

UNIVERSIDADE FEDERAL DO PARANÁ

VANIA GRYZAK GEVERT

**SEGMENTAÇÃO AUTOMÁTICA DE ESTRUTURAS PÉLVICAS DE IMAGENS
DE TOMOGRAFIA COMPUTADORIZADA PARA PLANEJAMENTO DA
RADIOTERAPIA DE CÂNCER DE PRÓSTATA**

CURITIBA
2017

VANIA GRYZAK GEVERT

**SEGMENTAÇÃO AUTOMÁTICA DE ESTRUTURAS PÉLVICAS DE IMAGENS
DE TOMOGRAFIA COMPUTADORIZADA PARA PLANEJAMENTO DA
RADIOTERAPIA DE CÂNCER DE PRÓSTATA**

Tese apresentada ao Programa de Pós Graduação em Métodos Numéricos em Engenharia da Universidade Federal do Paraná, como requisito para obtenção do título de doutora.

Orientador: Prof. Dr. Volmir Eugênio Wilhelm

CURITIBA
2017

G 396

Gevert, Vania Gryczak

Segmentação automática de estruturas pélvicas de imagens de tomografia computadorizada para planejamento da radioterapia de câncer de próstata / Vania Gryczak Gevert – Curitiba, 2017.

118 f.: il.; tabs. : color. : 30 cm.

Tese (doutorado) - Universidade Federal do Paraná, Programa de Pós-Graduação em Métodos Numéricos, Departamento de Matemática , Setor de Ciências Exatas.

Orientador: Prof. Volmir Eugênio Wilhelm

Bibliografia: p.84-95.

1. Radioterapia. 2. Imagem. 3. Câncer. I. Universidade Federal do Paraná. II. Wilhelm, Volmir Eugênio. III. Título.

CDD 616.5



TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **VANIA GRYZAK GEVERT** intitulada: **SEGMENTAÇÃO AUTOMÁTICA DE ESTRUTURAS PÉLVICAS DE IMAGENS DE TOMOGRAFIA COMPUTADORIZADA PARA PLANEJAMENTO DE RADIOTERAPIA DE CÂNCER DE PRÓSTATA**, após terem inquirido a aluna e realizado a avaliação do trabalho, são de parecer pela sua aprovação.

Curitiba, 05 de Abril de 2017.

VOLMIR EUGÊNIO WILHELM

Presidente da Banca Examinadora (UFPR)

NEIDA MARIA PATIAS VOLPI

Avaliador Interno (UFPR)

MAURO MIAZAKI

Avaliador Externo (UNICENTRO)

THALITA MONTEIRO OBAL

Avaliador Externo (UFPR)

ARINEI CARLOS LINDBECK DA SILVA

Avaliador Interno (UFPR)

Agradecimentos

Nada na vida conquistamos sozinhos. Sempre precisamos de outras pessoas para atingir os nossos objetivos. As vezes, um simples gesto pode mudar a nossa vida e contribuir para o nosso sucesso.

Concluir uma Tese de Doutorado é sempre um momento de felicidade que gostaria de compartilhar com todos meus familiares e amigos que tanto contribuíram direta ou indiretamente para a realização deste trabalho.

Agradeço ao meu orientador, professor Dr. Volmir Eugênio Wilhelm, pela enorme paciência, pelo incentivo e confiança, principalmente, pela amizade. Com ele, tive a oportunidade de enriquecer meus conhecimentos nos muitos encontros e discussões do trabalho e divido todas as minhas conquistas, pois seu apoio, ajuda e compreensão tornaram-se imprescindíveis para chegar onde estou. Não há palavras para descrever minha gratidão, a ele agradeço do fundo do meu coração.

Ao professor e amigo Arinei Carlos Lindbeck da Silva, pela orientação ao longo da dissertação e por assinar embaixo para que o professor Volmir me orientasse.

Aos professores da banca examinadora: Dra. Thalita, Dr. Arinei, Dr. Mauro e Dr. Neida, pela avaliação e pelas sugestões dadas.

Aos professores do PPGMNE pelos ensinamentos e apoio durante o curso e em especial a professora Dra. Neida Maria Patias Volpi a quem eu aprendi a admirar e a querer bem.

Ao pessoal da física-médica do hospital Erasto Gaertner, por todo suporte na pesquisa, em especial à Melissa e Fernanda, pelas discussões sobre planejamento de radioterapia, tema das imagens analisadas nesta tese. Pelo tempo e dedicação disponibilizados.

A minha grande amiga e incentivadora Thalita, pelas conversas e desabafos, pelos momentos de descontração, trocas de experiências e quilômetros rodados.

Aos colegas de doutorado pelo companheirismo, em especial: Josué, Naiane e Rômulo.

A todos os colegas do CESEC, pelo companheirismo.

A Gilberto que deixou de ser simplesmente chefe para ser meu amigo. Obrigada pelas conversas e desabafos, por estar pronto a me socorrer e por ser uma pessoa tão humana.

Aos meus pais, Vivaldi e Lindamar, pelo exemplo de vida e por me ensinarem a valorizar a educação. Pai, obrigada pela preocupação por eu estar sempre viajando no trecho Curitiba-Guarapuava, mas valeu cada quilômetro rodado. Mãe, obrigada por estar sempre de joelhos dobrados em oração e por me incentivar principalmente nestes últimos momentos.

A minha filha Ana Carolina, razão da minha vida, que apesar da pouca idade, soube entender e aceitar todas as vezes que não pudemos estar juntas. Por ser essa filha maravilhosa.

De maneira especial ao Fabiano, pelas horas de trabalho, discussões, programações e por não me deixar desistir no meio do caminho.

E, principalmente, agradeço a DEUS, meu grande companheiro, por sempre me iluminar e guiar. Por estar sempre presente em minha vida, e tornar tudo possível. Por me mostrar que, mesmo nos momentos difíceis, sempre existem portas a serem abertas. Pelo dom da vida, pela força e amparo nesta jornada.

"Eu guardei muita coisas em minhas mãos, e perdi todas; mas todas que coloquei nas mãos de

Deus, essas eu ainda possuo."

Martin Luther King Jr.

