



UNIVERSIDADE FEDERAL DO CEARÁ

CAMPUS SOBRAL

DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE

COMPUTAÇÃO

MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

FRANCISCO DANILO DA SILVA LIMA

SEGMENTAÇÃO DE LESÕES PERIAPICAIS EM IMAGENS ODONTOLÓGICAS

RADIOGRÁFICAS DIGITAIS UTILIZANDO MODELOS DE CONTORNO ATIVO

COM INICIALIZAÇÃO AUTOMÁTICA

SOBRAL-CE

2017

FRANCISCO DANILO DA SILVA LIMA

SEGMENTAÇÃO DE LESÕES PERIAPICAIS EM IMAGENS ODONTOLÓGICAS
RADIOGRÁFICAS DIGITAIS UTILIZANDO MODELOS DE CONTORNO ATIVO COM
INICIALIZAÇÃO AUTOMÁTICA

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica e de Computação do Programa de Pós-Graduação em Engenharia Elétrica e de Computação do *Campus* Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e de Computação. Área de Concentração: Algoritmos e Computação Distribuída

Orientador: Prof. Dr. Iális Cavalcante de Paula Júnior

SOBRAL-CE

2017

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

L698s Lima, Francisco Danilo da Silva.

Segmentação de Lesões Periapicais em Imagens Odontológicas Radiográficas Digitais utilizando Modelos de Contorno Ativo com Inicialização Automática / Francisco Danilo da Silva Lima. – 2017. 86 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Campus de Sobral, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Sobral, 2017.

Orientação: Prof. Dr. Iális Cavalcante de Paula Júnior.

1. Modelos de Contorno Ativo. 2. Morfologia Matemática. 3. Filtro de Gabor. 4. Segmentação. 5. Periapical Odontologia. I. Título.

CDD 621.3

FRANCISCO DANILO DA SILVA LIMA

SEGMENTAÇÃO DE LESÕES PERIAPICAIS EM IMAGENS ODONTOLÓGICAS
RADIOGRÁFICAS DIGITAIS UTILIZANDO MODELOS DE CONTORNO ATIVO COM
INICIALIZAÇÃO AUTOMÁTICA

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica e de Computação do Programa de Pós-Graduação em Engenharia Elétrica e de Computação do *Campus* Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e de Computação. Área de Concentração: Algoritmos e Computação Distribuída

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Iális Cavalcante de Paula
Júnior (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Jarbas Joaci de Mesquita Sá Junior
Universidade Federal do Ceará (UFC)

Prof. Dr. Rodrigo de Melo Souza Veras
Universidade Federal do Piauí (UFPI)

Dedico este trabalho aos meus queridos pais José e Maria, pois são eles os maiores motivadores de meus estudos; à minha amada Joanna Trycia, por seu amor e carinho; às minhas irmãs Alexandra e Alessandra; e à minha sobrinha Yanna Maria.

AGRADECIMENTOS

Ao concluir mais esta etapa de estudos na minha vida acadêmica, minha gratidão a Deus, por dar-me força no momento oportuno e saúde.

À minha grande amiga e companheira Joanna Trycia, pelo carinho e pela dedicação e motivação nesta caminhada.

Ao meu orientador, Prof. Dr. Iális Cavalcante de Paula Júnior, pela paciência e pelo incentivo para realização deste trabalho e pelos conselhos para meu crescimento com a pesquisa científica.

Aos professores participantes da banca examinadora, Prof. Dr. Jarbas Joaci de Mesquita Sá Junior (UFC) e Prof. Dr. Rodrigo de Melo Souza Veras (UFPI), pelo tempo, pelas valiosas colaborações e sugestões.

Aos professores do curso de Odontologia da UFC / *Campus* Sobral, Prof. Me. Filipe Nobre Chaves e Prof. Dr. Marcelo Bonifácio da Silva Sampieri, pela parceria e pelas contribuições no desenvolvimento deste trabalho.

A todos que direta ou indiretamente contribuíram para a realização desta pesquisa.

"Cultivar a ciência pela utilidade prática, imediata, é desvirtuar a alma da própria ciência."

(Malba Tahan)

RESUMO

A imagem é utilizada como uma das principais ferramentas de diagnóstico nas mais diversas áreas da saúde. Em muitos casos os diagnósticos guiados por imagem são de suma importância para revelar a causa de sintomas, acompanhar o tratamento de doenças e definir o tipo de tratamento adequado. Dentre as formas de aquisição de imagens médicas, têm-se as radiografias através de raios-X. Na área da Odontologia, as radiografias periapicais possuem um papel importante na obtenção de diagnósticos de patologias orais em pacientes. No entanto, no processo de realização do exame para o diagnóstico, muitas vezes a representação da estrutura anatômica tridimensional da face é feita em imagens bidimensionais, prejudicando a interpretação por parte do cirurgião-dentista. Além disso, as propriedades físicas de lesões e de tecidos da região maxilofacial podem não estar completamente correlacionadas com seus limites anatômicos, tornando a segmentação de tais lesões um procedimento bastante complexo e especializado, que muitas vezes requer uma interação manual considerável. O presente estudo propõe a utilização do Modelo de Contorno Ativo Localizado Baseado em Região, a partir de uma máscara inicial obtida, para segmentar lesões periapicais. Técnicas da Morfologia Matemática e filtros de Gabor são utilizados para identificar pontos para inicialização e melhor ajuste da máscara inicial do Modelo de Contorno Ativo (MCA). Os resultados das segmentações são comparados com o *Ground Truth* (GT), obtido por marcações das lesões por especialistas. Para uma avaliação quantitativa da metodologia proposta, são utilizadas métricas como coeficiente de similaridade de Dice, precisão e acurácia, que estabelecem a relação de proximidade da região segmentada com o resultado desejado. A média obtida com o coeficiente de Dice foi superior a 0,7 com desvio padrão inferior a 0,01. Em geral, os resultados mostraram-se promissores para o cumprimento dos objetivos e no avanço dos estudos na área de segmentação aplicada à saúde.

Palavras-chave: Modelos de Contorno Ativo. Morfologia Matemática. Filtro de Gabor. Segmentação. Periapical. Odontologia

ABSTRACT

The image is used as one of the main diagnostic tools in several areas of health. In many cases, imaging-guided diagnoses are of paramount importance to reveal the cause of symptoms, to follow disease treatment as well as to define the right kind of treatment. For instance, the radiography, amongst the most popular medical imaging techniques, uses a beam of X-rays in order to create the image. When it comes to Dentistry, periapical radiographs play an important role in obtaining diagnoses of oral pathologies in patients. However, in the process of performing the diagnostic exams, the representation of the three-dimensional anatomical structures of the face is often created from two-dimensional images, damaging the interpretation by the dental surgeon. Moreover, the physical properties of lesions and tissues of the maxillofacial region may not be fully correlated with their anatomical limits, making segmentation of such lesions a very complex and specialized procedure, which often requires considerable manual interaction. The present study proposes the use of the Localizing Region-Based Active Contours, from an initial mask, to segment periapical lesions. Mathematical Morphology Techniques and Gabor filter are used to identify points for initialization as well as fine-tune the MCA's initial mask adjustment. For a quantitative evaluation of the proposed approach, metrics such as Dice Coefficient, precision and accuracy are used to establish the proximity relation of the segmented region with the desired result. The average for Dice Coefficient was higher than 0.7 and standard deviation of less than 0.01. In general, the results were promising towards the accomplishment of the objectives and the progress of future studies in the area of image segmentation applied to health.

Keywords: Active Contour Models. Mathematical Morphology. Gabor Filter. Segmentation. Periapical radiograph. Odontology.

LISTA DE FIGURAS

Figura 1 – Resultados obtidas a partir da aplicação do Modelo de (CHAN; VESE, 2001).	33
Figura 2 – Exemplo de aplicação do filtro de Gabor na imagem original 2a. Em 2a, 2b, 2c e 2d tem-se o resultado da magnitude do filtro para as orientações iguais $0, \pi/4, \pi/2$ e $3\pi/4$, respectivamente.	40
Figura 3 – Exemplo de imagem antes da segmentação, de um GT e do resultado de segmentação. Em 3c pode-se observar alguns tipos de erros: 1 - Outras regiões incorretamente adicionadas; 2 - partes do fundo foram adicionadas; em 3 e 4 regiões de bordas e regiões internas não segmentadas, respectivamente.	41
Figura 4 – 4a é imagem original; 4b é o <i>ground truth</i> ; 4c, 4d e 4e são segmentações realizadas com Coeficiente de Similaridade de Dice igual a 0,6124, 0,8528 e 0,9895, respectivamente.	43
Figura 5 – Fluxograma explicativo da metodologia proposta. 5a mostra o processo para obtenção da máscara de entrada do MCA Localizado; e em 5b tem-se a etapa do processo de segmentação.	44
Figura 6 – 6a, 6b, 6c e 6d são exemplares de imagens de radiografias periapicais utilizadas neste estudo.	45
Figura 7 – 7a e 7c são imagens com a marcação realizada pelo especialista; 7b e 7d representam os GTs binarizados a partir das respectivas marcações.	46
Figura 8 – Histograma da região que compreende uma lesão periapical (vermelho) e da região dos elementos dentários (azul).	48
Figura 9 – Alguns exemplos dos resultados gerados após a aplicação em sequência da gaussiana, do melhoramento de contraste e do resultado da binarização. 9a e 9e são imagens originais; 9b e 9f são resultantes da aplicação do filtro gaussiano; 9c e 9g mostram o resultado do melhoramento de contraste baseado em PMR; e, por fim, 9d e 9h o resultado após a binarização.	49
Figura 10 – Máscaras iniciais. 10a e 10b foram obtidas a partir das imagens 9a e 9e, respectivamente.	50
Figura 11 – Pontos da estrutura anatômica do periápice dentário, espaços interdentais e faixa oclusal.	50

Figura 12 – Exemplos de componentes geradas a partir da aplicação do filtro de Gabor. 12a, 12b , 12c e 12d são componentes com $\theta = 0^\circ$; e 12e, 12f , 12g e 12h são componentes com $\theta = 90^\circ$	51
Figura 13 – Gráficos com o cálculo de frequência média de zeros e os pontos de máximo para cada uma das componentes obtidas com a aplicação do filtro de Gabor nas imagens 6b e 6d da Figura 6 (pág. 45) e também nas imagens 9a e 9e da Figura 9 (pág. 49).	53
Figura 14 – 14a, 14b, 14c e 14d mostram a identificação da linha base (em vermelho) da oclusal do dentes.	53
Figura 15 – Resultados obtidos a partir da identificação da linha da faixa oclusal. Em 15a tem-se todos os pontos incisais do dentes; Em 15b união dos <i>pixels</i> iguais a zeros da duas componentes binarizadas. 15c mostra a imagem original com os gráficos da regressão a partir dos pontos incisais e da projeção da integral realizada para linhas (colunas) ortogonais à linha base da oclusal com os picos encontrados; 15d apresenta as linhas interdentais e os pontos incisais intermediários e radiculares encontrados.	54
Figura 16 – Gráficos das medidas: Acurácia (16a), Precisão (16b) e Sensibilidade (16c) obtidas para cada uma das segmentações realizadas em relação ao <i>GT</i>	57
Figura 17 – Gráfico do Coeficiente de Similaridade de Dice obtido para cada uma das segmentações realizadas em relação ao <i>GT</i> . Os valores de mínimo (vermelho) e máximo (verde) obtidos para essa medida foram iguais a 0,6150 e 0,8912, respectivamente.	58
Figura 18 – Melhores segmentações em relação à sobreposição das marcações do especialistas. Para 18a, 18d, 18g foram obtidos os valores do CSD iguais a 0,8634, 0,8879 e 0,8912, respectivamente. Em 18b, 18e, 18h são ampliações da área da segmentação. Em 18c, 18f, 18i são apresentadas as sobreposições com o resultado final em uma imagem binária da segmentação e o <i>GT</i> : a área em branco corresponde a intersecção do <i>GT</i> com a região segmentada; na cor magenta áreas do <i>GT</i> que não foram segmentadas e na cor verde regiões que não pertenciam ao <i>GT</i> que foram segmentadas.	60

Figura 19 – Piores segmentações em relação à sobreposição das marcações do especialistas. Para 19a, 19d, 19g foram obtidos os valores do CSD iguais a 0,6523, 0,6999 e 0,6905, respectivamente. Em 19b, 19e, 19h são ampliações da área da segmentação. Em 19c, 19f, 19i são apresentadas as sobreposições com o resultado final em uma imagem binária da segmentação e o <i>GT</i> : a área em branco corresponde a intersecção do <i>GT</i> com a região segmentada; na cor magenta áreas do <i>GT</i> que não foram segmentadas e na cor verde regiões que não pertenciam ao <i>GT</i> que foram segmentadas.	61
Figura 20 – Segmentações inesperadas com piores valores para CSD. Para 20a o CSD foi igual a 0,6729 e para 20c igual 0,6150.	62
Figura 21 – Radiografia Panorâmica.	72
Figura 22 – Exemplos de radiografias intrabucais.	73
Figura 23 – Aparelho radiográfico periapical tipo fixo: A - tubo, B - cabeçote, C - braço, D - cabeça do tubo, E - painel de controle	74
Figura 24 – Técnica do Paralelismo. A imagem ilustra a relação paralela entre o longo eixo do dente e o receptor de imagem. O raio central é direcionado perpendicular a cada um. Esta técnica minimiza a distorção da imagem, mas requer um posicionador.	75
Figura 25 – Posicionador radiográfico destinados à técnica do paralelismo.	76
Figura 26 – Técnica da bisettriz. O feixe de raio x deve incidir perpendicularmente ao plano bissetor formado pelos planos do dente e do filme.	77
Figura 27 – Planos e pontos de referência para o correto posicionamento do paciente. Em 27a tem-se: 1 - Plano de Camper; 2- Plano oclusal/incisal e 3 - Plano de horizontal. Em 27b: 4 – Plano sagital mediano e 5 - Linha bipuplilar. Em 27c: 6 - Linha trago-comissura labial; 7 - Linha trago-comissura palpebral e 8 – Sulco mentolabial.	78
Figura 28 – Técnica do paralelismo para incisivos centrais e laterais superiores. 28a - O ponto de entrada do raio central é direcionado ao lábio superior, na linha média, logo abaixo do septo nasal (ápice nasal); 28b - Imagem radiográfica de incisivos superiores.	81

Figura 29 – Técnica do paralelismo para caninos superiores. 29a - O raio central deve ser orientado para entrar na região do lábio superior a cerca de 1 cm da linha média na região da asa do nariz; 29b - Imagem radiográfica do canino superior	81
Figura 30 – Técnica do paralelismo para pré-molares e molares superiores. 30a - O raio central deve passar pelo centro da raiz do segundo pré-molar. Este ponto geralmente está abaixo da pupila do olho; 30b - Imagem radiográfica de pré-molares e molares superiores	82
Figura 31 – Técnica do paralelismo para incisivos centrais e laterais inferiores. 31a - O ponto de entrada do raio central deve estar na bochecha abaixo do canto do olho e o zigoma na posição do segundo molar superior; 31b - Imagem radiográfica de incisivos inferiores.	83
Figura 32 – Técnica do paralelismo para caninos inferiores. 32a - O ponto de entrada é praticamente perpendicular a asa do nariz, sobre a posição do canino e cerca de 3 cm acima da borda inferior da mandíbula; 32b - Imagem radiográfica do canino inferior.	83
Figura 33 – Técnica do paralelismo para pré-molares e molares inferiores. 33a O feixe raio central deve ser posicionado abaixo da pupila e cerca de 3 cm acima da base da mandíbula; 33b Imagem radiográfica de pré-molares e molares inferiores.	84

LISTA DE TABELAS

Tabela 2 – Matriz de confusão para segmentação esperada e predita.	42
Tabela 3 – Média e desvio padrão das medidas para todas as segmentações do conjunto de imagens.	58
Tabela 4 – Posicionamento da cabeça do paciente para técnica da bisettriz na maxila: PSM perpendicular ao plano horizontal e plano de Camper paralelo ao plano horizontal	80
Tabela 5 – Posicionamento da cabeça do paciente para técnica da bisettriz na mandíbula: perpendicular ao plano horizontal e linha trago-comissura labial paralela ao plano horizontal.	80

LISTA DE ABREVIATURAS E SIGLAS

ATM	Articulação Temporomandibular
CSD	Coefficiente de Similaridade de Dice
FP	Falso Positivo
GFV	Fluxo do Vetor Gradiente
GT	<i>Ground Truth</i>
IC	Inteligência Computacional
MCA	Modelo de Contorno Ativo
OMS	Organização Mundial da Saúde
PDI	Processamento Digital de Imagem
PMR	Processamento Morfológico Rotacional
VC	Visão Computacional
VP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Motivação	20
1.2	Estado da Arte	22
1.3	Objetivos	24
<i>1.3.1</i>	<i>Objetivos Específicos</i>	24
1.4	Organização	24
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Segmentação	25
<i>2.1.1</i>	<i>Segmentação por descontinuidade</i>	26
<i>2.1.1.1</i>	<i>Detecção de Pontos e linhas</i>	27
<i>2.1.1.2</i>	<i>Detecção de borda</i>	28
<i>2.1.2</i>	<i>Segmentação por similaridade</i>	28
<i>2.1.2.1</i>	<i>Limiarização</i>	28
<i>2.1.2.2</i>	<i>Crescimento de Região</i>	29
<i>2.1.3</i>	<i>Outros métodos de segmentação</i>	30
2.2	Modelos de Contorno Ativo - MCA	30
<i>2.2.1</i>	<i>Versão Clássica</i>	30
<i>2.2.2</i>	<i>Modelo de Contorno Ativo Baseado em Região (Modelo de Chan-Vese)</i>	31
<i>2.2.3</i>	<i>Modelo de Contorno Ativo Localizado Baseado em Região</i>	32
2.3	Morfologia Matemática	34
<i>2.3.1</i>	<i>Erosão e Dilatação em imagens binárias</i>	34
<i>2.3.2</i>	<i>Abertura e Fechamento em imagens binárias</i>	35
<i>2.3.3</i>	<i>Erosão e Dilatação em escala de cinza</i>	36
<i>2.3.4</i>	<i>Abertura e Fechamento em escala de cinza</i>	36
<i>2.3.5</i>	<i>Transformada Top-Hat</i>	36
<i>2.3.6</i>	<i>Melhoramento de Contraste baseado com Processamento Morfológico Rotacional (PMR)</i>	37
2.4	Filtro de Gabor	38
2.5	Avaliação da Segmentação	39
<i>2.5.1</i>	<i>Matriz de Confusão - MC</i>	41

2.5.2	<i>Coeficiente de Similaridade de Dice (Coeficiente de Similaridade de Dice (CSD))</i>	42
3	METODOLOGIA	44
3.1	Aquisição das Imagens	44
3.2	Obtenção do <i>Ground Truth</i> - GT	45
3.3	Obtenção da Máscara Inicial	46
3.4	Deteção de Pontos Radiculares e Ajuste da Máscara Inicial	48
3.5	Aplicação do MCA	54
3.6	Avaliação	55
4	RESULTADOS E DISCUSSÕES	56
4.1	Métricas Obtidas	56
4.1.1	<i>Resultados - Análise Qualitativa</i>	59
4.1.1.1	<i>Segmentação de Lesões Inesperadas</i>	59
4.1.2	<i>Conclusão dos Resultados</i>	63
5	CONSIDERAÇÕES FINAIS, CONTRIBUIÇÕES E TRABALHOS FUTUROS	64
5.1	Considerações Finais	64
5.2	Trabalhos Futuros	65
	REFERÊNCIAS	66
	APÊNDICES	71
	APÊNDICE A – Radiografias Odontológicas	71
A.1	Radiografias extrabucais	71
A.2	Radiografias intrabucais	72
	APÊNDICE B – Radiografias Periapicais	74
B.1	Técnica do Paralelismo	75
B.2	Técnica da Bisetriz	77
B.3	Posicionamento do Paciente	78
B.4	Colocação de Receptor	78
B.5	Angulação da Cabeça do Tubo	79
B.5.1	<i>Angulação Horizontal</i>	79
B.5.2	<i>Angulação vertical</i>	79
B.6	Qualidade da radiografia	84

1 INTRODUÇÃO

A imagem durante anos desempenha um papel importante nas mais diversas áreas da saúde como umas das principais ferramentas de diagnóstico. São inúmeros os casos em que os diagnósticos guiados por imagem revelam a causa subjacente de sintomas e, além disso, podem constituir uma base para a investigação científica. E ainda, a imagem ajuda a documentar a presença ou ausência de doença, levando a novas investigações histológicas, imunológicas, de natureza molecular ou genética. Finalmente, a imagem é sistematicamente empregada para identificação de variações anatômicas normais com o objetivo de evitar o tratamento desnecessário ou inadequado (MUPPARAPU; NADEAU, 2016; Institute of Medicine and National Academies of Sciences, Engineering, and Medicine, 2015).

Dentre as formas de aquisição de imagens médicas, tem-se as radiografias através de raios-X. Sua utilidade para fins médicos foi reconhecida em 8 de novembro de 1895, quando o cientista Wilhelm C. Röntgen obteve a imagem radiográfica da mão de sua esposa. Durante mais de cem anos, os raios-X desempenharam um papel importante na obtenção de imagens da estrutura interna de objetos e estruturas do corpo humano de forma não destrutiva. Sete décadas após sua descoberta, o mesmo método simples de projeção bidimensional permaneceu o estado da arte para imagens médicas. (BEHLING, 2015; BIRKFELLNER, 2014; WHITE, 2013; GONZALEZ; WOODS, 2008).

Os raios-X são gerados usando um tubo de vácuo com um cátodo e um ânodo. O cátodo é aquecido, causando a liberação de elétrons livres. Estes elétrons circulam em alta velocidade para o ânodo carregado positivamente. Quando os elétrons atingem um núcleo, a energia é liberada sob a forma de radiação de raios-X. Ao colocar o paciente entre uma fonte de raios-X e um filme sensível à energia de raios-X, obtém-se uma imagem radiográfica da região onde os raios incidiram. (BIRKFELLNER, 2014; WHITE, 2013; GONZALEZ; WOODS, 2008). Mais detalhes da visão histórica do desenvolvimento do tubo de raio-x e do gerador, seu funcionamento, métricas para validação e interfaces, incluindo as principais conquistas que levam ao atual estado tecnológico e econômico desse campo de pesquisa, podem ser encontrados em Behling (2015).

A história de radiografias através de raios-X sendo aplicadas à Odontologia, também remonta ao ano de 1895, no qual, o odontólogo alemão Frederic Otto Walkhoff fez uma radiografia dentária em sua própria boca, poucas semanas após a descoberta dos raios-X por Wilhelm Rontgen. Antes do final de 1896, Otto Walkhoff e Fritz Giesel abriram o primeiro laboratório de

radiologia dentária. (WHITE, 2013; STELT, 2005; CRUSE; BELLIZZI, 1980).

O uso da radiografia convencional baseada em filmes tem dominado a prática dentária há muitos anos. Embora as radiografias planares sejam consideradas obsoletas pelo surgimento da imagem 3D na medicina, tais radiografias continuam a ser utilizadas de forma sistemática na radiologia oral e maxilofacial. As radiografias periapicais intra-orais e as radiografias de mordida, que pertencem à classe de radiografias em duas dimensões, possuem um papel importante na obtenção de diagnósticos de lesões na cavidade bucal e continuam sendo o padrão ouro para avaliação de muitas patologias orais em pacientes (MUPPARAPU; NADEAU, 2016; MAKDISSI; PAWAR, 2013; WHITE, 2013; STELT, 2005).

Com o advento das tecnologias computacionais - Processamento Digital de Imagem (PDI) e Visão Computacional (VC) aliadas à Inteligência Computacional (IC) - e as demandas crescentes por diagnósticos guiados por imagens médicas de forma rápida e precisa, surgiram nas últimas três décadas uma multiplicidade de trabalhos de pesquisa relacionados ao diagnóstico auxiliado por computador. Tais trabalhos têm possibilitado que as ideias e técnicas de Processamento de Imagem e Visão Computacional sejam utilizadas em uma variedade de aplicações práticas nas mais diversas áreas. Ressalta-se nesse contexto a área de imagens médicas, na qual o profissional da saúde terá como complemento de seus conhecimentos e de sua experiência o diagnóstico auxiliado por computador. A proposta é que os sistemas de VC sejam aplicados com uma abordagem mais focada e com soluções altamente especializadas para certos tipos de aplicações (Institute of Medicine and National Academies of Sciences, Engineering, and Medicine, 2015; BIRKFELLNER, 2014; GONZALEZ; WOODS, 2008; BLAKE, 2000)

Na área da Odontologia, com os avanços em curso das ferramentas computacionais, o campo da radiologia oral e maxilofacial, a partir da década de 1980, também alia-se à eletrônica e mais recentemente à computação. A radiografia digital passou a ser uma realidade entre os profissionais da área da Odontologia, possibilitando uma melhor visualização da anatomia da face, o que resultou em uma melhor detecção e favoreceu diagnóstico, tratamento e monitoramento de lesões e doenças bucais (MUPPARAPU; NADEAU, 2016; WHITE, 2013; MAKDISSI; PAWAR, 2013; STELT, 2005).

A radiografia digital é um tipo de imagem de raios-X que usa sensores digitais de raios-X para substituir o filme fotográfico tradicional de raios-X, produzindo imagens aprimoradas de dentes, gengivas e outras estruturas e condições orais que podem ser analisadas e manipuladas utilizando um computador. As imagens digitais são obtidas por um dos dois

métodos: (1) digitalizando filmes de raios-X; ou (2) ao ter os raios-X que incidem no paciente, o atravessam e caem diretamente em dispositivos, por exemplo uma tela de fósforo, que convertem os raios-X em luz. O sinal de luz, por sua vez, é capturado por um sistema de digitalização sensível à luz (MUPPARAPU; NADEAU, 2016; WHITE, 2013; GONZALEZ; WOODS, 2008).

As principais vantagens de um sistema de VC aplicado à radiologia oral e maxilofacial consistem na diminuição da dose de exposição, eliminação do processo químico de revelação/fixação, na possibilidade de manipulação das imagens, como alteração de contraste, brilho, alteração de cores e formas. E ainda, um sistema de VC possui ferramentas de Processamento de Imagem como filtros, realce de bordas para evidenciar uma região anatômica de interesse etc., que tornam possível uma nova perspectivas no diagnóstico por imagens, pois são alternativas viáveis para uma melhor detecção, observação e compreensão das informações contidas nas imagens. (WHITE, 2013; STELT, 2005; MOL, 2004)

Segundo Yoo (2004), os problemas inerentes ao Processamento de Imagens Médicas são divididos em: **filtragem**: são as tarefas básicas envolvidas na filtragem e pré-processamento dos dados antes da detecção e análise serem realizadas pela máquina ou pelo operador humano; **segmentação**: consiste na tarefa de particionar uma imagem em regiões contíguas com propriedades semelhantes e coesivas; e, **registro**: definida como a tarefa de agrupar os múltiplos fluxos de dados ou imagens, permitindo a fusão e análise de informações diferentes.

Este trabalho tem como foco a etapa de segmentação de lesões periapicais em imagens de radiográficas digitais. Nesse sentido, propõe-se a aplicação de técnicas para segmentação deste tipo de lesão e que servirão para auxiliar os profissionais da área de Odontologia na análise de imagens radiográficas periapicais.

Essa etapa se faz necessária, pois no processo de realização dos exames para o diagnóstico, muitas vezes a representação das estruturas anatômicas tridimensionais da face é feita em imagens bidimensionais, prejudicando a interpretação por parte do cirurgião-dentista (TURGEON; LAM, 2016; SUWA *et al.*, 2001). Além disso, as propriedades físicas de lesões e de tecidos da região maxilofacial podem não estar completamente correlacionadas com seus limites anatômicos, tornando a segmentação de tais lesões um procedimento bastante complexo e especializado, que muitas vezes requer uma interação manual considerável. Portanto, a segmentação automática de lesões periapicais, proposta neste trabalho, pode ser considerada bastante atraente como aplicação.

