesan et al., 2015) da cavidade escura utilizando um espelho bucal. No entanto, esse método limita-se apenas às porções visuais; os diagnósticos mais precisos necessitam de outros meios. O método mais utilizado na prática clínica é a radiografia interproximal de duas dimensões (2D) (Pitts, 2014). Os exames complementares incluem radiografias intrabuciais e exames por imagens como a Tomografia Computadorizada de Feixe Cônico (TCFC) (Figura 1). Especificamente, nos exames por TCFC, os sinais da presença de cáries são achados incidentais, uma vez que a indicação primária da TCFC não inclui a pesquisa de sinais da presença de cáries, como a descontinuidade do esmalte e a formação de áreas hipodensas em esmalte e dentina (Tyndall; Rathore, 2018)




Figura 1: Corte axial e sagital do dente, imagens retiradas do *dataset* com parceira Faculdade de Odontologia de Bauru (FOB) da Universidade de São Paulo

A TCFC é um método de captura radiográfica de imagem em três dimensões (3D)

([Gaalas et al., 2016](#)), gerando a possibilidade de visualizar a arcada dentária em diferentes ângulos ([Patel, 2014](#)). Além de auxiliar na identificação de cáries, esta modalidade de imagem é utilizada no diagnóstico e tratamento do canal dentário, desmineralização dos dentes, baixa formação óssea e planejamento de tratamento cirúrgico ([Setzer et al., 2017](#)).

A utilização das imagens TCFC é um avanço tecnológico mais relevante desde a introdução da radiografia panorâmica. Esse tipo de radiografia oferece um conjunto de imagens que fornecendo uma visão tridimensional dos tecidos maxilofaciais, reduzindo a dose de radiação em comparação com a tomografia computadorizada tradicional ([Scarfe; Farman; Sukovic, 2006](#)).

1.1 Motivação

A visualização dos dentes no volume da TCFC faz com que o radiologista inclua no laudo as alterações encontradas; dentre essas alterações podem estar as cáries dentárias. Nesses casos, é importante para o radiologista fazer o diagnóstico diferencial entre o que seria uma possível imagem de cárie e artefatos da imagem ([Terrabuio et al., 2021](#)), por exemplo.

Além disso, esta técnica pode auxiliar no diagnóstico de cárie quando um radiologista identifica como um achado incidental ([FELEMBAN; LOO; RAMESH, 2020](#)). Portanto, lesões de cárie incidentais e suspeitas podem fazer parte do laudo final da TCFC, emitido pelos radiologistas. [Kasraei et al. \(2017\)](#) mostraram melhor precisão no diagnóstico de cárie recorrente sob restauração composta usando imagens CBCT. O ganho dessa competência é explicado pela melhor visualização de todas as superfícies dentárias em diferentes cortes tomográficos (sagital, coronal e axial).

A detecção de alterações como as cáries em volumes de imagens de TCFC pode auxiliar o radiologista a compor um laudo mais preciso, sendo esta a principal motivação do presente projeto.

1.2 Objetivos específicos

O presente projeto tem como objetivo geral desenvolver um método computacional usando técnicas de aprendizado de máquina e processamento de imagens, visando a detectar e classificar regiões lesionadas por cáries nas imagens de TCFC. Dessa forma, será possível observar diferentes ângulos da lesão possibilitando a identificação de quais estru-

turas a cárie está localizada, assim como um estudo anatômico da mesma.

Os objetivos foram baseados no levantamento bibliográfico exploratório apresentado na seção 3 e definidos com um profissional de saúde da área de Odontologia. Para que o objetivo principal seja alcançado, foram definidos os seguintes objetivos específicos:

- diferenciar lesões de cáries de artefatos;
- segmentar as três estruturas dentais: esmalte, dentina e polpa;
- segmentar a região lesionada;
- classificar as lesões de cáries com base no *Score International Caries Detection and Assessment System* (ICDAS);
- fornecer uma visualização tridimensional interativa dos resultados a fim de favorecer a análise a partir de diferentes pontos de vista.

Portanto, a questão de pesquisa do projeto foi definida como: Qual é a melhor combinação de métodos de processamento de imagens e aprendizado de máquina capaz de detectar e classificar corretamente cáries a partir de exames de TCFC?

1.3 Justificativas

A taxa de acerto de alguns dentistas na detecção de cáries está relacionada diretamente à experiência na área de atuação profissional (Geibel et al., 2017). O presente projeto visa auxiliar o diagnóstico de cáries utilizando técnicas de aprendizado supervisionado, segmentando e classificando a região de interesse. Assim, o projeto apresenta relevância ao contribuir com a composição de diagnósticos com mais precisão, principalmente para profissionais menos experientes.

Visando aproveitar as características de imagens de TCFC, o presente projeto explora os aspectos que favorecem a identificação de cáries e a classificação. Assim, poderá auxiliar a encontrar achados, como as próprias cáries, possibilitando uma intervenção precoce causando menos danos à estrutura dentária do paciente.

1.4 Organização do Documento

A apresentação dos conceitos utilizados no projeto são discutidos na seção 2. Na seção 3 é apresentado o mapeamento da literatura inicial e a justificativa dos métodos utilizados.

A metodologia, contendo o matérias, experimentos e plano de trabalho é apresentada na seção 4. A disseminação e resultados após a implementação dos métodos são enunciados na seção 5. Por fim a conclusão do trabalho é discutida na seção 6.

2 CONCEITOS FUNDAMENTAIS

Na estrutura do dente existem três elementos fundamentais (Figura 2): o esmalte, a dentina e a polpa. O esmalte corresponde ao componente inorgânico mais mineralizado da estrutura dentária. Na camada situada abaixo do esmalte encontra-se a dentina, composta por um tecido mineralizado acelular (Zavgorodniy; Rohanizadeh; Swain, 2007) similar ao esmalte, no entanto com uma composição química diferente. Na camada mais interna está a polpa, que possui tecido conjuntivo e vasos sanguíneos. A polpa do dente possui função sensorial e defensiva, exprimindo uma resposta quimiotática que impede ou retarda a destruição do tecido pulpar.




Figura 2: Anatomia do dente, principais estruturas dentárias (WHITE, 2015)

A cárie dentária é uma doença que causa a desmineralização do esmalte e da dentina (Peres et al., 2019). Esse processo acontece dinamicamente por conta de ciclos de desmineralização e remineralização, mantendo-se na presença de bactérias cariogênicas, açúcares livres e saliva.

Essa doença é caracterizada pelo seu estágio inicial de desmineralização do esmalte dentário, causando o aparecimento de manchas brancas opaca e rugosa (presença de atividade) ou lesões de cor brancas com tecido duro (atividade passada) (Figura 3). Nesse estágio inicial pode ocorrer o aparecimento de microcavidades que possuem diferentes

características (Manzoli; Rodrigues; Groisman, 2010).



Figura 3: Dentes com manchas brancas (MATOS; TURBINO; MATSON, 1998)

A lesão pode progredir de forma lenta ou rápida e só finaliza quando ocorre a remoção do biofilme, que é conhecido como placa dentária. A placa dentária é formada por uma massa concentrada e sólida, rica em polissacarídeos não calcificados e glicoproteínas salivares firmemente aglutinadas (Menezes et al., 2020). Eventualmente, por meio da exposição dos fluoretos e saliva, a remineralização pode ocorrer nas camadas mais externas dos dentes, caracterizando assim a dinamicidade da cárie em seu processo etiopatogênico.

O estágio da doença pode variar, sendo a classificação internacional mais frequente utilizada o sistema ICDAS (*International Caries Detection and Assessment System*) que é utilizado principalmente para avaliar estágios clínicos do processo de cárie, que precede a cavitação (Qudeimat et al., 2019). A utilização dessa classificação clínica pode ser vista na Figura 4.

2.1 Exames para identificação da doença

O diagnóstico da doença pode ser agrupado por três métodos principais: exames visuais, métodos instrumentais e métodos por imagens (Pretty; Ellwood, 2013). É importante o entendimento desses métodos, pois a sua utilização correta pode auxiliar no tratamento precoce da doença.

2.1.1 Diagnóstico de cáries por imagens radiográficas

Os exames por imagens radiográficas utilizam a captação de radiação para criar imagens da anatomia dentária podendo ser visualizado em formato bidimensional ou tridi-

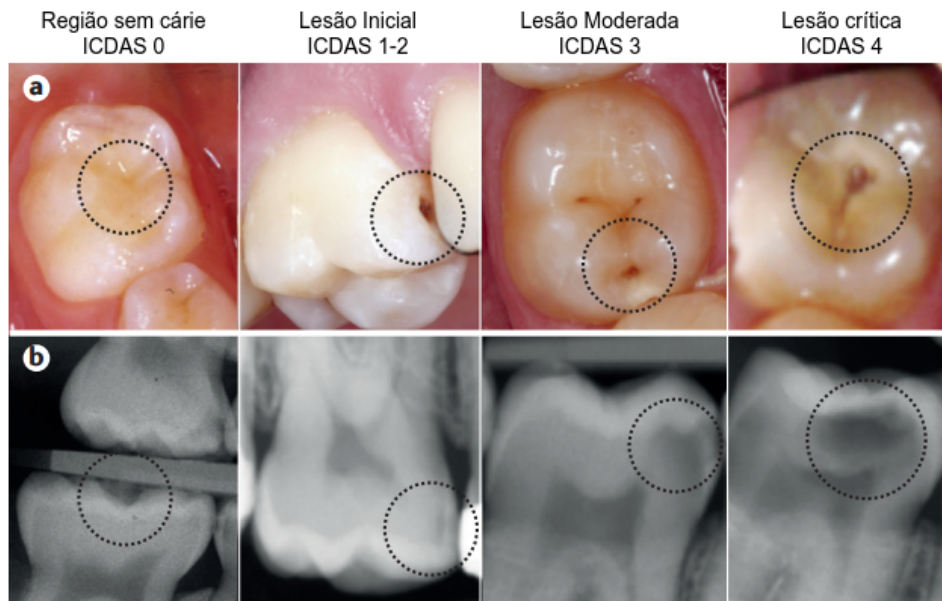


Figura 4: Exemplos de dentes com contendo cáries com classificação ICDAS (Pitts et al., 2017)

mensional. Esses utilizam de radiação ionizante que penetra os tecidos e são captadas por um detector; assim, a captação dessa radiação está diretamente relacionada com a densidade do tecido. Os tecidos possuem diferentes composições e absorvem quantidades diferentes de radiação, essa diferença pode ser captada por meio dos detectores do aparato, fornecendo uma imagem com diferentes tonalidades de cinza referentes aos diferentes níveis de absorção de radiação.

Dentre os exames de radiação ionizantes recomendados para o diagnóstico de cáries, temos as radiografias 2D do tipo interproximais (Pitts, 2014). Esse tipo de exame exhibe a coroa dos dentes superiores, inferiores e a crista alveolar, como visto na Figura 5. Esse exame possui a vantagem de emitir uma quantidade menor de radiação em comparação a outras radiografias, portanto é o exame recomendado para o diagnóstico de cáries.



Figura 5: Exemplo de radiografia interproximal (WHITE, 2015)

Por conta da TCFC oferecer a visualização de três dimensões (Gaalas et al., 2016), a detecção de alterações como as cáries em volumes de imagens de TCFC pode auxiliar o radiologista a compor um laudo mais preciso, sendo esta a principal motivação do presente projeto.

2.2 Identificação da cárie utilizando a TCFC

A utilização das imagens TCFC é um enorme avanço tecnológico desde a introdução da radiografia panorâmica. O desenvolvimento desta nova tecnologia está provendo à Odontologia a reprodução da imagem 3D dos tecidos mineralizados maxilofaciais, com mínima distorção e dose de radiação significativamente reduzida em comparação à tomografia computacional tradicional (Scarfe; Farman; Sukovic, 2006).

Esse exame possui uma fonte em formato cônico divergente de radiação ionizante. Essa radiação é emitida e é captada por um detector de área bidimensional que é preso num pórtico rotativo, fornecendo inúmeras imagens sequenciais conhecidas como imagens bases. Essas imagens possibilitam a visualização de um volumétrico de imagens maxilofaciais (GAALAS et al., 2016).

Quando a radiação for captada, ela terá sua intensidade avaliada por meio do valor do elemento da imagem (*pixel*). O valor desse *pixel* está ligado diretamente com a intensidade de *fótons* emitidos no detector, portanto é possível diferenciar os tipos de tecidos captados pela imagem (WHITE, 2015).

Por se tratar de uma radiação divergente em formato de cone ocorre uma diminuição significativa de radiação em comparação a outras tomografias. Essa é emitida na região de interesse (RDI) tornando-se o centro de rotação do equipamento. A radiação é emitida e é rotacionada por um arco de 180 a 360 graus (Figura 6).

Com a aquisição de múltiplos dados de projeção, é feita uma reconstrução através de um software. Esse programa incorpora múltiplos algoritmos para fornecer um conjunto de dados gerando uma tomografia 3D.

2.2.1 Digitalização da TCFC

Um dos principais fatores para aquisição das imagens é a quantidade de quadros captados pelo detector. Além disso, temos a integridade da trajetória do arco (180 a 360 graus) que pode variar junto com a velocidade de rotação da fonte .




Figura 6: Exame TCFC, emissão de radiação por meio de um formato cônico (WHITE, 2015)

O aumento do número de quadros propicia vantagens e desvantagens. Ao aumentarmos as taxas de quadros, oferece imagens com qualidade melhor, em contrapartida a radiação sobre o paciente é conseqüentemente maior (e vice-versa).

2.2.2 Voxel

Voxel é a unidade de medida que representa o detalhamento da imagem. O tamanho do *voxel* determina o nível de detalhes que uma imagem proporciona, ou seja, sua resolução espacial. Portanto, dentro do conjunto de dados volumétricos possuímos a unidade *voxel* (Figura 7). Na TCFC as unidades de *voxel* são isotrópicas, sendo isotrópicas nas três dimensões. O tamanho do *voxel* se relaciona com o tamanho da matriz e a captação do pixel do detector.

A mudança de tonalidades de cinza está relacionada com o detector que pode revelar diferenças de contrastes. Essa mudança está ligada a resolução de contraste do sistema gerando uma tonalidade de cinza. Em geral, na TCFC existem detectores de 12 *bits* a 16 *bits*, portanto um detector de 16 *bits* fornece 65536 tonalidades de cinza.




Figura 7: Tamanho do voxel (WHITE, 2015)

2.2.3 Construção da tomografia digital

A etapa de construção de tomografia digital é feita após a aquisição do conjunto de imagens bases, gerando o conjunto de dados volumétricos. Esse processo é denominado como reconstrução primária. Essa etapa pode ser observada pela Figura 8.

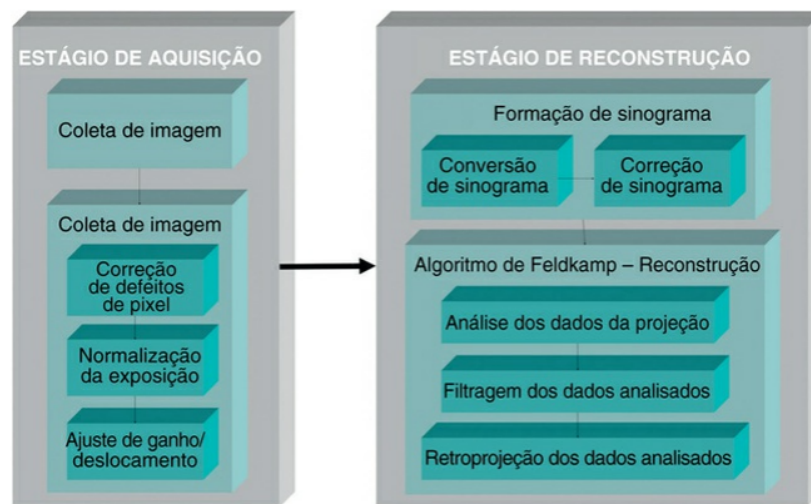


Figura 8: Etapas de construção da TCFC (WHITE, 2015)

A primeira etapa (aquisição) é usualmente feita no computador de aquisição, as etapas seguintes em geral são executadas em computador com uma capacidade de processamento maior. Em geral é feita uma correção das imperfeições geradas por ruídos, causadas por variações na sensibilidade do detector. A correção é feita por meio da aquisição de até 30 imagens utilizando a normalização dessas imagens e interpolação de defeito.