Resumo

Nos últimos anos, o aumento da incidência de casos de câncer de próstata vem se tornando um desafio para a ciência médica. Uma das modalidades de tratamento é a radioterapia de intensidade modulada, IMRT, que permite conformar o feixe de dose de radiação em imagens de duas ou três dimensões. Uma das fases do planejamento consiste na segmentação das imagens das estruturas de interesse, tais como tumores e órgãos nobres e saudáveis, que é realizada manualmente, tarefa que demanda tempo do especialista, limitando o número de planejamentos efetuados. Dessa forma, é proposto um algoritmo de segmentação automática para as estruturas de interesse da região pélvica masculina de imagens de tomografia computadorizada (TC) para o planejamento da radioterapia de câncer de próstata. Neste trabalho foram utilizadas 300 imagens de TC no padrão DICOM, que correspondem a 10 exames de pacientes. Na segmentação das estruturas de interesse, realizou-se um pré-processamento das imagens (filtragem), em seguida, aplicou-se o método de segmentação *Region Growing*. Para a segmentação automática da região pélvica masculina utilizando o método *Region Growing* é necessário a escolha dos *pixels* sementes, que na maioria dos casos, é realizada observando a imagem e selecionando manualmente um ponto na região de interesse que se quer segmentar. O objetivo é que esses pontos sejam escolhidos de forma automática, sem a interferência do observador. Para isso, é proposto um algoritmo de busca de *pixels* sementes (ABS) para a segmentação automática da região pélvica masculina, isto é, as regiões de cabeça de fêmur direita e esquerda, bexiga e reto, considerados tecidos nobres para a etapa de planejamento da radioterapia. A tese contou com o envolvimento de profissionais do Hospital Erasto Gaertner, que forneceram as imagens segmentadas manualmente dos pacientes em tratamento para que fosse realizada a comparação com a segmentação automática. Verificou-se que o algoritmo de *Region Growing* com lançamento automático de sementes teve um índice de similaridade médio, considerando todos os exames estudados de 81,46% para a bexiga e de 60,10% para o reto, e tempo computacional médio de 21,16 segundos. Obteve-se bons resultados confirmados pela equipe de física-médica do hospital Erasto Gaertner. Por conseguinte, a utilização de sistemas assistidos por computador torna-se necessário para superar a demora nesta etapa do planejamento da radioterapia, com uma redução significativa do tempo necessário para a segmentação.

Palavras-chave: planejamento da radioterapia, segmentação de imagens, *region growing*, algoritmo ABS.

Abstract

In past years, prostate cancer incidence is growing, and become a challenge for medical science. Intensity modulated radiotherapy, IMRT, is one of the treatment modalities that allow a radiation dose to be conformed into two or three dimensions images. One of the planning stages consists in interest structures segmentation, such as tumors, and healthy and noble organs, which is manually performed, a task that requires specialist time, and limits the number of accomplished plannings. This way, an algorithm for automatic segmentation is proposed to identify interest structures in the male pelvic region, by using computed tomography (CT) images for prostate cancer radiotherapy planning. For this job we used 300 CT images in DICOM standard, that correspond to 10 patients exams. In interest structures segmentation, it was performed an image pre-processing (filtering), and then, it was applied a segmentation method known as Region Growing. To use Region Growing method for male pelvic region automatic segmentation, it's required to choose seed pixels, which in most cases, it's performed by observing the image, and manually selecting one point in the interest region segmentation. The goal is for these points to be chosen automatically, without the observer's interference. For this purpose, a pixels selecting algorithm (ABS) is proposed for an automatic segmentation of the male pelvic region, which covers right and left femur head regions, urinary bladder, and rectum organ, all of them considered as noble tissues for this stage of radiotherapy planning. The thesis had involvement with Hospital Erasto Gaertner staff, that provided manual segmented images from patients under treatment, in order to perform comparison against automatic segmentation. It was possible to verify that the algorithm for growing regions with automatic seed launching had a mean index similarity, considering all studied exams of 81,46% for the bladder, and 60,10% for rectum organ, and the average computational time of 21,16 seconds. Good results were obtained, confirmed by the Medical physics team of Erasto Gaertner Hospital. Therefore, the use computer-aided systems become necessary in order to overcome the delay in this stage of planning for the radiotherapy, with a significant time reduction needed for the segmentation.

Keywords: radiotherapy planning, images segmentation, region growing, ABS algorithm.

Lista de Figuras

1.1	Região pélvica masculina	18
1.2	Estrutura de um acelerador linear (em vermelho - <i>gantry</i> ; amarelo - colimador; verde - mesa)	20
2.1	Etapas fundamentais no processamento de imagens médicas	29
2.2	Engenharia de imagem e segmentação de imagem	29
2.3	Valores em HU dos órgãos e tecidos	32
2.4	Tabela Hounsfield	33
2.5	Representação gráfica do janelamento	34
2.6	Janela de tecidos mole e ósseo	35
2.7	Imagens e seus respectivos histogramas	41
2.8	Segmentação e discretização	43
2.9	Técnicas de Segmentação	44
2.10	Exemplo do algoritmo <i>K-means</i> - parte 1	50
2.11	Exemplo do algoritmo <i>K-means</i> - parte 2	50
2.12	Exemplo do algoritmo <i>K-means</i> - parte 3	50
2.13	a) Acelerador linear b) Colimador multilâminas c) subfeixes	54
2.14	Colimador multilâminas: três configurações diferentes	54
2.15	Exemplo de discretização da próstata com dimensão $l \times c$	54
2.16	Representação de imagens utilizando <i>voxels</i>	55
2.17	Subfeixes irradiados de um ângulo a do <i>gantry</i>	56
2.18	<i>Gantry</i> e colimador multilâminas	56
2.19	Colimador a 0 graus	58
2.20	Composição de cinco campos	58

2.21	Região da próstata com 5 feixes de radiação	58
2.22	Movimento de rotação dos componentes (vermelho - <i>gantry</i> ; amarelo - colimador; verde - mesa). No cruzamento dos eixos de rotação do gantry e do colimador encontra-se o isocentro (estrela vermelha)	59
2.23	<i>Set-up</i> de tratamento mostrando o acelerador vertical para o posicionamento do paciente e ângulos para o tratamento. As luzes laterais e a marca lateral na pele são usadas para estabelecer a posição vertical do paciente.	59
3.1	Regiões de interesse: tecidos nobres e tumor	71
3.2	Fluxograma Algoritmo ABS	77
3.3	Algoritmo Proposto - Segmentação Região Pélvica Masculina	78
4.1	Imagem da TC região da próstata	81
4.2	Primeiro conjunto de 15, das 30 utilizadas nos testes de um paciente	81
4.3	Segundo conjunto de 15, das 30 utilizadas nos testes de um paciente	82
4.4	Imagem sem janelamento e com janelamento	84
4.5	Imagem dividida em 16 quadrantes	86
4.6	(a) Imagem original (b) Área de busca semente (ABS) para ossos pélvicos definida automaticamente a partir da imagem original	87
4.7	(a) Imagem original (b) Área de busca semente (ABS) para a bexiga definida automaticamente a partir da imagem original	87
4.8	(a) Imagem original (b) Área de busca semente (ABS) para o reto definida automaticamente a partir da imagem original	88
4.9	<i>Pixels</i> brancos e pretos na ABS em cada uma das três regiões	88
4.10	Imagem sem filtro e com filtro mediana	90
4.11	Em (a, c, e, g) são as seções segmentadas manualmente, enquanto em (b, d, f, h) são as seções segmentadas de forma automática, com o ponto de semente destacado em vermelho - paciente 5	92
4.12	Em (a, c, e, g) são as seções segmentadas manualmente, enquanto em (b, d, f, h) são as seções segmentadas de forma automática, com o ponto de semente destacado em vermelho - paciente 8	93

4.13	(a) imagem original fundida a outras regiões (b) segmentação manual pelo dosimetrista (c) segmentação automática pela metodologia proposta	94
B.1	12 imagens com segmentação manual pelo dosimetrista (colunas 1 e3) comparadas com a segmentação automática pela metodologia proposta (colunas 2 e 4)	117
B.2	18 imagens com segmentação manual pelo dosimetrista (colunas 1 e3) comparadas com a segmentação automática pela metodologia proposta (colunas 2 e 4)	118