Este trabalho também se torna interessante como aplicação no acompanhamento

e evolução durante a fase de tratamento das lesões identificadas. Pois com a segmentação e obtenção das áreas de interesse, será possível realizar medições quantitativas, como calcular a área da lesão para verificar crescimento ou redução dos achados.

Vale ressaltar que a detecção e a análise de lesões e outras patologias são, na maioria dos casos, decisões subjetivas e qualitativas associadas ao profissional cirurgião dentista. Assim, fica a cargo dos computadores e os sistemas de VC apenas a função de auxiliar esse profissional para que seja realizado um diagnóstico preciso e correto.

1.1 Motivação

O dente é uma das mais importantes estruturas presentes na boca. Inúmeras alterações ou lesões podem estar associadas ao órgão dentário na sua porção coronária e/ou radicular. Dentre estas, estão inclusos os cistos e tumores odontogênicos, que compreendem um grupo complexo de lesões que acometem a cavidade bucal e apresentam comportamento clínico e tipos histológicos diversos (MUSU *et al.*, 2016; NEVILLE DOUGLAS D. DAMM, 2015; JOHNSON *et al.*, 2014).

Os cistos odontogênicos são cavidades patológicas, revestidas com epitélio odontogênico e podem ser classificados de acordo com sua origem em: cistos de desenvolvimento e inflamatórios. O cisto periapical, denominado também como cisto periodontal apical ou cisto radicular, é o mais comum da região oral. É uma lesão de origem inflamatória associada à necrose pulpar, caracterizado como uma seqüela de um granuloma apical, que devido a manutenção de um processo inflamatório, estimula a proliferação de remanescentes epiteliais na região do periápice (MARTIN; SPEIGHT, 2017; NEVILLE DOUGLAS D. DAMM, 2015; BARNES JOHN W. EVESON, 2005).

A maior parte dos cistos radiculares é descoberta durante exames radiográficos de rotina. Nos exames radiográficos essas lesões são caracterizadas por meio de um aspecto radiolúcido com margens corticais bem definidas, presente no ápice radicular de um dente (GOHEL *et al.*, 2016). Pode ser tratado com sucesso pela extração do dente e curetagem do epitélio na zona da patologia apical ou através de tratamento endodôntico. Quando se opta pela exodontia, deve-se fazer a completa remoção do cisto, caso contrário, pode ocorrer o desenvolvimento de um cisto residual meses após o tratamento inicial e culminar em destruição significativa e enfraquecimento da mandíbula ou maxila. Atualmente, com o avanço da terapia endodôntica, a maioria dos tratamentos são finalizados com sucesso (GOHEL *et al.*, 2016; NAIR,

2006)

De acordo com Organização Mundial da Saúde (OMS) a frequência relativa do cisto periapical na população mundial no ano de 1997 foi de 52,3% no Reino Unido; 50,7% no Chile; 53,5%, na França; 50,2% na Espanha e 52,2% no Brasil. Os estudos de Prock et al. (2008), relataram maior prevalência em relação aos dados fornecidos pela OMS 2005, com 72,5% e 61,4% no Brasil, respectivamente.

O cisto periapical é na maioria dos casos relacionado à lesão cariosa profunda que progride levando a necrose pulpar. Essa é a justificativa mais plausível para explicar a alta prevalência dentro da população mundial. O mecanismo para desenvolver o cisto radicular inclui à necrose da polpa, a colonização e a proliferação de micro-organismos dentro do sistema radicular, a liberação de toxinas bacterianas e mediadores inflamatórios na região periapical e uma combinação de fatores envolvendo interação epitelial-estromal. A inflamação perirradicular leva à proliferação de restos de células epiteliais (restos epiteliais de Malassez) (BERNARDI *et al.*, 2015).

Na maioria dos casos, o tratamento endodôntico é a primeira opção para resolver lesões inflamatórias apicais. Muitas vezes a cura da lesão não ocorre após terapia, devendo o cirurgião-dentista lançar mão de outras alternativas de tratamento, como a cirurgia apical (VILLASIS-SARMIENTO *et al.*, 2017; NAIR, 2006).

As radiografias odontológicas desempenham um papel importante no diagnóstico de lesões e na condução do tratamento. A interpretação das imagens radiográficas pode ser difícil para o cirurgião-dentista, haja vista que se trata da representação da anatomia tridimensional das estruturas da face em apenas duas dimensões (WHITE, 2013; TURGEON; LAM, 2016; SUWA *et al.*, 2001). Os tipos de exames radiográficos realizados em odontologia são: periapical, interproximal e panorâmica.

Informações de como são executados os exames radiográficos, suas classificações e os tipos de lesões identificadas por esse tipo de exame podem ser consultadas no **Apêndice A**, no qual são apresentadas informações relevantes referentes às Radiografias Odontológicas. Já no **Apêndice B**, tem-se um aprofundamento sobre as radiografias periapicais, das quais as imagens utilizadas nos experimentos deste trabalho foram obtidas, bem como alguns padrões e boas práticas definidos para este tipo específico de exame.

Levando em consideração a proposta de um sistema de VC na área de Odontologia, o processo de segmentação compõe uma etapa fundamental, haja vista que tem um grande valor

clínico no auxílio da análise de imagens radiográficas odontológicas, o que possibilita elevar a qualidade dos diagnósticos e assim melhorar e otimizar o tratamento dos pacientes.

Nesse sentido, considerando a alta prevalência dos cistos periapicais e a importância da aquisição de novas ferramentas que visem colaborar com a interpretação diagnóstica do cirurgião-dentista frente aos achados radiográficos, detectar os estágios reais das lesões odontológicas e acompanhar a evolução do tratamento de lesões corretamente, o presente estudo propõe a utilização do Modelo de Contorno Ativo Localizado Baseado em Região (*Localizing Region-Based Active Contours*), a partir da máscara inicial obtida, para segmentar lesões periapicais. O Modelo de Contorno Ativo Localizado é um *framework* proposto por Lankton e Tannenbaum (2008), que é uma variação do Modelo de Contorno Ativo - MCA baseado em Região proposto por Chan e Vese (2001). Pretende-se utilizar técnicas da Morfologia Matemática para identificar pontos para uma melhor inicialização da máscara que será utilizada no MCA. Pretende-se ainda avaliar a metodologia aplicando métricas pertinentes ao tipo de problema abordado e que são bem estabelecidas na literatura para tais fins, como por exemplo: coeficiente de Dice, precisão e acurácia, que estabelecem a relação de proximidade da região segmentada com o resultado desejado.

1.2 Estado da Arte

Além do exame clínico e do histórico do paciente, as radiografias odontológicas auxiliam no diagnóstico de lesões e na condução do tratamento. No entanto, para obter o máximo de informações de uma radiografia para o auxílio do diagnóstico, o cirurgião-dentista deve ter um conhecimento adequado da anatomia normal das estruturas anatômicas da face e reconstruí-las mentalmente em uma imagem tridimensional das projeções bidimensionais da radiografia (WHITE, 2013). Nesse contexto, a segmentação de lesões possui um grande valor clínico no auxílio da análise de imagens radiográficas odontológicas, pois possibilita elevar a qualidade dos diagnósticos e assim melhorar e otimizar o tratamento de pacientes.

Diante disso, técnicas de segmentação aplicadas à Odontologia têm sido propostas buscando auxiliar o Cirurgião-Dentista durante todas as fases de tratamento, incluindo o diagnóstico clínico. Dentre as quais, Hasan *et al.* (2016) propõem a aplicação do Fluxo do Vetor Gradiente (GFV) juntamente com a técnica K-means para segmentação da área correspondente à mandíbula em imagens panorâmicas digitais. O método propõe ainda uma correção durante o processo de segmentação para melhorar os resultados. Do total de imagens segmentadas, o

método proposto atingiu 92% de sucesso.

Kronfeld *et al.* (2010) utilizam o MCA para estimar a posição exata dos dentes em moldes dentários com mínima interação com o usuário. Inicialmente, o contorno que separa os dentes e a gengiva é identificado. Em seguida, calcula-se o arco dental e os interstícios entre os dentes. Ao final, o método detecta o posicionamento exato dos dentes aplicando um MCA em volta das cúspides de cada dente. Os resultados experimentais mostraram que a ponderação da energia característica de atração, dada por $\lambda = 0,5$, é suficiente. Uma vez que a energia de pressão acelera o movimento do *snake*, os autores estabeleceram $\delta = 0,2$ para a inicialização do *snake* e $\delta = -0,2$ para o *snake* que se inicializa interno ao dente. Aos autores ressaltam que em moldes dentários nos quais a borda entre dente e a gengiva é muito suave, a segmentação falha. O mesmo erro ocorreu, quando os dentes vizinhos se sobrepõem devido a má oclusão severa. Nesses casos, o usuário precisa segmentar o dente manualmente.

Shah *et al.* (2006) propõe um método de extração do contorno de dentes utilizando a técnica com modelo de contorno ativo sem bordas. O procedimento acima mencionado foi utilizado para segmentar dentes de base de imagens radiográficas digitalizadas, as quais foram subdividas em dois tipos: *Ante-mortem* (AM), quando a pessoa está viva e *post-mortem* (PM) aquelas radiografias obtidos após a morte da pessoa. Um total de imagens foram selecionadas aleatoriamente para os experimentos. Em seguida, o algoritmo foi executado nessas imagens e os resultados foram categorizados manualmente em: (a) Perfeitamente dente segmentado (dente inteiro), (b) perfeitamente segmentado Coroa, (c) segmentação do contorno que pode ser corrigido a uma fase posterior e (d) erro na extração de contorno. Os resultados experimentais indicam os benefícios da abordagem proposta.

Lin *et al.* (2014) propõem um método para segmentar radiografias periapicais dentária. O método consiste em quatro estágios: melhoramento da imagem utilizando a transformação *power-law* adaptativa; análise de singularidade local usando o expoente de Hölder; reconhecimento de dentes aplicando o limiar de Otsu e análise de componentes conectados; e forma dos dentes usando *snakes* e operações morfológicas. Os experimentos foram realizados com 28 radiografias periapicais contendo 106 dentes no total. Os resultados demonstraram que 105 dentes foram isolados e segmentados com sucesso, nos quais obtiveram uma acurácia geral de 0,8959 para Verdadeiro Positivo (VP) e 0,0093 para Falso Positivo (FP) com desvio padrão de 0,0737 e 0,0096, respectivamente. Segundos os autores, a perda de 10% no VP ocorreu devido à dificuldade de identificar alguns dentes molares; e o pequeno valor da média do FP vem do

fato de que muitos dentes têm FP próximo de 0 e o valor do desvio padrão de FP ocorreu pelo fato de que alguns dentes não foram segmentados com sucesso.

1.3 Objetivos

O principal objetivo deste trabalho é utilizar técnicas como Modelo de Contorno Ativo para segmentação de lesões periapicais em imagens radiográficas digitais para o auxílio da análise de imagens radiográficas por partes dos profissionais da área de Odontologia.

1.3.1 Objetivos Específicos

- Utilizar técnicas da morfologia matemática para inicialização da máscara inicial do MCA;
- Aplicar o MCA na segmentação de lesões em imagens radiográficas periapicais;
- Avaliar a metodologia aplicando métricas pertinentes ao tipo de problema abordado;
- Produzir trabalhos científicos e/ou tecnológicos.

1.4 Organização

Este trabalho está organizado em 5 capítulos: no Capítulo 2 são introduzidos os conceitos dos métodos utilizados neste trabalho, bem como é feita uma abordagem teórica que embasa a aplicação de tais métodos. Também são explicados os métodos de avaliação. No Capítulo 3, são mostradas as etapas de execução da metodologia proposta e os experimentos realizados. No Capítulo 4 são mostrados resultados obtidos e realizadas suas análises e discussões. Por fim, no Capítulo 5, são apresentados as conclusões, contribuições e trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste Capítulo primeiramente é apresentado com detalhes o conceito e os tipos de segmentação aplicadas em imagens monocromáticas, bem como a teoria dos MCAs, suas vantagens e limitações. Em seguida, é relatada a teoria relacionada à Morfologia Matemática aplicada a imagens em escala de cinza. Também são introduzidos os conceitos sobre o Filtro de Gabor. Por fim, as métricas de avaliação adotadas para segmentação são apresentadas.

2.1 Segmentação

A segmentação de imagem é o problema de particionar uma imagem conforme um contexto de aplicação. A ideia fundamental desse problema é subdividir a imagem em segmentos múltiplos disjuntos de forma que padrões ou propriedades similares pertençam ao mesmo segmento. Esse procedimento, de particionar padrões em uma imagem e agrupá-los, ocorre naturalmente no sistema visual-cognitivo humano, que além de perceber os diferentes objetos ou padrões presentes em imagens, também é capaz de tomar decisões com base na informação visual obtida (DE SIDDHARTHA BHATTACHARYYA, 2016; (ED.), 2012).

Durante as últimas décadas, a segmentação de imagem tem sido estudada e utilizada em diversos processos e aplicações relacionadas à análise de imagem, como, por exemplo, reconhecimento biométrico ou de texto/caracteres, detecção de estruturas anatômicas em imagens médicas, detecção de movimento em vídeos (pessoas/carros), etc. (DE SIDDHARTHA BHATTACHARYYA, 2016; (ED.), 2012). Em sistemas de Visão Computacional, a segmentação constitui um processo importante, no qual regiões de interesse são identificadas, extraídas e reutilizadas em processos seguintes. A precisão da segmentação determina o eventual sucesso ou falha de tais processos (GONZALEZ; WOODS, 2008).

A segmentação consiste no processo de dividir uma imagem em regiões com propriedades e características semelhantes, tais como: níveis de cinza, textura, brilho, contraste, cor ou textura. A principal ideia é produzir uma partição de uma imagem de forma a categorizá-la em regiões homogêneas ou grupos de *pixels* similares (GONZALEZ; WOODS, 2008). São inúmeras as técnicas de segmentação atualmente disponíveis na literatura, e, algumas delas têm sido amplamente utilizadas em diferentes tipos de aplicações.

Gonzalez e Woods (2008) propõem que os métodos clássicos de segmentação para imagens monocromáticas fundamentam-se nas propriedades de descontinuidade e de similaridade.

dades dos valores de intensidade. Portanto, dividem esses métodos em duas categorias básicas. Na primeira categoria, pressupõe-se que os limites das regiões são suficientemente diferentes do plano de fundo. Essa diferença possibilita a detecção desses limites com base nas descontinuidades locais de intensidade. Em suma, a segmentação das regiões ocorre em zonas caracterizadas por mudanças bruscas das tonalidades presentes na imagem. A segmentação de pontos isolados, linhas ou bordas são as principais abordagens usadas nesta categoria. Na segunda categoria, considera-se um conjunto de critérios pré-definidos para particionar a imagem em regiões similares. Nesta categoria estão os métodos baseados em limiarização e no crescimento de regiões.

2.1.1 Segmentação por descontinuidade

De acordo com Gonzalez e Woods (2008), as técnicas de segmentação baseadas em descontinuidades podem detectar, em imagens em níveis de cinza, objetos de três tipos: pontos, linhas e/ou bordas. Tais técnicas utilizam uma operação com a primeira ou a segunda derivada para identificar as variações abruptas de intensidade de níveis de cinza de cada *pixel* e seus vizinhos. Para tanto, em imagens digitais, as derivadas são definidas em termos de diferenças finitas. Para aplicá-las à imagem, é utilizada uma abordagem que se resume em uma convolução bidimensional entre uma máscara e a imagem, que pode ser expressa da seguinte forma

$$g(x,y) = M_{3 \times 3} * f(x,y), \quad (2.1)$$

em que $*$ é o operador de convolução, $f(x,y)$ denota a imagem com suas coordenadas espaciais x e y , $g(x,y)$ é a imagem "convoluída" e $M_{3 \times 3}$ é a matriz com os coeficientes relativos à derivada. Em geral, considerando a matriz

$$M_{3,3} = \begin{pmatrix} w(-1,-1) & w(-1,0) & w(-1,1) \\ w(0,-1) & w(0,0) & w(0,1) \\ w(1,-1) & w(1,0) & w(1,1) \end{pmatrix}, \quad (2.2)$$

esse resultado pode ser obtido por meio da soma dos produtos dos coeficientes da máscara com os valores de intensidade de *pixels* abrangida pela máscara, conforme a expressão a seguir

$$g(x,y) = \sum_{s=-a}^{s=a} \sum_{t=-a}^{t=a} w(s,t)f(x+s,y+t), \quad (2.3)$$

em que $a = (n - 1)/2$ (GONZALEZ; WOODS, 2008).

2.1.1.1 Detecção de Pontos e linhas

As derivadas de segunda ordem, como o Laplaciano por exemplo, denotado por Δ , quando aplicadas às imagens, possibilitam a identificação de detalhes mais finos, como linhas, pontos isolados e ruídos. Utilizando uma aproximação por meio de diferenças finitas, é possível obter a máscara para o Laplaciano a seguir

$$M_{\Delta 3,3} = \begin{pmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{pmatrix}. \quad (2.4)$$

Assim, aplicando a equação 2.3 para a máscara $M_{\Delta 3,3}$ e a imagem $f(x,y)$, é possível destacar o *pixel* correspondente ao centro da máscara se este for um ponto. Intuitivamente, a ideia é que a intensidade de um ponto isolado seja bastante diferente do seu entorno e assim será facilmente detectável na aplicação do Laplaciano. Percebe-se ainda que para áreas da imagem com intensidade de *pixel* constante a resposta $g(x,y)$ será zero.

Para detecção de linhas, basicamente, o princípio é o mesmo. Como o Laplaciano é isotrópico, pode ser utilizado para detectar linhas em qualquer direção. No entanto, em algumas aplicações há o interesse na detecção de linhas em direções específicas. Assim, para linhas nas direções de 0° , 45° , 90° e 135° , também por meio da equação 2.3, utilizam-se as máscaras a seguir:

$$M_{0^\circ} = \begin{pmatrix} 1 & 1 & 1 \\ 2 & 2 & 2 \\ 1 & 1 & 1 \end{pmatrix}, \quad M_{45^\circ} = \begin{pmatrix} 1 & 1 & 2 \\ 1 & 2 & 1 \\ 2 & 1 & 1 \end{pmatrix}, \quad (2.5)$$

$$M_{90^\circ} = \begin{pmatrix} 1 & 2 & 1 \\ 1 & 2 & 1 \\ 1 & 2 & 1 \end{pmatrix}, \quad M_{135^\circ} = \begin{pmatrix} 2 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 2 \end{pmatrix},$$

em que M_{0° detecta linhas na horizontal, M_{90° detecta linhas na vertical e M_{45° e M_{135° detectam linhas nas diagonais (GONZALEZ; WOODS, 2008). As linhas que não satisfazem as condições mencionadas são melhor tratadas como regiões e manipuladas pelos métodos de detecção de borda.

2.1.1.2 Detecção de borda

Uma borda pode ser o resultado de mudanças no brilho, cor, sombra e textura, e essas mudanças podem ser usadas para determinar a profundidade, tamanho, orientação e propriedades de uma imagem digital (GONZALEZ *et al.*, 2017).

Dentre as técnicas de segmentação por descontinuidade, as técnicas de detecção de borda são utilizadas com maior frequência para segmentar imagens. Essas técnicas também se baseiam em mudanças abruptas na intensidades dos *pixels*. Normalmente são executadas em três etapas: 1 - suavização da imagem para redução de ruído; 2 - detecção de pontos da borda; e por fim, 3 - localização da borda (GONZALEZ; WOODS, 2008).

As técnicas de detecção de borda fazem uso de operadores gradiente na imagem. Operadores de gradiente e algumas aproximações são os mais utilizados para detecção de borda. Dentre as principais abordagens baseadas em operadores gradiente são: Sobel, Prewitt, Roberts, Kirsch e Canny (GONZALEZ *et al.*, 2017).

2.1.2 Segmentação por similaridade

2.1.2.1 Limiarização

Devido às suas propriedades intuitivas, simplicidade de implementação e velocidade computacional, a técnica de segmentação baseada em limiarização é uma das principais abordagens nas aplicações de segmentação de imagens (GONZALEZ; WOODS, 2008). Essa técnica, geralmente, tem como princípio básico as diferenças dos níveis de cinza que compõem diferentes objetos de uma imagem. Assim, a partir de um limiar estabelecido para cada região da imagem, é possível rotular cada *pixel*, associando-o à faixa de valores estabelecido em cada região. Por exemplo, em uma imagem com resolução de 8 bits, o limiar T pode estar entre 0 e 255. Logo, uma imagem $g(x, y)$ limiarizada é dada por:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) \leq T. \end{cases} \quad (2.6)$$

Deste modo, a matriz $g(x, y)$ resultante será uma imagem binarizada, ou seja, será composta por *pixels* com valores iguais a 1 ou 0.

Alternativamente, pode-se manter os valores originais para um grupo da imagem e isolar os *pixels* restantes. Dessa forma, dada a imagem $f(x,y)$, seus níveis de cinza podem ser saturados utilizando a seguinte transformação:

$$g(x,y) = \begin{cases} 1 & \text{se } f(x,y) > T \\ f(x,y) & \text{se } f(x,y) \leq T \end{cases} \quad (2.7)$$

Além dessas abordagens, a limiarização também pode ser aplicada para truncar os valores de níveis de cinza da imagem, de modo que os valores de $g(x,y)$ sejam limitados ao intervalo $[0, T]$; ou ainda, pode-se subdividir a imagem $g(x,y)$ em mais de duas regiões por meio da técnica denominada de multi-limiarização, na qual é estabelecido mais de um limiar com limites inferior e superior de cada região de interesse (HAN *et al.*, 2017; CUEVAS *et al.*, 2010; CUEVAS *et al.*, 2012).

2.1.2.2 Crescimento de Região

Na técnica segmentação por meio do crescimento de região, os *pixels* da imagem são agrupados por meio de algum critério de similaridade pré-estabelecido. Inicialmente, são selecionados os *pixels* sementes de acordo com um atributo desejado. Esse atributo pode ser um intervalo dentro da escala de cinza, média local, cor, etc. Em seguida, os *pixels* adjacentes são agrupados aos *pixels* sementes formando subregiões, caso as propriedades consideradas sejam semelhantes. Assim, cada subregião com as sementes cresce gradualmente acumulando mais *pixels* vizinhos, até que todos os *pixels* da imagem tenham sido atribuídos a alguma das subregiões (PETROU, 2010; GONZALEZ; WOODS, 2008; PITAS, 2000).

Para implementar essa técnica, faz-se necessário a escolha de regras que descrevam o mecanismo de crescimento e regras que verifiquem a homogeneidade das subregiões geradas após o crescimento. Assim, para cada passo k em uma subregião $R_i^{(k)}$ $| i = 1, 2, \dots, N$, são verificados os *pixels* que ainda não foram classificados e são 8-adjacentes aos *pixels* de bordas das subregiões. Em seguida, o *pixel* x é assinalado como pertencente à $R_i^{(k)}$. Ao final, verifica-se a homogeneidade das sub-regiões (PITAS, 2000).

2.1.3 Outros métodos de segmentação

Nas subseções anteriores foram discutidos métodos de segmentação baseados em conceitos como: detecção de borda, limiar e crescimento de região. Cada uma dessas abordagens possui vantagens e desvantagens. Na Seção 2.2 a seguir serão introduzidos os conceitos relacionados à técnica denominada de Modelo de Contorno Ativo - MCA. O MCA tem sido amplamente utilizado na segmentação de imagens com resultados promissores em diversas áreas.

2.2 Modelos de Contorno Ativo - MCA

No final dos anos 80 sugeriu-se que seria possível seguir bordas em imagens definindo-se uma curva na imagem, e então fazer essa curva mover-se ajustando-se às formas e/ou estruturas presentes na imagem. Essa curva deve ter características físicas tais como elasticidade e rigidez, e também ser atraída pelas bordas na imagem. Tais curvas são chamadas de modelos de contornos ativos, modelos deformáveis ou *Snakes* e foram inicialmente propostas por Kass *et al.* (1988). Desde então, são inúmeros os estudos e aplicações propostas em que se utilizam modelos de contorno ativo: rastreamento de objetos, reconhecimento de formas, segmentação e detecção de borda.

2.2.1 Versão Clássica

Na sua formulação original, proposta por Kass *et al.* (1988), o modelo de contorno ativo é baseado em borda, i.e., usa um detector de borda para determinar fronteiras de regiões. Diferentemente de um detector de bordas puro, o MCA assegura bordas fechadas e portanto representa bem regiões presentes na imagem.

Geometricamente, o modelo de contorno ativo é uma curva paramétrica interna a uma imagem no plano $(x, y) \in \mathbb{R}$. Essa curva é representada por $\mathbf{v}(s) = (x(s), y(s))^T$, em que x e y são coordenadas da função e $s \in [0, 1]$ é o domínio paramétrico. O funcional que representa a energia do MCA em uma imagem $I(x, y)$ é dado por:

$$E = \int_0^1 E_{int}(\mathbf{v}) + E_{ext}(\mathbf{v}), \quad (2.8)$$

em que o primeiro termo deste funcional de energia, dado por

$$E_{int}(\mathbf{v}) = \alpha(s) \left| \frac{\partial \mathbf{v}}{\partial s} \right|^2 ds + \int_0^1 \beta(s) \left| \frac{\partial^2 \mathbf{v}}{\partial s^2} \right|^2 ds, \quad (2.9)$$

caracteriza a energia interna. As duas funções de parâmetros determinam as características físicas do contorno: $\alpha(s)$ controla a elasticidade do contorno ou a resistência ao sofrer alguma tensão. Esse parâmetro define a capacidade de um ponto pertencente à curva se distanciar ou se aproximar dos pontos adjacentes; quanto ao $\beta(s)$, este controla a rigidez da curva. Este parâmetro é baseado nos ângulos internos da curva e tende a deixá-la mais suave.

O segundo termo em (2.8) representa a energia externa, e é dado por

$$E_{ext}(\mathbf{v}) = P(v(s)), \quad (2.10)$$

em que $P(v(s))$ denota uma função potencial obtida a partir de informações da imagem, possuindo inúmeras formas para sua definição. Uma possível escolha seria definir $P(v(s)) = -c|\nabla[G_\sigma * I(x,y)]|$, em que c controla a magnitude do potencial, ∇ é o operador gradiente, e $G_\sigma * I(x,y)$ denota a convolução da imagem com um filtro Gaussiano.

A forma final do contorno corresponde ao mínimo da energia $E(\mathbf{v})$. Dessa forma, o contorno $\mathbf{v}(s)$ que minimiza tal energia, satisfaz a equação de Euler-Lagrange (CELLINA, 2014)

$$-\alpha \frac{\partial^2 v(s)}{\partial s^2} + \beta \frac{\partial^4 v(s)}{\partial s^4} + \nabla P(v(s,t)) = 0. \quad (2.11)$$

Essa equação diferencial parcial expressa o equilíbrio de forças internas e externas. Os dois primeiros termos representam as forças de alongamento e flexão internos, respectivamente. O terceiro termo representa o par de forças externas obtidos dos dados da imagem. A abordagem usual para a resolução da equação 2.11 utiliza a aplicação de algoritmos numéricos.

