

# UMA ANÁLISE COMPARATIVA DE TÉCNICAS DE SEGMENTAÇÃO PARA IMAGENS ODONTOLÓGICAS

## A COMPARATIVE ANALYSIS OF SEGMENTATION TECHNIQUES FOR DENTAL IMAGES

Pedro Ivaldo Valença Rocha<sup>1</sup>  
Felipe Alberto B. S. Ferreira<sup>2</sup>

### RESUMO

A segmentação de imagens odontológicas é uma etapa fundamental para a análise automatizada de exames radiográficos, pois possibilita a identificação precisa de estruturas anatômicas relevantes para o diagnóstico clínico. Este trabalho tem como objetivo realizar uma análise comparativa entre diferentes técnicas tradicionais de segmentação aplicadas a radiografias panorâmicas odontológicas. Foram avaliados métodos baseados em contornos ativos, agrupamento e modelagem estatística, especificamente *Chan-Vese*, *Morphological Chan-Vese*, *K-means* e *Gaussian Mixture Model*. A metodologia consistiu na aplicação dessas técnicas a um conjunto de imagens radiográficas previamente segmentadas por especialistas, utilizado como referência (*ground truth*), seguido da avaliação quantitativa por meio das métricas de acurácia, precisão, *recall*, especificidade e *F1-score*, além de análise qualitativa dos resultados obtidos. Os resultados indicam que os métodos tradicionais apresentam desempenho satisfatório em imagens com bom contraste e baixa complexidade estrutural, porém demonstram limitações em cenários com ruído, baixo contraste e sobreposição anatômica. Dentre os métodos analisados, o *Morphological Chan-Vese* apresentou desempenho global superior, evidenciando maior robustez e equilíbrio entre as métricas avaliadas. Conclui-se que a escolha da técnica de segmentação deve considerar as características da imagem, o objetivo clínico e os recursos computacionais disponíveis, contribuindo para o desenvolvimento de sistemas de apoio ao diagnóstico odontológico.

**Palavras-chave:** processamento digital de imagens; segmentação de imagens; técnicas de segmentação; imagens odontológicas radiográficas.

### ABSTRACT

The segmentation of dental images is a fundamental step for the automated analysis of radiographic examinations, as it enables the accurate identification of anatomical structures relevant to clinical diagnosis. This study aims to perform a comparative analysis of different traditional image segmentation techniques applied to panoramic dental radiographs. Methods based on active contours, clustering, and statistical modeling were evaluated, specifically Chan-Vese, Morphological Chan-Vese, K-means, and Gaussian Mixture Model. The methodology consisted of applying these techniques to a dataset of radiographic images previously segmented by specialists and used as ground truth, followed by quantitative evaluation using accuracy, precision, recall, specificity, and F1-score metrics, in addition to qualitative analysis of the obtained results. The results indicate that traditional methods achieve satisfactory performance in images with good contrast and low structural complexity but show limitations in scenarios with noise, low contrast, and anatomical overlap. Among the analyzed methods, Morphological Chan-Vese demonstrated superior overall performance, exhibiting greater robustness and better balance among the evaluated metrics. It is concluded that the choice of segmentation

---

<sup>1</sup> Bacharelado em Engenharia Eletrônica pela Universidade Federal Rural de Pernambuco - Unidade Acadêmica do Cabo de Santo Agostinho, 2025

<sup>2</sup> Doutor em Engenharia Elétrica pela Universidade Federal de Pernambuco (UFPE) em 2020.

technique should consider image characteristics, clinical objectives, and available computational resources, contributing to the development of computer-aided dental diagnosis systems.

**Keywords:** image processing; image segmentation; segmentation techniques; radiographic dental images.

## INTRODUÇÃO

O avanço dos sistemas computacionais e dos algoritmos de processamento digital de sinais e imagens tem impulsionado o desenvolvimento de soluções automatizadas para análise de dados visuais em diversas aplicações de engenharia. Nesse contexto, a segmentação de imagens é considerada uma etapa fundamental, pois tem como finalidade subdividir uma imagem em regiões ou objetos de interesse, possibilitando a extração de informações relevantes para análises automatizadas (Gonzales; Woods, 2018).

Essa técnica pode ser aplicada em diferentes níveis de detalhamento, de acordo com a necessidade da análise, e constitui uma ferramenta indispensável para tornar a interpretação de dados visuais mais precisa e confiável. Com o avanço das tecnologias computacionais e o crescimento da quantidade de informações visuais disponíveis, a segmentação se consolidou como uma área estratégica em diversos campos científicos e tecnológicos (Bishop, 2006). Nessas aplicações, o uso de métodos computacionais contribui para a redução da subjetividade humana, além de permitir maior repetibilidade e padronização dos resultados.

Com isso, a ferramenta pode ser aplicada em diversas áreas, uma delas é na área da saúde, em especial na odontologia, em que a segmentação de imagens desempenha papel fundamental. As radiografias dentárias são amplamente utilizadas na prática clínica, pois permitem visualizar estruturas internas da cavidade bucal de forma rápida e acessível, além de apresentarem baixo custo em comparação a outros exames de imagem (White; Pharoah, 2014). Esses registros radiográficos podem

ser obtidos em duas modalidades principais: intraorais, quando o sensor é posicionado dentro da boca, e extraorais, quando o sensor é colocado externamente. Em ambos os casos, tais imagens representam uma fonte valiosa de dados para diagnósticos, planejamento de tratamentos e até mesmo processos de identificação humana em contextos forenses.

Apesar de sua importância clínica, a interpretação de radiografias odontológicas está sujeita a limitações e variabilidade. Desde a década de 1940, erros diagnósticos associados à análise de imagens médicas vêm sendo relatados, incluindo falhas na identificação de alterações anatômicas e patológicas (Cooper *et al.*, 2009). Na odontologia, estudos indicam que a avaliação radiográfica pode apresentar inconsistências significativas entre profissionais, influenciadas por fatores como experiência clínica, formação acadêmica e diferenças individuais na capacidade de reconhecimento de padrões visuais (Sherwood, 2012).

A literatura aponta que a variabilidade no desempenho de radiologistas decorre de múltiplos fatores, incluindo diferença na tomada de decisão e na capacidade de reconhecimento de padrões, delimitação de limites e bordas, os quais necessitam de habilidades que, por sua vez, podem ser influenciadas pela formação acadêmica, pela experiência profissional ou ainda por diferenças individuais de ordem perceptiva (Sunday; Donnelly; Gauthier, 2017).

Independentemente de sua relevância, a análise de radiografias dentárias enfrenta limitações que tornam a segmentação uma tarefa complexa. Entre os principais desafios, destacam-se o baixo contraste entre estruturas, a presença de

ruídos, a sobreposição de regiões anatômicas e a variação de forma e tamanho dos dentes (Chen *et al.*, 2020). Além disso, fatores técnicos relacionados ao processo de aquisição das imagens, como distorções, superexposição e artefatos, também interferem na qualidade final. Esses elementos dificultam a identificação clara de estruturas como raízes dentárias, canais radiculares e implantes, exigindo métodos de segmentação capazes de isolar e evidenciar as regiões de interesse com maior precisão (Pauwels; Jacobs; Horner, 2015).

Nesse cenário, diferentes técnicas de segmentação têm sido desenvolvidas e aplicadas com o intuito de superar tais limitações. Entre elas, destacam-se os métodos *Chan-Vese* (Chan; Vese, 2001), *Morphological Chan-Vese* (Vachier; Meyer, 2005), *K-means* (Hartigan; Wong, 1979) e *Gaussian Mixture Model* (Reynolds, 2009), que apresentam características particulares. O método *Chan-Vese* é especialmente eficaz em situações em que as bordas dos objetos não são bem definidas. O *Morphological Chan-Vese*, por sua vez, aprimora esse processo ao incorporar operações morfológicas, tornando-se mais robusto e veloz. Já o *K-means* se caracteriza por ser simples e eficiente, embora dependa de parâmetros iniciais bem ajustados para alcançar bons resultados. Por fim, o *Gaussian Mixture Model* se diferencia pela flexibilidade, permitindo representar diferentes formas e distribuições dentro da imagem. Essa diversidade metodológica possibilita a adaptação da segmentação a diferentes tipos de imagens e objetivos de análise.