Lista de Tabelas

3.1	Comparativo Algoritmo Proposto	76
4.1	Valores da largura da janela (<i>window width</i>) (WS) e do centro da janela (<i>window center</i>) (WC)	84
4.2	Dimensões da imagem recortada	85
4.3	Coordenadas dos <i>pixels</i> sementes para cada região em cada paciente	89
4.4	Tamanho do <i>pixel</i> em milímetros	91
4.5	Razão de similaridade (SI) entre a segmentação manual e a segmentação do algoritmo proposto	94
4.6	Razão verdadeiro positivo (TPR) e razão falso positivo (FPR)	95
4.7	Tempo (s) da segmentação de cada região para cada paciente	95

Sumário

1	Introdução	17
1.1	PROBLEMÁTICA	22
1.2	OBJETIVOS	24
1.3	METODOLOGIA	24
1.4	ESTRUTURA	26
2	Referencial Teórico	28
2.1	PROCESSAMENTO DE IMAGENS DIGITAIS	28
2.1.1	Aquisição de imagens	30
2.1.2	Pré-processamento	35
2.1.3	Filtros de imagens	36
2.1.4	Histograma	41
2.1.5	Segmentação	42
2.1.6	Algoritmos de <i>threshold</i>	45
2.1.7	Algoritmos baseados em regiões	45
2.1.8	Algoritmos baseados em técnicas de <i>clustering</i>	48
2.1.8.1	Algoritmo <i>K-means</i>	49
2.1.9	Métodos baseados em contorno	50
2.1.10	Extração de características das imagens	51
2.2	RADIOTERAPIA	53
2.2.1	<i>Gantry</i>	55
2.2.2	Dose Absorvida	55
2.2.3	Composição de campos segundo ajuste do colimador	57
2.2.4	Isocentro	57

2.3	REVISÃO DE LITERATURA	61
2.3.1	Segmentação da Região da Próstata	61
2.3.2	Segmentação de imagens: Region Growing	64
2.3.3	Pixel Semente	65
3	Metodologia	68
3.1	PRÉ-PROCESSAMENTO	69
3.2	MÉTODO <i>REGION GROWING</i>	71
3.3	PROPOSTA DE ALGORITMO DE SELEÇÃO DE <i>PIXELS</i> SEMENTES – ABS	74
3.4	MÉTRICAS	78
4	Resultados e Discussões	80
4.1	AMBIENTE DE TESTES	83
4.2	PRÉ-PROCESSAMENTO	84
4.3	ALGORITMO ABS	86
4.4	<i>REGION GROWING</i>	90
5	Considerações Finais e Trabalhos Futuros	97
	Referências	100
A	Artigo Conbrepro 2014	112
B	Segmentação Paciente 8	117

Capítulo 1

Introdução

De acordo com estimativas mundiais do projeto Globocan 2012, da Agência Internacional para Pesquisa em Câncer (IARC do inglês *International Agency for Research on Cancer*) da Organização Mundial da Saúde (OMS), foram registrados 14,1 milhões de novos casos, e um total de 8,2 milhões de mortes por câncer em todo o mundo naquele ano.

Câncer é a denominação dada a um conjunto de mais de cem doenças que têm em comum o crescimento desordenado (maligno) de células que invadem os tecidos e órgãos, podendo espalhar-se (metástase) para outras regiões do corpo. Dividindo-se rapidamente, estas células tendem a ser muito agressivas e incontroláveis, determinando a formação de tumores (acúmulo de células cancerosas) ou neoplasias malignas. Por outro lado, um tumor benigno significa simplesmente uma massa localizada de células que se multiplicam vagarosamente e se assemelham ao seu tecido original, raramente constituindo um risco de vida (INCA, 2014).

O problema do câncer no Brasil ganha relevância pelo perfil epidemiológico que essa doença vem apresentando, e, com isso, o tema conquista espaço nas agendas políticas e técnicas de todas as esferas de governo. O conhecimento sobre a situação dessa doença permite estabelecer prioridades e alocar recursos de forma direcionada para a modificação positiva desse cenário na população brasileira.

O Instituto Nacional de Câncer José Alencar Gomes da Silva (INCA) destaca-se pelo seu papel nacional no desenvolvimento de ações estratégicas de estruturação e implementação da política de prevenção e controle do câncer, incluindo, de forma especial, seu compromisso na disseminação de informações que contribuam para o estabelecimento de prioridades em termos de saúde pública.

No Brasil, a estimativa para o ano de 2014, que será válida também para o ano de 2015, aponta para a ocorrência de aproximadamente 576 mil novos casos, incluindo os de pele não melanoma, reforçando a magnitude do problema do câncer no país. O câncer de pele do tipo não melanoma (182 mil casos novos) será o mais incidente na população brasileira, seguido pelos tumores de próstata (69 mil), mama feminina (57 mil), cólon e reto (33 mil), pulmão (27 mil), estômago (20 mil) e colo do útero (15 mil).

O câncer de próstata é o segundo mais comum entre os homens (atrás apenas do câncer de pele não-melanoma). Em valores absolutos, é o sexto tipo mais comum no mundo e o mais prevalente em homens, representando cerca de 10% do total. O único fator de risco bem estabelecido para o desenvolvimento do câncer de próstata é a idade. Aproximadamente 62% dos casos diagnosticados no mundo ocorrem em homens com 65 anos ou mais. Com o aumento da expectativa de vida mundial, é esperado que o número de casos novos aumente cerca de 60% até o ano de 2015 (INCA, 2014).

A próstata é uma glândula masculina e que se localiza na parte baixa do abdômen. É um órgão muito pequeno, com forma de maçã e se situa logo abaixo da bexiga e à frente do reto. Envolve a porção inicial da uretra, tubo pelo qual a urina armazenada na bexiga é eliminada. Produz parte do sêmen, líquido espesso que contém os espermatozóides, e é liberado durante o ato sexual.

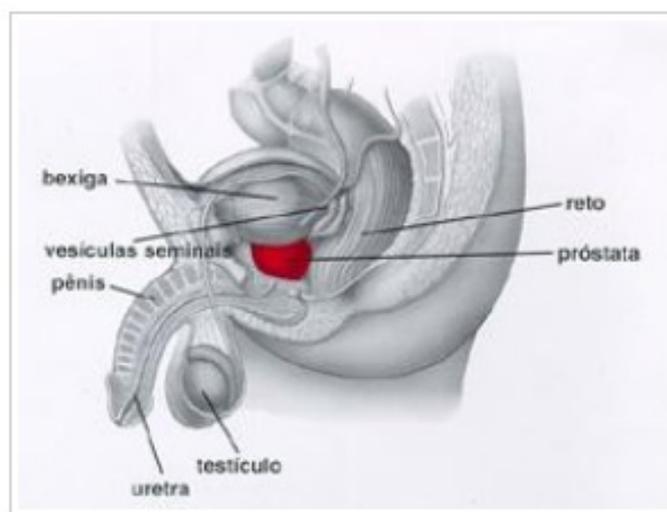


Figura 1.1: Região pélvica masculina
Fonte: INCA (2014)

O câncer de próstata não produz sintomas nas fases iniciais. Com o decorrer do tempo, podem surgir dificuldade para expelir a urina, enfraquecimento do jato urinário, ou aumento do número de

micções. Estes sintomas são comuns nos casos de crescimento benigno, de modo que a presença deles não indica, necessariamente, a existência de câncer, mas exige, no mínimo, uma avaliação médica.

