



**SENAI CIMATEC**

**PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM  
COMPUTACIONAL E TECNOLOGIA INDUSTRIAL  
Mestrado em Modelagem Computacional e Tecnologia Industrial**

**Dissertação de mestrado**

**Avaliação de métodos de segmentação aplicados a  
imagens de raio-X panorâmico dos dentes**

Apresentada por: Gil Jader Oliveira da Silva

Orientador: Valter de Senna

Co-orientador: Luciano Rebouças de Oliveira

24 de Fevereiro de 2015

Gil Jader Oliveira da Silva

# Avaliação de métodos de segmentação aplicados a imagens de raio-X panorâmico dos dentes

Dissertação de mestrado apresentada ao Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial, Curso de Mestrado em Modelagem Computacional e Tecnologia Industrial do SENAI CIMATEC, como requisito parcial para a obtenção do título de **Mestre em Modelagem Computacional e Tecnologia Industrial**.

Área de conhecimento: Interdisciplinar

Orientador: Valter de Senna

*SENAI CIMATEC*

Co-Orientador: Luciano Rebouças de Oliveira

*UNIVERSIDADE FEDERAL DA BAHIA (UFBA)*

Salvador  
SENAI CIMATEC  
2015

---

## Nota sobre o estilo do PPGMCTI

---

Esta dissertação de mestrado foi elaborada considerando as normas de estilo (i.e. estéticas e estruturais) propostas aprovadas pelo colegiado do Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial e estão disponíveis em formato eletrônico (*download* na Página Web [http://ead.fieb.org.br/portal\\_faculdades/dissertacoes-e-teses-mcti.html](http://ead.fieb.org.br/portal_faculdades/dissertacoes-e-teses-mcti.html) ou solicitação via e-mail à secretaria do programa) e em formato impresso somente para consulta.

Ressalta-se que o formato proposto considera diversos itens das normas da Associação Brasileira de Normas Técnicas (ABNT), entretanto opta-se, em alguns aspectos, seguir um estilo próprio elaborado e amadurecido pelos professores do programa de pós-graduação supracitado.

# SENAI CIMATEC

Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial

Mestrado em Modelagem Computacional e Tecnologia Industrial

A Banca Examinadora, constituída pelos professores abaixo listados, leram e recomendam a aprovação da Dissertação de mestrado, intitulada “Avaliação de métodos de segmentação aplicados a imagens de raio-X panorâmico dos dentes”, apresentada no dia 24 de Fevereiro de 2015, como requisito parcial para a obtenção do título de **Mestre em Modelagem Computacional e Tecnologia Industrial**.

Orientador:

---

Prof. Dr. Valter de Senna  
SENAI CIMATEC

Co-Orientador:

---

Prof. Dr. Luciano Rebouças de Oliveira  
Departamento de Ciências da Computação - UFBA

Membro externo da Banca:

---

Prof. Dr. José Garcia Vivas Miranda  
Departamento de Geofísica Nuclear - UFBA

Membro interno da Banca:

---

Prof. Dr. Roberto Luiz Souza Monteiro  
SENAI CIMATEC

Dedico esta dissertação à minha esposa Ritinha,  
pessoa com quem amo partilhar a vida.  
Devido a sua paciência, compreensão, apoio e alegria,  
este trabalho pôde ser concretizado.

---

## Agradecimentos

---

Quero agradecer, em primeiro lugar, a Deus, pela força e coragem durante toda esta longa caminhada.

À minha Esposa. Nos momentos mais difíceis, que não foram raros neste último ano, sempre me fazendo acreditar que chegaria ao final desta difícil, porém gratificante etapa. Obrigado pela paciência e compreensão por tantos finais de semana e noites que precisei ficar trabalhando nesta pesquisa ao invés de sairmos para nos divertirmos. Este período nos mostrou a verdade sobre nosso relacionamento. Sou grato por cada gesto carinhoso, cada sorriso, e ansioso por estar ao seu lado, o resto da minha vida. Obrigado Ritinha!

Ao meu pai que, com muito carinho, não mediu esforços, me proporcionando todo o apoio necessário no ensino fundamental e médio para que eu chegasse até esta etapa de minha vida. Obrigado Sr. Gil Gonçalves da Silva por me possibilitar a oportunidade de estudar, sou muito feliz por isso.

Ao professor Valter de Senna, pela paciência na orientação e por todo o apoio que tornaram possível a conclusão desta dissertação. Obrigado por ter acreditado na pesquisa e pelas constantes demonstrações de sabedoria e humildade.

Ao professor Luciano Rebouças, por seus ensinamentos, orientações, paciência e confiança no trabalho realizado. Obrigado por ter compartilhado comigo o que era o broto daquilo que veio a ser este trabalho.

Aos professores José Garcia e Roberto Monteiro, pelas recomendações no trabalho e pela participação na banca examinadora.

Agradeço individualmente ao colega Leandro Miranda da UFBA por ter me ajudado em parte das imagens na etapa de anotação dos dentes.

Estendo meus agradecimentos aos meus colegas de trabalho Bruno Almeida e Luiz Cláudio e aos demais colegas do Data Center do Senai/CIMATEC, por todo o apoio, incentivo e compreensão durante a realização deste trabalho.

Salvador, Brasil  
dia de 24 de Fevereiro de 2015

Gil Jader Oliveira da Silva

---

## Resumo

---

A área de Reconhecimento de Padrões tem auxiliado em pesquisas que envolvem extração de informações odontológicas em imagens de raio-X para realização de diagnósticos sobre os pacientes. Por meio de imagens obtidas com o exame radiológico (raio-X), o odontólogo pode analisar toda a estrutura dentária e construir (caso necessário) o plano de tratamento do paciente. Dentre os exames radiológicos, existe a Ortopantomografia (raio-X panorâmico), que possibilita identificar irregularidades dentárias, como por exemplo: os dentes inclusos, anormalidades ósseas, quistos, tumores, infecções, fraturas, dentre outras. No entanto, a análise depende de um trabalho cuidadoso do profissional e esta não é realizada de forma automática, principalmente devido à dificuldade de existirem ferramentas computacionais capazes de extrair as características dessas imagens da forma desejada. O objetivo deste trabalho é, portanto, realizar uma revisão de métodos de segmentação de imagens, demonstrando a aplicação de cada um deles em imagens de raio-X (panorâmico), com o objetivo principal de isolar os dentes para facilitar a sua análise. Sendo assim, uma avaliação extensa do desempenho dos algoritmos de segmentação é realizada para determinar qual método de segmentação é o mais indicado para adaptação ao domínio do problema estudado, possibilitando diferenciar os dentes de outros elementos, nas imagens analisadas. Para alcançar este objetivo, a metodologia comumente utilizada em pesquisas na área é adotada, realizando análise qualitativa durante as primeiras etapas que são a coleta e anotação de *datasets* (catalogando as imagens que serão analisadas) e pré-processamento (utilizando técnicas para preparar as imagens para as etapas subsequentes), e, logo após, realizando análise quantitativa e experimental, a partir das anotações das imagens, que correspondem a demarcações dos objetos de interesse nas imagens, obtidas de forma manual. Este processo permite viabilizar uma posterior comparação entre os resultados obtidos automaticamente por meio dos algoritmos de segmentação e a segmentação feita manualmente pelo processo de anotação. Durante as etapas de segmentação das imagens, são utilizados algoritmos responsáveis por separar os conjuntos de características extraídas, entre aquelas mais prováveis de pertencerem aos objetos de interesse e aquelas menos prováveis. Em seguida, os resultados são analisados utilizando as métricas: Precisão (*Precision*), *Recall* também chamada de Sensibilidade (*Sensitivity*), Especificidade (*Specificity*), Taxa de Acerto (*accuracy*) e a medida *F-score*, para medição de desempenho dos algoritmos de segmentação estudados e verificando qual deles alcançou os melhores resultados. Esta pesquisa visa, portanto, contribuir para a construção futura de um modelo sistematizado para detecção automatizada de possíveis anomalias dentárias, e que produzirá informações que servirão de base para uma segunda opinião ao diagnóstico médico dentário.

**Palavras chaves:** Análise de desempenho, Métricas, raio-X panorâmico, Segmentação

---

## Abstract

---

The Pattern Recognition area has assisted in research involving extraction of dental information in X-ray images to perform diagnostics on patients. Through images taken with the radiological examination (X-ray), the dentist can analyze the entire tooth structure and building (if necessary) the patient's treatment plan. Among the radiological examinations, there is Orthopantomography (panoramic X-ray), which allows to identify dental irregularities, such as: the impacted teeth, bone abnormalities, cysts, tumors, infections, fractures, among others. However, the analysis depends on careful professional work and this is not done automatically, mainly due to the difficulty there are computational tools capable of extracting the characteristics of these images as desired. The objective is therefore to conduct a review of image segmentation methods, demonstrating the application of each X-ray pictures (wide), with the main objective to isolate the teeth to facilitate analysis. Thus, an extensive performance evaluation of segmentation algorithms is held to determine which segmentation method is the most suitable for adaptation to the problem domain studied, allowing differentiate the teeth of other elements in the analyzed images. To accomplish this, the methodology commonly used in research in the area is adopted, performing qualitative analysis during the first steps that are the collection and annotation textit datasets (cataloging the images to be analyzed) and pre-processing (using techniques to prepare the images for subsequent steps), and, soon after, performing quantitative and experimental analysis, from the notes of the images, which correspond to boundaries of objects of interest in the images, obtained manually. This process allows facilitate the subsequent comparison of the results obtained automatically by means of segmentation algorithms and segmentation done manually by the annotation process. Finally, during the steps of the image segmentation algorithms are used responsible for separate sets of extracted features, among those most likely to belong to the objects of interest and those least likely. Then the results are analyzed using the metrics: Precision, Recall also called Sensitivity, Specificity, Accuracy and the measure F-score for performance measurement of segmentation algorithms studied and checking which one achieved the best results. This research therefore aims to contribute to the future construction of a systematic model for automated detection of potential dental anomalies, and that will produce information that will form the basis for a second opinion to the dental medical diagnosis.

**Keywords:** Performance Analysis, Metrics, panoramic X-ray, Segmentation

---

# Sumário

---

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Organização do documento . . . . .	3
<b>2</b>	<b>Estado da arte e relação com o trabalho proposto</b>	<b>5</b>
2.1	Análise qualitativa dos trabalhos relacionados . . . . .	9
2.2	Considerações finais . . . . .	13
<b>3</b>	<b>Dentição humana e imagens de raio-X dentários</b>	<b>14</b>
3.1	Dentição humana . . . . .	14
3.2	Raios-X dentários . . . . .	16
3.2.1	Anomalias dentárias e tipos de raio-X . . . . .	17
3.3	Considerações finais . . . . .	19
<b>4</b>	<b>Métodos de segmentação de imagens</b>	<b>21</b>
4.1	Segmentação de imagens . . . . .	21
4.2	Segmentação baseada em histograma da imagem . . . . .	24
4.2.1	<i>Limiarização Básica Global</i> . . . . .	25
4.3	Segmentação baseada em limiar variável local . . . . .	28
4.3.1	<i>Método Niblack (Method Niblack)</i> . . . . .	29
4.4	Segmentação baseada em região . . . . .	31
4.4.1	Crescimento de Região ( <i>Region Growing</i> ) . . . . .	31
4.4.2	Divisão e União de Regiões ( <i>Region Splitting and Merging</i> ) . . . . .	35
4.5	Segmentação baseada em entropia da informação . . . . .	38
4.5.1	Método Pun ( <i>Method Pun</i> ) . . . . .	38
4.5.2	Método Renyi ( <i>Method Renyi</i> ) . . . . .	41
4.6	Considerações finais . . . . .	43
<b>5</b>	<b>Análise comparativa de Métodos de segmentação</b>	<b>44</b>
5.1	Aquisição das imagens do <i>Dataset</i> . . . . .	45
5.1.1	Câmera de raio-X . . . . .	45
5.2	Categorização e recorte das imagens do <i>dataset</i> . . . . .	47
5.3	Anotação das imagens do <i>dataset</i> . . . . .	49
5.3.1	Dificuldades encontradas durante o processo de anotação . . . . .	50
5.4	Determinação do ROI . . . . .	52
5.5	Análise das estatísticas do <i>dataset</i> construído . . . . .	53
5.5.1	Estatísticas dos <i>pixels</i> do ROI das imagens . . . . .	55
5.6	Análise de desempenho dos algoritmos de segmentação . . . . .	58
5.6.1	Métricas para análise de desempenho dos algoritmos . . . . .	58
5.6.1.1	Medidas da teoria da detecção de sinais . . . . .	58
5.6.1.2	Taxa de Acerto (Accuracy) . . . . .	59
5.6.1.3	Especificidade (Specificity) . . . . .	60
5.6.1.4	Precisão (Precision) . . . . .	60
5.6.1.5	Sensibilidade (Sensitivity/Recall) . . . . .	60
5.6.1.6	Medida F-score . . . . .	61

---

5.6.2	Metodologia adotada para análise de desempenho dos algoritmos de segmentação estudados . . . . .	62
5.6.3	Métodos de segmentação analisados . . . . .	65
5.6.3.1	Validação da execução do cálculo das métricas estudadas . . . . .	66
5.6.3.2	Limiarização Básica Global (Basic Global Thresholding) . . . . .	67
5.6.3.3	Método Niblack (Method Niblack) . . . . .	69
5.6.3.4	Crescimento de região (Region Growing) . . . . .	71
5.6.3.5	Divisão e União de Regiões (Region Splitting and Merging) . . . . .	73
5.6.3.6	Método Pun (Method Pun) . . . . .	75
5.6.3.7	Método Renyi (Method Renyi) . . . . .	77
5.6.3.8	Análise geral dos resultados . . . . .	79
5.7	Considerações finais . . . . .	80
<b>6</b>	<b>Conclusões</b>	<b>82</b>
<b>A</b>	<b>Aprovação do Parecer Consubstanciado do CEP</b>	<b>85</b>
A.1	Primeira página da aprovação do CEP . . . . .	85
A.2	Segunda página da aprovação do CEP . . . . .	86
	<b>Referências</b>	<b>87</b>

---

## Lista de Tabelas

---

2.1	Análise qualitativa por método de segmentação . . . . .	10
2.2	Análise qualitativa por resultados obtidos . . . . .	11
5.1	Propriedades da ORTHOPHOS XG 5 . . . . .	46
5.2	Contagem de imagens classificadas e anotadas do <i>dataset</i> e média de dentes das imagens por categoria . . . . .	54
5.3	Exemplo dos valores obtidos das operações estatísticas . . . . .	56
5.4	Resultados das Médias das Operações Estatísticas por Categoria . . . . .	56
5.5	Métricas usadas para avaliação das técnicas de segmentação . . . . .	62
5.6	Exemplo do processo de cálculo das métricas, por imagem, em cada categoria e obtenção da média e desvio padrão dos valores . . . . .	67
5.7	Resultados das análises da segmentação baseada em <b>Limiarização Básica Global</b> . . . . .	68
5.8	Resultados das análises da segmentação baseada no <b>Método Niblack</b> . . . . .	70
5.9	Resultados das análises da segmentação baseada em <b>Crescimento de Região</b> . . . . .	72
5.10	Resultados das análises da segmentação baseada em <b>Divisão e União de Regiões</b> . . . . .	74
5.11	Resultados das análises da segmentação baseada no <b>Método Pun</b> . . . . .	76
5.12	Resultados das análises da segmentação baseada no <b>Método Renyi</b> . . . . .	78
5.13	Média Geral dos Resultados . . . . .	79

---

## Lista de Figuras

---

3.1	Nomenclatura e numeração dos dentes baseado na notação ISO 3950. . . .	15
3.2	Partes estruturais do dente. . . . .	16
4.1	Exemplos de imagens das categorias do <i>dataset</i> do presente trabalho. . . .	23
4.2	Exemplo de seleção manual de limiar baseado no histograma de uma imagem.	25
4.3	Amostra de resultados da segmentação <b>Basic Global Thresholding</b> . . .	27
4.4	Exemplo de uma vizinhança 3 x 3 em torno de um ponto (x,y) numa imagem.	28
4.5	Exemplos de resultados da segmentação pelo método <b>Niblack</b> . . . . .	30
4.6	Seleção manual das sementes para o algoritmo de crescimento de região . .	32
4.7	Exemplos de resultados da segmentação pelo método <b>Region growing</b> . . .	34
4.8	Processo básico de divisão e união. . . . .	36
4.9	Exemplos de resultados da segmentação pelo método <b>Region Splitting and Merging</b> . . . . .	37
4.10	Exemplos de resultados da segmentação pelo método <b>Pun</b> . . . . .	40
4.11	Exemplos de resultados da segmentação pelo método <b>Renyi</b> . . . . .	42
5.1	Visão geral das etapas do trabalho. . . . .	44
5.2	ORTHOPHOS XG 5 / XG 5 DS / Ceph. . . . .	45
5.3	Exemplo do recorte e redimensionamento das imagens do <i>dataset</i> deste trabalho . . . . .	48
5.4	Processo de anotação dos dentes . . . . .	49
5.5	Resultado da anotação de uma imagem do <i>dataset</i> deste trabalho . . . . .	50
5.6	Dificuldade de visualização do ápice . . . . .	50
5.7	Anotação de dentes sobrepostos . . . . .	51
5.8	Dificuldade em anotar dentes com partes incompletas . . . . .	51
5.9	Dificuldade em anotar imagens com implante dentário . . . . .	52
5.10	Processo de anotação da região bucal das imagens do <i>dataset</i> deste trabalho	52
5.11	Processo de delimitação do ROI das imagens do <i>dataset</i> deste trabalho. . .	53
5.12	Mapa de calor das imagens do <i>dataset</i> , representando as respectivas frequências de ocorrências dos níveis de intensidade dos <i>pixels</i> . . . . .	57
5.13	Matriz de Confusão . . . . .	59
5.14	Etapas do processo de segmentação e análise de desempenho dos algoritmos de segmentação . . . . .	63
5.15	Escolha da metodologia adotada no presente trabalho para segmentação e análise de desempenho dos algoritmos de segmentação estudados . . . . .	64
5.16	Exemplo do processo de obtenção dos valores, por imagem, das métricas utilizadas no presente trabalho . . . . .	65
5.17	Exemplo do processo de validação da execução do cálculo das métricas utilizadas no presente trabalho . . . . .	66
A.1	Informações da aprovação da pesquisa pelo CEP . . . . .	85
A.2	Continuação da aprovação da pesquisa pelo CEP . . . . .	86

## Introdução

---

Na Odontologia, as imagens médicas são fontes de dados fundamentais em pesquisas que envolvem extração de informação dessas imagens para realizar diagnósticos sobre os pacientes. Estas fontes incluem as imagens de radiografia. Segundo [Essig MS \(2008\)](#), os raios-X dentários estão divididos em duas categorias principais: as radiografias intraorais, que mostram a imagem que se encontra no interior da boca e as radiografias extraorais, que mostram a imagem que se encontra no exterior da boca. Nestas categorias, existem três tipos de raios-X dentais que ocorrem com maior frequência nos exames odontológicos: **A radiografia extraoral panorâmica** - Também chamado de raio-X panorâmico ou Ortodontomografia; **a radiografia intraoral *bitewing*** - ou raio-X *bitewing*; e **a radiografia intraoral periapical** ou somente raios-X periapicais.

A partir das imagens obtidas com o exame radiológico (raio-X), o odontólogo pode analisar toda a estrutura dentária e construir (caso necessário) o plano de tratamento do paciente. Entretanto, devido a inexistência de recursos automatizados adequados para auxiliar a análise das imagens de raio-X panorâmico, a avaliação desses exames ocorre de maneira empírica, isto é, valendo-se apenas da experiência do dentista, tornando a mensuração dos resultados inteiramente sob a percepção visual desse profissional. A dificuldade de análise das imagens de raio-X dentais ainda é maior se tratando das radiografias panorâmicas, devido ao fato destas imagens não serem restritas apenas a uma parte isolada dos dentes como ocorre nas imagens radiográficas intraorais, pois além dos dentes, elas mostram as regiões temporomandibulares (articulações da mandíbula com o crânio) e detalhes originados pelos ossos das áreas nasais e queixo. Outras informações existentes nas radiografias panorâmicas e que dificultam a análise destas imagens são: variações dos dentes de paciente para paciente, artefatos usados para restaurações e próteses, as baixas qualidades das imagens causadas por algumas condições, tais como o ruído, baixo contraste, homogeneidade nas regiões próximas aos objetos de interesse, espaço existente por um dente faltando, e limitação dos métodos de aquisição, o que resulta, algumas vezes, em segmentação mal sucedida. Portanto, ainda existem pesquisas para encontrar um método adequado de segmentação de imagens de raios-X dentais. No entanto, poucas pesquisas se concentram em imagens de raios-X dentais panorâmicas, e as existentes não realizam uma análise detalhada dos resultados para avaliar o desempenho dos métodos de segmentação utilizados. Partindo deste cenário, foi formulado o seguinte questionamento: Qual método de segmentação obtém o melhor desempenho para extrair características de imagens radiográficas (raio-X panorâmico), de modo que, possibilite isolar as suas unidades significativas (dentes) para facilitar a sua análise? Com essa questão posta, o presente

trabalho apresenta uma proposta para avaliar algoritmos de segmentação.

Segmentação se refere ao processo de dividir uma imagem digital em múltiplas regiões (conjunto de *pixels*) ou objetos, com o objetivo de simplificar e/ou mudar a representação de uma imagem para facilitar a sua análise. Segmentação de imagens é tipicamente usada para localizar objetos e formas (linhas, curvas, etc) em imagens. Sendo assim, o objetivo desta dissertação consiste em realizar uma revisão de métodos de segmentação, onde o interesse está em verificar se cada algoritmo estudado consegue identificar corretamente, em imagens de raio-X panorâmico, cada dente individualmente, ou ainda, próteses, implantes, dentes quebrados ou restaurados. Tal objetivo é perseguido de modo que ocorra a separação destes objetos em relação às outras partes da imagem.

Seguindo o contexto apresentado no parágrafo anterior, os objetivos específicos do trabalho aqui proposto são:

1. Utilizar as métricas: Precisão (*Precision*), *Recall* também chamada de Sensibilidade (*Sensitivity*), Especificidade (*Specificity*), Taxa de Acerto (*accuracy*) e a medida *F-score*, definidas em Fawcett (2006), para medir o desempenho de cada método de segmentação, assim, verificando qual algoritmo de segmentação consegue melhor realizar a separação dos objetos de interesse (dentes) em relação às outras partes da imagem de raio-X panorâmico;
2. Identificar qual método de segmentação de imagem é o mais apropriado para adaptação ao domínio do problema estudado.

A principal contribuição deste trabalho e que foi pouco investigada pelos trabalhos revisados e discutidos no Capítulo 2, é a realização de uma análise detalhada dos resultados, em que, utilizou-se as medidas da teoria da detecção de sinais (BUSHBERG et al., 2002): **verdadeiros positivos (VP)**, **verdadeiros negativos (VN)**, **falsos positivos (FP)** e **falsos negativos (FN)**. Em seguida, estas medidas foram expostas na tabela conhecida como matriz de confusão (ou tabela de confusão) (LAMPERT; NICKISCH; HARMELING, 2009). A tabela de confusão foi calculada a partir da utilização do conjunto de imagens correspondente ao *dataset* deste trabalho. A partir disso, a quantidade e os tipos de erros e acertos cometidos foram determinados por meio da aplicação das métricas: Precisão (*Precision*), *Recall* também chamada de Sensibilidade (*Sensitivity*), Especificidade (*Specificity*), Taxa de Acerto (*accuracy*) e a medida *F-score*, assim verificando o desempenho de cada método de segmentação analisado. Um resumo das métricas utilizadas no presente trabalho pode ser encontrado no Capítulo 5, na Tabela 5.4.

Ressalta-se o alto nível da qualidade e a quantidade das imagens do *dataset* do presente trabalho, caracterizando um diferencial significativo quando comparado a outros trabalhos. O *dataset* levantado para a pesquisa experimental do trabalho proposto conta com uma diversidade de imagens, com características distintas e distribuídas em 10 categorias que foram definidas durante a consecução deste trabalho.

Este trabalho irá possibilitar que pesquisadores da área de Odontologia e Visão Computacional, de posse dos resultados, possam aprimorar os algoritmos de segmentação que apresentarem os melhores desempenhos para alcançar um objetivo maior, que consiste na construção futura de um modelo sistematizado para análise de possíveis anomalias dentárias em exames de ortopantomografia. Assim, espera-se que os benefícios aos pacientes sejam diagnósticos mais precisos por meio de uma segunda opinião, por um sistema especialista, dada ao odontologista.

Todas as radiografias utilizadas nesta pesquisa foram obtidas no Centro de Diagnóstico por Imagem da Universidade Estadual do Sudoeste da Bahia - UESB, sob à coordenação do professor e odontólogo Dr. Matheus Pithon. As radiografias seguiram a portaria 453 da Vigilância Sanitária que rege a regulamentação das diretrizes básicas em radiodiagnóstico médico e odontológico no Brasil. As imagens radiográficas utilizadas para esta pesquisa foram codificadas visando a não identificação do paciente no referido estudo. O uso das radiografias na pesquisa foi autorizada pela Comitê de Ética em Pesquisa com Seres Humanos (CEP), através do parecer de número 646.050 aprovado em 13/05/2014, conforme documento disponível no Anexo A desta dissertação.

## 1.1 Organização do documento

O restante do documento é organizado da seguinte forma:

- **Capítulo 2 - Estado da arte e relação com o trabalho proposto:** Apresenta alguns trabalhos que foram importantes para o estudo proposto nesta dissertação. Neste capítulo, um estudo bibliográfico é realizado, embasado em alguns autores, verificando assim as semelhanças existentes entre esses trabalhos e o estudo proposto. Este capítulo também salienta aspectos importantes que diferenciam este trabalho dos demais;
- **Capítulo 3 - Dentição humana e imagens de raio-X dentários:** São apresentados alguns dos principais tipos de raios-X dentários e algumas das anomalias dentárias mais encontradas na literatura, além de conceitos elementares sobre a

Odontologia. Em seguida, são mostradas informações sobre a dentição humana, destacando detalhes que podem ser melhor avaliados por meio da segmentação das imagens de raio-X, isolando os objetos de interesse (dentes) para facilitar sua análise. Compõe a fundamentação teórica necessária para o trabalho realizado;

- **Capítulo 4 - Métodos de segmentação de imagens:** Contextualiza o problema da segmentação de imagens, enfatizando a utilização de algoritmos de segmentação em imagens dentárias. São apresentadas as categorias e os métodos de segmentação de imagens que foram analisadas neste trabalho;
- **Capítulo 5 - Análise Comparativa de Métodos de Segmentação:** Características do *dataset* do presente trabalho são mostradas por meio das análises estatísticas que foram realizadas. São apresentadas a metodologia, os critérios e métodos adotados para realização desta pesquisa, descrevendo como a avaliação dos métodos de segmentação de imagens foram analisados, utilizando as métricas: Precisão (*Precision*), *Recall* também chamada de Sensibilidade (*Sensitivity*), Especificidade (*Specificity*), Taxa de Acerto (*accuracy*) e a medida *F-score*, para medir o desempenho de cada método de segmentação com base na aplicação em imagens de raio-x panorâmico do *dataset* construído para o presente trabalho;
- **Capítulo 6 - Conclusões:** Apresenta as conclusões, contribuições e algumas sugestões de atividades de pesquisa a serem desenvolvidas no futuro.

---

## Estado da arte e relação com o trabalho proposto

---

O êxito da vida não se mede pelo caminho que você conquistou, mas sim pelas dificuldades que superou no caminho.  
(Abraham Lincoln)

Este capítulo tem como objetivo apresentar os trabalhos correlatos e que possuem algum grau de similaridade com o tema desta dissertação. Foi feita uma análise de cada trabalho com base na quantidade de imagens do *dataset*, tipo de imagens de raio-X usadas, métodos de segmentação aplicados e avaliação dos resultados. Esses critérios foram, portanto, utilizados para realizar a busca e fazer a avaliação de cada trabalho. Um resumo da análise qualitativa dos trabalhos revisados se encontra nas Tabelas 2.1 e 2.2. Nestas tabelas, o sinal de hífen representa que em alguns casos os dados do critério avaliado precisam ser esclarecidos melhor ou simplesmente não foram especificados.

O trabalho de [Senthilkumaran \(2012\)](#) mostra um estudo sobre detecção de bordas para segmentação de imagens de raio-X dentárias usando lógica *Fuzzy*. O autor descreve como a lógica *Fuzzy* pode ser considerada uma opção para a representação e processamento de imagens digitais, já que estas apresentam características não uniformes e ruidosas. Entretanto, destaca-se que existe a necessidade do uso de técnicas adicionais de pré-processamento que consistem em ajustar a ordem dos *pixels* para a aplicação da segmentação por *Fuzzy*. São utilizadas imagens de radiografias dentárias do tipo *bitewing* para aplicação da segmentação utilizando a lógica *Fuzzy*. Contudo, não é mencionado a quantidade de imagens usadas no experimento realizado e também não é apresentada a análise dos resultados para comprovar a eficiência da segmentação. Os resultados são apenas comparados com imagens obtidas após aplicação de algoritmos de detecção de bordas.

[Said et al. \(2006\)](#) apresentam uma solução usando morfologia matemática para o problema da segmentação por limiarização de imagens radiográficas dos dentes do tipo *bitewing* e *periapicais*. A solução proposta inclui: 1) a filtragem de ruído, 2) limiarização para isolar os dentes do fundo, e 3) análise de componentes para determinar as Regiões dos Objetos de Interesse (*ROIs*) qualificados com base em propriedades geométricas. Algumas dificuldades foram encontradas por causa da ocorrência de imagens desfocadas, existência de

restaurações, dentes sobrepostos, qualidade de digitalização das imagens, e baixo contraste entre os dentes. Desse modo, destacando que é difícil conseguir um ótimo desempenho com todas as imagens, o estudo realizado é comparado com outras três abordagens existentes na literatura que utilizam princípios semelhante este. A comparação é efetuada com base em uma métrica empírica proposta em (NASSAR; CHAUDHRY; AMMAR, 2004). Os resultados mostraram que a solução proposta apresentou a menor taxa de falha entre as abordagens estudadas. Nada é dito sobre o *dataset* analisado e nem sobre a quantidade de imagens utilizadas nos experimentos.

No trabalho de (LIRA et al., 2014) é proposta uma abordagem de segmentação baseado em uma técnica de aprendizagem supervisionada para o reconhecimento de textura. Em primeiro lugar, a extração de características é realizada utilizando os momentos de *Chebyshev* discutidos em (YAP; RAVEENDRAN; ONG, 2001) e técnicas estatísticas. Os dados obtidos são a entrada para um classificador *bayesiano* que, após o treinamento, é capaz de distinguir duas classes de *pixels*: ativo (dentro da textura de interesse) ou inativo (fora dos dentes). O estudo realizado utiliza radiografias do tipo *bitewing* e *periapical*. Para quantificar a qualidade da segmentação obtida utiliza-se a operação lógica *XOR*, indicando o percentual de acerto, entre a imagem segmentada automaticamente e a sua segmentação manual. Os resultados experimentais mostram que a metodologia é promissora, mas que necessita de melhorias em certos aspectos. Destaca-se que métodos mais eficazes para análise de textura e para eliminação da sobreposição são necessários. Também não é discutido sobre a qualidade e quantidade de imagens analisadas nos experimentos realizados e nem em relação ao *dataset* utilizado.

Rad, Rahim e Norouzi (2013) introduzem um método para segmentação e extração de características de imagens de raio-X odontológico. O método proposto inicialmente realiza uma etapa de pré-processamento para melhorar a qualidade das imagens, reduzir o ruído e aumentar o contraste da estrutura de interesse, antes da segmentação. Em seguida, o método é aplicado usando o método de segmentação *level-set method* (LI et al., 2011). Foram extraídas características das imagens de raios-X dentários, utilizando medidas estatísticas de textura, obtidas por meio do método *GLCM* (*Gray-level Co-occurrence matrix method*) que foi proposto inicialmente por (HARALICK; SHANMUGAM; DINSTEN, 1973). Os autores destacam que os dados extraídos podem ser usados para obter medidas dos dentes para aplicações dentárias automáticas em sistemas de diagnóstico odontológico. As radiografias utilizadas são do tipo *bitewing*. Entretanto, nada é especificado sobre a análise dos resultados para comprovar a eficiência e o desempenho do método proposto. Também não são mencionadas informações sobre o *dataset* utilizado nos experimentos.