O presente estudo busca analisar comparativamente o desempenho desses quatro métodos aplicados à segmentação de dentes em radiografias panorâmicas odontológicas, em consonância com estudos prévios que investigam a aplicação de técnicas de segmentação nesse tipo de imagem (Silva *et al.*, 2018). A escolha dessa modalidade radiográfica se justifica pela

sua abrangência, pois possibilita a visualização simultânea de toda a arcada dentária e das estruturas ósseas adjacentes, fornecendo informações essenciais para diagnósticos clínicos e procedimentos cirúrgicos. Para realizar essa avaliação, serão utilizadas métricas quantitativas e qualitativas, tais como acurácia, *recall*, precisão e *F1-score*, que permitirão mensurar o desempenho dos métodos de forma objetiva. Além disso, a análise será conduzida com base em um banco de radiografias previamente segmentadas (*ground truth*), disponibilizado pela UFBA/UESC (Pinheiro *et al.*, 2020), garantindo confiabilidade nos resultados obtidos.

A relevância deste trabalho reside na possibilidade de contribuir para o aprimoramento das ferramentas computacionais de apoio ao diagnóstico odontológico. A comparação entre diferentes métodos de segmentação pode indicar quais técnicas apresentam maior adequação para lidar com os desafios específicos das radiografias dentárias, fornecendo subsídios para aplicações práticas em consultórios e centros de pesquisa. Ademais, os avanços na segmentação de imagens radiográficas não apenas favorecem diagnósticos mais precisos e tratamentos mais eficazes, como também podem ampliar o uso dessas tecnologias em áreas correlatas, como a cirurgia bucomaxilofacial, a implantodontia e a odontologia legal (Kaur; Jain, 2019).

Dessa forma, este estudo se insere em um contexto de crescente interesse pelo uso de métodos computacionais aplicados à saúde, com potencial de impactar positivamente a prática odontológica e a qualidade de vida dos pacientes. Ao investigar comparativamente quatro técnicas de segmentação, busca-se não apenas identificar a mais eficiente em termos de desempenho técnico, mas também fomentar o desenvolvimento de soluções mais acessíveis e eficazes para a

análise de imagens radiográficas no âmbito odontológico.

## OBJETIVOS

Com o avanço das tecnologias e a evolução das técnicas de análise de imagens aplicadas ao diagnóstico clínico, o objetivo deste trabalho é analisar métodos de segmentação de imagens digitais, visando contribuir para o aprimoramento de processos automatizados, os quais proporcionam maior celeridade ao diagnóstico, ampliando as possibilidades de êxito no tratamento.

### Objetivo Geral

Realizar uma análise comparativa e qualitativa de diferentes técnicas de segmentação de imagens aplicadas a imagens odontológicas, mais especificamente, radiografias panorâmicas.

### Objetivos específicos

- Estudar os conceitos básicos de segmentação de imagens no contexto do processamento digital de imagens;
- Analisar as principais técnicas de segmentação de imagens utilizadas em aplicações de engenharia;
- Realizar a segmentação de imagens odontológicas utilizando as técnicas *Chan-Vese*, *Morphological Chan-Vese*, *K-means* e *Gaussian Mixture Model (GMM)*;
- Realizar uma comparação dos resultados de segmentação em termos de acurácia, recall, especificidade, precisão e *F1-score*.

## FUNDAMENTAÇÃO TEÓRICA

A radiografia odontológica começou a ser utilizada no início do século

XX (White; Pharoah, 2014). Desde então, esses exames evoluíram de forma significativa, acompanhando os avanços tecnológicos da medicina diagnóstica por imagem. Essa evolução permitiu a obtenção de imagens com melhor qualidade, maior resolução espacial e maior confiabilidade para a análise clínica.

Inicialmente, em formato analógico, as radiografias eram registradas em filmes, demandando tempo de revelação e suscetibilidade a falhas no processo químico (Farman; Scarfe, 2006). Com a chegada da era digital, ocorreram melhorias na qualidade das imagens e maior praticidade no armazenamento.

Além disso, surgiu a possibilidade de utilização de técnicas de processamento e análise computacionais, automatizando o processo e abrindo caminhos para estudos mais avançados em segmentação. Com base nesse panorama, observa-se que a fundamentação teórica não deve considerar apenas aspectos técnicos, sendo de fundamental relevância discutir também como essas imagens são obtidas, o processo de segmentação e suas aplicações, além das dificuldades enfrentadas durante esse processo.

Nesta seção, serão abordadas as definições essenciais, começando pela obtenção das imagens radiográficas na odontologia, seguidas por uma discussão sobre os conceitos e métodos de segmentação de imagens, os quais formam a base teórica necessária para compreender as abordagens e desafios tratados neste trabalho.

### Imagens radiográficas odontológicas

As imagens feitas por raio-x são parte fundamental da anamnese clínica em consultas odontológicas (White; Pharoah, 2014). Sua importância se deve ao fato de que aumentam a precisão dos diagnósticos e, consequentemente, tornam os tratamentos recomendados mais eficazes.

Essas imagens proporcionam aos profissionais uma visão detalhada das estruturas dentárias, ósseas e dos tecidos circundantes que não são visíveis apenas com inspeção visual.

Neste trabalho, foram utilizadas imagens de raio-x panorâmicas, amplamente empregadas na odontologia por sua capacidade de capturar uma visão completa da estrutura dentária e maxilofacial.

Segundo White e Pharoah (2007), as radiografias panorâmicas são fundamentais para a avaliação inicial de pacientes, fornecendo detalhes essenciais para diagnósticos e planos de tratamento. A estrutura apresentada na Figura 1 é um exemplo de uma imagem de raio-x panorâmica.

Figura 1 – Imagem de um Raio-x panorâmico



Fonte: White; Pharoah, 2007.

Com avanço da era digital, esse tipo de exame passou por transformações significativas. A digitalização trouxe melhorias na qualidade das imagens e maior praticidade no armazenamento, ao mesmo tempo em que introduziu novos desafios no processamento e análise dos dados. Nesse sentido, o termo “digital” refere-se tanto ao formato numérico das imagens quanto aos seus detalhes (White; Pharoah, 2007).


Diferentemente das radiografias analógicas, as quais possuem uma escala de densidade contínua, as imagens digitais são caracterizadas pela distribuição espacial dos píxeis e tons de cinza associados. Esse resultado é obtido por meio do processo de conversão analógico-digital (CAD), que

envolve a amostragem e a quantificação dos sinais analógicos gerados pelos raios-x, permitindo uma visualização mais detalhada e passível de processamento computacional (White; Pharoah, 2007).

## Segmentação de imagem

A segmentação de imagens é um processo essencial no processamento digital de imagens, utilizado para dividir uma imagem em regiões distintas com base em critérios predefinidos, como cor, intensidade ou textura (Gonzalez; Woods, 2018). Na Figura 2, é apresentado um exemplo de segmentação, no qual a imagem original representa uma situação do cotidiano, especificamente um cenário de tráfego urbano, contendo diferentes elementos, como veículos, pedestres, edificações e árvores. A imagem segmentada destaca algumas dessas regiões, permitindo a identificação de áreas de interesse.

Figura 2 – Exemplo de segmentação de imagem em cenário urbano



Fonte: Visão Computacional, 2022. Disponível em: <https://visaocomputacional.com.br>.

A partir dessa segmentação, é possível realizar diversas análises, como o controle do tráfego, a estimativa do tempo de travessia de faixas de pedestres com base na quantidade de pessoas, a verificação do porte das árvores, entre outras aplicações. Dessa forma, observa-se que a segmentação

de imagens possibilita a extração de informações relevantes e a tomada de decisões a partir dos dados visuais analisados.

Em aplicações médicas, a segmentação desempenha um papel crucial na identificação e análise de estruturas anatômicas, permitindo diagnósticos mais precisos e a automatização de processos de detecção de patologias (Suzuki, 2017). O objetivo principal é simplificar ou alterar a representação de uma imagem, facilitando a análise e a interpretação. O principal objetivo da segmentação é identificar e isolar as áreas de interesse em uma imagem, para facilitar a análise ou a tomada de decisão. Quando aplicável, destacam-se regiões relevantes, como órgãos, tecidos ou lesões, e ignoram-se áreas irrelevantes para o diagnóstico.

No caso das radiografias panorâmicas odontológicas, a segmentação é utilizada para isolar regiões de interesse, como dentes, mandíbula e maxila, facilitando análises clínicas e tratamentos odontológicos.

### **Métodos de segmentação utilizados no trabalho**

A segmentação de imagens odontológicas é um passo fundamental para a análise automatizada de exames como radiografias periapicais, panorâmicas e tomografias computadorizadas, permitindo a separação precisa de estruturas anatômicas (dentes, raízes, ossos) e detecção de patologias (cáries, lesões, abscessos).