Os principais instrumentos utilizados para o seu diagnóstico incluem o exame digital transretal da próstata, dosagens do antígeno prostático específico (PSA) e a biópsia por ultrassonografia transretal (USTR)(RHODEN, 2010).

Cirurgia, radioterapia e quimioterapia são modalidades de tratamento do câncer (LORENCETTI, 2005). A radioterapia pode ser subdividida em duas categorias: teleterapia (radiação aplicada de uma fonte radioativa externa) e braquiterapia (colocação de sementes radioativas no local cangerígeno - próstata). A escolha do tratamento mais adequado deve ser individualizada e definida após discutir os riscos e benefícios com o médico.

A cirurgia geralmente só é recomendada depois de avaliação e análise abrangentes de todas as opções de tratamento. Um paciente, ao tomar essa decisão, deve estar bem ciente dos benefícios e riscos do procedimento.

Não está claro se a radiação é tão boa quanto a remoção prostática. A decisão sobre qual tratamento escolher pode ser difícil. Frequentemente, a radioterapia é a melhor alternativa em pacientes cuja saúde torna a cirurgia muito arriscada.

Os medicamentos podem ser usados para ajustar os níveis de testosterona. Isso é chamado de manipulação hormonal. Tendo em vista que os tumores prostáticos dependem da testosterona, a redução dos níveis desse hormônio geralmente é eficaz para evitar o crescimento e posterior disseminação do câncer. A manipulação de hormônios é usada principalmente para aliviar os sintomas em pacientes com a doença já em fase de metástase.

A quimioterapia é aplicada, geralmente, para tratar de cânceres de próstata resistentes ao tratamento hormonal.

O tratamento adequado para o câncer de próstata não é concensual. As opções variam dependendo do estágio do tumor.

A teleterapia, ou radioterapia externa, é uma modalidade de tratamento que objetiva a administração de uma dose de radiação ionizante, num volume tumoral previamente definido, buscando diminuir ou erradicar o tumor, minimizando os danos nos tecidos adjacentes. Pode ser utilizada individualmente, ou agregada em outras estratégias de tratamento.

Convencionalmente, os feixes de radiação externos são entregues utilizando um acelerador li-

near, com um colimador multilâminas (MLC ou formador de feixes) alojado na cabeça da unidade de tratamento (ver figura 1.2). Este dispositivo pode girar 360 graus em torno de um único eixo, e fazer várias paradas para a irradiação.



Figura 1.2: Estrutura de um acelerador linear (em vermelho - *gantry*; amarelo - colimador; verde - mesa)

Fonte: Obal (2011)

A dose total de radiação depende do tipo da doença, das dimensões e localização do tumor, e das condições clínicas do paciente. É prescrita pelo médico uma dose para cada tipo de tecido: tumoral, nobre e saudável. Na maioria dos casos, o tratamento dura entre seis e sete semanas. O fracionamento das doses (doses diárias, distribuídas ao longo de várias semanas) e os intervalos das aplicações (descanso nos fins de semana) são estabelecidos para permitir a recuperação dos tecidos normais atingidos pela radiação.

Após confirmação da indicação do tratamento por radioterapia, da técnica escolhida, do método e da prescrição de dose pelo médico radioterapeuta, o paciente é submetido às seguintes fases:

- Simulação;
- Tomografia de Planejamento;
- Planejamento;
- Aplicações.

Na etapa de simulação, com o auxílio de um equipamento chamado simulador, a equipe médica (formada também por físicos e técnicos de radioterapia) irá estudar o melhor posicionamento do corpo e do local em que a radioterapia agirá para receber o tratamento.

Com a ajuda de radiografias, encontra-se os locais desejados, marcando na pele com tinta vermelha ou uma forma de picadas de agulha com tinta preta (uma espécie de "tatuagem" definitiva) e, em alguns casos, podem-se utilizar moldes para manter o paciente na mesma posição.

Na tomografia computadorizada (TC), a submissão do paciente ocorre na posição em que serão efetuadas as aplicações de radiação. Esta tomografia não é utilizada para diagnóstico, e sim para o planejamento da radioterapia. Para tanto, a TC permite obter imagens representativas de seções do corpo, utilizando processamento computadorizado, possibilitando gerar imagens tridimensionais do interior do paciente.

Na etapa de planejamento, o paciente não necessita estar presente. Os profissionais envolvidos, como dosimetristas, físicos e médicos, irão delimitar na imagem da tomografia o local do corpo que será tratado, bem como os órgãos normais adjacentes (também chamados de tecidos nobres e saudáveis) que serão protegidos. Após a identificação dessas estruturas, é realizado o planejamento das incidências da radiação, e o computador vai verificar se a distribuição da dose está adequada, ou seja, se o local que precisa ser tratado está recebendo de forma concentrada a dose prescrita, e os órgãos normais e saudáveis o mínimo possível.

Os modernos equipamentos de radioterapia atuam, em conjunto com aplicativos de software, no planejamento radioterápico. Estes sistemas computacionais desempenham um papel central de apoio à decisão, permitindo a manipulação de imagens e a simulação dos efeitos de um esquema de tratamento. Contudo, podem atingir custos de implantação e manutenção bastante elevados. Tais sistemas, entretanto, não realizam procedimentos automáticos de otimização.

O físico médico responde pela qualidade dos tratamentos, desde a simulação até a última seção de radioterapia de um paciente. Deve determinar o tempo de exposição para cada incidência de radiação no paciente, para que a dose prescrita pelo médico radioterapeuta seja atingida de maneira eficaz.

Após o término e aceite do planejamento pelo médico, o paciente começa a receber as aplicações, cujo número pode variar de uma única aplicação, até 42. Estas aplicações são diárias, realizadas nos dias úteis, e o paciente fica na sala de tratamento entre dez e vinte minutos, dependendo da complexidade da técnica utilizada. São indolores e geralmente os pacientes saem bem, sem sintomas e sem necessidade de um acompanhante, exceto em determinadas situações, caso as condições clínicas prévias exijam.

1.1 PROBLEMÁTICA

Os números atuais do Sistema Único de Saúde (SUS) apontam, segundo relatório de novembro de 2011, divulgado pelo Tribunal de Contas da União (TCU), que pacientes diagnosticados com câncer levam, em média, 113,4 dias para iniciar a radioterapia.

Preocupada com o aumento no risco de morte gerado pela demora do início do tratamento, e com o objetivo de impor aos hospitais um atendimento mais rápido, a presidência da república sancionou, no dia 23 de novembro de 2012, a Lei nº 12.732, obrigando o SUS a iniciar o tratamento de pacientes diagnosticados com câncer em um prazo máximo de sessenta dias.