O trabalho de [Dighe e Shriram \(2012\)](#) apresenta uma solução baseada na Biometria Dental, que é uma técnica comumente usada na identificação de indivíduos, geralmente em cadáveres. A Biometria Dental consiste em quatro etapas: Pré-processamento da radiografia (realizando ajustes nos níveis de intensidade dos *pixels*), segmentação, extração de características e comparação das radiografias originais com as segmentadas. Desenvolveu-se um algoritmo com a proposta de identificação humana de forma semiautomática, utilizando radiografias *periapicais*. O trabalho foi realizado utilizando um *dataset* contendo 38 radiografias dentais. A parte do algoritmo responsável pela segmentação inclui: 1) Utilização de limiar para separar os objetos de interesse do fundo e 2) determinação das Regiões dos Objetos de Interesse (*ROIs*) a partir dos objetos qualificados com base em propriedades geométricas para isolar os dentes na radiografia. Ao final do estudo, é relatado que o algoritmo não funciona bem em imagens com dentes faltando, sendo proposto para trabalhos futuros a implementação de métodos para descobrir a distância entre dentes para melhorar o desempenho do algoritmo nestes casos. Os resultados finais obtidos neste estudo não são avaliados para comprovar a eficiência do algoritmo de forma sistemática.

[Jantsch e Felipussi \(2012\)](#) descrevem duas técnicas de pseudocoloração aplicado em imagens de raio-X panorâmico dos dentes, destacando a abordagem aplicada com o emprego da equalização do histograma e utilização do filtro de *Wiener* ([WIENER, 1949](#)). Os resultados obtidos com o método proposto foram validados por especialista de domínio específico (realizando a mensuração de dimensões e distâncias das áreas de interesse (dentes) em relação a outras estruturas ósseas). Os autores destacam que a aplicação desta abordagem a imagens radiológicas médicas ou odontológicas proporciona benefícios dentre os quais possibilita o conforto na análise da imagem pela redução da fadiga visual do profissional da saúde e maior confiabilidade na provisão dos laudos devido a visualização de detalhes quase imperceptíveis em imagens monocromáticas. No contexto das imagens radiológicas médicas e odontológicas, o estudo em ([JANTSCH; FELIPUSSI, 2012](#)) examina o processo de coloração em imagens de raio-X da mão e raio-X panorâmicas dentais, apresentando que o objetivo da pesquisa realizada não foi o de reconhecer padrões e objetos nas imagens avaliadas, mas destacar possíveis lesões existentes nos ossos, identificadas através da análise das imagens radiográficas após aplicação da técnica de pseudocoloração. Nada é dito sobre o *dataset* utilizado e não são analisados os resultados obtidos por meio de métricas para comprovar a eficiência do processo de segmentação realizado.

O trabalho de [Bansal \(2012\)](#) mostra uma abordagem utilizando morfologia matemática para o problema da segmentação em imagens dentárias. É proposto o uso do histograma de gradientes orientados (HOG) ([DALAL; TRIGGS; SCHMID, 2006](#)) e momentos invariantes de HU ([HU, 1962](#)) para extração de características das imagens e que foram usadas

como características a serem classificadas por uma máquina de vetores de suporte (*SVM*) (OSUNA; FREUND; GIROSI, 1997), que consiste em métodos do aprendizado supervisionado que analisam os dados e reconhecem padrões. O autor construiu um *dataset* com imagens de 200 pacientes, formando um total de 576 radiografias do tipo *periapical*. De modo geral, o processo de segmentação realizado utiliza uma combinação de dois métodos principais: Melhoria de imagem usando filtros morfológicos e detecção de contorno. Em seguida, a análise de componente conectado é realizada nas imagens, onde cada imagem é analisada para identificar os diferentes componentes conectados. Os segmentos que apresentam mais do que 4000 *pixels* são experimentalmente identificado como dente e são armazenados como novas imagens. Usando as imagens segmentadas, os segmentos foram extraídos e marcados manualmente, como molares e pré-molares. Um total de 329 dentes (molares e pré-molares, apenas) foram segmentados, sendo 164 molares e 165 imagens pré-molares. Destacou-se que a precisão da segmentação obtida é nominal, mas não ideal para a automação completa do processo de segmentação. Ressalta-se que o método proposto necessita realizar operações manuais para selecionar as Regiões dos Objetos de Interesse (*ROIs*). Por fim, enfatiza que a principal causa de erro de segmentação apresentado está relacionada a má qualidade de algumas imagens de raio-X. Em alguns casos, quando os raios-X apresentavam contrastes adequados, os dentes foram segmentados com maior precisão. A análise dos resultados é verificada comparando o percentual de acerto do algoritmo de classificação (*SVM*) entre os dois grupos de características extraídas utilizando os métodos HOG e HU, mostrando que os melhores resultados foram alcançados por meio das características extraídas por HU.

Com o propósito de auxiliar a Biometria Dental, cujo objetivo principal é o reconhecimento de indivíduos não identificados, o trabalho de Wanat (2011) apresenta um método para segmentação de radiografias panorâmicas odontológicas. É utilizada uma abordagem de segmentação diferente da Biometria Dental tradicional, focando na detecção de lacunas entre a coroa e a raiz dos dentes, possibilitando separar os dentes, mesmo em situações de oclusões. Segundo o autor, o método apresentado funciona de forma totalmente automática. Este método de segmentação, utiliza a técnica apresentada em (FREJLICHOWSKI; WANAT, 2010), que é baseado na decomposição da imagem em uma pirâmide Laplaciano, separando a imagem de raio-X em imagens pequenas contendo progressivamente frequências de intensidades dos *pixels* mais baixas do que as existentes na imagem original. Em seguida, uma série de filtros são aplicados às camadas selecionadas da pirâmide, incluindo ajustes de nitidez e métodos para realce de contraste, antes da imagem ser recomposta novamente. O método foi testado em um *dataset* de 218 imagens de raio-X panorâmico dos dentes, cada uma dimensionada com 1500 x 800 *pixels*. Não são especificadas métricas para efetuar análise dos resultados e nem para avaliar a eficiência da solução proposta, apenas é descrito a duração do processo de segmentação realizado.

Oliveira (2009) desenvolveu um método para a detecção de cárie dentária em radiografias panorâmicas dentais. O *dataset* utilizado tem o total de 1392 imagens em escala de cinza, com diferentes tipos de estrutura dental, tamanhos de boca e o número de dentes por imagem. O *dataset* foi organizado e as imagens distribuídas em 3 categorias: imagens contendo todos os dentes, imagens contendo alguns dentes e imagens sem dentes. A metodologia adotada é composta de cinco etapas: A primeira é baseada na análise estatística dos tamanhos e componentes de cada imagem, a fim de definir uma região de interesse inicial; nesse sentido, as informações não úteis originadas pelas regiões nasais e queixo são desprezadas, e cada imagem é cortada, considerando apenas a região da boca. A segunda etapa, realiza a separação das mandíbulas superior e inferior, a partir de um ajuste polinomial, usando o conjunto de *pixels* localizados entre as mandíbulas. Esta técnica de ajuste polinomial, utilizado como processo de separação das mandíbulas foi baseado em outros trabalhos citados neste estudo. Depois de ter as mandíbulas separadas, a terceira etapa foi detectar os vales existentes entre os dentes; esses vales tendem a ser mais escuros do que os próprios dentes, mas nem sempre estão presentes, devido a ocorrência de dentes sobrepostos. Nesta etapa são aplicadas também técnicas de processamento de imagens a fim de identificar a distância entre os dentes e então destacar a separação entre eles em cada uma das mandíbulas. De posse das imagens que correspondem as mandíbulas superiores e inferiores, com cada vale entre os dentes destacados, ou seja, evidenciando a distância entre os dentes. Na quarta etapa, é realizada a segmentação propriamente dita. O algoritmo adotado para efetuar a segmentação foi o *Active Contour Without Edges*, onde a saída desejável é a região que contém exatamente o dente. Entretanto, o autor relata que o resultado não correspondeu ao que era desejado, pois são obtidos resultados contendo regiões das imagens que não correspondem aos objetos de interesse (dentes). Por esse motivo, ainda na quarta etapa é realizado um processo de pós-processamento com o objetivo de melhorar os resultados da segmentação, removendo informações que se referem ao fundo da imagem. A quinta etapa consiste em extrair características das imagens resultantes do processo de segmentação e em seguida aplicar classificadores para realizar a detecção de cárie dentária. Não são efetuadas análises aprofundadas dos resultados, sendo apenas informado o percentual da taxa de acerto referente ao processo de segmentação e detecção de cárie.

## 2.1 Análise qualitativa dos trabalhos relacionados

Nesta seção, é apresentada a análise comparativa dos trabalhos selecionados, caracterizando-os nas Tabelas 2.1 e 2.2 e posicionando o presente trabalho em relação a eles (na última linha de cada tabela).

Tabela 2.1: Análise qualitativa dos trabalhos relacionados por método de segmentação, tamanho do *dataset* e tipo de raio-X

Trabalho	Dataset	raio-X	Técnica de Segmentação
( <a href="#">SENTHILKUMARAN, 2012</a> )	-	<i>bitewing</i>	Detecção de bordas e lógica <i>Fuzzy</i>
( <a href="#">SAID et al., 2006</a> )	-	<i>bitewing</i> e <i>periapical</i>	Limiarização por morfologia matemática
( <a href="#">LIRA et al., 2014</a> )	-	<i>bitewing</i> e <i>periapical</i>	Aprendizagem supervisionada utilizando o classificador <i>bayesiano</i>
( <a href="#">RAD; RAHIM; NOROUZI, 2013</a> )	-	<i>bitewing</i>	<i>level-set method</i>
( <a href="#">DIGHE; SHRIRAM, 2012</a> )	38 imagens	<i>periapical</i>	Biometria Dental e limiarização
( <a href="#">JANTSCH; FELIPUSSI, 2012</a> )	-	<i>panorâmico</i>	Pseudocoloração baseado na equalização do histograma das imagens e utilização do filtro de <i>Wiener</i> desenvolvido por <i>Norbert Wiener</i>
( <a href="#">BANSAL, 2012</a> )	576 imagens	<i>periapical</i>	Morfologia matemática, detecção de contorno e aprendizagem supervisionada utilizando o classificador <i>SVM</i>
( <a href="#">WANAT, 2011</a> )	218 imagens	<i>panorâmico</i>	Método proposto por ( <a href="#">FREJLICHOWSKI; WANAT, 2010</a> )
( <a href="#">OLIVEIRA, 2009</a> )	1392 imagens	<i>panorâmico</i>	<i>Active Contour Without Edges</i>
Trabalho proposto	1500 imagens	<i>panorâmico</i>	(1) <i>Basic Global Thresholding</i> ; (2) <i>Method Niblack</i> ; (3) <i>Region Growing</i> ; (4) <i>Region Splitting and Merging</i> ; (5) <i>Method Pun</i> ; (6) <i>Method Renyi</i>

Tabela 2.2: Análise qualitativa dos trabalhos relacionados por resultados obtidos

Trabalho	Análise dos Resultados
( <a href="#">SENTHILKUMARAN, 2012</a> )	-
( <a href="#">SAID et al., 2006</a> )	Comparação com outros trabalhos utilizando métrica proposta em ( <a href="#">NASSAR; CHAUDHRY; AMMAR, 2004</a> )
( <a href="#">LIRA et al., 2014</a> )	Operação lógica <i>XOR</i> (indicando o percentual de acerto) entre a imagem segmentada automaticamente e a sua segmentação manual
( <a href="#">RAD; RAHIM; NOROUZI, 2013</a> )	-
( <a href="#">DIGHE; SHRIRAM, 2012</a> )	-
( <a href="#">JANTSCH; FELIPUSSI, 2012</a> )	-
( <a href="#">BANSAL, 2012</a> )	-
( <a href="#">WANAT, 2011</a> )	-
( <a href="#">OLIVEIRA, 2009</a> )	Verificação do percentual da taxa de acerto referente ao processo de segmentação
Trabalho proposto	(1)Uso de medidas de teoria da detecção de sinais: True Positive (TP), True Negative (TN), False Negative (FN) e False Positive (FP); (2)Uso de medidas de desempenho: Precisão ( <i>Precision</i> ), <i>Recall</i> também chamada de Sensibilidade ( <i>Sensitivity</i> ), Especificidade ( <i>Specificity</i> ), Taxa de Acerto ( <i>accuracy</i> ) e a medida <i>F-score</i> .

Conforme é possível observar nas Tabelas 2.1 e 2.2, a maioria dos trabalhos listados não possuem informações sobre o *dataset* utilizado. Entretanto, em alguns, apesar de disponibilizarem esses dados, percebe-se limitação com relação a quantidade de imagens utilizadas e também predominância em relação ao uso de radiografias intraorais. Nos trabalhos destacados em ([SENTHILKUMARAN, 2012](#)), ([SAID et al., 2006](#)), ([LIRA et al., 2014](#)), ([RAD; RAHIM; NOROUZI, 2013](#)) e ([JANTSCH; FELIPUSSI, 2012](#)), nada é dito sobre o *dataset* utilizado. Porém, os trabalhos em ([DIGHE; SHRIRAM, 2012](#)) e ([BANSAL, 2012](#)), apesar de informarem a quantidade de imagens utilizadas nos experimentos realizados, trabalharam com poucas imagens e utilizando imagens radiográficas do tipo *bitewing* e/ou *periapical*.

O trabalho de [Oliveira \(2009\)](#) construiu um *dataset* com 1392 imagens para aplicar a metodologia proposta, utilizando imagens de raio-X panorâmico, porém se restringe a imagens com todos os dentes ou faltando dentes, sem nenhum tipo de alteração estrutural presente nos dentes, tais como, implantes, próteses, aparelhos, mandíbulas com mais de

32 dentes, dentre outros tipos.

O trabalho proposto aqui neste documento, construiu um *dataset* com 1500 imagens e que representa um número maior que os trabalhos revisados na literatura. Além disso, esse banco de dados é composto por imagens com características relevantes, o que possibilitou a classificação destas em 10 categorias de acordo com as variações estruturais em relação aos dentes, no que se refere ao número de dentes, existência de restaurações, existência de implantes, existência de aparelhos e existência de imagens com mais de 32 dentes. Variando também em relação ao tamanho da boca e das maxilas e mandíbulas.

O trabalho de [Wanat \(2011\)](#) descreve que o processo de segmentação em imagens de raio-X dentais intraorais (*bitewing* e *periapical*), apresentam complexidade menor de segmentação se comparado com a realização deste processo em imagens de raio-X panorâmicas. Isso se deve ao fato das imagens intraorais focarem em uma área específica, restrita a apenas poucos dentes e desse modo eliminando outras regiões que estão presentes nas imagens de raio-X panorâmicas, tornando o processo de segmentação destas mais complexo.

O objetivo do presente trabalho difere dos outros citados, apresentando a proposta de **avaliar** métodos de segmentação em imagens de raio-X panorâmicas. Enquanto que, de modo geral, os trabalhos revisados utilizam um único método, este realizou experimentos com seis métodos de segmentação. Os métodos de segmentação utilizados no trabalho aqui proposto estão classificados em quatro categorias conforme a seguir:

- **Segmentação Baseada em Histograma da Imagem:** *Basic Global Thresholding*.
- **Segmentação Baseada em Limiar Variável Local:** *Method Niblack*.
- **Segmentação Baseada em Região:** *Region Growing* e *Region Splitting and Merging*.
- **Segmentação Baseada em Entropia da Informação:** *Method Pun* e *Method Renyi*.

## 2.2 Considerações finais

Na Tabela 2.2, é possível observar que dentre os nove trabalhos revisados, 66% não realizaram nenhum tipo de análise para avaliação dos resultados e 33% não fizeram uma análise aprofundada dos resultados para comprovar o desempenho e a eficiência dos métodos de segmentação adotados para os experimentos. Além disso, trabalharam com *datasets* pequenos ou contendo imagens com pouca variação, por exemplo, com dentes ou sem dentes.

A partir dos dados apresentados na Tabela 2.1, constatou-se que dentre os nove trabalhos analisados seis utilizaram apenas imagens intraorais do tipo *bitewing* ou *periapical* e os outros três usaram imagens extraorais *panorâmicas*. O trabalho de Oliveira (2009) que utilizou imagens de raio-X dentais *panorâmicas*, efetuou uma série de pré-processamento digital das imagens, fatiando-as para um formato próximo do tipo *bitewing*.

No próximo capítulo, serão apresentadas definições referente as imagens radiográficas e especificando os tipos mais utilizados de raios-X dentários na Odontologia, ressaltando a importância destas imagens para a prevenção e tratamento de anomalias dentárias. Destacam-se as imagens de raio-X panorâmico, pois compõem o *dataset* do presente trabalho. São apresentados alguns detalhes pertinentes sobre a dentição humana, observando que a utilização de métodos de segmentação aplicados a imagens de raio-X panorâmico dos dentes pode contribuir para facilitar a análise de cada dente individualmente e auxiliar profissionais da área de Saúde dentária a construir (caso necessário) o plano de tratamento do paciente de maneira mais eficiente. Entretanto, ressalta-se a necessidade da utilização de métodos de segmentação que produzam resultados eficazes, isolando os dentes e desprezando informações ruidosas nas imagens de raio-X para que possam ser melhor analisadas.

---

## Dentição humana e imagens de raio-X dentários

---

A vida é como andar de bicicleta. Para ter equilíbrio você tem que se manter em movimento...

(Albert Einstein)

Neste capítulo são apresentadas definições sobre a dentição humana e apresentadas algumas das anomalias dentárias comumente encontradas na literatura. Em seguida, discute-se sobre a origem das imagens de raio-X, enfatizando a importância do uso dos raios-X em Odontologia e os tipos de radiografias utilizadas para auxílio ao diagnóstico e tratamento dentário. Finaliza-se o capítulo com a contextualização de como a segmentação das imagens radiográficas panorâmicas pode contribuir para o diagnóstico médico dentário.

### 3.1 *Dentição humana*

Os dentes são órgãos do corpo humano de consistência dura, natureza calcária e cor branca. Os dentes estão fixados nos maxilares e as principais funções constituem cortar, prender e triturar os alimentos. Além da função mastigatória, os dentes possuem as funções de estética e de auxílio na fonação, visto que a pronúncia correta de alguns fonemas depende deles, juntamente com a língua. Os seres humanos possuem duas dentições. A primeira dentição, ou dentição decídua, é formada por 20 dentes temporários, popularmente conhecidos como dentes-de-leite: quatro incisivos, dois caninos e quatro molares, tanto no maxilar superior quanto no inferior que caem entre os 6 e os 11 anos de um indivíduo. Entretanto, em um ser humano adulto, sem a ocorrência de anomalias dentárias (alterações dos dentes causadas por fatores locais, sistêmicos ou hereditários), existem 32 dentes, dezesseis em cada arco dental, cada um responsável por realizar uma função ou tarefa específica, distribuídos conforme a seguir ([FEHRENBACH et al., 2012](#)):

- **Incisivos:** dentes frontais (quatro superiores e quatro inferiores) para cortar os alimentos.
- **Caninos:** dentes com pontas agudas (dois superiores e dois inferiores), também chamados de "presas", que rasgam os alimentos.
- **Pré-molares:** dentes com duas pontas na superfície (quatro superiores e quatro inferiores) para esmagar e triturar os alimentos.
- **Molares:** existem seis superiores e seis inferiores, responsáveis por triturar os alimentos, estes dentes possuem várias cúspides na superfície de mordida. O terceiro ou último molar também é conhecido como dente do siso.

A Figura 3.1 mostra uma imagem de raio-X panorâmico do *dataset* utilizado no presente trabalho, com a designação dos nomes de cada dente. Os nomes estão representados apenas no arco superior, pois cada dente paralelo do arco inferior possui o mesmo nome de seu correspondente no arco superior. Além da nomenclatura, também é possível observar na figura a numeração dos dentes, uma convenção internacional, chamada Notação Dentária Internacional. Esse sistema de referência, segue os padrões de qualidade estabelecidos pelo sistema ISO e é também conhecida como Notação ISO 3950. De acordo com a notação ISO 3950, divide-se a boca em quadrantes, acompanhando a visão que o dentista tem na hora do exame, ou seja, de frente para o paciente. Em seguida, os dentes são numerados em cada quadrante, sendo que, primeiro vem o número correspondente ao quadrante ao qual ele pertence, e, depois, o número correspondente ao tipo de dente. Logo, um dente representado pelo número 11, será o primeiro dente do primeiro quadrante (conhecido como incisivo central).

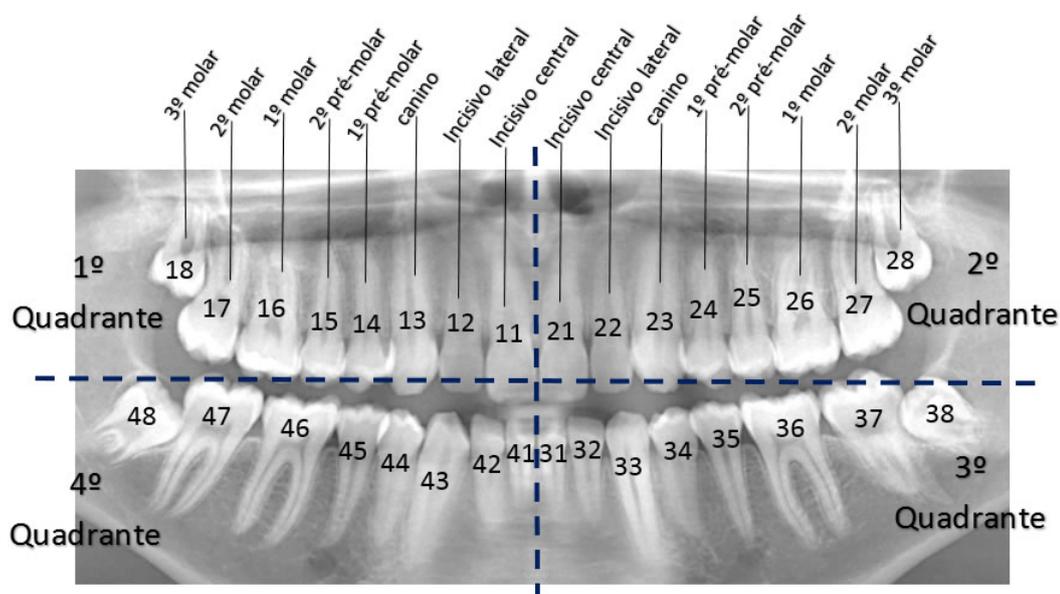


Figura 3.1: Nomenclatura e numeração dos dentes baseado na notação ISO 3950.

Segundo [Fehrenbach et al. \(2012\)](#), cada dente é basicamente formado por três partes: (1) Raiz é a parte do dente presa aos ossos da face (maxila e mandíbula); (2) Coroa é a parte branca visível do dente; (3) Colo é a parte localizada entre a raiz e a coroa. A Figura 3.2 apresenta as partes estruturais de um dente. Na Figura 3.2, também é possível observar outros elementos estruturais que compõem um dente e que podem ser visualizados por meio da análise das imagens de raio-X dentários. Ainda de acordo com [Fehrenbach et al. \(2012\)](#), o **esmalte** é a região mais externa da superfície do dente. Sob ele está a **dentina** substância dura e sensível que contém sais de cálcio e envolve a polpa do dente. A **polpa** é uma substância mole e vermelha, formada por tecido conjuntivo e é rica em nervos e vasos sanguíneos, por fim, o **ápice** que representa o final da raiz.



Figura 3.2: Partes estruturais do dente.

### 3.2 Raios-X dentários

No final do ano de 1895, um físico alemão chamado *Wilhelm Konrad Roentgen*, enquanto realizava experimentos com raios catódicos, descobriu os raios-X. Visto que não se conhecia as características destes raios, ele denominou-os de raios "X", termo usado pelos matemáticos para as variáveis desconhecidas ([SAARI, 2001](#)). No início do século XX, cientistas começaram a investigar esses novos raios que podiam mostrar o corpo humano por dentro e que representavam uma extraordinária revolução na medicina ([ESSIG, 2008](#)). Os médicos, então, adotaram os raios-X para tirar fotos (chamadas de radiografias) dos ossos, o que os ajudou a tratar lesões de forma mais efetiva.

Atualmente, os raios-X são usados nas mais diversas áreas, tais como: na segurança dos aeroportos, em atividades industriais, produções cinematográficas ou mesmo em trabalhos militares. Entretanto, no contexto da medicina, os rápidos avanços nesta área causaram um impacto significativo na Odontologia. Segundo [Kreich et al. \(2005\)](#), os raios-X possuem aplicabilidade clínica principalmente na Endodontia que é a especialidade da Odontologia responsável pelo estudo da polpa dentária, de todo o sistema de canais radiculares e dos tecidos periapicais. Desse modo, possibilitam aumento da qualidade diagnóstica e permitem estudos de alterações ósseas e dentárias mais eficazes.

Na Estomatologia, que é a ramo da Odontologia responsável por diagnosticar e tratar as enfermidades relacionadas com a boca e todo aparelho estomatognático (lábios, dentes e demais estruturas da orofaringe), os raios-X também têm um papel importante, uma vez que proporciona a detecção precoce de doenças dentárias e impedem complicações futuras (TOMMASI, 2002).

Em Biometria Dental, o uso de raios-X dentais também é de grande importância para a identificação de pessoas falecidas. Kumar, Ghosh e Logani (2014) observam que em situações catastróficas, onde ocorre o não-reconhecimento total do indivíduo devido a deformações em todo o corpo, o raio-X dental é a única maneira de identificar esses indivíduos.

### 3.2.1 Anomalias dentárias e tipos de raio-X

De acordo com Alvares e Tavano (2002), anomalias dentárias são distúrbios no desenvolvimento ou crescimento das estruturas dentárias. Essas alterações podem estar relacionadas com a forma, tamanho, número, posição ou função dos dentes. Além disso, podem ser ocasionadas devido a alguns fatores, dentre os quais destacam-se:

- **Fatores Locais** - Infecções, traumatismo e cirurgias acidentais.
- **Fatores Sistêmicos** - Distúrbios hormonais, intoxicações devido ao uso de medicamentos ou deficiências nutricionais.
- **Fatores Hereditários** - Passados de geração em geração.

Na Odontologia, as anomalias possuem classificação, isto é, quando relacionada ao aumento, diminuição ou posição dos dentes, são classificadas como: *hipoplasiantes* (diminuição do número de dentes ou dos tecidos que o compõe), *heterotópicas* (caracterizadas pelo irrompimento e/ou posição dos dentes fora de seu local habitual) e *hiperplasiantes* (aumento do número de dentes ou dos tecidos que o compõe) (ALVARES; TAVANO, 2002). Esta última, constitui a categoria contendo a anomalia conhecida como dentes supranumerários.

Outras anomalias dentárias são frequentemente estudadas na literatura. Neville, Damm e Allen (2004) destacam: **dentes natais**, são dentes que já estão presentes no momento do nascimento do bebê; **pérolas de esmalte**, estruturas hemisféricas de esmalte em localizações incomuns, principalmente nas raízes de molares e mais raramente em pré-molares; **fusão dentária**, resultado da união embriológica de dois dentes em desenvolvimento;

**taurondontismo**, caracteriza-se pelo aumento do corpo da câmara pulpar em dentes que possuem mais de uma raiz, assemelhando-se a dentes de touro.

O diagnóstico precoce e o tratamento de pacientes são importantes para prevenir anomalias dentárias, minimizar complicações e melhorar os prognósticos. Neste sentido, as radiografias são um complemento essencial, pois evidenciam detalhes impossíveis de serem detectados durante o exame clínico.

Segundo a revista *APCD*<sup>1</sup> (Associação Paulista de Cirurgiões-Dentistas) e o *IRHPA*<sup>2</sup> (Instituto de Diagnóstico por Imagem), de modo geral, os raios-X dentais estão divididos em duas categorias principais: as radiografias intraorais e as radiografias extraorais, conforme descrição a seguir.

A radiografia intraoral ou intra bucal, mostra a imagem do interior da boca e é a mais comumente utilizada na medicina dentária. Ela permite que um dentista observe todas as anomalias que podem estar no interior da boca, como por exemplo: as cáries dentárias, a saúde óssea da área circundante de um dente e o estado e desenvolvimento dos dentes. Dentre as radiografias intraorais, destacam-se, pela sua frequência de ocorrência, nos consultórios odontológicos, as seguintes radiografias:

- **A radiografia intraoral *bitewing*** - Ou raio-X *bitewing*. Estes são usados para verificar a existência de cáries entre os dentes e mostrar como os dentes superiores e inferiores se encontram alinhados. Também possibilita verificar a perda de massa óssea nos casos de uma doença gengival.
- **A radiografia intraoral *periapical*** - Os raios-X *periapicais* mostram todo o dente, a partir da coroa exposta à extremidade da raiz e dos ossos que suportam o dente. Estes raios-X são usados para encontrar problemas dentários abaixo da linha da gengiva ou na mandíbula, como dentes inclusos, abscessos, cistos, tumores e alterações ósseas associadas a algumas doenças.
- **A radiografia *oclusal*** - Trata-se de um raio-X que é utilizado para verificar o nascimento e crescimento dos dentes e detectar se existe alguma fratura nos maxilares.

A radiografia extra bucal ou extraoral, mostra a imagem que se encontra no exterior da boca e permite conhecer o estado dos dentes, apesar do seu objetivo incidir sobre os

<sup>1</sup>[http://www.apcd.org.br/index.aspx?Pagina=Revista\\_APCD.html](http://www.apcd.org.br/index.aspx?Pagina=Revista_APCD.html)

<sup>2</sup><http://www.irhpa.com.br/exames/exame.asp?id=13>

maxilares e o crânio. Este tipo de raio-X verifica a relação entre os dentes e os maxilares e examina os ossos das articulações temporomandibulares (articulações da mandíbula com o crânio). Nesta categoria destacam-se as seguintes:

- **A radiografia extraoral *tomograma*** - é um tipo de radiografia, no qual o dentista consegue ver em detalhes determinadas estruturas que não são vistas com um raio-X do tipo intra oral, por exemplo, a articulação temporomandibular, mostrando se esta apresenta algum tipo de anomalia.
- **A radiografia extraoral *panorâmica (Foco deste trabalho)*** - Também conhecido como raios-X *panorâmico* ou *ortopantomografia*. É um dos exames radiológicos capaz de obter informações fundamentais para diagnóstico de anomalias em medicina dentária. Através desse exame, o dentista pode visualizar todos os dentes de uma só vez, inclusive os que ainda não estão erupcionados. O exame ortopantomográfico possibilita a visualização de irregularidades dentárias, como por exemplo: os dentes inclusos, anormalidades ósseas, quistos, tumores, cancros, infecções, fraturas pós-acidentes, distúrbios da articulação temporomandibular que causam dor na região de ouvido, face, pescoço e cabeça. É comum odontólogos solicitá-lo também como exame pré-operatório em cirurgias dos dentes e ossos das região temporomandibular.

No trabalho aqui proposto, todos os experimentos foram realizados objetivando a segmentação em radiografias dos dentes do tipo panorâmica. Detalhes sobre as imagens utilizadas são apresentadas no Capítulo 5.

### **3.3 Considerações finais**

A detecção de doenças odontológicas em estágio preliminar é importante para o tratamento e recuperação total dos dentes. Por meio do exame radiológico (raio-x), o odontólogo pode analisar toda a estrutura dentária e constituir (caso necessário) o plano de tratamento do paciente. No entanto, a análise depende de um trabalho cuidadoso do profissional e esta não é realizada de forma automática, permitindo inclusive que a identificação de possíveis anomalias dentárias passem despercebidas, em alguns casos. O problema se torna ainda maior quando existe a necessidade de análise de imagens como os raios-X panorâmicos dos dentes, pois possibilitam a visualização de irregularidades dentárias em todos os dentes em uma única imagem, além da área nasal e região temporomandibular. Neste sentido, uma opção é a utilização de métodos de segmentação para a extração de características das imagens radiográficas panorâmicas (de forma automática ou semiautomática), isolando os dentes para facilitar a sua análise. Entretanto, o método de segmentação deve conseguir realizar a divisão das imagens de raio-X em

suas unidades significativas (dentes), desprezando todas as regiões que não compõem os dentes (gengivas, ossos do queixo e da boca, área nasal e temporomandibular). Sendo assim, uma avaliação aprofundada do desempenho dos algoritmos de segmentação deve ser aplicada para comprovar a eficiência dos resultados e então determinar qual método de segmentação é o mais indicado para auxílio ao diagnóstico médico dentário.