O objetivo da segmentação é distinguir as diferentes regiões da imagem com base em propriedades homogêneas, como intensidade, textura e forma, possibilitando que algoritmos de visão computacional identifiquem padrões clínicos relevantes.

Para realizar a segmentação das imagens de radiografias panorâmicas odontológicas, foram utilizados quatro

métodos distintos: Chan-Vese, Morphological Chan-Vese, K-means e Gaussian Mixture Model (GMM).

Cada um desses métodos possui abordagens específicas e é adequado para diferentes aplicações, determinadas conforme as características da imagem.

O método Chan-Vese é baseado em um modelo de contorno ativo que não depende explicitamente de gradientes, permitindo a detecção de bordas suaves e regiões homogêneas. Ele é amplamente utilizado em imagens médicas por sua capacidade de segmentar estruturas com limites poucos definidos, comuns em radiografias odontológicas (Chan; Vese, 2001).

A variação Morphological Chan-Vese combina o modelo clássico de contorno ativo sem dependência explícita de gradientes, proposto por Chan e Vese (2001), com operações morfológicas, acelerando a convergência do algoritmo e tornando-o mais robusto à presença de ruído e artefatos (Getreuer, 2012). Essa abordagem contribui para a obtenção de contornos mais contínuos e estáveis em regiões anatômicas com baixo contraste.

Já o método K-means utiliza um algoritmo de agrupamento não supervisionado que classifica os pixels em  $k$  grupos distintos com base na intensidade ou cor. Apesar de um método relativamente simples, ele apresenta bons resultados em imagens com contraste definido entre estruturas (Jain; Murty; Flynn, 1999).

Por fim, o Gaussian Mixture Model (GMM) realiza a segmentação modelando a distribuição dos pixels como uma combinação de múltiplas distribuições Gaussianas. Esse método é capaz de lidar com heterogeneidades de intensidade e regiões com variação gradual de tons de cinza, o que torna adequado para radiografias onde as transições entre tecidos são sutis (Reynolds, 2009).

A comparação entre esses métodos permite avaliar suas vantagens e limitações sob diferentes aspectos da imagem, como

contrate, ruído, nitidez de contornos e complexidade estrutural, possibilitando identificar o modelo mais eficaz para o diagnóstico odontológico sob o ponto de vista quantitativo, utilizando métricas de avaliação

### Aplicação em raio-x odontológico

A escolha das radiografias panorâmicas odontológicas como objeto de estudo se deve à relevância clínica desse exame na odontologia. Pois, além da necessidade das imagens para diagnóstico médico, acompanhamento, avaliação e desenvolvimento de planos de tratamento, a radiografia também é utilizada na identificação de cadáveres humanos.

Em casos de catástrofes, a identificação da vítima pode ser muito complicada devido à destruição ou estado avançado da decomposição da matéria orgânica, nesses casos os dentes são muitas vezes o único meio de identificar a vítima.

Desse modo, compreende-se a necessidade de processos ágeis e automáticos para dar celeridade no acompanhamento médico ou identificação de múltiplas vítimas em caso de grandes catástrofes. Entretanto, a segmentação dessas imagens ainda é um desafio devido à complexidade anatômica, sobreposição de estruturas e variação na qualidade da imagem.

A avaliação dos métodos propostos permitirá identificar quais técnicas são mais adequadas para esse tipo de imagem, contribuindo para avanços na segmentação automática em aplicações odontológicas.

## METODOLOGIA

Nesta seção, são apresentadas as etapas utilizadas para a segmentação de imagens de radiografias panorâmicas odontológicas.

Foram aplicadas diferentes técnicas de segmentação e os resultados foram

avaliados por meio de comparação visual e métricas qualitativas.

### Conjunto de dados

Foram utilizadas imagens de radiografias panorâmicas odontológicas, extraídas de um banco de dados da UFBA/UESC, com resolução de  $1991 \times 1127$  pixels, acompanhadas de suas respectivas segmentações realizadas manualmente por um profissional especializado, utilizadas como referência (*ground truth*), além de máscaras das regiões de interesse, utilizadas para delimitar a área analisada. Essas imagens encontram-se organizadas em diferentes categorias, incluindo imagens originais, máscaras e segmentações de referência.

As imagens originais são as radiografias sem nenhum tipo de tratamento prévio. Esses arquivos estavam organizados em uma pasta específica, denominada diretório de entrada.

Figura 3 – Uma das imagens originais que foi segmentada.



Fonte: Banco de dados da UFBA/UESC. Disponível em: <https://universe.roboflow.com/teeth-segmentation/ufba-425>

A Figura 3 apresenta o tipo de imagem que foi trabalhada. Nessa imagem é possível ver a estrutura dos dentes, a estrutura dos ossos do maxilar, os tecidos e uma estrutura de aparelho ortodôntico. Esta imagem é conforme foi obtida durante a consulta.


Para o processamento de radiografias odontológicas são utilizadas máscaras

das regiões de interesse (ROI - *Region of Interest*), as quais são imagens que ajudam a delimitar a região que se deseja segmentar, isolando e destacando a área de interesse para análise. No caso desse estudo, buscamos como área de interesse a parte central da imagem, onde estão localizados os dentes, com sua raiz e polpa.

Um aspecto fundamental dessa etapa é que a aplicação de máscaras contribui para a redução de ruídos, uma vez que, ao restringir o processamento à região de interesse, eliminam-se estruturas que não possuem relevância para o diagnóstico, como partes do crânio ou tecidos moles.

Essa estratégia também favorece a padronização do algoritmo, visto que radiografias odontológicas frequentemente apresentam variações de contraste e enquadramento. A utilização de máscaras padronizadas é amplamente empregada na literatura para compensar essas variações, garantindo maior consistência entre as imagens analisadas e contribuindo para o aumento da precisão dos métodos de segmentação (Gonzalez; Woods, 2018; Silva *et al.*, 2018; Pauwels; Jacobs; Horner, 2015). Na Figura 4, apresenta-se um exemplo da aplicação dessa abordagem.

Figura 4 – Uma das imagens que serviram de máscara para isolar as áreas de interesse.




Fonte: Banco de dados da UFBA/UESC. Disponível em: <https://universe.roboflow.com/teeth-segmentation/ufba-425>

As imagens de segmentação de referência *ground truth* são feitas por dentistas ou radiologistas, e servem como a “resposta correta” para que seja possível avaliar se o método pode ser usado para a situação desejada.

A Figura 5 apresenta um exemplo de segmentação realizada por um especialista. Nessa imagem, é possível visualizar apenas a estrutura de interesse para diagnóstico, diferentemente da Figura 3, a qual é a imagem sem nenhum tipo de processamento, sendo possível observar a estrutura dentária, os ossos do maxilar, os tecidos circundantes e um aparelho ortodôntico.

O uso de segmentações de referência auxilia na redução de erros sistêmicos, uma vez que métodos automáticos podem apresentar dificuldades em regiões com baixa nitidez ou elevado nível de ruído, conforme amplamente discutido na literatura (Pham; Xu; Prince, 2000; Silva *et al.*, 2018).

Figura 5 – Uma das imagens segmentada por um especialista.



Fonte: Banco de dados da UFBA/UESC. Disponível em: <https://universe.roboflow.com/teeth-segmentation/ufba-425>

## Etapas do processamento

Ao se considerar a análise de imagens voltadas para a área médica, é comum a aplicação de técnicas baseadas na morfologia matemática, que se dedica ao estudo das formas e estruturas presentes nas imagens. De modo similar, a morfologia matemática constitui um conjunto de ferramentas amplamente utilizadas para a extração de componentes estruturais das imagens, permitindo realçar, quantificar e descrever características relevantes.

Esse tipo de abordagem possibilita a identificação de elementos como frontei-

ras, contornos, esqueletos e regiões de interesse, aspectos fundamentais para a representação fidedigna das formas anatômicas.

No âmbito da odontologia, a aplicação de técnicas morfológicas mostra-se particularmente eficaz, uma vez que as estruturas dentárias apresentam contornos bem definidos e padrões geométricos característicos. Assim, a utilização do processamento morfológico contribui para a segmentação precisa dessas estruturas, favorecendo tanto a análise automatizada quanto a interpretação clínica.

Dessa forma, o presente estudo direciona-se especificamente à análise e representação das estruturas dentárias, utilizando os métodos de pré-processamento das imagens e posteriormente a sua segmentação através de algoritmos para o estudo morfológico.