Um dos motivos que leva à demora no início do tratamento é o planejamento do método utilizado. Segundo Hong *et al.*, 2005, o planejamento do IMRT é mais complexo do que o planejamento da 3D-CRT (*D conformal radiation therapy*). Para ambos, o radioterapeuta designa alvos específicos (tumor alvo e regiões eletivas modulares), e estruturas evitadas (parede retal, bexiga, medula espinhal, glândulas salivares, etc.). Na 3D-RCT, os arranjos dos feixes simples são conformados de forma que se tenham margens de campo para compensar as variações diárias de configuração e características físicas do próprio feixe. A dose de radiação e os cortes são calculados em um processo denominado *forward planning*. Já no planejamento do IMRT, é necessário definir as especificações de dose para o órgão alvo e para as estruturas que se pretende proteger, determinando restrições/permisões de tolerância, de acordo com a importância da proteção necessária ao órgão avaliado nestas restrições/permisões.

O software de planejamento cria uma série de padrões de modulação em que cada feixe de ângulo empenha-se em alcançar as doses prescritas pelo médico. Este processo é conhecido como planejamento inverso.

O primeiro passo no planejamento é delinear (segmentar) previamente a forma do tumor e dos órgãos nobres na imagem tomográfica que devem ser protegidos da radiação, garantindo assim, a aproximação da dose prescrita no volume alvo.

As consequências clínicas por imprecisão incluem uma subdosagem em volumes alvos (aumentando os riscos de recorrência do tumor) e uma superdosagem nos tecidos normais (com aumento no risco de complicações). Atualmente o contorno dos órgãos é feito de forma manual por um radioterapeuta ou dosimetrista. Tratando-se de imagens tridimensionais, esta tarefa pode ser desgastante e demanda tempo do especialista.

O processo de segmentação de uma imagem consiste na divisão de seus elementos (*pixels*) em múltiplas regiões, analisando suas características comuns, ou seja, extraíndo objetos ou áreas de interesse presentes na imagem.

Os trabalhos existentes sobre segmentação de imagens médicas têm se concentrado em raios-X, ressonância magnética (RM), tomografia computadorizada (TC) e ultrassonografia. Podem ser amplamente classificados em três metodologias: métodos de crescimento de regiões (*region growing*), métodos baseados em forma e métodos estatísticos.

De acordo com Parraga (2008), com o avanço dos equipamentos de auxílio ao diagnóstico e sistemas cirúrgicos cada vez menos invasivos, novos métodos de segmentação automática também são propostos para automatizar a tarefa manual e torná-la mais precisa e reproduzível. Para que estes métodos sejam usados clinicamente, auxiliando no diagnóstico, planejamento e tratamento de patologias por imagem, os algoritmos ainda devem ser exaustivamente testados e melhorados tornando-se mais precisos, rápidos e automáticos.

Desta forma, a segmentação adequada de imagens médicas representa uma etapa crucial no desenvolvimento de modelos biomecânicos realistas que auxiliem os profissionais de saúde, tanto no apoio à tomada de decisão como no treino desses profissionais e na consequente redução de custos (SILVA, 2011).

O estudo de imagens médicas depende principalmente da interpretação visual dos radiologistas. No entanto, o delineamento de órgãos é uma das partes mais tediosas e demoradas de planejamento de radioterapia, e geralmente subjetivo, pois depende da experiência do radiologista. É geralmente realizada pelo contorno manual em seções bidimensionais utilizando ferramentas de desenho simples, e isso pode levar várias horas para delinear todas as estruturas de interesse em um conjunto de imagens utilizadas para o planejamento.

Por conseguinte, a utilização de sistemas assistidos por computador torna-se necessário para superar essas limitações. Neste trabalho, é introduzido um algoritmo de área de busca de semente (ABS) para o método crescimento de regiões (automatizado) para delineamento de órgãos, que permite uma redução significativa do tempo necessário para o contorno.

Depois que as regiões de interesse forem segmentadas, o físico médico inicia o processo de otimização no planejamento da intensidade de dose, posições do acelerador linear e disposição da abertura das lâminas no colimador.

1.2 OBJETIVOS

O objetivo principal deste trabalho é propor um algoritmo de segmentação automática para as estruturas de interesse da região pélvica masculina de imagens de tomografia computadorizada (TC) para o planejamento da radioterapia de câncer de próstata.

Os objetivos específicos são:

- Criar um banco de casos de teste para imagens médicas da região da próstata;
- Propor um algoritmo de escolha de *pixels* sementes (ABS) para o método *Region Growing*;
- Aplicar o algoritmo de segmentação automática de imagens médicas para a região pélvica masculina;
- Comparar utilizando métricas a segmentação automática com a segmentação do especialista;

Como tarefas necessárias, destacam-se as de criar, implementar e testar os algoritmos computacionais, capazes de realizar a tarefa de auxiliar no planejamento do tratamento radioterápico em teleterapia (IMRT).

1.3 METODOLOGIA

A proposta do emprego de métodos de processamento digital de imagens (PDI), aliado a radioterapia IMRT, podem auxiliar no saneamento do nível de subjetividade imposto pelo dosimetrista e clínico avaliador. Neste processo, o sistema de PDI pode ser usado para análise computacional das imagens da cavidade pélvica masculina, classificando-as e produzindo resultados baseados em suas informações de cor, forma e aspectos geométrico-morfológicos associados.

Este trabalho é apoiado tecnicamente pelos profissionais do Hospital Erasto Gaertner, com projeto aprovado pelo Comitê de Ética do Hospital na Pesquisa n. 2042.

Um sistema de processamento digital de imagens (PDI) é constituído por várias etapas e possui a capacidade de produzir uma resposta com base em um domínio do problema, no qual cada etapa é executada por uma série de algoritmos computacionais a fim de se obter um resultado ideal a partir da imagem digital. As etapas básicas de um sistema de PDI são: aquisição da imagem, pré-processamento, segmentação, extração de características e reconhecimento (interpretação).

A imagem obtida pela TC pode apresentar diversas imperfeições, tais como: presença de *pixels* ruidosos, contraste e/ou brilho inadequado, caracteres interrompidos ou indevidamente conectados. A função da etapa de pré-processamento é aprimorar a qualidade da imagem para as etapas subsequentes. As operações efetuadas nesta etapa são ditas de baixo nível, porque trabalham diretamente com os valores de intensidade dos *pixels*, tais como redução de ruído, aumento de contraste e suavização de imagem.

Técnicas de filtragens digitais também podem ser aplicadas para remover ruídos ou fazer a detecção de bordas, melhorando a definição das imagens. Atualmente, existem diversas técnicas de processamento para a análise de imagens que permitem quantificar parâmetros, visando fornecer elementos para aprimorar o diagnóstico.

A base de várias técnicas de processamento de imagem no domínio espacial é o histograma. Trata-se de um conjunto de números indicando o percentual de *pixels* que apresentam um determinado nível de cinza. A manipulação do histograma pode ser realizada para o melhoramento de imagem, pois, em sua visualização, obtém-se uma indicação da qualidade da imagem quanto ao nível de contraste e quanto ao seu brilho médio (se a imagem é predominantemente clara ou escura).

A equalização de histograma é uma técnica que consiste no ajustamento da escala de níveis de cinza de uma imagem para que o histograma da imagem de entrada seja mapeado num histograma uniforme (ACHARYA, 2005). Assim, objetiva a obtenção de um histograma uniforme a partir de uma imagem inicial.