Na segunda etapa (reconstrução) é enviado o conjunto de imagens corrigidas para o computador de reconstrução. Essas imagens são convertidas em um sinograma, que consiste em utilizar as imagens base aplicando a transformada de *radon*. As imagens gerada são composta por várias ondas senoidais com diferentes amplitudes, devido à aquisição de imagens por diferentes ângulos. Com a construção do sinograma é possível utilizar algoritmos para efetuar a construção do conjunto de dados 3D. Em geral, essa etapa de reconstrução é feita pelo algoritmo *feldkamp*.

2.2.4 Pontos fortes e considerações clínicas

A utilização de TCFC deve limitar algumas avaliações em específico, podendo aparecer eventuais cáries nas tomografias que devem ser reportadas pelo radiologista (WHITE, 2015). Sendo essas recomendações:

- identificação de potenciais canais acessórios em dentes com suspeita de morfologia complexa;
- identificação de anomalias do sistema de canais radiculares e determinação da curvatura da raiz;
- diagnóstico de periapicopatias dentais em pacientes que apresentam sinais clínicos contraditórios ou não específicos e sintomas ou interpretações radiológicas convencionais;
- diagnóstico de doenças de origem não endodôntica;
- avaliação intraoperatória ou pós-operatória de complicações do tratamento endodôntico;
- diagnóstico e tratamento de trauma dentoalveolar;
- localização e diferenciação de reabsorção radicular ou reabsorção cervical invasiva externa ou interna;
- planejamento de caso pré-cirúrgico para determinar a localização exata do ápice radicular e avaliar a proximidade de estruturas anatômicas adjacentes.

2.2.5 Exemplos de imagens características de TCFC

Por meio da TCFC é possível avaliar se existe lesão e se ela pode estar ou não em fase de atividade. A principal característica da cárie dentária é a presença de desmineralização

do esmalte e da dentina. Essa desmineralização ocasiona uma perda de densidade do material proporcionando uma maior penetração de raios ionizantes captados pelos detectores do aparato.

A diminuição da densidade pode ser visualizada como imagens radiolúcidas nas radiografias devido uma baixa absorção de raios-X. Na figura 9 é possível observar essa diferença de densidade nas tomografias computadorizadas de feixe cônico.




Figura 9: TCFC com a indicação de cárie destacada na região circular branca (Tyndall; Rathore, 2018)

2.3 Técnicas de processamento de imagens

Nessa seção serão apresentadas as principais técnicas de processamento de imagens empregadas no presente projeto para a identificação de regiões de interesse e extração de características.

2.3.1 Segmentação de imagens

A segmentação de imagens é um processo de partição de uma imagem em partes menores. A segmentação utiliza algoritmos para dividir a imagem em diferentes partes, sendo essa abordagem é amplamente utilizada em múltiplas áreas. Algumas aplicações da segmentação de imagens estão em pesquisa médica, visão computacional e reconhecimento de padrões e restauração digital.

A segmentação é uma técnica utilizada em diversas áreas em especial na área de processamento de imagens médicas (GONZALEZ, 2002). A segmentação atua especialmente em exames médicos para oferecer a visualização de diferentes partes do corpo ou diagnosticar uma determinada doença, podendo ser utilizada para a reconstrução de diferentes

partes do corpo (SZELISKI, 2011).

Existem muitas maneiras de realizar a segmentação de imagens. O método mais comum é o limiar, mas também são usados métodos de foco de crescimento de área, wavelet e fractal (GONZALEZ, 2002). Cada abordagem resolve o problema segmentando a imagem de forma diferente. Por exemplo, o crescimento da região divide uma imagem em partes com base em linhas ou caixas.

2.3.2 Limiarização Multimodal

A limiarização multimodal de imagens é um processo de segmentação de imagem que busca subdividir a imagem em diferentes áreas ou regiões com base em diferentes critérios (GONZALEZ, 2002). Esse método é bastante interessante para destacar as determinadas características da imagem ou para facilitar a análise de imagens, sendo um processo importante em várias áreas, como visão computacional, processamento de imagens médicas e análise de dados de satélite.

A técnica de limiarização multimodal utiliza um histograma por meio da distribuição de *pixels* da imagem, essa técnica busca encontrar mínimos locais nesse histograma separando as estruturas resultantes em um número de limiares (HARING, 1966), obtendo assim uma separação dos elementos dessa imagem. Ao final do método é possível obter uma divisão dessa imagem em múltiplos limiares gerando a separação dessas imagens (segmentação).

2.3.3 Morfologia matemática

A Morfologia Matemática é um conjunto de técnicas definidas a partir da teoria dos reticulados e da topologia (GONZALEZ, 2002). O uso de morfologia matemática se baseia em utilizar os chamados elementos estruturantes (ES), que serão aplicados em uma determinada imagem digital.

Para aplicação de técnicas morfológicas em imagens é necessário que os ES sejam arranjos matriciais. Dessa forma é possível aplicar um determinado arranjo com uma regra específica de um conjunto. Assim é aplicado uma determinada “varredura”, no qual o elemento estruturante irá passar por todos os elementos da imagem, resultando em uma operação de conjuntos sobre a imagem, gerando uma nova figura.

No caso específico da operação de dilatação, o ES gera uma varredura sobre uma imagem, seguindo a equação 2.1, no qual A representa a imagem e B representa o elemento

estruturante.

$$A \oplus B = \left\{ z \mid (\hat{B})_z \cap A \neq \emptyset \right\} \quad (2.1)$$

A dilatação proporciona um aumento ou “engrossamento” dessa imagem que possui valores binários. O resultado gerado por essa operação é controlada pelo ES utilizado, sendo um ES mais extenso proporcionando uma operação de dilatação maior sobre uma imagem.

2.3.4 Haralick Features

A abordagem utilizada nesse projeto prevê o uso de estatística de segunda ordem para extração de características. Essa abordagem é bastante utilizada em imagens médicas como radiografias e tomografias, sendo assim possível extrair características e padrões, fornecendo informações revelantes para o aprendizado supervisionado.

A extração de característica de *Haralick* prevê utilizar informações relevantes entre os níveis de cinza de uma determinada imagem, utilizando informações sobre esses níveis de cinzas como medidas: média, variância, desvio padrão, etc (SINGH; SRIVASTAVA; AGARWAL, 2017).

As característica de *Haralick* é uma técnica que utiliza os conceitos de estática de segunda ordem, buscando identificar padrões por meio do cálculo de matriz de covariância dos níveis de cinza de uma imagem. Essa matriz utiliza os níveis de cinza considerando as posição de cada um dos valores, dessa forma é possível avaliar além da distribuição das tonalidade de cinza, a diferenciação de elementos da imagem por meio desta técnica.

A matriz de co-ocorrência ou conhecida como *gray level coocurrence matrix* (GLCM) representa a organização e distribuição dos níveis de cinza de uma determinada imagem (SINGH; SRIVASTAVA; AGARWAL, 2017). A partir do cálculo dessas matrizes é possível obter as características de *Haralick* no qual cada uma delas é calculada por meio de técnicas estatísticas conforme a Tabela 1. O elemento $p(i, j)$ apresenta o valor do pixel no ponto de coordenadas i, j de da imagem, $p_{x+y}(i)$ corresponde os valores de entrada da entrada da matriz GLCM, N_g é um valor com os números de níveis de cinza distintos na imagem e μ e σ correspondem a média e o padrão valores de desvio.

Tabela 1: Fórmulas utilizadas para calcular as treze características de Haralick

Característica	Fórmula
Angular Second Moment	$f_1 = \sum_i \sum_j p(i, j)^2$
Contrast	$f_2 = \sum_{k=0}^{N_g-1} k^2 p_{x-y}(k)$
Correlation	$f_3 = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$
Soma dos quadrados da Variance	$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 p(i, j)$
Inverse Difference Moment	$f_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)^2} p(i, j)$
Sum Average	$f_6 = \sum_{i=2}^{2N_g} i p_{x+y}(i)$
Sum Variance	$f_7 = \sum_{i=2}^{2N_g} (i - f_6)^2 p_{x+y}(i)$
Sum Entropy	$f_8 = - \sum_{i=2}^{2N_g} p_{x+y}(i) \log(p_{x+y}(i))$
Entropy	$f_9 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log(p(i, j))$
Difference Variance	$f_{10} = \text{variance of } p_{x-y}$
Difference Entropy	$f_{11} = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \log(p_{x-y}(i))$
Information Measures of Correlation	$f_{12} = \frac{f_9 - HXY1}{\max(HX, HY)}$
Information Measures of Correlation	$f_{13} = [1 - \exp(-2(HXY2 - f_9))]^{1/2}$

2.3.5 Momentos de Hu

Os momentos de Hu (Equação 2.2) de uma imagem são bastante utilizados no processamento digital de imagens, sendo aplicados na teoria de reconhecimentos de padrões. Sendo que $I(x, y)$ corresponde aos *pixels* de uma imagens, M_{ij} representa os momentos do plano x e y, e $x^i y^j$ é a influência de x ou y no cálculo dos momentos.

$$M_{ij} = \sum_x \sum_y x^i y^j I(x, y) \quad (2.2)$$

$$\{\bar{x}, \bar{y}\} = \left\{ \frac{M_{10}}{M_{00}}, \frac{M_{01}}{M_{00}} \right\}$$

Prokop e Reeves (1992) apresentaram um conjunto de características obtidas a partir dos momentos (Equação 2.3), esses momentos são invariantes à escala, rotação e translação dos objetos. As características extraídas por meio do cálculo dos momentos de Hu podem

ser vistos na Tabela 2.

Tabela 2: Fórmulas utilizadas para calcular os momentos de Hu

Características
$h_0 = \eta_{20} + \eta_{02}$
$h_1 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$
$h_2 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$
$h_3 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$
$h_4 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) \left[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03}^2) + (3\eta_{21} - \eta_{03}) \left[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] \right]$
$h_5 = (\eta_{20} - \eta_{02}) \left[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \right]$
$h_6 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) \left[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03}^2) + (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03}) \left[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] \right]$

$$\mu_{ij} = \sum_x \sum_y (x - \bar{x})^i (y - \bar{y})^j I(x, y) \quad (2.3)$$

$$\eta_{ij} = \frac{\mu_{i,j}}{\mu_{00}^{(i+j)/2+1}}$$

2.3.6 Características relacionadas ao contorno da imagem

As propriedades relacionadas ao contorno das imagens foram obtidas por meio da segmentação. A partir da segmentação gerada foi calculado um contorno (conjunto de pontos que permitem traçar os limites de uma imagem), obtendo as propriedades a seguir por meio desses contornos.

Portanto por meio do contorno da imagem é possível calcular valores numéricos que buscam identificar as relações dessas imagens. A tabela 3 possui as equações e explicações de cada uma das características, sendo a *Largura* e a *Altura* a quantidade de *pixels* desse contorno e a *áreaConvexa* correspondendo à área considerando apenas os pontos mais exteriores desse contorno.

Tabela 3: Características calculadas pelo contorno da imagem

Característica	Fórmula
<i>Aspect Ratio</i>	$\frac{Largura}{Altura}$
<i>Extent</i>	$\frac{AreaObjeto}{AreaRetangular}$
<i>Solidity</i>	$\frac{AreaObjeto}{AreaConveza}$
<i>Equivalent Diameter</i>	$\sqrt{\frac{4 \times AreaObjeto}{\pi}}$
<i>Rect Area</i>	$Largura * Altura$

2.4 Aprendizado de máquina

A construção de modelos computacionais capazes de aprenderem por meio da experiência é dito como o aprendizado de máquina (AM) (MURPHY, 2012). O modelo de aprendizado máquina utiliza de um determinado conjunto de dados e a partir de padrões efetua uma determinada classificação ou predição. Essa abordagem se tornou muito útil ao longo dos anos, pois por meio dos dados é possível extrair decisões sobre um determinado problema (MURPHY, 2012).

Uma das classificações dos métodos de AM é a divisão entre modelos supervisionados e não supervisionados. Para a aplicação do aprendizado supervisionado é necessário definir como entrada um conjunto de dados devidamente rotulados (características) e uma variável que se deseja prever. O modelo irá extrair padrões que oferecem informações a respeito da variável que será predita, aprendendo assim com as informações a respeito de um conjunto de dados. (MURPHY, 2012)

Alguns destes modelos foram abordados nesse projeto e serão explicados nas seções a seguir, assim como técnicas para medir o desempenho dos algoritmos de aprendizado de máquina.

2.4.1 Validação Cruzada *k-fold*

Para a avaliação de modelos que utilizam aprendizado supervisionado, a técnica validação cruzada é amplamente aplicada para avaliar o desempenho de um modelo (KOHAVI, 1995). É possível estimar métricas de desempenho a respeito de um determinado modelo, separando um conjunto entre partes destinadas ao treinamento e partes destinadas ao teste, avaliando a generalização do modelo.

O método *k-fold* utiliza o conjunto total de dados separados em K partes de mesmo tamanho, a cada iteração um subconjunto K é separado para teste e os k-1 subconjuntos são utilizados para treinamento de um modelo. Sendo assim, é possível obter K amostras de desempenho a respeito de um determinado modelo, gerando assim métricas específicas com uma média e desvio padrão, obtendo assim uma medida confiável sobre o modelo. Na Figura 10 é possível observar um exemplo de validação cruzada com cinco *folds*.



Figura 10: Exemplo de validação cruzada com 5 *folds*.

2.4.2 Support Vector Machine

O algoritmo Support Vector Machine (SVM) busca separar diferentes classes de um conjunto de dados, visando a aumentar a margem entre essas classes por meio do cálculo de uma reta (hiperplano) que separe os mesmos (CERVANTES et al., 2020). Dessa forma, o modelo SVM recebe um conjunto de dados e por meio de algumas iterações o mesmo efetua o cálculo de um hiperplano buscando dividir esse conjunto de dados.

No entanto, a geração de um hiperplano oferece a divisão de um determinado conjunto de dados, especificamente quando os mesmos são linearmente separáveis. Dessa forma, para o modelo SVM obter um melhor desempenho são utilizadas funções *kernel* que alteram a distribuição do conjunto de dados (CERVANTES et al., 2020).

Kernels são funções que recebem um conjunto de dados e geram uma transformação dessa distribuição em um novo plano. O algoritmo SVM calcula uma reta que busca maximizar a divisão de classes, por meio da geração de um hiperplano (uma reta). Em problemas que não é possível efetuar a separação linear de classes é utilizado uma técnica que altera a distribuição das amostras de dados, facilitando assim a geração de uma reta linear em uma distribuição diferente, por meio da função *kernel*. Portanto é possível

efetuar a classificação de dados que não são linearmente separáveis por meio da utilização de funções *kernels*.

Para problemas de multiclases é possível utilizar a estratégia *one vs all* (RIFKIN; KLAUTAU, 2004). A estratégia consiste em dividir o conjunto de dados de classificação multiclasse em vários conjuntos de dados de classificação binária e ajustar um modelo de classificação binária para cada tipo de classe. Portanto, ao final do processo é possível obter diferentes modelos para diferentes classes e selecionar a classe predita com base nessa estratégia, oferecendo assim o algoritmo SVM a classificação entre classes.

2.4.3 Random forest

O modelo preditor *Random Forest* utiliza a estratégia de *bagging* para o treinamento de árvores de decisão obtendo uma melhor generalização e conseqüentemente diminuindo o erro de predição (BREIMAN, 2001). Dessa forma, um conjunto de árvores de decisão individuais corresponde a um modelo preditor mais forte quando exposto a um diferente conjunto de dados.

A árvore de decisão é um algoritmo de aprendizado de máquina supervisionado para classificação. A partir de um determinado conjunto de atributos a árvore oferece escolhas e quebras em decisões, sendo o nós (*decision nodes*), estabelecidos a partir de um critério de maior importância, a ligação desse nós são critérios que oferecem a separação de um conjunto de classes. Ao final da geração dessa árvore é possível obter uma classificação da uma subconjunto de atributos, sendo a raiz (*root node*) o valor predito ao final como uma determinada escolha.