### Pré-processamento das imagens

O pré-processamento das imagens é uma etapa que serve para garantir a qualidade e a eficácia da segmentação. Esta etapa envolve diversas técnicas para melhorar o contraste, reduzir ruídos e preparar as imagens para os algoritmos de segmentação. As etapas realizadas foram conforme apresentadas a seguir.

Em primeiro lugar é necessário realizar a leitura da imagem. As imagens foram carregadas sem qualquer tipo de processamento ou tratamento prévio. Esses arquivos estavam organizados em uma pasta específica, denominada diretório de entrada, para a leitura inicial foi utilizada a biblioteca *Matplotlib*, módulo *pyplot*, e a função *imread*, garantindo que todas as imagens fossem processadas no mesmo formato e resolução, conforme ilustrado na Figura 6.

Figura 6 – Leitura das imagens.

```
import matplotlib.pyplot as plt
import glob

images_folder = "input/images/"
list_images = []

for file in glob.glob(images_folder + "*.jpg"):
    list_images.append(file)

list_images.sort()

for path in list_images:
    print("Imagem:", path.replace(images_folder, "").replace(".jpg", ""))

    image = color.rgb2gray(plt.imread(path))
```

Fonte: Elaborado pelo próprio autor.

Após a leitura, é feita a conversão para escala de cinza: Como muitas técnicas de segmentação utilizam informações de intensidade de pixels, as imagens coloridas foram convertidas para escala de cinza utilizando a função *rgb2gray* da biblioteca *skimage.color*, conforme mostra o trecho do código na Figura 7.

Figura 7 – Conversão para escala de cinza.

```
from skimage import color

image = color.rgb2gray(plt.imread(path))
```

Fonte: Elaborado pelo próprio autor.

Essa conversão reduz a complexidade dos dados e facilita a segmentação baseada em intensidade de pixels. Seguindo o pré-processamento, é feita a equalização do histograma. Esse procedimento ajuda a melhorar o contraste da imagem a destacar regiões de interesse. Foi aplicada a equalização de histograma utilizando a função *equalize\_hist* da biblioteca *skimage.exposure*, conforme a Figura 8. Esse processo redistribui os valores de intensidade, garantindo uma melhor diferenciação entre estruturas dentárias e o fundo da imagem.

Figura 8 – Equalização do histograma.

```
from skimage.exposure import equalize_hist

image = equalize_hist(image)
```

Fonte: Elaborado pelo próprio autor.

Após a conversão e equalização, os valores dos pixels foram automaticamente normalizados para o intervalo [0,1], uma vez que as funções *rgb2gray* e *equalize\_hist* da biblioteca *scikit-image* retornam matrizes com intensidade padronizada.

Essa normalização implícita garante que todas as imagens apresentem a mesma escala de intensidade, evitando discrepâncias nos resultados causadas por variações de iluminação.

Ainda na parte de pré-processamento, a função `get_blocks()` foi utilizada. Está demonstrado o trecho na Figura 9, para estruturar as imagens de modo compatível com técnicas de segmentação baseadas em agrupamento, como *K-Means* e *Gaussian Mixture Model (GMM)*.

Figura 9 – Função `get_blocks()` para divisão em blocos.

```
def get_blocks(matrix, k):
    lines = matrix.shape[0]
    cols = matrix.shape[1]

    blocks = np.zeros((int((lines * cols) / (k*k)), k*k))
    index = 0

    for i in range(int(lines / k)):
        for j in range(int(cols / k)):
            blocks[index, :] = matrix[i*k : i*k + k, j*k : j*k + k].flatten()
            index = index + 1

    return blocks
```

Fonte: Elaborado pelo próprio autor.

Embora o algoritmo permita a divisão da imagem em blocos de tamanho  $k \times k$ , neste trabalho adotou-se o processamento pixel a pixel ( $k = 1$ ), de modo a preservar integralmente a resolução espacial original das radiografias. Adicionalmente, foi realizado o ajuste do tamanho das imagens para garantir compatibilidade dimensional com os algoritmos de segmentação empregados.

Para finalizar a etapa de pré-processamento, foi realizado o ajuste do tamanho das imagens, conforme ilustrado na Figura 10, com o objetivo de garantir compatibilidade dimensional entre os dados de entrada e os algoritmos de segmentação empregados. Quando necessário, as imagens foram ajustadas por meio de preenchimento simétrico (*padding*), de modo a manter a integridade da informação original. Ressalta-se que esse procedimento não altera o processamento pixel a pixel adotado neste trabalho, sendo aplicado exclusivamente para assegurar a consistência dimensional das imagens utilizadas.

Figura 10 – Ajuste de tamanho das imagens.

```
import numpy as np
padded_image = np.pad(image, ((0, math.ceil(image.shape[0]/k)*k - image.shape[0]),
                               (0, math.ceil(image.shape[1]/k)*k - image.shape[1])), 'symmetric')
blocks = util.get_blocks(padded_image, k)

output_directory = 'output'
if not os.path.exists(output_directory):
    os.makedirs(output_directory)
```

Fonte: Elaborado pelo próprio autor.

O pré-processamento é uma fase preparatória com a intenção de garantir que os métodos de segmentação possam operar de maneira eficiente e produzir resultados mais consistentes. Após tudo isso entramos na aplicação das técnicas escolhidas, nesse trabalho.

## Métodos de segmentação

De maneira geral, a segmentação de imagens tem como objetivo principal dividir a região espacial ocupada pelo objeto de referência em sub-regiões que atendam a condições específicas, tais como homogeneidade de intensidade, similaridade de textura ou proximidade espacial entre os pixels (Gonzalez; Woods, 2008).

Nesse contexto, todos os métodos de segmentação devem assegurar que cada pixel da imagem pertença a uma única região, sendo que os pixels de cada região devem estar conectados entre si de forma predefinida. Por outro lado, é necessário que as diferentes regiões permaneçam distintas e separadas.

Ao analisarmos a segmentação de imagens monocromáticas, é possível destacar duas características essenciais: descontinuidade e similaridade (Gonzales; Woods, 2008). Com base nesses critérios, foram empregadas quatro diferentes abordagens para a segmentação.

### a) Segmentação por Chan-Vese

O modelo de Chan-Vese, proposto por Chan e Vese (2001), é um método de segmentação baseado em contornos ativos (*active contours*), fundamentado na formulação de Mumford–Shah e na técnica de *level set*. Sua principal vantagem em relação aos

métodos baseados em gradiente está no fato de que o algoritmo não depende explicitamente da detecção de bordas, mas sim da minimização de uma função de energia que busca separar regiões homogêneas dentro da imagem. Essa característica torna o método mais robusto em cenários onde as bordas não são bem definidas, como em imagens com baixo contraste, presença de ruído ou sobreposição de estruturas, condições frequentemente observadas em radiografias odontológicas.

O processo inicia-se com uma curva inicial definida de forma independente das bordas reais da imagem, a qual pode assumir uma forma simples, como um círculo ou uma curva fechada genérica. Essa curva evolui iterativamente até se ajustar às regiões de interesse, sendo guiada pela diferença de intensidades entre as áreas internas e externas ao contorno. Uma das principais vantagens do método de Chan-Vese é sua robustez em imagens com baixo contraste ou bordas pouco definidas, características frequentemente observadas em radiografias odontológicas.

O processo iterativo do método é conduzido até que ocorra a convergência do contorno, caracterizada por variações desprezíveis entre iterações sucessivas. Para evitar tempos excessivos de processamento ou possíveis instabilidades numéricas, adota-se também um número máximo de iterações como critério de parada.

Neste trabalho, esse valor foi definido como um limite superior, permitindo que o algoritmo seja interrompido automaticamente quando a convergência é atingida ou, alternativamente, ao alcançar o número máximo estabelecido, garantindo estabilidade computacional e previsibilidade do tempo de execução.

Para a implementação do método, foi utilizada a função `chan_vese()` da biblioteca *scikit-image*, com os seguintes parâmetros:

- $\mu = 0,25$ : peso associado à suavização do contorno;
- $\lambda_1 = 1$  e  $\lambda_2 = 1$ : pesos das regiões internas e externas ao contorno;
- `max_num_iter = 200`: número máximo de iterações, definido como limite superior do processo iterativo.

Apesar de sua versatilidade e robustez, o método de Chan-Vese apresenta algumas limitações, como o custo computacional relativamente elevado em função do número de iterações necessárias para a convergência, além de sensibilidade à escolha dos parâmetros de energia. Ainda assim, o método tem sido amplamente aplicado com sucesso em diferentes contextos da área médica, incluindo a segmentação de tumores cerebrais em imagens de ressonância magnética e outras aplicações que demandam segmentação em imagens com bordas pouco definidas.