Na literatura, os trabalhos de segmentação de imagens médicas têm se concentrado em raios-X, ressonância magnética (RM), tomografia computadorizada (TC) e ultrassonografia, e podem ser amplamente classificados em três metodologias: métodos de crescimento de regiões (*Region Growing*), métodos baseados em forma e métodos estatísticos.

Os métodos baseados em regiões provêm do conceito de que as características quantificáveis dentro de uma estrutura tendem a ser homogêneas. Uma abordagem simples passa por escolher um *pixel* ou um grupo de *pixels* (chamados de sementes) e fundir os *pixels* vizinhos cuja intensidade ou outra propriedade seja semelhante (BANKMAN, 2000).

A vantagem de um método de *Region Growing* é ser capaz de segmentar corretamente as regiões que possuem propriedades semelhantes e estão separadas espacialmente, gerando regiões interligadas (SURI *et al.*, 2005). A sua principal desvantagem é que usualmente requer intervenção manual para obter o ponto inicial de colocação das sementes. Assim, é necessário colocar uma semente

para cada região a segmentar. Uma outra desvantagem prende-se com o fato de que sementes colocadas em regiões iniciais diferentes podem originar segmentações distintas numa mesma imagem (BANKMAN, 2000).

A maioria das estratégias usadas pelos métodos baseados em forma, como contorno ativo (*snake*), passa pela otimização de funções objetivo, procurando encontrar um compromisso entre um termo de energia baseado na imagem, e outro termo relacionado com uma energia interna ou modelo de forma (tipicamente, a suavidade de pontos adjacentes).

Estes modelos necessitam ter um contorno inicial próximo ao desejado e, posteriormente, a *snake* é impelida a deslocar-se em direção a uma solução apropriada de segmentação (SILVA, 2004). A partir disto, pode-se facilmente apurar as desvantagens deste método: o fato de ser sensível aos valores iniciais e de ser fraco para aplicação em estruturas com curvaturas elevadas (SILVA *et al.*, 2008).

Recentemente, foram introduzidos outros métodos neste campo, incluindo métodos estatísticos e abordagens de lógica *fuzzy*. Geralmente definem uma distribuição específica parametrizada, e o principal trabalho é estimar parâmetros pré definidos. Isto significa que tais abordagens implicitamente impõem algumas suposições prévias sobre a distribuição dos dados. Por conseguinte, o seu desempenho depende de quão bem a distribuição assumida fica próxima da distribuição de dados reais. São úteis quando as distribuições de dados de diferentes classes de tecido são conhecidas previamente. No entanto, em casos reais, especialmente em aplicações médicas, geralmente não se têm conhecimento prévio sobre a distribuição dos dados.

Segundo Parraga (2008), o desenvolvimento de um único algoritmo ou método que atenda a qualquer tipo de imagem ou exame é provavelmente uma utopia, devido à complexidade inerente da anatomia humana e das patologias. Portanto, os métodos devem ser adaptados a cada tipo de modalidade de imagem e a cada região do corpo humano.

1.4 ESTRUTURA

O trabalho está organizado da seguinte forma: o capítulo 2 apresenta o referencial teórico, com os principais conceitos envolvidos no planejamento do tratamento do câncer por radioterapia, conceitos de processamento digital de imagens e a revisão de literatura sobre o tema.

O capítulo 3 apresenta a metodologia, com a utilização de um pré-processamento (janelamento e

filtragem) e a proposta de um algoritmo de busca de *pixels* sementes para o método *Region Growing* para a segmentação automática das estruturas pélvicas masculina.

O capítulo 4 apresenta os resultados computacionais obtidos nesta aplicação e a comparação desses resultados com a do dosimetrista (especialista).

No final, o capítulo 5 apresenta as considerações finais e sugestões de trabalhos futuros.

Capítulo 2

Referencial Teórico

Neste capítulo é descrito o referencial teórico do processamento digital de imagens, os tipos de filtros de imagens e alguns dos algoritmos (métodos) de segmentação. Incluiu-se também subseções dos conceitos de radioterapia e revisão bibliográfica dos temas citados.

2.1 PROCESSAMENTO DE IMAGENS DIGITAIS

As primeiras aplicações de imagens digitais surgem no início dos anos 20, com o sistema Bartlane para transmissão intercontinental de imagens por cabo submarino. Porém, as origens do processamento digital de imagem remontam a 1964, quando imagens da superfície lunar são processadas para compensar distorções introduzidas durante sua aquisição (FARIA, 2010).

Em paralelo com as aplicações espaciais, as técnicas digitais de processamento de imagem começaram a ser usadas no campo da medicina. A invenção da Tomografia Axial Computorizada (TC), no início dos anos 70, foi um dos marcos mais importantes na aplicação de processamento de imagem no diagnóstico médico (FARIA, 2010).

O avanço tecnológico dos métodos de diagnóstico por imagem evoluiu consideravelmente. O diagnóstico por imagem revolucionou a medicina de tal forma que hoje é praticamente inviável a detecção de muitos problemas sem a utilização de algum tipo de imagem. A área de diagnóstico por imagem tem acompanhado a evolução tecnológica digital (SIQUEIRA, 2010).

Para a manipulação de imagens utilizando ferramentas computacionais, podem ser necessárias etapas no processamento de imagens, dentre elas, a aquisição, o pré-processamento, a segmentação e a análise de imagens (PEDRINI; SCHWARTZ, 2007).

A etapa de aquisição consiste na obtenção das imagens a serem processadas; o pré-processamento visa a melhora da qualidade da imagem (redução de ruído, aumento de contraste, suavização) e sua adequação às fases posteriores; o objetivo da segmentação é identificar regiões similares; a análise e reconhecimento é a etapa onde as informações presentes na imagem são interpretadas.

Na figura 2.1 é apresentado um esquema com as etapas fundamentais ao processamento de imagens médicas. Observa-se que as etapas não precisam ser necessariamente realizadas, pode-se ter a etapa de aquisição e após a análise e reconhecimento de padrões, sem necessariamente realizar as etapas de pré-processamento e segmentação.

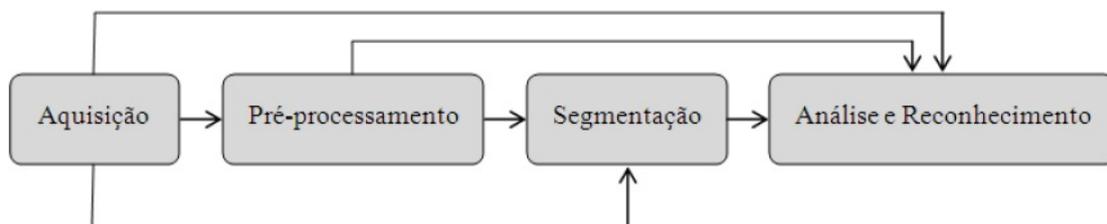


Figura 2.1: Etapas fundamentais no processamento de imagens médicas

Fonte: Siqueira (2010)

As técnicas de processamento de imagens podem ser agrupadas sob uma estrutura geral, engenharia de imagem (EI), que consiste em três camadas: o processamento de imagem (baixa camada), análise de imagem (camada intermediária) e compreensão da imagem (alta camada), como mostrado na figura 2.2. Nos últimos anos, a engenharia de imagem formou uma nova disciplina e têm realizado grandes progressos (Zhang, 2006).