A escolha dos atributos de uma árvore pode ser feita de diferentes formas, as abordagens mais utilizadas são ganho de informação e entropia. Ambas as escolhas representam quanto os dados estão uniformes e desorganizados. Dessa forma, a escolha dos *decision nodes* é feita a partir do cálculo de entropia ou ganho de informação, buscando otimizar o ganho de informação ou minimizar a entropia, oferecendo as melhores escolhas a partir de um conjunto de dados.

A estratégia de *Bagging* tem como objetivo evitar o *overfitting*, ela é utilizada para se obter o modelo *Random Forest* que corresponde a várias árvores de decisão geradas a partir dessa estratégia. Portanto cada árvore de decisão é treinada a partir de um subconjunto aleatório da amostra de treinamento (amostras independentes, mas a partir da mesma distribuição), e usando um subconjunto aleatório de características, oferecendo

assim baixa correlação entre as árvores e o modelo preditivo de cada um.

2.4.4 XGBoost

O algoritmo *XGboost* é um algoritmo de aprendizado de máquina que combina o uso do *gradient boosting* e o uso de árvore de decisões (CHEN; GUESTRIN, 2016). O algoritmo é bastante utilizado em problemas em que o conjunto de dados não é tão grande, principalmente em problemas com características tabulares.

O funcionamento do algoritmo *XGboost* é bastante similar ao algoritmo de *random forest*, utilizando diversas árvores de decisão. Ele utiliza uma amostra aleatória do conjunto de treino, combinando diversos modelos fracos para a melhoria de um modelo coletivamente melhor. A predição final é uma média de várias árvores de decisão.

A estratégia de *gradient boosting* vem da ideia de *boosting*, que tem como objetivo a melhoria de um único modelo "fraco", combinando-o com vários outros modelos "fracos" para gerando um modelo coletivamente melhor. O uso do *gradient boosting* é uma melhoria no processo de adição de modelos "fracos", utilizando o algoritmo de gradiente descendente com uma função objetivo. O aumento de gradiente define resultados direcionados para o próximo modelo com objetivo de minimizar erros, gerando assim um conjunto de modelos "fracos". Dessa forma, o mesmo busca minimizar o erro quadrático conforme novos modelos são adicionados.

O fato do modelo ser utilizado em diversos problemas como regressão, classificação e ranqueamento, fez o mesmo se tornar bastante popular. Além de oferecer a portabilidade em diferentes sistemas operacionais e ser uma biblioteca utilizada em diversas linguagens de programação.

2.5 Métricas de avaliação

As métricas de avaliação dos resultados obtidos tanto pelo modelo classificador quanto o uso de processamento de imagens serão discutidas nessa seção. No presente trabalho além de avaliar os modelos e o uso de processamento de imagens, também é necessário comparar as técnicas desenvolvidas avaliando assim a capacidade de generalização dos processos envolvidos. Dessa forma, nessa seção serão discutidos métricas a respeito desses resultados. Os termos utilizados para gerar essas métricas correspondem a: valores positivos (VP), valores negativos (VN), falsos negativos (FN) e falsos positivos (FP).

A métrica acurácia procura obter um percentual de acertos em relação a real classe daquela predição. Dessa forma, é possível obter uma relação total entre quantidade de acertos de todas classes e o total de instâncias. Sendo assim, na Equação 2.4, é possível obter essa relação.

$$\text{Acurácia} = \frac{VP + VN}{VP + FN + VN + FP} \quad (2.4)$$

Para se obter uma relação entre a quantidade de verdadeiros positivos e falsos positivos a métrica de precisão é bastante utilizada. Ela mede a capacidade de um determinado modelo ou técnica em relação aos acertos da classe escolhida e erro da predição dessa mesma classe. Dessa forma, a Equação 2.5 corresponde a essa métrica

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2.5)$$

A métrica de sensibilidade ou revocação corresponde a relação entre quantidade de verdadeiros positivos e falsos negativos. Com ela é possível avaliar quanto uma classe está realmente sendo classificada, esta métrica é bastante utilizada no contexto médicos nos quais o diagnóstico é fundamental. A equação 2.6 representa essa relação.

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (2.6)$$

A métrica de especificidade busca avaliar a capacidade de um método ou técnica em classificar os resultados negativos ou classe minoritária. A equação que busca obter essa relação corresponde a equação 2.7.

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (2.7)$$

A F1-score é uma métrica que busca balancear o uso da precisão e revocação, utilizando uma média harmônica entre as duas métricas. Sendo possível por meio dessa métrica avaliar o modelo caso possua a sensibilidade ou precisão muito baixa, essa métrica é bastante utilizada em um conjunto de dados desbalanceados. A Equação 2.8 representa essa relação.

$$\text{F1} = 2 * \frac{\text{Precisão} * \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (2.8)$$

Para avaliar a segmentação, foi utilizado o índice Jaccard definido como a Equação 2.9, no qual S corresponde à segmentação manual do especialista e G corresponde à segmentação do método. O índice de Jaccard possui valores entre 0 e 1. Quanto mais próximo o valor de jaccard esteve de 1 significa que todos os *pixels* foram corretamente classificados pelo método desenvolvido.

$$J(S, G) = \frac{|S \cap G|}{|S| + |G| - |S \cap G|} \quad (2.9)$$

3 REVISÃO DE LITERATURA

Nessa seção são discutidos aspectos relevantes na literatura sobre a segmentação, classificação e visualizações tridimensionais interativas. Dessa forma, serão apresentados trabalhos correlatos e técnicas relevantes para a composição do projeto. As seções correspondem ao uso de detecção ou segmentação das cáries, classificação de cáries e por fim métodos de visualizações interativos aplicados à Odontologia.

3.1 Segmentação e detecção da cáries

A localização de cáries e detecções de outras doenças na TCFC foi abordada por [Ezhov et al. \(2021\)](#). No contexto de classificação e detecção de doenças na TCFC, o artigo propõe que seja realizada a segmentação da arcada dentária; dessa forma, cada dente é utilizado como entrada para diversos classificadores e localizadores específicos para cada doença. Na detecção de cáries, o módulo localizador utiliza a rede neural *U-net*, apresentada em [Ronneberger, Fischer e Brox \(2015\)](#), gerando a segmentação da área lesionada. O trabalho, apesar de propor a localização da cárie, não classifica a intensidade da lesão.

[Chen e Zhang \(2017\)](#) utilizaram técnicas de processamento de imagens para identificar cáries em volumes tridimensionais. O *pipeline* de processamento de imagens calcula os vetores de características de cada *pixel* da TCFC; em seguida, esses vetores são utilizados como entrada para um localizador fornecendo a segmentação da região cariada.

[Ahmed et al. \(2017\)](#) combinaram técnicas de aprendizado de máquina não supervisionadas usando o método de *mean threshold* e k-means para gerar uma segmentação. O estudo apresentou métricas específicas para avaliar os resultados da segmentação. No entanto, o trabalho utilizou tomografia computadorizada, ao contrário da TCFC ([SETZER et al., 2017](#)).

Com o uso de aprendizado não supervisionado o trabalho de [Oltu et al. \(2021\)](#) com-

binaram técnicas de processamento de imagem e *Fuzzy C Means* para segmentar a região da cárie, possibilitando a visualização de lesões. [Kumari, Rao e Reddy \(2022\)](#) aplicaram diferentes técnicas para aumentar o contraste e usou uma heurística modificada aplicando *Fuzzy Means* para detecção de cáries em imagens de raio x.

A revisão sistemática descrita em [Mohammad-Rahimi et al. \(2022\)](#) selecionou estudos com objetivo de detectar cáries utilizando *deep learning*, o único trabalho que efetuou a segmentação da lesão na TCFC foi ([Ezhov et al., 2021](#)).

3.2 Classificação da cárie

Diversos estudos buscam melhorar o diagnóstico por meio da utilização de imagens radiológicas com classificação e segmentação da lesão a partir de técnicas de aprendizado supervisionado e não supervisionado.

[Verma et al. \(2020\)](#) utilizaram uma abordagem unindo processamento de imagem e redes neurais classificando entre cáries e sem cáries. [Patil, Kulkarni e Bhise \(2018\)](#) propuseram técnicas de pré-processamento e extração de componentes utilizando *Multilinear Principal Component Analysis* (MPCA), gerando uma entrada para uma rede neural que classifica a intensidade da cárie.

[Prados-Privado et al. \(2020\)](#) proporcionaram uma revisão sistemática reunindo publicações referentes a alguns tipos de redes neurais convolucionais para o diagnóstico de cáries. A revisão forneceu uma análise comparativa desses trabalhos e apontou problemas como falta de profissionais especializados em análise das imagens, baixa quantidade de dados e alguns problemas de viés.

[Imak et al. \(2022\)](#) utilizou uma rede neural convolucional e reportou acurácia de 99,13 classificando a radiografia panorâmica com e sem cárie, ao final do método ele propôs identificar a região da lesão, no entanto, os dados provenientes da cárie são extremamente desbalanceados.

3.3 Modelos tridimensionais aplicados à Odontologia

Aplicações na reconstrução de dentes em ambientes 3D têm sido bastante utilizadas principalmente para estudos anatômicos. Por se tratar de um modelo 3D é possível visualizar em diferentes ângulos uma determinada estrutura. [Chiodera et al. \(2021\)](#) relataram em seu trabalho que estudantes de Odontologia ficaram mais interessados em estudar

diferentes anatomias utilizando um modelo 3D em um dispositivo *mobile* ao invés de um modelo 2D.

Boer, Wesselink e Vervoorn (2016) relataram uma melhora significativa no aprendizado de estudantes de odontologia no primeiro ano em ambientes 3D, comparando a tecnologia 3D com a 2D. Iwanaga et al. (2021) investigaram o uso de ambientes imersivos buscando entender a experiência de uma palestra on-line sobre um procedimento cirúrgico e anatomia relacionados a odontologia, concluindo que o uso dessas tecnologias pode ser bastante vantajoso principalmente por conta dos últimos anos pandêmicos.

Além de ambientes virtuais imersivos, o trabalho Zafar et al. (2020) utilizaram o dispositivo háptico que monitora a aplicação de uma força na mão de usuários, simulando o movimento de uma mão. O ambiente de treinamento oferece as sensações de toque ao perfurar com uma broca odontológica em procedimentos de remoção de cáries. A conclusão do artigo foi que a simulação apresentada pode auxiliar a prática de abordagens dentárias em situações reais.

Khanagar et al. (2021) apresentaram um levantamento com estudos a respeito do uso de inteligência artificial e ambientes virtuais em sistemas odontológicas, concluindo que esses sistemas automatizados têm tido um desempenho excepcionalmente bom, com uma exatidão e precisão semelhantes a profissionais da área.

3.4 Considerações Finais

A partir dos trabalhos citados, verifica-se a o uso de técnicas de aprendizado de máquina com técnicas de processamento de imagens para identificação, segmentação e classificação de cáries. A revisão sistemática (Mohammad-Rahimi et al., 2022) identificou os principais trabalhos que buscam segmentar essa lesão; no entanto, essa segmentação aconteceu majoritariamente em radiografias *bitewing* e radiografias periapicais.

A ausência de trabalhos envolvendo a TCFC se deve à falta de profissionais especializados no manuseio desse tipo de aparato, visto que o mesmo envolve um alto custo e a sua primeira utilização comercial foi em 1998 (Mueller; Lowder, 1998). No entanto, a TCFC está se popularizando e se tornando um dos tipos de tomografias essenciais para diversos tipos de diagnóstico.

Considerando esta lacuna, será desenvolvido um método com objetivo de segmentar e classificar cáries dentárias na TCFC, diagnosticando a cárie interproximal, além disso com os resultados obtidos será desenvolvido um método tridimensional interativo. Os

métodos desenvolvidos serão discutidos na próxima seção.

4 MATERIAIS E MÉTODOS

O principal objetivo do presente projeto é obter a identificação e classificação de cáries, oferecendo ao dentista um auxílio no diagnóstico a respeito da presença de cáries a partir de imagens de TCFC. Para o desenvolvimento do projeto foram empregadas algumas bibliotecas e linguagens de programação (Seção 4.1). Os materiais utilizados no projeto são abordados na Seção 4.2. A segmentação e detecção das cáries (Seção 4.3). A classificação das cáries (Seção 4.4)

4.1 Tecnologias Utilizadas

Nessa seção são discutidos aspectos tecnológicos empregados no presente projeto, como o uso de bibliotecas e linguagens de programação.

4.1.1 Linguagem Python

A linguagem *python* (FOUNDATION, 2022) foi escolhida como linguagem de programação do projeto. A linguagem possui inúmeras bibliotecas que auxiliaram no desenvolvimento de técnicas computacionais. Além disso, possui diversos recursos para computação gráfica oferecendo funções para o processamento do conjunto de dados.

Por fim a linguagem de programação é bastante utilizada no contexto de aplicações de aprendizado de máquina que é um dos objetivos específicos do projeto.

4.1.2 Biblioteca OpenCV

Além de ser multiplataforma, a biblioteca *Open CV* (TEAM, 2022) possui muitos recursos utilizados na área de visão computacional. A biblioteca foi originalmente desenvolvida na linguagem C++ possuindo diversos algoritmos implementados nessa linguagem, a mesma possui uma *Application Programming Interface (API)* que possibilita a utilização

dessas funções na linguagem *Python*. A biblioteca possui funções:

- segmentação por limiarização;
- detecção de contornos;
- aplicação do método do envoltória convexa;
- operações de morfologia matemática.

Sendo assim a biblioteca foi utilizada na etapa de processamento de imagens.

4.1.3 Biblioteca Unity

Unity (HAAS, 2014) é uma ferramenta que possibilita criar videogames para diversas plataformas: *desktop, consoles, mobile e Gear VR*. A ferramenta de Unity possui um estilo específico de programação oferecendo diversos recursos computacionais para gerar jogos interativos. Dessa forma, por meio da ferramenta computacional será oferecido um modelo tridimensional com técnicas interativas para o usuário.

Em jogos do tipo 3D, a ferramenta *Unity* possibilita a elaboração de texturas e compressão da mesmas utilizando recursos computacionais para oferecer um mecanismo de jogo eficiente. Além das texturas, a ferramenta Unity conta com diversos recursos para tornar o jogo mais realista como: reflexão, mapeamento, oclusão de ambiente, sombras e diversos tipos de renderização.

4.1.4 Scikit-learn

A biblioteca scikit-learn (PEDREGOSA et al., 2011) é uma biblioteca de código aberto que oferece diversas implementações de algoritmos de aprendizado de máquina. Dentre as implementações de algoritmos existem: classificação, regressão e agrupamento de dados. Além disso, os algoritmos utilizados na biblioteca são implementações feitas utilizando a linguagem de programação *Python*, facilitando a execução dos experimentos.

4.1.5 Pydicom

O uso da biblioteca *Pydicom* (MASON, 2011) possibilita a manipulação de arquivo que utilizam a extensão no formato *Digital Imaging and Communications in Medicine* (DICOM).

O uso dessa biblioteca possibilita a manipulação de arquivos que utilizam essa extensão. Assim é possível alterar os arquivos até que os mesmos sejam transformados em entradas específicas para cada um dos métodos estabelecidos no presente projeto.

4.2 Base de imagens utilizadas

A base de imagens utilizada nos experimentos do presente projeto foi fornecida pela Faculdade de Odontologia de Bauru (FOB) da Universidade de São Paulo. Os cortes da TCFC foram segmentados manualmente por um especialista utilizando o software ITK-SNAP (YUSHKEVICH et al., 2006) para gerar um conjunto de imagens segmentadas, avaliando os resultados das técnicas desenvolvidas.

O conjunto de dados contém dez dentes *ex-vivo*, sendo oito dentes cariados e dois dentes saudáveis (sem cárie). Cada dente foi classificado com base na *International Caries Detection and Assessment System* (ICDAS). A TCFC foi produzida pelo equipamento Accuitomo 170, que oferece dois tipos de protocolos: *High Fidelity* (HF), recomendado para realizar reconstruções com zoom e *HighResolution* (HR), recomendado para estruturas ósseas delicadas, como o osso ossicular (CORPORATION, 2013). Exemplos de imagens do conjunto de dados são mostrados na Figura 11.