2.2.2 Modelo de Contorno Ativo Baseado em Região (Modelo de Chan-Vese)

O Modelo de Contorno Ativo Baseado em Região, proposto por Chan e Vese (2001), é uma solução para o problema formulado por Mumford (1989) para segmentação. Este modelo tem a seguinte formulação: Seja Ω um conjunto aberto do \mathbb{R}^2 e $C(q) : [0, 1] \rightarrow \mathbb{R}^2$ uma curva planar parametrizável. Para um dada imagem $I \subset \Omega$, o modelo Chan-Vese consiste em minimizar o funcional de energia dado por

$$F_{CV} = \lambda_1 \int_{int(C)} |I - c_1|^2 dx dy + \lambda_2 \int_{ext(C)} |I - c_2|^2 dx dy, \quad (x,y) \in \Omega, \quad (2.12)$$

em que C é a curva que tem seus pontos atualizados durante os cálculos e c_1 e c_2 são as médias dos níveis de cinza na região interna e externa de C , respectivamente. Considerando a função *level set* $\phi(x, y)$, pode-se assumir que

$$\begin{cases} C = \{(x, y) \in \Omega : \phi(x, y) = 0\} \\ \text{int}(C) = \{(x, y) \in \Omega : \phi(x, y) > 0\} \\ \text{ext}(C) = \{(x, y) \in \Omega : \phi(x, y) < 0\} \end{cases} \quad (2.13)$$

Rescrevendo c_1 e c_2 em termos de ϕ , tem-se que

$$c_1(\phi) = \frac{\int_{\Omega} u_0(x, y) H(\phi(x, y)) dx dy}{\int_{\Omega} H(\phi(x, y)) dx dy}, \quad (2.14)$$

$$c_2(\phi) = \frac{\int_{\Omega} u_0(x, y) (1 - H(\phi(x, y))) dx dy}{\int_{\Omega} (1 - H(\phi(x, y))) dx dy}. \quad (2.15)$$

Incorporando o tamanho do comprimento e a área de C na equação 2.12, mantendo c_1 e c_2 fixos, o mínimo de energia em relação a ϕ que satisfaz o funcional dado, para um $t \geq 0$, corresponde a seguinte formulação

$$\frac{\partial \phi(x, y)}{\partial t} = \delta(\phi(x, y)) \left[\mu \nabla \left(\frac{\nabla \phi(x, y)}{|\nabla \phi(x, y)|} \right) - \nu - \lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2 \right], \quad (2.16)$$

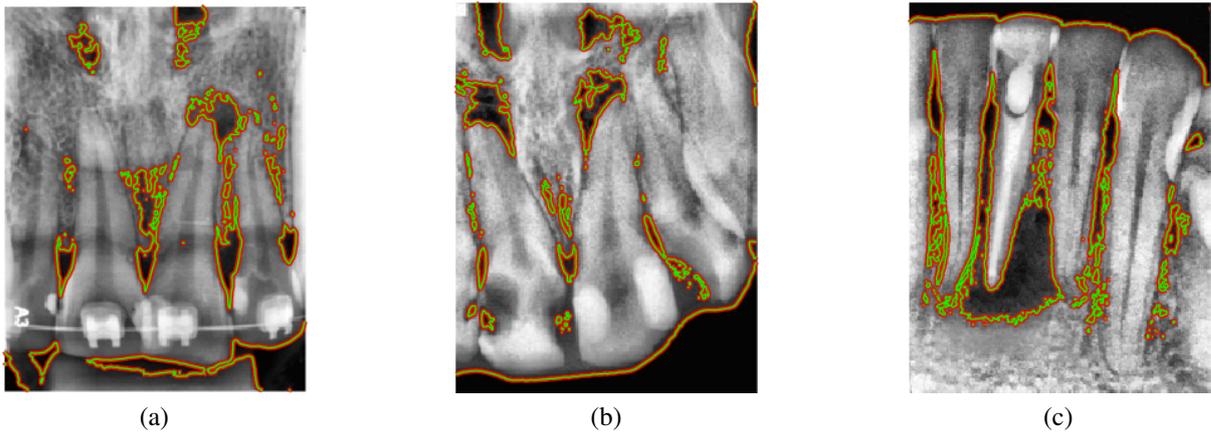
em que $\mu > 0$, $\nu > 0$, $\lambda_1 > 0$ e $\lambda_2 > 0$ são pesos fixos, ∇ representa o operador gradiente, $H(\phi(x, y))$ é a função de Heaviside e $\delta(\phi(x, y))$ é a função de Dirac.

Para exemplificar sua utilização, o modelo proposto por Chan e Vese (2001) foi aplicado nas imagens utilizadas nos experimentos, conforme será mostrado no Capítulo 3 (pág. 44). A máscara de entrada foi obtida utilizando os passos apresentados nas Seções 3.3 e 3.4; e a quantidade de iterações definida para 500. O resultado é mostrado na Figura 1 (pág. 33) a seguir.

2.2.3 Modelo de Contorno Ativo Localizado Baseado em Região

Modelo de Contorno Ativo Localizado Baseado em Região (em inglês *Localizing Region-Based Active Contours*), é um *framework* para segmentar regiões de interesse proposto por Lankton e Tannenbaum (2008). Esse *framework* utiliza a energia em termos de áreas de interesse locais menores, o que permite superar as desvantagens da utilização de energias globais utilizadas no MCA baseado em região convencional, que falham em algumas aplicações com propósitos de segmentação local.

Figura 1 – Resultados obtidas a partir da aplicação do Modelo de (CHAN; VESE, 2001).



Fonte: Imagens geradas durante os experimentos.

A ideia básica do MCA Localizado é construir uma família de energias locais em cada ponto ao longo da curva do MCA. Para otimizar essas energias locais, cada ponto é considerado separadamente e se move para minimizar (ou maximizar) a energia calculada em sua própria região local. Para calcular essas energias locais, as vizinhanças locais são divididas em interior local e exterior local pela curva em evolução. A otimização da energia é então realizada com o ajuste do MCA para cada região local (LANKTON; TANNENBAUM, 2008).

Seja uma imagem em escala de cinza $I \in \Omega$, em que $\Omega \subset \mathbb{R}^2$. A curva fechada C é representada pela função *level set* ϕ , com $C = \{x \in \Omega | \phi(x) = 0\}$ (VESE; GUYADER, 2015). O interior de C é dado pela aproximação da versão suavizada da Função de Heaviside:

$$\mathcal{H}(\phi(x)) = \begin{cases} 1, & \phi(x) < -\varepsilon \\ 0, & \phi(x) > \varepsilon \\ \frac{1}{2} \left\{ 1 + \frac{\phi}{\varepsilon} + \frac{1}{\pi} \sin\left(\frac{\pi\phi(x)}{\varepsilon}\right) \right\}, & \text{caso contrário.} \end{cases}, \quad (2.17)$$

Da mesma forma, o exterior de C é dado por $1 - \mathcal{H}(\phi(x))$.

O funcional de energia que descreve esse *framework* é dado por:

$$E(\phi) = \int_{\Omega_x} \delta\phi(x) \int_{\Omega_y} B(x,y) \cdot F(I(y), \phi(y)) dy dx + \lambda \int_{\Omega_x} \delta\phi(x) \|\nabla\phi(x)\| dx \quad (2.18)$$

em que $F(I(y), \phi(y))$ é uma energia interna genérica, $B(x,y)$ é a função característica que define a região local de acordo com o parâmetro r (raio). O segundo termo da integral penaliza o comprimento de cada arco da curva com o peso fixo λ . Lankton e Tannenbaum (2008) definem

a função $B(x,y)$ da seguinte forma:

$$B(x,y) = \begin{cases} 1, & \|x-y\| < r \\ 0, & \text{caso contrário.} \end{cases}, \quad (2.19)$$

Finalmente, para este modelo, o variacional da energia em relação a ϕ é dado por:

$$\frac{\partial \phi(x)}{\partial t} = \delta(\phi(x)) \int_{\Omega_y} B(x,y) \cdot \nabla_{\phi(y)} F(I(y), \phi(y)) dy + \lambda \delta(\phi(x)) \operatorname{div} \left(\frac{\nabla \phi(x)}{|\nabla \phi(x)|} \right). \quad (2.20)$$

2.3 Morfologia Matemática

Historicamente, a morfologia matemática inciou-se como uma técnica para estudar conjuntos aleatórios com aplicações para o setor de mineração. Depois as aplicações expandiram-se ao processamento e análise de imagens. Atualmente, em processamento de imagens, concentra-se na utilização de operações morfológicas aplicadas às estruturas geométricas presentes nas imagens (NAJMAN, 2010; SHIH, 2009). O princípio básico desse processo consiste em aplicar operações com um elemento estruturante, de tamanho fixo ou variado, em uma imagem e identificar as estruturas existentes na imagem que se encaixam ou não a esse elemento, com o objetivo de ressaltar aspectos específicos das formas na imagem. As operações elementares da morfologia matemática são a **erosão** e a **dilatação**, as quais combinadas em sequencia produzem outras operações, como por exemplo, **abertura** e **fechamento**.

Nas subseções 2.3.1 e 2.3.2 são abordadas as versões para imagens binárias. Já nas subseções 2.3.3, 2.3.4, 2.3.5 e 2.3.6, são explicadas, respectivamente, as operações para imagens em tons de cinza, a operação de transformação *top-hat* e a técnica de Melhoramento de contraste utilizando Processamento Morfológico Rotacional - PMR, utilizada neste trabalho.

2.3.1 Erosão e Dilatação em imagens binárias

Sejam A e B dois conjuntos no espaço euclidiano n -dimensional, com elementos a e b , respectivamente, em que $a = (a_1, a_2, \dots, a_N)$ e $b = (b_1, b_2, \dots, b_n)$ são n -tuplas de coordenadas. Seguem as seguintes definições:

A translação de A por b , denotada por $(A)_b$, é definida como:

$$(A)_b = \{c \in E^n | c = a + b\}. \quad (2.21)$$

Uma das operações elementares da morfologia matemática é a erosão. A erosão do conjunto A pelo conjunto B , denotada por $A \ominus_b B$, é dada por:

$$A \ominus_b B = \{x \in E^n | x + B \in A, \quad \forall \quad b \in B\}. \quad (2.22)$$

Essa relação, $A \ominus_b B$, expressa que todos os pontos em que B transladado por x cabe em A . A cerca da erosão, A é a imagem de entrada e B o elemento estruturante. De forma mais informal, os termos "encolher" e "reduzir" são utilizados para se referir à erosão.

Já a dilatação do conjunto A pelo conjunto B , denotada por $A \oplus_b B$, é denotada por:

$$A \oplus_b B = \{c \in E^n | c = a + b, \text{ em que } a \in A \quad e \quad b \in B\}. \quad (2.23)$$

A operação de dilatação $A \oplus_b B$ pode ser reescrita usando união de translações do conjunto A , de acordo com:

$$A \oplus_b B = \bigcup_{b \in B} (A)_b, \quad (2.24)$$

ou seja, a dilatação pode ser obtida efetuando-se a união de translações da imagem A por todos os pontos do elemento estruturante B .

2.3.2 Abertura e Fechamento em imagens binárias

A abertura do conjunto A por um elemento estruturante B , denotada por $A \circ B$, é definida como a aplicação da operação de erosão de A por B seguida da dilatação por B . Conforme descrita a seguir:

$$A \circ B = (A \ominus_b B) \oplus_b B, \quad (2.25)$$

Similarmente, o fechamento do conjunto A por um elemento estruturante B , denotado por $A \bullet_b B$, é definido como,

$$A \bullet_b B = (A \oplus_b B) \ominus_b B, \quad (2.26)$$

ou seja, aplica-se a dilatação de A por B seguida da erosão pelo mesmo elemento estruturante B .

A abertura e o fechamento para imagens binárias podem ser interpretados da seguinte forma. A abertura irá remover todos os *pixels* nas regiões que são suficientemente pequenas ou finas para conter o elemento estruturante. Em oposição à abertura, o fechamento tende a preencher pequenos furos e concavidades menores do que elemento estruturante. Essas operações podem ser utilizadas para suprimir características espaciais ou discriminar objetos de acordo com sua distribuição de tamanho (SHIH, 2009; GONZALEZ; WOODS, 2008).

2.3.3 Erosão e Dilatação em escala de cinza

Sejam I e K domínios da imagem em tons de cinza $i(x, y)$ e o elemento estruturante também em escala de cinza $k(m, n)$, respectivamente. Quando i ou k estão em escala de cinza, as operações morfológicas aplicadas sobre essas duas funções são chamadas morfologia em tons de cinza (SHIH, 2009). Assim, a erosão em escala de cinza é realizada obtendo o mínimo de um conjunto de diferenças, e é dada por:

$$(i \ominus_g k)(x, y) = \min\{i(x + m, y + n) - k(m, n)\}. \quad (2.27)$$

Por outro lado, a dilatação em escala de cinza é obtida por meio do máximo de um conjunto de somas, e é definida por:

$$(i \oplus_g k)(x, y) = \max\{i(x - m, y - n) + k(m, n)\}, \quad (2.28)$$

para todo $(m, n) \in K$ e $(x \pm m, y \pm n) \in I$.

2.3.4 Abertura e Fechamento em escala de cinza

A abertura em escala de cinza de uma imagem $i(x, y)$ por um elemento estruturante $k(m, n)$, é denotada por $i \circ_g k$, e é dada por:

$$i \circ_g k = (i \ominus_g k) \oplus_g k, \quad (2.29)$$

Por sua vez, a operação de fechamento em escala de cinza de uma imagem $i(x, y)$ por um elemento estruturante $k(m, n)$, é expressa por:

$$i \bullet_g k = (i \oplus_g k) \ominus_g k, \quad (2.30)$$

2.3.5 Transformada Top-Hat

A transformada *Top-Hat* consiste na operação de subtração da imagem original e o resultado da abertura ou do fechamento aplicado a mesma imagem. É comumente utilizada para o melhorar imagens com baixo contraste. As denominações *white top-hat* e *black top-hat* também são utilizadas para designar essa transformada (GONZALEZ; WOODS, 2008).

Assim, sejam f uma imagem em escala de cinza e $\lambda_k(f)$ e $\varphi_k(f)$ imagens resultantes da abertura e do fechamento pelo elemento estruturante k , respectivamente; o operador *white top-hat*, que pode ser utilizado para destacar estrutura mais claras, é denotado por:

$$WTH(f) = f - \lambda_k(f). \quad (2.31)$$

Da mesma forma, o operador *black top-hat*, que pode ser utilizado para destacar estruturas mais escuras, é definido como:

$$BTH(f) = \varphi_k(f) - f. \quad (2.32)$$

2.3.6 Melhoria de Contraste baseado com PMR

Nas seções anteriores, foram abordadas algumas técnicas de operações morfológicas convencionais. Durante a execução dessas operações, o elemento estruturante é aplicado à imagem em uma direção fixa. Segundo Kimori *et al.* (2007), Kimori *et al.* (2010), essa abordagem unidirecional do elemento estruturante deixa a desejar quando a imagem possui i variações direcionais mais complexas, como, por exemplo, em imagens médicas. Nesse contexto, Kimori *et al.* (2007) propõem a técnica denominada de Morfologia Matemática Rotacional ou Processamento Morfológico Rotacional - PMR, do inglês *Rotational Morphological Processing*, que consiste em aplicar um único elemento estruturante a uma série de rotações da imagem original. Em seguida, são executadas as operações morfológicas convencionais, abertura e fechamento, para cada imagem rotacionada. Finalmente, as imagens processadas são combinadas em uma única imagem de saída por meio de uma operação de máximo ou mínimo do valor de *pixel* correspondentes. Esse processo é descrito nos passos a seguir:

- Passo 1: A imagem original f é rotacionada no sentido horário. Para a rotação consideram-se os ângulos dentro do intervalo $[0, \pi]$, que é igualmente dividido em N direções. A imagem f_i é a resultante da rotação da imagem original f pelo ângulo $\theta_i = \pi_i/N(\text{rad})$, em que $i = 0, 1, \dots, N - 1$.
- Passo 2: As imagens rotacionadas f_i são processadas pelas operações de abertura ou fechamento utilizando um único elemento estruturante B . Os resultados das operações de abertura e fechamento na imagem rotacionada f_i por B são denotados $\gamma_B(f_i)$ e $\phi_B(f_i)$, respectivamente.
- Passo 3: Em seguida, as imagens resultantes $\gamma_B(f_i)$ ou $\phi_B(f_i)$ são rotacionadas no sentido anti-horário para θ_i (rad). As i -ésimas imagens resultantes após a abertura e fechamento com a nova rotação, são denotadas h_i^o e h_i^c , respectivamente.
- Passo 4: As imagens resultantes do passo anterior são combinadas para gerar uma imagem final. A operação de abertura ou fechamento baseada em PMR cria a imagem de saída a partir dos *pixels* que armazenam o valor máximo ou mínimo sobre todas as imagens processadas na localização do *pixel* correspondente.

Logo, os operadores de abertura-PMR $\gamma_B'(f)$ e fechamento-PMR $\phi_B'(f)$, são definidos conforme a seguir:

$$\text{abertura - PMR : } \gamma_B'(f(x, y)) = \max_{i \in \{0, 1, \dots, N-1\}} \{h_i^o(x, y)\}, \quad (2.33)$$

$$\text{fechamento - PMR : } \phi_B'(f(x, y)) = \min_{i \in \{0, 1, \dots, N-1\}} \{h_i^c(x, y)\}. \quad (2.34)$$

Em termos de PMR, os operadores *white top-hat* e *black top-hat* são formulados da seguinte forma:

$$WTH'(f) = f - \gamma_B'(f(x, y)), \quad (2.35)$$

$$BTH'(f) = \phi_B'(f(x, y)) - f. \quad (2.36)$$

Em (KIMORI *et al.*, 2010) e (KIMORI *et al.*, 2011) as operações *top-hat* baseadas em PMR são aplicadas em várias estruturas biomédicas.

Da mesma forma, definimos o operador de contraste com *top-hat* baseado em PMR como (KIMORI, 2013)

$$\lambda = f + v_{WTH'} - v_{BTH'}, \quad (2.37)$$

em que $v_{WTH'}$ e $v_{BTH'}$ denotam as resultantes da equalização do histograma seguida do aumento de contraste por uma transformação linear (GONZALEZ; WOODS, 2008) aplicados à WTH' e BTH' , respectivamente.

2.4 Filtro de Gabor

O filtro de Gabor foi proposto por Gabor (1946). Para o caso de sinais em uma dimensão (1D), o filtro de Gabor é obtido por meio da modulação de uma senóide com uma Gaussiana, conforme:

$$\psi_e(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{x^2}{2\sigma^2}} \cos(2\pi\phi_0 x) \quad (2.38)$$

$$\psi_e(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{x^2}{2\sigma^2}} \sin(2\pi\phi_0 x) \quad (2.39)$$

em que ϕ_0 é a frequência espacial e σ é o desvio padrão do núcleo da Gaussiana (OPPENHEIM ALAN S. WILLISKY, 2010).

A versão no domínio da frequência foi demonstrada por Gabor (1946) e dada por:

$$\begin{aligned}\psi(x) = \psi_e(x) + i\psi_o(x) &= \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{x^2}{2\sigma^2}} (\cos(2\pi i\phi_0 x) + i\sin(2\pi i\phi_0 x)) \\ &= \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{x^2}{2\sigma^2}} e^{i2\pi i\phi_0 x}.\end{aligned}\quad (2.40)$$

Nas áreas de Processamento de Imagem e Visão Computacional, o filtro de Gabor tem sido utilizado durante décadas em muitas aplicações nos campos de análise de imagens, reconhecimento de objetos, extração de características, dentre outros (KAMARAINEN *et al.*, 2006; FEICHTINGER THOMAS STROHMER (AUTH.), 1998).

Para sinais bidimensionais, como imagens, a forma geral do filtro de Gabor é dada por:

$$\psi(x, y, \theta_k, \omega, \sigma) = e^{-\frac{1}{2}\left(\frac{x_{\theta_k}^2}{\sigma_x^2} + \frac{y_{\theta_k}^2}{\sigma_y^2}\right)} e^{2\pi i\omega x_{\theta_k}} = e^{-\frac{1}{2}\left(\frac{x_{\theta_k}^2}{\sigma_x^2} + \frac{y_{\theta_k}^2}{\sigma_y^2}\right) + 2\pi i\omega x_{\theta_k}} \quad (2.41)$$

em que x e y são as coordenadas espaciais, $x_{\theta_k} = x \cos \theta_k + y \sin \theta_k$, $y_{\theta_k} = -x \sin \theta_k + y \cos \theta_k$, $\theta_k = \frac{\pi(k-1)}{m} | k = 1, 2, 3, \dots, m$ é o ângulo da k -ésima orientação do filtro, σ é o desvio padrão da distribuição Gaussiana do filtro de Gabor para os eixos x e y ; e ω é a frequência de onda no plano senoidal.

Na Figura 2 é mostrado um exemplo da aplicação do filtro de Gabor em uma imagem $I(u, v)$ nas orientações $0, \pi/4, \pi/2$ e $3\pi/4$, utilizando a expressão:

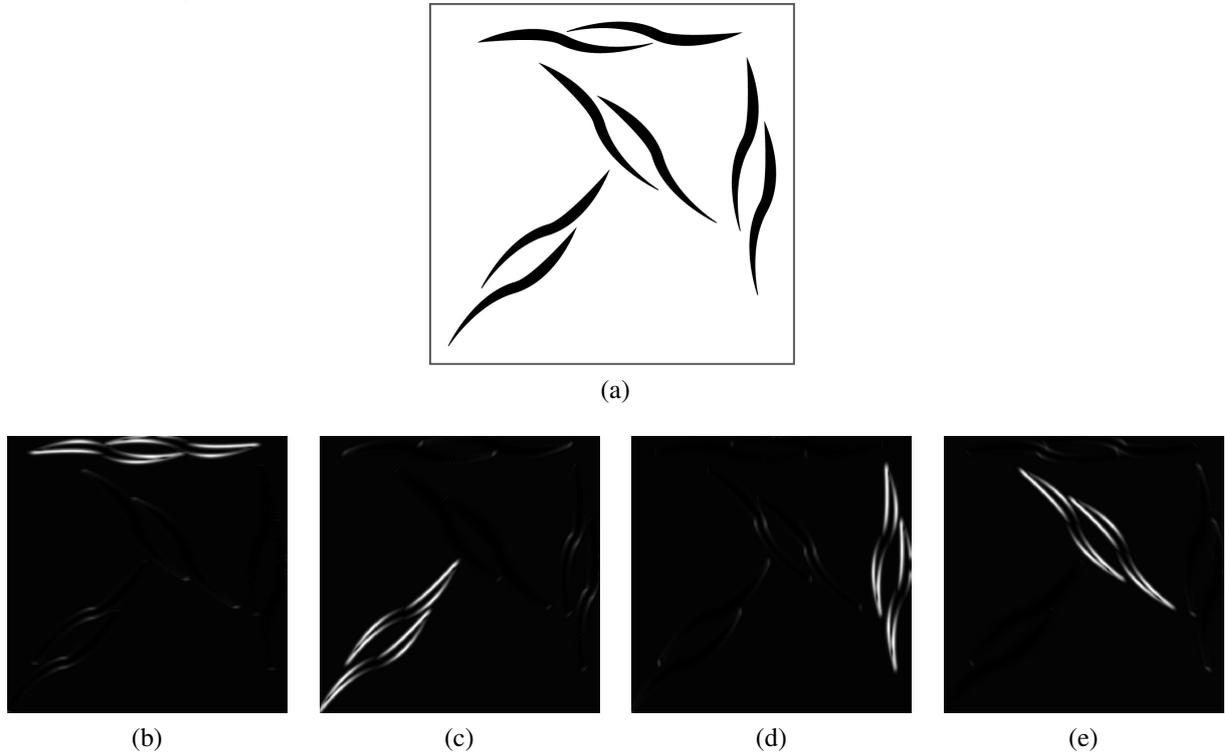
$$g_{\theta_k}(u, v, \omega, \sigma) = \left| \sum_{x=-\frac{\omega}{2}}^{\frac{\omega}{2}} \sum_{y=-\frac{\omega}{2}}^{\frac{\omega}{2}} I(u+x, v+y) \psi(x, y, \theta_k, \omega, \sigma) \right| \quad (2.42)$$

Ainda na Figura 2, com a aplicação do filtro de Gabor é possível obter informações da imagem em uma orientação particular θ_k , pois o filtro remove ruídos e preserva as variações senoidais nos níveis de cinza.

2.5 Avaliação da Segmentação

Em muitas aplicações, a qualidade da segmentação determina o eventual sucesso ou falha na etapa de análise da imagem. Daí a importância de assegurar que no processo de segmentação sejam obtidos resultados com acurácia considerável. Para tanto, faz-se necessário a utilização de métodos para avaliar os resultados obtidos na segmentação e garantir que os

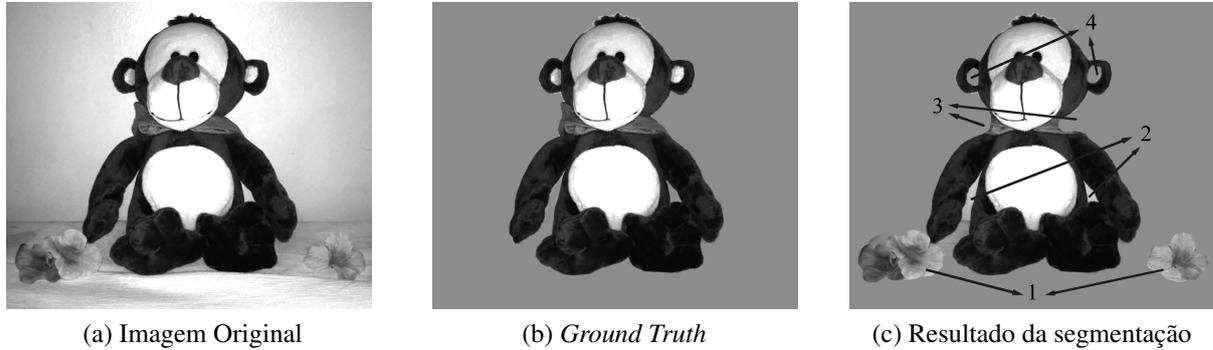
Figura 2 – Exemplo de aplicação do filtro de Gabor na imagem original 2a. Em 2a, 2b, 2c e 2d tem-se o resultado da magnitude do filtro para as orientações iguais $0, \pi/4, \pi/2$ e $3\pi/4$, respectivamente.



requisitos de qualidade da segmentação sejam alcançados (SHI *et al.*, 2014; GONZALEZ; WOODS, 2008; MONTEIRO; CAMPILHO, 2006).

Segundo (ZHANG *et al.*, 2008), existem dois métodos para obtenção de métricas de avaliação da segmentação: não-supervisionado e supervisionado. Para métricas de avaliação não-supervisionada não há a exigência de um GT, que consiste no padrão de referência para segmentação, i.e, é a segmentação ideal. Tais métricas são obtidas com base nas informações da imagem segmentada e na definição de um conjunto de parâmetros que geram os melhores resultados gerais de segmentação em um conjunto predeterminado de imagens de teste. Na abordagem supervisionada, a segmentação é avaliada por meio da comparação com um GT, que é geralmente obtido com o auxílio de um ou mais especialistas. Na figura 3 tem-se um exemplo de GT e de segmentação com erros.

Figura 3 – Exemplo de imagem antes da segmentação, de um GT e do resultado de segmentação. Em 3c pode-se observar alguns tipos de erros: 1 - Outras regiões incorretamente adicionadas; 2 - partes do fundo foram adicionadas; em 3 e 4 regiões de bordas e regiões internas não segmentadas, respectivamente.