No próximo capítulo, é realizada uma breve introdução sobre segmentação de imagens e as dificuldades encontradas para realização do processo de segmentação em imagens de raio-X dentárias. Em seguida, são apresentadas as categorias e os métodos de segmentação de imagens analisados no presente trabalho, descrevendo-os e apresentando como são implementados.

## Métodos de segmentação de imagens

O degrau de uma escada não serve simplesmente para que alguém permaneça em cima dele, destina-se a sustentar o pé de um homem pelo tempo suficiente para que ele coloque o outro um pouco mais alto.  
(Thomas Huxley)

A segmentação de imagens é uma das mais difíceis tarefas nas áreas de Visão Computacional e Processamento de Imagens, desempenhando um papel importante na análise de imagens, especialmente no que se refere ao reconhecimento de padrões. No presente capítulo, são apresentadas definições sobre o processo de segmentação de imagens. Em seguida, os métodos de segmentação de imagens avaliados no presente trabalho são apresentados, descrevendo cada categoria dos métodos e especificando os passos necessários que devem ser adotados para implementação e utilização dos algoritmos de segmentação.

### 4.1 Segmentação de imagens

Segmentação significa decompor uma imagem em suas unidades ou objetos que a compõem. O nível a que a decomposição é realizada depende do problema a ser resolvido, ou seja, a segmentação deve parar quando os objetos de interesse forem isolados. O objetivo deste trabalho, consiste na análise de algoritmos de segmentação, a fim de verificar se cada algoritmo estudado consegue identificar corretamente a presença ou ausência dos dentes, ou ainda, próteses, implantes, dentes quebrados ou restaurações.

As imagens de raio-X dentais panorâmicas utilizadas no presente trabalho estão em níveis de cinza e foram capturadas no espaço de cor RGB (*Red, Green, Blue*). Sendo assim, são imagens de 24 bits, 8 bits para cada componente RGB, onde cada canal de cor contém valores variando de 0 à 255. Quando as imagens digitais são exibidas em níveis de cinza, no espaço de cor RGB, significa que seus componentes R, G e B são sempre iguais. Desse modo, um *pixel* na cor preta é representado por: R igual a 0 (zero), G igual a 0 (zero) e B igual a 0 (zero). Portanto, as variações nas áreas claras e escuras são codificadas como um conjunto de números, onde: nas áreas claras (correspondentes a regiões que absorvem uma grande porção do feixe de raios-X), são atribuídos valores altos, tal como 255, sempre

iguais, nos três canais de cores (RGB) para todos os *pixels* da região, indicando o branco total, enquanto que nas áreas escurecidas (que são causadas por baixa absorção de raios-X), são atribuídos valores 0s (zeros), sempre iguais, nos três canais de cores (RGB) para todos os *pixels* da região, indicando o negro total. Aos níveis de cinza intermediários são atribuídos valores, sempre iguais, entre 0 e 255 nos três canais de cores (RGB). Os métodos de segmentação analisados no presente trabalho são baseados em limiarização, isto é, necessitam de um valor de limiar para a segmentação de uma imagem. Os métodos de segmentação que utilizam limiar, só trabalham com imagens em níveis de cinza e utilizando um único canal de cor. Conforme explicação anterior, as imagens originais já estão em níveis de cinza, desse modo, contendo todos os componentes iguais nos três canais de cores, o que possibilitou realizar a análise das imagens com um único canal de cor, por meio dos algoritmos de segmentação estudados, sem perda de informação e sem comprometer os resultados das análises. As imagens do *dataset* do presente trabalho foram categorizadas do seguinte modo:

- **Categoria 1:** Imagens **com todos** os dentes e contendo dentes **com restauração e com aparelho**.
- **Categoria 2:** Imagens **com todos** os dentes contendo dentes **com restauração e sem aparelho**.
- **Categoria 3:** Imagens **com todos** os dentes contendo dentes **sem restauração e com aparelho**.
- **Categoria 4:** Imagens **com todos** os dentes contendo dentes **sem restauração e sem aparelho**.
- **Categoria 5:** Imagens contendo implante.
- **Categoria 6:** Imagens contendo mais de 32 dentes.
- **Categoria 7:** Imagens **faltando** dentes contendo dentes **com restauração e com aparelho**.
- **Categoria 8:** Imagens **faltando** dentes contendo dentes **com restauração e sem aparelho**.
- **Categoria 9:** Imagens **faltando** dentes contendo dentes **sem restauração e com aparelho**.
- **Categoria 10:** Imagens **faltando** dentes contendo dentes **sem restauração e sem aparelho**.

A Figura 4.1 mostra uma imagem de raio-X correspondente a cada uma de sua respectiva categoria do *dataset* do presente trabalho.

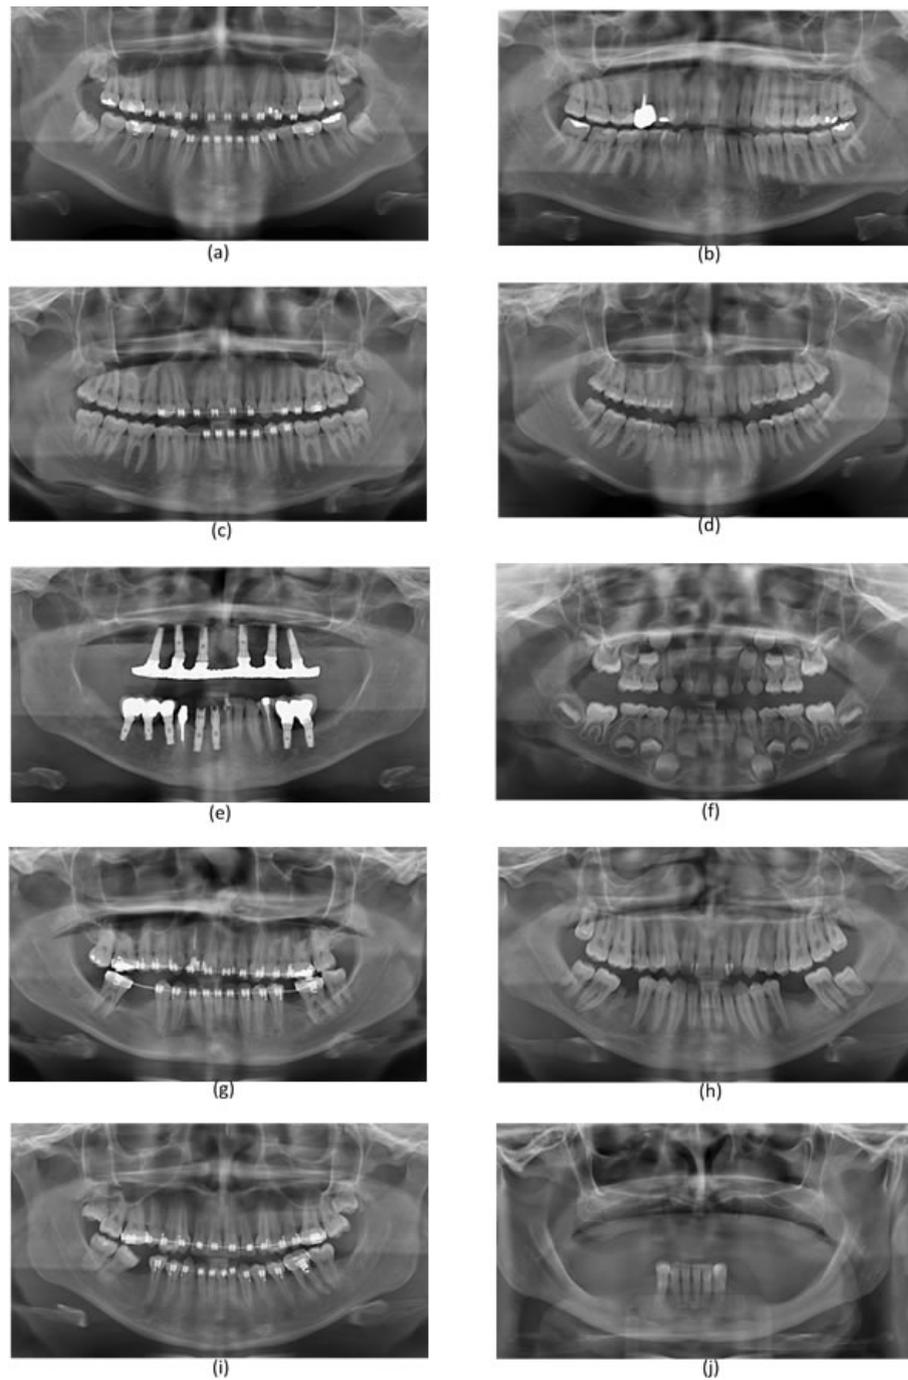


Figura 4.1: Exemplos de imagens das categorias do *dataset* do presente trabalho: **(a) Categoria 1:** Imagem com todos os dentes e contendo dentes com restauração e com aparelho; **(b) Categoria 2:** Imagem com todos os dentes contendo dentes com restauração e sem aparelho; **(c) Categoria 3:** Imagem com todos os dentes contendo dentes sem restauração e com aparelho; **(d) Categoria 4:** Imagem com todos os dentes contendo dentes sem restauração e sem aparelho; **(e) Categoria 5:** Imagem contendo implante; **(f) Categoria 6:** Imagem contendo mais de 32 dentes; **(g) Categoria 7:** Imagem faltando dentes contendo dentes com restauração e com aparelho; **(h) Categoria 8:** Imagem faltando dentes contendo dentes com restauração e sem aparelho; **(i) Categoria 9:** Imagem faltando dentes contendo dentes sem restauração e com aparelho; **(j) Categoria 10:** Imagem faltando dentes contendo dentes sem restauração e sem aparelho.

Segundo [Sezgin e Sankur \(2004\)](#), os métodos de segmentação são categorizados de acordo com as características (histograma, entropia, região, maximização/minimização de funções, dentre outras) procuradas na imagem para gerar o ponto de corte (valor que determina o que são os objetos de interesses e o que não são na imagem analisada). No presente trabalho, foram estudados seis métodos de segmentação que estão agrupados em quatro categorias: (1) Segmentação Baseada em Histograma da Imagem, (2) Segmentação Baseada em Limiar Variável Local, (3) Segmentação Baseada em Região e (4) Segmentação Baseada em Entropia da Informação. As próximas seções descrevem cada um dos métodos de segmentação estudados neste trabalho, conceituando-os e descrevendo como funcionam.

## 4.2 Segmentação baseada em histograma da imagem

Existem imagens, onde os níveis de cinza dos *pixels* que pertencem aos objetos de interesse são substancialmente diferentes dos níveis de cinza dos *pixels* que pertencem ao fundo. Nestes casos, a segmentação por limiarização baseada no histograma da imagem se torna uma ferramenta simples, mas eficaz para separar objetos do fundo. Exemplos de aplicações de limiar são a extração de caracteres impressos em documentos ou processamento de mapas, onde linhas, legendas e outros elementos podem ser isolados ([KAMEL; ZHAO, 1993](#)); ([ABAK et al., 1997](#)).

Supõe-se que um determinado histograma de intensidade corresponde a uma imagem,  $f(x, y)$ , composto por objetos claros sobre um fundo escuro, de tal forma que objetos e fundo têm níveis de intensidade agrupados em dois modos dominantes. Uma maneira para extrair os objetos do fundo é selecionar um limiar  $T$  que separa estas duas regiões. Então, qualquer ponto da imagem  $(x, y)$  em que  $f(x, y) \leq T$  é chamado de fundo, caso contrário, o ponto é chamado de objeto (o inverso vale para objetos escuros sobre um fundo claro). Neste sentido, a imagem segmentada resultante  $g(x, y)$  é definida como:

$$g(x, y) = \begin{cases} a & \text{se } f(x, y) > T \\ b & \text{se } f(x, y) \leq T \end{cases} \quad (4.1)$$

Uma maneira de escolher um limiar é por inspeção visual do histograma da imagem. Por exemplo, o histograma na [Figura 4.2](#) tem dois modos distintos, e que é fácil escolher um limiar  $T$  que os separa. Uma outra maneira de escolher  $T$  é por tentativa e erro, realizando a seleção de diferentes limiares até que seja encontrado um que produza um bom resultado. Entretanto, os métodos de segmentação que se baseiam no histograma da imagem geralmente utilizam algoritmos capazes de encontrar o limiar automaticamente,

a partir de dados da imagem.

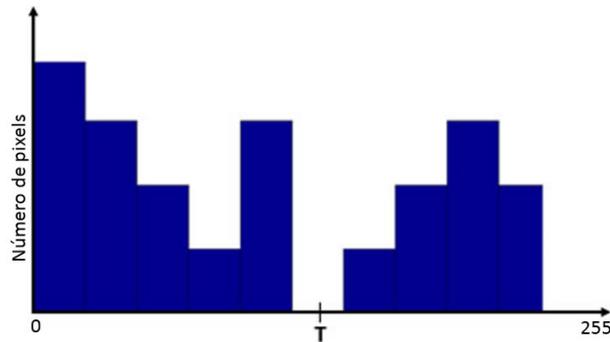


Figura 4.2: Exemplo de seleção manual de limiar baseado no histograma de uma imagem.

Nas próximas seções, serão apresentados os métodos de segmentação que foram analisados no presente estudo e que trabalham selecionando de forma automatizada o valor de limiar, com base nas propriedades da imagem.

#### 4.2.1 Limiarização Básica Global

Com base no histograma de uma imagem, um dos métodos mais conhecidos de limiarização é a Limiarização Básica Global (do inglês, *Basic Global Thresholding*). O sucesso desta técnica depende muito fortemente de quão bem o histograma pode ser particionado. Esta abordagem utiliza os seguintes passos:

1. Estimar um valor inicial para o limite global,  $T$ ;
2. Segmentar a imagem usando  $T$ . Isto irá produzir dois grupos de *pixels*:  $G_1$  consistindo de todos os *pixels* com intensidade de valores maiores que  $T$  e  $G_2$ , consistindo de *pixels* com valores menores ou iguais a  $T$ ;
3. Calcular os valores médios de intensidade  $m_1$  e  $m_2$  para os *pixels* nas regiões  $G_1$  e  $G_2$ , respectivamente;
4. Calcular um novo valor de limiar usando:

$$T = \frac{1}{2}(m_1 + m_2) \quad (4.2)$$

5. Repetir os passos 2 a 4 até que a diferença de  $T$  em sucessivas iterações seja menor do que um valor positivo pré-definido por um parâmetro  $\Delta T$  (valor usado para controlar o número de iterações). Quanto maior é o  $\Delta T$ , menos interações o algoritmo irá

executar. Este valor deve ser entre 0 e 1, o valor padrão determinado pelo método de Limiarização Básica Global é utilizar 0,5 para o parâmetro  $\Delta T$  (adotado no presente trabalho);

6. Por fim, converter a imagem em tons de cinza para uma imagem binária utilizando o limiar  $\mathbf{T}/\mathbf{den}$ , onde  $\mathbf{T}$  é o limiar obtido nos passos anteriores e  $\mathbf{den}$  é um número inteiro (por exemplo, 255 para uma imagem de 8-bits), que dimensiona o valor máximo da razão de  $\mathbf{T}/\mathbf{den}$  para 1. A imagem de saída substitui todos os *pixels* da imagem de entrada que estiverem com nível de intensidade maior do que o limiar  $\mathbf{T}/\mathbf{den}$  pelo valor 1 (correspondente a cor branca) e substitui todos os outros *pixels* pelo valor 0 (correspondente a cor preta).

Na limiarização básica global, a média é uma boa escolha inicial para  $T$ . Sendo assim, para cada imagem que foi segmentada utilizando a limiarização básica global, o presente trabalho utilizou como limiar inicial para execução do algoritmo, a **média** obtida pelas análises estatísticas dos *pixels* do ROI (Região dos Objetos de Interesse), que foram calculados para cada imagem individualmente. O processo para seleção do ROI nas imagens e também das análises estatísticas que foram realizadas são detalhados no Capítulo 5.

O algoritmo padrão de Limiarização Básica Global determina que deve ser informado para o parâmetro **den**, o maior valor de intensidade dos *pixels* da imagem a ser segmentada. As imagens do *dataset* do presente trabalho são imagens de *8-bits* em escala de cinza, portanto, com níveis de intensidade dos *pixels* que variam no intervalo de 0 a 255. Entretanto, no trabalho aqui proposto, foi informado para o parâmetro **den**, o **maior valor** obtido pelas análises estatísticas dos *pixels* dos ROIs, que foram calculados para cada imagem individualmente.

Portanto, a limiarização global consiste no estabelecimento de um valor de intensidade (limiar) de tal modo que todos os *pixels* com valor inferior ao limiar pertencem a uma região e o restante pertença a outra. A Figura 4.3 apresenta uma amostra do processo de limiarização global realizado no trabalho aqui proposto, em que é mostrado a primeira imagem segmentada de cada categoria do *dataset* do presente trabalho, após aplicação da segmentação por limiarização básica global.

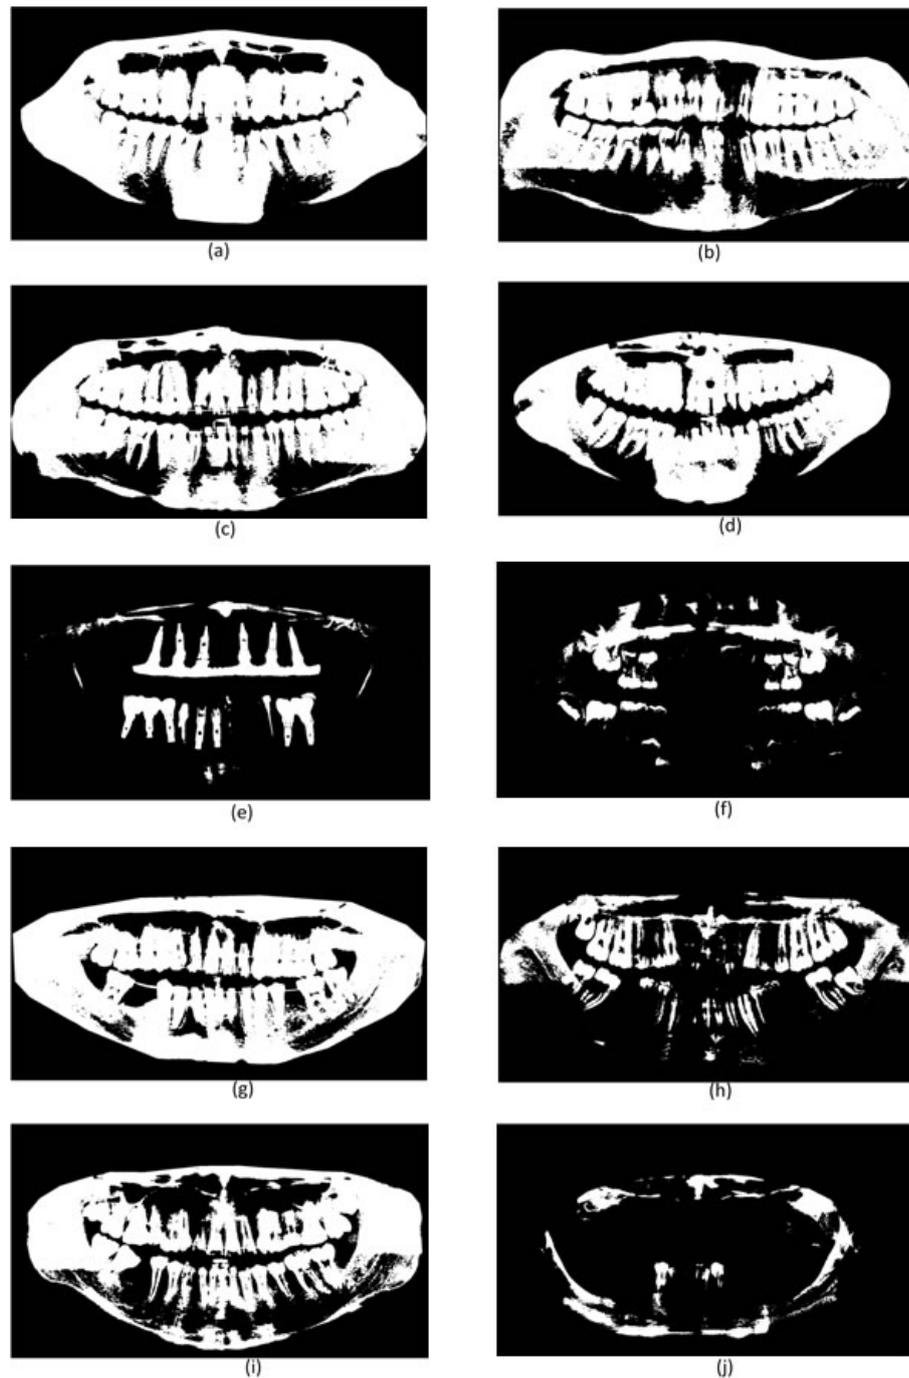


Figura 4.3: Exemplos de resultados da segmentação pelo método *Basic Global Thresholding*: (a) **Categoria 1**: Imagem com todos os dentes e contendo dentes com restauração e com aparelho; (b) **Categoria 2**: Imagem com todos os dentes contendo dentes com restauração e sem aparelho; (c) **Categoria 3**: Imagem com todos os dentes contendo dentes sem restauração e com aparelho; (d) **Categoria 4**: Imagem com todos os dentes contendo dentes sem restauração e sem aparelho; (e) **Categoria 5**: Imagem contendo implante; (f) **Categoria 6**: Imagem contendo mais de 32 dentes; (g) **Categoria 7**: Imagem faltando dentes contendo dentes com restauração e com aparelho; (h) **Categoria 8**: Imagem faltando dentes contendo dentes com restauração e sem aparelho; (i) **Categoria 9**: Imagem faltando dentes contendo dentes sem restauração e com aparelho; (j) **Categoria 10**: Imagem faltando dentes contendo dentes sem restauração e sem aparelho.

### 4.3 Segmentação baseada em limiar variável local

Limiarização global normalmente falha quando a imagem apresenta uma variação considerável no contraste e iluminação, resultando em muitos *pixels* que não podem ser facilmente classificados como primeiro ou segundo plano, isto é, *pixels* que correspondem aos objetos de interesse ou ao fundo da imagem. Uma solução para este problema consiste em tentar estimar uma "função de sombreamento", e em seguida utilizá-la para compensar o padrão de intensidades não uniformes. A abordagem comumente utilizada para compensar irregularidades, ou quando exista muita variação de intensidade dos *pixels* relacionadas ao objeto dominante (caso em que a limiarização global tem dificuldades), é a utilização de limiar variável baseado em estatísticas locais dos *pixels* da imagem.

Em métodos de segmentação que utilizam limiarização variável local, um limiar  $T(x,y)$  é calculado para cada ponto  $(x, y)$  na imagem, baseado em duas medidas de estatísticas locais: média e desvio padrão, dentro de um bloco de vizinhança local de tamanho  $n \times n$  para cada ponto  $(x, y)$ . Sendo assim, a segmentação baseada em limiar variável local, faz a utilização de uma região quadrada ou retangular centrada na posição  $(x, y)$ , como na Figura 4.4. O centro da região é movido de *pixel* para *pixel* a partir do canto superior esquerdo da imagem, e, à medida que se move, ele envolve diferentes vizinhanças, obtendo o limiar  $T$  em cada local  $(x, y)$ . A base para a limiarização local é a realização do cálculo de desvio padrão e média dos *pixels* de uma vizinhança de cada ponto em uma imagem. Estas duas medidas são úteis para a determinação dos limiares locais, pois são descritores de contraste e luminosidade, e que correspondem a propriedades que quando estão presentes com muita intensidade em uma imagem, dificultam o processo de segmentação em algoritmos que utilizam um único limiar global, como a técnica de limiarização global que foi apresentada na seção anterior.

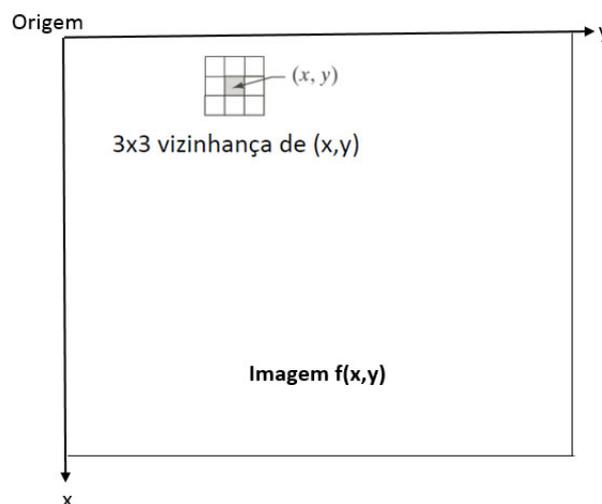


Figura 4.4: Exemplo de uma vizinhança 3 x 3 em torno de um ponto  $(x,y)$  numa imagem.

Considerando uma imagem em escala de cinza  $f(x,y)$ , a segmentação baseada em limiar variável local, tem o objetivo de calcular um valor de limiar local  $T(x, y)$  para cada *pixel* tal que:

$$b(x, y) = \begin{cases} 0 & \text{se } f(x, y) \leq T(x, y) \\ 1 & \text{caso contrário} \end{cases} \quad (4.3)$$

onde  $b(x,y)$  é a imagem binarizada.

### 4.3.1 Método Niblack (*Method Niblack*)

Adaptações da segmentação que utiliza limiarização variável local tem sido realizada, como apresentado em (SINGH et al., 2011) e (SINGH et al., 2012). Entretanto, a presente dissertação baseia-se no método originalmente proposto por Niblack (1985). Nesta abordagem, o valor de limiar local  $T(x,y)$  em um ponto  $(x,y)$  é calculado com um bloco de tamanho  $w \times w$ , utilizando a equação:

$$T(x, y) = m(x, y) + k * \sigma(x, y) \quad (4.4)$$

onde  $m(x,y)$  e  $\sigma(x,y)$  representam a média e o desvio padrão local do bloco local de tamanho  $w \times w$ . Portanto, o algoritmo padrão baseado no método Niblack, necessita de três parâmetros iniciais para realizar a segmentação:

- **f** - A imagem a ser segmentada;
- **nhood** - é uma matriz de zeros e uns em que os elementos não zero especificam os vizinhos utilizados no cálculo do desvio padrão local. O padrão do método Niblack é a utilização de uma matriz 3 X 3 (adotado no presente trabalho);
- **k** - é uma constante de desequilíbrio (também chamado de *bias*) que modifica o contraste local obtido pelo desvio padrão local. O valor padrão do método Niblack é utilizar  $k$  igual a 1 (adotado no presente trabalho), para manter o valor encontrado com o cálculo de desvio padrão local;

A Figura 4.5 apresenta uma amostra do processo de segmentação baseado em limiarização variável local, em que é mostrado a primeira imagem segmentada de cada categoria do *dataset* do presente trabalho, após aplicação da segmentação pelo método Niblack.

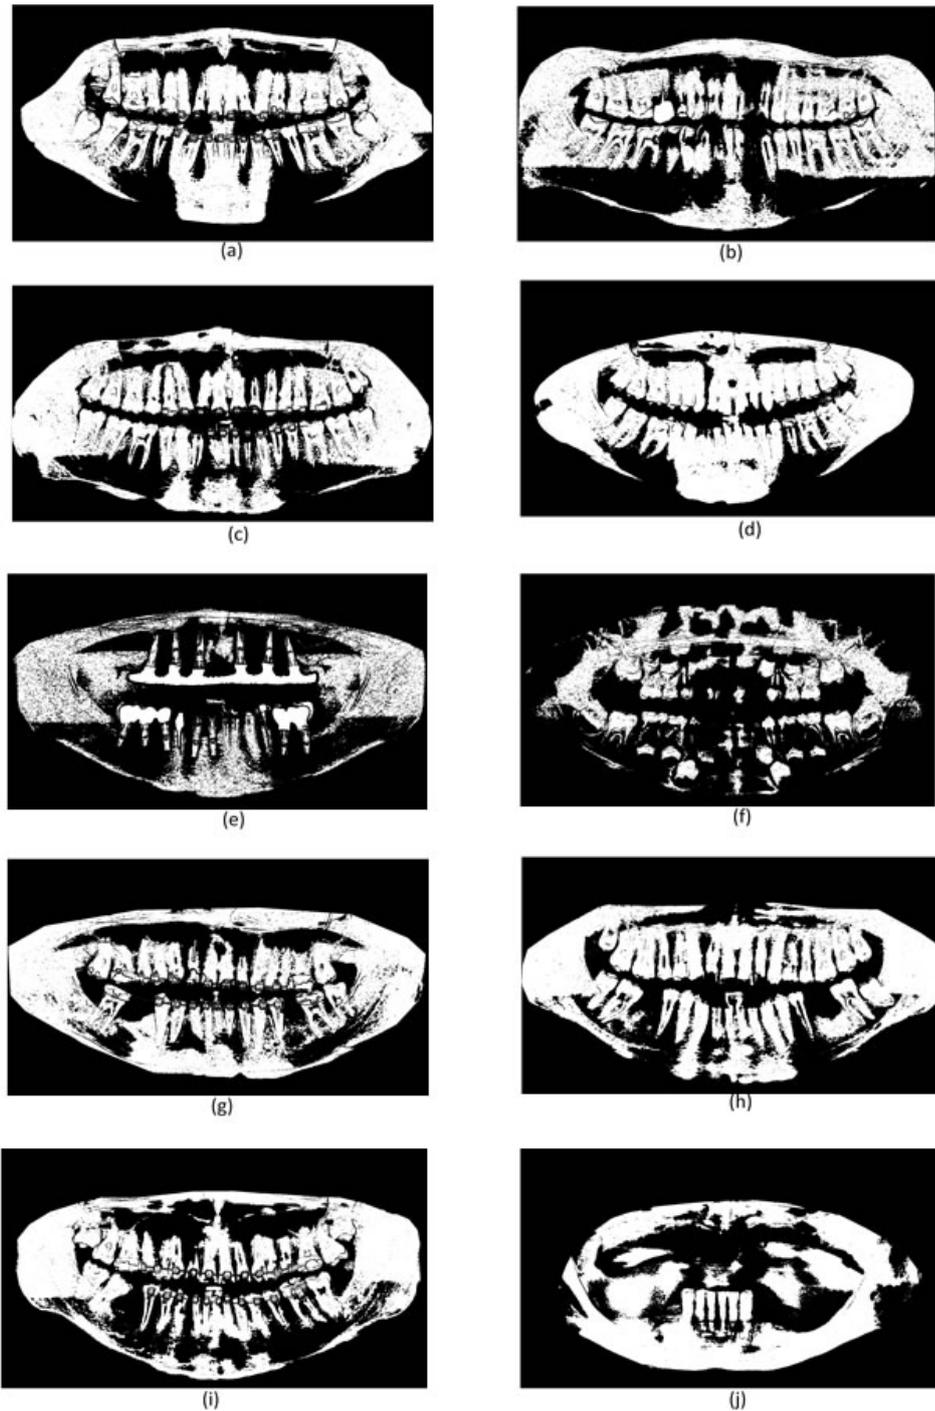


Figura 4.5: Exemplos de resultados da segmentação pelo método Niblack: (a) **Categoria 1:** Imagem com todos os dentes e contendo dentes com restauração e com aparelho; (b) **Categoria 2:** Imagem com todos os dentes contendo dentes com restauração e sem aparelho; (c) **Categoria 3:** Imagem com todos os dentes contendo dentes sem restauração e com aparelho; (d) **Categoria 4:** Imagem com todos os dentes contendo dentes sem restauração e sem aparelho; (e) **Categoria 5:** Imagem contendo implante; (f) **Categoria 6:** Imagem contendo mais de 32 dentes; (g) **Categoria 7:** Imagem faltando dentes contendo dentes com restauração e com aparelho; (h) **Categoria 8:** Imagem faltando dentes contendo dentes com restauração e sem aparelho; (i) **Categoria 9:** Imagem faltando dentes contendo dentes sem restauração e com aparelho; (j) **Categoria 10:** Imagem faltando dentes contendo dentes sem restauração e sem aparelho.