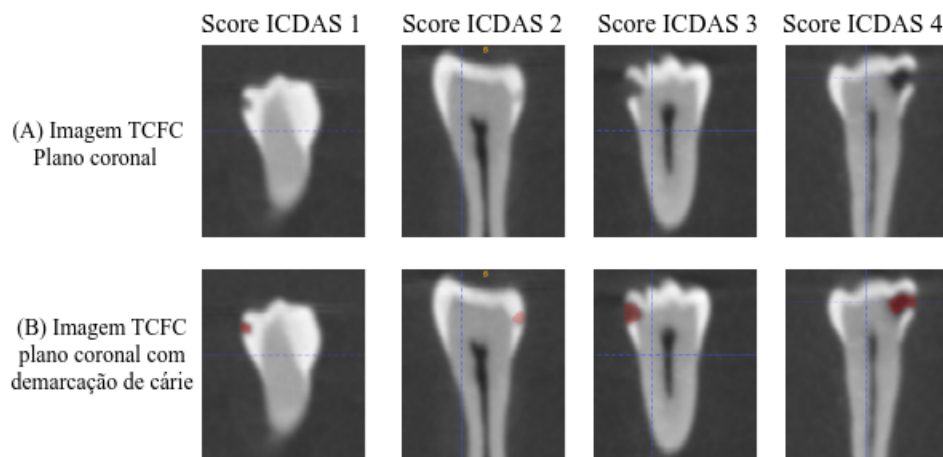


Figura 11: Exemplos de dentes com diferentes pontuações com base na Classificação Internacional de Detecção de Cárie (ICDAS): (A) imagens sem demarcação de cáries; (B) imagens com segmentação manual de cáries (região vermelha).

A TCFC utiliza a escala *grayscale*, sendo cada pixel um inteiro de 16 bits, fornecendo um conjunto de valores possíveis entre $[-2^{15} : +2^{15}]$. A vantagem de utilizá-la na TCFC é fornecer uma dose menor de radiação e oferecer imagens com uma boa resolução (Razi; Niknami; Ghazani, 2014). No entanto esse tipo de tomografia é bastante influenciada pelo

dispositivo e pela configuração do aparato (Ali; Fteita; Kulmala, 2015), dessa forma na seção 4.3 foi construído um método capaz de separar essas estruturas.

4.3 Identificação de cáries

A abordagem no presente projeto utilizou técnicas de processamento de imagem para segmentar imagens de TCFC e detectar cáries nas fatias segmentadas. Foi usado um conjunto de dados privado apresentado na seção 4.2. A visão geral do método proposto é mostrada na Figura 12 e detalhada nas próximas subseções.

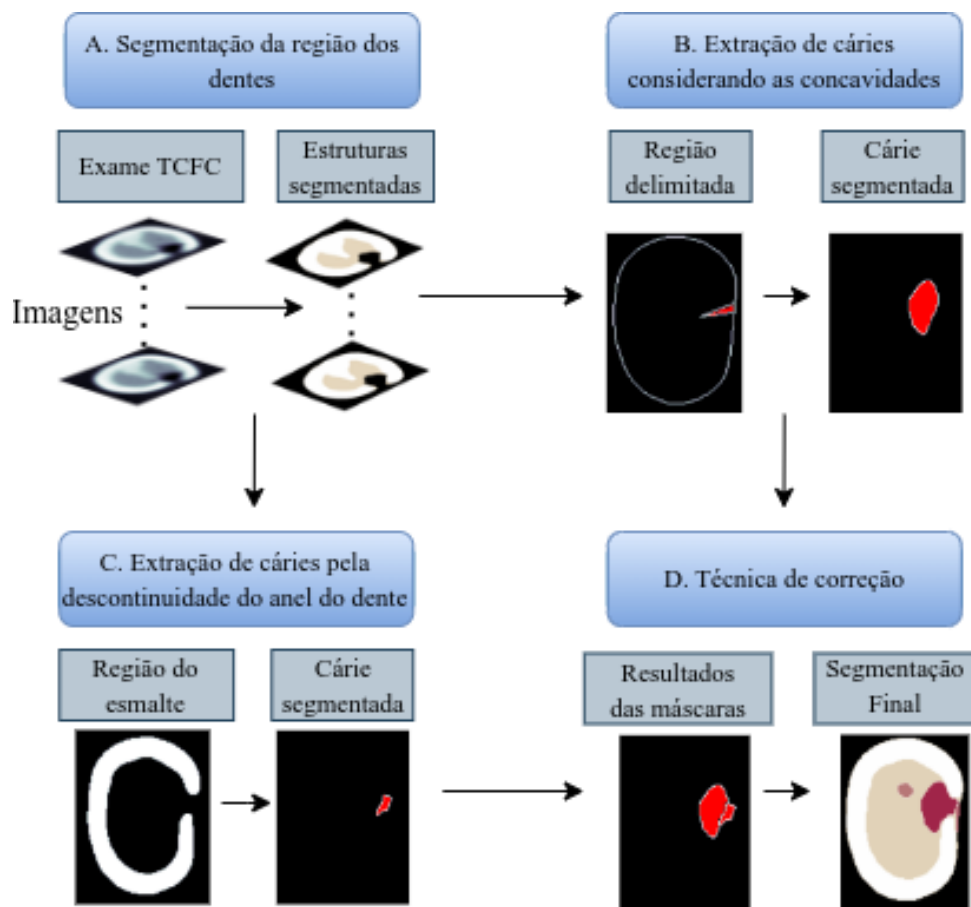


Figura 12: Visão geral da abordagem desenvolvida. : A) Representação das imagens 3D TCFC; B) Extração de cárie considerando as concavidades. C) Extração de cárie considerando a descontinuidade do esmalte dentário. D) Técnica de correção e combinação das máscaras geradas nas etapas anteriores.

4.3.1 Segmentação de estruturas dos dentes

Um exame TCFC gera um volume 3D $I_{3D}(x, y, s)$, composto por imagens 2D (fatias) (Figura 13A), em que (x, y, s) representa a intensidade do pixel na linha x e coluna y ,

localizada na fatia s .




Figura 13: Segmentação das estruturas dentárias. A) Representação de um exame TCFC. B) Aplicação do filtro gaussiano. C) Separação inicial das estruturas dentárias utilizando limiarização multimodal. D) Aplicação da região de crescimento na polpa do dente F) Aplicação da operação morfológica no esmalte. E) Representação final da estrutura S_t .

A segmentação de estruturas foi elaborada com o objetivo de desenvolver uma técnica capaz de verificar a descontinuidade do esmalte e a presença de concavidades nos dentes. A distribuição dos *pixels* da TCFC muda de acordo com o equipamento. Considerando este cenário, foi aplicado um limiar multimodal (TSAI, 1995) a todas as fatias que compõem o I_{3D} .

A primeira etapa da técnica consiste em aplicar uma convolução G_σ do kernel gaussiano a I_{3D} . A aquisição de imagens de TCFC capta a radiação ionizante nos tecidos, de forma que alguns ruídos também podem ser capturados. Portanto, o Kernel Gaussiano foi aplicado em $I_{3D}(x, y, s)$ para reduzir o efeito do ruído (Figura 13B). Além disso, a aplicação do kernel gaussiano auxilia na composição do histograma (TSAI, 1995) observado na Figura 14.

O próximo passo foi segmentar cada fatia da TCFC, considerando três estruturas dentárias (polpa do dente, dentina e esmalte). Como a distribuição dos *pixels* é variável a técnica de limiarização multimodal é importante para esse tipo de imagem. Para isso foi necessário calcular um histograma sobre a distribuição de *pixels* de I_{3D} . O cálculo dos dois mínimos locais neste histograma correspondentes a T_0 e T_1 (Figura 14). Com esses dois mínimos locais, utilizou-se um limiar multimodal usando T_0 e T_1 , segmentando as estruturas resultantes de acordo com a Equação 4.1.

Antes de aplicar a Equação 4.1 em $I_{3D}(x, y, s)$, foi definido S_t um volume 3D que representa a segmentação do dente. Os valores de S_t são respectivamente: 0 que representa o fundo, 1 que corresponde ao material da dentina, 2 que indica o esmalte do dente e, finalmente, o valor 3 a polpa do dente.




Figura 14: Distribuição de pixels de um TCFC. Para este gráfico ilustrativo, considerou-se *pixels* maiores que cem para a visualização, pois a representação destes seria impossível devido aos valores desbalanceados.

$$S_t(x, y, s) = \begin{cases} 0.0 & \text{if } I_{3D}(x, y, s) < T_0 \\ 1.0 & \text{if } I_{3D}(x, y, s) \geq T_0 \text{ and } I_{3D}(x, y, s) < T_1 \\ 2.0 & \text{if } I_{3D}(x, y, s) \geq T_1 \end{cases} \quad (4.1)$$

Após aplicar o limiar multimodal (Figura 13C), foi iniciada a etapa de segmentação da polpa do dente. Esta etapa é fundamental pois o material possui baixa densidade, e conseqüentemente, quando aplicado o algoritmo de delimitação da área (Seção 4.3.2) esta região pode interferir. Primeiramente é necessário calcular o centro do dente em cada fatia para determinar a região da raiz do dente. Para isso, foi calculado o momento da imagem usando a intensidade dos *pixels*, determinando \bar{x} e \bar{y} por meio da Equação 4.2, no qual M_{ij} representa os momentos do plano x e y, e $x^i y^j$ é a influência de x ou y no cálculo dos momentos.

$$M_{ij} = \sum_x \sum_y x^i y^j I_{3D}(x, y) \quad (4.2)$$

$$\{\bar{x}, \bar{y}\} = \left\{ \frac{M_{10}}{M_{00}}, \frac{M_{01}}{M_{00}} \right\}$$

A polpa é uma estrutura vascular encontrada no centro do dente, na qual o material da dentina sobrepõe o mesmo. Na Figura 15 é possível observar que o material está no meio do dente. Portanto, foi aplicada uma técnica de crescimento de região considerando o

centro do dente como semente inicial, sendo delimitada pelo material da dentina, conforme representado na Equação 4.3. O processo final atribui o valor 3.0 aos *pixels* correspondentes à polpa do dente, resultando na operação mostrada na Figura 13D.

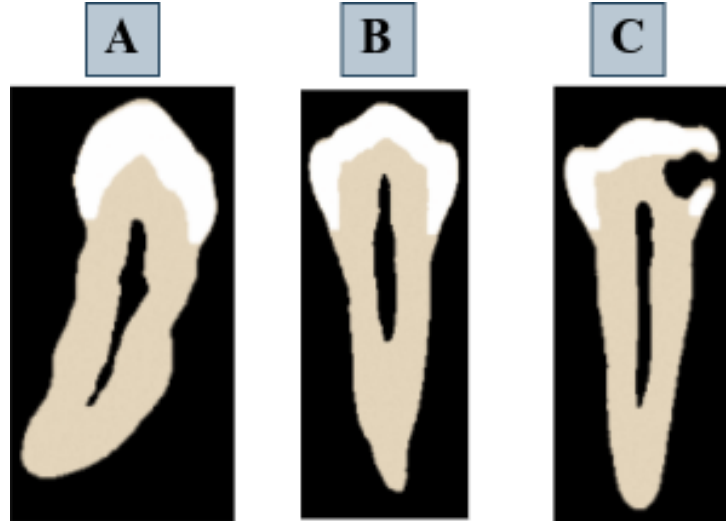


Figura 15: Dentes A, B, C, com visualização coronal, respectivamente, com escores ICDAS de 1, 2 e 4. A região escura ao redor da região marrom-amarelada corresponde ao material vascular pulpar do dente.

$$S_t(x, y, s) = \begin{cases} 3.0 & \text{if } S_t(x, y, s) \neq 1.0 \\ 1.0 & \text{else} \end{cases} \quad (4.3)$$

A aplicação da limiarização multimodal pode gerar algumas falhas de segmentação, principalmente na região do esmalte. Assim, neste cenário, a operação morfológica dilatação é aplicada nas regiões cujos *pixels* possuem valores 2.0, conforme Figura 13F. O próximo passo é unir a estrutura dilatada com S_t obtendo o resultado correspondente à Figura 13E. Por fim, temos a estrutura S_t correspondente à Figura 16 que representa a segmentação do dente em um volume 3D.

Para aplicar as técnicas desenvolvidas para extração de cárie considerando concavidades (Seção 4.3.2) e descontinuidade do esmalte dentário (Seção 4.3.3), foi estabelecida uma região de interesse (ROI). O cálculo da ROI foi determinado nas fatias em que o esmalte dentário está presente. A busca teve início pela primeira fatia em que ocorre o esmalte dentário (s_{min}) e a última fatia em que ocorre o esmalte dentário (s_{max}). A Figura 16 ilustra a ocorrência do esmalte e como a iteração ocorreu sobre este volume S_t , para obter a ROI. Portanto, foi estabelecido um intervalo de fatias s_{min} e s_{max} , nas quais os métodos são aplicados para extrair regiões de cárie interproximal.




Figura 16: Exemplo de segmentação de um dente: volume 3D representando as estruturas esmalte do dente, dentina e polpa do dente.

4.3.2 Extração de cáries por concavidades

A formação de cáries pode causar a destruição do esmalte do dente, bem como da estrutura da dentina. O método busca regiões em que este material foi desmineralizado. As técnicas são aplicadas conforme Figura 17 para identificar evidências de cárie.




Figura 17: Extração de cárie por concavidades. A) Estruturas segmentadas. B) Pontos gerados pelo algoritmo para delimitação de área C) Região gerada pelo método *convexhull* D) Aplicação da região de crescimento. F) Geração de máscara

O método foi desenvolvido para obter os pontos que delimitam a região em todos os cortes das imagens TCFC (Figura 17B). O Algoritmo 1 mostra os passos do método, tendo como entradas S_t correspondentes aos elementos das estruturas segmentadas e o centro do dente (\bar{x}, \bar{y}) . O algoritmo inicia a busca no ponto médio (\bar{x}, \bar{y}) , percorrendo uma linha reta com um ângulo que foi variado entre zero e 360 graus? Qual o passo. Essa busca ocorre até encontrar um valor correspondente a $S_t = 0.0$, finalizando a busca e armazenando o ponto correspondente conforme mostrado na Figura 17B. O método itera sobre a ROI, retornando os pontos delimitadores (P_d) sobre todas as fatias da ROI.

O próximo passo foi aplicar o método de casco convexo (SKLANSKY, 1982) em P_d .

Algorithm 1 Algorithm for Area Delimitation

Input: \bar{x}, \bar{y}, S_t
Output: *delimitersPoints*
Initialization :

```

1: delimitersPoints  $\leftarrow \{\}$ 
2: for angle = 0 to 360 do
3:    $x \leftarrow \bar{x}, y \leftarrow \bar{y}$ 
4:    $i \leftarrow 0$ 
5:   while  $S_t(x, y) \neq 0.0$  do
6:      $x \leftarrow \cos(\textit{angle}) * i + \bar{x}$ 
7:      $y \leftarrow \sin(\textit{angle}) * i + \bar{y}$ 
8:      $i \leftarrow i + 1$ 
9:   end while
10:  delimitersPoints.append( $\{x, y\}$ )
11: end for
12: return delimitersPoints

```

A técnica do casco convexo retorna a intersecção de todos os conjuntos convexos de P_d . Os pontos não considerados em P_d são armazenados como possíveis sinais de cárie (P_S). Com os pontos P_d foi criado uma área delimitada (D_A), que é a região correspondente à Figura 17C. A região D_A corresponde à área limitada que a técnica de crescimento de região pode iterar. Portanto, foi controlado até quanto a região pode se expandir.

Para gerar a segmentação da cárie, um método de crescimento de região é aplicado em P_S (Figura 17D), delimitado pela região correspondente a D_A . Além disso, D_A é alterado pelo parâmetro *scale*, pois a área original cobriria todos os pontos e regiões que não são cáries quando o método de crescimento de região é aplicado. O parâmetro *scale* é um valor no intervalo $[0,1]$, que permite aumentar ou diminuir a área considerada para a técnica de crescimento de região.