## **b) Segmentação por Morphological Chan-Vese**

O método Morphological Chan-Vese é uma variação do modelo Chan-Vese que substitui a evolução contínua da função *level set* por operações morfológicas discretas, como erosão e dilatação (Vese; Chan, 2002). A função *level set* é responsável por representar o contorno de forma implícita, permitindo sua evolução e adaptação às regiões de interesse da imagem sem a necessidade de detecção explícita de bordas. Ao empregar operadores morfológicos para aproximar essa evolução, o algoritmo torna-se mais simples do ponto de vista computacional, numericamente estável e menos sensível a ruídos locais.

A principal vantagem do método é sua eficiência computacional, já que a evolução do contorno ocorre por meio de operações matemáticas mais rápidas. Além disso, por utilizar morfologia matemática, o algoritmo apresenta maior robustez na seg-

mentação de imagens com intensidades heterogêneas ou estruturas parcialmente sobrepostas, cenário frequente em radiografias panorâmicas.

No contexto médico, essa abordagem tem sido aplicada em problemas que exigem rapidez sem grande perda de precisão. Por exemplo, estudos relatam seu uso na detecção de nódulos pulmonares em exames de tomografia (Kapur *et al.*, 2011) e na segmentação de imagens dermatológicas para identificação de lesões de pele (Xie; Mirmehdi, 2008). Esses casos demonstram que a variação morfológica é uma alternativa eficiente ao Chan-Vese tradicional quando se busca equilíbrio entre desempenho e custo computacional.

Para análise do método foi utilizada a biblioteca `morphological_chan_vese()`, utilizando os seguintes parâmetros:

- `num_iter=200`: Número de iterações.
- `init_level_set='checkerboard'`: Inicialização do contorno em padrão quadriculado.
- `smoothing=5`: Intensidade da suavização aplicada.

A inicialização do contorno foi realizada por meio do padrão *checkerboard*, que consiste em uma distribuição quadriculada de regiões internas e externas ao longo da imagem. Essa estratégia permite a criação de múltiplos contornos iniciais distribuídos uniformemente, reduzindo a dependência da posição inicial e aumentando a robustez do método em imagens com estruturas complexas e contrastes heterogêneos. Tal abordagem é especialmente adequada para radiografias panorâmicas odontológicas, nas quais a localização das regiões de interesse não é previamente conhecida.

### c) Segmentação por K-Means

O *K-means* é um algoritmo de agrupamento não supervisionado que

divide os pixels da imagem em  $k$  grupos homogêneos com base em suas intensidades.

O algoritmo funciona iterativamente, ajustando os centros dos *clusters*, os quais são definidos como grupos de elementos que apresentam características semelhantes entre si e diferente de elementos pertencentes a outro grupo (Jain; Murty; Flynn, 1999). Ou seja, o algoritmo realiza o agrupamento de elementos semelhantes dentro das imagens até que a distribuição dos pixels seja estabilizada.

Ou seja, com base no funcionamento do algoritmo, inicialmente são selecionados  $k$  valores de dados como centros iniciais dos *clusters*. Cada *cluster* pode ser compreendido como um conjunto de pontos caracterizados por vetores de atributos, como a intensidade do pixel. O centro de cada *cluster*, denominado centroide, é definido como a média aritmética dos vetores associados aos pontos que o compõem. Dessa forma, o algoritmo busca minimizar a soma das distâncias entre cada ponto e o centroide de seu respectivo *cluster*, garantindo que os elementos atribuídos a um mesmo grupo apresentem maior similaridade entre si do que em relação aos demais grupos (Bishop, 2006).

Em seguida, calcula-se a distância entre cada centro e os demais elementos do conjunto, atribuindo cada elemento ao *cluster* mais próximos. Em seguida, atualizam-se as médias de cada agrupamento, de forma que esse processo é repetido iterativamente até que o critério de convergência seja satisfeito.

O critério de convergência do algoritmo K-means é baseado na variação dos centróides entre iterações consecutivas. O processo iterativo é interrompido quando a mudança nos centróides se torna inferior a um valor de tolerância previamente definido, indicando estabilidade dos *clusters*. Neste trabalho, foi adotado o valor de tolerância  $tol = 10^{-5}$ , garantindo que o

algoritmo seja encerrado somente quando as alterações nos centros dos agrupamentos se tornem desprezíveis.

Diante desse cenário, compreende-se que o objetivo do *k-means clustering* é dividir os dados em  $k$  grupos, de forma que o cada elemento pertença ao *cluster* cuja média esteja mais próxima (Panwar; Gopal; Kumae, 2016).

Apesar de ser um método computacionalmente eficiente, ele pode ser sensível a variações de iluminação e contraste.

Neste trabalho, o número de *clusters* foi definido como  $k = 2$ , considerando-se a natureza binária do problema de segmentação, no qual o objetivo é separar a região de interesse correspondente aos dentes do fundo da imagem. A adoção de dois *clusters* permite uma distinção direta entre objeto e fundo, evitando a fragmentação excessiva das regiões segmentadas e contribuindo para uma interpretação mais consistente dos resultados em radiografias odontológicas.

Para a implementação, foi utilizado `KMeans` da biblioteca `sklearn.cluster`, com os parâmetros:

- `n_clusters=2`: Dois clusters.
- `max_iter=100`: Limite de 100 iterações.
- `tol=1e-5`: Tolerância para convergência.

#### **d) Segmentação por Gaussian Mixture Model (GMM)**

O *Gaussian Mixture Model* (GMM) é um método probabilístico baseado na suposição de que os dados podem ser representados como uma combinação de múltiplas distribuições gaussianas. Em imagens, isso significa assumir que os pixels pertencem a diferentes regiões de interesse, cada uma modelada por uma gaussiana (Bishop, 2006).

Diferente do *K-means*, que atribui cada pixel a um único cluster de forma rígida, o GMM trabalha com probabilidades de pertencimento, permitindo que um mesmo *pixel* seja associado a diferentes grupos com diferentes graus de confiança. Essa característica o torna mais flexível para lidar com imagens que apresentam transições suaves de intensidade ou regiões sobrepostas.

O treinamento do GMM geralmente é feito pelo algoritmo de *Expectation-Maximization (EM)*, que ajusta os parâmetros das distribuições gaussianas de acordo com os dados. Como vantagem, o método é mais preciso em cenários de sobreposição, mas apresenta maior complexidade computacional e pode sofrer com convergência lenta em *datasets* grandes.

Na área médica, o GMM já foi utilizado para segmentar tecidos cerebrais em ressonância magnética (Zhang; Brady; Smith, 2001) e identificar lesões em exames de mama (Reynolds, 2009). Essas aplicações reforçam a adequação do modelo para imagens odontológicas, especialmente nas regiões em que há sobreposição entre dentes, ossos e tecidos moles.

No contexto das radiografias panorâmicas odontológicas, o uso do GMM mostra-se particularmente adequado em cenários nos quais há sobreposição de estruturas e variações graduais de intensidade, como ocorre entre dentes, ossos e tecidos moles. Ao modelar estatisticamente a distribuição dos pixels, o método permite uma separação mais flexível entre regiões de interesse e fundo, contribuindo para uma segmentação mais consistente em imagens com contrastes heterogêneos.

Foi utilizado o `GaussianMixture` da biblioteca `sklearn.mixture`, adotou-se a configuração de matriz de covariância completa no modelo GMM, permitindo que cada componente gaussiano estime automaticamente seus próprios parâmetros de média e covariância. Essa escolha possibilita a modelagem de correlações entre os atribu-

tos dos pixels, tornando o método mais flexível na representação de distribuições complexas. Tal característica é particularmente relevante em radiografias panorâmicas odontológicas, nas quais há variações graduais de intensidade e sobreposição entre dentes, ossos e tecidos moles.

- `n_components=2`: Dois componentes para representar regiões de interesse e fundo.
- `covariance_type='full'`: Matriz de covariância completa.

### Métodos para avaliação de resultados

Os resultados das segmentações, foram avaliados de forma quantitativa. O objetivo foi mensurar o desempenho de cada técnica em relação ao *ground truth*, fornecido por especialistas, a partir de métricas consolidadas na literatura para problemas de segmentação binária.