Fonte: Imagem adaptada de (SHI *et al.*, 2014)

Além disso, tais métodos avaliativos podem ainda ter uma abordagem significativamente diferente, pois as definições dos padrões de referência podem variar. Assim, considerando as abordagens clássicas de segmentação, a avaliação não-supervisionada e supervisionada podem ser aplicadas para obter métricas baseadas em bordas e métricas baseadas em região. A primeira, se concentra em como avaliar a "distorção" da borda resultante da segmentação. Na segunda, a avaliação pode ser obtida por meio da sobreposição das regiões segmentadas com as regiões de referência. (SHI *et al.*, 2014; MONTEIRO; CAMPILHO, 2006)

Neste estudo, utilizamos a abordagem supervisionada para obter as métricas necessárias para avaliar a sobreposição de regiões. Para tanto, utiliza-se as métricas como: coeficiente de DICE, e também, acurácia, sensibilidade, dentre outras, obtidas a partir da matriz de confusão. Essas medidas são descritas nas subseções 2.5.1 e 2.5.2 a seguir.

2.5.1 *Matriz de Confusão - MC*

É comum apresentar várias medidas no contexto dos problemas de classificação binária/segmentação. Um dos recursos utilizados para obter essas medidas e sintetizar a predição em relação ao valor esperado, é a matriz de confusão (POWERS, 2011). A Tabela 2 mostra como é definida a matriz de confusão para os casos de segmentação ou classificação binária.

Considerando o problema de segmentação, objeto deste estudo, os *pixels* da região segmentada podem pertencer ao GT, denotada na matriz de confusão da Tabela 2 como região **R**, e podem não pertencer ao GT, denotada também na matriz de confusão como $\sim\mathbf{R}$. Assim, a quantidade de *pixels* segmentados corretamente é representada pelos valores Verdadeiro Positivo

Tabela 2 – Matriz de confusão para segmentação esperada e predita.

		Predito	
		R	$\sim R$
Esperado	R	VP	FP
	$\sim R$	FN	VN

(VP) e Verdadeiro Negativo (VN). Falso Positivo (FP) é a quantidade de *pixels* que não pertencem ao GT segmentados como pertencentes ao GT; por fim, Falso Negativo (FN) é a quantidade de *pixels* que pertencem ao GT segmentados como não pertencentes ao GT.

As métricas a seguir são obtidas a partir da matriz de confusão:

- Acurácia: mede a proporção de segmentações corretas em relação ao total de elementos segmentados, conforme a equação

$$Ac = \frac{VP + VN}{VP + VN + FP + FN}; \quad (2.43)$$

- Precisão: é o valor preditivo positivo que mede a capacidade da segmentação em identificar pontos que não correspondem ao GT. É definida pela equação

$$Pr = \frac{VP}{VP + FP}; \quad (2.44)$$

- Sensibilidade (*Recall*): representa a proporção de elementos apresentados no GT que foram identificados corretamente. É dada pela equação

$$Se = \frac{VP}{VP + FN}; \quad (2.45)$$

2.5.2 Coeficiente de Similaridade de Dice (CSD)

Coeficiente de Similaridade de Dice, também relatado na literatura como Índice de Sørensen–Dice (ISC), proposto em diferentes trabalhos por Sørensen (1948) e Dice (1945) para mediar a associação entre diferentes grupos de espécies na área de botânica (HUHTA, 1979). Atualmente, essa medida vem sendo aplicada para avaliar o resultado alcançado após a segmentação de imagens. O CSD é definido como

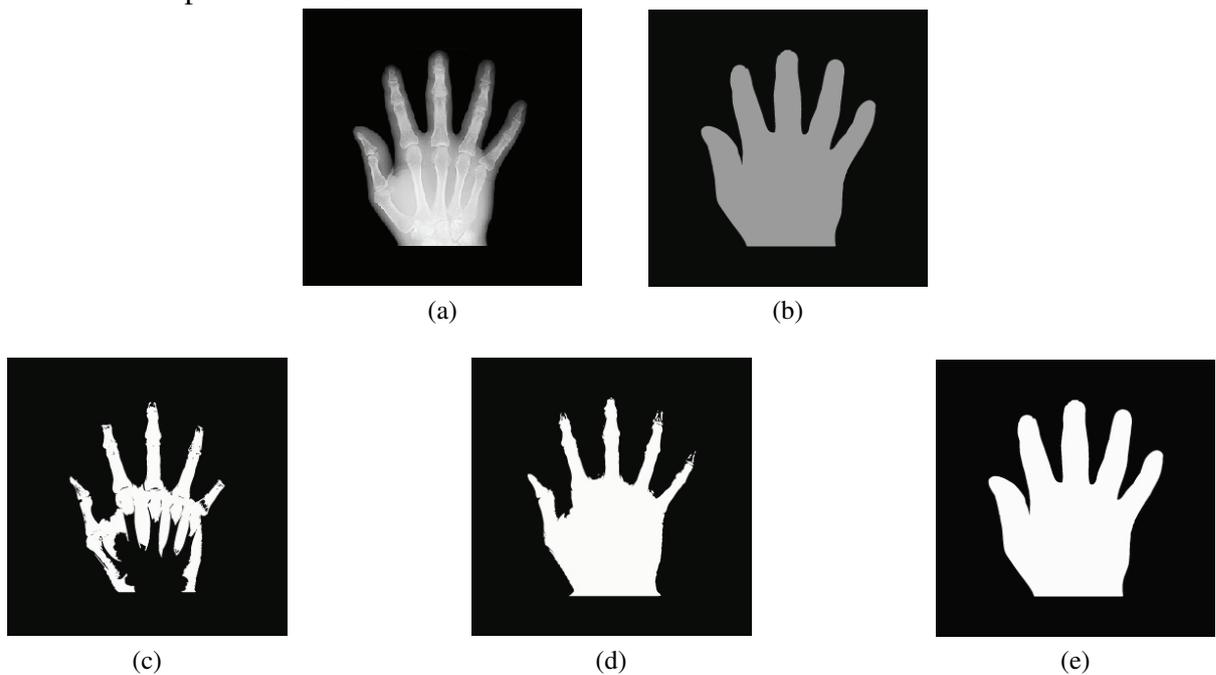
$$CSD(A, B) = \frac{2\#(A \cap B)}{\#(A) + \#(B)}, \quad (2.46)$$

em que # denota a cardinalidade e $0 \leq CSD(A, B) \leq 1$. Na avaliação da segmentação, CSD pode ser entendido como uma medida para a sobreposição espacial entre o GT e a região segmentada. De acordo com (ZIJDENBOS *et al.*, 1994), uma boa medida para segmentação ocorre quando $CSD > 0.700$, como no exemplo da Figura 4 (pág. 43).

O CSD também pode ser expresso em termos de Verdadeiro Positivo (VP), Falso positivo (FP) e Falsos Negativo (FN)

$$CSD(A, B) = \frac{2VP}{2VP + FP + FN} \quad (2.47)$$

Figura 4 – 4a é imagem original; 4b é o *ground truth*; 4c, 4d e 4e são segmentações realizadas com Coeficiente de Similaridade de Dice igual a 0,6124, 0,8528 e 0,9895, respectivamente.

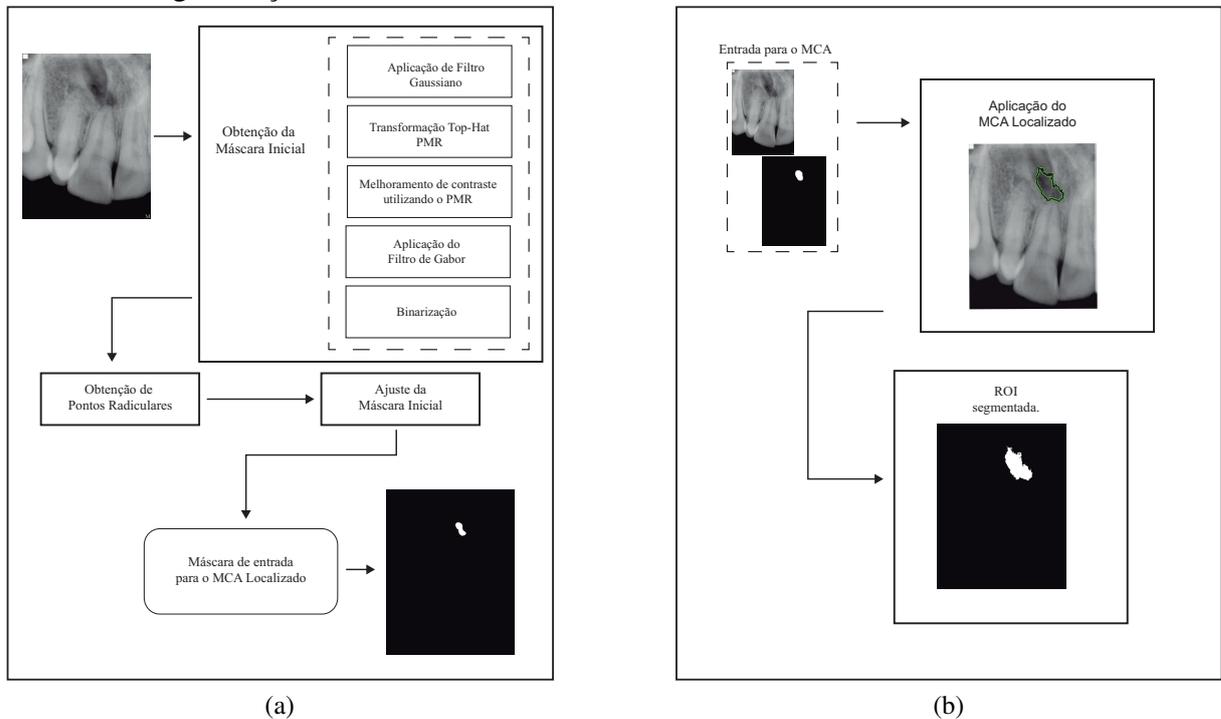


Fonte: Arquivo pessoal.

3 METODOLOGIA

Neste capítulo são descritos todos passos necessários para segmentação de lesões em imagens radiográficas periapicais, proposta deste estudo. Inicialmente, na Seção 3.1, o processo de aquisição das imagens é abordado. Em seguida, na Seção 3.2, descreve-se como foram obtidas as informações do GT de cada imagem. Nas Seções 3.3, 3.4 e 3.5 são descritas as etapas de obtenção da máscara inicial para o MCA, detecção de pontos radiculares para ajuste da máscara inicial e a aplicação do MCA, respectivamente. Essas três etapas são ilustradas e resumidas no fluxograma nas Figuras 5a e 5b a seguir.

Figura 5 – Fluxograma explicativo da metodologia proposta. 5a mostra o processo para obtenção da máscara de entrada do MCA Localizado; e em 5b tem-se a etapa do processo de segmentação.



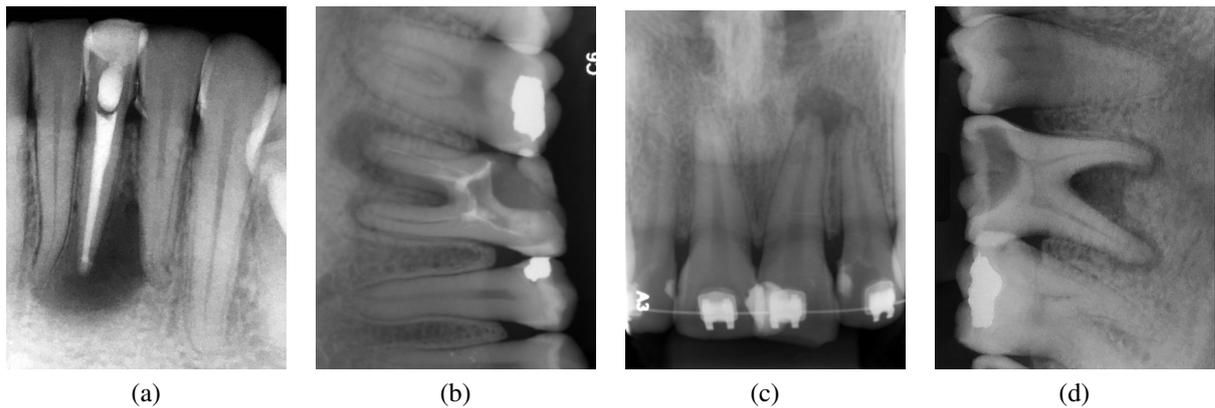
Fonte: Autoria própria.

3.1 Aquisição das Imagens

A radiografia periapical possibilita uma visão em conjunto dos elementos dentais - a anatomia dentária (coroa e raiz), as estruturas ao redor dos dentes da região de incidência dos raios-x e do tecido ósseo adjacente. Para os experimentos, foram utilizadas 30 (trinta) imagens de radiografias periapicais, obtidas por meio das técnicas da bisettriz ou do paralelismo (ver

Apêndice B, página 74), capturadas em níveis de cinza, com codificação de cor com 8 bits (256 níveis de cinza) e uma resolução 476×620 pixels, nas quais os pacientes foram diagnosticados com cisto periapical. A obtenção dessas imagens foi possível com a parceria realizada com o curso de Odontologia da UFC - *Campus* Sobral. A seguir, na Figura 6, tem-se três exemplares do conjunto de imagens deste trabalho.

Figura 6 – 6a, 6b, 6c e 6d são exemplares de imagens de radiografias periapicais utilizadas neste estudo.



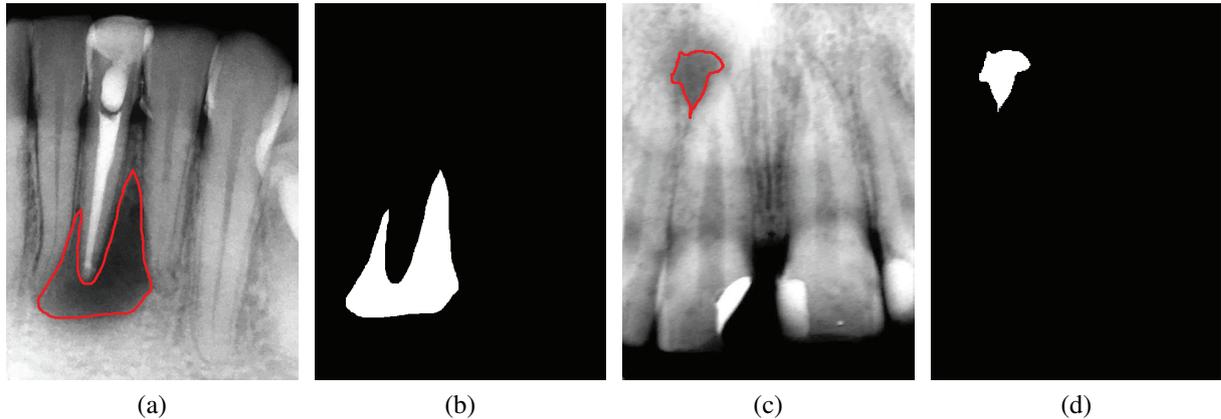
Fonte: Imagens obtidas em parceria com o curso de Odontologia - UFC / *Campus* Sobral

3.2 Obtenção do *Ground Truth* - GT

Conforme descrito na Seção 2.5, o *Ground Truth* - GT é o padrão de referência estabelecido para comparação com os resultados obtidos na segmentação. Com o objetivo de avaliar a metodologia proposta, criou-se uma aplicação web dotada de ferramentas que possibilitaram o cadastro das imagens utilizadas neste trabalho, bem com a realização das marcações das regiões de interesse (*ROIs* – *Regions of Interest*), que compreendem as lesões e que serão denominadas de GT. Todas as marcações foram realizadas por especialistas cirurgiões-dentistas e professores do Curso de Odontologia da Universidade Federal do Ceará - UFC, *Campus* Sobral. A Figura 7, página 46, mostra duas imagens com suas respectivas marcações e a imagem binária gerada com a(s) ROI(s) obtida(s) a partir da marcação.

As informações referentes ao GT de cada imagem foram armazenadas em banco de dados, inclusive com a descrição, dada pelo especialista cirurgião-dentista, das lesões diagnosticadas na imagem.

Figura 7 – 7a e 7c são imagens com a marcação realizada pelo especialista; 7b e 7d representam os GTs binarizados a partir das respectivas marcações.



Fonte: Imagens geradas durante a obtenção do GT em parceria com o curso de Odontologia - UFC / *Campus* Sobral.

3.3 Obtenção da Máscara Inicial

Na etapa descrita na Figura 5a, temos o processo de obtenção da máscara inicial que será utilizada no Modelo de Contorno Ativo. Inicialmente, deve-se realizar o pré-processamento da imagem de entrada, de agora em diante denominada de I . O filtro gaussiano é aplicado para remoção de ruídos, no qual é utilizada a função gaussiana em duas dimensões, dada por

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2}, \quad (3.1)$$

em que x é a coordenada no eixo x , y a coordenada no eixo y e σ é o desvio padrão da distribuição gaussiana. Os valores dessa distribuição são usados para construir uma matriz de convolução que é aplicada em I gerando a imagem I_G . Uma vez que a imagem digital é um conjunto de *pixels* discretos, uma aproximação discreta da função gaussiana é obtida antes de realizar a convolução. Para os experimentos, foram utilizados uma janela de dimensão 3×3 e o valor de σ igual a $5,0$. Esses valores foram obtidos empiricamente.

Após a aplicação do filtro gaussiano, é executado o passo para melhoramento de contraste, no qual considerou-se as especificidades do conjunto de imagens. Tais imagens são em escala de cinza, com codificação de cor com 8 bits (256 níveis de cinza) e apresentam inúmeras estruturas anatômicas da região oral e maxilofacial, como, por exemplo: mandíbula, dente, osso alveolar, cavidade nasal, seio maxilar e septo nasal e, nos achados apresentados neste trabalho, uma ou mais regiões com lesão. Uma vez que nas imagens radiográficas os dentes apresentam um aspecto mais radiopaco do que as outras estruturas, e as lesões têm um aspecto mais radiolúcido, aplicamos a técnica de melhoramento de contraste utilizando PMR

proposta por (KIMORI, 2013; KIMORI *et al.*, 2010; KIMORI *et al.*, 2007), apresentada na Seção 2.3.6, que possibilita evidenciar as diferenças entre essas duas estruturas. A Figura 8 (pág. 48) mostra o histograma representativo da região de lesão e do elemento dentário, no qual observa-se que intervalos dos níveis de cinza pertencentes a cada região são disjuntos. Foram criadas quatro versões de \mathbf{I} , denotadas por I_{θ_i} , $i = 1, 2, 3$ e 4 , rotacionadas em 30° , 45° , 60° e 90° . Para cada I_{θ_i} , aplicou-se a operação morfológica de abertura e fechamento, resultando em versões γ_{θ_i} e ϕ_{θ_i} , respectivamente. Em seguida, γ_{θ_i} e ϕ_{θ_i} são todas rotacionadas para o ângulo inicial de 0° , com as imagens resultantes passando a ser denotadas por α_i e β_i . Em seguida, as versões resultantes são combinadas pixel a pixel para obter a abertura-PMR e fechamento-PMR, conforme a seguir:

$$\text{abertura - PMR} : \gamma' \theta = \max_{i \in (1,2,3,4)} \{\alpha_i\}, \quad (3.2)$$

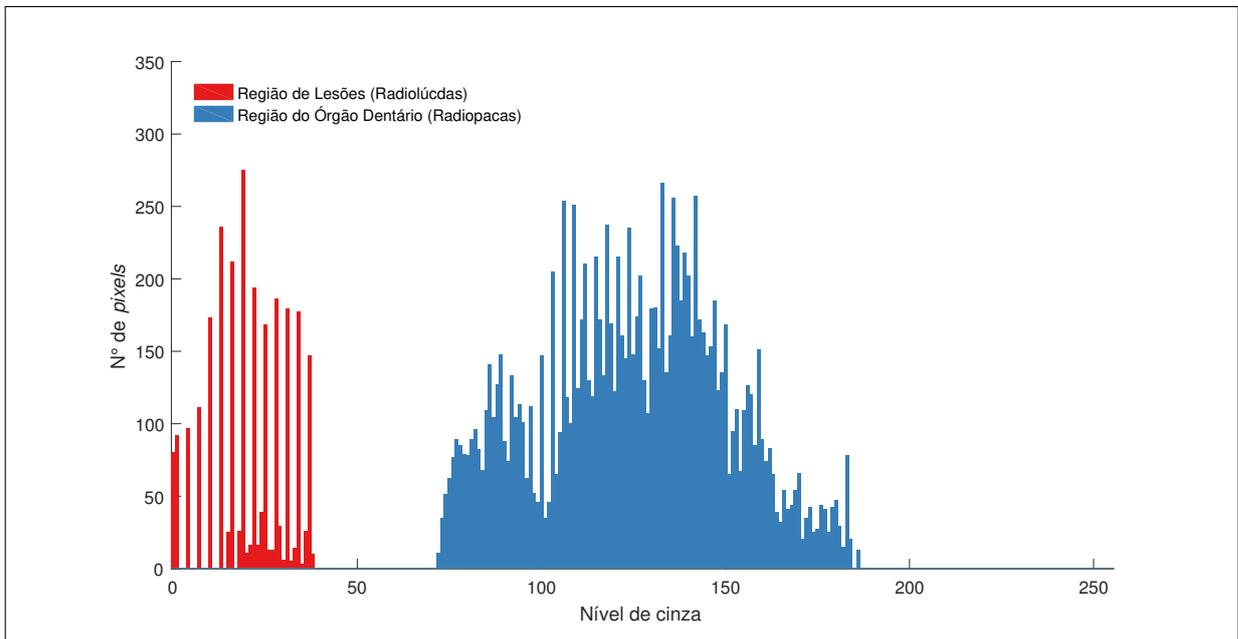
$$\text{fechamento - PMR} : \phi' \theta = \min_{i \in (1,2,3,4)} \{\beta_i\}. \quad (3.3)$$

Com a abertura-PMR e fechamento-PMR, o próximo passo é a obtenção das transformadas *white top-hat* e *black top-hat* em termos de PMR, conforme mostrado na Subseção 2.3.6. Por fim, aplica-se a operação para aquisição do melhoramento de contraste com os operadores *white top-hat* e *black top-hat* em termos do PMR, com operações de adição (*white top-hat*) e subtração (*black top-hat*) com a imagem I_G , resultante da aplicação do filtro gaussiano. A equação 3.3, definida na Subseção ??, descreve esta operação. Posteriormente, aplicamos uma binarização da imagem por limiarização (*threshold*). A Figura 9 mostra alguns exemplos de imagens e os resultados gerados após a aplicação em sequência da gaussiana, do melhoramento de contraste e do resultado da binarização.

A partir da imagem binarizada, foi executado um processamento simples para remoção de regiões não fechadas e de regiões dos espaços interdentais. Por fim, obtém-se a máscara inicial de entrada para o MCA. O resultado obtido é ilustrado na Figura 10 (pág. 50).

Conforme relatado anteriormente, há inúmeras estruturas anatômicas na região oral e maxilofacial. Algumas dessas estruturas podem aparecer na imagem radiográfica com um aspecto semelhante ao das lesões, como pode ser visto na imagem 9e, na qual as fossas nasais apresentam-se também com aspecto radiolúcido. Para o cirurgião dentista é simples diferenciar essas estruturas. Quando existem essas variações nas imagens radiográficas, a máscara inicial obtida possui regiões de *pixels* que deverão ser removidas antes da aplicação do MCA para

Figura 8 – Histograma da região que compreende uma lesão periapical (vermelho) e da região dos elementos dentários (azul).



Fonte: Arquivo pessoal

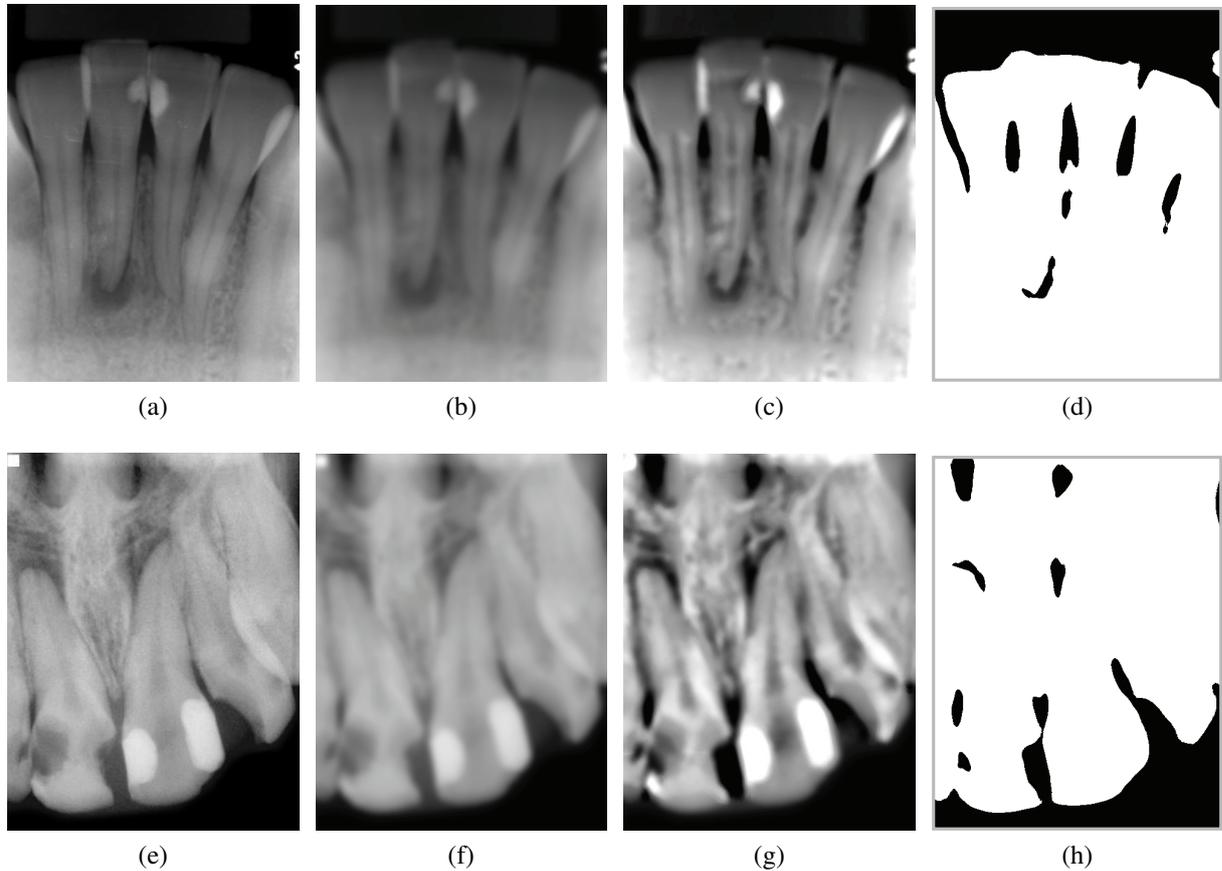
segmentação das lesões, conforme pode ser visto na imagem 10b. Esse procedimento deve ser realizado para que sejam evitados erros na segmentação. Para contornar esse problema, a etapa de detecção de pontos radiculares deve ser executada para ajuste da máscara inicial, de acordo com os procedimentos apresentados na Seção 3.4 a seguir.

3.4 Detecção de Pontos Radiculares e Ajuste da Máscara Inicial

O foco deste estudo é a segmentação de lesões periapicais, também denominadas de lesões radiculares. Esse tipo de lesão acomete parte da região do periápice do dente (MARTIN; SPEIGHT, 2017; NEVILLE DOUGLAS D. DAMM, 2015; BARNES JOHN W. EVESON, 2005). Portanto, o objetivo desta etapa é encontrar pontos pertencentes às regiões radiolúcidas, com margens corticais bem definidas, presentes no ápice radicular dentário. Nesse sentido, o processo de detecção de pontos radiculares é aplicado à imagem **I** para ajuste da máscara inicial obtida durante a etapa apresentada na Seção 3.3.