Assim, quando o valor *scale* é alto, pode abranger regiões que não são cáries devido a deformidades ou desgaste natural do dente. Por outro lado, valores baixos de *scale* podem restringir o algoritmo de crescimento de região, que irá iterar em um número menor de regiões. Consequentemente, é possível reduzir o valor dos falso-positivos, mas aumentar o valor dos falso-negativos. Portanto, é necessário encontrar um valor ideal deste parâmetro para obter regiões que realmente correspondam à cárie. A escolha desse parâmetro foi feita a partir da escolha da geração da curva ROC definida nas próximas seções.

A área gerada pelo método de crescimento de região corresponde à segmentação de cárie, conforme mostrado na Figura 17D. Esta área é adicionada à estrutura S_t (Figura 17F), gerando assim a segmentação desta região danificada.

4.3.3 Extração de cárie de esmalte por descontinuidade

O método desenvolvido anteriormente inclui casos em que ocorre a desmineralização da dentina e do esmalte. No entanto, existem casos em que o material do esmalte pode não ter sido danificado o suficiente para ser tão evidente nas imagens de TCFC. Assim, nesta fase, a técnica desenvolvida propõe identificar as regiões nas quais ocorreu essa descontinuidade do esmalte dentário.




Figura 18: Segmentação de cárie por falha de esmalte. A) Entrada de S_t para a técnica B) Subtração de regiões. C) Aplicação do filtro mediano D) Resultado final da técnica.

A primeira etapa ocorre na iteração sobre o ROI. Em cada iteração, o método busca verificar se a formação do anel de esmalte dentário já ocorreu para identificar sinais de descontinuidade do esmalte.

Usamos o algoritmo de busca em profundidade (DFS) para verificar se a formação do anel de esmalte ocorreu em uma fatia. Iniciamos o processo iterando sobre o ROI, iniciando a busca em \bar{x} e \bar{y} , que corresponde aos centros do dente. O algoritmo de busca se move para *pixels* vizinhos, caso $S(t)$ seja diferente de 2.0, que corresponde ao material do esmalte. Ao final da busca, é possível verificar se o algoritmo atingiu as bordas da imagem. Se esta condição for verdadeira, esta fatia tem uma descontinuidade no esmalte e a fatia é marcada como s_{true} . Caso contrário, a fatia é marcada como s_{false} .

Usamos a subtração entre as regiões contínuas e descontínuas para obter a região da lesão (Equação 4.4). Assim, em todas as fatias na qual esta condição é verdadeira (s_{true}), subtraímos a última fatia na qual a condição não ocorreu (s_{false}), retornando a região de diferença (R_d) de acordo com Equação 4.4

$$R_d = S_e(s_{false}) - S_e(s_{true}) \quad (4.4)$$

A subtração entre as regiões será a segmentação da área, fornecendo a região lesionada. No entanto, a subtração dessas regiões pode causar algum ruído, conforme o resultado exemplificado na Figura 18B.

A próxima etapa do método consiste em remover o ruído causado por essa subtração. Usamos um filtro de mediana com uma janela 5×5 aplicada a R_d (Figura 18C). O último passo foi combinar a segmentação gerada a partir da técnica anterior com S_t , conforme Figura 18D.

4.3.4 Técnica de correção

Conforme mostrado nas seções anteriores, o método avalia a geração de cáries causadas por concavidades ou falta de esmalte. No entanto, isso pode causar alguma detecção de cárie falso-positiva. Assim, uma técnica de correção foi desenvolvida para minimizar a geração dessas falsas cáries.

Esta técnica foi desenvolvida com base na percepção de que os dentes possuem estruturas anatômicas diferentes. Alguns dentes têm concavidades que se estendem até a raiz. Assim, quando o método de crescimento de região é aplicado, ele se estende até a raiz do dente, conforme Figura 19A. Para reduzir a incidência de casos falso-positivos, foi criada regra para avaliar a extensão da lesão até a raiz do dente.



Figura 19: Correção de falsos sinais de cárie. A) Corresponde à região antes de aplicar a técnica de correção. B) Regra aplicada ao dente.

A regra foi criada avaliando a extensão da lesão ao longo dos cortes. O falso sinal de cárie está presente na dentina e tem extensão até a raiz do dente. A heurística utiliza a relação entre a extensão da lesão nas fatias da vizinhança e a quantidade dessa lesão na dentina. Portanto, se a segmentação se estender até a raiz do dente e não tiver um percentual mínimo de distribuição no esmalte, (consideramos 10% da avaliação da incidência de falso-positivos), essa lesão é removida. Portanto, a técnica de correção remove a região segmentada correspondente ao falso-positivo da cárie, como mostra a Figura 19B.

4.4 Etapa de classificação das cáries

A etapa anterior apresentou resultados relacionados a identificação da região lesionada utilizando técnicas de processamento de imagens. No entanto, para auxiliar a compor laudos radiológicos com maior precisão relacionadas à cárie, será feita uma etapa de classificação da lesão para avaliar a gravidade da mesma.

A classificação de lesões de cáries com base no *Score (ICDAS)* é um dos objetivos específicos do projeto. Portanto, para se obter uma predição a respeito de uma determinada imagem ou fatia do dente será necessário utilizar o aprendizado de máquina com intuito de se obter uma classificação multiclasse, sendo a saída dos algoritmos de aprendizado supervisionado valores correspondentes a : inteiros no intervalo $[0,4]$.

A partir dos resultados obtidos na etapa de processamento de imagens foi desenvolvido um método que efetua a extração de características relacionadas ao formato do dente e à lesão (Figura 20). Portanto será utilizado um vetor de características para obter o treinamento dos modelos.




Figura 20: Sequência de técnicas correspondendo ao treinamento dos modelos de aprendizado supervisionado.

4.4.1 Uso de imagens para aprendizado de máquina

Para esse projeto será utilizado imagens bidimensionais percorrendo axialmente a tomografia. O conjunto de imagens utilizado possui a variável *target* que corresponde se a imagem possui um *score* ICDAS dessa cárie.

O *dataset* do projeto possui exames TCFC de oito dentes com cárie e dois sem cárie. Além disso, cada exame gera cerca de 350 imagens, totalizando cerca de 3500 imagens. A distribuição de imagens com cárie é de: sessenta e quatro imagens com *score* ICDAS 4, quarenta e um imagens com *score* ICDAS 3, dezoito imagens com *score* ICDAS 2 e quarenta imagens com *score* ICDAS 1.

Para o treinamento dos algoritmos de aprendizado de máquinas foi utilizado todas as imagens com cáries por meio da validação cruzada estratificada (seção 2.4.1) que cor-

responde a separação do conjunto de dados entre teste e treino. Além disso, para casos que não houve indícios de cárie, foi utilizado a média entre esses casos que corresponde a quarenta imagens, portanto foram escolhidas aleatoriamente 40 imagens dos dois dentes sem cáries.

4.4.2 Normalização

Na etapa de pré-processamento dos dados foi feita a normalização das características extraídas. Esse método foi utilizado no projeto por conta da influência dos valores no algoritmo de SVM (GRAF; BORER, 2001). Como o algoritmo utiliza o hiperplano para dividir as classes do problema, o mesmo tem uma influência significativa nas escalas dos eixos (características do problema) afetando assim o cálculo deste hiperplano.

A normalização escolhida *feature scaling* (TAX; DUIN, 2000) que consiste em redimensionar o intervalo de valores para dimensionar o intervalo entre $[0, 1]$, sendo assim todas as características estarão na mesma escala. A Equação 4.5 corresponde a esse procedimento, sendo x o valor da característica a ser normalizada e x' o resultado dessa operação.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (4.5)$$

4.4.3 Extração de características

A partir dos resultados obtidos na etapa anterior será desenvolvido um método computacional que efetuará a extração de características relacionadas ao formato do dente e a lesão da cárie. Com isso, será utilizado as características extraídas como entrada para o treinamento dos algoritmos de aprendizado supervisionado.

O primeiro conjunto de características a serem extraídos são os momentos de Hu (Seção 2.3.5). Em visão computacional e processamento de imagens, os momentos de imagem são frequentemente usados para caracterizar a forma de um objeto em uma imagem. O cálculo dessas características é feito utilizando os momentos de imagens. A ideia é que o descritor de imagem *Hu Moments* é utilizado para quantificar a forma de escala, rotação e translação dos objetos de um objeto em uma imagem. Sendo assim, será possível extrair padrões dessas imagens e oferecer um conjunto de dados necessários para a aplicação de aprendizado de máquina.

O segundo conjunto de características extraídas de cada um dos elementos de imagens foi *Haralicks features* (Seção 2.3.4). Essa extração de características consiste em utilizar os níveis de cinza correspondentes de uma determinada imagem, considerando as posição de cada um dos valores de cinza, obtendo padrões relacionados níveis de cinza de uma determinada imagem.

Por fim, o cálculo de características relacionadas ao contorno da imagem (Seção 2.3.6). A extração de ambos os elementos foi feita na região segmentada do dente e na região segmentada da cárie, em casos em que não houve a geração da segmentação da cárie foram utilizados zeros.

Portanto, foram obtidas um conjunto de 30 características relacionadas ao as imagens do dente. Sendo essas relacionadas ao descritor de imagem (7 características), a variação de intensidade de cinza (13 características), formato do dente (5 características) ao volume gerado pela segmentação da lesão (5 características), elementos fundamentais para a aplicação do aprendizado de máquina.

4.4.4 Calibração de hiperparâmetros

Os hiperparâmetros de um algoritmo de aprendizado de máquina são definidos como os parâmetros do modelo a serem escolhidos antes de se treinar o modelo. Esses parâmetros devem ser definidos antes do treinamento, pois o modelo não pode alterar o valor dos mesmo no processo de treinamento. Sendo assim a escolha desses hiperparâmetros pode afetar a velocidade e qualidade do processo de aprendizagem.

No processo de aprendizado dos modelos, foi utilizado a validação cruzada estratificada. O conjunto de dados foi dividido em alguns *folds* testando o aprendizado do algoritmo com um determinado conjunto de hiperparâmetros, obtendo uma média da acurácia a partir desses *folds*. Com isso, foi possível avaliar a influência que um conjunto de hiperparâmetros tem sobre um determinado modelo.

Diferentes algoritmos de aprendizado de máquina requerem diferentes hiperparâmetros, alguns algoritmos mais simples exigem poucos hiperparâmetros para serem alterados. Na execução do projeto os hiperparâmetros foram utilizados: a Tabela 4 correspondendo aos hiperparâmetros calibrados da SVM, a Tabela 5 hiperparâmetros do algoritmo *random forest* e por fim a Tabela 6 com os hiperparâmetros do algoritmo *XGBoost*.

Tabela 4: Tabela com hiperparâmetros do algoritmo SVM

Hiperparâmetro	Descrição	Escolhas
<i>Kernels</i>	Função matemática que altera a distribuição do conjunto de dados	['linear', 'poly', 'rbf']
<i>C</i>	Parâmetro de regularização. A força da regularização é inversamente proporcional a C	[0.1, 1, 10, 100]
<i>Gamma</i>	Corresponde a curvatura que queremos em um limite de decisão.	[1, 0.5, 0.1, 0.001]

Tabela 5: Tabela com hiperparâmetros do algoritmo *Random Forest*

Hiperparâmetro	Descrição	Escolhas
<i>Number estimators</i>	Número de árvores	[5,10,20,30]
<i>Max features</i>	O número de características a serem considerados ao procurar a melhor divisão	['sqrt', 'log2']
<i>Criterion</i>	A função para medir a qualidade de uma divisão de um nó	['gini', 'entropy']
<i>Max Depth</i>	A profundidade máxima da árvore	[5, 10, 20]
<i>Min samples leaf</i>	O número mínimo de amostras necessárias para dividir um nó	[1, 2, 4]

Tabela 6: Tabela com hiperparâmetros do algoritmo *XGBoost*

Hiperparâmetro	Descrição	Escolhas
<i>Number estimators</i>	Número de árvores	[5,10,20,30]
<i>Max features</i>	O número de características a serem considerados ao procurar a melhor divisão	['sqrt', 'log2']
<i>Max Depth</i>	A profundidade máxima da árvore	[5, 10, 20]
<i>Gamma</i>	Corresponde a redução de perda mínima necessária para fazer uma divisão	[1, 2, 3]
<i>Min child leaf</i>	O número mínimo de amostras necessárias para dividir um nó	[1, 2, 5, 10]
<i>Colsample bytree</i>	Proporção de subamostras de colunas ao construir cada árvore	[0.5, 0.1]

4.4.5 Avaliação de modelos

Após o treinamento dos modelos, os dados são separados para validação dos mesmos, estimando assim o erro e avaliando a capacidade de generalização do modelo. São utilizadas métricas de erro multi classe tais como acurácia, precisão, sensibilidade e especificidade (Seção 2.5).

É importante destacar que a avaliação está sendo realizada no conjunto de imagens da tomografia computadorizada, para métodos futuros é esperado avaliar a generalização do conjunto inteiro da TCFC.

4.5 Plataforma de visualização 3D interativa

A plataforma disponibiliza os resultados obtidos nas etapas anteriores será feito na ferramenta *Unity*, a renderização do modelo assim como as técnicas aplicadas a esse modelo serão discutidas nas seções seguintes.

4.5.1 Renderização do Modelo

Visualizações 3D oferecem características mais realistas oferecendo técnicas interativas sobre modelos 3D, facilitando um estudo pré-cirúrgico. Um dos objetivos específicos do projeto foi construir um *software* capaz de efetuar uma reconstrução do dente, a partir da segmentação obtida, gerando assim um ambiente tridimensional com interação.




Figura 21: Pipeline com reconstrução do modelo, a visualização corresponde a última etapa

A disponibilização de um modelo 3D é feito por meio da técnica de reconstrução. A estrutura do dente possui três estruturas dentárias (polpa do dente, dentina e esmalte), esses elementos possuem densidades diferentes, portanto foram aplicadas técnicas de processamento de imagens gerando a separação dessas estruturas (Figura 21). Portanto foi possível obter um modelo reconstruído do dente com a segmentação dessas estruturas.

Por meio do ambiente de desenvolvimento é possível estabelecer técnicas de interação sobre o protótipo. A interação com o ambiente oferece a visualização em diferentes ângulos da estrutura 3D, oferecendo um entendimento melhor a respeito da estrutura anatômica. Além de auxiliar num possível diagnóstico da lesão da cárie.

Com a segmentação anatômica das estruturas do dente obtidas, o processamento converte essa segmentação em um modelo 3D obtendo um sistema em diferentes plataformas. Dentre essas plataformas inclui-se a visualização no *desktop*, que oferece ao usuário a possibilidade de interagir com o modelo.

O ambiente 3D foi construído na plataforma *Unity3D* (HAAS, 2014), possibilitando futuramente a interação com diferentes interações com um óculos de realidade virtual. Por meio da plataforma *Unity* foi possível gerar a reconstrução do modelo dentário, oferecendo a visualização com técnicas interativas. A linguagem *Unity* oferece um conjunto lógico de funções as quais permite a utilização de lógica para renderização do modelo. Dessa forma, foi possível obter o modelo que corresponde a Figura 22.

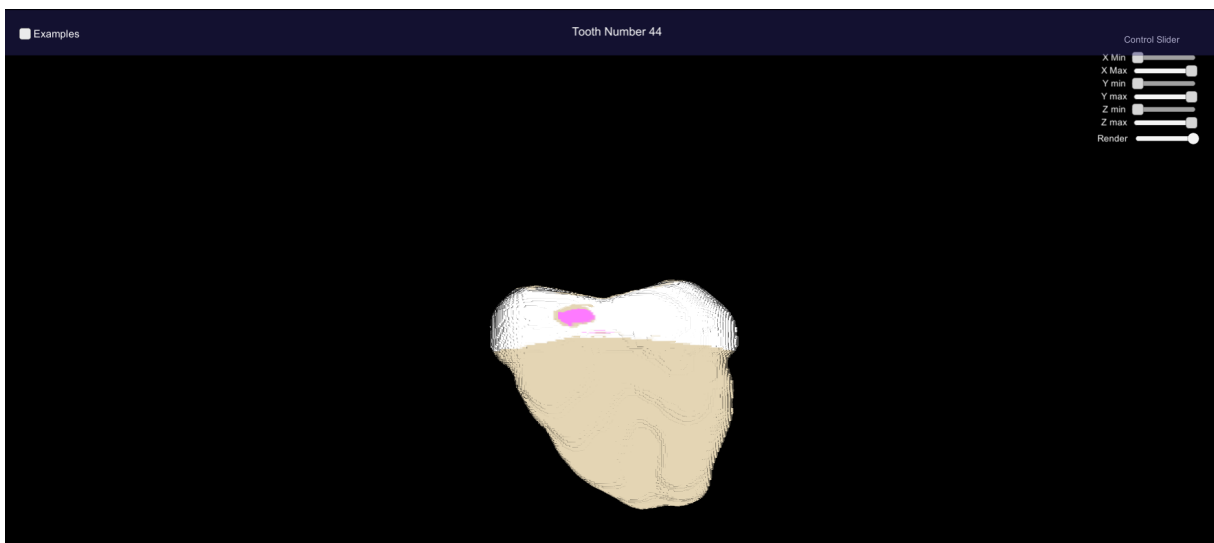


Figura 22: Sistema com modelo reconstruído do dente.