O cálculo das métricas foi implementado em linguagem *Python*, utilizando as bibliotecas *Matplotlib*, *scikit-learn*. O código realiza a leitura das imagens segmentadas, máscaras de região de interesse e imagens de referência, realizando o cálculo automático das métricas de desempenho.

O *script* percorre as listas de imagens segmentadas e de referência, realizando a comparação *pixel a pixel* entre a segmentação obtida e o *ground truth*.

Para cada imagem, são calculados os valores de verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN) por meio da função, *confusion\_matrix*, da biblioteca *scikit-learn*.

A partir desses valores, são calculadas as métricas de acurácia, especificidade, precisão, *recall* e *F1-score*. O cálculo para cada um desses métodos está descrito a seguir:

1. **Acurácia (*Accuracy*)**: Mede a proporção total de pixels corretamente classificados, representando uma visão geral da eficácia da segmentação. A expressão é dado por:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. **Especificidade (*Specificity*)**: Indica a capacidade do método em identificar corretamente os pixels pertencentes ao fundo da imagem, evitando falsos positivos.

$$Specificity = \frac{TN}{TN + FP}$$

3. **Precisão (*Precision*)**: Mede a proporção de pixels segmentados corretamente entre todos os classificados como segmento.

$$Precision = \frac{TP}{TP + FP}$$

4. **Recall (*Sensibilidade*)**: Mede a capacidade do método em detectar os pixels do segmento corretamente.

$$Recall = \frac{TP}{TP + FN}$$

5. **F1-Score**: É a média harmônica entre precisão e *recall*, fornecendo uma métrica mais equilibrada quando há desequilíbrio entre classes. E o F1-Score é dado por:

$$F1Score = \frac{2 \cdot (Precision \times Recall)}{Precision + Recall}$$

Cada métrica foi calculada individualmente para todas as imagens do conjunto de dados, e os resultados foram armazenados em arquivos CSV separados, permitindo a análise estatística posterior do desempenho dos métodos. Essa abordagem pode ser usada para um volume grande de

comparações, pois, garante reprodutibilidade e consistência na comparação entre diferentes algoritmos de segmentação.

## RESULTADOS

Para esse trabalho foi segmentado um conjunto com 9 imagens, com características distintas e níveis de dificuldades diferentes umas das outras. Algumas tinham mais contraste, zonas mais bem delimitadas, regiões com mais densidades de informações, e outras com o oposto disso.

Para exemplificar foi demonstrada abaixo a imagem original, conforme a Figura 11, e em seguida as respectivas segmentações, que estão demonstradas nas Figuras 12 a 15 na sequência das segmentações.

Para esta exemplificação foi utilizada a imagem 9 do conjunto, a qual apresenta características que dificultam o processo de segmentação, como baixo contraste entre estruturas, presença de artefatos metálicos que nesse caso são implantes e braquetes, também a variação de densidade óssea e sobreposição de regiões anatômicas, fatores que comprometem a definição precisa das fronteiras e a separação adequada das áreas de interesse.

Figura 11 – Imagem 9 original.



Fonte: Banco de dados da UFBA/UESC. Disponível em: <https://universe.roboflow.com/teeth-segmentation/ufba-425>

Na Figura 11 observa-se o resultado da segmentação obtida pelo método

Chan-Vese. O algoritmo alcançou uma acurácia de 75,59%, evidenciando uma classificação correta da maioria dos pixels da imagem.

Em relação à segmentação do fundo, a especificidade atingiu o valor de 74,74%, indicando uma boa capacidade do método em identificar corretamente os pixels pertencentes ao fundo da imagem. Por outro lado, a segmentação da região de interesse apresentou uma precisão de 44,09%, evidenciando a presença de falsos positivos na identificação dos dentes.

O recall alcançou 78,94%, demonstrando uma elevada capacidade de detecção das regiões relevantes, embora com perda de precisão. O F1-score, calculado em 56,60%, reflete o equilíbrio entre precisão e recall. Esses resultados indicam que, apesar de o método apresentar desempenho razoável e boa sensibilidade, ainda existem limitações significativas na segmentação da região de interesse, comprometendo a qualidade final do processo.

Figura 12 – Imagem 9 segmentada pelo método Chan-Vese.



Fonte: Elaborado pelo próprio autor.

Na Figura 13 apresenta-se o resultado da segmentação obtida pelo método Gaussiano. O algoritmo obteve uma acurácia de 70,64%, indicando que a maior parte dos pixels da imagem foi classificada corretamente. A especificidade alcançou 71,29%, evidenciando uma boa capacidade do método em identificar corretamente os pixels de fundo.

Figura 13 – Imagem 9 segmentada pelo método Gaussiano.



Fonte: Elaborado pelo próprio autor.

Em relação à região de interesse, o desempenho foi mais limitado. O recall atingiu 68,08%, o que demonstra uma sensibilidade razoável na detecção das regiões relevantes. Contudo, a precisão foi de apenas 37,44%, revelando que uma parte significativa dos pixels detectados como pertencentes à região de interesse foi classificada incorretamente.

Como métrica de equilíbrio entre precisão e recall, o F1-score foi de 48,30%, valor que reforça as limitações do método na segmentação da região de interesse.

De modo geral, o método Gaussian Mixture Model (GMM) apresentou desempenho moderado. Embora tenha demonstrado boa capacidade de identificar corretamente os pixels de fundo, refletida por valores satisfatórios de especificidade, sua baixa precisão comprometeu a qualidade da segmentação da região de interesse, resultando em uma representação menos fiel quando comparada aos demais métodos avaliados.

Na Figura 14 é apresentado o resultado da segmentação obtida pelo método Morphological Chan-Vese. O algoritmo alcançou uma acurácia de 76,03%, indicando um desempenho geral superior na classificação dos pixels da imagem. A especificidade, de 75,36%, evidencia uma boa capacidade do método em diferenciar corretamente os pixels de fundo.

Figura 14 – Imagem 9 segmentada pelo método Morphological Chan-Vese.



Fonte: Elaborado pelo próprio autor.

Quanto à região de interesse, o método apresentou um recall de 78,66%, destacando uma elevada sensibilidade para detectar as regiões relevantes. No entanto, a precisão foi de apenas 44,62%, revelando que uma proporção significativa dos pixels identificados como pertencentes à região de interesse foi incorretamente classificada.

O F1-score obtido foi de 59,9%, valor que sintetiza o equilíbrio entre precisão e recall. Esse índice sugere que, embora o método apresente uma boa taxa de detecção (recall elevado), sua baixa precisão ainda compromete a fidelidade da segmentação.

De forma geral, o método *Morphological Chan-Vese* apresentou resultados superiores em comparação aos métodos *Gaussian Mixture Model* e *Chan-Vese padrão*, especialmente em termos de *recall* e acurácia, indicando maior capacidade de detecção das regiões de interesse. Ainda assim, a presença de falsos positivos, refletida em valores de precisão inferiores ao desejável, indica a necessidade de ajustes adicionais para aprimorar a precisão e, conseqüentemente, a qualidade final da segmentação.

Na Figura 15 apresenta-se o resultado da segmentação utilizando o método *K-Means*. O algoritmo obteve uma acurácia de 75,70%, indicando que a maioria dos pixels foi classificada corretamente. A especificidade, de 75,29%, evidencia um bom

desempenho na identificação dos pixels de fundo.

Figura 15 – Imagem 9 segmentada pelo método K-Means.



Fonte: Elaborado pelo próprio autor.

No que se refere à região de interesse, o método alcançou um recall de 77,33%, o que demonstra boa sensibilidade para detectar as áreas relevantes. Entretanto, a precisão foi de apenas 44,12%, revelando que uma parcela significativa dos pixels identificados como pertencentes à região de interesse não correspondia à classificação correta.

O F1-score calculado foi de 56,20%, refletindo o equilíbrio entre precisão e recall. Esse valor sugere que, apesar da boa capacidade de detecção (recall elevado), o método apresenta limitações consideráveis em termos de precisão, o que impacta na qualidade da segmentação final.

De modo geral, o método K-Means apresentou desempenho semelhante ao Morphological Chan-Vese, com bons índices de acurácia e recall, mas ainda marcado por baixa precisão. Isso indica que o método é eficiente em detectar a região de interesse, porém tende a gerar um número expressivo de falsos positivos.

As Tabelas 1 a 5 apresentam os resultados das métricas de avaliação obtidas para cada método de segmentação aplicado.

A Tabela 1 mostra os valores de *recall*.