As imagens radiográficas periapicais utilizadas neste estudo foram obtidas por meio das técnicas da bissetriz ou do paralelismo (ver Apêndice B, página 74). Esses tipos de radiografias periapicais devem mostrar o(s) dente(s) completamente, incluindo o osso circundante. Alia-se a isso o fato de que deve estar associada à qualidade dessas imagens radiográficas: 1 - o registro das áreas de interesse; nas intraorais, o comprimento da raiz do(s) dente(s) e pelo menos

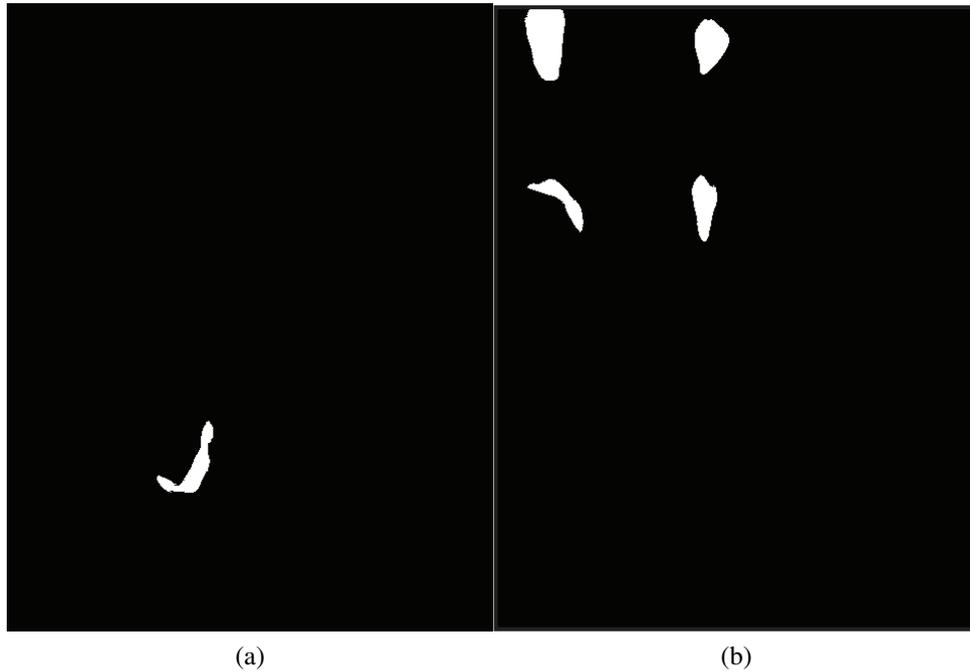
Figura 9 – Alguns exemplos dos resultados gerados após a aplicação em sequência da gaussiana, do melhoramento de contraste e do resultado da binarização. 9a e 9e são imagens originais; 9b e 9f são resultantes da aplicação do filtro gaussiano; 9c e 9g mostram o resultado do melhoramento de contraste baseado em PMR; e, por fim, 9d e 9h o resultado após a binarização.



Fonte: Imagens geradas durante os experimentos e em parceria com o curso de Odontologia - UFC / *Campus* Sobral.

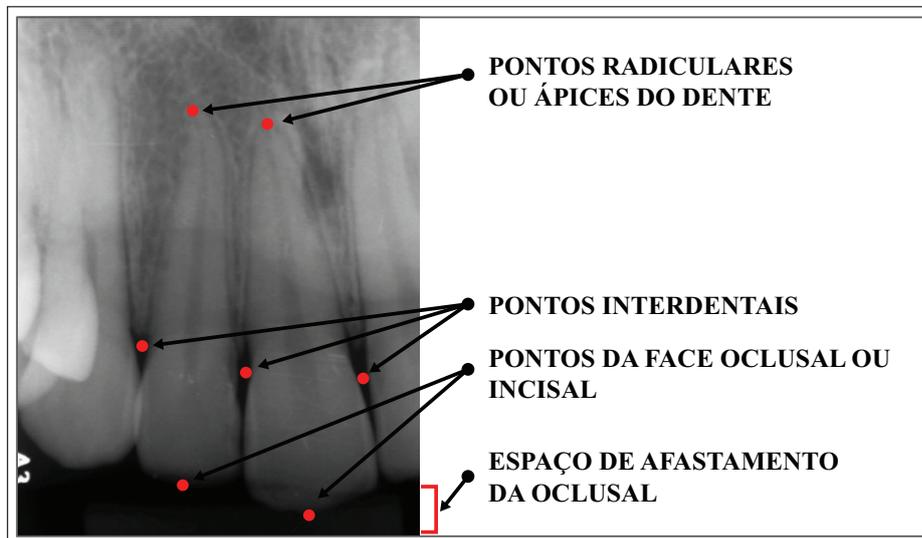
2mm de osso periapical devem estar visíveis; 2 - se há evidência de uma condição patológica, a área de toda a lesão mais algum osso normal circundante devem aparecer; e, 3 - a ultrapassagem da face oclusal ou incisal do(s) dente(s) em cerca de 4 a 5mm (WHITE, 2013; FREITAS; ROSA, 2004; FITZGERALD, 2001). Estas peculiaridades das radiografias periapicais permitem identificar alguns padrões nas imagens utilizadas neste trabalho, como, por exemplo, o espaço de afastamento a partir da face oclusal do(s) dente(s), os espaços interdentais entre as faces mesial ou distal. A Figura 11 mostra alguns dos pontos importantes para execução desta etapa.

Figura 10 – Máscaras iniciais. 10a e 10b foram obtidas a partir das imagens 9a e 9e, respectivamente.



Fonte: Imagens geradas durante os experimentos.

Figura 11 – Pontos da estrutura anatômica do periápice dentário, espaços interdentais e faixa oclusal.



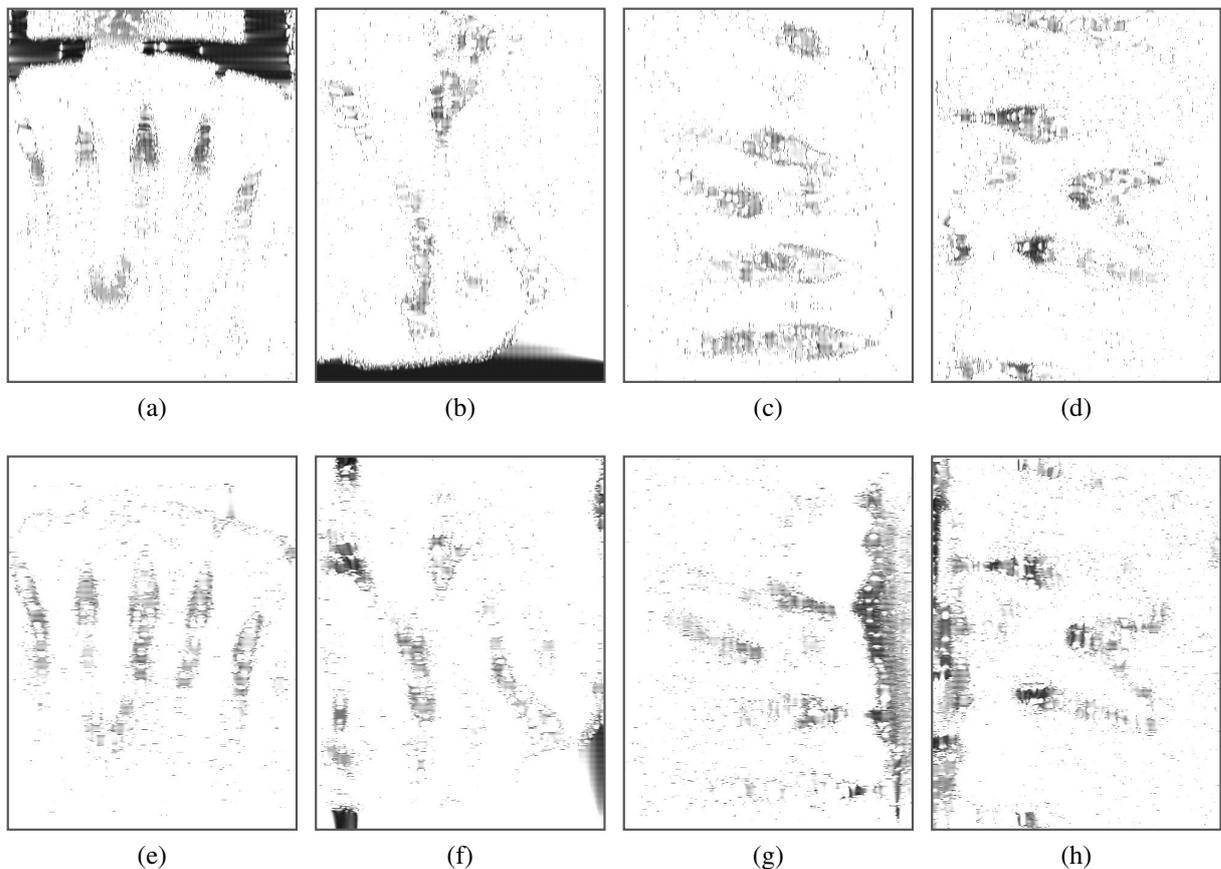
Fonte: Arquivo pessoal

Além disso, uma observação também importante é que há variações na orientação das imagens. Portanto, o primeiro passo do processo consiste em encontrar a linha do limite oclusal dos dentes.

O processo também inicia-se com técnica de melhoramento de contraste utilizando o PMR aplicada à imagem **I**. No entanto, para o filtro gaussiano aplicado antes da técnica,

foram utilizados uma janela de dimensão 3×3 e o valor de σ igual a $0,5$. Estes valores foram estabelecidos empiricamente, obtendo assim $I_{G_{\sigma=0,5}}$ que é menos desfocada do que a versão I_G da etapa anterior (Seção 3.3). Em seguida, aplica-se o filtro de Gabor em $I_{G_{\sigma=0,5}}$. Para tanto, como as linhas interdentais são sempre ortogonais a linha base do limite oclusal dos dentes, foram escolhidas as orientações $\theta = 0^\circ$ e 90° graus para obtenção de duas componentes de magnitude. Neste processo, o desvio padrão σ da distribuição gaussiana que modula o filtro de Gabor tem valor $\sigma = 0,5$ para os eixos x e y ; o comprimento de onda λ (*em pixels*) do fator senoidal tem valor igual $2,0$; a largura de banda de frequência espacial b igual a $1,0$; e a razão de aspecto espacial γ , que controla a elipticidade do fator gaussiano, igual a $0,5$. Todos esses parâmetros foram determinados empiricamente. Exemplos de componentes geradas a partir da aplicação do filtro de Gabor em alguns dos exemplares do conjunto de imagens são exibidos na Figura 12, na qual são mostradas as resposta de magnitude resultante do filtro de Gabor aplicado nas imagens 6b e 6d da Figura 6 (pág. 45) e também nas imagens 9a e 9e da Figura 9 (pág. 49).

Figura 12 – Exemplos de componentes geradas a partir da aplicação do filtro de Gabor. 12a, 12b, 12c e 12d são componentes com $\theta = 0^\circ$; e 12e, 12f, 12g e 12h são componentes com $\theta = 90^\circ$.



Fonte: Imagens geradas durante os experimentos.

Em seguida, é realizada uma binarização das componentes para o cálculo da frequência média dos *pixels* iguais a zero. Para a componente com $\theta = 0^\circ$ e $\theta = 90^\circ$ considera-se, respectivamente, as equações

$$fm_{1z}(i) = \frac{\sum_{j=1}^M 1 - I_{\theta}bw(i, j)}{M}, \quad i = 1, 2, \dots, N, \quad (3.4)$$

e

$$fm_{2z}(j) = \frac{\sum_{i=1}^N 1 - I_{\theta}bw(i, j)}{N}, \quad j = 1, 2, \dots, M, \quad (3.5)$$

em que N é a quantidade de linhas e M a quantidade de colunas. A partir do cálculo das frequências, verificam-se os pontos de máximo, de acordo com o mostrado nos gráficos da Figura 13 (pág. 53). Dessa forma, é identificada qual componente possui o ponto da linha base do limite oclusal dos dentes, mostrada na Figura 14 (pág. 53) a seguir.

Identificada a linha base do limite oclusal, obtêm-se todos os pontos incisais, para os quais é aplicada uma regressão polinomial para gerar a curva do limite oclusal. Para essa regressão consideramos um polinômio $p(x) = p_1x^n + p_2x^{n-1} + \dots + p_nx + p_{n+1}$ de grau 6 para se ajustar aos pontos dados.

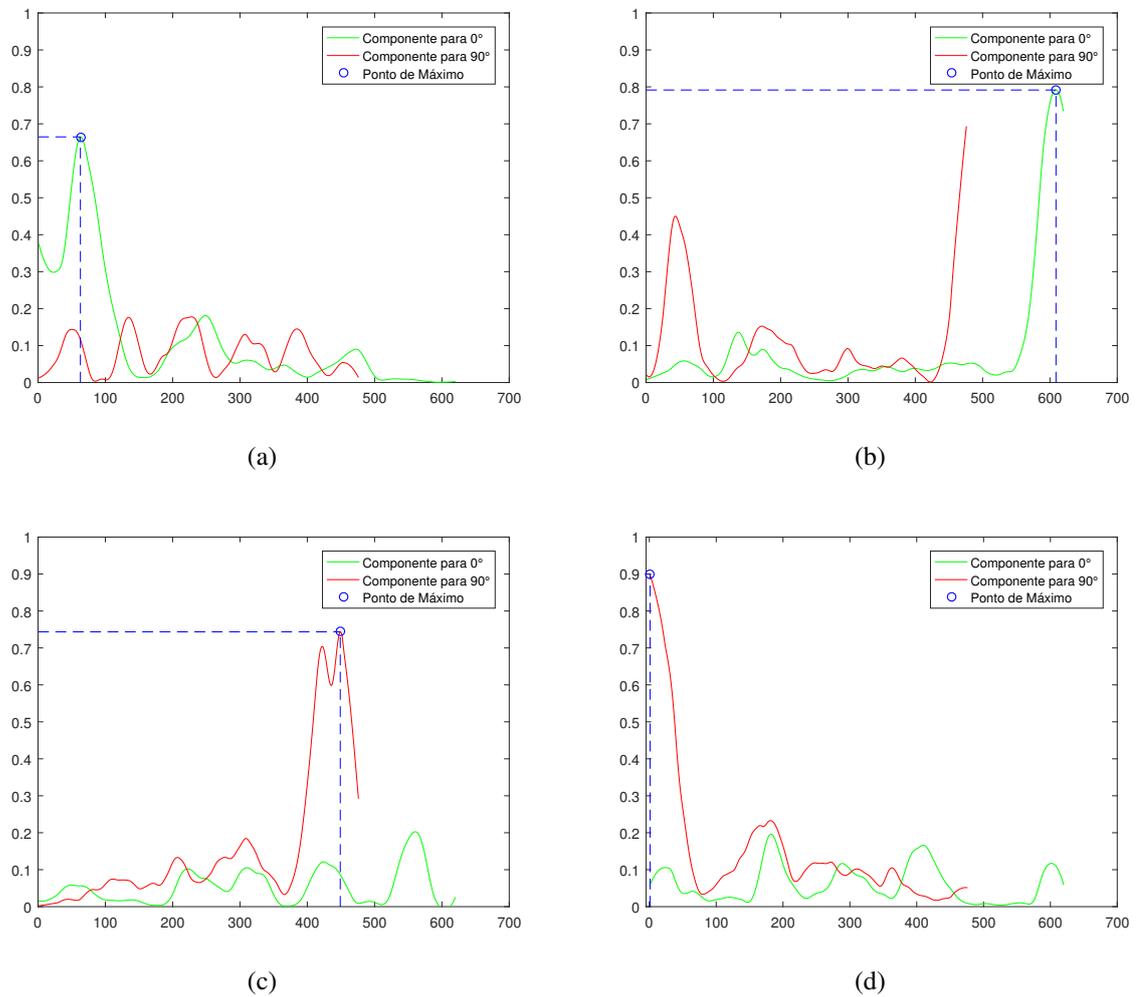
Em seguida, para identificação dos picos e obtenção das linhas interdentais, realiza-se a união dos *pixels* iguais a zeros das imagens binarizadas a partir das duas componentes, seguida da soma dos *pixels* iguais a 1 das linhas (colunas) ortogonais à linha base. Os vales da curva gerada a partir da soma são os pontos interdentais (linhas ou colunas com maior incidência de 0's). Nesse processo, para uma melhor visualização e entendimento, o gráfico gerado foi invertido (os vales passam a ser pico) e plotado juntamente com a imagem original. O resultado pode ser visualizado na Figura 15 (pág. 54).

Finalmente, com as coordenadas do pontos radiculares encontradas B_{radic} , para o ajuste da máscara inicial obtida na Seção 3.3 (pág. 46), obtêm-se as coordenadas do centroide das regiões da máscara inicial C_{masc} e calcula-se distância euclidiana D_e , dada por:

$$D_e(P, Q) = \sqrt{(p_x - q_x)^2 + (p_y - q_y)^2}, \quad P \in B_{radic} | P = (p_x, p_y) \quad e \quad Q \in C_{masc} | Q = (q_x, q_y), \quad (3.6)$$

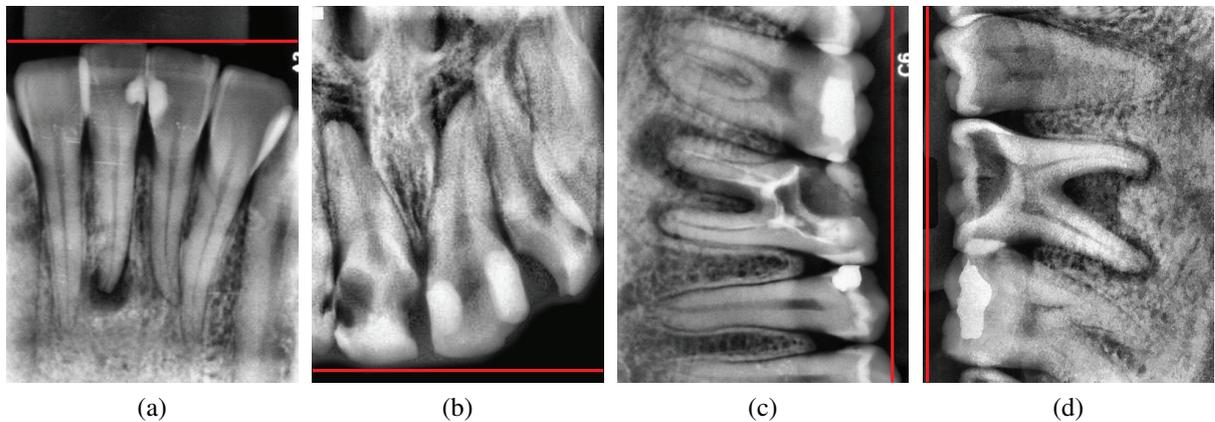
para cada centroide em relação a todos os pontos radiculares. Todas as regiões dos centroides com distância menor ou igual ao raio r_{max} de valor igual 100 (em *pixels*), são mantidas na máscara inicial. As demais, são removidas.

Figura 13 – Gráficos com o cálculo de frequência média de zeros e os pontos de máximo para cada uma das componentes obtidas com a aplicação do filtro de Gabor nas imagens 6b e 6d da Figura 6 (pág. 45) e também nas imagens 9a e 9e da Figura 9 (pág. 49).



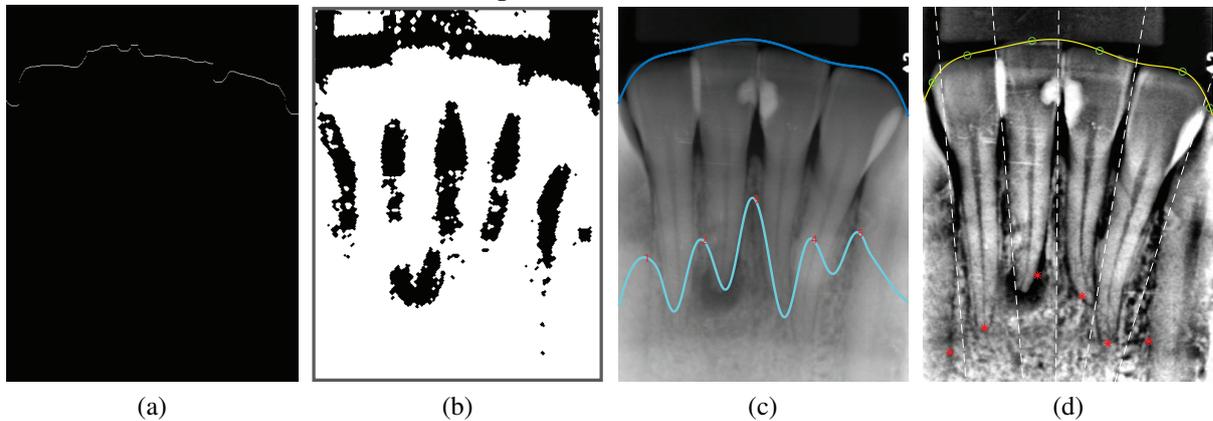
Fonte: Imagens geradas durante os experimentos.

Figura 14 – 14a, 14b, 14c e 14d mostram a identificação da linha base (em vermelho) da oclusal do dentes.



Fonte: Imagens geradas durante os experimentos.

Figura 15 – Resultados obtidos a partir da identificação da linha da faixa oclusal. Em 15a tem-se todos os pontos incisais dos dentes; Em 15b união dos *pixels* iguais a zeros da duas componentes binarizadas. 15c mostra a imagem original com os gráficos da regressão a partir dos pontos incisais e da projeção da integral realizada para linhas (colunas) ortogonais à linha base da oclusal com os picos encontrados; 15d apresenta as linhas interdentais e os pontos incisais intermediários e radiculares encontrados.



Fonte: Imagens geradas durante os experimentos.

Posteriormente, temos a etapa descrita na Figura 5b, na qual a imagem original e a máscara ajustada são as entradas. O método de segmentação utilizando o MCA é executado e a região de interesse da imagem é obtida, conforme descrito na Seção 3.5 a seguir.

3.5 Aplicação do MCA

Nesta etapa é aplicado o Modelo de Contorno Ativo Localizado Baseado em Região (*Localizing Region-Based Active Contours*) a partir da máscara inicial obtida. O MCA Local é um *framework* proposto por Lankton e Tannenbaum (2008), em que a segmentação é baseada nas informações locais de um determinado raio (R) centrado em cada ponto da curva do Modelo de Contorno Ativo, conforme apresentada na Subseção 2.2.3 (pág. 32). Escolheu-se esse modelo pelo fato de que as regiões de interesse, mesmo possuindo delimitações bem definidas, apresentam semelhanças com outras regiões. Dessa forma, a aplicação de um MCA baseado em regiões com cálculo de energia global poderá segmentar regiões que não correspondem a lesões.

Para aplicação do MCA Localizado, os parâmetros foram definidos da seguinte forma: o raio R igual a 69 (em *pixels*) e peso γ do termo de suavização da curvatura do MCA igual a 0,5.

Finalmente, para avaliar a metodologia proposta, todas as regiões de interesse segmentadas das imagens são comparadas com o *GT*. Na Seção 3.6 são descritos os procedimentos para a avaliação do método e obtenção dos valores das métricas, conforme descritas na Subseção

2.5.

3.6 Avaliação

Conforme descrito na Seção 3.2 (pág. 45), utilizou-se uma avaliação supervisionada para verificar os resultados das segmentações realizadas, com base nas regiões de interesse (ROIs – Regions of Interest), que compreendem as lesões e que foram marcadas por especialistas cirurgiões-dentistas, denominadas de *Ground Truth - GT*. O objetivo é comparar as regiões segmentadas pelo método proposto com o GT (marcações dos especialistas - Seção 3.2)

Para estabelecer as métricas que quantifiquem a precisão do método de segmentação, além de reduzir a subjetividade visual da análise, considerou-se cada uma das medidas descritas na Subseção 2.5 (pág. 39). Inicialmente, foi obtida a matriz de confusão para cada um dos resultados obtidos com a segmentação das lesões. Com a matriz de confusão gerada, foram obtidas as medidas: Acurácia (AC), Precisão (PR), Sensibilidade (SE). Para a medida de sobreposição da região segmentada com o GT, foi calculado o Coeficiente de Similaridade de Dice - CSD, também para cada uma dos resultados de segmentação. O resultados são apresentados no Capítulo 4 (pág. 56).

4 RESULTADOS E DISCUSSÕES

Este capítulo trata dos resultados alcançados após a realização dos experimentos com a segmentação da(s) lesão(ões) periapicais, conforme especificado no Capítulo 3. A segmentação resultante é uma imagem binária que apresenta fundo (*background*) na cor preta (*pixels* iguais a 0) e a região segmentada, que compreende a possível lesão, apresenta cor branca (*pixels* iguais a 1). Uma base com 30 (trinta) imagens periapicais radiográficas digitais foi construída em parceria com o curso de Odontologia da Universidade Federal Ceará - UFC / *Campus* Sobral, assim como o *Ground Truth - GT* para cada uma das 30 (trinta) imagens adquiridas.

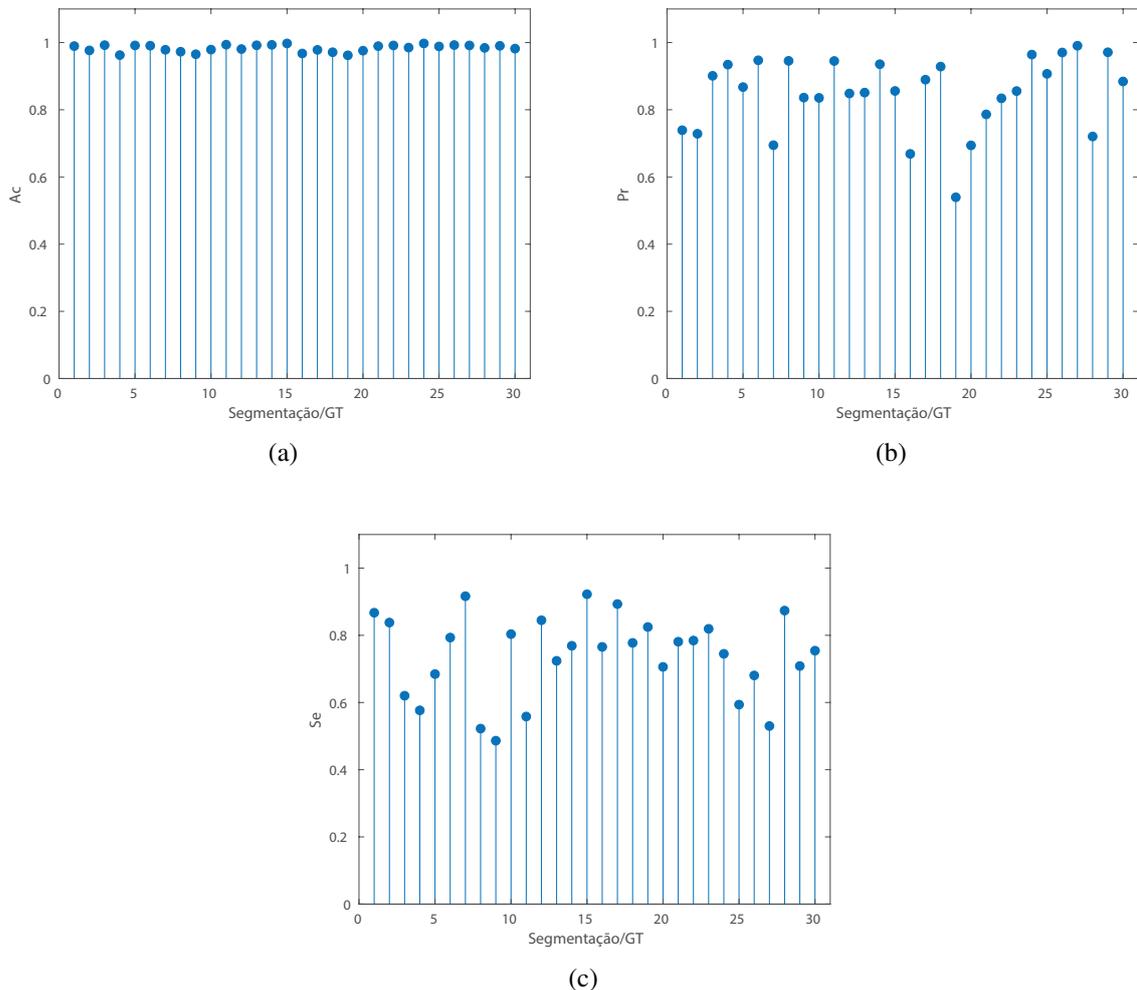
4.1 Métricas Obtidas

Nos experimentos, executou-se a metodologia proposta e, após a obtenção do resultado da segmentação, foram calculadas as medidas de Acurácia (Ac), Precisão (Pr) e Sensibilidade (Se) oriundas da matriz de confusão gerada. A Figura 16 apresenta os gráficos para cada uma dessas medidas, obtidas em relação à segmentação e ao *GT* de cada imagem.