## 4.4 Segmentação baseada em região

O objetivo da segmentação baseada em região é particionar uma imagem em regiões, encontrando limites entre elas com base em descontinuidades nos níveis de intensidade dos *pixels*. Nesta seção, serão apresentados os métodos que foram avaliados no presente trabalho, que são baseados em crescimento e divisão de regiões.

### 4.4.1 Crescimento de Região (*Region Growing*)

O método de segmentação conhecido como Crescimento de Regiões (do inglês, *Region Growing*) é um procedimento que agrupa *pixels* ou sub-regiões em regiões maiores com base em critérios pré-definidos para o crescimento. A abordagem básica é começar com um conjunto de pontos chamados de centróides ou sementes. Em seguida, compara-se cada *pixel* com a média dos valores de intensidade dos *pixels* de uma região próxima, mas que ainda não foi definida como segmento. Se o valor de intensidade do *pixel* for próximo a média de uma região, ele será adicionado a esta região e a média da região é atualizada. Se for encontrado mais de uma região próxima, o *pixel* será acrescentado àquela cuja média possuir o valor mais próximo do valor de intensidade do *pixel*. Se duas regiões diferentes possuírem médias iguais, então elas são fundidas em uma só e o *pixel* será adicionado a esta nova fusão. Se o *pixel* não possuir um valor próximo a nenhuma região existente, então uma nova região é criada e o *pixel* em questão é adicionado a esta região como primeiro membro.

Selecionar um conjunto de um ou mais pontos de semente depende da natureza do problema. Um procedimento padrão do método baseado em crescimento de região é calcular para cada *pixel* o mesmo conjunto de propriedades que serão atribuídos aos *pixels* para as regiões durante o processo de crescimento. Se os resultados desses cálculos gerar conjuntos de valores de *pixels* cujas propriedades coloque-os perto do centro (*centroides*) dos valores que estamos procurando, então estes valores podem ser utilizados como sementes. O algoritmo baseado em crescimento de região, por padrão recebe três parâmetros para realizar as operações de segmentação:

- **f** - A imagem a ser segmentada;
- **Sementes** - Pontos iniciais para iniciar o processo de crescimento de regiões;
- **dist** - Limiar que servirá de base para indicar a similaridade entre os *pixels* que farão parte da região ou não. Este limiar também funciona como critério de parada para o algoritmo, conforme explicado adiante.

Uma região é formada por meio da comparação de todos os *pixels* vizinhos não alocados para a região. Por padrão, a **diferença entre o valor da intensidade de um *pixel* candidato e o valor médio de intensidade da região em crescimento**, é usado como medida da semelhança. O *pixel* com a menor diferença medida desta maneira é atribuído à respectiva região. Este processo termina quando a diferença de intensidade entre a média da região e o *pixel* novo tornar-se maior do que um limiar especificado, este limiar é o parâmetro *dist* que representa a distância entre os *pixels*, indicando assim o critério de parada do algoritmo. A técnica de segmentação de crescimento de região para quando não existem mais *pixels* que satisfaçam os critérios para inclusão nas regiões.

No presente trabalho, foram escolhidas **manualmente** as células contendo as coordenadas X e Y dos centroides (centro dos objetos de interesse) das regiões dos dentes (objetos de interesse nas imagens), para servirem de sementes. Os valores das sementes foram agrupados em vetores para cada imagem correspondente, que serviram como os pontos iniciais para execução do algoritmo de crescimento de região. A Figura 4.6 ilustra o processo de seleção das sementes (centroides) em uma das imagens do *dataset* do presente trabalho.

```
seeds = [420 300; 489 382; 579 408; 672 414; 750 421; 814 429; 888
442; 955 453; 1035 454; 1100 454; 1179 460; 1263 456; 1334 451; 1424
444; 1538 396; 1595 297; 346 576; 468 581; 609 614; 711 630; 784
645; 864 650; 934 645; 988 644; 1044 642; 1097 642; 1163 642; 1248
650; 1328 651; 1438 609; 1562 582; 1688 578];
```

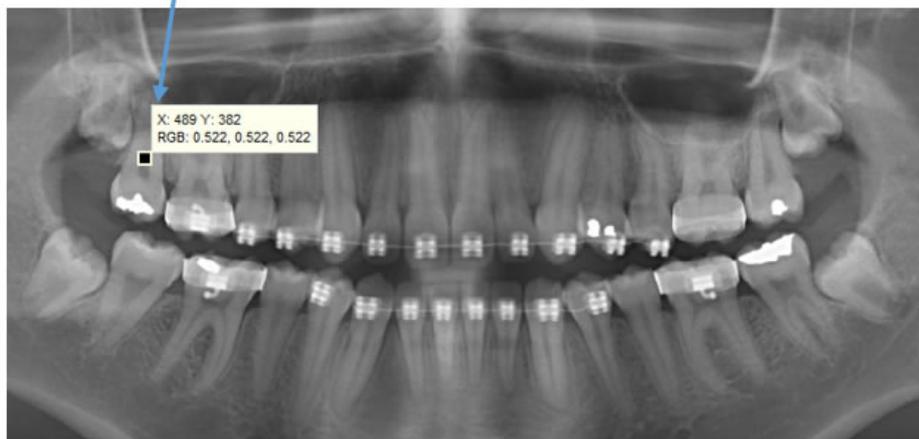


Figura 4.6: Seleção manual das sementes para o algoritmo de crescimento de região

De posse dos centroides que foram utilizados como sementes para o segmentador baseado em crescimento de região, o último parâmetro definido foi o *dist* que conforme explicado anteriormente, corresponde ao valor numérico que representa a distância máxima de similaridade entre os *pixels* de um segmento. O parâmetro *dist* também corresponde ao valor condicional de parada do algoritmo, quando não existem mais *pixels* que satisfaçam

aos critérios para inclusão na região, ou seja, quando a diferença da média de intensidade entre os *pixels* de uma região e um *pixel* novo tornar-se maior que o parâmetro *dist* informado e, portanto, não existindo mais *pixels* a serem inseridos nas regiões.

Por padrão, o parâmetro *dist* do segmentador baseado em crescimento de região possui o valor 0.1. De acordo com [Gonzales e Woods \(2008\)](#), não é recomendável informar valores para o parâmetro *dist*, acima de 0.1, pois prejudica os resultados da segmentação, aumentando gradativamente o tempo de processamento do segmentador durante as operações de segmentação. Entretanto, no presente trabalho, foram realizadas avaliações informando o valor 0.1, o valor 0.05 e o valor 0.025 para o parâmetro *dist* do algoritmo de segmentação baseado em crescimento de região. Verificou-se que, quanto menor foi o valor informado para o parâmetro *dist*, piores foram os resultados obtidos das segmentações. Este processo foi realizado nas 1500 imagens existentes do *dataset* do presente trabalho e que foram utilizadas para análise de desempenho dos algoritmos de segmentação. Os resultados da escolha do parâmetro *dist* foram validados por meio do cálculo da métrica Sensibilidade (percentual de acerto dos *pixels* relevantes corretamente identificados), indicando que o valor 0.1 quando passado para o parâmetro *dist*, alcançou melhores resultados e, portanto, foi a escolha do presente trabalho para realizar a segmentação baseado em crescimento de região.

O algoritmo de segmentação baseado em crescimento de região, necessita de muito processamento para ser executado. Todos os experimentos do presente trabalho foram realizados em um computador com processador **Intel (R) Core (TM) i7-4500 U CPU @ 1.80 GHz 2.40 GHz** e com **8 GB de memória RAM**. Entretanto, para realizar a segmentação das imagens do *dataset* do presente trabalho, que possuem dimensões 1991 X 1127 *pixels*, utilizando o método de segmentação baseado em crescimento de região, demandou aproximadamente 2 horas para cada imagem. Desse modo, como a avaliação dos algoritmos de segmentação estudados no presente trabalho, foram realizadas em 1500 imagens, necessitaria de aproximadamente 180000 minutos, o que equivalem a 3000 horas e que correspondem a 125 dias para efetuar a segmentação utilizando crescimento de região, tornando inviável a avaliação do método nas condições mencionadas. Sendo assim, foi necessário redimensionar as imagens para 350 X 198 *pixels*, o que demandou cerca de 30 segundos de processamento para segmentar cada imagem. A Figura 4.7 apresenta uma amostra dos resultados obtidos pelo método de segmentação baseado em crescimento de região.

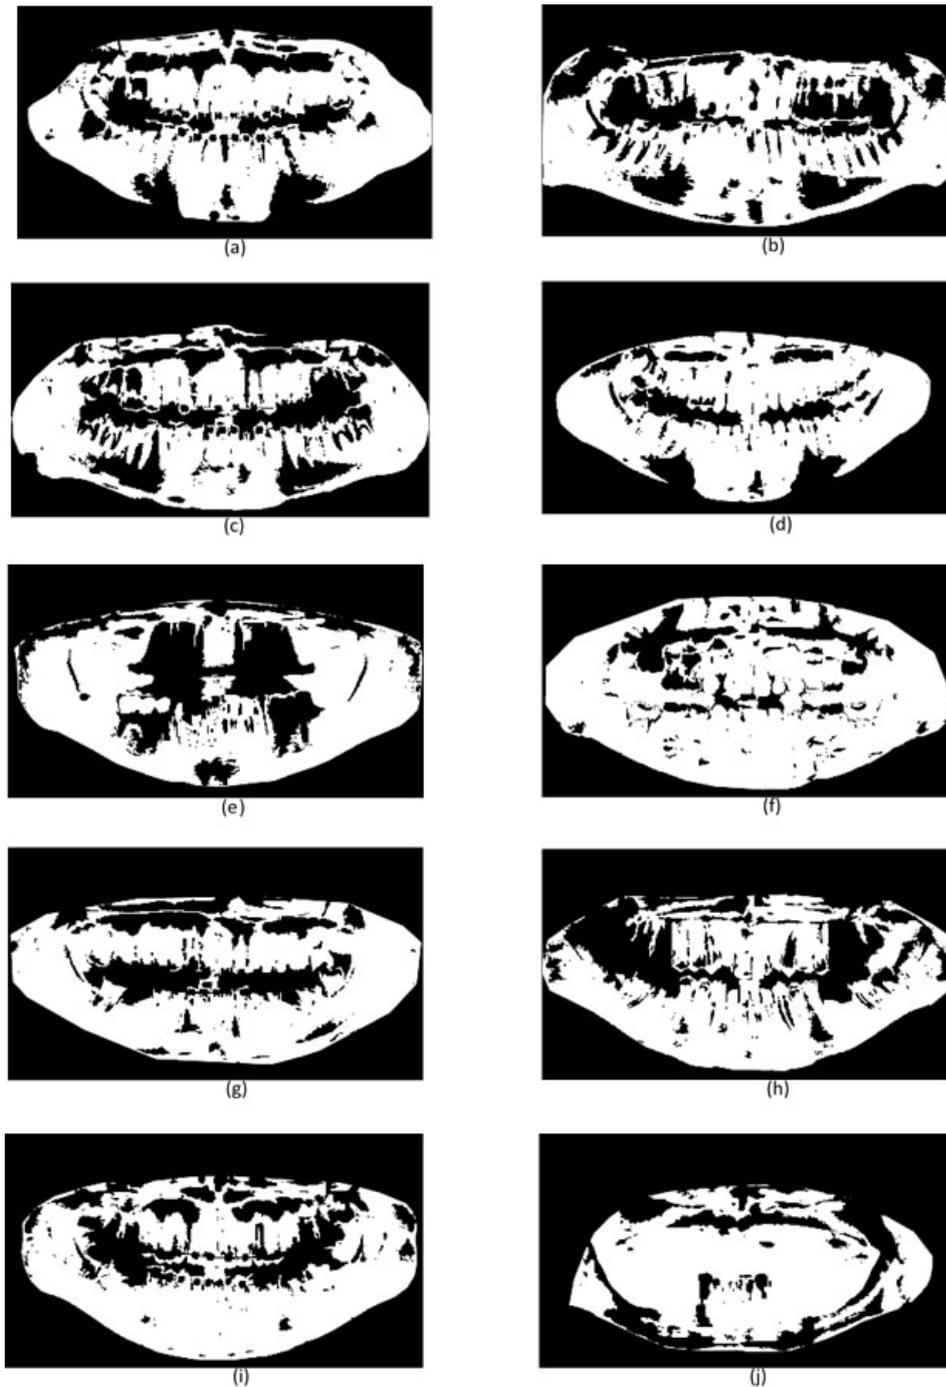


Figura 4.7: Exemplos de resultados da segmentação pelo método **Region growing**: (a) **Categoria 1**: Imagem com todos os dentes e contendo dentes com restauração e com aparelho; (b) **Categoria 2**: Imagem com todos os dentes contendo dentes com restauração e sem aparelho; (c) **Categoria 3**: Imagem com todos os dentes contendo dentes sem restauração e com aparelho; (d) **Categoria 4**: Imagem com todos os dentes contendo dentes sem restauração e sem aparelho; (e) **Categoria 5**: Imagem contendo implante; (f) **Categoria 6**: Imagem contendo mais de 32 dentes; (g) **Categoria 7**: Imagem faltando dentes contendo dentes com restauração e com aparelho; (h) **Categoria 8**: Imagem faltando dentes contendo dentes com restauração e sem aparelho; (i) **Categoria 9**: Imagem faltando dentes contendo dentes sem restauração e com aparelho; (j) **Categoria 10**: Imagem faltando dentes contendo dentes sem restauração e sem aparelho.

#### 4.4.2 Divisão e União de Regiões (*Region Splitting and Merging*)

O método discutido na seção anterior forma regiões a partir de um conjunto de pontos chamados de sementes. Uma outra alternativa, baseada em segmentação de regiões é a divisão e união de regiões que emprega uma filosofia oposta ao crescimento de regiões. Na divisão e união de regiões, o procedimento de segmentação é iniciado tratando toda a imagem como uma única região e, em seguida, a imagem é subdividida em um conjunto de regiões desconexas arbitrarias, que são sucessivamente unidas e/ou divididas em uma tentativa de satisfazer as condições estabelecidas.

De modo geral, este método consiste em duas etapas sucessivas: (i) Dividindo a imagem em um conjunto de regiões desconectadas. Em seguida, após cada divisão, (ii) é usado um processo de união que compara regiões adjacentes e as une se necessário, baseando-se em critérios de similaridade entre as regiões (por exemplo, intervalos específicos de níveis de cinza, cor, contraste, intensidade ou uma faixa de valores). O processo para realizar a divisão de regiões ocorre em quatro etapas:

1. A imagem original é considerada como área de interesse inicial;
2. A área de interesse é examinada para decidir se todos os *pixels* contidos na região satisfazem algum critério de similaridade;
3. Se VERDADEIRO, a área de interesse (também chamada de bloco) corresponde a uma região na imagem e recebe um rótulo;
4. Se FALSO, a área de interesse é dividida **em quatro subáreas iguais** e cada uma é sucessivamente considerada como área de interesse.

Esse processo continua até que nenhuma outra divisão ocorra e quando não seja possível mais nenhuma união de regiões. O nível mais granular de divisão que possa ocorrer é quando existirem áreas que contiverem somente um *pixel*. No entanto, se apenas a divisão for efetuada, a segmentação final conterà muitas regiões vizinhas com propriedades idênticas ou similares. Após cada divisão, é usado um processo de união que compara regiões adjacentes e as une se necessário, conforme é ilustrado na Figura 4.8. De acordo com [Solomon e Breckon \(2013\)](#), o processo em que cada bloco é dividido em quatro sub-blocos iguais é conhecido como decomposição *quadtree*, ou seja, uma árvore em que cada nó tem exatamente quatro descendentes. Note-se que a raiz da árvore corresponde a imagem inteira e que cada nó corresponde à subdivisão de um nó em quatro nós descendentes. Usando essa abordagem, todos as *quadregiões* (como são chamadas) que satisfazem o critério de similaridade são preenchidas com *1s*. Do mesmo modo, as *quadregiões* que não

satisfazem o critério de similaridade são preenchidos com  $\theta_s$ , criando assim uma imagem segmentada.

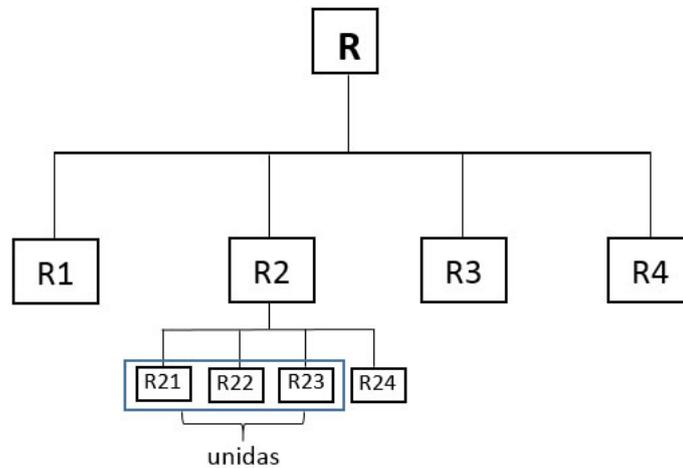


Figura 4.8: Processo básico de divisão e união.

O Algoritmo de divisão e união de regiões, por padrão recebe três parâmetros para realizar as operações de segmentação:

- **f** - A imagem a ser segmentada;
- **qtdecomp** - Tamanho mínimo do bloco para decomposição (este parâmetro deve ser um inteiro positivo e que por padrão é definido com o valor 1, a qual permite que a decomposição até regiões de tamanho de  $1 \times 1$  *pixels*). No presente trabalho foi mantido este padrão;
- **splitmerge** - Critério de similaridade que serve para indicar se a região (bloco) deve ser dividida ou não.

No presente trabalho, foi definido o critério de similaridade baseado na abordagem discutida em [Gonzales e Woods \(2008\)](#), que consiste em verificar se uma região deve ser dividida ou não, comparando se o valor do desvio padrão da intensidade dos *pixels* da região analisada é maior do que o menor valor de intensidade dos *pixels* da região analisada. Caso sim, a região é dividida; caso contrário, não. A Figura 4.9 apresenta uma amostra do processo de segmentação baseada no método de divisão e união de regiões.

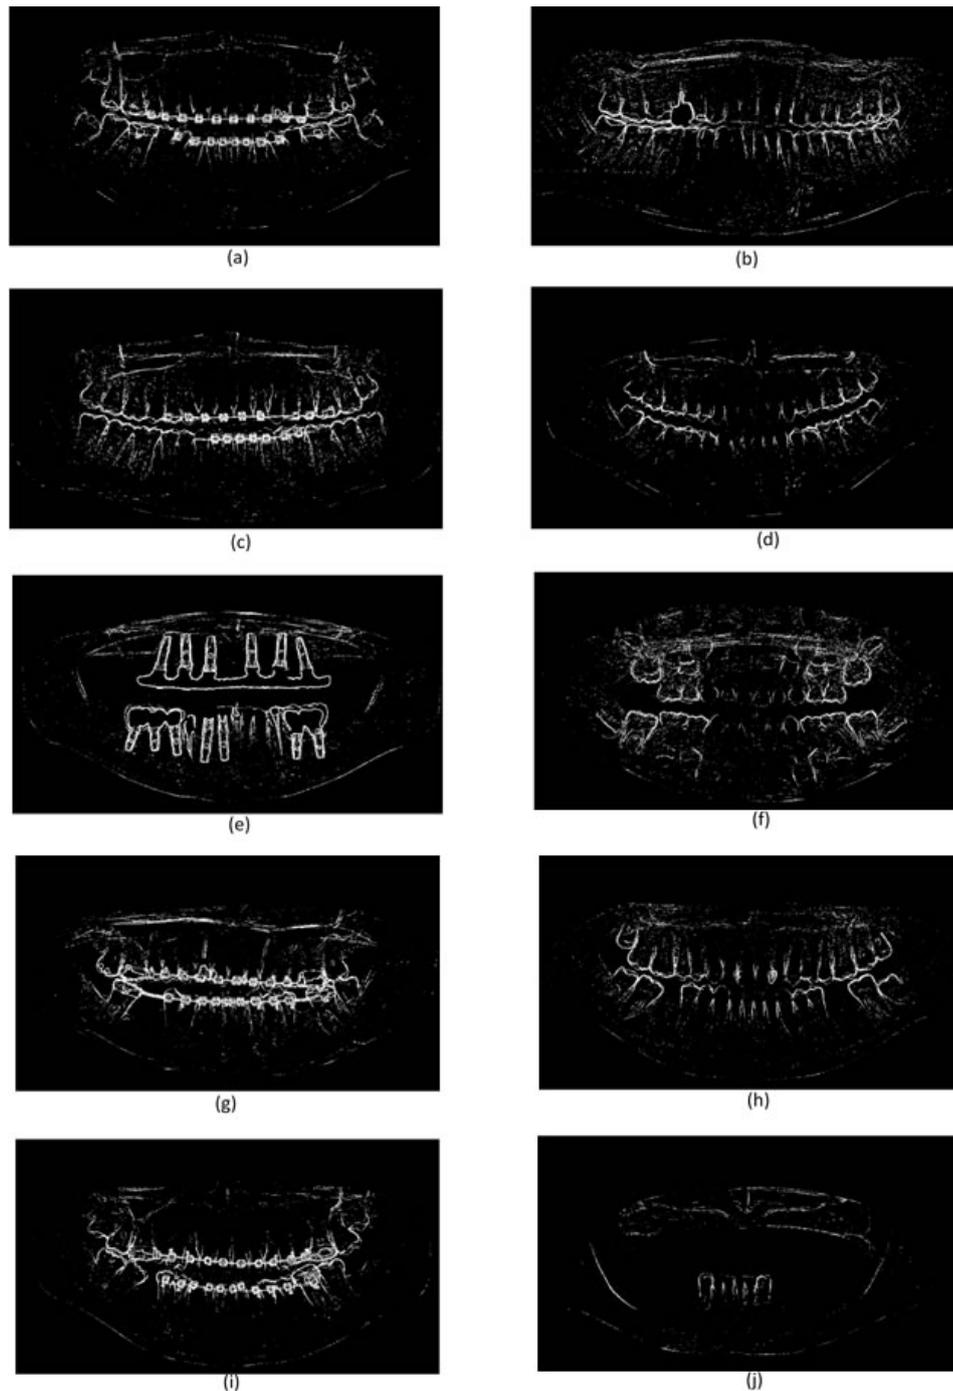


Figura 4.9: Exemplos de resultados da segmentação pelo método **Region Splitting and Merging**: (a) **Categoria 1**: Imagem com todos os dentes e contendo dentes com restauração e com aparelho; (b) **Categoria 2**: Imagem com todos os dentes contendo dentes com restauração e sem aparelho; (c) **Categoria 3**: Imagem com todos os dentes contendo dentes sem restauração e com aparelho; (d) **Categoria 4**: Imagem com todos os dentes contendo dentes sem restauração e sem aparelho; (e) **Categoria 5**: Imagem contendo implante; (f) **Categoria 6**: Imagem contendo mais de 32 dentes; (g) **Categoria 7**: Imagem faltando dentes contendo dentes com restauração e com aparelho; (h) **Categoria 8**: Imagem faltando dentes contendo dentes com restauração e sem aparelho; (i) **Categoria 9**: Imagem faltando dentes contendo dentes sem restauração e com aparelho; (j) **Categoria 10**: Imagem faltando dentes contendo dentes sem restauração e sem aparelho.

## 4.5 Segmentação baseada em entropia da informação

Segundo [Shannon \(1948\)](#), a entropia da informação é uma forma de medir a quantidade de informação de uma fonte (neste trabalho, as fontes de informações são os níveis de cinza das imagens utilizadas). De acordo com [Shannon \(1948\)](#), o conceito de entropia refere-se à incerteza de uma distribuição de probabilidade e a medida que propôs destina-se a quantificar essa incerteza. Então, dado um evento  $\mathbf{E}$ , algumas informações podem ser obtidas sobre ele:

- Se  $\mathbf{E}$  acontece com probabilidade 1, a informação é nula;
- Se  $\mathbf{E}$  acontece com probabilidade 0, a informação é máxima.

Assim, dado um evento  $E$  e a probabilidade  $p(E)$  dele acontecer, para um conjunto de elementos  $i$  associados ao evento (ou à fonte de símbolos), a entropia é calculada pela seguinte equação:

$$E = -\sum_q p(i) \log(p(i)), \text{ para todos os } q \text{ símbolos} \quad (4.5)$$

Em análise de imagens digitais, a letra  $\mathbf{E}$  é substituída pela letra  $\mathbf{H}$ , representando a Entropia de uma fonte. Neste caso, os  $i$  elementos são os tons de cinza da imagem. A entropia de uma imagem pode ser definida como um número quantificador da aleatoriedade da imagem, ou seja, quanto maior for este número, mais irregular, atípica ou despadronizada será a imagem analisada.

### 4.5.1 Método Pun (*Method Pun*)

Os métodos de segmentação baseados em entropia, exploram a entropia da distribuição dos níveis de cinza numa imagem. Sendo assim, recebem apenas a imagem e um valor de limiar como parâmetros de entrada. O limiar funciona como o ponto de corte e em seguida, calcula-se a entropia dos tons abaixo e acima desse ponto de corte, retornando como saída a imagem segmentada.

O Método proposto originalmente por [Pun \(1981\)](#) é um dos métodos de segmentação baseado em entropia mais conhecido na literatura. De modo geral, o método de [Pun \(1981\)](#) realiza a segmentação de uma imagem do seguinte modo:

Dado um ponto de corte  $t$ , deve-se calcular a entropia dos tons abaixo ( $H_b$ ) e acima de ( $H_w$ ) de  $t$ . A entropia associada com *pixels* pretos que foram submetidos a um limiar  $t$  é obtida por:

$$H_b = - \sum_0^t p[i] \log(p[i]) \quad (4.6)$$

A entropia para *pixels* brancos é calculada por:

$$H_w = - \sum_{t+1}^{255} p[i] \log(p[i]) \quad (4.7)$$

onde  $p_i$  é a probabilidade do *pixel* possuir o nível de cinza  $i$ . O algoritmo deve procurar  $t$  que maximize  $\mathbf{H}$ , através da operação  $\mathbf{H} = H_w + H_b$ .

No presente trabalho foram calculados  $n$  valores de corte variando de 0 à 255, que subdividem todo o espectro de níveis de cinza de cada imagem. Ao final, realizou-se o somatório de todos os máximos obtidos, desse modo, maximizando  $H$  por meio da equação:  $\mathbf{H} = H_w + H_b$ , conforme explicado anteriormente. A Figura 4.10 apresenta uma amostra do processo de segmentação baseado no método *Pun*.

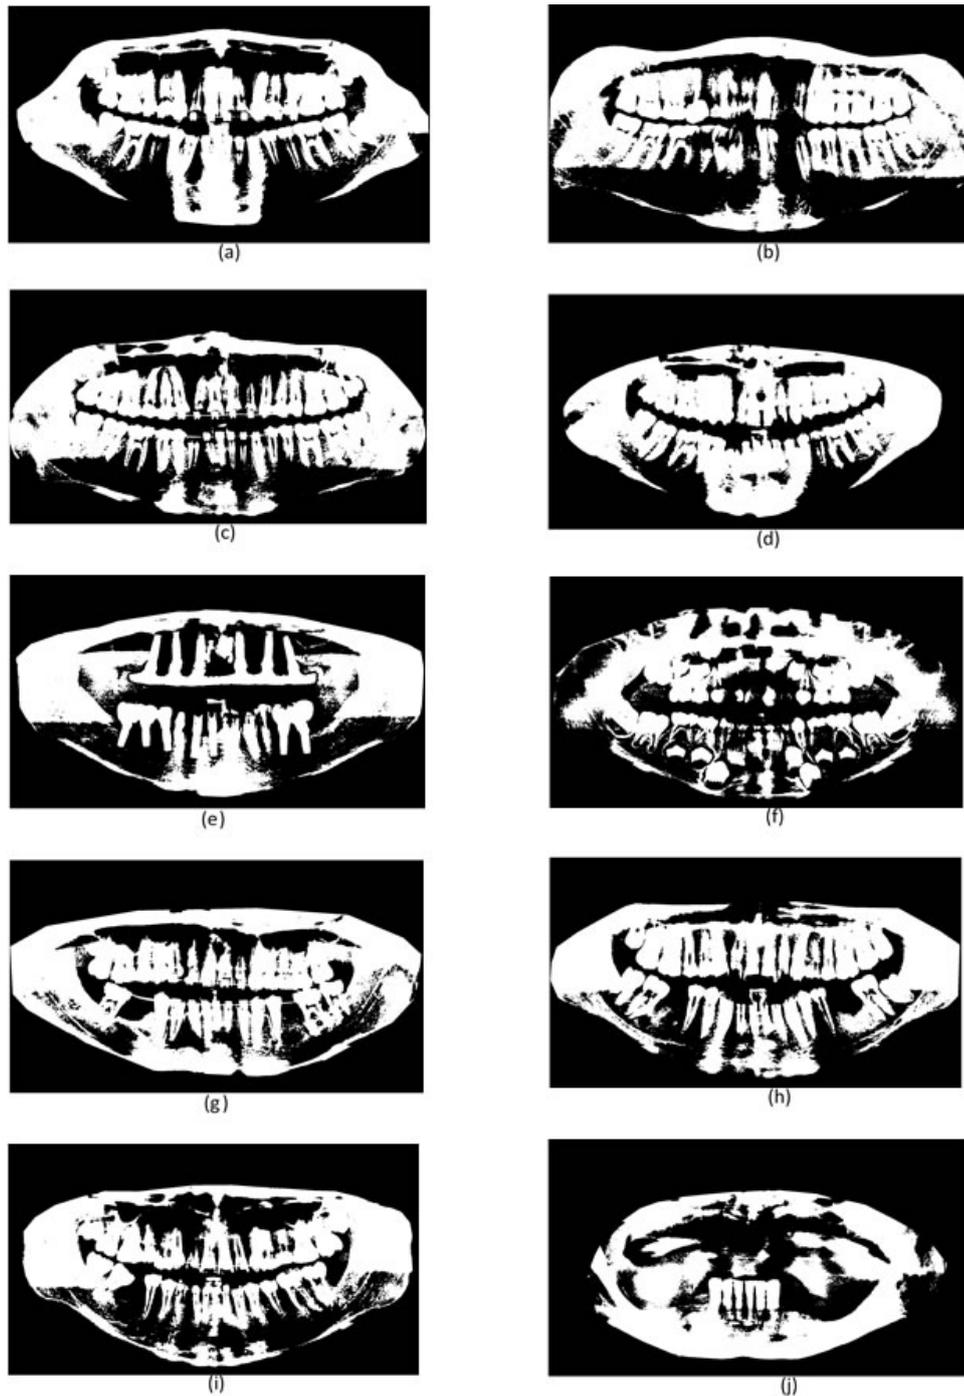


Figura 4.10: Exemplos de resultados da segmentação pelo método **Pun**: (a) **Categoria 1**: Imagem com todos os dentes e contendo dentes com restauração e com aparelho; (b) **Categoria 2**: Imagem com todos os dentes contendo dentes com restauração e sem aparelho; (c) **Categoria 3**: Imagem com todos os dentes contendo dentes sem restauração e com aparelho; (d) **Categoria 4**: Imagem com todos os dentes contendo dentes sem restauração e sem aparelho; (e) **Categoria 5**: Imagem contendo implante; (f) **Categoria 6**: Imagem contendo mais de 32 dentes; (g) **Categoria 7**: Imagem faltando dentes contendo dentes com restauração e com aparelho; (h) **Categoria 8**: Imagem faltando dentes contendo dentes com restauração e sem aparelho; (i) **Categoria 9**: Imagem faltando dentes contendo dentes sem restauração e com aparelho; (j) **Categoria 10**: Imagem faltando dentes contendo dentes sem restauração e sem aparelho.