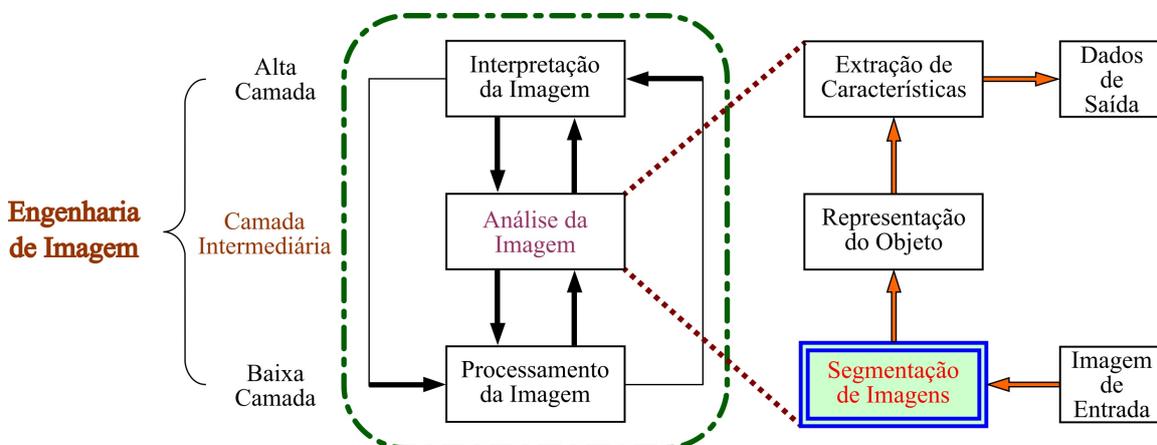


Figura 2.2: Engenharia de imagem e segmentação de imagem

Fonte: Zhang (2006)

2.1.1 Aquisição de imagens

A aquisição de imagens médicas consiste em obter imagens do corpo humano. Essa etapa do processamento não é implementada em *software* e necessita de *hardware* especializado. Os dispositivos de captura de imagens (*scanners*) variam conforme o tipo das imagens de interesse (Tomografia Computadorizada, Ressonância Magnética, Ultra-Som, Raio-X, entre outros) (SIQUEIRA, 2010).

As imagens deste trabalho foram adquiridas com o uso da tomografia computadorizada (TC) e são disponibilizadas no formato DICOM, uma plataforma em que é possível visualizar e manipular imagens médicas.

A TC permite obter imagens representativas de secções do corpo, utilizando processamento computadorizado da informação recolhida após exposição do paciente a radiação X, permitindo gerar imagens tridimensionais do interior do paciente.

Conforme Silva (2008), matematicamente, uma imagem pode ser descrita como uma função da intensidade do sinal retornado em um sensor. A aproximação mais clássica é a definição como uma função da "intensidade luminosa" refletida do objeto. A maioria das imagens considera o espaço bidimensional, sendo definida como $f(a, b)$, onde a e b são as coordenadas espaciais, e f na coordenada espacial (a, b) fornece a intensidade, ou seja, o brilho da imagem no ponto.

A imagem depende da "quantidade de luz" incidente na cena e da "quantidade de luz" refletida pelos objetos da cena. Dessa forma, afirma-se que: $f(a, b) = i(a, b) \times r(a, b)$ onde:

- $i(a, b)$ depende da fonte de luz, $(0 \leq i(a, b) \leq \infty)$;
- $r(a, b)$ depende do tipo de material que compõe o objeto, $(0 \leq r(a, b) \leq 1)$.

Verifica-se que $r(a, b)$ assume o valor zero para absorção total e o valor 1 (um) para reflexão total.

O domínio é finito, geralmente uma matriz retangular, e o conjunto imagem é formado por valores no intervalo $[0, M]$. Para aplicações práticas, a imagem é uma função contínua, representada por medidas obtidas em intervalos regularmente espaçados. Os valores assumidos em cada ponto medido são quantificados em um número pertencente a uma escala de diferentes cores. Em imagens médicas, geralmente essas cores são relacionadas a níveis de cinza, sendo atribuído zero à cor mais escura (preto) e um máximo M à cor mais clara da escala (branco).

Dessa forma, pode-se representar uma imagem como uma matriz onde cada ponto é um valor discreto, conforme mostra a equação 2.1, onde l e c correspondem à quantidade de linhas e colunas, respectivamente.

$$f(a,b) = \begin{pmatrix} f(0,0) & f(0,1) & \dots & f(0,c-1) \\ f(1,0) & f(1,1) & \dots & f(1,c-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(l-1,0) & f(l-1,1) & \dots & f(l-1,c-1) \end{pmatrix} \quad (2.1)$$

O objetivo de definir matematicamente a imagem é a possibilidade de manipular o seu conteúdo a fim de transformá-la ou retirar dela informações importantes. Ao vasto conjunto de operações que podemos aplicar em uma matriz que representa uma imagem denomina-se processamento de imagem. Cada ponto ou elemento constituinte da matriz-imagem é chamado de *pixel*, que é uma abreviação do termo em inglês *picture element*. A medida de um *pixel* depende da resolução espacial com a qual a imagem foi adquirida. Os cortes tomográficos são imagens digitais (2D) em níveis de cinza, em que cada *pixel* da imagem assume um valor de intensidade.

O *pixel* é o elemento básico de uma imagem digital 2D. Cada *pixel* mostra informação do brilho referente à anatomia do paciente naquele *voxel*. A largura e a altura do *pixel* são iguais à largura e à altura do *voxel*. O *voxel* tem uma terceira dimensão que representa a espessura do corte.

Para cada elemento de volume, *voxel* (*volume element*), o computador calcula um dado valor numérico que representa o valor do coeficiente de atenuação daquele *voxel*. Este valor de atenuação na realidade corresponde à quantidade média de absorção de radiação daquele tecido representado pelo *pixel* no monitor. A densidade na tomografia computadorizada é diretamente proporcional (relação linear) com o coeficiente de atenuação, uma constante do tecido influenciado por muitos fatores. O coeficiente de atenuação quantifica a absorção da radiação X, para uma dada energia do fóton. Após a calibração interna do tomógrafo, a densidade do tomograma para a água pura é ajustada para o valor numérico 0, e a densidade do ar padrão para -1000 unidades Hounsfield (*Hounsfield units*, ou simplesmente HU). Esta relação entre o coeficiente de atenuação do tecido e as unidades de Hounsfield forma a conhecida Escala de Hounsfield (PEREIRA, 2016).

O valor de atenuação do ar padrão e da água pura, definidos como -1000 HU e 0 HU, respectivamente, representam pontos fixos na escala de densidade da TC e mantêm-se inalterados mesmo

com a variação da tensão do tubo. Esta é a vantagem da Escala de Hounsfield, sua invariância com qualquer parâmetro eletro-eletrônico, mecânico ou de processamento computacional. Desta forma, os tomógrafos do mundo todo trabalham com esta escala, facilitando a troca de informações entre técnicos e médicos radiologistas. Trata-se, pois, de um padrão universal.

Dependendo da radiação efetiva gerada pelo aparelho de tomografia, a relação da atenuação dos diferentes tipos de tecidos para o padrão da água poderá variar. Portanto, os valores de densidades listados na literatura devem ser considerados como simples indicações ou pontos de referência, e não como valores absolutos para um determinado tecido ou órgão.