4.5.2 Técnicas interativas

A partir da aquisição de imagens da TCFC foi desenvolvido um método de reconstrução em um modelo 3D, por meio dessa reconstrução serão estabelecidas algumas técnicas interativas nessa estrutura. Dentre as técnicas previstas para o modelo se encontra a rotação, redimensionamento, controle de renderização do modelo e controle das estruturas dentárias.

O Movimento de rotação corresponde ao movimento circular de um objeto ao redor de um centro ou ponto de rotação. Dessa forma, a técnica rotação corresponde ao movimento circular em torno dos eixos x, y e z sobre o modelo 3D. Além da técnica de rotação, está prevista a utilização do redimensionamento do objeto, aplicando assim a operação que corresponde ao "zoom" (Figura 23).

O controle de renderização do modelo foi feito pensando no plano 3D. A renderização da estrutura do dente pode ser controlada por meio desses planos. Na Figura 24 é possível observar a atuação do *slider* no eixo X, controlando a renderização do modelo, possibilitando a visualização da estrutura central do dente. Essa técnica oferece a possibilidade de visualizar em diferentes ângulos a estrutura do dente, assim como a lesão da cárie.

Por fim, a técnica interativa corresponde ao controle de renderização das estruturas segmentadas, a qual é possível visualizar as diferentes estruturas anatômicas do dente por meio dessa técnica, controlando assim a renderização da mesma (Figura 25).

4.6 Discussões

Por meio dos métodos citados será avaliado o uso dessas aplicações, assim como a discussão dos resultados. O primeiro método empregado visa utilizar o processamento de imagens gerando a segmentação da lesão, o segundo método apresentado busca classificar as cáries utilizando o score ICDAS e por fim será discutido o uso futuro das tecnologias interativas sobre o modelo segmentado.

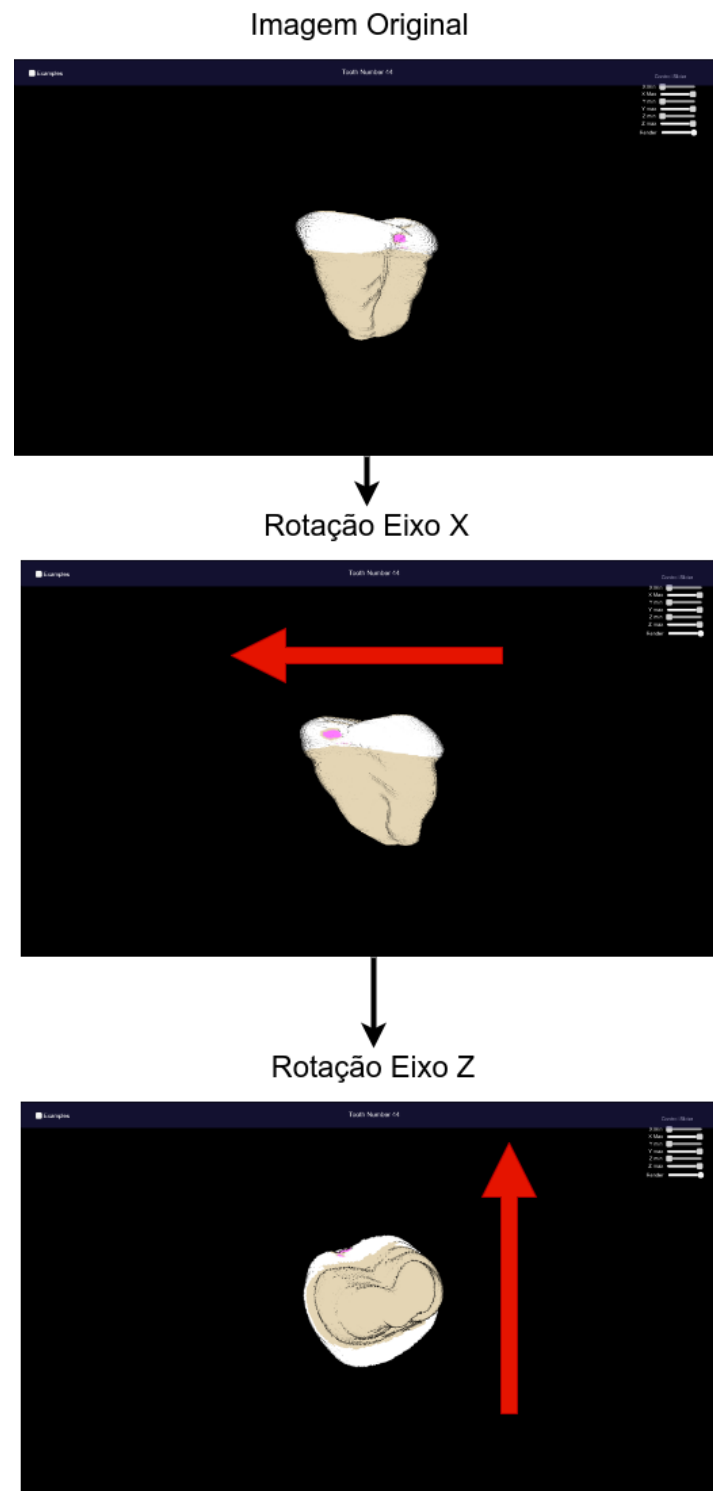


Figura 23: Aplicação da técnica de rotação no ambiente *Unity*, rotação em dois eixos. As setas em vermelhos correspondem ao movimento feito com o mouse.

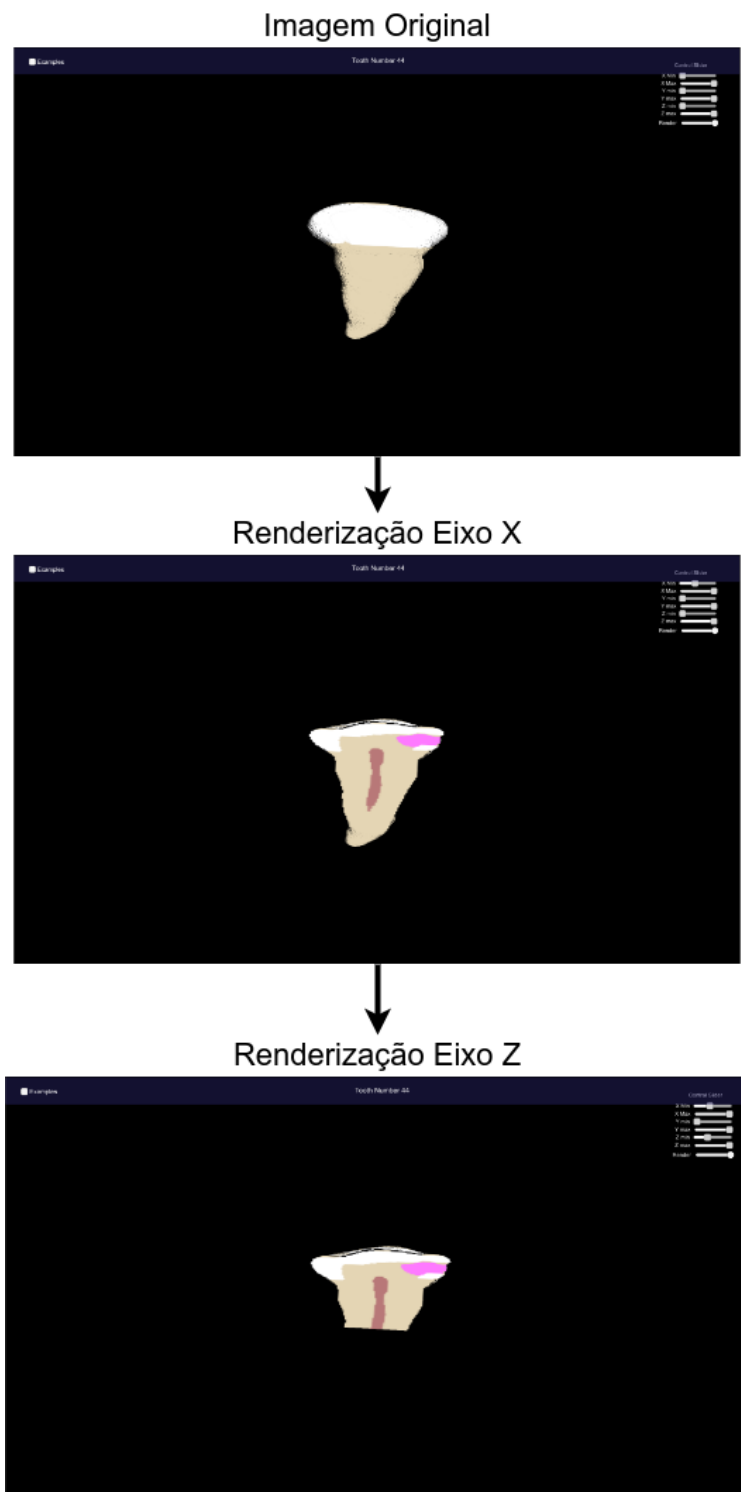


Figura 24: Aplicação de renderização, controle da renderização do modelo 3D em diferentes eixos.

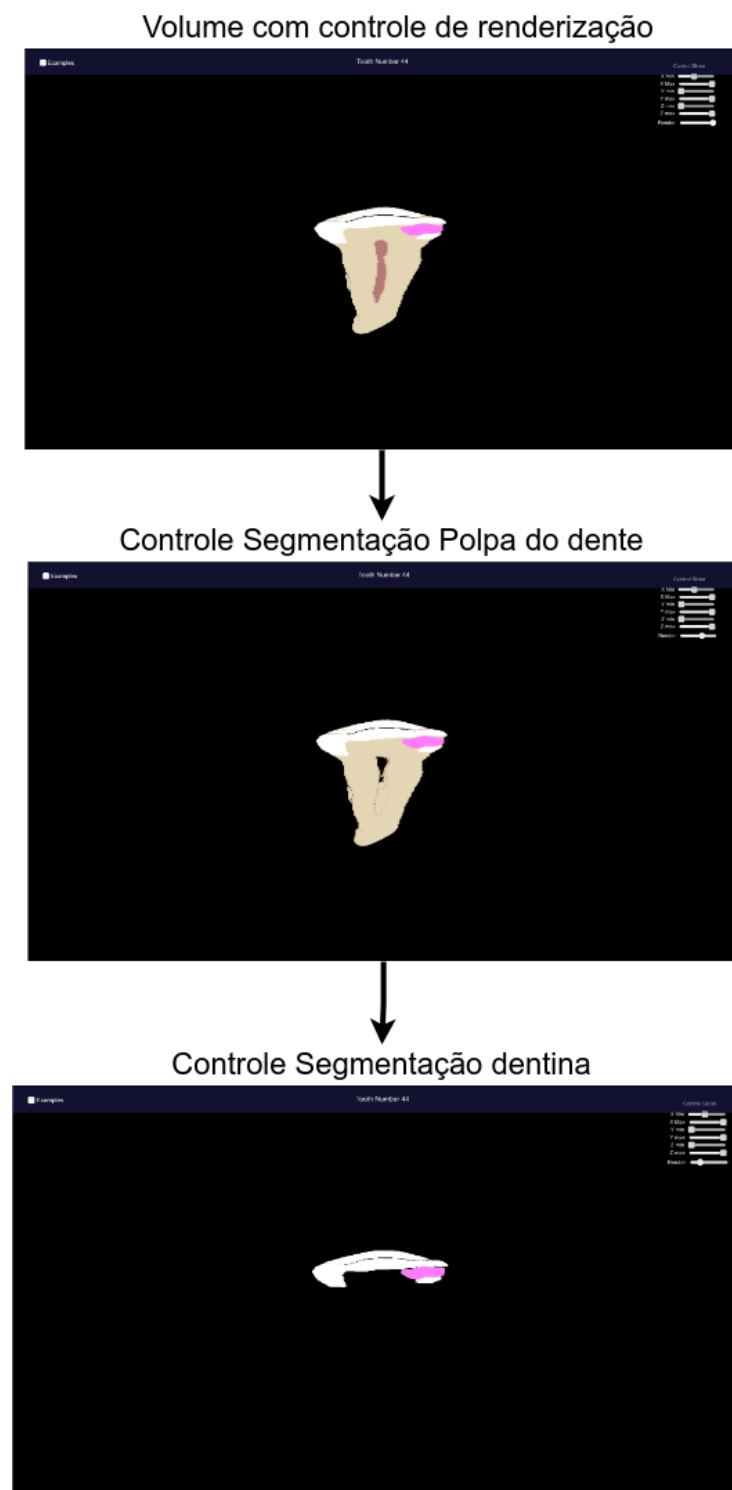


Figura 25: Controle da segmentação, separando os três tecidos principais: polpa do dente, dentina e esmalte.

5 RESULTADOS

Nessa seção são discutidos aspectos relevantes em relação ao uso de processamento de imagens e aprendizado supervisionado. Essas técnicas foram separadas em tópicos e as discussões com os respectivos resultados estão nas seções a seguir.

5.1 Processamento de imagens

A Figura 26 mostra a curva ROC obtida a partir da variação fornecida pelo parâmetro *scale* (Seção 4.3.2). A escolha do valor foi feita para reduzir a taxa de falsos-positivos e garantir uma alta taxa de verdadeiros positivos. Portanto o valor de *scale* = 0,91 foi escolhido para o protocolo HF, e *scale* = 0,92 para o protocolo HR, que corresponde a quebrada da escala contínua (indicado nos retângulos pretos na Figura 26) curvas ROC. A diferença dos protocolos foi discutida na Seção 4.2.




Figura 26: Curva ROC gerada a partir de dois protocolos, Alta resolução (HR) e Alta Fidelidade (HF). O retângulo preto corresponde a pontos com *scale* = 0,91 em HF e *scale* = 0,92 em HR.

Nas Tabelas 7 e 8 é possível observar os resultados da aplicação do método a oito dentes cariados com diferentes *scores ICDAS*, além disso os resultados possuem dois protocolos, HR e HF. A média de todas as métricas foi maior na execução do protocolo de HR como pode ser observado na Tabela 7.

Dentre todos os dentes, apenas o dente 6 obteve melhores resultados no protocolo HF. De maneira geral, o protocolo HR forneceu uma melhor estrutura para a segmentação da cárie. A diferença encontrada em ambos os protocolos ocorre na separação das estruturas. Antes de aplicarmos a limiarização multimodal, a intensidades dos *pixels* possui uma diferença, quando é obtido dois mínimos locais nos histogramas, isso afeta diretamente a separação das estruturas e, conseqüentemente, a segmentação final do método. Além disso, o protocolo de HR teve um melhor valor de AUC, conforme mostrado na Figura 26. Os resultados estão de acordo com as especificações do fabricante para fornecer imagens com estruturas ósseas delicadas, que podem ser estendidas para identificação de cárie.

Ezhov et al. (2021) utilizaram 4398 dentes para treinar um modelo com uma região contextualizada. Esse modelo obteve localização de cáries com sensibilidade de 72,85% e especificidade de 99,53%. Em comparação com (Ezhov et al., 2021), é possível observar que nosso estudo obteve especificidade e sensibilidade semelhantes. No, outras métricas propostas pelo nosso trabalho, como índice de Jaccard, f1-score, precisão e exatidão, não puderam ser comparadas, pois os outros trabalhos não apresentaram as mesmas métricas.