### 4.5.2 Método Renyi (Method Renyi)

O algoritmo Renyi (SAHOO; WILKINS; YEAGER, 1997), se baseia na entropia de (TSALLIS, 1988) que, por sua vez, usa duas distribuições de probabilidade (objeto e fundo do objeto), derivadas das distribuições de cinza originais da imagem. Sendo assim, dado que  $p_0, p_1, p_2, \dots, p_{255}$  são probabilidades de níveis de cinza da imagem, duas probabilidades são derivadas delas,  $A_1$  e  $A_2$ , para objeto e fundo do objeto, respectivamente. A entropia de Renyi é definida pela seguinte equação:

$$H_t^\alpha = \frac{1}{1-\alpha} \ln \sum_{k=0}^{255} (p_k^\alpha) \quad (4.8)$$

onde:

- $H_t^\alpha$  - Corresponde a distribuições de probabilidade (objeto ou fundo do objeto), derivadas das distribuições de cinza originais da imagem;
- $k$  - Corresponde ao valor da variação dos níveis de cinza na imagem;
- $\alpha$  - Corresponde a um valor positivo real menor do que 1.

Portanto, o algoritmo Renyi inicia a segmentação da imagem, separando a entropia da distribuição dos níveis de cinza em duas classes  $A_1$  e  $A_2$ , correspondentes aos objetos e ao fundo dos objetos respectivamente, como abaixo:

$$H_{A_1}^\alpha = \frac{1}{1-\alpha} \ln \sum_{k=0}^t \left( \frac{p_i}{p(A_1)} \right)^\alpha \quad (4.9)$$

$$H_{A_2}^\alpha = \frac{1}{1-\alpha} \ln \sum_{k=t+1}^{255} \left( \frac{p_i}{p(A_2)} \right)^\alpha \quad (4.10)$$

onde:  $H_{A_1}^\alpha$  - Corresponde ao objeto de interesse na imagem;  $H_{A_2}^\alpha$  - Corresponde ao fundo da imagem. Por fim, a segmentação é realizada através da equação:

$$H = \text{Max}\{H_{A_1}^\alpha(t) + H_{A_2}^\alpha(t)\}, \text{ onde } \alpha \text{ é um valor positivo real menor do que 1.} \quad (4.11)$$

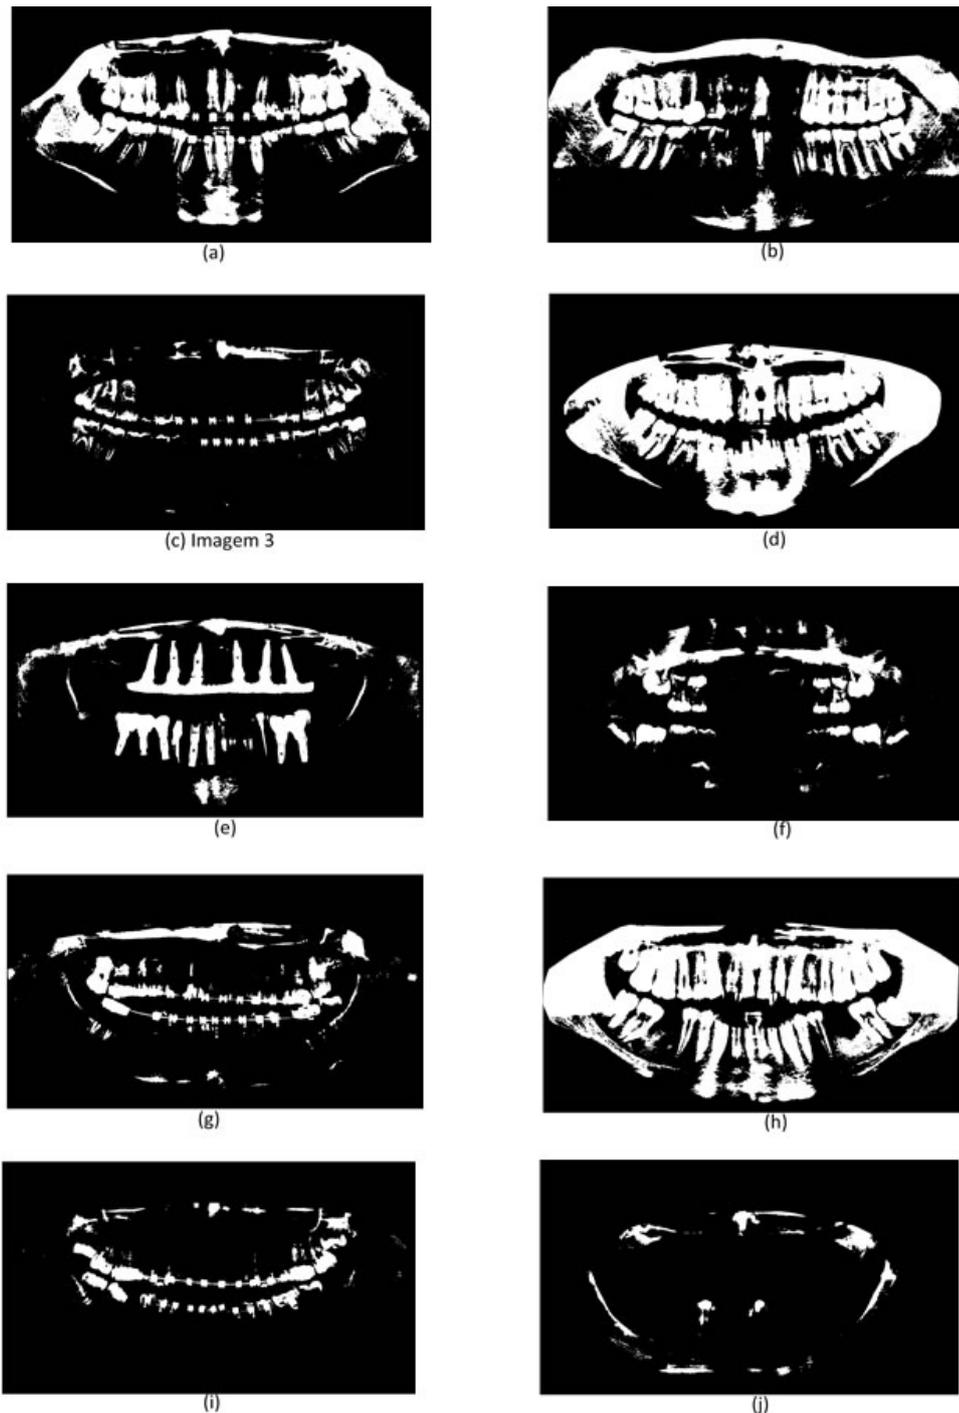


Figura 4.11: Exemplos de resultados da segmentação pelo método **Renyi**: (a) **Categoria 1**: Imagem com todos os dentes e contendo dentes com restauração e com aparelho; (b) **Categoria 2**: Imagem com todos os dentes contendo dentes com restauração e sem aparelho; (c) **Categoria 3**: Imagem com todos os dentes contendo dentes sem restauração e com aparelho; (d) **Categoria 4**: Imagem com todos os dentes contendo dentes sem restauração e sem aparelho; (e) **Categoria 5**: Imagem contendo implante; (f) **Categoria 6**: Imagem contendo mais de 32 dentes; (g) **Categoria 7**: Imagem faltando dentes contendo dentes com restauração e com aparelho; (h) **Categoria 8**: Imagem faltando dentes contendo dentes com restauração e sem aparelho; (i) **Categoria 9**: Imagem faltando dentes contendo dentes sem restauração e com aparelho; (j) **Categoria 10**: Imagem faltando dentes contendo dentes sem restauração e sem aparelho.

## 4.6 *Considerações finais*

O presente capítulo, introduziu algumas das definições do processo de segmentação de imagens. Em seguida, foram apresentados os métodos de segmentação estudados no trabalho aqui proposto, descrevendo os passos necessários para implementação e utilização dos algoritmos de segmentação correspondente a cada um dos métodos.

No próximo capítulo, serão detalhados os passos utilizados para realização de cada etapa da metodologia adotada do presente trabalho, iniciando com informações sobre o processo de obtenção das imagens para realização do presente estudo. Em seguida, a análise estatística do *dataset* utilizado é apresentada, onde se obteve os valores que serviram como parâmetros para execução dos métodos de segmentação analisados. Encerrando com a avaliação dos métodos de segmentação estudados com a aplicação das métricas já mencionadas no Capítulo 2: *Accuracy*, *Specificity*, *Precision*, *Recall (Sensitivity)* e *F-score*, apresentando os valores encontrados em tabelas e analisando os resultados obtidos por cada método de segmentação.

## Análise comparativa de Métodos de segmentação

Paciência e perseverança  
tem o efeito mágico de fazer  
as dificuldades desaparecerem e  
os obstáculos sumirem.  
(John Quincy Adams)

No presente capítulo, são descritas as etapas que foram realizadas no trabalho aqui proposto. Neste sentido, a metodologia desenvolvida para realização do presente estudo é apresentada e que consiste, de modo geral, em seis etapas, iniciando com a aquisição das imagens por meio do ortopantomógrafo (aparelho usado para geração das imagens de ortopantomografia). Na segunda etapa, as imagens coletadas foram classificadas em 10 categorias de acordo com a variedade das características estruturais dos dentes. A terceira etapa, consiste em realizar a anotação das imagens (obtendo as imagens binárias), que correspondem a demarcações dos objetos de interesse em cada imagem analisada. Após a finalização do processo de anotação dos dentes é realizada a anotação da região bucal, onde as anotações correspondentes a região bucal são utilizadas para determinação da Região dos Objetos de Interesse (ROI) nas imagens analisadas. A sexta e última etapa consiste na análise de desempenho dos algoritmos de segmentação estudados, descrevendo as métricas utilizadas para medir o desempenho de cada algoritmo e dispendo os valores em tabelas para confrontar os resultados alcançados por cada método de segmentação avaliado. A Figura 5.1 apresenta a metodologia utilizada no presente estudo.

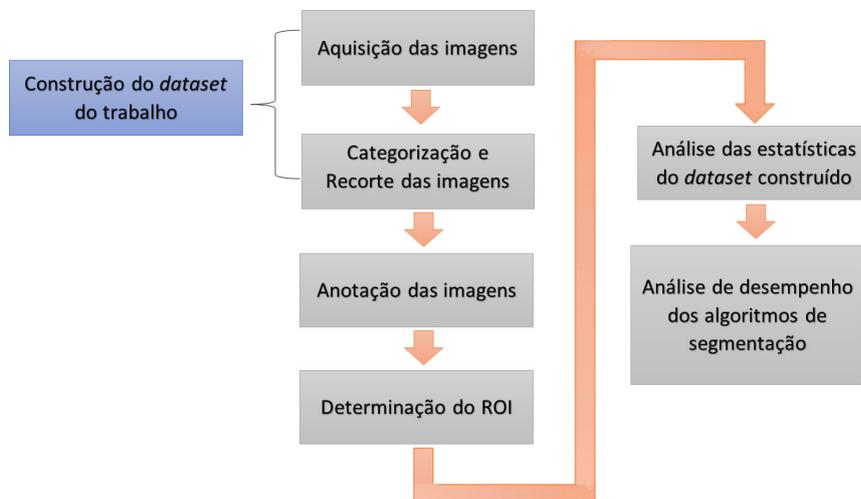


Figura 5.1: Visão geral das etapas do trabalho.

## 5.1 Aquisição das imagens do *Dataset*

Nesta seção, é apresentado como o *dataset* do presente trabalho foi construído, primeiro informando detalhes sobre a câmera de raios-X odontológico que capturou as imagens, mostrando algumas notas relativas as suas principais propriedades (morfológicas e estruturais). Em seguida, são especificadas informações sobre como as imagens foram classificadas, baseado nas características dos objetos de interesse (dentes) e, por fim, descrevendo o recorte realizado para delimitar a área de trabalho nas imagens do presente estudo.

### 5.1.1 Câmera de raio-X

Todas as imagens do *dataset* do trabalho aqui proposto foram obtidas através do ortopantomógrafo **ORTHOPHOS XG 5 / XG 5 DS / Ceph** ilustrado na Figura 5.2, fabricado e mantida pela empresa *Sirona Dental Systems GmbH* que possui as propriedades descritas na tabela 5.2. As radiografias foram adquiridas no Centro de Diagnostico por Imagem da Universidade Estadual do Sudoeste da Bahia - UESB, sob à coordenação do odontólogo pesquisador, Dr. Matheus Pithon. Os procedimentos para aquisição das radiografias seguiram a portaria 453 da Vigilância Sanitária que rege a regulamentação das diretrizes básicas em radiodiagnóstico médico e odontológico no Brasil. As imagens radiográficas utilizadas para esta pesquisa foram codificadas visando a não identificação do paciente no referido estudo. O uso das radiografias na pesquisa foi autorizada pela Comissão Nacional de Ética em Pesquisa (CONEP) e pelo Comitê de Ética em Pesquisa (CEP), através do parecer de número 646.050 aprovado em 13/05/2014, conforme documento disponível no Anexo A desta dissertação.



Figura 5.2: ORTHOPHOS XG 5 / XG 5 DS / Ceph.

O *dataset* do presente trabalho é composto por 1500 imagens de raio-X panorâmico que foram obtidas pela UESB sob a coordenação do Dr. Matheus Pithon no ano de 2012. As imagens possuem significativas variações estruturais em relação aos dentes, no que se refere ao número de dentes, existência de restaurações, existência de implantes, existência de aparelhos, ou a existência de dentes supranumerários. Além de variarem em relação ao tamanho da boca e das maxilas e mandíbulas. Todas as imagens originalmente obtidas pelo ortopantomógrafo ORTHOPHOS XG 5 / XG 5 DS / Ceph possuem dimensões 2440 X 1292 *pixels*, conforme descrito no Capítulo 4, são imagens em escala de cinza com níveis de intensidade dos *pixels* variando de 0 até 255 em um único canal de cor.

Tabela 5.1: Propriedades da ORTHOPHOS XG 5

Propriedade	Descrição
Modelo	ORTHOPHOS XG 5 / XG 5 DS / Ceph
Frequência nominal	50 Hz / 60 Hz
Potência de saída do tubo	1080 W com qualquer duração de radiação
Voltagem do tubo	60 – 90 kV (at 90 kV max. 12 mA)
Escala das imagens	Para P1, arcada dentária normal aprox. 1:1,19, ou seja, a imagem adquirida é ampliada por aprox. 19%, em média, em comparação com a realidade.
Tubo de raio-X	Siemens SR 90/15 FN or CEI OCX 100
Sensor panorâmico	<i>Digital CCD line sensor, repluggable for panoramic exposure technique</i>
Área de sensor ativo, tipo panorâmico	138 mm x 6.48 mm
Resolução do sensor panorâmico	0.027 mm de tamanho dos <i>pixels</i>
Distância do foco-sensor panorâmico	497 mm
Tamanho das imagens	2440 X 1292 <i>pixels</i>

Quando comparado com outros tipos de imagens radiográficas, por exemplo, intraorais, o trabalho com imagens de raio-X panorâmico é mais desafiador, devido a razões que aumentam a sua heterogeneidade, dentre as quais destacam-se:

- Diferentes níveis de ruído, devido ao dispositivo de aquisição das imagens, que capta uma perspectiva global da boca do paciente.
- Baixo contraste, global ou sobre as regiões locais das imagens, tornando as propriedades morfológicas complexas.
- Ruído originado pela coluna vertebral, que cobre os dentes frontais em alguns casos.

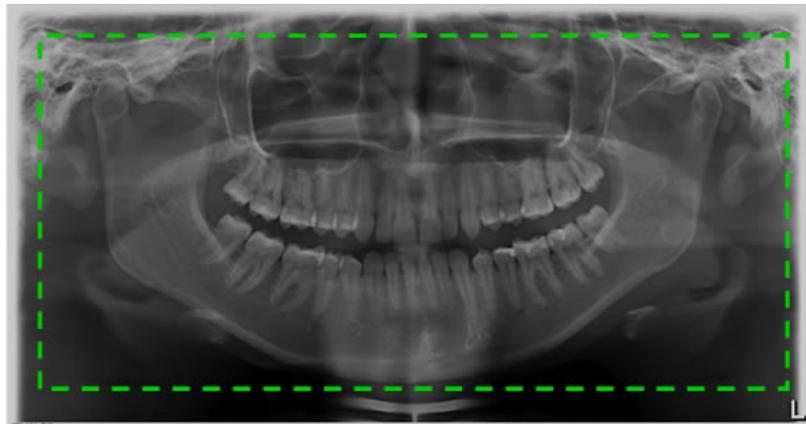
## 5.2 Categorização e recorte das imagens do *dataset*

No presente trabalho, formou-se um *dataset* com 1500 imagens, que foram distribuídas entre 10 categorias, e **que foram nomeadas utilizando números inteiros, em ordem sequencial por categoria**. Conforme discutido no Capítulo 4, as imagens foram classificadas de acordo com a variedade das características estruturais dos dentes, do seguinte modo:

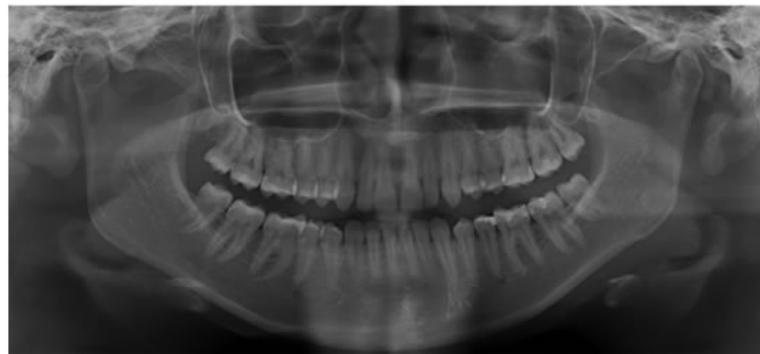
- **Categoria 1:** Imagens **com todos** os dentes e contendo dentes **com restauração e com aparelho**.
- **Categoria 2:** Imagens **com todos** os dentes contendo dentes **com restauração e sem aparelho**.
- **Categoria 3:** Imagens **com todos** os dentes contendo dentes **sem restauração e com aparelho**.
- **Categoria 4:** Imagens **com todos** os dentes contendo dentes **sem restauração e sem aparelho**.
- **Categoria 5:** Imagens contendo implante.
- **Categoria 6:** Imagens contendo mais de 32 dentes.
- **Categoria 7:** Imagens **faltando** dentes contendo dentes **com restauração e com aparelho**.
- **Categoria 8:** Imagens **faltando** dentes contendo dentes **com restauração e sem aparelho**.
- **Categoria 9:** Imagens **faltando** dentes contendo dentes **sem restauração e com aparelho**.
- **Categoria 10:** Imagens **faltando** dentes contendo dentes **sem restauração e sem aparelho**.

O processo de categorização das imagens do *dataset* do presente trabalho foi realizado de forma manual, selecionado imagem a imagem individualmente, contando dente a dente e verificando as suas características estruturais, descritas ao longo desta seção. Por fim, as imagens foram recortadas para desprezar informações não relevantes (borda branca ao redor das imagens e parte da coluna vertebral) geradas pelo ortopantomógrafo usado. Com o processo de recorte, ocorreu alteração no dimensionamento das imagens para 1991 X 1127 *pixels*, porém sem afetamento dos objetos de interesse (dentes) conforme mostra a Figura 5.3 que representa o processo de recorte realizado utilizando uma imagem de

raio-X panorâmico do *dataset* do presente trabalho. As imagens recortadas foram salvas com a nova dimensão para serem utilizadas nas etapas seguintes e que serão apresentadas nas próximas seções deste capítulo.



**Imagem original com dimensão 2440 X 1292 pixels**



**Imagem recortada e redimensionada para dimensão 1991 X 1127 pixels**

Figura 5.3: Exemplo do recorte e redimensionamento das imagens do *dataset* deste trabalho

### 5.3 Anotação das imagens do *dataset*

As anotações correspondem a demarcações dos objetos de interesse na imagem, obtidas de forma manual, onde o objetivo é viabilizar uma posterior comparação entre o desempenho do algoritmo na segmentação destes objetos e a segmentação feita manualmente por meio da anotação. A realização da anotação de imagens, também é conhecido como processo de definição do *ground truth*, pois corresponde ao resultado ideal que se deseja obter de forma automática pelos algoritmos de segmentação, ou seja, a imagem anotada é comparada com os resultados dos algoritmos de segmentação, desse modo, avaliando o desempenho de cada um deles. No presente trabalho, foram realizadas anotações dos dentes de 1500 imagens do *dataset* do trabalho aqui proposto, distribuídas entre as categorias listadas anteriormente neste capítulo.

O processo de anotação das imagens do *dataset* do presente trabalho, ocorreu em duas partes anotando em cada imagem dente a dente individualmente. Primeiro, iniciou-se pelo maxilar superior através da anotação do 3º molar superior direito e fazendo a anotação de todos os dentes da arcada superior até o 3º molar superior esquerdo. Em seguida, o mesmo processo foi realizado no maxilar inferior com todos os dentes e no mesmo sentido que foi feito com o maxilar superior, da esquerda para a direita, iniciando com a anotação do 3º molar inferior direito e fazendo a anotação de todos os dentes da arcada inferior até o 3º molar inferior esquerdo. A Figura 5.4 ilustra o processo de anotação dos dentes através de uma imagem de raio-X panorâmico do *dataset* do presente trabalho.

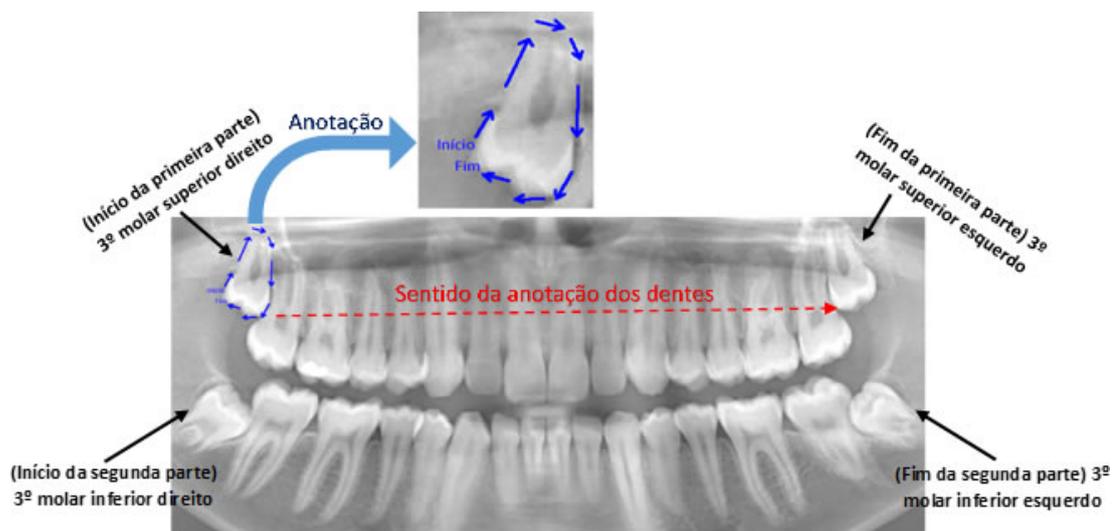


Figura 5.4: Processo de anotação dos dentes

Após finalizar o processo de anotação de todos os dentes de uma imagem, obteve-se a imagem binarizada, isto é, a imagem formada pela matriz binária que representa o padrão a ser utilizado para comparar com os resultados dos algoritmos de segmentação estudados

no presente trabalho. A Figura 5.5 mostra o resultado obtido após anotação de uma imagem do *dataset* do trabalho aqui proposto. O processo foi realizado em 1500 imagens do *dataset* deste trabalho. As imagens anotadas foram armazenadas e **nomeadas utilizando números inteiros em ordem sequencial, equivalente a numeração de cada imagem original correspondente**. As imagens anotadas foram utilizadas na etapa de avaliação de desempenho dos algoritmos de segmentação que será apresentada mais adiante, ainda neste capítulo.

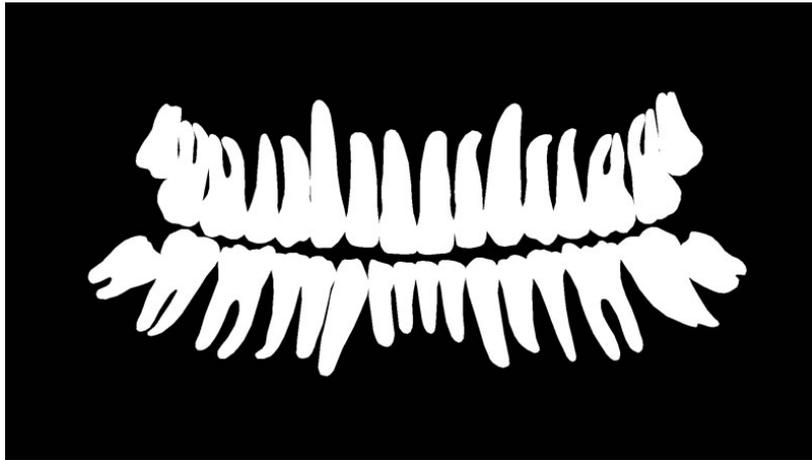


Figura 5.5: Resultado da anotação de uma imagem do *dataset* deste trabalho

### 5.3.1 Dificuldades encontradas durante o processo de anotação

Ocorreram dificuldades durante o processo de anotação das imagens do *dataset* do trabalho aqui proposto. A primeira dificuldade encontrada, foi a identificação do *ápice* dos dentes em algumas imagens de raio-X, dificultando o contorno do dente durante a anotação, onde nesses casos, foi necessário "supor" um possível final da raiz para realizar a anotação da melhor maneira possível, como mostra a Figura 5.6.



Figura 5.6: Dificuldade de visualização do ápice

A segunda dificuldade identificada, foi relacionada a existência de dentes sobrepostos e que ocorreram em quantidade significativa na maioria das imagens do *dataset* do presente trabalho. Desse modo, quando ocorrem dentes sobrepostos, ao anotar o primeiro dente, torna-se difícil fazer a anotação do segundo. Sendo assim, ao realizar a anotação de dentes sobrepostos, na imagem binarizada, resultante da anotação, ocorreu um tipo de fusão, ou seja, junção em parte dos dentes sobrepostos, conforme mostra a Figura 5.7.

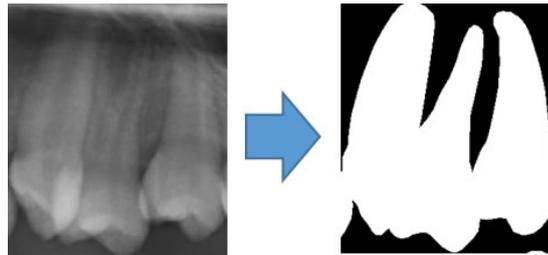


Figura 5.7: Anotação de dentes sobrepostos

A terceira dificuldade encontrada durante o processo de anotação das imagens, ocorreu devido a existência de imagens de raio-X contendo dentes incompletos (dentes quebrados ou com estrutura comprometida devido a anomalias dentárias). Nestes casos, considerou-se apenas a estrutura do dente que estava visível para realização do processo de anotação, conforme ilustra a Figura 5.8.

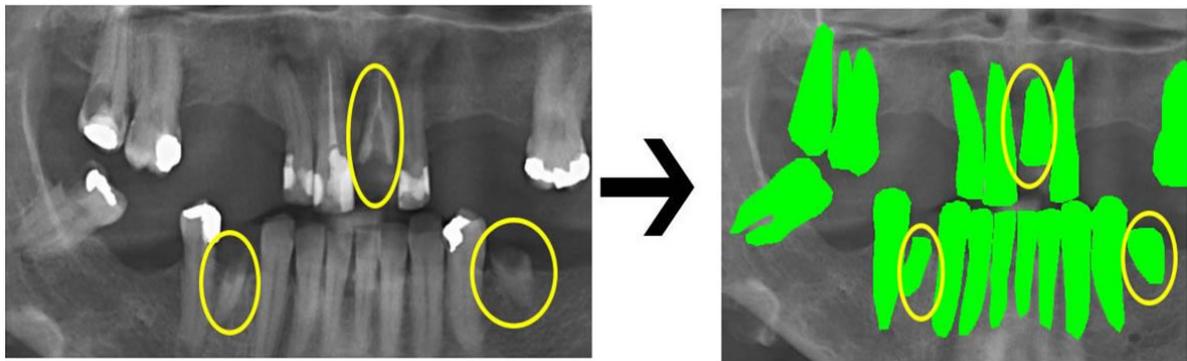


Figura 5.8: Dificuldade em anotar dentes com partes incompletas

A quarta dificuldade do processo de anotação, foi relacionada a anotação de imagens de raio-X que apresentam implante dentário. Os implantes possuem formato diferente dos dentes, desse modo, foi necessário alterar o padrão estabelecido no presente trabalho para realização das anotações dente a dente para as imagens contendo implante dentário. Nesses casos, a anotação foi realizada seguindo o formato do implante, conforme mostra a Figura 5.9.

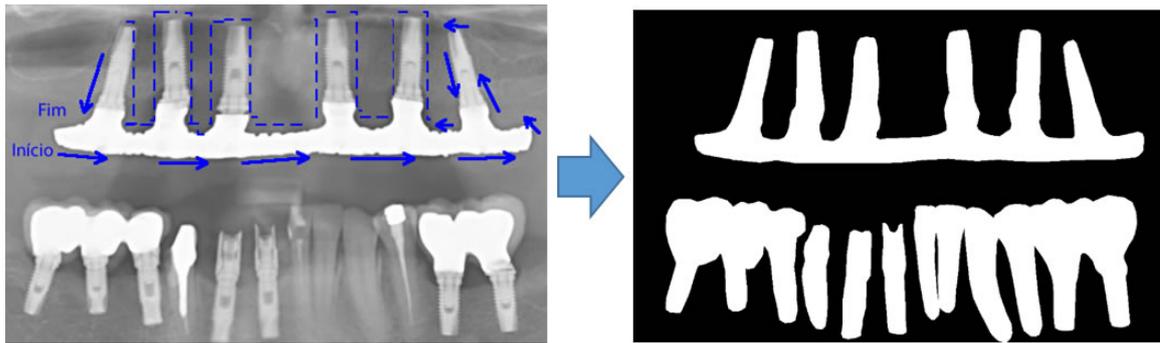


Figura 5.9: Dificuldade em anotar imagens com implante dentário

#### 5.4 Determinação do ROI

Para cada imagem anotada do *dataset* do presente trabalho, após a finalização do processo de anotação dos dentes, realizou-se também a anotação da região bucal, iniciando o processo de anotação pelo lado direito da boca e contemplando toda a região delimitada pelo contorno dos maxilares, desse modo, correspondendo a área que contém todos os dentes (objetos de interesse) conforme Figura 5.10.

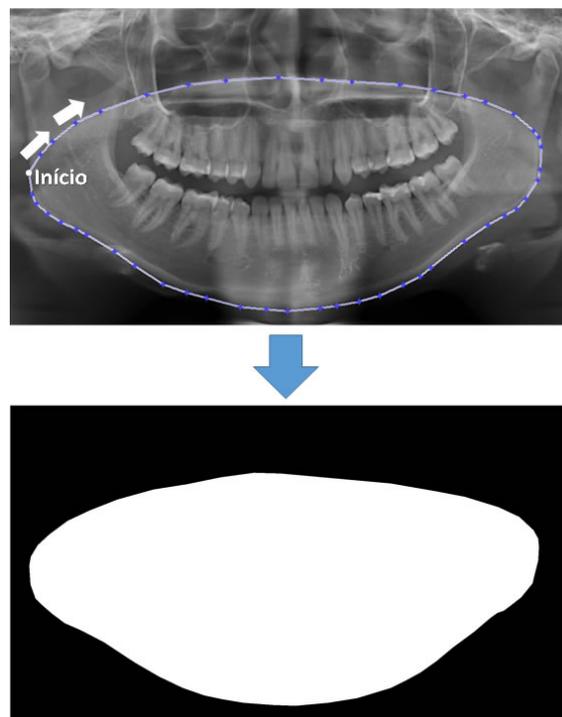


Figura 5.10: Processo de anotação da região bucal das imagens do *dataset* deste trabalho

As imagens binárias obtidas pelo processo de anotação da região bucal, foram armazenadas no *dataset* do presente trabalho e **nomeadas utilizando numeração sequencial equivalente a cada imagem original correspondente**. Em seguida, as imagens anotadas da região bucal foram utilizadas para determinação da Região dos Objetos de

Interesse (ROI). Sendo assim, para delimitar o ROI nas imagens de raio-X panorâmico do *dataset* deste trabalho, realizou-se a multiplicação, entre os elementos da matriz da imagem de raio-X panorâmico e a sua matriz binária correspondente, resultante do processo de anotação bucal, conforme é mostrado na Figura 5.11.