Tabela 1 - Recall das imagens segmentadas

Imagens	Gaussian	Chan Vese	Kmeans	Morpho C. V
1	82,11%	83,68%	83,24%	83,83%
2	36,48%	76,34%	75,47%	76,09%
3	61,83%	78,17%	77,65%	77,57%
4	61,54%	84,71%	83,55%	84,21%
5	66,62%	84,29%	83,98%	84,07%
6	46,23%	70,17%	71,05%	71,18%
7	54,48%	91,18%	89,64%	90,94%
8	65,22%	76,77%	75,51%	76,12%
9	68,08%	78,94%	77,33%	78,66%

Fonte: Elaborado pelo próprio autor.

A Tabela 2 apresenta os valores de *F1-score*.

Tabela 2 - F1 Score das segmentações.

Imagens	Gaussian	ChanVese	Kmeans	Morpho C. V
1	57,3%	57,4%	57,2%	57,5%
2	31,6%	54,4%	54,5%	54,6%
3	49,2%	57,3%	56,9%	57,4%
4	47,9%	58,2%	58,2%	58,3%
5	31,2%	40,2%	40,2%	40,3%
6	33,4%	55,8%	55,7%	56,1%
7	33,6%	44,8%	44,7%	45,0%
8	48,2%	59,0%	58,9%	59,1%
9	48,3%	56,6%	56,2%	56,9%

Fonte: Elaborado pelo próprio autor.

A Tabela 3 exhibe os resultados de acurácia, para os métodos aplicados.

Tabela 3 – Acurácia das segmentações.

Imagens	Gaussian	Chan Vese	K-means	Morpho C. V
1	75,58%	75,21%	75,22%	75,28%
2	64,23%	70,94%	71,37%	71,26%
3	71,88%	74,36%	74,11%	74,68%
4	76,31%	78,45%	78,75%	78,71%
5	65,68%	70,78%	70,82%	70,95%
6	63,17%	77,79%	77,42%	77,71%
7	72,35%	71,11%	71,52%	71,38%
8	67,52%	75,30%	75,58%	75,59%
9	70,64%	75,59%	75,70%	76,03%

Fonte: Elaborado pelo próprio autor.

A Tabela 4 corresponde à precisão dos métodos.

Tabela 4 – Precisão das segmentações

Imagens	Gaussian	Chan Vese	Kmeans	Morpho C. V
1	43,96%	43,63%	43,61%	43,73%
2	27,93%	42,24%	42,60%	42,54%
3	40,79%	45,19%	44,86%	45,55%
4	39,22%	44,31%	44,64%	44,63%
5	20,34%	26,41%	26,39%	26,50%
6	26,18%	46,36%	45,85%	46,28%
7	24,32%	29,69%	29,80%	29,86%
8	38,21%	47,93%	48,27%	48,29%
9	37,44%	44,09%	44,12%	44,62%

Fonte: Elaborado pelo próprio autor.

A Tabela 5 apresenta os valores de especificidade.

Tabela 5- Especificidade

Imagens	Gaussian	Chan Vese	Kmeans	Morpho C. V
1	73,95%	73,10%	73,22%	73,16%
2	72,37%	69,36%	70,16%	69,84%
3	74,72%	73,28%	73,11%	73,87%
4	79,49%	77,10%	77,72%	77,53%
5	65,56%	68,99%	69,08%	69,22%
6	67,41%	79,70%	79,02%	79,34%
7	74,99%	68,14%	68,85%	68,50%
8	68,21%	74,86%	75,61%	75,43%
9	71,29%	74,74%	75,29%	75,36%

Fonte: Elaborado pelo próprio autor.

### Análise dos resultados

Para tornar a análise dos resultados mais clara e objetiva, as Tabelas 6 e 7 apresentam os dados condensados, resultantes do cálculo das médias e dos desvios-padrão de cada métrica para cada método de segmentação.

A análise comparativa entre os métodos de segmentação *Chan-Vese*, *Morphological Chan-Vese*, *K-means* e *Gaussian Mixture* evidencia diferenças significativas no desempenho e na

consistência dos resultados obtidos sobre as imagens radiográficas panorâmicas odontológicas.

A Tabela 6 apresenta as médias das métricas de avaliação e a Tabela 7 os respectivos desvios padrão, permitindo uma análise integrada entre acurácia, precisão, *recall*, especificidade e *F1-score*.

Tabela 6 – Médias das métricas de avaliação.

Métricas	ChanVese	K-means	Morpho C. V	Gaussian
<b>Acurácia</b>	0,743	0,745	0,746	0,697
<b>Precisão</b>	0,410	0,411	0,413	0,331
<b>Recall</b>	0,804	0,797	0,805	0,602
<b>Especificidade</b>	0,732	0,7356	0,735	0,720
<b>F1-Score</b>	0,537	0,536	0,539	0,423

Fonte: Elaborado pelo próprio autor.

Tabela 7 – Desvios padrão das métricas de avaliação.

Métricas	ChanVese	K-means	Morpho C. V	Gaussian
<b>Acurácia</b>	0,028	0,027	0,028	0,048
<b>Precisão</b>	0,076	0,076	0,076	0,087
<b>Recall</b>	0,061	0,057	0,060	0,134
<b>Especificidade</b>	0,038	0,0368	0,0381	0,0438
<b>F1-Score</b>	0,066	0,065	0,066	0,097

Fonte: Elaborado pelo próprio autor.

De modo geral, observa-se que o método *Morphological Chan-Vese* apresentou o melhor desempenho global entre as técnicas avaliadas. Este método alcançou as maiores médias de acurácia (0,7461), *recall* (0,8051) e *F1-score* (0,5396), demonstrando elevada

sensibilidade na detecção das regiões de interesse e bom equilíbrio entre precisão e recall.

Esse comportamento está relacionado à capacidade do algoritmo em incorporar informações morfológicas durante a evolução do contorno ativo, o que favorece a delimitação de bordas em regiões com baixo contraste — característica recorrente em radiografias odontológicas.

O método *Chan-Vese* tradicional e o *K-means* apresentaram desempenho intermediário, com médias de *F1-score* próximas (0,5374 e 0,5361, respectivamente) e acurácia ligeiramente inferior ao *Morphological Chan-Vese*. Embora esses métodos tenham mantido boa capacidade de detecção das regiões relevantes com *recall* acima de (0,79), apresentaram baixa precisão aproximadamente (0,41), o que indica a ocorrência de falsos positivos — regiões indevidamente classificadas como pertencentes à área de interesse. Essa limitação é particularmente evidente em imagens com variação de intensidade e presença de ruídos estruturais, nas quais os métodos tendem a expandir excessivamente as fronteiras segmentadas.

O método *Gaussian Mixture*, por sua vez, exibiu o pior desempenho geral, com *F1-score* médio de 0,4230 e os maiores desvios padrão entre as métricas (notadamente no recall, com DP = 0,1324). Essa alta dispersão indica instabilidade do método frente à diversidade das imagens analisadas, possivelmente devido à sua dependência da distribuição estatística dos níveis de cinza. Em imagens com contrastes não uniformes, o modelo de mistura gaussiana tende a produzir classificações inconsistentes, prejudicando a segmentação das estruturas anatômicas.

A análise dos desvios padrão reforça essas observações. O *Morphological Chan-Vese* apresentou as menores variações nas métricas, refletindo maior consistência estatística entre as imagens testadas. Em contrapartida, o *Gaussian Mixture* mostrou

elevada variabilidade, o que compromete sua confiabilidade para aplicações clínicas ou automáticas. Essa estabilidade do *Morphological Chan-Vese* demonstra que a introdução de operações morfológicas atua de forma benéfica na suavização de contornos e redução da sensibilidade a ruídos.

Com base nesses resultados, pode-se concluir que o método *Morphological Chan-Vese* representa a abordagem mais eficiente e robusta para a segmentação de radiografias panorâmicas odontológicas no contexto avaliado. Além do desempenho superior em termos de recall e acurácia, o método apresenta menor custo computacional em comparação ao *Chan-Vese* tradicional, uma vez que substitui a evolução contínua do contorno por operações morfológicas discretas, tornando o processo mais estável e rápido. Sua combinação de boa capacidade de detecção, acurácia consistente e estabilidade entre amostras evidencia um desempenho equilibrado e adequado para aplicações que exigem extração precisa de estruturas anatômicas.

No entanto, o desempenho limitado em termos de precisão indica que ainda há margem para aprimoramentos, como a adoção de abordagens híbridas que combinem segmentação morfológica com técnicas de aprendizado de máquina supervisionado ou redes neurais convolucionais, visando à redução da ocorrência de falsos positivos.