Os valores apresentados no gráfico da Figura 16a, como podem ser observados, estão todos apresentando valores acima 95% de acurácia. Apesar de ser um dado ótimo para a pesquisa, leva, na verdade, a uma percepção errada de que todas as segmentações (para cada imagem) estiveram muito próximas das marcações realizadas pelos especialistas cirurgiões-dentistas. Considerando a base de imagens utilizada, esses valores são reflexos de um dado interessante, de que a(s) lesões(s) periapical(is) corresponde(m), em média, a uma região com 10.000 *pixels* de uma imagem com 295.120 *pixels* (resolução 476x620). Essa discrepância da quantidade de *pixels* não pertencentes à área da lesão, possibilita uma alta probabilidade de que o valor Verdadeiro Negativo (VN) seja elevado, o que resulta nos valores mostrados no gráfico de acurácia. No entanto, é um indicativo de que regiões que compreendem os espaços interdentais, a faixa após a oclusal e outras, não foram segmentadas como pertencentes ao *GT*, haja vista que estas também apresentam intensidade dos *pixels* próximos das apresentadas pelas lesões, que resultaria em um valor menor para VN.

Quanto aos valores de precisão, esses permitem obter uma melhor informação dos resultados em relação a não segmentação de partes que pertencem ao *GT*. Os valores observados com menor precisão foram para aquelas imagens em que as áreas que compreendem as lesões e ao *GT* possuem *pixels* mais heterogêneos, conforme apresentado na Subseção 4.1.1

Figura 16 – Gráficos das medidas: Acurácia (16a), Precisão (16b) e Sensibilidade (16c) obtidas para cada uma das segmentações realizadas em relação ao *GT*.



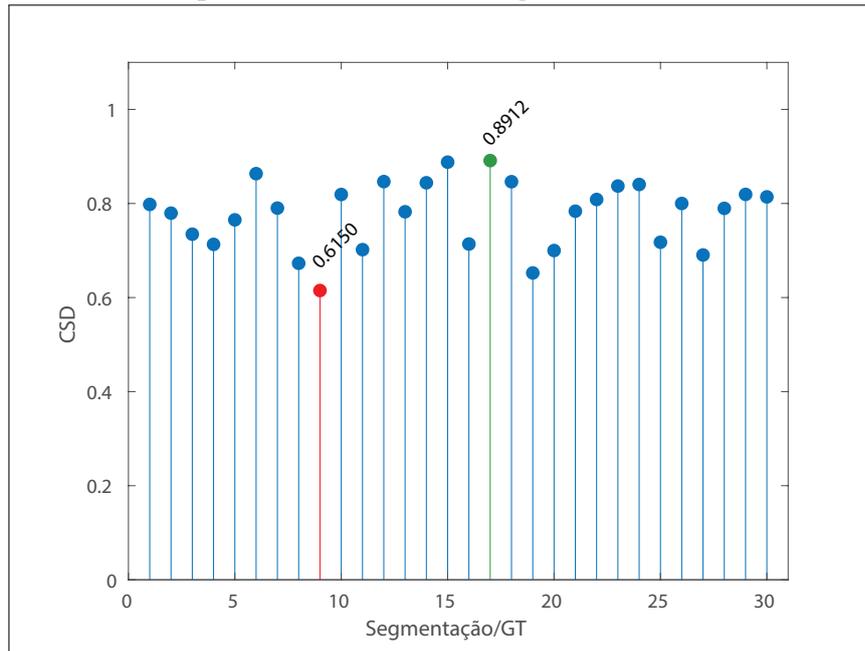
Fonte: Autoria própria.

seguinte. Consequentemente, as que apresentaram maior precisão, foram aquelas que possuem a(s) lesão(ões) com interior e margens “visualmente” bem definidas. Essas peculiaridades também influenciaram significativamente nos valores da medida de sensibilidade exibidas no gráfico da Figura 16c. No gráfico é possível observar que algumas segmentações apresentaram valores de Sensibilidade abaixo de 0,6(60%), ou seja, foram segmentadas regiões que não pertenciam ao *GT*, o que elevou o valor do Falso Negativo (FN). No entanto, no geral, os valores de sensibilidade ficaram acima de 0,7(70%) , o que é uma medida razoável no contexto deste estudo.

Em seguida, foi calculada a medida de sobreposição espacial, Coeficiente de Similaridade de Dice (CSD), para cada segmentação realizada. O gráfico gerado para esta métrica é mostrados na Figura 17, no qual pode-se observar que não foram obtidos valores abaixo de 0,6.

Em geral, os resultados foram significativos para CSD e ficaram acima de 0,75, evidenciando com essa medida uma substancial reprodutibilidade e precisão na segmentação das lesões realizada pelo método proposto. Na Subseção 4.1.1 são mostrados os resultados da segmentações e discutidas algumas das possíveis causas para os valores ruins obtidos na segmentação, o pior deles para o CSD foi igual a 0,6150 (em vermelho no gráfico).

Figura 17 – Gráfico do Coeficiente de Similaridade de Dice obtido para cada uma das segmentações realizadas em relação ao *GT*. Os valores de mínimo (vermelho) e máximo (verde) obtidos para essa medida foram iguais a 0,6150 e 0,8912, respectivamente.



Fonte: Autoria própria.

Além das medidas apresentadas, a Tabela 3 mostra a média e o desvio padrão das métricas obtidas para todo o conjunto de imagens em relação ao *GT*. Os valores para médias ficaram todos acima de 0,7, com desvio padrão inferior a 0,1100. Vale ressaltar a média obtida para o Coeficiente de Dice, que ficou em torno de 0,77, com desvio padrão igual 0,0937, que é um indicativo de uma boa reprodutibilidade das segmentações em relação ao *GT* de cada imagem.

Tabela 3 – Média e desvio padrão das medidas para todas as segmentações do conjunto de imagens.

	Ac	Pr	Se	CSD
Média	0,9834	0,8490	0,7388	0,7773
Desvio Padrão	0,0104	0,1091	0,0937	0,0712

Fonte: Autoria própria.

Na Subsecção 4.1.1 a seguir são apresentadas por meio de imagens a sobreposição de alguns dos resultados obtidos da segmentação realizada com o seu respectivo *GT* e a segmentação final em imagem binária. Também é discutida a avaliação qualitativa, obtida a partir da opinião dos profissionais especialistas envolvidos, referente a alguns resultados com segmentações inesperadas (*outliers*).

4.1.1 Resultados - Análise Qualitativa

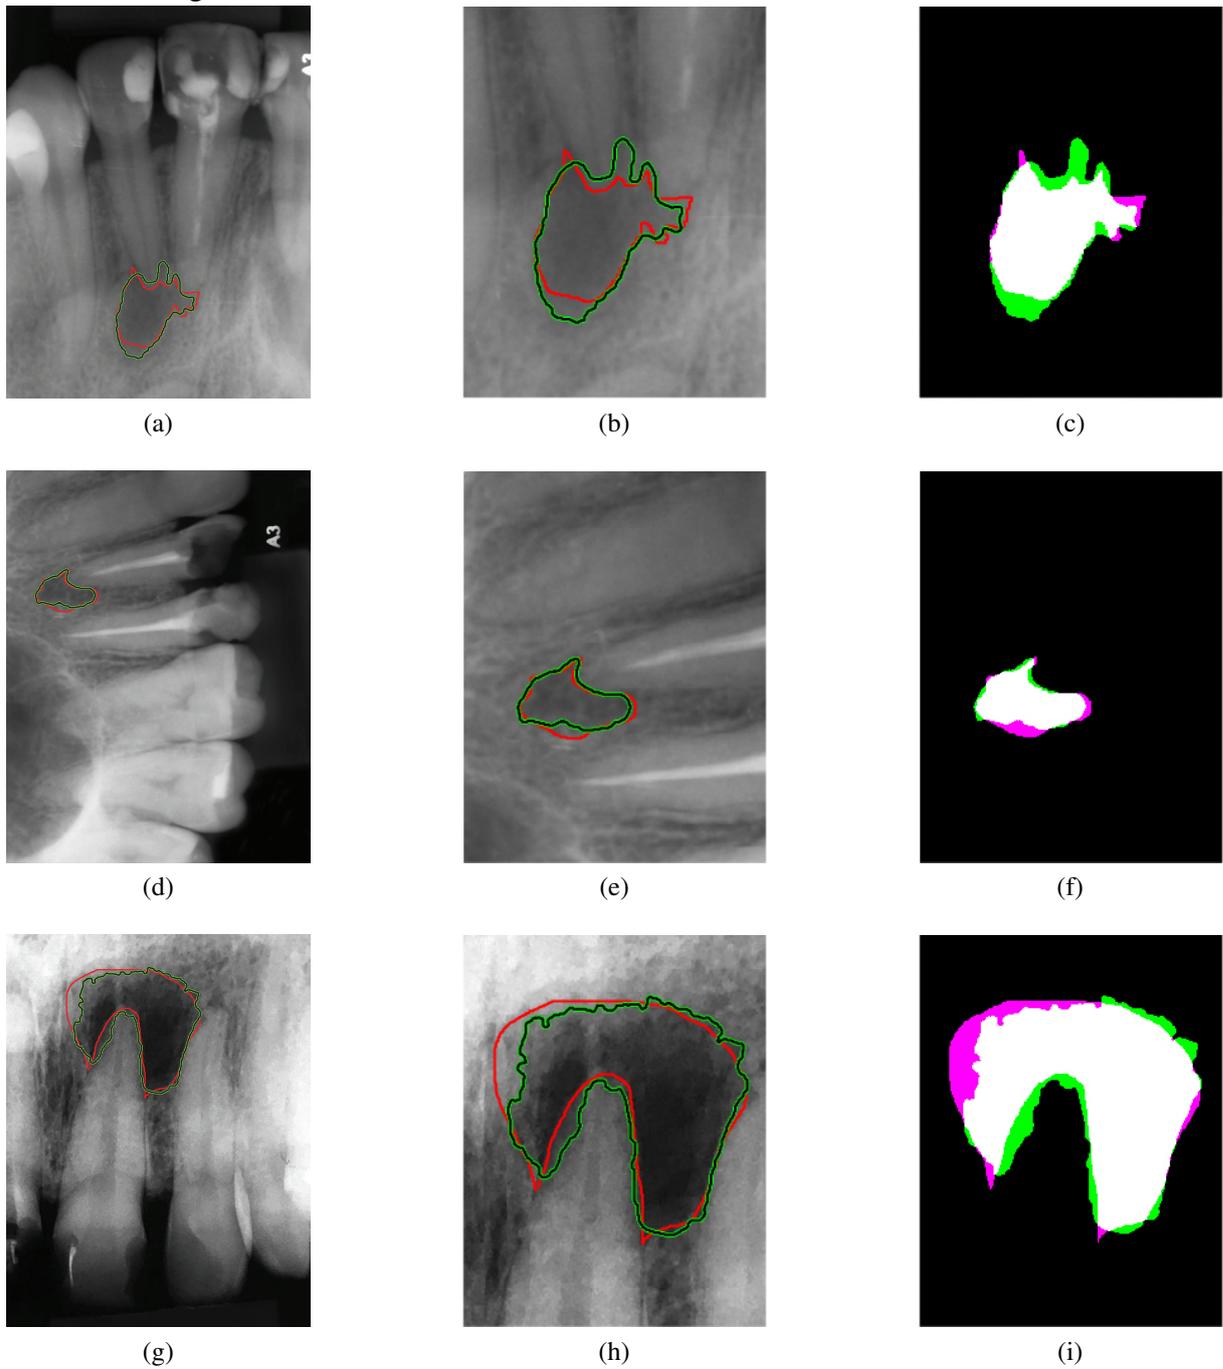
Na Figura 18 são mostrados 03 (três) dos melhores resultados ($CSD > 0,85$) obtidos dos resultados da segmentação e nas Figura 19 (pág. 61) e 20 (pág. 62) são exibidos 05 (cinco) dos piores ($CSD < 0,7$), (02) dois dos quais (Figuras 20a e 20c) são discutidos separadamente, pois apresentaram segmentações inesperadas. Todos esses resultados referem-se à sobreposição das regiões segmentadas em relação ao *GT*. As marcações realizadas pelos especialistas estão em vermelho, as realizadas após a segmentação com MCA estão em verde. Também são apresentadas as sobreposições com o resultado final em uma imagem binária para cada segmentação e o *GT*, nas quais a área em branco corresponde à intersecção do *GT* com a região segmentada, na cor magenta áreas do *GT* que foram segmentadas e na cor verde regiões que não pertenciam ao *GT* que foram segmentadas.

Para os resultados mostrados nas Figura 18a, 18d e 18g os valores obtidos para CSD foram de 0,8634, 0,8879 e 0,8912, respectivamente. Esse valores refletem a ótima sobreposição da segmentação realizada em relação às marcações dos especialistas. No entanto, as diferenças observadas nas ampliações das Figuras 18b, 18e e 18h são devido às limitações e a subjetividade relacionadas a marcação do especialista, haja vista ser impossível para o profissional identificar e marcar os limites exatos da margens das lesões. Isso sugere que a ferramenta criada para obtenção *GT* deve ser melhorada e oferecer mais recursos (melhorias de contraste, ampliação da imagem, etc) que possibilitem uma melhor exatidão na coleta do *GT*. Este mesmo fato ocorre para as Figuras 19a e 19b, com valores de CSD iguais a 0,6523 e 0,6999, respectivamente, que são reflexos dos valores baixos da precisão, obtidos devido a heterogeneidade dos *pixels* da área da lesão.

4.1.1.1 Segmentação de Lesões Inesperadas

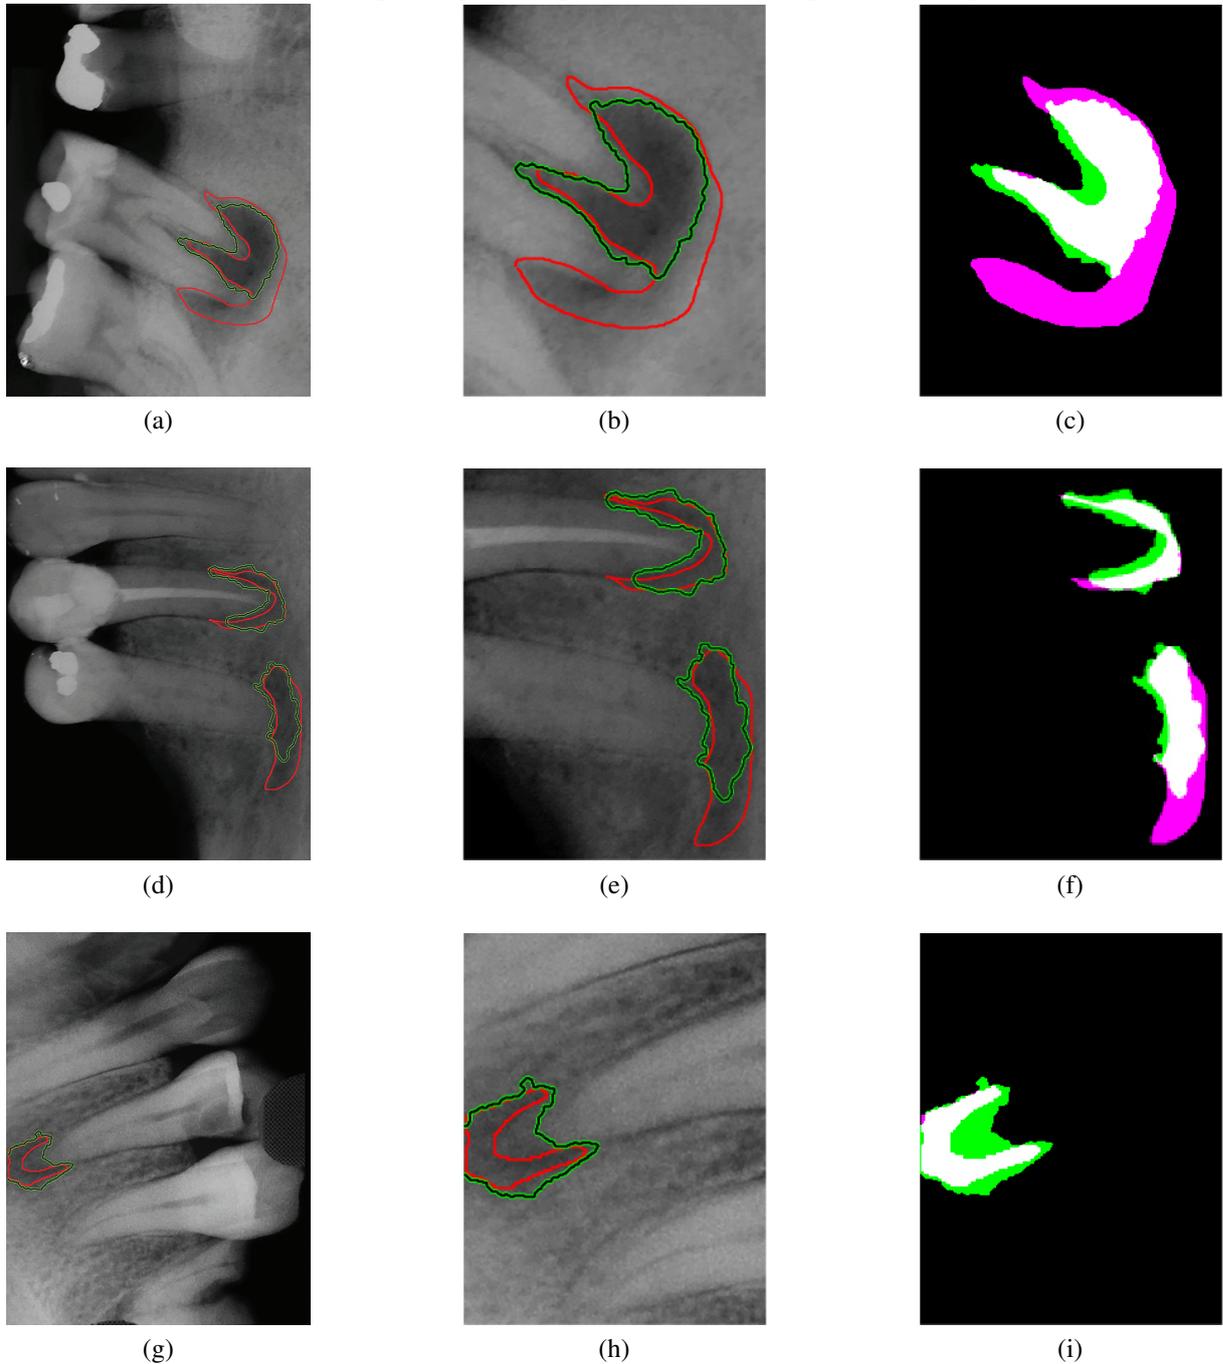
A Figura 20 apresentam dois casos, nos quais foram segmentadas regiões inesperadas e os menores valores para o CSD. Na Figura 20 o CSD foi igual a 0,6729 e para 20 o CSD foi

Figura 18 – Melhores segmentações em relação à sobreposição das marcações do especialistas. Para 18a, 18d, 18g foram obtidos os valores do CSD iguais a 0,8634, 0,8879 e 0,8912, respectivamente. Em 18b, 18e, 18h são ampliações da área da segmentação. Em 18c, 18f, 18i são apresentadas as sobreposições com o resultado final em uma imagem binária da segmentação e o *GT*: a área em branco corresponde a intersecção do *GT* com a região segmentada; na cor magenta áreas do *GT* que não foram segmentadas e na cor verde regiões que não pertenciam ao *GT* que foram segmentadas.



Fonte: Imagens geradas durante os experimentos.

Figura 19 – Piores segmentações em relação à sobreposição das marcações do especialistas. Para 19a, 19d, 19g foram obtidos os valores do CSD iguais a 0,6523, 0,6999 e 0,6905, respectivamente. Em 19b, 19e, 19h são ampliações da área da segmentação. Em 19c, 19f, 19i são apresentadas as sobreposições com o resultado final em uma imagem binária da segmentação e o *GT*: a área em branco corresponde a intersecção do *GT* com a região segmentada; na cor magenta áreas do *GT* que não foram segmentadas e na cor verde regiões que não pertenciam ao *GT* que foram segmentadas.

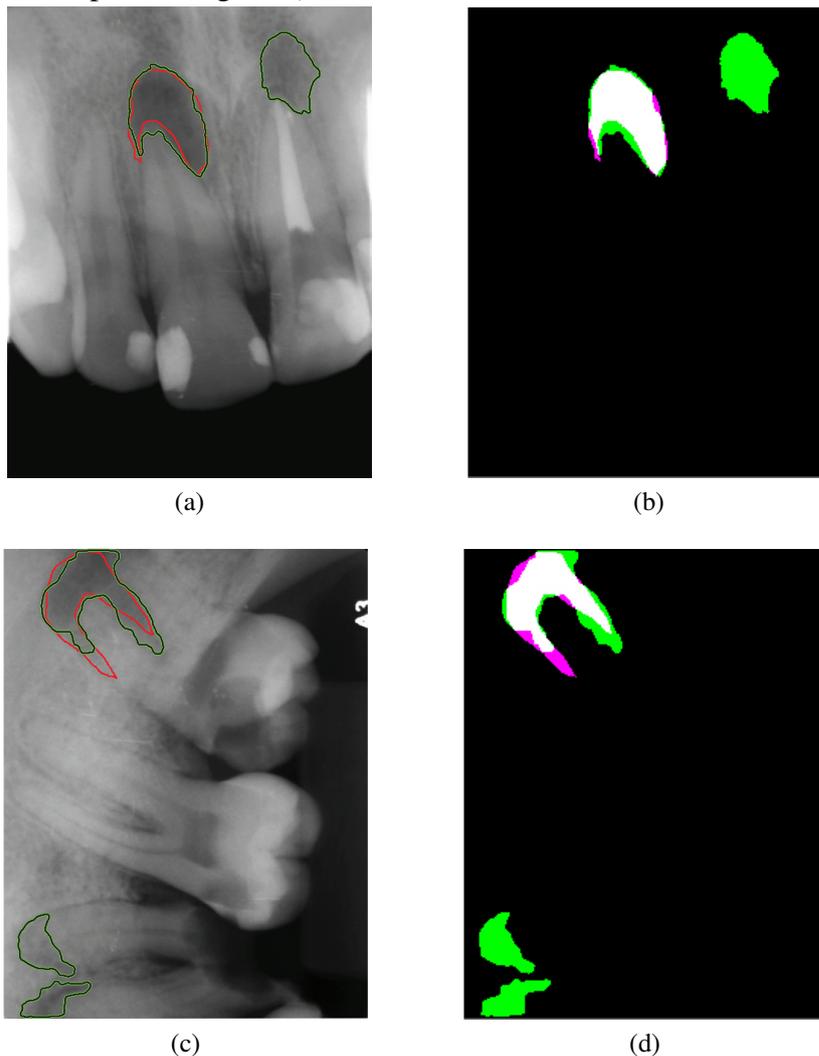


Fonte: Imagens geradas durante os experimentos.

igual a 0,6150. Diante da dúvida e para verificação do erro cometido na segmentação, esses casos foram consultados e discutidos com os especialistas. Para surpresa do resultado, eles consideram

o resultado como positivo. Na análise realizada para segmentação mostrada na Figura 20a, eles afirmaram que a área marcada na segmentação fora da região do *GT* corresponde a uma lesão em reparo, ou seja, foi realizado o tratamento e há uma regressão da lesão. Isso foi unânime entre os dois especialistas consultados. E mais, consideram que esse fato foi importante, pois o tratamento endodôntico só terá sucesso completo quando a lesão estiver totalmente reparada. No entanto, para a mesma imagem, um deles acredita (não tem certeza) que há uma outra lesão não marcada por eles e também não segmentada pelo MCA. Para a imagem da Figura 20c, eles também confirmaram que as segmentações realizadas fora do *GT* estão corretas e que realmente há lesões associadas as segmentações. Diante disso, foi possível perceber que o método levou a uma discussão interessante entre os especialistas, o que contribui para evidenciar melhor os casos nos quais houve dúvidas e auxiliá-los no diagnóstico.

Figura 20 – Segmentações inesperadas com piores valores para CSD. Para 20a o CSD foi igual a 0,6729 e para 20c igual 0,6150.



Fonte: Imagens geradas durante os experimentos.

4.1.2 Conclusão dos Resultados

Diante do exposto, com os resultados acima discutidos, as médias e o desvios padrão obtidos para cada medida na Tabela 3, aliadas às observações discutidas nas Subseções 4.1 e 4.1.1, indicam que os resultados foram promissores, e as segmentações realizadas correspondem em geral ao *GT* obtido com as marcações dos especialistas. No entanto, vale ressaltar a importância de uma nova avaliação, com uma abordagem mais qualitativa, ou seja, realizar uma avaliação junto ao especialista do quão ótimo, bom ou ruim para todas as segmentações realizadas após a aplicação da metodologia proposta. A partir disso, utilizar medidas relacionadas a essas avaliações, como, por exemplo, o índice Kappa (κ). Também faz-se necessário verificar a possibilidade da utilização de outros métodos de segmentação para comparação de resultados com a metodologia proposta. Esse procedimento pode confirmar a validade do método e dos valores observados.

5 CONSIDERAÇÕES FINAIS, CONTRIBUIÇÕES E TRABALHOS FUTUROS

Neste capítulo são abordadas as considerações finais e as contribuições deste trabalho. Também são apresentadas algumas recomendações de trabalhos futuros.

5.1 Considerações Finais

Neste trabalho foi apresentada uma metodologia para segmentação de lesões periapicais a partir de imagens radiográficas periapicais utilizando MCA localizado com inicialização automática. O objetivo deste trabalho foi criar uma metodologia que possibilitasse o auxílio do profissional cirurgião-dentista no diagnóstico dessas lesões. Para tanto, na fase inicial da pesquisa, foi estabelecida uma parceria com o curso de Odontologia da Universidade Federal do Ceará - UFC / *Campus* Sobral, para aquisição das imagens e obtenção do *ground truth* - *GT*, que corresponde às marcações realizadas pelos especialistas das lesões diagnosticadas. A metodologia proposta, desenvolvida para segmentação dessas lesões, utilizou o Modelo de Contorno Ativo localizado e técnicas oriundas da morfologia matemática para obtenção da máscara inicial para o MCA. Além disso, foi necessário implementar técnicas para melhoria de contraste das imagens e identificação de pontos radiculares do órgão dentário para ajuste da máscara inicial utilizada pelo MCA. A metodologia foi avaliada utilizando métricas pertinentes ao contexto de segmentação de imagens, a saber, acurácia, precisão, sensibilidade e o Coeficiente de Dice, obtendo médias para essas medidas superiores a 0,7. Vale ressaltar, ainda, a discussão gerada pela segmentação inesperada de lesões em algumas imagens. Essas lesões não foram marcadas pelos especialistas. No entanto, após consultá-los, eles reafirmaram que as segmentações estavam corretas. Esse fato é um indicativo de que o método pode contribuir para o auxílio desses profissionais no diagnóstico desse tipo de patologia. Portanto, em geral, os resultados mostraram-se promissores para o cumprimento dos objetivos, bem como no avanço dos estudos na área de segmentação aplicada à saúde.