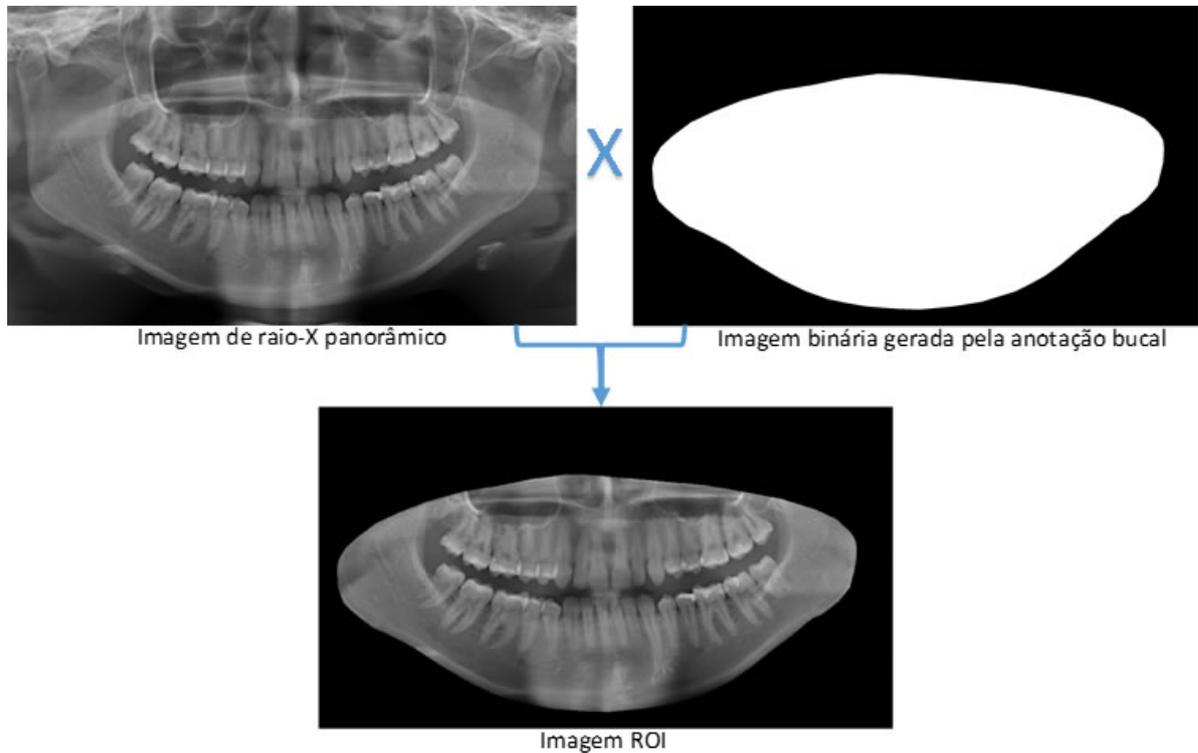


Figura 5.11: Processo de delimitação do ROI das imagens do *dataset* deste trabalho.

A imagem ROI obtida com o processo mostrado na Figura 5.11, delimita a área que representa a região da imagem de raio-X panorâmico que contém os dentes (objetos de interesse do presente trabalho), desse modo, desprezando outras regiões da imagem que não são relevantes para análise dos algoritmos de segmentação estudados.

## 5.5 Análise das estatísticas do *dataset* construído

As análises das estatísticas do *dataset* do presente trabalho foram iniciadas por meio da contagem das imagens classificadas por categoria do *dataset*, onde obteve-se o total de 1500 imagens que foram classificadas em 10 categorias. Em seguida, efetuou-se a contagem do total de imagens por categoria, das quais foram realizado o processo de anotação dos dentes. Por fim, calculou-se a média do total de dentes por imagens de cada categoria. A tabela 5.2 apresenta os resultados da análise realizada.

Tabela 5.2: Contagem de imagens classificadas e anotadas do *dataset* e média de dentes das imagens por categoria

Número	Categoria	Anotadas	Média de dentes por imagem
1	Imagens <b>com todos</b> os dentes e contendo dentes <b>com</b> restauração e <b>com</b> aparelho	73	32
2	Imagens <b>com todos</b> os dentes e contendo dentes <b>com</b> restauração e <b>sem</b> aparelho	220	32
3	Imagens <b>com todos</b> os dentes e contendo dentes <b>sem</b> restauração e <b>com</b> aparelho	45	32
4	Imagens <b>com todos</b> dentes contendo dentes <b>sem</b> restauração e <b>sem</b> aparelho	140	32
5	Imagens contendo im- plante	120	18
6	Imagens contendo mais de 32 dentes	170	37
7	Imagens <b>faltando</b> dentes e contendo dentes <b>com</b> restauração e <b>com</b> aparelho	115	27
8	Imagens <b>faltando</b> dentes e contendo dentes <b>com</b> restauração e <b>sem</b> aparelho	457	29
9	Imagens <b>faltando</b> dentes e contendo dentes <b>sem</b> restauração e <b>com</b> aparelho	45	28
10	Imagens <b>faltando</b> dentes e contendo dentes <b>sem</b> restauração e <b>sem</b> aparelho	115	28
	<b>Total Geral</b>	<b>1500</b>	

### 5.5.1 Estatísticas dos *pixels* do ROI das imagens

As operações estatísticas foram realizadas com 1500 imagens do *dataset* do presente trabalho, que também foram utilizadas no processo de anotação dos dentes e anotações da região bucal, conforme explicado anteriormente. Para todas as operações estatísticas, considerou-se apenas os *pixels* da região do ROI (descrito na seção 5.4) das imagens. Os resultados das operações estatísticas, além de exibirem informações sobre os *pixels* das imagens do *dataset* deste trabalho, também serviram de base para passagem de parâmetro para execução dos algoritmos de segmentação estudados. As operações estatísticas realizadas no trabalho aqui proposto foram as seguintes:

- **Maior Valor ou Valor Máximo:** Maior valor de intensidade dos *pixels* do ROI das imagens.
- **Menor Valor ou Valor Mínimo:** Menor Valor de intensidade dos *pixels* do ROI das imagens.
- **Média:** Cálculo da média dos valores de intensidade dos *pixels* do ROI das imagens.
- **Entropia:** Cálculo da entropia dos valores de intensidade dos *pixels* do ROI das imagens.
- **Desvio padrão:** Cálculo do desvio padrão dos valores de intensidade dos *pixels* do ROI das imagens.

As operações listadas anteriormente foram calculadas **para cada imagem individualmente de cada categoria do *dataset* do presente trabalho**, os valores obtidos serviram de base para execução dos algoritmos de segmentação analisados no trabalho aqui proposto e que serão apresentados mais adiante, ainda neste capítulo. Após serem obtidos os valores correspondentes as operações estatísticas por imagem, calculou-se a média dos valores obtidos das operações: Maior Valor, Menor Valor, Média e Entropia de cada categoria. Por fim, a última operação estatística calculada foi o desvio padrão da intensidade dos *pixels* do ROI de cada imagem do *dataset*. A Tabela 5.3 ilustra um exemplo do processo realizado para obtenção dos resultados das operações estatísticas das imagens do *dataset*, obtendo-se os valores das estatísticas dos *pixels* **por imagem** e em seguida, calculando-se a média dos valores obtidos das operações: Maior Valor, Menor Valor, Média e Entropia.

Tabela 5.3: Exemplo dos valores obtidos das operações estatísticas

Imagem	V. Máximo	V. Mínimo	Média	Entropia	Desvio Padrão
<b>1</b>	255	16	109,83	6,98	32,18
<b>2</b>	255	5	107,73	6,77	29,70
.....					
<b>71</b>	255	1	107,05	7,08	36,94
<b>72</b>	255	7	111,68	7,98	32,67
<b>73</b>	255	19	108,04	6,90	32,81
.....					
<b>Média Geral</b>	<b>255,00</b>	<b>8,17</b>	<b>108,40</b>	<b>6,96</b>	

Utilizando o padrão mostrado na Tabela 5.3, obtiveram-se as **médias** das operações estatísticas: Maior Valor, Menor Valor, Média (Média das médias) e Entropia das imagens de todas as categorias do *dataset* do presente trabalho. Em seguida, organizaram-se as médias das operações em uma única tabela para melhor analisar os resultados encontrados entre as categorias, conforme é apresentado na Tabela 5.4.

Tabela 5.4: Resultados das Médias das Operações Estatísticas por Categoria

Médias Gerais das Categorias				
Categoria	V. Máximo	V. Mínimo	Média	Entropia
Cat.1	253	10	108,30	6,93
Cat.2	250	16	108,29	6,83
Cat.3	248	13	107,25	6,88
Cat.4	215	20	107,31	6,82
Cat.5	254	5	109,36	6,94
Cat.6	230	18	100,43	6,86
Cat.7	255	7	108,50	6,88
Cat.8	253	11	106,72	6,89
Cat.9	251	9	107,33	6,89
Cat.10	214	20	105,94	6,70

A partir da análise da Tabela 5.4 é possível confrontar os resultados dos valores obtidos entre as categorias. Verificou-se que a categoria 5, é formada por imagens que apresentam *pixels* do ROI com intensidade mais altas quando comparada as outras categorias, pois constituem as imagens com implantes dentários, que correspondem a regiões de grande luminosidade nas imagens, resultando em *pixels* com intensidade maiores que os existentes nas imagens das outras categorias. Neste sentido, as imagens da categoria 5 são também as que apresentaram maior valor da média de intensidade dos *pixels*. De acordo com [Gonzales e Woods \(2008\)](#), a média corresponde a um descritor de luminosidade das imagens digitais. Sendo assim, os valores das médias apresentados na Tabela 5.4, indicam que as imagens da categoria 5 são as que apresentam regiões de maior luminosidade, já que

possuem maior valor da média quando comparado com as imagens das outras categorias.

Finalizando as análises estatísticas do trabalho aqui proposto, foram obtidas as frequências de ocorrências dos valores de intensidade dos *pixels* do ROI das imagens de cada categoria do *dataset* do presente trabalho. As frequências foram armazenadas em uma matriz e agrupadas em 256 colunas, correspondentes à faixa de valores dos níveis de cinza possíveis das imagens, ou seja, 0 à 255, conforme descrito no início do presente capítulo. Desse modo, as linhas da matriz representam as imagens do *dataset* do presente trabalho e as colunas a quantidade de vezes que o valor de intensidade de *pixel* ocorreu. Após obter a matriz com a frequência de ocorrência de todos os *pixels* do ROI das imagens de cada categoria do *dataset* do presente trabalho, foi gerado o mapa de calor correspondente a matriz de ocorrência dos *pixels*. A Figura 5.12 apresenta o mapa de calor referente a matriz da frequência de ocorrência de todos os *pixels* do ROI das imagens do *dataset* do trabalho aqui proposto. Por meio do mapa de calor ilustrado na Figura 5.12 é possível notar que, a maior ocorrência de intensidade dos *pixels* em todas as imagens foi entre a faixa de valores de 49 até 149.

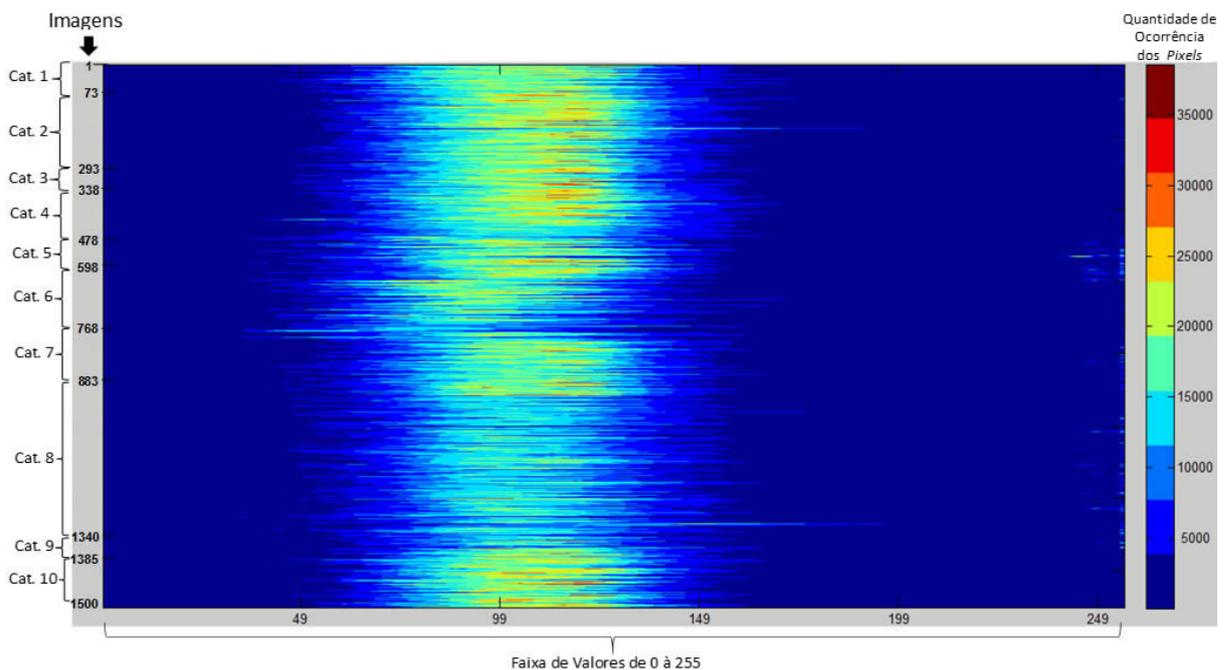


Figura 5.12: Mapa de calor das imagens do *dataset*, representando as respectivas frequências de ocorrências dos níveis de intensidade dos *pixels*

## 5.6 Análise de desempenho dos algoritmos de segmentação

Nesta seção, será apresentada a análise de desempenho dos algoritmos de segmentação estudados no presente trabalho, descrevendo as métricas utilizadas para medir o desempenho de cada algoritmo e dispondo os valores obtidos em tabelas, confrontando os resultados e, assim, constatando, dentre as técnicas de segmentação de imagens estudadas, qual foi a mais eficaz quando aplicada a imagens de raio-X panorâmico dos dentes.

### 5.6.1 Métricas para análise de desempenho dos algoritmos

As métricas utilizadas no presente trabalho já foram apresentadas no Capítulo 2. Neste Capítulo, serão descritos os procedimentos utilizados para realização do cálculo de cada uma das métricas para análise de desempenho dos algoritmos de segmentação.

#### 5.6.1.1 Medidas da teoria da detecção de sinais

Todas as métricas descritas nas próximas seções são baseadas na utilização das medidas da teoria de detecção de sinais (BUSHBERG et al., 2002), que consistem na avaliação dos resultados entre a imagem (ou conjunto de imagens) segmentada automaticamente e a sua segmentação manual (anotação). As medidas são as seguintes:

- **Positivo (P)**: Representa o objeto (*pixel*) ou conjunto de objetos (*pixels*) que pertence a classe de interesse;
- **Negativo (N)**: Representa o objeto (*pixel*) ou conjunto de objetos (*pixels*) que não pertence a classe de interesse;
- **Verdadeiro Positivo (VP)**: O elemento de entrada é positivo e o algoritmo de segmentação classifica como positivo;
- **Verdadeiro Negativo (VN)**: O elemento de entrada é negativo e o algoritmo de segmentação classifica como negativo;
- **Falso Positivo (FP)** : O elemento de entrada é negativo e o algoritmo de segmentação classifica como positivo;
- **Falso Negativo (FN)**: O elemento de entrada é positivo e o algoritmo de segmentação classifica como negativo.

Em que, P corresponde ao *pixel* representado com o valor 1 (um) e N corresponde ao *pixel* representado com valor 0 (zero) nas imagens binárias avaliadas. As medidas listadas nos itens anteriores, são expostas na tabela conhecida como matriz de confusão, onde a partir dessa matriz, são especificadas as métricas que serão apresentadas nas próximas seções. De acordo com [Visa et al. \(2011\)](#), matriz de confusão é uma tabela com duas linhas e duas colunas que indica o número de **verdadeiros positivos**, **verdadeiros negativos**, **falsos positivos** (*Falso Alarme*) e **falsos negativos**, e que contém informações sobre como é a classificação predita de um *pixel* (através de uma imagem segmentada manualmente) e como o *pixel* realmente foi classificado por um algoritmo de segmentação, conforme mostra a Figura 5.13.

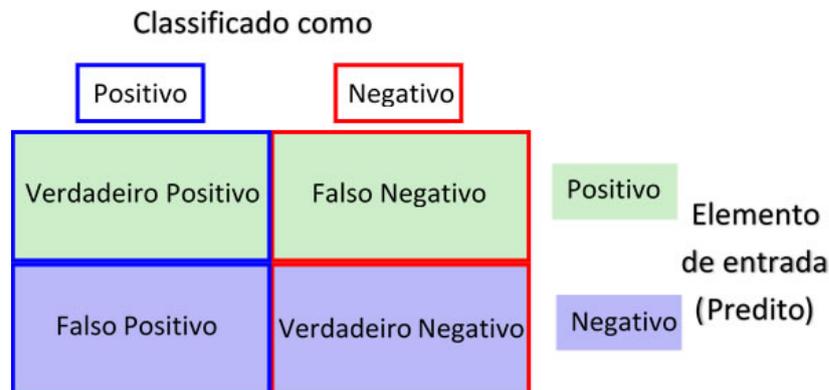


Figura 5.13: Matriz de Confusão

### 5.6.1.2 Taxa de Acerto (*Accuracy*)

A taxa de acerto é uma medida estatística que indica o quão próximo um valor medido é o valor real (verdadeiro), isto é, refere-se a proporção de resultados verdadeiros (ambos os verdadeiros positivos e verdadeiros negativos) na população analisada. Ou ainda, representa a relação entre o total de acertos sobre o conjunto total de erros e acertos. De acordo com [Provost, Fawcett e Kohavi \(1998\)](#), a taxa de acerto é obtida da seguinte forma

$$Accuracy = \frac{VP + VN}{VP + FN + FP + VN} \quad (5.1)$$

onde para um bom resultado de segmentação, *Accuracy* deve ser próximo de 1 (um), sendo assim, FN e FP devem ser próximos de zero.

### 5.6.1.3 Especificidade (*Specificity*)

Especificidade (também chamada de verdadeira taxa negativa) é uma medida estatística de desempenho de classificação binária. Como um bom resultado de segmentação consiste em evitar *falsos alarmes*, alguns testes de desempenho podem enganar, por exemplo, em situações que sempre ocorrerem "negativos". A Especificidade mede a proporção de negativos que são corretamente identificados como tal, e é complementar à taxa de falso positivo. A especificidade é dada por

$$\textit{Specificity} = \frac{VN}{FP + VN} \quad (5.2)$$

onde para um bom resultado de segmentação, *Specificity* deve ser próximo de 1 (um), sendo assim, FP deve ser próximo de zero.

### 5.6.1.4 Precisão (*Precision*)

Em reconhecimento de padrões e recuperação de informações com classificação binária, precisão (também chamado de valor preditivo positivo) é a fração de instâncias recuperadas que são relevantes. Em termos simples, alta precisão significa que um algoritmo retornou resultados substancialmente mais relevantes do que irrelevantes. A precisão é calculada através da porcentagem de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas, corretamente ou não. A precisão é dada por

$$\textit{Precision} = \frac{VP}{VP + FP} \quad (5.3)$$

onde para um bom resultado de segmentação, *Precision* deve ser próximo de 1 (um). Assim, para *Precision* tender a 1, é preciso que FP tenda a zero (ou seja, poucos erros).

### 5.6.1.5 Sensibilidade (*Sensitivity/Recall*)

Sensibilidade (também chamada de taxa positiva verdadeira, ou taxa de recordação (*Recall*) como é mais conhecida), mede a proporção de positivos reais, devidamente identificados como tal. Neste contexto, é definida como o número de verdadeiros positivos dividido pelo número total de elementos que, na verdade, pertencem à classe positiva (isto é, a soma dos verdadeiros positivos e falsos negativos, que são itens que não foram marcados como pertencendo à classe positiva mas deveriam ter sido). A sensibilidade é expressa

como

$$Recall = \frac{VP}{VP + FN} \quad (5.4)$$

onde para um bom resultado de segmentação, *Recall* deve ser próximo de 1 (um). Assim, para *Recall* tender a 1, é preciso que FN tenda a zero.

#### 5.6.1.6 Medida *F-score*

Em recuperação de informação, uma pontuação perfeita de precisão igual a 1, significa que nos resultados obtidos por uma pesquisa, foram encontrados mais *pixels* relevantes (positivos) do que irrelevantes (negativos) (mas não diz nada sobre se todos os *pixels* positivos foram identificados), enquanto uma pontuação perfeita de sensibilidade igual a 1, significa que todos os *pixels* positivos foram identificados pela pesquisa (mas não diz nada sobre quantos *pixels* negativos também foram recuperados).

Normalmente, a precisão e sensibilidade não são analisadas de forma isolada. Em vez disso, ambos os valores obtidos por estas medidas são comparados por meio da utilização de outra medida, conhecida como medida *F-score* (também chamada de medida F1 ou *F-measure*) que representa a média harmônica entre a precisão e a sensibilidade. A medida *F-score* atinge o seu melhor resultado obtendo o valor 1 (um) e o pior resultado quando obtêm o valor 0 (zero). A medida *F-score* foi definida originalmente por [Rijsbergen \(1979\)](#), que a descreveu matematicamente como

$$Fscore = \frac{2 * Recall * Precision}{Recall + Precision} \quad (5.5)$$

A Tabela 5.5 apresenta um resumo das métricas que foram discutidas ao longo desta seção.

Tabela 5.5: Métricas usadas para avaliação das técnicas de segmentação

<b>Medidas da Detecção de Sinais</b>	
Verdadeiros Positivos (VP)	O elemento de entrada é positivo e o algoritmo classifica como positivo
Verdadeiros Negativos (VN)	O elemento de entrada é negativo e o algoritmo classifica como negativo
Falsos Positivos (FP)	O elemento de entrada é negativo e o algoritmo classifica como positivo
Falsos Negativos (FN)	O elemento de entrada é positivo e o algoritmo classifica como negativo
<b>Métricas Usadas para Avaliação de Desempenho dos Algoritmos</b>	
<b><i>Taxa de Acerto (Accuracy)</i></b>	Relação entre o total de acertos sobre o conjunto total de erros e acertos. Esse valor é calculado por: $(VP + VN)/(VP + FN + FP + VN)$
<b><i>Especificidade (Specificity)</i></b>	Porcentagem de amostras negativas identificadas corretamente sobre o total de amostras negativas. Esse valor é calculado por: $VN/(FP + VN)$
<b><i>Precisão (Precision)</i></b>	Porcentagem de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas. Esse valor é calculado por: $VP/(VP + FP)$
<b><i>Sensibilidade (Sensitivity/Recall)</i></b>	Porcentagem de amostras positivas classificadas corretamente sobre o total de amostras positivas. Esse valor é calculado por: $VP/(VP + FN)$
<b><i>Medida F-score</i></b>	Representa a média harmônica entre a precisão e a sensibilidade. É calculada por: $2*Recall*Precision/(Recall + Precision)$

### 5.6.2 Metodologia adotada para análise de desempenho dos algoritmos de segmentação estudados

No presente trabalho, realizou-se a segmentação das imagens por meio de cada algoritmo de segmentação analisado, utilizando as imagens **cortadas** obtidas por intermédio do processo apresentado na Figura 5.3. Por fim, foram considerados apenas os *pixels* do ROI das imagens segmentadas para aplicação das métricas discutidas na seção 5.6.1. A Figura 5.14 ilustra as etapas do processo de segmentação realizado nas imagens do *dataset* do trabalho aqui proposto.

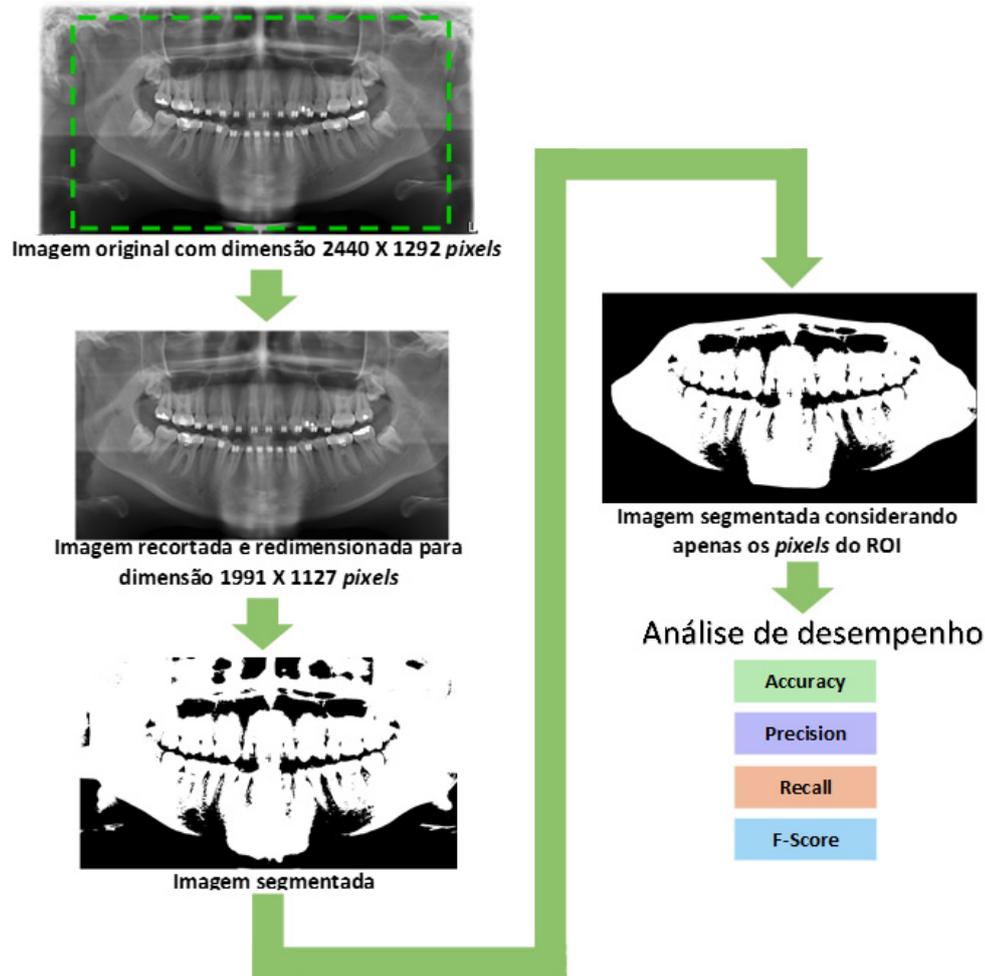
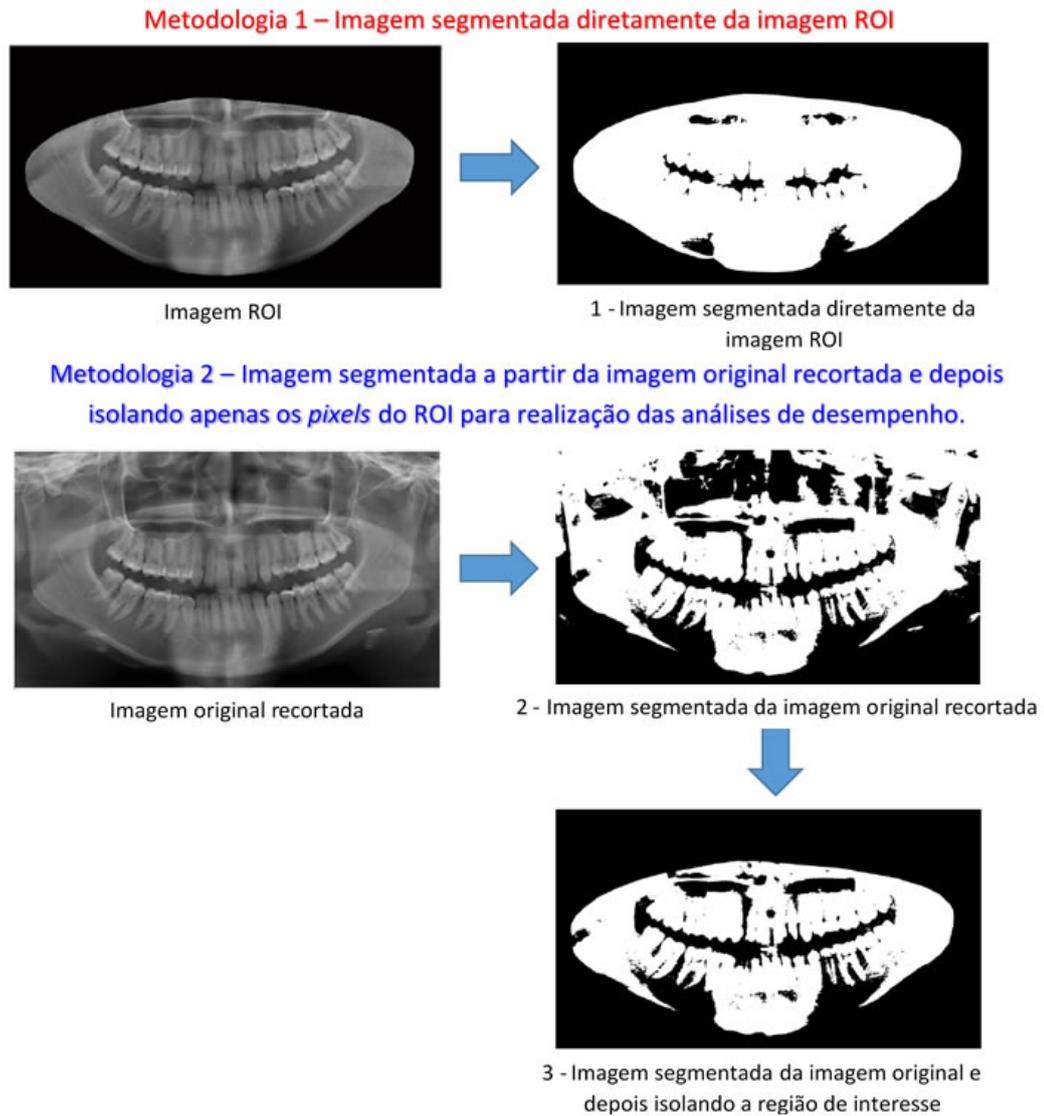


Figura 5.14: Etapas do processo de segmentação e análise de desempenho dos algoritmos de segmentação

O processo ilustrado na Figura 5.14 foi aplicado nas 1500 imagens do *dataset* do trabalho aqui proposto. Experimentos foram realizados aplicando a segmentação diretamente nas imagens contendo apenas a área do ROI. Entretanto, melhores resultados foram obtidos aplicando a segmentação na imagem original recortada e após a segmentação, isolando os *pixels* do ROI para efetuar a análise de desempenho dos algoritmos estudados, conforme mostrado na Figura 5.14. A análise para verificar que a metodologia apresentada na Figura 5.14 obteve melhores resultados do que se aplicado a segmentação diretamente nas imagens considerando apenas a região do ROI, foi validada realizando os dois processos mencionados e confrontando os resultados, com base na média geral da métrica Taxa de Acerto (*Accuracy*) (definida na seção 5.6.1.2), que foi calculada para todos os métodos de segmentação avaliados. Desse modo, comprovando que a metodologia apresentada na Figura 5.14 alcançou melhores resultados, portanto, foi adotada para análise de desempenho dos algoritmos de segmentação estudados no presente trabalho. A Figura 5.15 mostra a aplicação das duas metodologias discutidas neste parágrafo, apresentando os

valores correspondentes ao cálculo da média geral da métrica Taxa de Acerto (*Accuracy*) de todas as imagens do *dataset*, comprovando que a metodologia 2 (adotada no presente trabalho) foi a que alcançou melhor resultado. O processo de obtenção da média geral da métrica Taxa de Acerto e das demais métricas utilizadas no presente trabalho, será apresentado mais adiante, ainda neste Capítulo.