O uso de *deep learning* foi proposto em trabalhos como segmentação automática de dentes (LEE et al., 2020; WU et al., 2020; ZHENG et al., 2021; CUI; LI; WANG, 2019) e segmentação de lesões de cárie (Ezhov et al., 2021). Ainda assim, a falta de dados é um dos problemas significativos, uma vez que o uso de abordagens de aprendizado profundo requer um conjunto de dados com uma quantidade considerável de amostras. No presente trabalho obtivemos resultados como: AUC de 0.928, 88.50% de precisão e 99.58% de especificidade, bons resultados mesmo com um número reduzido de amostras em comparação com Ezhov et al. (2021).

Por outro lado, o processamento de imagens envolve algumas limitações, como obter técnicas específicas para separar as estruturas do dente, como: a limiarização multimodal, uso de morfologia matemática e aplicação da região de crescimento. Além disso, foi necessário estabelecer uma regra para reduzir a incidência de falsos positivos para o problema. Mesmo que haja limitações, neste trabalho foi possível observar um conjunto de técnicas de técnicas de processamento de imagem pode ser suficiente para identificar cáries em imagens TCFC quando o conjunto de dados que contém poucas amostras.

Tabela 7: Tabela com os resultados com o parâmetro $scale = 0.92$, utilizando o high resolution protocol

Tooth	ICDAS	Accuracy	Sensitivity	Specificity	Precision	F1-Score	Jaccard index
1	1	99.6	77.78	100.00	100.00	87.50	58.01
2	1	99.0	93.55	99.36	90.62	92.06	91.23
3	2	98.6	75.00	98.99	54.55	63.16	50.67
4	2	99.4	80.00	99.80	88.89	84.21	50.71
5	3	99.6	90.00	100.00	100.00	94.74	78.47
6	3	99.2	100.00	99.17	84.00	91.30	83.41
7	4	99.8	100.00	99.79	96.67	98.31	80.61
8	4	98.4	82.35	99.57	93.33	87.50	69.91
Mean (sd)		99.20 ± 0.50	87.33 ± 9.91	99.58 ± 0.37	88.50 ± 14.79	87.34 ± 10.74	70.37 ± 15.59

Tabela 8: Tabela com os resultados com o parâmetro $scale = 0.91$, utilizando high fidelity protocol

Tooth	ICDAS	Accuracy	Sensitivity	Specificity	Precision	F1-Score	Jaccard index
1	1	99.2	55.56	100.00	100.00	71.43	50.00
2	1	98.6	87.10	99.36	90.00	88.52	85.37
3	2	97.8	62.50	98.38	38.46	47.62	47.37
4	2	99.0	50.00	100.00	100.00	66.67	22.78
5	3	99.6	90.00	100.00	100.00	94.74	70.24
6	3	99.4	100.00	99.38	87.50	93.33	92.43
7	4	99.4	96.55	99.58	93.33	94.92	79.13
8	4	98.2	80.00	99.57	93.33	86.15	76.86
Mean (sd)		98.90 ± 0.64	77.71 ± 19.22	99.53 ± 0.53	87.82 ± 20.51	80.42 ± 17.01	65.52 ± 23.4

5.2 Classificação ICDAS

Neste trabalho, foram treinados três algoritmos de aprendizado de máquina avaliando o desempenho dos métodos empregados. Os dados utilizados para a aplicação do método de aprendizado de máquina foram discutidos na Seção 4.4.1.

Para a avaliação dos métodos empregados foram gerados quatro conjuntos de dados. Sendo a primeira variação correspondendo ao uso da técnica de redução e fusão de dimensionalidade *Principal Component Analysis* (PCA) (JOLLIFFE, 1986), utilizando um conjunto de características fundidas que explicam 90% da variância desses dados. A técnica PCA atua na redução da dimensionalidade do problema, o que pode diminuir a complexidade do problema oferecendo uma melhora na classificação dos modelos de aprendizado de máquina.

A outra variação no conjunto de dados corresponde à extração de características com o uso de processamento de imagens. Por meio da segmentação da lesão gerada da etapa do processamento de imagens é possível extrair características da dimensionalidade da lesão, fornecendo assim quatro tipos de conjunto de dados. A Tabela 9 possui as métricas de acurácia e F1 Score de cada um dos modelos.

Portanto, para esse presente trabalho foram testados três algoritmos de aprendizado

de máquina variando quatro conjuntos de dados. A primeira variação do conjunto de dados corresponde a extração de características sem utilizar a etapa de processamento de imagens, a segunda variação corresponde ao mesmo conjunto de dados no entanto utilizando o algoritmo PCA, a terceira variação corresponde ao uso de extração de características com processamento de imagens e por fim a quarta variação corresponde à utilização de processamento de imagens e o algoritmo PCA.

Tabela 9: Acurácia/F1-Score dos modelos utilizando quatro conjunto de dados. Foram extraídas características e comparadas com o uso de processamento de imagens e sem o uso de processamento de imagens, além disso com a técnica de redução de dimensionalidade (PCA).

Dados	SVM	RF	XG Boost
Sem processamento	91.66/92.08	85.24/85.23	96.56/96.14
Sem processamento (PCA)	90.11/89.74	83.22/81.87	90.15/88.71
Com processamento	97.07/96.58	95.55/92.35	97.56/96.46
Com processamento (PCA)	96.05/95.81	88.22/86.26	90.70/90.17

Na Tabela 9 é possível observar que o uso do processamento de imagens no aprendizado de máquina trouxe os melhores resultados. Além disso, é possível observar que o uso do algoritmo de PCA não ofereceu uma melhora nos classificadores utilizados. Apesar da PCA ser uma técnica de fusão de características, o vetor de características dos dados não possui uma dimensionalidade grande, dessa forma os classificadores não obtiveram uma melhora utilizando essa técnica.

5.2.1 Classificação sem o uso de processamento de imagens

Na Tabela 10 os resultados foram obtidos a partir da extração de características, no entanto os mesmos não utilizam a segmentação da lesão. Dessa forma, o algoritmo *XGBoost* obteve as melhores métricas tanto na acurácia quanto no F1-score médio.

Tabela 10: Acurácia/F1-Score obtidos utilizando a validação cruzada estratificada sem o uso de processamento

Métrica	SVM (std)	Random Forest (std)	XG Boost (std)
Acurácia	91.66 ± 2.56	90.15 ± 2.14	96.56 ± 4.08
F1-Score	92.08 ± 3.44	90.64 ± 5.85	96.14 ± 2.77

Apesar dos resultados obtidos serem inferiores ao uso de processamento de imagens, é possível observar que o conjunto de técnicas utilizado para a extração de características oferece informações aos modelos, atingindo acurácia e F1-Score acima de 90%. Sendo

assim é possível concluir que o uso das características de *haralick* e *hu moments* ofereceram informações relevantes para o treinamento desses modelos.

5.2.2 Classificação sem o uso de processamento de imagens e PCA

Os resultados da Tabela 11 utilizando a técnica PCA mostraram novamente que o algoritmo *XGBoost* obteve a melhor acurácia. No entanto, é possível observar que o algoritmo SVM possui um F1-Score médio maior que os outros modelos.

Tabela 11: Acurácia/F1-Score obtidos utilizando a validação cruzada estratificada sem o uso de processamento de imagens com PCA

Métrica	SVM (std)	Random Forest (std)	XG Boost (std)
Acurácia	90.11 ± 4.55	83.22 ± 4.23	90.15 ± 4.88
F1-Score	89.74 ± 2.56	81.17 ± 8.61	88.71 ± 6.195

A melhora do algoritmo SVM se comparado aos outros modelos pode ser explicada pela questão da dimensionalidade do problema. A fusão de características proporcionada pela técnica PCA ofereceu uma melhora no cálculo do hiperplano do algoritmo SVM. Consequentemente houve uma melhora nos resultados obtidos neste algoritmo.

5.2.3 Classificação com o uso de processamento de imagens

A tabela 12 apresenta as métricas de acurácia e f1 score médio obtidos no conjunto de dados de testes para a configurações de hiper parâmetros que obtiveram os melhores valores de acurácia média. É possível observar que a melhor acurácia média e F1-score médio foram encontrados no *XGBoost*.

Tabela 12: Acurácia/F1-Score obtidos utilizando a validação cruzada estratificada

Métrica	SVM (std)	Random Forest (std)	XG Boost (std)
Acurácia	97.07 ± 3.31	95.55 ± 3.33	97.56 ± 4.28
F1-Score	96.57 ± 2.56	92.35 ± 10.63	97.45 ± 1.69

Os melhores resultados na acurácia média podem ser explicados devido à combinação de técnicas do XG boost, utilizando a técnica de gradiente descendente e *bagging* com o conjunto de dados. Esse conjunto de técnicas combinadas tem tido resultados bastante expressivos tornando um dos classificadores mais utilizados na literatura (CHEN; GUESTRIN, 2016).

O algoritmo de *Random Forest* obteve um dos piores resultados se comparado a outros modelos. A aplicação do modelo de *Random Forest* em geral possui melhores resultados combinando o uso de dados categóricos (BREIMAN, 2001). No presente projeto todas as características utilizadas são dados numéricos, sendo assim a separação entre conjuntos não beneficiou tanto o uso desse algoritmo em específico.

5.2.4 Classificação com uso de processamento de imagens e PCA

Por fim temos a Tabela 13 que utiliza um conjunto de dados extraído características com o uso de processamento de imagens e PCA. O algoritmo de SVM obteve os melhores resultados tanto na acurácia e F1-score médio. Além disso, o desvio padrão desse modelo foi bem baixo se comparado com outros algoritmos de aprendizado de máquina.

Tabela 13: Acurácia/F1-Score obtidos utilizando a validação cruzada estratificada sem o uso de processamento de imagens

Métrica	SVM (std)	Random Forest (std)	XG Boost (std)
Acurácia	96.09 ± 3.43	88.22 ± 9.37	90.70 ± 4.28
F1-Score	95.81 ± 2.62	86.26 ± 7.65	90.17 ± 3.28

É possível notar que o uso de fusão de características piorou os resultados obtidos nos algoritmos de XGBoost, SVM e RF se comparado com a Tabela 12. O uso da técnica de PCA não melhorou nenhum dos resultados obtidos. A piora dos resultados pode ser explicada pelo fato das características do conjunto de dados não serem expressivas o suficiente. Dessa forma, a fusão de características não proporcionou uma melhor separação de classes.

5.2.5 Métricas específicas multiclasse

A avaliação de cada uma das cinco classes foi feita utilizando três métricas específicas: sensibilidade, especificidade e precisão. Sendo assim, cada gráfico gerado corresponde a um do conjunto de dados e as barras de cada um dos gráficos é um *Score*.

Na Figura 27 é possível observar que a métrica de sensibilidade possui o menor valor no *score* 2, evidenciando a dificuldade de classificar entre os *score* 1 e 3. Além disso, o algoritmo *XGBoost* apresentou sensibilidade em todas as classes valores maiores de 60%, evidenciando a eficiência deste algoritmo.

A métrica precisão (Figura 28) corresponde a quantidade de verdadeiros positivos sobre a soma de todos os valores preditos como positivos. É possível observar que todos

os valores de precisão no conjunto de dados com processamento tanto PCA e sem PCA obtiveram valores acima de 80%. No entanto, sem o uso de processamento de imagens essa métrica decaiu bastante chegando a atingir valores entre 70% a 80% nos casos de *score* 3 e 1.

Por fim temos a métrica de especificidade (Figura 29) que é a métrica que busca avaliar o número de resultados negativos. Nesse sentido todos os modelos apresentaram resultados superiores a 90%, dessa forma o número de falsos positivos é muito menor que os valores de verdadeiro negativos.




Figura 27: Métrica de desempenho: sensibilidade dos algoritmos SVM, RF e XGBoost.




Figura 28: Métrica de desempenho: precisão dos algoritmos SVM, RF e XGBoost.




Figura 29: Métrica de desempenho: especificidade dos algoritmos SVM, RF e XGBoost.

6 CONSIDERAÇÕES FINAIS

Neste trabalho foram desenvolvidos métodos para detectar, classificar e visualizar cáries dentárias. A detecção ou identificação foi baseada no uso de técnicas de processamento de imagem para a segmentação da cárie. A classificação da região de interesse foi desenvolvida por meio do uso de aprendizado de máquina, obtendo os melhores resultados com o algoritmo XGBoost. Os modelos foram treinados com um conjunto de dados utilizando características da etapa de processamento de imagens. Por fim, a visualização tridimensional interativa foi obtida por meio da reconstrução da TCFC e reproduzida no ambiente Unity.

Os resultados da etapa de processamento de imagens correspondem às métricas 88,5% de precisão 87,33%, de sensibilidade e 70,37% de Jaccard Index. É possível considerar que a utilização do método pode ser estendida a outros tipos de aplicações, como a detecção de outros tipos de cárie e segmentação do canal dentário.

Os resultados gerados neste trabalho fornecem evidências de que as técnicas de processamento de imagem podem segmentar e identificar a região lesada por cáries em imagens de TCFC. A abordagem utilizada foi capaz de identificar casos de cárie interproximal. Além disso, com as adaptações necessárias, o projeto pode proporcionar a segmentação de cada dente.

Na etapa de classificação foi possível atingir uma acurácia e F1-Score acima de 96%. Sendo assim, por meio do uso do aprendizado de máquina foi possível obter um modelo que classifica a lesão da cárie entre os níveis 0 e 4 com êxito.

Além disso, foi possível constatar que a utilização de processamento de imagens ofereceu uma melhora no modelo de aprendizado de máquina obtendo melhores métricas de desempenho. Dessa forma, o presente trabalho possui uma contribuição no uso de aprendizado supervisionado aplicado à Odontologia e processamento de imagem.

Para visualização 3D interativa foi proposto um conjunto de técnicas para auxiliar no diagnóstico da cárie e estudo da anatomia dentária. Por meio das técnicas de rotação,

controle de renderização e controle de segmentação, o sistema ofereceu características interativas sobre o modelo reconstruído do dente que permite melhor aprofundamento no estudo da caracterização das estruturas dentárias.

Conclui-se que as técnicas interativas possam corroborar para o aprendizado odontológico assim como auxílio diagnóstico. Apesar de não existirem resultados específicos do sistema, o levantamento bibliográfico assim como o modelo 3D, apresentam uma contribuição no uso de realidade virtual.

Para trabalhos futuros as técnicas de processamento de imagens serão submetidas a um conjunto maior de dados. Dessa forma será possível criar maiores evidências a respeito do método e comparar o mesmo com outros trabalhos da literatura, os quais propuseram o uso de aprendizado profundo nesse contexto de cárie.

Para classificação é esperado que seja utilizado o aprendizado profundo, comparando o mesmo com o método desenvolvido nesse projeto. Portanto, será possível obter comparações e discussões entre métodos e justificar o uso de aprendizado de máquina, gerando assim uma contribuição na literatura.

Para trabalhos na visualização tridimensional interativa é esperado que o sistema seja avaliado por um conjunto de odontologistas. Assim é possível coletar os resultados e avaliar as técnicas interativas. Além disso, é esperado coletar um *feedback* informal da opinião dos odontologistas, tornando possível a continuidade no presente projeto e alcançando melhorias no sistema.

As contribuições citadas podem potencialmente alcançar um impacto tecnológico uma vez que o sistema desenvolvido, depois de validado, pode ser implementado na rotina clínica dos dentistas. Assim, os resultados do projeto também podem trazer impacto social e econômico, pois diagnósticos mais precisos podem contribuir para intervenções mais precoces.