Pode-se destacar como principal contribuição deste trabalho a aplicação do MCA localizado com inicialização automática na área de odontologia para segmentações de lesões periapicais em imagens radiográficas. Além disso, o *framework* para inicialização da máscara inicial utilizada pelo MCA, que utiliza técnicas oriundas da morfologia matemática e filtro de Gabor.

5.2 Trabalhos Futuros

Este trabalho foi possível graças à parceria com profissionais do curso de Odontologia da Universidade Federal do Ceará - UFC / *Campus* Sobral. Parceria esta que vislumbra possíveis aplicações que irão auxiliar esses profissionais no diagnóstico e contribuir no aprimoramento na condução do tratamento de pacientes diagnosticados com alguma patologia. Além disso, tais aplicações possibilitam a geração de produção científica e conhecimento no âmbito acadêmico, e mais, o estreitamento dentro da academia de áreas de conhecimento distintas, o que é uma tendência nos dias atuais. Diante disso, serão listadas a seguir algumas sugestões de trabalhos futuros que visam melhorar os resultados obtidos por este estudo, bem como, outras possíveis linhas de pesquisa dentro do mesmo tema, que foram identificadas durante as atividades desta pesquisa:

- A aplicação de outros métodos de segmentação e comparação com a metodologia proposta;
- A introdução de medidas qualitativas para avaliar o método, como por exemplo, índice Kappa (κ);
- A investigação e implementação de possíveis melhorias para MCA localizado dentro da problemática em questão, Por exemplo: investigar a variação dos *pixels* dentro das lesões para gerar um novo tipo de energia interna;
- A implementação de técnicas que permitam a identificação dos padrões de estruturas anatômicas normais, como por exemplo, fossas nasais, seios maxilares, forames e outras;
- Como o melhoramento de contraste aplicado nas imagens utilizadas, foi possível perceber que a estrutura do osso alveolar possui uma textura bem característica, limitada por trabéculas ósseas e espaços medulares. Isso sugere que é possível utilizar um segmentador baseado em textura para segmentar essa região e os dentes, que possuem uma textura mais uniforme e radiopaca.
- Já que o profissional é capaz de imaginar as estrutura anatômicas em 3D a partir da imagem radiográfica em 2D, um trabalho interessante seria implementar uma técnica que possibilite converter a imagem radiográfica em 2D para uma similar em 3D.

REFERÊNCIAS

- BARNES JOHN W. EVESON, P. A. R. D. S. L. **Pathology And Genetics of Head and Neck Tumours (World Health Organization Classification of Tumours)**. 1. ed. [S.l.: s.n.], 2005. ISBN 9789283221920,9789283224174,9283224175.
- BEHLING, R. **Modern diagnostic x-ray sources : technology, manufacturing, reliability**. [S.l.]: CRC Press, 2015. ISBN 978-1-4822-4133-4,1482241331.
- BERNARDI, L.; VISIOLI, F.; NÖR, C.; RADOS, P. V. Radicular cyst: An update of the biological factors related to lining epithelium. **Journal of Endodontics**, v. 41, n. 12, p. 1951 – 1961, 2015. ISSN 0099-2399. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0099239915008043>>.
- BIRKFELLNER, W. **Applied Medical Image Processing, Second Edition: A Basic Course**. 2. ed. [S.l.]: CRC Press, 2014. ISBN 1466555572,9781466555570.
- BLAKE, M. I. A. **Active Contours: The Application of Techniques from Graphics, Vision, Control Theory and Statistics to Visual Tracking of Shapes in Motion**. 1. ed. [S.l.]: Springer, 2000. ISBN 3540762175,9783540762171.
- CELLINA, A. The validity of the euler–lagrange equation for solutions to variational problems. **Journal of Fixed Point Theory and Applications**, v. 15, n. 2, p. 577–586, Jun 2014. ISSN 1661-7746. Disponível em: <<https://doi.org/10.1007/s11784-014-0198-8>>.
- CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, v. 10, n. 2, p. 266–277, Feb 2001. ISSN 1057-7149.
- CRUSE, W. P.; BELLIZZI, R. A historic review of endodontics, 1689-1963, part 2. **Journal of Endodontics**, v. 6, n. 4, p. 532 – 535, 1980. ISSN 0099-2399. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0099239980802019>>.
- CUEVAS, E.; SENCIÓN, F.; ZALDIVAR, D.; PÉREZ-CISNEROS, M.; SOSSA, H. A multi-threshold segmentation approach based on artificial bee colony optimization. **Applied Intelligence**, v. 37, n. 3, p. 321–336, Oct 2012. ISSN 1573-7497. Disponível em: <<https://doi.org/10.1007/s10489-011-0330-z>>.
- CUEVAS, E.; ZALDIVAR, D.; PÉREZ-CISNEROS, M. A novel multi-threshold segmentation approach based on differential evolution optimization. **Expert Systems with Applications**, v. 37, n. 7, p. 5265 – 5271, 2010. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417410000151>>.
- DE SIDDHARTHA BHATTACHARYYA, S. C. P. D. a. S. **Hybrid Soft Computing for Multilevel Image and Data Segmentation**. 1. ed. [S.l.]: Springer International Publishing, 2016. (Computational Intelligence Methods and Applications). ISBN 978-3-319-47523-3,978-3-319-47524-0.
- DICE, L. R. Measures of the amount of ecologic association between species. **Ecology**, Ecological Society of America, v. 26, n. 3, p. 297–302, 1945. ISSN 00129658, 19399170. Disponível em: <<http://www.jstor.org/stable/1932409>>.
- (ED.), H. P.-G. P. **Advances in image segmentation**. [S.l.]: InTech, 2012. ISBN 978-953-51-0817-7,978-953-307-228-9.

FEICHTINGER THOMAS STROHMER (AUTH.), H. G. F. T. S. e. H. G. **Gabor Analysis and Algorithms: Theory and Applications**. 1. ed. [S.l.]: Birkhäuser Basel, 1998. (Applied and Numerical Harmonic Analysis). ISBN 978-1-4612-7382-0,978-1-4612-2016-9.

FITZGERALD, R. Error in radiology. **Clinical Radiology**, v. 56, n. 12, p. 938 – 946, 2001. ISSN 0009-9260. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S000992600190858X>>.

FREITAS, A. de; ROSA, J. **Radiologia odontológica**. [S.l.]: Artes Médicas, 2004. ISBN 9788574040158.

FROMMER, H. H.; STABULAS-SAVAGE, J. J. **Radiology for the dental professional /**. 9th ed. ed. St. Louis, Mo. :: Mosby-Elsevier., 2011.

GABOR, D. Theory of information. **IEE**, v. 143, p. 429–457, 1946.

GOHEL, A.; VILLA, A.; SAKAI, O. Benign jaw lesions. **Dental Clinics**, Elsevier, v. 60, n. 1, p. 125–141, Jan 2016. ISSN 0011-8532. Disponível em: <<http://dx.doi.org/10.1016/j.cden.2015.08.005>>.

GONZALEZ, C.; MELIN, P.; CASTRO, J.; CASTILLO, O. **Edge Detection Methods Based on Generalized Type-2 Fuzzy Logic**. 1. ed. [S.l.]: Springer International Publishing, 2017. (SpringerBriefs in Applied Sciences and Technology). ISBN 978-3-319-53993-5,978-3-319-53994-2.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing (3rd Edition)**. Pearson/Prentice-Hall, Inc., 2008. ISBN 013168728X, 9780131687288. Disponível em: <<https://books.google.com.br/books?id=8uGOnjRGEzoC>>.

HAN, J.; YANG, C.; ZHOU, X.; GUI, W. A new multi-threshold image segmentation approach using state transition algorithm. **Applied Mathematical Modelling**, v. 44, n. Supplement C, p. 588 – 601, 2017. ISSN 0307-904X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0307904X17301117>>.

HASAN, M. M.; ISMAIL, W.; HASSAN, R.; YOSHITAKA, A. Automatic segmentation of jaw from panoramic dental x-ray images using GVF snakes. In: **2016 World Automation Congress (WAC)**. Institute of Electrical and Electronics Engineers (IEEE), 2016. Disponível em: <<http://dx.doi.org/10.1109/WAC.2016.7583022>>.

HUHTA, V. Evaluation of different similarity indices as measures of succession in arthropod communities of the forest floor after clear-cutting. **Oecologia**, v. 41, n. 1, p. 11–23, Jul 1979. ISSN 1432-1939. Disponível em: <<https://doi.org/10.1007/BF00344834>>.

Institute of Medicine and National Academies of Sciences, Engineering, and Medicine. **Improving Diagnosis in Health Care**. Washington, DC: The National Academies Press, 2015. ISBN 978-0-309-37769-0. Disponível em: <<https://www.nap.edu/catalog/21794/improving-diagnosis-in-health-care>>.

JOHNSON, N. R.; GANNON, O. M.; SAVAGE, N. W.; BATSTONE, M. D. Frequency of odontogenic cysts and tumors: a systematic review. In: . [s.n.], 2014. v. 5, n. 1, p. 9–14. Disponível em: <<http://dx.doi.org/10.1111/jicd.12044>>.

- KAMARAINEN, J. K.; KYRKI, V.; KALVIAINEN, H. Invariance properties of gabor filter-based features-overview and applications. **IEEE Transactions on Image Processing**, v. 15, n. 5, p. 1088–1099, May 2006. ISSN 1057-7149.
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. **INTERNATIONAL JOURNAL OF COMPUTER VISION**, v. 1, n. 4, p. 321–331, 1988.
- KIMORI, Y. Morphological image processing for quantitative shape analysis of biomedical structures: effective contrast enhancement. **Journal of synchrotron radiation**, v. 20, n. Pt 6, p. 848–53, Nov 2013.
- KIMORI, Y.; BABA, N.; MORONE, N. Extended morphological processing: a practical method for automatic spot detection of biological markers from microscopic images. **BMC bioinformatics**, v. 11, p. 373, 2010.
- KIMORI, Y.; KATAYAMA, E.; MORONE, N.; KODAMA, T. Fractal dimension analysis and mathematical morphology of structural changes in actin filaments imaged by electron microscopy. **Journal of Structural Biology**, v. 176, n. 1, p. 1 – 8, 2011. ISSN 1047-8477. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1047847711002000>>.
- KIMORI, Y.; OGUCHI, Y.; ICHISE, N.; BABA, N.; KATAYAMA, E. A procedure to analyze surface profiles of the protein molecules visualized by quick-freeze deep-etch replica electron microscopy. **Ultramicroscopy**, v. 107, n. 1, p. 25 – 39, 2007. ISSN 0304-3991. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0304399106000799>>.
- KRONFELD, T.; BRUNNER, D.; BRUNETT, G. Snake-based segmentation of teeth from virtual dental casts. **Computer-Aided Design and Applications**, Informa UK Limited, v. 7, n. 2, p. 221–233, jan 2010. Disponível em: <<http://dx.doi.org/10.3722/cadaps.2010.221-233>>.
- LANKTON, S.; TANNENBAUM, A. Localizing region-based active contours. **IEEE Transactions on Image Processing**, v. 17, n. 11, p. 2029–2039, Nov 2008. ISSN 1057-7149.
- LIN, P.; HUANG, P.; HUANG, P.; HSU, H.; CHEN, C. Teeth segmentation of dental periapical radiographs based on local singularity analysis. **Computer Methods and Programs in Biomedicine**, v. 113, n. 2, p. 433 – 445, 2014. ISSN 0169-2607. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S016926071300357X>>.
- LOUGHLIN, A.; DRAGE, N.; GREENALL, C.; FARNELL, D. J. J. An investigation in to the impact of acquisition location on error type and rate when undertaking panoramic radiography. **Radiography**, Elsevier, v. 23, n. 4, p. 305–309, 2017/11/12 XXXX. ISSN 1078-8174. Disponível em: <<http://dx.doi.org/10.1016/j.radi.2017.07.004>>.
- MAKDISSI, J.; PAWAR, R. Digital radiography in the dental practice: an update. **Primary dental journal**, v. 2, n. 1, p. 58–64, Jan 2013.
- MARTIN, L. H. C.; SPEIGHT, P. M. Odontogenic cysts: an update. **Diagnostic Histopathology**, Elsevier, v. 23, n. 6, p. 260–265, May 19 2017. ISSN 1756-2317. Disponível em: <<http://dx.doi.org/10.1016/j.mpdhp.2017.04.006>>.
- MOL, A. Imaging methods in periodontology. **Periodontology 2000**, Munksgaard International Publishers, v. 34, n. 1, p. 34–48, 2004. ISSN 1600-0757. Disponível em: <<http://dx.doi.org/10.1046/j.0906-6713.2003.003423.x>>.

MONTEIRO, F. C.; CAMPILHO, A. C. Performance evaluation of image segmentation. In: _____. **Image Analysis and Recognition: Third International Conference, ICIAR 2006, Póvoa de Varzim, Portugal, September 18-20, 2006, Proceedings, Part I**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. p. 248–259. ISBN 978-3-540-44893-8. Disponível em: <https://doi.org/10.1007/11867586_24>.

MUMFORD, D. Optimal approximation by piecewise smooth functions and associated variational problems. **Commun. Pure Applied Mathematics**, p. 577–685, 1989.

MUPPARAPU, M.; NADEAU, C. Oral and maxillofacial imaging. **Dental Clinics of North America**, v. 60, n. 1, p. 1 – 37, 2016. ISSN 0011-8532. Oral Radiology: Interpretation and Diagnostic Strategies. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0011853215000890>>.

MUSU, D.; ROSSI-FEDELE, G.; CAMPISI, G.; COTTI, E. Ultrasonography in the diagnosis of bone lesions of the jaws: a systematic review. In: . [s.n.], 2016. v. 122, n. 1, p. e19 – e29. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2212440316300104>>.

NAIR, P. N. R. On the causes of persistent apical periodontitis: a review. **International Endodontic Journal**, Blackwell Publishing Ltd, v. 39, n. 4, p. 249–281, 2006. ISSN 1365-2591. Disponível em: <<http://dx.doi.org/10.1111/j.1365-2591.2006.01099.x>>.

NAJMAN, H. T. e. L. **Mathematical Morphology: From Theory to Applications**. [S.l.]: Wiley-ISTE, 2010. ISBN 9781848212152,9781118600788.

NEVILLE DOUGLAS D. DAMM, C. M. A. A. C. C. B. W. **Oral and Maxillofacial Pathology**. 4. ed. [S.l.]: Saunders, 2015. ISBN 1455770523,9781455770526.

OPPENHEIM ALAN S. WILLSKY, S. H. A. V. **Sinais e Sistemas**. 2. ed. [S.l.]: Pearson, 2010. ISBN 857605504X,9788576055044.

PANELLA, J. **Radiologia odontológica e imaginologia**. Guanabara Koogan, 2006. (Fundamentos de odontologia). ISBN 9788527712323. Disponível em: <<https://books.google.com.br/books?id=t-eHPgAACAAJ>>.

PASLER, F.; VISSER, H. **Pocket Atlas of Dental Radiology**. Thieme, 2007. (Clinical sciences). ISBN 9781588903358. Disponível em: <<https://books.google.com.br/books?id=fs2vdxuTIYC>>.

PETROU, C. P. M. **Image Processing: The Fundamentals**. 2ed.. ed. [S.l.]: Wiley, 2010. ISBN 047074586X,978-0-470-74586-1.

PITAS, I. **Digital image processing algorithms and applications**. Wiley, 2000. (AWiley-Interscience publication). ISBN 9780471377399. Disponível em: <<https://books.google.com.br/books?id=XPBRAAAAMAAJ>>.

POWERS, D. M. Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation. **Journal of Machine Learning Technologies**, Bioinfo Publications, v. 2, n. 1, p. 37–63, 2011.

PROCKT, A. P.; SCHEBELA, C. R.; MAITO, F. D. M.; SANT'ANA-FILHO, M.; RADOS, P. V. Odontogenic cysts: Analysis of 680 cases in brazil. **Head Neck Pathol**, Humana Press Inc, New York, v. 2, n. 3, p. 150–156, Sep 2008. ISSN 1936-055X. 60[PII]. Disponível em: <<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC2807569/>>.

SHAH, S.; ABAZA, A.; ROSS, A.; AMMAR, H. Automatic tooth segmentation using active contour without edges. In: **2006 Biometrics Symposium: Special Session on Research at the Biometric Consortium Conference**. [S.l.: s.n.], 2006. p. 1–6.

SHI, R.; NGAN, K. N.; LI, S. Jaccard index compensation for object segmentation evaluation. In: **2014 IEEE International Conference on Image Processing (ICIP)**. [S.l.: s.n.], 2014. p. 4457–4461. ISSN 1522-4880.

SHIH, F. Y. **Image processing and mathematical morphology: Fundamentals and applications**. 1. ed. [S.l.]: CRC Press, 2009. ISBN 1420089439,9781420089448,9781420089431,1420089447.

SØRENSEN, T. **A Method of Establishing Groups of Equal Amplitude in Plant Sociology Based on Similarity of Species Content and Its Application to Analyses of the Vegetation on Danish Commons**. [S.l.]: I kommission hos E. Munksgaard, 1948. (Biologiske skrifter).

STELT, P. F. van der. Filmless imaging: the uses of digital radiography in dental practice. **Journal of the American Dental Association (1939)**, v. 136, n. 10, p. 1379–87, Oct 2005.

SUWA, K.; FURUKAWA, A.; MATSUMOTO, T.; YOSUE, T. Analyzing the eye movement of dentists during their reading of ct images. In: . [s.n.], 2001. v. 89, n. 1, p. 0054–0061. Disponível em: <<http://dx.doi.org/10.1007/s10266-001-8186>>.

TURGEON, D. P.; LAM, E. W. Influence of experience and training on dental students' examination performance regarding panoramic images. In: . [s.n.], 2016. v. 80, n. 2, p. 156–164. Disponível em: <<http://www.jdentaled.org/content/80/2/156.abstract>>.

VESE, L. A.; GUYADER, C. L. **Variational Methods in Image Processing**. [S.l.]: Chapman & Hall/CRC, 2015. ISBN 1439849730, 9781439849736.

VILLASIS-SARMIENTO, L.; ROBERTSON, J. P.; MELENDEZ, A.; CEPEDA, L. G.; LEYVA-HUERTA, E. Prevalence and distribution of odontogenic cysts in a mexican sample. a 753 cases study. v. 9, 04 2017.

WHITE, M. J. P. S. C. **Oral Radiology: Principles and Interpretation**. 7. ed. [S.l.]: Mosby, 2013. ISBN 0323096336,9780323096331.

YOO, T. S. **Insight into Images: Principles and Practice for Segmentation, Registration, and Image Analysis**. 1. ed. [S.l.]: A K Peters/CRC Press, 2004. ISBN 9781568812175,1568812175.

ZHANG, H.; FRITTS, J. E.; GOLDMAN, S. A. Image segmentation evaluation: A survey of unsupervised methods. **Computer Vision and Image Understanding**, v. 110, n. 2, p. 260 – 280, 2008. ISSN 1077-3142. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1077314207001294>>.

ZIJDENBOS, A. P.; DAWANT, B. M.; MARGOLIN, R. A.; PALMER, A. C. Morphometric analysis of white matter lesions in mr images: method and validation. **IEEE Transactions on Medical Imaging**, v. 13, n. 4, p. 716–724, Dec 1994. ISSN 0278-0062.

APÊNDICE A – RADIOGRAFIAS ODONTOLÓGICAS

Os raios X foram descobertos em 1895 por Wilhelm Conrad Roentgen, o que trouxe à odontologia avanços significativos. Tal descoberta possibilitou que o profissional cirurgião-dentista solucionasse dúvidas frequentes, ocorridas em todas as fases de tratamento, incluindo diagnóstico, planejamento e execução do tratamento, e através de avaliação e acompanhamento pós-tratamento. Atualmente, este recurso ainda é extensamente utilizado na área de Odontologia e proporciona a obtenção de informações essenciais para realização de exames e descobertas de patologias intraorais.

Uma radiografia convencional é feita com uma fonte de raios-X estacionária e apresenta informações das estruturas anatômicas tridimensionais em imagens no plano bidimensional. O volume total dos tecidos entre a fonte de raios-X e o receptor de imagem é projetado em uma imagem bidimensional, ou seja, em visões planas. Para extrair o máximo de informações de uma radiografia que auxiliem no diagnóstico, o clínico deve ter uma compreensão clara da anatomia normal e reconstruir mentalmente uma imagem tridimensional das estruturas anatômicas das projeções bidimensionais da radiografia. A utilização de radiografias de alta qualidade facilitam grandemente esta tarefa. Os princípios da geometria de projeção descrevem o efeito do tamanho do ponto focal e posição relativa do receptor de objeto e imagem de acordo com a recomendação de cada técnica de incidência. Os clínicos usam esses princípios para maximizar a clareza da imagem, minimizar a distorção e localizar estruturas de interesse no campo da imagem (WHITE, 2013).

Os exames radiográficos realizados em odontologia são divididos em exames extrabucais e intrabucais:

- Radiografias extrabucais: radiografia panorâmica; radiografia de Articulação Temporomandibular (ATM); telerradiografia lateral e frontal;
- Radiografias intrabucais: radiografia interproximal; radiografia oclusal; radiografia periapical.

A.1 Radiografias extrabucais

Os exames radiográficos extrabucais usam filmes da radiologia convencional para sua execução. Caracterizam-se por serem posicionados no equipamento de raios-X fora da boca do usuário. A radiografia panorâmica, Figura 21, é o exame extra-oral realizado com maior

frequência em odontologia (LOUGHLIN *et al.*, XXXX). Oferece uma visão geral de todos os dentes e das regiões anatômicas que compreendem: maxila, mandíbula e ATMs. São por vezes associadas às técnicas intrabucais para obtenção de um diagnóstico mais conclusivo (WHITE, 2013; PANELLA, 2006).

Figura 21 – Radiografia Panorâmica.



Fonte: Arquivo pessoal

A.2 Radiografias intrabucais

As radiografias intrabucais são as mais utilizadas na prática clínica diária pelo cirurgião-dentista. São divididas em:

1. Técnica radiográfica periapical:
 - a) da bisettriz
 - b) do paralelismo
2. Técnica radiográfica interproximal
3. Técnica radiográfica oclusal

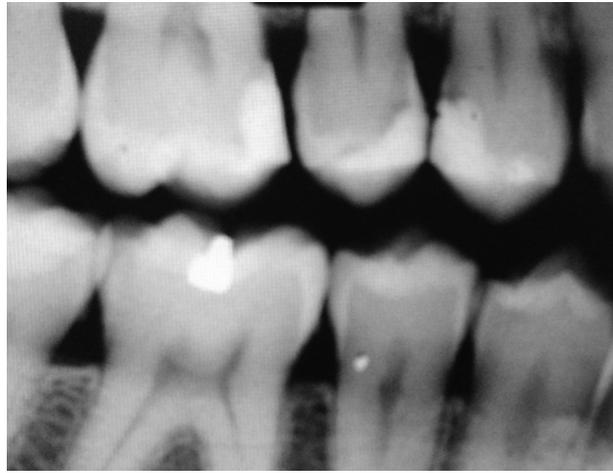
As radiografias periapicais devem mostrar o dente completamente, incluindo o osso circundante, como ilustra a Figura 22a (pág. 73). As imagens *Bite-wing* (interproximal), Figura 22b (pág. 73), mostram apenas as coroas dos dentes e as cristas alveolares adjacentes. São ideais para o diagnóstico de cáries proximais, adaptação de coroas e excessos marginais de restaurações. As imagens oclusais, Figura 22c (pág. 73), mostram uma área de dentes e zonas da maxila e mandíbula, podem ser usadas na investigação de fraturas, lesões ou dentes impactados (WHITE,

2013).

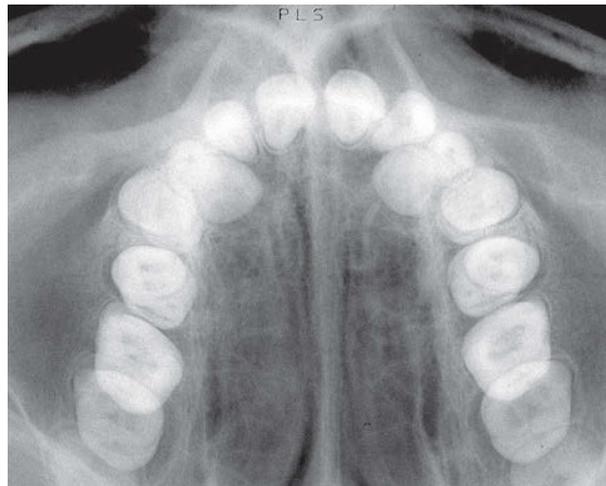
Figura 22 – Exemplos de radiografias intrabucais.



(a) Radiografia periapical
(Técnica da Bissetriz)



(b) Radiografia interproximal



(c) radiografia oclusal

Fonte: Imagens 22a e 22b pertencem ao arquivo pessoal do autor. Imagem 22c adaptada de (WHITE, 2013).

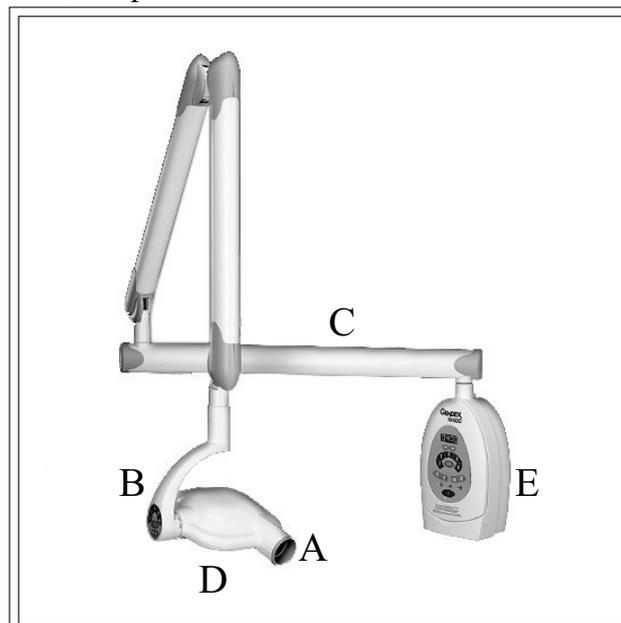
APÊNDICE B – RADIOGRAFIAS PERIAPICAIS

Na área da odontologia, as radiografias periapicais são consideradas do tipo intra-bucal de regiões específicas da arcada dentária. Nessas radiografias, a película radiográfica é posicionada muito próximo ao dente tornando seu tamanho quase real, diferenciando-se assim da panorâmica que não apresenta o tamanho real da estrutura maxilofacial. Sua finalidade é geralmente para verificação de cistos, tratamentos periodontais pré e pós-cirúrgicos, acompanhamento de dentes inclusos, extrações dentárias, visualização de dentes supranumerários e análise de patologias em geral. Essa técnica permite a avaliação de toda a estrutura dentária e suas adjacências (WHITE, 2013; PANELLA, 2006)

A radiografia periapical abrange duas técnicas diferentes, a técnica da bisettriz, mais utilizada em consultórios odontológicos e a técnica do paralelismo, utilizada frequentemente em clínicas de radiologia odontológica por sua praticidade. Podem ser pedidas individualmente, como complementação de outros exames, ou em um conjunto de 14 exames, abrangendo assim todos os dentes, chamado de levantamento periapical ou seriografia (WHITE, 2013).