Método de Segmentação	Metodologia 1 - Média geral da métrica <b>Taxa de Acerto</b> , utilizando as imagens segmentadas diretamente das imagens ROI	Metodologia 2 - Média geral da métrica <b>Taxa de Acerto</b> , utilizando as imagens segmentadas das imagens originais e depois isolando a região de interesse
Lim. Básica Global	0,67	0,78
Lim. Variável Local	0,73	0,80
Crescimento de Região	0,58	0,66
Divisão/União de Regiões	0,74	0,81
Método Pun	0,76	0,80
Método Renyi	0,77	0,84

Figura 5.15: Escolha da metodologia adotada no presente trabalho para segmentação e análise de desempenho dos algoritmos de segmentação estudados

### 5.6.3 Métodos de segmentação analisados

Nesta seção, são demonstrados como os algoritmos de segmentação estudados foram analisados, por meio da utilização das métricas discutidas na seção 5.6.1. Por fim, os valores obtidos são apresentados em tabelas para melhor avaliar os resultados alcançados.

Para cada imagem segmentada, realizou-se o cálculo das métricas discutidas na seção 5.6.1. A Figura 5.16 apresenta um exemplo dos valores obtidos, **por imagem**, com base na imagem segmentada pelo algoritmo de segmentação e a sua imagem correspondente segmentada manualmente por meio do processo de anotação manual dos dentes, que foi apresentado na seção 5.3.

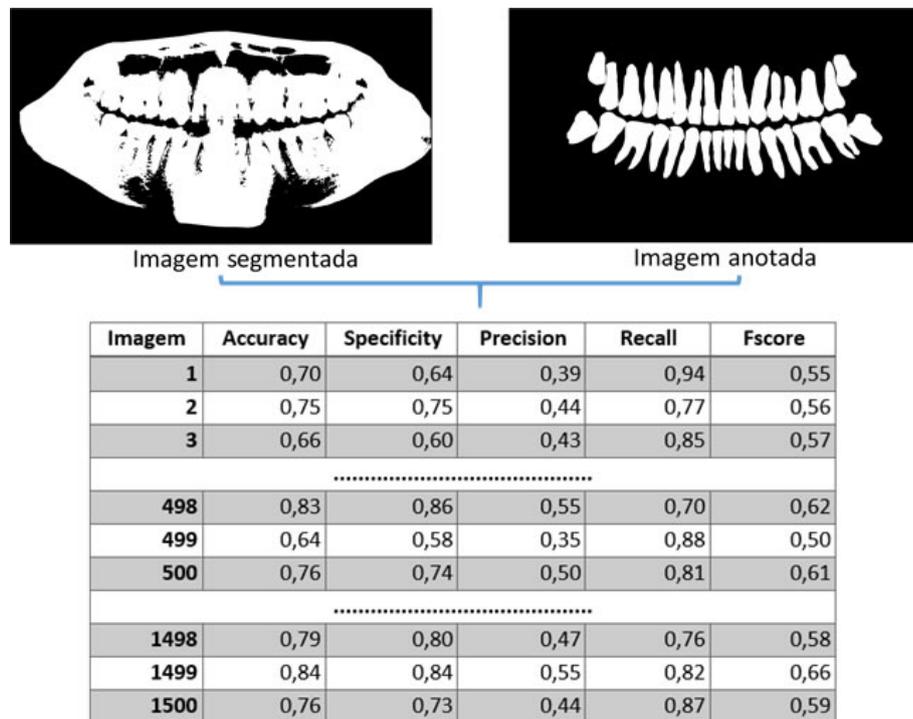


Figura 5.16: Exemplo do processo de obtenção dos valores, por imagem, das métricas utilizadas no presente trabalho

O processo apresentado na Figura 5.16, foi realizado com todas as imagens segmentadas, obtidas por cada um dos 6 algoritmos de segmentação estudados na presente pesquisa. Foram realizadas, portanto, as análises de desempenho com 9000 imagens segmentadas, que representam as 1500 imagens obtidas por cada algoritmo de segmentação avaliado.

### 5.6.3.1 Validação da execução do cálculo das métricas estudadas

Conforme descrito ao longo do presente capítulo, as imagens do *dataset* do presente trabalho, foram nomeadas utilizando números inteiros em ordem sequencial. Este padrão ocorreu para todas as imagens armazenadas no *dataset*: imagens originais, imagens anotadas e imagens segmentadas. Neste sentido, a validação da execução dos algoritmos de segmentação estudados ocorreu realizando a verificação da nomenclatura das imagens e armazenando a imagem segmentada com o mesmo nome da imagem original.

Para realizar a validação da execução do cálculo das métricas estudadas, desenvolveu-se um algoritmo que verifica a nomenclatura das imagens segmentadas manualmente pelo processo de anotação e das imagens segmentadas automaticamente pelo método de segmentação analisado. Caso a nomenclatura seja a mesma nas duas imagens, isto é, apresente o mesmo número inteiro, então a execução do algoritmo que calcula as métricas é realizada com sucesso e passa para a imagem seguinte do *dataset*. Caso contrário, a execução é interrompida. A Figura 5.18 ilustra um exemplo do processo de validação da execução do cálculo das métricas utilizadas no presente trabalho e que foi discutido neste parágrafo.

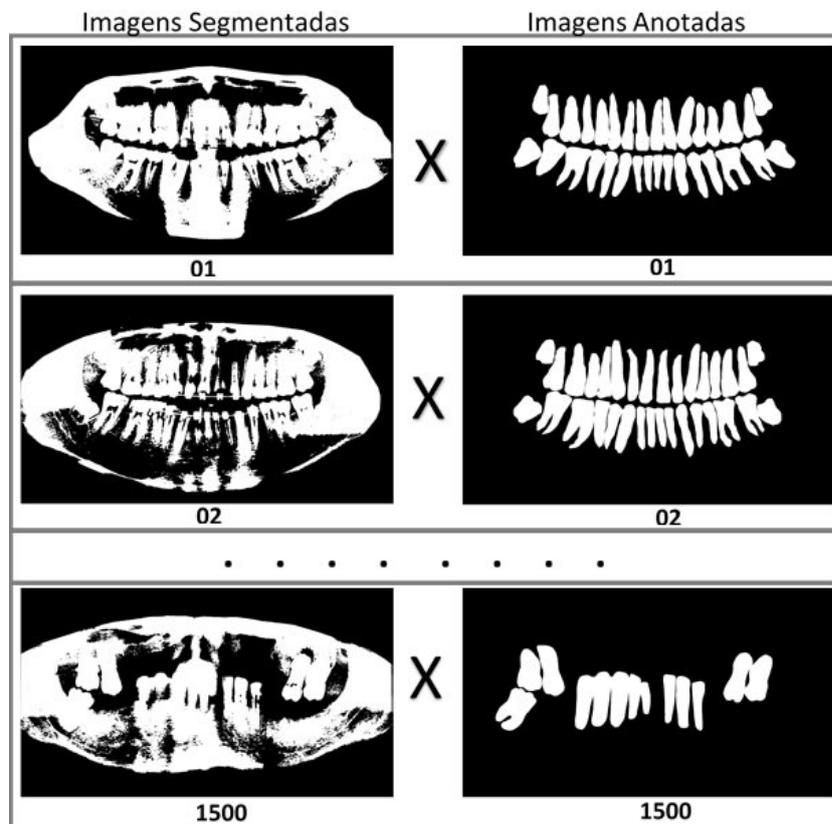


Figura 5.17: Exemplo do processo de validação da execução do cálculo das métricas utilizadas no presente trabalho

### 5.6.3.2 Limiarização Básica Global (*Basic Global Thresholding*)

O cálculo das métricas para análise de desempenho dos algoritmos de segmentação foi similar ao usado para realização das análises estatísticas discutidas na seção 5.5.1. Neste sentido, efetuou-se os cálculos das métricas de **imagem a imagem** de cada categoria do *dataset* do presente trabalho e, por fim, obtiveram-se a **média** e o **desvio padrão** para cada métrica referente aos valores obtidos das métricas de todas as imagens de cada categoria. A Tabela 5.6 ilustra um exemplo do processo discutido neste parágrafo.

Tabela 5.6: Exemplo do processo de cálculo das métricas, por imagem, em cada categoria e obtenção da média e desvio padrão dos valores

Imagem	Accuracy	Specificity	Precision	Recall	Fscore
<b>1</b>	0,70	0,64	0,39	0,94	0,55
<b>2</b>	0,75	0,75	0,44	0,77	0,56
<b>3</b>	0,66	0,60	0,43	0,85	0,57
.....					
<b>71</b>	0,78	0,77	0,48	0,83	0,61
<b>72</b>	0,81	0,84	0,52	0,67	0,58
.....					
<b>Média</b>	<b>0,74</b>	<b>0,72</b>	<b>0,45</b>	<b>0,81</b>	<b>0,58</b>
<b>Desvio Padrão</b>	<b>0,05</b>	<b>0,09</b>	<b>0,04</b>	<b>0,09</b>	<b>0,02</b>

Utilizando o mesmo padrão mostrado na Tabela 5.6, obteve-se as médias e o desvio padrão das métricas das imagens de **cada categoria** do *dataset* do presente trabalho, em seguida, organizou-se as médias e os desvios padrões das métricas em uma única tabela para melhor analisar os resultados encontrados entre as categorias e calcular a **média geral, que corresponde a média das médias de todas as categorias**. A média geral foi obtida para cada método de segmentação analisado. Os valores mostrados na Tabela 5.7 correspondem as médias, os desvios padrões e as médias gerais das métricas que foram calculadas a partir das imagens segmentadas pelo método de segmentação baseado em limiarização básica global. Entretanto, o mesmo processo foi realizado com todos os algoritmos de segmentação analisados no trabalho aqui proposto e os resultados serão apresentados nas próximas seções.

A média geral é uma média ponderada dos valores calculados das categorias, obtida a partir do cálculo da média da métrica e multiplicando-se pelo número de imagens da sua respectiva categoria. Em seguida, soma-se os valores encontrados de todas as categorias e o resultado do somatório é dividido por 1500, que representa o total de imagens do *dataset* do presente trabalho. Desse modo, obtendo a média geral das categorias de cada métrica estudada. As tabelas 5.7 até 5.12 apresentam os resultados obtidos das médias gerais, que foram calculadas para cada método de segmentação analisado no presente trabalho.

Tabela 5.7: Resultados das análises da segmentação baseada em Limiarização Básica Global

Categoria	Accuracy	DP Accuracy	Specificity	DP Specificity	Precision	DP Precision	Recall	DP Recall	Fscore	DP Fscore
cat1	<b>0,76</b>	0,04	<b>0,76</b>	0,07	<b>0,47</b>	0,05	<b>0,77</b>	0,10	<b>0,58</b>	0,04
cat2	<b>0,75</b>	0,05	<b>0,74</b>	0,08	<b>0,47</b>	0,06	<b>0,79</b>	0,09	<b>0,58</b>	0,04
cat3	<b>0,77</b>	0,05	<b>0,78</b>	0,09	<b>0,51</b>	0,06	<b>0,73</b>	0,13	<b>0,59</b>	0,05
cat4	<b>0,79</b>	0,04	<b>0,87</b>	0,08	<b>0,59</b>	0,10	<b>0,55</b>	0,14	<b>0,55</b>	0,06
cat5	<b>0,75</b>	0,07	<b>0,76</b>	0,10	<b>0,32</b>	0,16	<b>0,74</b>	0,13	<b>0,42</b>	0,11
cat6	<b>0,83</b>	0,02	<b>0,92</b>	0,06	<b>0,71</b>	0,10	<b>0,50</b>	0,18	<b>0,56</b>	0,11
cat7	<b>0,74</b>	0,05	<b>0,73</b>	0,07	<b>0,36</b>	0,06	<b>0,82</b>	0,08	<b>0,49</b>	0,06
cat8	<b>0,84</b>	0,05	<b>0,86</b>	0,07	<b>0,58</b>	0,11	<b>0,73</b>	0,11	<b>0,64</b>	0,08
cat9	<b>0,76</b>	0,05	<b>0,77</b>	0,08	<b>0,47</b>	0,09	<b>0,73</b>	0,10	<b>0,56</b>	0,07
cat10	<b>0,80</b>	0,06	<b>0,85</b>	0,09	<b>0,42</b>	0,18	<b>0,56</b>	0,17	<b>0,44</b>	0,15
<b>Categoria (Imagens)</b>	<b>Imagens X Accuracy</b>	<b>Imagens X Specificity</b>	<b>Imagens X Precision</b>	<b>Imagens X Recall</b>	<b>Imagens X Fscore</b>					
cat1 (73)	55,37	55,13	34,34	55,91	42,11					
cat2 (220)	164,36	161,71	103,27	172,89	128,03					
cat3 (45)	34,57	34,94	23,08	32,88	26,66					
cat4 (140)	110,72	121,24	82,79	77,25	77,31					
cat5 (120)	90,07	90,61	38,88	88,49	50,41					
cat6 (170)	141,01	157,03	120,55	85,64	94,67					
cat7 (115)	85,11	83,43	40,97	93,76	56,36					
cat8 (457)	381,65	392,65	266,94	335,33	291,42					
cat9 (45)	34,41	34,80	21,20	32,85	25,19					
cat10 (115)	92,06	97,18	48,33	64,63	50,97					
<b>SOMA</b>	<b>1189,34</b>	<b>1228,72</b>	<b>780,35</b>	<b>1039,63</b>	<b>843,13</b>					
<b>Média Geral</b>	<b>0,79</b>	<b>0,82</b>	<b>0,52</b>	<b>0,69</b>	<b>0,56</b>					

DP = Desvio Padrão

Média Geral = SOMA/1500

A partir dos resultados obtidos das imagens segmentadas pelo método de segmentação baseado em Limiarização Básica Global, pode-se verificar através da Tabela 5.7 que, dentre os valores obtidos com o cálculo das métricas, observa-se que a categoria 8 foi a que obteve a maior proporção identificada do somatório de verdadeiros positivos e verdadeiros negativos, logo, obtendo a melhor Taxa de Acerto (*Accuracy*).

A categoria 6 que contém as imagens com mais de 32 dentes, foi a que obteve o maior valor de Especificidade (*Specificity*), indicando que foi a categoria em que o algoritmo de segmentação básica global, apresentou o maior número de verdadeiros negativos. Neste sentido, comparando a **relação** entre *pixels* relevantes (positivos) e irrelevantes (negativos) identificados, pode-se notar que a categoria 6 foi a que também obteve a maior Precisão (*Precision*) nos resultados, determinando que foi a categoria em que o algoritmo melhor retornou resultados mais relevantes do que irrelevantes. Entretanto, a categoria 6 foi a que obteve o menor número de verdadeiros positivos, portanto, indicando que muitos *pixels* relevantes não foram identificados e, desse modo, apresentando baixo valor de Sensibilidade (*Recall*) em relação as outras categorias. Além disso, verifica-se que a categoria 7 foi a que melhor identificou os verdadeiros positivos, desse modo, apresentando o maior valor de Sensibilidade (*Recall*) encontrado.

Por fim, percebeu-se que utilizando a segmentação básica global nas imagens do *dataset* do presente trabalho, constatou-se que a categoria 5 foi a que apresentou os piores resultados das métricas: Precisão (*Precision*) e também da medida *F-score*. Conclui-se que a categoria 5 apresentou os piores resultados das métricas citadas, pois representa a categoria que contém as imagens com implantes dentários, desse modo, por as imagens apresentarem regiões de alta intensidade dos *pixels* (correspondentes aos implantes), prejudicou o algoritmo de segmentação básica global, que realiza o processo de segmentação baseado na intensidade dos *pixels*.

### 5.6.3.3 Método Niblack (*Method Niblack*)

Do mesmo que apresentado na seção anterior, a Tabela 5.8 mostra os resultados do cálculo das métricas utilizadas no presente trabalho, mostrando os valores das médias e dos desvios padrões encontrados utilizando as imagens segmentadas por meio do método de segmentação Niblack.

Tabela 5.8: Resultados das análises da segmentação baseada no Método Niblack

Categoria	Accuracy	DP Accuracy	Specificity	DP Specificity	Precision	DP Precision	Recall	DP Recall	Fscore	DP Fscore
cat1	0,79	0,04	0,78	0,05	0,48	0,05	0,85	0,05	0,61	0,04
cat2	0,78	0,04	0,76	0,06	0,48	0,06	0,85	0,05	0,61	0,05
cat3	0,80	0,04	0,79	0,05	0,51	0,05	0,85	0,04	0,63	0,04
cat4	0,80	0,05	0,80	0,07	0,54	0,10	0,83	0,06	0,65	0,06
cat5	0,74	0,05	0,73	0,06	0,28	0,09	0,86	0,08	0,42	0,11
cat6	0,87	0,03	0,90	0,05	0,65	0,09	0,74	0,13	0,68	0,07
cat7	0,77	0,04	0,75	0,05	0,37	0,06	0,88	0,06	0,52	0,06
cat8	0,87	0,05	0,89	0,06	0,61	0,10	0,80	0,07	0,69	0,07
cat9	0,79	0,04	0,78	0,05	0,46	0,08	0,84	0,05	0,59	0,07
cat10	0,77	0,05	0,75	0,06	0,37	0,15	0,87	0,06	0,49	0,16
Categoria (Imagens)	Imagens X Accuracy	Imagens X Specificity	Imagens X Precision	Imagens X Recall	Imagens X Fscore	Imagens X Fscore	Imagens X Recall	Imagens X Fscore	Imagens X Fscore	Imagens X Fscore
cat1 (73)	57,72	56,60	34,77	62,13	44,47	44,47	62,13	44,47	44,47	44,47
cat2 (220)	171,89	167,90	105,30	187,10	134,25	134,25	187,10	134,25	134,25	134,25
cat3 (45)	35,96	35,35	22,91	38,07	28,54	28,54	38,07	28,54	28,54	28,54
cat4 (140)	112,69	111,63	75,67	116,71	90,86	90,86	116,71	90,86	90,86	90,86
cat5 (120)	89,26	87,65	34,08	103,77	49,84	49,84	103,77	49,84	49,84	49,84
cat6 (170)	147,54	152,41	111,16	125,46	115,82	115,82	125,46	115,82	115,82	115,82
cat7 (115)	88,90	86,73	42,84	101,72	59,92	59,92	101,72	59,92	59,92	59,92
cat8 (457)	399,50	406,25	279,84	366,04	313,84	313,84	366,04	313,84	313,84	313,84
cat9 (45)	35,66	35,22	20,75	37,62	26,54	26,54	37,62	26,54	26,54	26,54
cat10 (115)	88,20	86,36	42,03	99,91	56,58	56,58	99,91	56,58	56,58	56,58
<b>SOMA</b>	<b>1227,32</b>	<b>1226,12</b>	<b>769,36</b>	<b>1238,53</b>	<b>920,66</b>	<b>920,66</b>	<b>1238,53</b>	<b>920,66</b>	<b>920,66</b>	<b>920,66</b>
<b>Média Geral</b>	<b>0,82</b>	<b>0,82</b>	<b>0,51</b>	<b>0,83</b>	<b>0,61</b>	<b>0,61</b>	<b>0,83</b>	<b>0,61</b>	<b>0,61</b>	<b>0,61</b>

DP = Desvio Padrão

Média Geral = SOMA/1500

Analisando a Tabela 5.8, a partir dos resultados obtidos das imagens segmentadas pelo Método Niblack, nota-se que foram alcançados resultados semelhantes aos obtidos pela segmentação por limiarização global. Sendo assim, observa-se que a categoria 6 e a categoria 8 foram as que obtiveram a maior proporção identificada do somatório de verdadeiros positivos e verdadeiros negativos, logo, obtendo a melhor Taxa de Acerto (*Accuracy*) em relação as outras categorias.

Ainda, de forma semelhante ao ocorrido nos resultados das análises utilizando a segmentação baseada em limiarização global, verifica-se que a categoria 6 que contem as imagens com mais de 32 dentes, também foi a que obteve o maior valor de Especificidade (*Specificity*), indicando que foi a categoria em que o algoritmo de segmentação baseado no Método Niblack, obteve o maior número de verdadeiros negativos. Neste sentido, comparando a **relação** entre *pixels* relevantes (positivos) e irrelevantes (negativos) identificados, pode-se notar que a categoria 6 corresponde a que também obteve a maior Precisão (*Precision*) nos resultados, representando a categoria em que o algoritmo melhor retornou resultados mais relevantes do que irrelevantes. Entretanto, refere-se a categoria que pior identificou os verdadeiros positivos. Portanto, indica que muitos *pixels* relevantes não foram identificados e, desse modo, apresentando baixo valor de Sensibilidade (*Recall*) em relação as outras categorias.

Utilizando a segmentação baseada no Método Niblack, verifica-se que a categoria 7 foi a que melhor identificou os verdadeiros positivos, desse modo, apresentando o maior valor de Sensibilidade (*Recall*). Do mesmo modo que ocorreu com os resultados obtidos a partir da segmentação baseada em limiarização global, percebeu-se que o algoritmo de segmentação baseado no Método Niblack também não apresentou bom desempenho nas imagens do *dataset* da categoria 5, obtendo os valores mais baixos das métricas: Precisão (*Precision*) e da medida *F-score* em relação as outras categorias. Conclui-se que os resultados ruins obtidos das métricas Precisão (*Precision*) e *F-score* na categoria 5, são devido as imagens dessa categoria possuírem os implantes dentários, com regiões de alta intensidade dos *pixels* (correspondentes aos implantes), o que dificultou o processo de segmentação utilizando o Método Niblack, que realiza o processo de segmentação baseado na intensidade dos *pixels*.

#### 5.6.3.4 Crescimento de região (*Region Growing*)

A Tabela 5.9 mostra os resultados do cálculo das métricas utilizadas no presente trabalho, mostrando os valores das médias e dos desvios padrões encontrados utilizando as imagens segmentadas por meio do método de segmentação baseado em Crescimento de Região.

Tabela 5.9: Resultados das análises da segmentação baseada em Crescimento de Região

Categorias	Accuracy	DP Accuracy	Specificity	DP Specificity	Precision	DP Precision	Recall	DP Recall	Fscore	DP Fscore	
cat1	0,64	0,05	0,64	0,06	0,32	0,05	0,62	0,10	0,42	0,06	
cat2	0,64	0,04	0,65	0,06	0,34	0,04	0,61	0,08	0,43	0,04	
cat3	0,65	0,04	0,68	0,06	0,34	0,05	0,54	0,10	0,41	0,05	
cat4	0,67	0,06	0,69	0,08	0,39	0,09	0,60	0,08	0,47	0,07	
cat5	0,60	0,07	0,61	0,08	0,18	0,07	0,55	0,17	0,26	0,09	
cat6	0,71	0,05	0,73	0,08	0,43	0,07	0,67	0,11	0,52	0,07	
cat7	0,62	0,06	0,60	0,07	0,25	0,05	0,73	0,08	0,37	0,06	
cat8	0,75	0,06	0,78	0,08	0,44	0,10	0,65	0,10	0,51	0,08	
cat9	0,64	0,04	0,66	0,07	0,30	0,05	0,56	0,11	0,38	0,06	
cat10	0,63	0,06	0,62	0,08	0,25	0,10	0,69	0,12	0,35	0,12	
Categoria (Imagens)											
	Imagens X Accuracy			Imagens X Specificity			Imagens X Precision			Imagens X Fscore	
cat1 (73)	46,40		46,73		23,49		44,97		30,69		
cat2 (220)	141,17		143,33		73,77		133,38		94,52		
cat3 (45)	29,04		30,42		15,24		24,45		18,57		
cat4 (140)	93,64		96,94		54,53		83,61		65,23		
cat5 (120)	72,48		73,27		21,04		66,09		30,92		
cat6 (170)	121,54		124,00		73,24		113,18		87,87		
cat7 (115)	71,43		68,85		28,94		84,48		42,86		
cat8 (457)	344,85		357,66		200,11		296,82		234,43		
cat9 (45)	28,61		29,64		13,43		25,01		17,22		
cat10 (115)	72,32		71,31		29,13		79,22		40,57		
<b>SOMA</b>	<b>1021,49</b>		<b>1042,15</b>		<b>532,92</b>		<b>951,21</b>		<b>662,87</b>		
<b>Média Geral</b>	<b>0,68</b>		<b>0,69</b>		<b>0,36</b>		<b>0,63</b>		<b>0,44</b>		

DP = Desvio Padrão

Média Geral = SOMA/1500

A partir dos resultados obtidos das imagens segmentadas pelo método de segmentação baseado em Crescimento de Região, pode-se verificar por meio da Tabela 5.9 que, os valores apresentados são mais baixos do que os obtidos pelas análises realizadas com os métodos de segmentação apresentados nas seções 5.6.3.2 e 5.6.3.3. No entanto, conforme discutido no Capítulo 4, ressalta-se que as imagens foram redimensionadas para realização do processo de segmentação baseado em Crescimento de Região. Observa-se que a categoria 8 apresentou a maior proporção identificada do somatório de verdadeiros positivos e verdadeiros negativos, logo, obtendo a melhor Taxa de Acerto (*Accuracy*). O maior valor de Especificidade (*Specificity*) encontrado com a análise das imagens segmentadas pelo método baseado em Crescimento de Região, foi a da categoria 8, representando a categoria em que o algoritmo apresentou o maior número de verdadeiros negativos quando comparado as outras categorias. Comparando a **relação** entre *pixels* relevantes (positivos) e irrelevantes (negativos) identificados, nota-se, do mesmo modo que ocorreu com os métodos de segmentação analisados nas seções 5.6.3.2 e 5.6.3.3, que a categoria 6 corresponde a que também obteve a maior Precisão (*Precision*) nos resultados, representando a categoria em que o algoritmo melhor retornou resultados mais relevantes do que irrelevantes em relação as demais categorias analisadas.

Os resultados das análises apresentadas na Tabela 5.9, indicam que na categoria 3, muitos *pixels* relevantes (positivos) não foram identificados e, desse modo, apresentando baixo valor de Sensibilidade (*Recall*) em relação as outras categorias. Semelhante a análise realizada dos métodos de segmentação das seções 5.6.3.2 e 5.6.3.3, verifica-se que a categoria 7 também representou a que melhor identificou os verdadeiros positivos, desse modo, apresentando o maior valor de Sensibilidade (*Recall*) encontrado. Utilizando a segmentação baseada em Crescimento de Região nas imagens do *dataset* do presente trabalho, constatou-se que a categoria 5 apresentou os piores resultados das métricas: Precisão (*Precision*) e também da medida *F-score*, pois representa a categoria que contém as imagens com implantes dentários, desse modo, por as imagens apresentarem regiões de alta intensidade dos *pixels* (correspondentes aos implantes), prejudicou o algoritmo de segmentação baseado em Crescimento de Região, que realiza o processo de segmentação baseado na intensidade dos *pixels*.

### 5.6.3.5 Divisão e União de Regiões (*Region Splitting and Merging*)

A Tabela 5.10 mostra os resultados do cálculo das métricas utilizadas no presente trabalho, demonstrando os valores das médias e dos desvios padrões encontrados com as imagens segmentadas por meio do método baseado em Divisão e União de Regiões.

Tabela 5.10: Resultados das análises da segmentação baseada em Divisão e União de Regiões

Categorias	Accuracy	DP Accuracy	Specificity	DP Specificity	Precision	DP Precision	Recall	DP Recall	Fscore	DP Fscore
cat1	0,80	0,02	0,99	0,00	0,82	0,06	0,11	0,03	0,19	0,05
cat2	0,79	0,02	1,00	0,00	0,83	0,05	0,06	0,01	0,12	0,02
cat3	0,79	0,02	1,00	0,00	0,89	0,05	0,10	0,03	0,18	0,05
cat4	0,77	0,02	1,00	0,00	0,85	0,05	0,05	0,01	0,10	0,02
cat5	0,89	0,05	1,00	0,00	0,82	0,10	0,18	0,08	0,28	0,09
cat6	0,78	0,03	1,00	0,00	0,81	0,06	0,06	0,02	0,12	0,03
cat7	0,85	0,03	0,99	0,00	0,59	0,11	0,10	0,03	0,17	0,05
cat8	0,81	0,05	1,00	0,00	0,88	0,08	0,07	0,02	0,13	0,03
cat9	0,82	0,03	1,00	0,00	0,88	0,05	0,12	0,03	0,21	0,05
cat10	0,84	0,07	1,00	0,00	0,70	0,21	0,05	0,01	0,09	0,02
Categoria (Imagens)	Imagens X Accuracy	Imagens X Specificity	Imagens X Precision	Imagens X Recall	Imagens X Fscore					
cat1 (73)	58,66	72,56	60,08	7,99	14,00					
cat2 (220)	173,35	219,16	181,67	13,72	25,46					
cat3 (45)	35,50	44,84	40,01	4,47	7,97					
cat4 (140)	107,87	139,60	118,85	7,15	13,47					
cat5 (120)	106,46	119,44	98,13	21,27	33,74					
cat6 (170)	132,82	169,25	137,33	10,75	19,82					
cat7 (115)	97,93	113,57	67,66	11,91	20,04					
cat8 (457)	369,72	455,86	400,03	32,45	59,72					
cat9 (45)	36,68	44,81	39,65	5,39	9,41					
cat10 (115)	97,03	114,60	80,03	5,91	10,78					
<b>SOMA</b>	<b>1216,03</b>	<b>1493,69</b>	<b>1223,43</b>	<b>121,02</b>	<b>214,42</b>					
<b>Média Geral</b>	<b>0,81</b>	<b>1,00</b>	<b>0,82</b>	<b>0,08</b>	<b>0,14</b>					

DP = Desvio Padrão  
Média Geral = SOMA/1500

Com base nos dados apresentados na Tabela 5.10, observa-se que a segmentação baseada em Divisão e União de Regiões resultou em valores altos de Especificidade (Specificity) em todas as categorias, correspondendo a 100% de acerto, indicando que foram detectados todos os verdadeiros negativos. Os altos valores da métrica Especificidade se justifica pelo fato do método de segmentação baseado em Divisão e União de Regiões gerar como resultado da segmentação, imagens destacando apenas as bordas dos objetos, logo, muitas regiões das imagens segmentadas que não correspondem as bordas, resultam na cor preta e que representam o valor zero dos *pixels* das imagens binárias geradas pelo processo de segmentação. Desse modo, todos os *pixels* na cor preta (referente aos verdadeiros negativos) foram detectados.

Utilizando a mesma análise descrita do parágrafo anterior, isto é, sabendo que o método de segmentação baseado em Divisão e União de Regiões gera como resultado a imagem segmentada destacando apenas a borda dos objetos. Verifica-se na Tabela 5.10 que, para todas as categorias, foram encontrados valores baixos de Sensibilidade (Recall), apontando que muitos verdadeiros positivos não foram detectados, indicando que, de modo geral, **apenas 9%** dos *pixels* correspondentes a área dos dentes (objetos de interesse) das imagens foram identificados por meio da segmentação baseada em Divisão e União de Regiões. Ainda analisando os resultados da Tabela 5.10, é possível observar que a categoria 3, quando comparado com as outras categorias, obteve a melhor média harmônica entre a Precisão (Precision) e a Sensibilidade (Recall), medida pela métrica *F-score*.

#### 5.6.3.6 Método Pun (Method Pun)

A Tabela 5.11 mostra os resultados do cálculo das métricas utilizadas no presente trabalho, demonstrando os valores das médias e dos desvios padrões encontrados com as imagens segmentadas por meio do Método Pun.