REFERÊNCIAS

- WHITE, M. J. P. S. C. RADIOLOGIA ORAL 7ª EDIÇÃO Fundamentos e Interpretação. 7nd ed. ed. Los Angeles, California: Elsevier Editora, 2015. ISBN 978-85-352-7841-5. páginas , 17, 19, 20, 21, 22, 23
- MATOS, A. B.; TURBINO, M. L.; MATSON, E. Efeito das técnicas de microabrasão no esmalte: estudo em microscopia eletrônica de varredura. Revista de Odontologia da Universidade de São Paulo, v. 12, p. 105–112, abr. 1998. ISSN 0103-0663. Publisher: Universidade de São Paulo. Disponível em: <http://www.scielo.br/j/rousp/a/9K8F4Cv6VkwQ5fGC4nYdzLD/?lang=pt>. páginas , 18
- Pitts, N. B. et al. Dental caries. v. 3, 2017. Disponível em: <https://www.nature.com/articles/nrdp201730>. páginas , 19
- Tyndall, D. A.; Rathore, S. Cone-beam ct diagnostic applications: caries, periodontal bone assessment, and endodontic applications. Dental Clinics of North America, Volume 52, p. 829, October 2018. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/18805231/>. páginas , 13, 24
- Peres, M. A. et al. Oral diseases: a global public health challenge. The Lancet, v. 394, p. 250–252, jul 2019. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/10916327/>. páginas 13, 17
- Piovesan, T. C. et al. Visual inspection for caries detection: A systematic review and meta-analysis. Journal of Dental Research International Association for Dental Research, v. 94, May 2015. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/25994176/>. páginas 13
- Pitts, N. B. The use of bitewing radiographs in the management of dental caries: scientific and practical considerations. Dentomaxillofacial Radiology, v. 25, Jan 2014. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/9084279/>. páginas 13, 19
- Gaalaas, L. et al. Ex vivo evaluation of new 2d and 3d dental radiographic technology for detecting caries. Dentomaxillofacial Radiology, Volume 45, January 2016. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/26670605/>. páginas 14, 20
- Patel, S. Cone beam computed tomography in endodontics a review. international endodontic Journal, v. 48, February 2014. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/iej.12270>. páginas 14
- Setzer, F. C. et al. A survey of cone-beam computed tomographic use among endodontic practitioners in the united states. international endodontic Journal, v. 43, May 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0099239916310676>. páginas 14

Scarfe, W. C.; Farman, A. G.; Sukovic, P. Clinical applications of cone-beam computed tomography in dental practice. 2006. Disponível em: <http://www.cda-adc.ca/jcda/vol-72/issue-1/75.html>. páginas 14, 20

Terrabuio, B. R. et al. Cone-beam computed tomography artifacts in the presence of dental implants and associated factors: an integrative review. Imaging Science in Dentistry, v. 51, n. 2, p. 93–106, jun. 2021. ISSN 2233-7822. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8219451/>. páginas 14

FELEMBAN, O. M.; LOO, C. Y.; RAMESH, A. Accuracy of Cone-beam Computed Tomography and Extraoral Bitewings Compared to Intraoral Bitewings in Detection of Interproximal Caries. The Journal of Contemporary Dental Practice, v. 21, n. 12, p. 1361–1367, dez. 2020. ISSN 1526-3711. páginas 14

KASRAEI, S. et al. Comparison of Cone-Beam Computed Tomography and Intraoral Radiography in Detection of Recurrent Caries under Composite Restorations. Brazilian Dental Journal, v. 28, p. 85–91, fev. 2017. ISSN 0103-6440, 1806-4760. Publisher: Fundação Odontológica de Ribeirão Preto. Disponível em: <http://www.scielo.br/j/bdj/a/6L9fgJbDWfXjrFpb8nxmx7v/?lang=en>. páginas 14

Geibel, M.-A. et al. Radiographic diagnosis of proximal caries—influence of experience and gender of the dental staff. Clinical Oral Investigations, February 2017. Disponível em: <https://link.springer.com/article/10.1007%2Fs00784-017-2078-2>. páginas 15

Zavgorodniy, A. V.; Rohanizadeh, R.; Swain, M. V. Ultrastructure of dentine carious lesions. Archives of oral biology, v. 53, p. 124–132, August 2007. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/17915189/>. páginas 17

Manzoli, F. R.; Rodrigues, L. J. A.; Groisman, S. Principais índices clínico-visuais para classifi cação de lesões de cárie e doença periodontal. jul 2010. Disponível em: https://www.researchgate.net/publication/220003441_Principais_indices_clinico-visuais_para_classificacao_de_lesoes_de_carie_e_doenca_periodontal. páginas 18

Menezes, M. L. F. V. de et al. The importance of dental biofilme control: a review of the literature. Electronic Journal CollectionHealth, August 2020. Disponível em: <https://acervomais.com.br/index.php/saude/article/view/3698>. páginas 18

Qudeimat, M. A. et al. Bmc oral health. 2019. Disponível em: <https://bmcoralhealth.biomedcentral.com/articles/10.1186/s12903-019-0730-8>. páginas 18

Pretty, I.; Ellwood, R. The caries continuum: Opportunities to detect, treat and monitor the re-mineralization of early caries lesions. Journal of dentistry, v. 41, 2013. Disponível em: <https://bmcoralhealth.biomedcentral.com/articles/10.1186/s12903-019-0730-8>. páginas 18

GAALAAS, L. et al. Ex vivo evaluation of new 2D and 3D dental radiographic technology for detecting caries. Dento Maxillo Facial Radiology, v. 45, n. 3, p. 20150281, 2016. ISSN 0250-832X. páginas 20

GONZALEZ, R. E. W. R. C. Digital Image Processing. 2nd ed. ed. New Jersey, USA: Prentice Hall, 2002. ISBN 9780201180756. páginas 24, 25

- SZELISKI, R. Computer Vision. Washington, USA: Springer London, 2011. páginas 25
- HARING, D. R. Multi-threshold threshold elements. IEEE Transactions on Electronic Computers, EC-15, n. 1, p. 45–65, fev. 1966. ISSN 0367-7508. Conference Name: IEEE Transactions on Electronic Computers. páginas 25
- SINGH, S.; SRIVASTAVA, D.; AGARWAL, S. GLCM and its application in pattern recognition. In: 2017 5th International Symposium on Computational and Business Intelligence (ISCBI). [S.l.: s.n.], 2017. p. 20–25. páginas 26
- PROKOP, R. J.; REEVES, A. P. A survey of moment-based techniques for unoccluded object representation and recognition. CVGIP: Graphical Models and Image Processing, v. 54, n. 5, p. 438–460, set. 1992. ISSN 1049-9652. Disponível em: <https://www.sciencedirect.com/science/article/pii/104996529290027U>. páginas 27
- MURPHY, K. P. Machine learning: a probabilistic perspective. [S.l.]: MIT press, 2012. páginas 29
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: Proceedings of the 14th international joint conference on Artificial intelligence - Volume 2. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995. (IJCAI'95), p. 1137–1143. ISBN 978-1-55860-363-9. páginas 29
- CERVANTES, J. et al. A comprehensive survey on support vector machine classification: Applications, challenges and trends. Neurocomputing, v. 408, p. 189–215, set. 2020. ISSN 0925-2312. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0925231220307153>. páginas 30
- RIFKIN, R.; KLAUTAU, A. In Defense of One-Vs-All Classification. The Journal of Machine Learning Research, v. 5, p. 101–141, dez. 2004. ISSN 1532-4435. páginas 31
- BREIMAN, L. Random Forests. Machine Learning, v. 45, n. 1, p. 5–32, out. 2001. ISSN 1573-0565. Disponível em: <https://doi.org/10.1023/A:1010933404324>. páginas 31, 65
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, NY, USA: Association for Computing Machinery, 2016. (KDD '16), p. 785–794. ISBN 9781450342322. Disponível em: <https://doi.org/10.1145/2939672.2939785>. páginas 32, 64
- Ezhov, M. et al. Clinically applicable artificial intelligence system for dental diagnosis with CBCT. Scientific Reports, v. 11, n. 1, jul. 2021. ISSN 2045-2322. Disponível em: <https://www.nature.com/articles/s41598-021-94093-9>. páginas 35, 36, 61
- Ronneberger, O.; Fischer, P.; Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. arXiv:1505.04597 [cs], maio 2015. ArXiv: 1505.04597. Disponível em: <http://arxiv.org/abs/1505.04597>. páginas 35
- CHEN, R.; ZHANG, H. Large-scale 3D Reconstruction with an R-based Analysis Workflow. In: Proceedings of the Fourth IEEE/ACM International Conference on Big Data Computing, Applications and Technologies. New York, NY, USA: Association for Computing Machinery, 2017. (BDCAT '17), p. 85–93. ISBN 978-1-4503-5549-0. Disponível em: <https://doi.org/10.1145/3148055.3148062>. páginas 35

AHMED, S. et al. Identification and volume estimation of dental caries using CT image. In: 2017 IEEE International Conference on Telecommunications and Photonics (ICTP). [S.l.: s.n.], 2017. p. 48–51. páginas 35

SETZER, F. C. et al. A Survey of Cone-beam Computed Tomographic Use among Endodontic Practitioners in the United States. Journal of Endodontics, v. 43, n. 5, p. 699–704, maio 2017. ISSN 0099-2399. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0099239916310676>. páginas 35

Oltu, B. et al. Detection of occlusal plaque and caries using fuzzy c means based segmentation algorithm. 2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA), August 2021. Disponível em: <https://ieeexplore.ieee.org/document/9548375>. páginas 35

Kumari, A. R.; RAO, S. N.; REDDY, P. R. Heuristically Modified Fusion-based Hybrid Algorithm for Enhanced Dental Caries Segmentation. In: 2022 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI). [S.l.: s.n.], 2022. p. 1–7. páginas 36

Mohammad-Rahimi, H. et al. Deep learning for caries detection: A systematic review. Journal of Dentistry, v. 122, p. 104115, jul. 2022. ISSN 0300-5712. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0300571222001725>. páginas 36, 37

Verma, D. et al. Anomaly detection in panoramic dental x-rays using a hybrid deep learning and machine learning approach. 2020 IEEE REGION 10 CONFERENCE (TENCON), November 2020. Disponível em: <https://ieeexplore.ieee.org/document/9293765>. páginas 36

Patil, S.; KULKARNI, V.; BHISE, A. Caries detection with the aid of multilinear principal component analysis and neural network. 2018 Second International Conference on Green Computing and Internet of Things (ICGCIoT), August 2018. Disponível em: <https://ieeexplore.ieee.org/document/8753002>. páginas 36

Prados-Privado, M. et al. Dental caries diagnosis and detection using neural networks: A systematic review. Digital Workflows and Material Sciences in Dental Medicine, October 2020. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/33172056/>. páginas 36

Imak, A. et al. Dental Caries Detection Using Score-Based Multi-Input Deep Convolutional Neural Network. IEEE Access, v. 10, p. 18320–18329, 2022. ISSN 2169-3536. Conference Name: IEEE Access. páginas 36

CHIODERA, G. et al. Essential Lines: a simplified filling and modeling technique for direct posterior composite restorations. The International Journal of Esthetic Dentistry, v. 16, n. 2, p. 168–184, maio 2021. ISSN 2198-591X. páginas 36

BOER, I. R. de; WESSELINK, P. R.; VERVOORN, J. M. Student performance and appreciation using 3D vs. 2D vision in a virtual learning environment. European Journal of Dental Education, v. 20, n. 3, p. 142–147, 2016. ISSN 1600-0579. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/eje.12152>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/eje.12152>. páginas 37

- IWANAGA, J. et al. A new option for education during surgical procedures and related clinical anatomy in a virtual reality workspace. Clinical Anatomy, v. 34, n. 3, p. 496–503, 2021. ISSN 1098-2353. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/ca.23724>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/ca.23724>. páginas 37
- ZAFAR, S. et al. Virtual Reality as a novel educational tool in pre-clinical paediatric dentistry training: Students' perceptions. International Journal of Paediatric Dentistry, v. 30, n. 6, p. 791–797, 2020. ISSN 1365-263X. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/ipd.12648>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/ipd.12648>. páginas 37
- KHANAGAR, S. B. et al. Scope and performance of artificial intelligence technology in orthodontic diagnosis, treatment planning, and clinical decision-making - A systematic review. Journal of Dental Sciences, v. 16, n. 1, p. 482–492, jan. 2021. ISSN 1991-7902. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1991790220301161>. páginas 37
- Mueller, P. O.; Lowder, M. Q. Dental sepsis. The Veterinary Clinics of North America. Equine Practice, v. 14, n. 2, p. 349–363, vii, ago. 1998. ISSN 0749-0739. páginas 37
- FOUNDATION, P. S. Python. 2022. <https://www.python.org/>. Accessed on 10-dez-2022. páginas 39
- TEAM, O. OpenCV. 2022. <https://opencv.org/>. Accessed on 13-dez-2022. páginas 39
- HAAS, J. K. A history of the unity game engine. Worcester Polytechnic Institute, 2014. páginas 40, 55
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in python. Journal of machine learning research, v. 12, n. Oct, p. 2825–2830, 2011. páginas 40
- MASON, D. Su-e-t-33: pydicom: an open source dicom library. Medical Physics, Wiley Online Library, v. 38, n. 6Part10, p. 3493–3493, 2011. páginas 40
- YUSHKEVICH, P. A. et al. User-guided 3D active contour segmentation of anatomical structures: Significantly improved efficiency and reliability. Neuroimage, v. 31, n. 3, p. 1116–1128, 2006. páginas 41
- CORPORATION, J. M. 3D Accuitomo 170 | MORITA. 2013. Disponível em: <https://www.jmoritaeurope.de/america/en/products/diagnostic-and-imaging-equipment/cone-beam-ct-systems/3d-accuitomo-170/>. páginas 41
- Razi, T.; Niknami, M.; Ghazani, F. A. Relationship between Hounsfield Unit in CT Scan and Gray Scale in CBCT. Journal of Dental Research, Dental Clinics, Dental Prospects, v. 8, n. 2, p. 107–110, 2014. ISSN 2008-210X. páginas 41
- Ali, A. S.; Fteita, D.; Kulmala, J. Comparison of physical quality assurance between Scanora 3D and 3D Accuitomo 80 dental CT scanners. The Libyan Journal of Medicine, v. 10, n. 1, p. 28038, jan. 2015. ISSN 1819-6357. páginas 42

TSAI, D.-M. A fast thresholding selection procedure for multimodal and unimodal histograms. *Pattern Recognition Letters*, v. 16, n. 6, p. 653–666, jun. 1995. ISSN 0167-8655. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016786559580011H>. páginas 43

SKLANSKY, J. Finding the convex hull of a simple polygon. *Pattern Recogn. Lett.*, Elsevier Science Inc., USA, v. 1, n. 2, p. 79–83, dec 1982. ISSN 0167-8655. Disponível em: [https://doi.org/10.1016/0167-8655\(82\)90016-2](https://doi.org/10.1016/0167-8655(82)90016-2). páginas 46

GRAF, A. B.; BORER, S. Normalization in Support Vector Machines. In: RADIG, B.; FLORCZYK, S. (Ed.). *Pattern Recognition*. Berlin, Heidelberg: Springer, 2001. (Lecture Notes in Computer Science), p. 277–282. ISBN 978-3-540-45404-5. páginas 51

TAX, D. M. J.; DUIN, R. P. W. Feature Scaling in Support Vector Data Descriptions. p. 6, 2000. páginas 51

LEE, S. et al. Automated CNN-Based Tooth Segmentation in Cone-Beam CT for Dental Implant Planning. *IEEE Access*, v. 8, p. 50507–50518, 2020. ISSN 2169-3536. Conference Name: IEEE Access. páginas 61

WU, X. et al. Center-Sensitive and Boundary-Aware Tooth Instance Segmentation and Classification from Cone-Beam CT. In: *2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI)*. [S.l.: s.n.], 2020. p. 939–942. ISSN: 1945-8452. páginas 61

ZHENG, Z. et al. Anatomically Constrained Deep Learning for Automating Dental CBCT Segmentation and Lesion Detection. *IEEE Transactions on Automation Science and Engineering*, v. 18, n. 2, p. 603–614, abr. 2021. ISSN 1558-3783. Conference Name: IEEE Transactions on Automation Science and Engineering. páginas 61

CUI, Z.; LI, C.; WANG, W. ToothNet: Automatic Tooth Instance Segmentation and Identification From Cone Beam CT Images. In: *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2019. p. 6361–6370. ISSN: 2575-7075. páginas 61

JOLLIFFE, I. *Principal Component Analysis*. [S.l.]: Springer Verlag, 1986. páginas 62