A técnica do paralelismo fornece uma visão menos distorcida da dentição, devendo ser priorizada quando possível. Caso as restrições anatômicas ocorram, a técnica do ângulo da bisettriz pode ser usada para realização adequada da tomada radiográfica, permitindo a colocação correta do receptor (filme radiográfico) e angulação do tubo (ver Figura 23, pág. 74).

Figura 23 – Aparelho radiográfico periapical tipo fixo: A - tubo, B - cabeçote, C - braço, D - cabeça do tubo, E - painel de controle

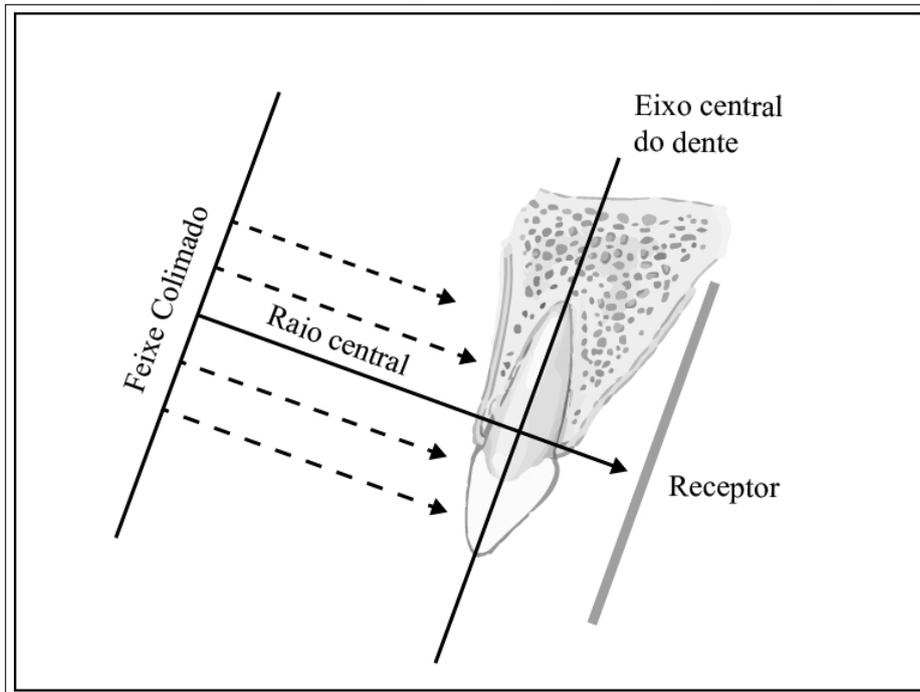


Fonte: Adaptado de (FROMMER; STABULAS-SAVAGE, 2011)

B.1 Técnica do Paralelismo

O conceito central da técnica de paralelismo (também chamado de técnica de ângulo reto ou técnica de cone longo) é que o raio-X e o receptor sejam suportados paralelamente ao longo eixo dos dentes, e o raio central do feixe é direcionado para os dentes e receptor, de acordo como ilustrado na Figura 24, página 75. Esta orientação do receptor, dos dentes e do raio central minimiza a distorção geométrica e apresenta as verdadeiras relações anatômicas entre os dentes e o tecido ósseo. Para reduzir a distorção geométrica, a fonte de raios-x deve estar localizada relativamente distante dos dentes. O uso de uma fonte longa para o objeto reduz a distância e o tamanho aparente do ponto focal, aumentando assim a nitidez da imagem e fornece imagens com uma ampliação mínima.

Figura 24 – Técnica do Paralelismo. A imagem ilustra a relação paralela entre o longo eixo do dente e o receptor de imagem. O raio central é direcionado perpendicular a cada um. Esta técnica minimiza a distorção da imagem, mas requer um posicionador.



Fonte: Adaptado de (WHITE, 2013)

O exame é corretamente aplicado com uso de posicionadores radiográficos (ver Figura 25, pág. 76), que permitem a colocação precisa de forma paralela do receptor na boca do paciente. Para projeções maxilares, a borda superior do receptor geralmente repousa na linha média do palato. Da mesma forma, para projeções mandibulares, o receptor deve ser usado para deslocar a língua posteriormente ou em direção à linha média para permitir que a borda inferior do receptor repouse sobre o assoalho da boca. Também é importante usar um instrumento

Figura 25 – Posicionador radiográfico destinados à técnica do paralelismo.

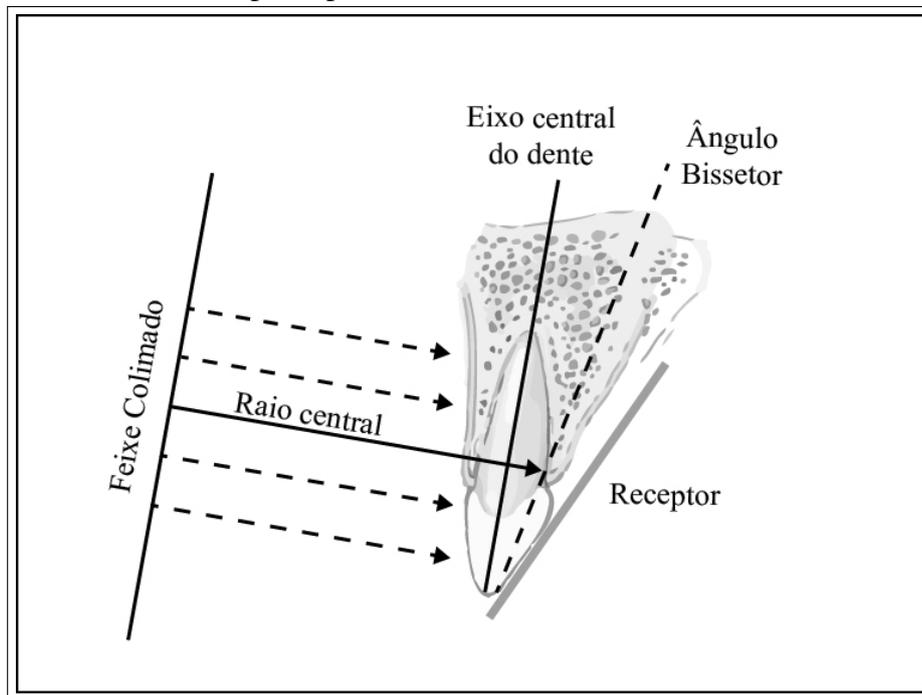


Fonte: Adaptado de (WHITE, 2013)

de retenção de receptores que tenha um anel de guia externo. Este anel de guia é usado para alinhar o cilindro do raio-X garantindo que a película esteja centrada ao raio por trás dos dentes, perpendiculares ao raio-X (WHITE, 2013).

A utilização do posicionador de receptor de imagem para radiografias periapicais dispensa um posicionamento específico do usuário. É suficiente posicionar o receptor de imagem na região de interesse e ajustar o distanciador do equipamento de raios-X perpendicularmente a 1 cm de distância da pele do usuário, centralizado em relação ao receptor de imagem. O receptor de imagem deve ser inserido ao posicionador e colocado atrás dos dentes do usuário, por dentro da arcada dentária, com o auxílio do bloco de mordida do posicionador, conforme ilustrado na Figura 26, página 77.

Figura 26 – Técnica da bissetriz. O feixe de raio x deve incidir perpendicularmente ao plano bissetor formado pelos planos do dente e do filme.



Fonte: Adaptado de (WHITE, 2013)

B.2 Técnica da Bissetriz

A técnica da bissetriz tem como base a lei isométrica de Cieszinski: “A imagem projetada tem o mesmo comprimento e as mesmas proporções do objeto, desde que o ponto central seja perpendicular à bissetriz do ângulo formado entre o filme e objeto.” A regra de isometria afirma que dois triângulos são iguais quando eles compartilham um lado completo e têm dois ângulos iguais. O teorema é aplicado da seguinte forma: O receptor está posicionado o mais próximo possível da superfície lingual dos dentes, descansando no palato ou assoalho, como mostra a Figura 26. O plano receptor e o longo eixo dos dentes formam um ângulo com seu ápice no ponto em que o receptor está em contato com os dentes, ao longo de uma linha imaginária que divide esse ângulo e direciona o raio central do feixe perpendicular a esta bissetriz. Assim, obtêm-se dois triângulos com dois ângulos iguais e um lado comum. Para se obter uma radiografia dentária correta deve-se conhecer algumas linhas básicas formadas por esta regra: o plano médio do dente, a linha do filme e a bissetriz formada entre eles (WHITE, 2013; FROMMER; STABULAS-SAVAGE, 2011; PANELLA, 2006).

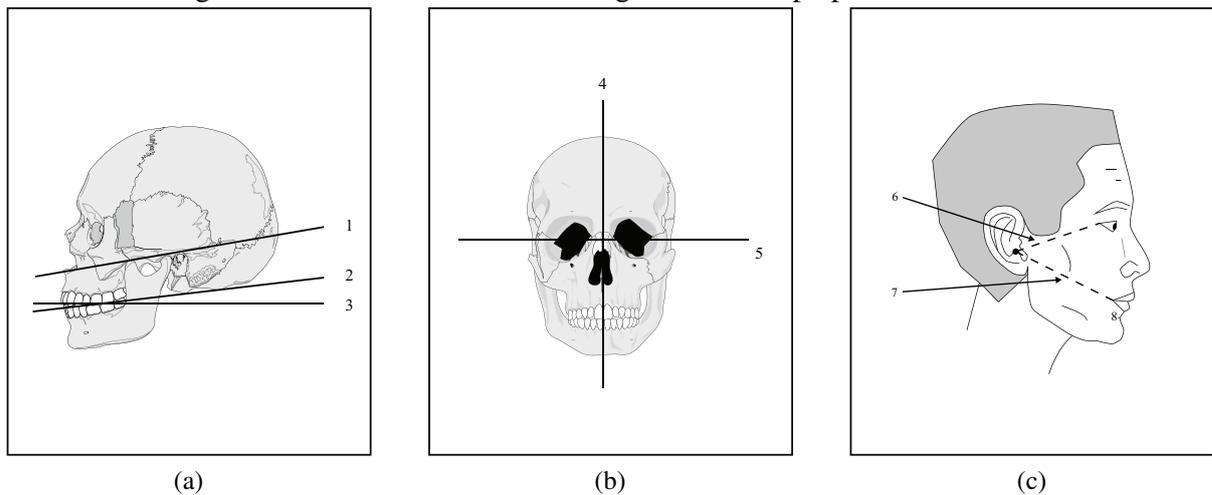
Estas projeções, quando bem expostas e devidamente processadas, podem gerar informações de diagnóstico consideráveis para complementar o exame clínico (WHITE, 2013;

FROMMER; STABULAS-SAVAGE, 2011).

B.3 Posicionamento do Paciente

Para as imagens do arco maxilar, a cabeça do paciente deve ser posicionada verticalmente com o plano sagital mediano e oclusal (plano horizontal). Quando a tomada radiográfica contemplar dentes inferiores ou mandibulares, a cabeça deve ser inclinada ligeiramente para frente e dessa maneira compensar a mudança do plano oclusal quando a boca é aberta (WHITE, 2013; FROMMER; STABULAS-SAVAGE, 2011). Na Figura 27 são mostradas imagens que ilustram os planos de referência para o correto posicionamento do paciente, bem como o foco central em relação ao receptor.

Figura 27 – Planos e pontos de referência para o correto posicionamento do paciente. Em 27a tem-se: 1 - Plano de Camper; 2- Plano oclusal/incisal e 3 - Plano de horizontal. Em 27b: 4 – Plano sagital mediano e 5 - Linha bipupilar. Em 27c: 6 - Linha trago-comissura labial; 7 - Linha trago-comissura palpebral e 8 – Sulco mentolabial.



Fonte: Adaptado de (PASLER; VISSER, 2007)

B.4 Colocação de Receptor

O filme radiográfico ou receptor deve ser posicionado atrás da área de interesse, com o fim apical contra a mucosa na superfície lingual ou palatina. A borda oclusal ou incisal deve ser estendida por 4-5mm além dos dentes. Se necessário para o conforto do paciente, o canto anterior de uma película pode ser amolecido dobrando-o antes de ser colocado contra a mucosa. O cuidado deve ser tomado para não dobrar o filme excessivamente porque isso pode resultar em distorção de imagem considerável e defeitos de pressão na emulsão que é aparente no filme

processado (WHITE, 2013).

B.5 Angulação da Cabeça do Tubo

Para as Subseções B.5.1 e B.5.1, as angulações da cabeça do tubo são especificadas nas Tabelas 4 e 5 a seguir, nas quais são apontadas as regiões, angulação vertical, angulação horizontal e área de incidência para obtenção da radiografia periapical utilizando a técnica da bissetriz. Para compreensão da técnica do paralelismo, o conjunto de imagens nas Figuras 28 (pág. 81), 29 (pág. 81), 30 (pág. 82), 31 (pág. 83), 32 (pág. 83) e 33 (pág. 84) ilustram o uso do posicionador de receptor de imagem, posicionamento do paciente e do feixe central dos raios-x de acordo com o guia externo e pontos de referência para obtenção das imagens radiográficas.

B.5.1 Angulação Horizontal

Quando um dispositivo de retenção de receptores com um anel de localização do feixe é usado, o instrumento está posicionado horizontalmente de modo que, quando o tubo estiver alinhado com o anel, o raio central é direcionado através dos contatos na região que está sendo examinada. E se o dispositivo de retenção de receptores não possui uma localização de feixe característica, o tubo é apontado de modo a direcionar o raio central através dos contatos. Nesta situação, o feixe de radiação também está centrado no receptor. Esta angulação geralmente está em ângulo reto (na projeção horizontal) para as superfícies bucal ou facial dos dentes em cada região.

B.5.2 Angulação vertical

Na prática clínica, o feixe de raio x deve ser incidido centralmente em ângulos retos para um plano, dividindo o ângulo entre o receptor e o longo eixo do dente. Este princípio funciona bem com planos, estruturas bidimensionais, mas os dentes que têm profundidade ou são multirradiculares apresentam distorção. A angulação vertical excessiva resulta em encurtamento da imagem, enquanto a angulação vertical insuficiente resulta em alongamento. O ângulo que direciona o raio central perpendicular ao plano de divisão varia com a anatomia individual. Várias medidas podem ser usadas como guia geral quando o plano oclusal é orientado paralelamente ao chão.

Tabela 4 – Posicionamento da cabeça do paciente para técnica da bissetriz na maxila: PSM perpendicular ao plano horizontal e plano de Camper paralelo ao plano horizontal

Região	Ângulo vertical	Ângulo horizontal	Área de incidência
Incisivos Centrais	+50° a 55°	0°	Ápice nasal
Caninos e incisivos laterais	+45° a 50°	60° a 75°	Asa do nariz
Pré-Molares	+30° a 40°	70° a 80°	Encontro da linha que desce da pupila com a linha trago-asa do nariz(Camper)
Molares	+20° a 30°	80° a 90°	Encontro da linha que desce 1 cm atrás da comissura palpebral externa com a linha trago-asa do nariz (Camper)

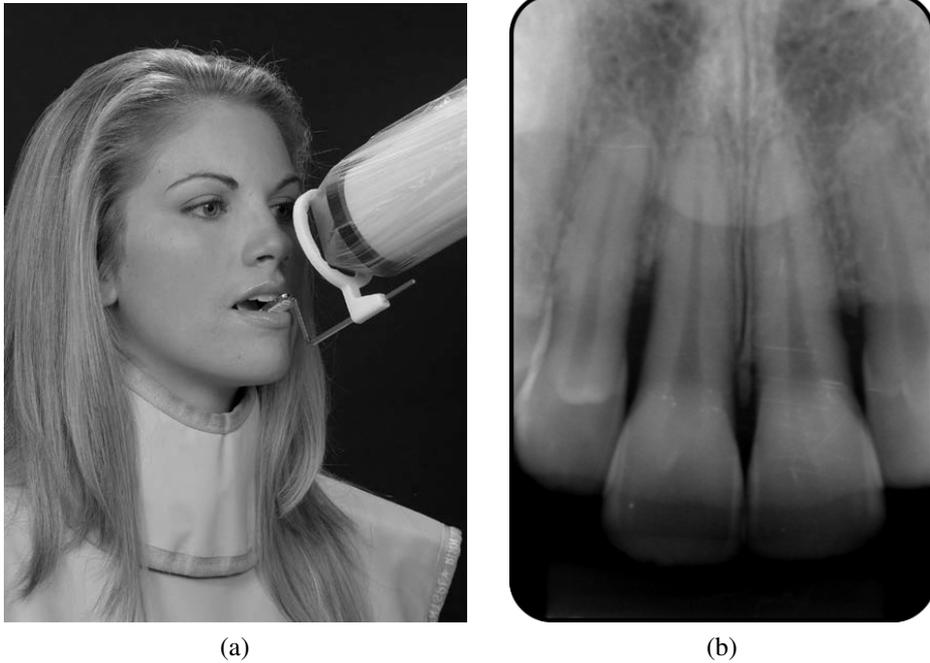
Fonte: (PANELLA, 2006).

Tabela 5 – Posicionamento da cabeça do paciente para técnica da bissetriz na mandíbula: perpendicular ao plano horizontal e linha trago-comissura labial paralela ao plano horizontal.

Região	Ângulo vertical	Ângulo horizontal	Área de incidência
Incisivos	-15° a -20°	0°	Sulco mentolabial
Caninos	-10° a -15°	45° a 50°	Encontro da linha asa do nariz com a linha que passa 2 cm acima da borda da mandíbula.
Pré-Molares	-5° a -10°	70° a 80°	Encontro da linha que desce da pupila 0,5 cm acima da base da mandíbula
Molares	0° a -5°	80° a 90°	Encontro da linha que desce 1 cm atrás da comissura palpebral externa com a linha com 0,5 cm da base da mandíbula.

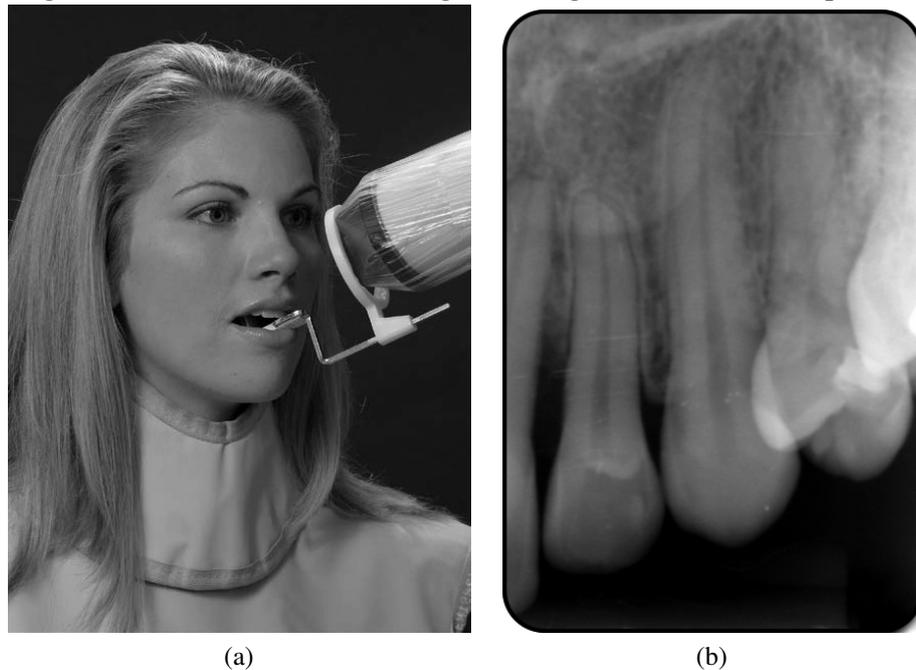
Fonte: (PANELLA, 2006).

Figura 28 – Técnica do paralelismo para incisivos centrais e laterais superiores. 28a - O ponto de entrada do raio central é direcionado ao lábio superior, na linha média, logo abaixo do septo nasal (ápice nasal); 28b - Imagem radiográfica de incisivos superiores.



Fonte: 28a adaptada de (WHITE, 2013) e 28b obtida em parceria com o curso de Odontologia UFC.

Figura 29 – Técnica do paralelismo para caninos superiores. 29a - O raio central deve ser orientado para entrar na região do lábio superior a cerca de 1 cm da linha média na região da asa do nariz; 29b - Imagem radiográfica do canino superior



Fonte: 29a adaptada de (WHITE, 2013) e 29b obtida em parceria com o curso de Odontologia UFC - *Campus Sobral*.

Figura 30 – Técnica do paralelismo para pré-molares e molares superiores. 30a - O raio central deve passar pelo centro da raiz do segundo pré-molar. Este ponto geralmente está abaixo da pupila do olho; 30b - Imagem radiográfica de pré-molares e molares superiores



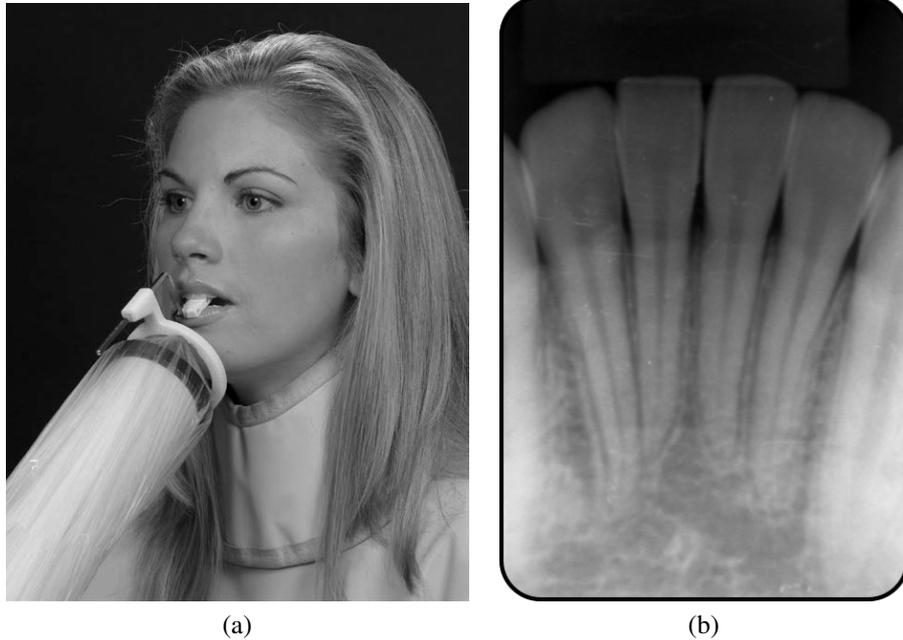
(a)



(b)

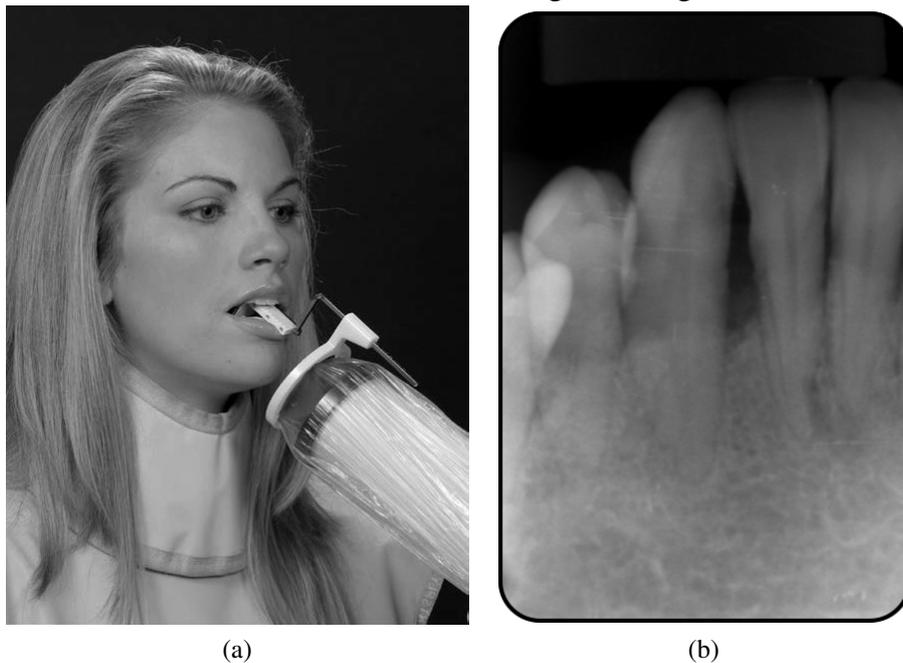
Fonte: 30a adaptada de (WHITE, 2013) e 30b obtida em parceria com o curso de Odontologia UFC - *Campus* Sobral.

Figura 31 – Técnica do paralelismo para incisivos centrais e laterais inferiores. 31a - O ponto de entrada do raio central deve estar na bochecha abaixo do canto do olho e o zigoma na posição do segundo molar superior; 31b - Imagem radiográfica de incisivos inferiores.



Fonte: 31a adaptada de (WHITE, 2013) e 31b obtida em parceria com o curso de Odontologia UFC - *Campus* Sobral.

Figura 32 – Técnica do paralelismo para caninos inferiores. 32a - O ponto de entrada é praticamente perpendicular a asa do nariz, sobre a posição do canino e cerca de 3 cm acima da borda inferior da mandíbula; 32b - Imagem radiográfica do canino inferior.



Fonte: 32a adaptada de (WHITE, 2013) e 32b obtida em parceria com o curso de Odontologia UFC - *Campus* Sobral.

Figura 33 – Técnica do paralelismo para pré-molares e molares inferiores. 33a O feixe raio central deve ser posicionado abaixo da pupila e cerca de 3 cm acima da base da mandíbula; 33b Imagem radiográfica de pré-molares e molares inferiores.



(a)



(b)

Fonte: 33a adaptada de (WHITE, 2013) e 33b obtida em parceria com o curso de Odontologia UFC - *Campus* Sobral.

B.6 Qualidade da radiografia

Todo exame radiográfico deve produzir imagens de ótima qualidade de diagnóstico, incorporando os seguintes recursos:

1. As radiografias devem registrar as áreas de interesse na imagem. No caso de imagens periapicais intraorais, o comprimento das raízes e pelo menos 2 mm de osso periapical

devem ser visíveis. Se a evidência de uma condição patológica estiver presente, a área de toda a lesão mais algum osso normal circundante deve aparecer em uma radiografia. Outro aspecto importante é a ultrapassagem da face oclusal ou incisal cerca de 4 a 5 mm (WHITE, 2013; FREITAS; ROSA, 2004; FITZGERALD, 2001).

2. As radiografias devem ter a menor quantidade possível de distorção. A maior parte da distorção é causada por uma angulação imprópria do feixe de raios-X e não pela curvatura das estruturas ou inadequado posicionamento do receptor (WHITE, 2013).
3. As imagens devem ter uma densidade e contraste ótimos que auxiliem na interpretação do cirurgião-dentista. A miliamperagem (mA), o pico de quilovoltagem (kVp), e o tempo de exposição são parâmetros cruciais que influenciam na densidade e no contraste. Além disso, o processamento defeituoso da película radiográfica na câmara escura pode afetar negativamente a qualidade de uma radiografia devidamente exposta. O praticante deve respeitar sempre o tempo do processamento, a qualidade das soluções de fixador e revelador, bem como as etapas de lavagem evitando a obtenção de imagens inadequadas (WHITE, 2013; PANELLA, 2006; FREITAS; ROSA, 2004).