Tabela 5.11: Resultados das análises da segmentação baseada no Método Pun

Categoria	Accuracy	DP Accuracy	Specificity	DP Specificity	Precision	DP Precision	Recall	DP Recall	Fscore	DP Fscore	
cat1	0,80	0,03	0,79	0,04	0,48	0,05	0,83	0,06	0,61	0,04	
cat2	0,79	0,04	0,78	0,05	0,48	0,05	0,82	0,06	0,61	0,05	
cat3	0,81	0,03	0,80	0,04	0,52	0,04	0,83	0,05	0,63	0,04	
cat4	0,81	0,05	0,81	0,06	0,55	0,09	0,81	0,06	0,65	0,06	
cat5	0,74	0,05	0,72	0,05	0,28	0,09	0,87	0,08	0,41	0,11	
cat6	0,87	0,03	0,89	0,04	0,64	0,08	0,77	0,09	0,69	0,06	
cat7	0,78	0,04	0,77	0,04	0,38	0,06	0,87	0,06	0,52	0,06	
cat8	0,88	0,04	0,90	0,05	0,62	0,10	0,78	0,07	0,68	0,07	
cat9	0,80	0,03	0,79	0,04	0,46	0,07	0,83	0,06	0,59	0,07	
cat10	0,78	0,05	0,77	0,05	0,37	0,15	0,84	0,08	0,50	0,16	
<b>Categoria (Imagens)</b>											
	Imagens X Accuracy					Imagens X Precision					Imagens X Fscore
cat1 (73)	58,17	57,52	173,71	171,72	35,19	60,82	44,43				
cat2 (220)	173,71	171,72	36,30	36,07	106,50	181,49	133,82				
cat3 (45)	36,30	36,07	113,72	114,03	23,24	37,18	28,55				
cat4 (140)	113,72	114,03	88,74	86,98	76,68	112,77	90,45				
cat5 (120)	88,74	86,98	147,55	151,47	33,75	104,54	49,61				
cat6 (170)	147,55	151,47	89,93	88,27	109,37	130,15	117,89				
cat7 (115)	89,93	88,27	400,76	409,93	43,52	100,14	60,30				
cat8 (457)	400,76	409,93	35,81	35,50	283,30	356,89	312,53				
cat9 (45)	35,81	35,50	89,53	88,61	20,76	37,19	26,49				
cat10 (115)	89,53	88,61	1234,24	1240,12	42,78	96,91	57,03				
<b>SOMA</b>	<b>1234,24</b>	<b>1240,12</b>	<b>775,08</b>	<b>775,08</b>	<b>1218,07</b>	<b>921,11</b>					
<b>Média Geral</b>	<b>0,82</b>	<b>0,83</b>	<b>0,52</b>	<b>0,52</b>	<b>0,81</b>	<b>0,61</b>					

DP = Desvio Padrão  
Média Geral = SOMA/1500

Analisando os resultados da Tabela 5.11 que foram obtidos utilizando as imagens segmentadas por meio do Método Pun, observa-se que a categoria 8 alcançou o maior valor referente a proporção identificada do somatório de verdadeiros positivos e verdadeiros negativos, logo, obtendo a melhor Taxa de Acerto (*Accuracy*), quando comparado as outras categorias. Nota-se que a categoria 8 também encontrou o maior valor de Especificidade (*Specificity*), indicando que obteve o maior número de verdadeiros negativos detectados. Porém, a categoria 8 representou a segunda categoria que menos conseguiu identificar os verdadeiros positivos nas imagens, desse modo, obtendo o segundo menor valor de Sensibilidade (Recall) dentre as categorias analisadas. Neste sentido, comparando a **relação** entre *pixels* relevantes (positivos) e irrelevantes (negativos) identificados, pode-se notar que a categoria 6 obteve a maior Precisão (*Precision*) nos resultados, representando a categoria em que o algoritmo melhor retornou resultados mais relevantes do que irrelevantes.

De forma semelhante ao ocorrido com as análises dos métodos de segmentação apresentados nas seções anteriores, percebeu-se que o algoritmo de segmentação baseado no Método Pun não apresentou bom desempenho nas imagens do *dataset* da categoria 5, obtendo os valores mais baixos das métricas: Precisão (*Precision*) e também da medida *F-score* em relação as outras categorias.

### 5.6.3.7 Método Renyi (*Method Renyi*)

A Tabela 5.12 mostra os resultados do cálculo das métricas utilizadas no presente trabalho, demonstrando os valores das médias e dos desvios padrões encontrados com as imagens segmentadas por meio do Método Renyi.

Tabela 5.12: Resultados das análises da segmentação baseada no Método Renyi

Categoria	Accuracy	DP Accuracy	Specificity	DP Specificity	Specificity	DP Specificity	Precision	DP Precision	Recall	DP Recall	Fscore	DP Fscore	
cat1	0,84	0,03	0,96	0,07	0,76	0,14	0,30	0,22	0,37	0,14	0,37	0,14	
cat2	0,81	0,05	0,90	0,12	0,64	0,16	0,44	0,29	0,43	0,16	0,43	0,16	
cat3	0,83	0,03	0,95	0,09	0,80	0,17	0,30	0,24	0,37	0,14	0,37	0,14	
cat4	0,81	0,06	0,85	0,12	0,60	0,14	0,63	0,26	0,56	0,12	0,56	0,12	
cat5	0,90	0,06	0,96	0,07	0,68	0,17	0,41	0,24	0,46	0,16	0,46	0,16	
cat6	0,85	0,03	0,96	0,06	0,79	0,14	0,40	0,25	0,47	0,17	0,47	0,17	
cat7	0,87	0,04	0,96	0,07	0,66	0,15	0,30	0,20	0,35	0,11	0,35	0,11	
cat8	0,86	0,04	0,97	0,06	0,76	0,14	0,33	0,25	0,40	0,19	0,40	0,19	
cat9	0,85	0,03	0,97	0,05	0,76	0,15	0,24	0,18	0,32	0,12	0,32	0,12	
cat10	0,82	0,09	0,84	0,13	0,43	0,18	0,62	0,28	0,46	0,16	0,46	0,16	
<b>Categoria (Imagens)</b>													
	Imagens X Accuracy			Imagens X Specificity			Imagens X Precision			Imagens X Recall			Imagens X Fscore
cat1 (73)	61,41		70,05		55,27		21,75		26,91				
cat2 (220)	179,02		197,65		140,30		97,65		95,69				
cat3 (45)	37,16		42,82		35,92		13,67		16,45				
cat4 (140)	113,36		119,23		84,27		88,75		78,29				
cat5 (120)	108,19		115,80		81,90		48,95		54,74				
cat6 (170)	144,59		162,56		134,28		68,65		79,91				
cat7 (115)	100,57		110,40		76,47		34,05		40,69				
cat8 (457)	391,28		441,13		347,06		151,96		181,06				
cat9 (45)	38,06		43,74		34,29		10,98		14,61				
cat10 (115)	94,02		96,38		49,36		71,56		52,35				
<b>SOMA</b>	<b>1267,66</b>		<b>1399,75</b>		<b>1039,13</b>		<b>607,96</b>		<b>640,70</b>				
<b>Média Geral</b>	<b>0,85</b>		<b>0,93</b>		<b>0,69</b>		<b>0,41</b>		<b>0,43</b>				

DP = Desvio Padrão  
Média Geral = SOMA/1500

A Tabela 5.12 permite verificar que, utilizando a segmentação pelo Método Renyi, os valores calculados da métrica Especificidade (Specificity) foram altos em todas as categorias, representando que mais de 90% dos verdadeiros negativos foram identificados e que houve baixa ocorrência de falsos positivos. O algoritmo de segmentação baseado no Método Renyi gerou como resultado da segmentação a maior parte da imagens na cor preta (conforme é possível visualizar no exemplo mostrado na Figura 4.11 do Capítulo 4), ocasionando na maioria dos *pixels* com valor 0 (zero). Entretanto, enquanto que ocorreram muitos verdadeiros negativos, observa-se que os valores obtidos da métrica Sensibilidade (Recall) em todas as categorias foi baixo, alcançando uma média geral de apenas 40% de acerto, indicando que poucas regiões dos objetos de interesse (dentes) foram identificados pela segmentação utilizando o Método Renyi.

Por fim, comparando a **relação** entre *pixels* relevantes (positivos) e irrelevantes (negativos) identificados, pode-se notar que a categoria 3 corresponde a categoria que obteve a maior precisão (*Precision*) nos resultados, representando a categoria em que o algoritmo melhor retornou resultados mais relevantes do que irrelevantes. Entretanto, utilizando o Método Renyi, a categoria 4, representou a que melhor encontrou os verdadeiros positivos, portanto, indicando que muitos *pixels* relevantes foram identificados, desse modo, apresentando baixo valor de falsos negativos em relação as outras categorias analisadas.

### 5.6.3.8 Análise geral dos resultados

As médias gerais obtidas das métricas, que foram apresentadas por meio das tabelas correspondentes a cada um dos métodos de segmentação discutidos ao longo do presente capítulo, foram organizadas em uma única tabela para melhor avaliar os resultados obtidos por cada um dos métodos de segmentação estudados, conforme é apresentado na Tabela 5.13.

Tabela 5.13: Média Geral dos Resultados

Método	Accuracy	Specificity	Precision	Recall	Fscore
<b>Lim. Básica Global</b>	0,79	0,82	0,52	0,69	0,56
<b>Método Niblack</b>	0,82	0,82	0,51	0,83	0,61
<b>Crescimento de Região</b>	0,68	0,69	0,36	0,63	0,44
<b>Divisão/União de Regiões</b>	0,81	1,00	0,82	0,08	0,14
<b>Método Pun</b>	0,82	0,83	0,52	0,81	0,61
<b>Método Renyi</b>	0,85	0,93	0,69	0,41	0,43

Analisando a Tabela 5.13, verifica-se que a segmentação baseada no Método Renyi, apresentou o melhor resultado da métrica Taxa de acerto (Accuracy), correspondendo a maior proporção do somatório de verdadeiros positivos e verdadeiros negativos.

Os métodos de segmentação baseados em Divisão e União de Regiões e o Método Renyi, obtiveram os maiores valores calculados pela métrica Especificidade em todas as categorias do *dataset* utilizado no presente trabalho. Isso ocorre devido a estes algoritmos apresentarem mais de 90% da área das imagens segmentadas na cor preta, correspondendo aos *pixels* com valor 0 (que representam os negativos nas métricas estudadas). Sendo assim, pode-se concluir que as imagens segmentadas pelo algoritmo baseado em Divisão e União de Regiões e o Método Renyi, apresentaram predominância de verdadeiros negativos em seus resultados. Entretanto, quando a segmentação resulta na predominância de elementos de uma certa classe (por exemplo, verdadeiros negativos), indica que para um problema de classificação binária, o resultado do algoritmo de segmentação é equivalente a sugestão aleatória de uma classe, isso representa resultados que não são melhores que uma escolha ao acaso.

O Método Niblack apresentou o maior valor de Sensibilidade (Recall), indicando que as imagens segmentadas pelo Método Niblack, apresentaram maior número de verdadeiros positivos e, portanto, pouca quantidade de falsos negativos em relação aos demais métodos de segmentação estudados. Neste sentido, Observa-se que o Método Niblack foi o que melhor conseguiu identificar os *pixels* que compõem os objetos de interesse (dentes) nas imagens analisadas. No entanto, com base nos dados apresentados na Tabela 5.13, conclui-se que nenhum dos métodos de segmentação estudados, conseguiu isolar completamente, os objetos de interesse (dentes) nas imagens utilizadas do *dataset* do presente trabalho.

## 5.7 Considerações finais

A segmentação completamente autônoma é uma das tarefas mais difíceis no projeto de sistemas de Visão Computacional. Métodos de segmentação de imagens tem sido desenvolvidos, sendo classificados em categorias de acordo com suas especificidades, não havendo porém uma solução geral satisfatória para qualquer problema. Percebe-se que para a resolução de um problema de segmentação de imagem, geralmente é necessário a modificação dos métodos de modo à sua adaptação ao domínio do problema. Observa-se, assim, a crescente tendência de se utilizar métodos que aprendem a segmentar, ao invés de se ter critérios pré-definidos.

O presente capítulo apresentou o trabalho realizado para análise de desempenho dos métodos de segmentação estudados. Foram detalhadas cada etapa da metodologia adotada, iniciando com o processo de aquisição e classificação das imagens para formação do *dataset* utilizado. Em seguida, definindo como foi realizado o processo de anotação das imagens do *dataset*, resultando no padrão para ser comparado com os resultados obtidos

pelos métodos de segmentação avaliados. Introduziu-se as dificuldades encontradas durante a etapa de anotação das imagens do *dataset*, seguindo com a apresentação sobre como foi realizado o processo de delimitação do ROI nas imagens utilizadas para avaliação dos métodos de segmentação. Informações detalhadas sobre toda a análise estatística realizada foi apresentada, exemplificando como os valores obtidos serviram de base para execução dos algoritmos de segmentação. Finalizando o capítulo com a análise de desempenho dos métodos de segmentação estudados, introduzindo as métricas utilizadas (*accuracy*, *specificity*, *precision*, *recall (sensitivity)* e *F-score*) e mostrando como o processo de segmentação foi realizado. Por fim, apresentando os resultados alcançados com a segmentação das imagens por meio de cada método analisado.

A partir da avaliação realizada neste capítulo, conclui-se que nenhum dos algoritmos estudados, conseguiu isolar de maneira eficaz os objetos de interesse (dentes) nas imagens do *dataset* utilizado no presente trabalho. Entretanto, foi possível perceber que os algoritmos de segmentação baseados no Método Niblack e no método Pun, alcançaram os melhores resultados em relação aos outros algoritmos de segmentação analisados. Sendo assim, observa-se que o processo de segmentação das imagens de raio-X panorâmico, baseado em limiarização, obteve significativa melhoria de desempenho quando utilizado um limiar local variando em diferentes regiões da imagem ao invés de usar um único limiar global para realizar a segmentação das imagens.

No próximo capítulo são apresentadas as conclusões do presente trabalho, envolvendo as contribuições e as dificuldades encontradas, além de algumas sugestões de atividades de pesquisa a serem desenvolvidas no futuro.

## Conclusões

---

O objetivo do presente trabalho foi realizar uma avaliação de métodos de segmentação de imagens, verificando o desempenho de cada um deles, por meio da aplicação em imagens de radiografia extraoral panorâmica (ortopantomografia), onde o interesse consistiu em verificar se cada algoritmo de segmentação estudado conseguiu extrair características das imagens radiográficas (raio-X panorâmico) e dividir a imagem em suas unidades significativas (dentes). Para alcançar os objetivos propostos, foram estudadas e aplicadas as métricas: *Accuracy*, *Specificity*, *Precision*, *Recall (Sensitivity)* e *F-score*, apresentando os valores encontrados em tabelas e analisando os resultados obtidos por cada método de segmentação.

Para realização do presente trabalho, foi elaborada uma metodologia que consistiu em seis etapas: (1) **Aquisição da imagens**; (2) **Categorização e recorte das imagens do *dataset***; (3) **Anotação das imagens do *dataset***; (4) **Determinação da Região dos Objetos de Interesse - ROI**; (5) **Análise das estatísticas do *dataset* construído**; (6) **Análise de desempenho dos algoritmos de segmentação estudados**.

Após o estudo realizado neste trabalho, pode-se chegar as seguintes conclusões:

Com a aplicação das métricas: *Accuracy*, *Specificity*, *Precision*, *Recall (Sensitivity)* e *F-score*, foi possível concluir que nenhum dos algoritmos estudados conseguiu isolar de maneira eficaz os objetos de interesse (dentes) nas imagens do *dataset* utilizado no presente trabalho. Entretanto, observou-se que os algoritmos de segmentação baseados no Método Niblack e no método Pun, alcançaram os melhores resultados em relação aos outros algoritmos de segmentação analisados. Portanto, identificou-se o método de segmentação de imagem mais apropriado para adaptação ao domínio do problema estudado. Desse modo, cumprindo todos os objetivos específicos propostos.

Comparando os resultados alcançados pelo método de segmentação baseado em Limiar Global e o Método Niblack, verificou-se que o algoritmo de segmentação baseado no Método Niblack obteve melhor desempenho em relação aos demais métodos de segmentação estudados. Sendo assim, observa-se que o processo de segmentação das imagens de raio-X panorâmico, baseado em limiarização, obteve significativa melhoria de desempe-

nho quando utilizado um limiar local variando em diferentes regiões da imagem ao invés de usar um único limiar global para realizar a segmentação das imagens.

Os algoritmos baseados na Divisão e União de regiões e o Método Renyi, apresentaram predominância de verdadeiros negativos e falsos negativos em seus resultados de segmentação, desse modo, obtendo baixo valor de Sensibilidade (*Recall*), o que corresponde a pouca ocorrência de verdadeiros positivos. Logo, indicando que seus resultados não foram melhores do que uma escolha ao acaso.

O algoritmo de segmentação baseado em Crescimento de Região, poderia ter seus resultados melhorados, caso fossem efetuadas as segmentações das imagens com as dimensões originais, conforme foram realizadas com os demais métodos de segmentação analisados. Porém, conforme foi descrito na seção 4.4.1 do Capítulo 4, necessitaria de recursos computacionais mais robustos do que os utilizados na presente pesquisa, evitando horas de processamento para realização das operações de segmentação por meio do algoritmo baseado no Crescimento de Região.

Por fim, a partir da pesquisa realizada é possível concluir que as imagens segmentadas pelos algoritmos de segmentação analisados, necessitam de uma etapa seguinte de pós-segmentação, com isso, os resultados obtidos por cada algoritmo analisado poderiam ser melhorados. Verifica-se também a crescente tendência de se utilizar métodos que aprendem a segmentar, ao invés da utilização de métodos com critérios pré-definidos.

Durante a realização do trabalho, existiram dificuldades a serem superadas, uma dificuldade enfrentada, foi relacionada a determinação do ROI das Imagens, essa etapa do trabalho foi realizado de forma manual por meio do processo de anotação bucal. Entretanto, resultados melhores seriam obtidos por meio da utilização de um método automatizado para delimitar a região dos objetos de interesse nas imagens.

A principal contribuição deste trabalho e que até o momento não se tem registro de estudos, foi a avaliação aprofundada de métodos de segmentação aplicados a imagens de raio-X panorâmico dos dentes, por meio da realização de uma análise detalhada dos resultados, em que foram utilizadas as métricas: Precisão (*Precision*), *Recall* também chamada de Sensibilidade (*Sensitivity*), Taxa de Acerto (*accuracy*) e Especificidade (*Specificity*) para medição de desempenho dos algoritmos de segmentação estudados. Neste sentido, contribuindo para a construção futura de um modelo sistematizado para análise de possíveis

anomalias dentárias e produzindo informações que servirão de base para uma segunda opinião ao diagnóstico médico dentário.

Outra contribuição foi a construção de um *dataset* com 1500 imagens de raio-X panorâmicas, caracterizando um diferencial significativo quando comparado a outros trabalhos, que conta com uma diversidade de imagens, com características distintas e distribuídas em 10 categorias que foram definidas durante a consecução deste trabalho.

Para trabalhos futuros, sugere-se a avaliação de técnicas de segmentação baseadas em aprendizagem por meio de classificação de padrões, utilizando as métricas estudadas nesta pesquisa. Desse modo, pretende-se alcançar melhores resultados separando os dentes dos não dentes nas imagens de raio-X dentais panorâmicas. Outra sugestão seria a criação de um modelo sistematizado para a detecção de anomalias dentárias em imagens de ortopantomografia.

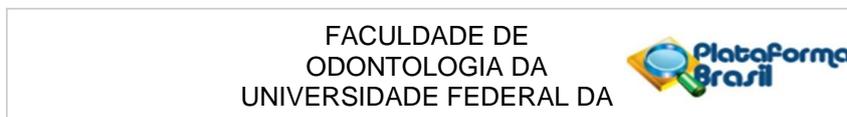
# Aprovação do Parecer Consubstanciado do CEP

## A.1 Primeira página da aprovação do CEP

<p>FACULDADE DE ODONTOLOGIA DA UNIVERSIDADE FEDERAL DA</p> 
<b>PARECER CONSUBSTANCIADO DO CEP</b>
<p><b>DADOS DO PROJETO DE PESQUISA</b></p> <p><b>Título da Pesquisa:</b> DETECÇÃO AUTOMÁTICA DE ANOMALIAS EM ORTOPANTOMOGRÁFIA UTILIZANDO TÉCNICAS DE VISÃO COMPUTACIONAL</p> <p><b>Pesquisador:</b> Luciano Rebouças de Oliveira</p> <p><b>Área Temática:</b></p> <p><b>Versão:</b> 3</p> <p><b>CAAE:</b> 15251213.3.0000.5024</p> <p><b>Instituição Proponente:</b></p> <p><b>Patrocinador Principal:</b> Pró-Reitoria de Pesquisa, Criação e Inovação</p>
<p><b>DADOS DO PARECER</b></p> <p><b>Número do Parecer:</b> 646.050</p> <p><b>Data da Relatoria:</b> 13/05/2014</p> <p><b>Apresentação do Projeto:</b></p> <p>A ortopantomografia ou raio-X panorâmico é um dos exames radiológicos capaz de obter informações fundamentais para diagnóstico de anomalias em medicina dentária. Tal área vem se beneficiando com inovações tecnológicas e científicas, permitindo melhores avaliações em anomalias, tais como: dentes ausentes, estágio de erupção dentária (avaliação do desenvolvimento dos gêmens dentários dos dentes permanentes), agenesia (ausência de dentes), linhas de fraturas ósseas, existência de terceiros molares (dentes siso) e a sua posição nos maxilares, avaliação da massa óssea, existência de restaurações e/ou de próteses dentárias, morfologia do côndilo, dentre outras. O diagnóstico das patologias, no entanto, depende de uma análise cuidadosa do profissional, não sendo esta análise realizada de forma automática, atualmente. O presente projeto, portanto, tem como objetivo contribuir com inovações técnico-científicas utilizando visão computacional para o auxílio na detecção de patologias dentárias, auxiliando o profissional de odontologia, no processo de um diagnóstico mais preciso.</p> <p><b>Objetivo da Pesquisa:</b></p> <p>Descrito no parecer consubstanciado CEP - 561045.</p>
<p><b>Endereço:</b> Av. Araújo Pinho nº 62 - Sala do Comitê de Ética - 4º andar</p> <p><b>Bairro:</b> Canela <b>CEP:</b> 40.110-150</p> <p><b>UF:</b> BA <b>Município:</b> SALVADOR</p> <p><b>Telefone:</b> (71)3283-8969 <b>Fax:</b> (71)3283-8962 <b>E-mail:</b> cepodobahia@ufba.br</p>

Figura A.1: Informações da aprovação da pesquisa pelo CEP

## A.2 Segunda página da aprovação do CEP



Continuação do Parecer: 646.050

**Avaliação dos Riscos e Benefícios:**

Descritos no parecer consubstanciado CEP - 561045.

**Comentários e Considerações sobre a Pesquisa:**

Descritos no parecer consubstanciado CEP - 561045.

**Considerações sobre os Termos de apresentação obrigatória:**

Após atendimento às pendências apresentadas no parecer consubstanciado 561045, o protocolo apresenta os Termos de apresentação obrigatória conforme a legislação em vigor.

**Recomendações:**

Apresentar relatório final da pesquisa.

**Conclusões ou Pendências e Lista de Inadequações:**

Não há pendências.

**Situação do Parecer:**

Aprovado

**Necessita Apreciação da CONEP:**

Não

**Considerações Finais a critério do CEP:**

A plenária deste Colegiado acompanha o parecer do relator.

SALVADOR, 13 de Maio de 2014

---

**Assinado por:**  
**Sandra de Cássia Santana Sardinha**  
**(Coordenador)**

**Endereço:** Av. Araújo Pinho nº 62 - Sala do Comitê de Ética - 4º andar  
**Bairro:** Canela **CEP:** 40.110-150  
**UF:** BA **Município:** SALVADOR  
**Telefone:** (71)3283-8969 **Fax:** (71)3283-8962 **E-mail:** cepodobahia@ufba.br

Página 2 de 02

Figura A.2: Continuação da aprovação da pesquisa pelo CEP

---

## Referências Bibliográficas

---

- ABAK, A.; ; MAM, T. T.; BARIS, U.; SANKUR, B. The performance evaluation of thresholding algorithms for optical character recognition. In: INTL. CONF. DOCUMENT ANAL. RECOG. ICDAR. [S.l.], 1997. p. 697–700.
- ALVARES, L. C.; TAVANO, O. Anomalias dentárias do complexo maxilo mandibular. *Curso de Radiologia em Odontologia*, v. 5, p. 190–205, 2002.
- BANSAL, S. *Dental X Ray Segmentation and Tooth Classification*. [S.l.], 2012.
- BUSHBERG, T.; SEIBERT, J.; LEIDHOLDT, E.; BOONE, J. *The Essential Physics Of Medical Imaging*. Second edition. [S.l.: s.n.], 2002.
- DALAL, N.; TRIGGS, B.; SCHMID, C. Human detection using oriented histograms of flow and appearance. In: EUROPEAN CONFERENCE ON COMPUTER VISION. [S.l.], 2006.
- DIGHE, S.; SHRIRAM, R. Preprocessing, segmentation and matching of dental radiographs used in dental biometrics. *International Journal of Science and Applied Information Technology*, v. 1, n. 2, 2012.
- EISEN, M. B.; SPELLMAN, P. T.; BROWN, P. O.; BOTSTEIN, D. Cluster analysis and display of genome-wide expression patterns. *Proc. Natl. Acad. Sci.*, v. 95, n. 25, p. 14863–14868, 1998.
- ESSIG, M. E. M. G. dental x-rays. *Susan Van Houten, RN, BSN, MBA*, v. 8, 2008.
- ESSIG MS, E. M. G. Dental x-rays. *Healthwise*, 8 2008.
- FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters 27 (2006) 27(8):861–874*, 2006.
- FEHRENBACH; MARGARET, J.; BATH-BALOGH; MARY. *ANATOMIA, HISTOLOGIA E EMBRIOLOGIA DOS DENTES E ESTRUT OROFACIAIS*. [S.l.: s.n.], 2012.
- FREJLICHOWSKI, D.; WANAT, R. Application of the laplacian pyramid decomposition to the enhancement of digital dental radiographic images for the automatic person identification. In: IMAGE ANALYSIS AND RECOGNITION 7TH INTERNATIONAL CONFERENCE. [S.l.], 2010.
- GONZALES, R. C.; WOODS, R. E. *Digital Image Processing*. 3rd ed. ed. [S.l.: s.n.], 2008.

HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics, SMC*, v. 3, n. 6, p. 610–621, 1973.

HU, M. K. Visual pattern recognition by moment invariants. *IRE TRANSACTIONS ON INFORMATION THEORY*, 1962.

JANTSCH, G. E.; FELIPUSSI, S. C. Estudo de técnicas de pseudocoloração aplicadas a imagens radiográficas - uma abordagem aprimorada. *SCIENTIA PLENA*, v. 8, n. 11, 2012.

KAMEL, M.; ZHAO, A. Extraction of binary character/graphics images from grayscale document images. *CVGIP: Graphical Models and Image Processing*, v. 55, p. 203–217, 1993.

KREICH, E. M.; LEAL, G. A.; SLUSARZ, P. A. A.; SANTINI, R. M. Imagem digital na odontologia. *UEPG Ciências Biológicas e da Saúde, Ponta Grossa*, v. 11, n. 3, p. 53–61, 2005.

KUMAR, A.; GHOSH, S.; LOGANI, A. Occurrence of diversity in dental pattern and their role in identification in indian population: An orthopantomogram based pilot study. *Journal of Forensic Dental Sciences*, v. 6, p. 42–45, 2014.

LAMPERT, C.; NICKISCH, H.; HARMELING, S. Learning to detect unseen object classes by between-class attribute transfer. computer vision and pattern recognition. In: *IEEE COMPUTER SOCIETY CONFERENCE ON*, 0:951–958. [S.l.], 2009.

LI, C. et al. A level set method for image segmentation in the presence of intensity inhomogeneities with application to mri. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, v. 20, n. 7, 2011.

LIRA, P. H. M.; GIRALDI, G. A.; NEVES, L. A. P.; FEIJÓO, R. A. Dental r-ray image segmentation using texture recognition. *IEEE LATIN AMERICA TRANSACTIONS*, v. 12, n. 4, 2014.

NASSAR, D. E. M.; CHAUDHRY, F. U.; AMMAR, H. H. On performance evaluation of image segmentation algorithms: Success is not all or none. *1st Int. Comput. Eng. Conf., Cairo, Egypt*, p. 354–359, 2004.

NEVILLE, B.; DAMM, D. D.; ALLEN, C. M. Anomalias dentárias. In: \_\_\_\_\_. [S.l.]: Patologia Oral e Maxilofacial, 2004. cap. 2, p. 41–103.

NIBLACK, W. *An introduction to digital image processing*. [S.l.]: Strandberg Publishing Company Birkerød, 1985. 215 p.

OLIVEIRA, J. P. R. de. *Caries Detection in Panoramic Dental X-ray Images*. Dissertação (Mestrado) — Department of Computer Science of University of Beira Interior, Covilhã, Portugal, 2009.

- OSUNA, E. E.; FREUND, R.; GIROSI, F. Support vector machines: Training and applications. *Massachusetts Institute of Technology*, n. 144, 1997.
- PROVOST, F.; FAWCETT, T.; KOHAVI, R. The case against accuracy estimation for comparing induction algorithms. *Proceedings of the Fifteenth International Conference on Machine Learning*, p. 445, 1998.
- PUN, T. Entropic thresholding: A new approach. *Comput. Graph. Image Process*, v. 16, p. 210–239, 1981.
- RAD, A. E.; RAHIM, M. S. M.; NOROUZI, A. Digital dental x-ray image segmentation and feature extraction. *TELKOMNIKA*, v. 11, n. 6, p. 3109–2114, 2013.
- RIJSBERGEN, K. van. *INFORMATION RETRIEVAL*. 2. ed. [S.l.]: Butterworth, 1979.
- SAARI, P. *medicine and disease - who discovered the x ray?* Uxl-gale. [S.l.: s.n.], 2001.
- SAHOO, P.; WILKINS, C.; YEAGER, J. Threshold selection using renyis entropy. *Pattern Recogn*, v. 30, p. 71–84, 1997.
- SAID, E. H.; NASSAR, D. E. M.; FAHMY, G.; AMMAR, H. H. Teeth segmentation in digitized dental x-ray films using mathematical morphology. *IEEE TRANSACTIONS ON INFORMATION FORENSICS AND SECURITY*, v. 1, n. 2, 2006.
- SENTHILKUMARAN, N. Fuzzy logic approach to edge detection for dental x-ray image segmentation. *(IJCSIT) International Journal of Computer Science and Information Technologies*, Vol. 3 (5), 2012.
- SEZGIN, M.; SANKUR, B. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, v. 13, n. 1, p. 146–165, 2004.
- SHANNON, C. A mathematical theory of communication. *The Bell System Technical Journal*, v. 27, p. 379–423, 623–656, 1948.
- SINGH, O. I.; SINAM, T.; JAMES, O.; SINGH, T. R. Local contrast and mean thresholding in image binarization. *International Journal of Computer Applications*, v. 51, n. 6, p. 4–10, 2012.
- SINGH, T. R.; ROY, S.; SINGH, O. I.; SINAM, T.; SINGH, K. M. A new local adaptive thresholding technique in binarization. *IJCSI International Journal of Computer Science Issues*, v. 8, n. 2, p. 271–277, 2011.
- SOLOMON, C.; BRECKON, T. *Fundamentos de Processamento Digital de Imagens: uma abordagem prática com exemplos em Matlab*. [S.l.]: LTC – Livros Técnicos e Científicos Editora Ltda, 2013.
- TOMMASI, A. F. *Diagnóstico em patologia bucal*. 3. ed. [S.l.: s.n.], 2002.

TSALLIS, C. Possible generalization of boltzmann-gibbs statistics. *Journal of Statistical Physics*, v. 52, p. 479–487, 1988.

VISA, S.; RAMSAY, B.; RALESCU, A.; KNAAP, E. van der. Confusion matrix-based feature selection. *Proceedings of The 22nd Midwest Artificial Intelligence and Cognitive Science Conference 2011*, p. 120–127, 2011.

WANAT, R. A problem of automatic segmentation of digital dental panoramic x-ray images for forensic human identification. *The 15th Central European Seminar on Computer Graphics*, 2011. Faculty of Computer Science and Information Technology.

WIENER, N. *EXTRAPOLATION, INTERPOLATION, AND SMOOTHING OF STATIONARY TIME SERIES*. [S.l.]: THE M.I.T. PRESS. MASSACHUSETTS INSTITUTE OF TECHNOLOGY, 1949.

YAP, P. T.; RAVEENDRAN, P.; ONG, S. H. Chebyshev moments as a new set of moments for image reconstruction. In: *PROCEEDINGS, I. I. J. C. on N. N.* (Ed.). [S.l.: s.n.], 2001. p. 2856–2860.

*Avaliação de métodos de segmentação aplicados a imagens de raio-X panorâmico dos dentes*

Gil Jader Oliveira da Silva

Salvador, 24 de Fevereiro de 2015.