## CONCLUSÃO

A segmentação de imagens odontológicas é um componente fundamental para a automação do diagnóstico, planejamento e monitoramento em odontologia, contribuindo para maior precisão e eficiência na análise das estruturas anatômicas. Ao longo deste trabalho, foram avaliadas e comparadas diferentes técnicas de segmentação aplicadas a radiografias panorâmicas odontológicas, considerando métodos

baseados em contornos ativos e técnicas de agrupamento estatístico.

Os resultados obtidos evidenciaram diferenças significativas de desempenho entre os métodos analisados. O método *Morphological Chan-Vese* apresentou o melhor desempenho global, destacando-se principalmente pelos valores mais elevados de *recall* e acurácia, além de maior estabilidade entre as amostras avaliadas. Esses resultados indicam uma maior capacidade do método em identificar corretamente as regiões de interesse, mesmo em imagens caracterizadas por baixo contraste e sobreposição de estruturas, condições comuns em radiografias panorâmicas odontológicas.

O método *Chan-Vese* tradicional e as abordagens baseadas em *K-means* e *Gaussian Mixture Model (GMM)* apresentaram desempenho intermediário, com boa capacidade de identificação do fundo, refletida em valores satisfatórios de especificidade, porém com limitações relacionadas à baixa precisão, evidenciando a ocorrência de falsos positivos na segmentação da região de interesse. Esses resultados reforçam as dificuldades enfrentadas por métodos puramente baseados em intensidade ou agrupamento estatístico em cenários de alta complexidade anatômica.

Além do desempenho em termos de métricas quantitativas, o *Morphological Chan-Vese* demonstrou vantagem adicional em relação ao custo computacional, uma vez que substitui a evolução contínua do contorno por operações morfológicas discretas, tornando o processo mais estável e eficiente. Dessa forma, o método mostrou-se mais adequado para aplicações que exigem extração precisa de estruturas anatômicas com equilíbrio entre desempenho e eficiência computacional.

Apesar dos resultados promissores, a limitação observada nos valores de precisão indica que ainda há margem para aprimoramentos. Como trabalhos futuros, sugere-se a investigação

de abordagens híbridas que combinem técnicas clássicas de segmentação com métodos de aprendizado de máquina supervisionado ou redes neurais convolucionais, visando à redução de falsos positivos e ao aumento da robustez da segmentação em imagens odontológicas.

Além disso, o menor custo computacional do método *Morphological Chan-Vese* em relação ao *Chan-Vese* tradicional reforça sua viabilidade para aplicações práticas e sistemas de apoio ao diagnóstico, nos quais eficiência e estabilidade são requisitos fundamentais.

## REFERÊNCIAS

BISHOP, C. M. **Pattern recognition and machine learning**. New York: Springer, 2006. Disponível em: <https://link.springer.com/book/10.1007/978-0-387-45528-0>. Acesso em: 10 jan. 2025.

CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, v. 10, n. 2, p. 266–277, 2001. Disponível em: <https://ieeexplore.ieee.org/document/902291>. Acesso em: 10 jan. 2025.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 4. ed. London: Pearson Education, 2018. Disponível em: <https://www.pearson.com/en-gb/subject-catalog/p/digital-image-processing/P200000006029>. Acesso em: 10 jan. 2025.

KAPUR, J. N.; SAHOO, P. K.; WONG, A. K. C. A new method for gray-level picture thresholding using the entropy of the histogram. **Computer Vision, Graphics, and Image Processing**, v. 29, n. 3, p. 273–285, 1985. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0734189X8580013X>. Acesso em: 10 jan. 2025.

LI, C. *et al.* Distance regularized level set evolution and its application to image segmentation. **IEEE Transactions on Image**

**Processing**, v. 19, n. 12, p. 3243–3254, 2010. Disponível em: <https://ieeexplore.ieee.org/document/5557813>. Acesso em: 10 jan. 2025.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: **Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability**. Berkeley: University of California Press, 1967. Disponível em: <https://projecteuclid.org/euclid.bsmmsp/1200512992>. Acesso em: 10 jan. 2025.

MURPHY, K. P. **Machine learning: a probabilistic perspective**. Cambridge, MA: MIT Press, 2012. Disponível em: <https://mitpress.mit.edu/9780262018029/machine-learning/>. Acesso em: 10 jan. 2025.

PANWAR, P.; GOPAL, G.; KUMAR, R. Image segmentation using K-means clustering and thresholding. **International Research Journal of Engineering and Technology (IRJET)**, v. 3, n. 5, p. 1787–1793, 2016. Disponível em: <https://www.irjet.net/archives/V3/i5/IRJET-V3I5345.pdf>. Acesso em: 10 jan. 2025.

PANWAR, R.; GOPAL, G.; KUMAR, P. Image segmentation using K-means clustering algorithm. **International Journal of Computer Applications**, v. 157, n. 6, p. 25–29, 2016. Disponível em: <https://www.ijcaonline.org/archives/volume157/number6/26879-2016909908>. Acesso em: 10 jan. 2025.

PAUWELS, R.; JACOBS, R.; HORNER, K. Diagnostic performance of panoramic and cone beam CT imaging for dental applications. **Dentomaxillofacial Radiology**, v. 44, n. 1, p. 20140247, 2015. Disponível em: <https://academic.oup.com/dmfr/article/44/1/20140247/7323647> Acesso em: 10 jan. 2025.

PHAM, D. L.; XU, C.; PRINCE, J. L. Current methods in medical image segmenta-

tion. **Annual Review of Biomedical Engineering**, v. 2, p. 315–337, 2000. Disponível em: <https://www.annualreviews.org/doi/10.1146/annurev.bio-eng.2.1.315>. Acesso em: 10 jan. 2025.

REYNOLDS, D. Gaussian mixture models. In: LI, S. Z.; JAIN, A. (ed.). **Encyclopedia of biometrics**. Boston: Springer, 2009. p. 659–663. Disponível em: [https://link.springer.com/referenceworkentry/10.1007/978-0-387-73003-5\\_196](https://link.springer.com/referenceworkentry/10.1007/978-0-387-73003-5_196). Acesso em: 10 jan. 2025.

SCORALICK, R. A. *et al.* Identificação humana por meio do estudo de imagens radiográficas panorâmicas: relato de caso. **Revista de Odontologia da UNESP**, v. 42, n. 6, p. 465–470, 2013. Disponível em: <https://www.scielo.br/j/rounesp/a/Yk7hZCwJbR8YQZ6PZxqP7jQ/>. Acesso em: 10 jan. 2025.

SILVA, G.; OLIVEIRA, L.; PITHON, M. Automatic segmenting teeth in X-ray images: trends, a novel data set, benchmarking and future perspectives. **Expert Systems with Applications**, v. 107, p. 15–31, 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417418302252>. Acesso em: 10 jan. 2025.

STARY, D. *et al.* Vessel segmentation of fundus images by a novel method based on K-means clustering. **Computers in Biology and Medicine**, v. 72, p. 128–139, 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0010482516300710>. Acesso em: 10 jan. 2025.

SUZUKI, K. Overview of deep learning in medical imaging. **Radiological Physics and Technology**, v. 10, n. 3, p. 257–273, 2017. Disponível em: <https://link.springer.com/article/10.1007/s12194-017-0406-5>. Acesso em: 10 jan. 2025.

VESE, L. A.; CHAN, T. F. A multiphase level set framework for image segmentation

using the Mumford and Shah model. **International Journal of Computer Vision**, v. 50, p. 271–293, 2002. Disponível em: <https://link.springer.com/article/10.1023/A:1020874308076>. Acesso em: 10 jan. 2025.

## **AGRADECIMENTOS**

Agradeço a Deus por me permitir chegar até aqui; toda honra e glória sejam dadas ao Seu Santo Nome.

Agradeço aos meus pais, José Cícero e Marlene, que me deram toda a estrutura necessária, todos os fundamentos morais, éticos e de fé, para que eu pudesse trilhar este caminho.

Agradeço à minha irmã, Eduarda, por estar ao meu lado, apoiando-me e acreditando no meu sonho.

Agradeço à minha namorada, Letícia, parceira que Deus colocou em minha vida, e que me deu um ânimo novo para que eu conseguisse finalizar este trabalho.

Agradeço ao professor Felipe, por ter aceitado a orientação deste trabalho, toda paciência comigo, toda orientação e suporte durante este processo.

E, por fim, agradeço a todos os amigos que conquistei ao longo da jornada acadêmica.