Na figura 2.3 pode-se verificar um resumo dos valores médios da Escala Hounsfield, de alguns órgãos e tecidos do corpo humano, bem como a dispersão (variação máxima e mínima) em torno deste valor médio.

Tipo de tecido	Valor médio (HU)	Dispersão
Ósseo (compacto)	>250	
Ósseo (esponjoso)	130 ± 100	
Tiróide	70 ± 10	
Fígado	65 ± 5	45 a 75
Músculo	45 ± 5	35 a 50
Baço	45 ± 5	35 a 55
Linfoma	45 ± 10	40 a 60
Pâncreas	40 ± 10	25 a 55
Rim	30 ± 10	20 a 40
Gordura	-65 ± 10	-80 a -100
Fluídos		Valor Médio (HU)
Sangue (coagulado)		80 ± 10
Sangue (venoso)		55 ± 5
Plasma		27 ± 2
Suor (>30 g proteína/l)		> 18 ± 2
Transpiração (<30 g proteína/l)		< 18 ± 2
Solução		12 ± 2

Figura 2.3: Valores em HU dos órgãos e tecidos
Fonte: Pereira (2016)

Na tomografia computadorizada tem-se uma quantia maior de tons de cinza, algo em torno de 250 tons. Porém, aqui, a convenção para nomenclaturas muda no sentido de que na tomografia trabalha-se com densidade. Hiperdenso para estruturas brancas, isodenso para estruturas que possuam densidade semelhante e hipodenso para estruturas pretas. Basicamente a tomografia trabalha com janelas, dentre as principais podemos destacar: janela óssea, janela de partes moles, janela mediastinal e janela pulmonar. Mas como pode-se guiar no que é hiperdenso, isodenso ou hipodenso? Simples. A escala de Hounsfield (HU), que categoriza a densidade de certas estruturas e

lesões, auxiliando a compreender melhor os sinais emitidos por determinadas lesões ou estruturas anatômicas. Na figura 2.4 tem-se um resumo da escala de Hounsfield.

<i>Densidade na TC</i>	<i>Valores de atenuação</i>	<i>Imagem no filme</i>
Meio de contraste	+100 a 1.000	Branca brilhante
Osso	100	Branca
Água (partes moles)	0 a 100	Cinza médio
Gordura	-60 a -100	Cinza escuro
Ar	-120 a -1.000	Preto

Figura 2.4: Tabela Hounsfield
Fonte: Pereira (2016)

A imagem tomográfica calculada pelo computador é na realidade um conjunto de milhares de valores de Hounsfield memorizados numa matriz quadrada. Estes valores podem variar normalmente de -1000 HU a +3095 HU, devido à codificação digital em 12 bits ($2^{12} = 4096$). Porém, o que interessa ao técnico e ao médico radiologista é uma imagem em tons de cinza mostrada no monitor. Para que isso aconteça, é necessário que se realize uma correspondência entre a Escala de Hounsfield e a escala de níveis de cinza.

Contudo, o olho humano normalmente só pode distinguir entre 20 e 30 tons diferentes. Se toda a escala de densidade de 4000 HU fosse apresentada em uma única imagem, o que seria visível seria apenas uma massa de tecidos moles, alguma musculatura e ossos, além dos pulmões ou regiões com ar. A faixa entre -1000 HU e 1000 HU seria vista pelo radiologista como uma mancha só. Ele não poderia visualizar todas as nuances densitométricas mensuráveis pelo computador, e importantes informações para o diagnóstico seriam perdidas. A janela da imagem foi então desenvolvida como uma forma de produzir contrastes vívidos mesmo em diferenças densiométricas suaves. O nome janela é utilizado, pois ela permite que se visualize apenas uma parte da imagem, não em tamanho, mas em contraste, e também simboliza sua flexibilidade de movimentação, tal qual uma janela comum (PEREIRA, 2016).

O conceito da janela torna possível a expansão da escala de cinza (largura da janela, *window width*) de acordo com uma faixa arbitrária de densidades. Valores de atenuação acima do limite superior da janela aparecem com tom branco, e aqueles abaixo do limite inferior são apresentados em preto. A largura da janela (W) refere-se à extensão de números de TC que são exibidos como

matizes de cinza. Janela ampla indica mais números de TC como um grupo (escala longa ou contraste baixo). Assim, a largura da janela controla o contraste (janelas amplas contraste baixo, como na obtenção de imagens do tórax; janela estreita, contraste alto, como na obtenção de imagens do crânio).

O nível ou centro da janela (*window center*) determina o centro da escala de densidades, ou seja, quais estruturas e órgãos são representados com os níveis intermediários de cinza. O nível da janela (L), também chamado algumas vezes de centro da janela, controla a densidade da imagem, ou determina o número de TC que será o cinza central da extensão da largura da janela. O nível da janela é geralmente determinado pela densidade de tecido que ocorre mais frequentemente dentro de uma estrutura anatômica.

Os ajustes da janela devem ser realizados de acordo com as estruturas a serem diagnosticadas. Janelas estreitas proporcionam uma imagem de alto-contraste, no entanto, há o perigo de estruturas fora da faixa da janela serem inadequadamente apresentadas ou mesmo, não serem percebidas. Com ajustes de janela mais amplos, diferenças pequenas de densidades aparecem homoganeamente sendo assim, mascaradas. A resolução é desta forma reduzida (PEREIRA, 2016).

Na figura 2.5 observa-se a representação gráfica do janelamento e nota-se que todos os valores fora da janela são todos convertidos numa única cor (branco ou preto). Na primeira escala o centro é 200 na escala Hounsfield, relacionado com o 128 na escala de cinza, enquanto que a largura da janela é de 800, pois é a variação de -500 a 900 na escala Hounsfield. Na segunda escala o centro é 1000 HU relacionado com o centro 128 da escala de cinza, enquanto a largura da janela é de 400, pois é a variação de 800 a 1200 na escala Hounsfield.

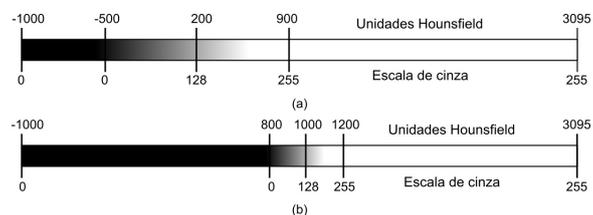


Figura 2.5: Representação gráfica do janelamento
Fonte: Pereira (2016)

Quando é escolhida uma janela larga, representa-se centenas de valores de densidade para cada tom de cinza, assim, consegue-se ver apenas o que é muito diferente, por exemplo, ar e osso. A analogia é com uma grande janela voltada para o horizonte. Para vermos tudo de uma vez, perde-se

pequenos detalhes. Assim, não é possível ver o parênquima cerebral, apenas osso, por isto chama-se de janela óssea. No tórax, o mediastino fica obscurecido, mas o parênquima pulmonar é delineado pelo ar, por isto chama-se de janela pulmonar. Qual a diferença entre elas? O centro. A janela larga para osso tem largura de 2000 HU e centro de 300 a 600. Na janela pulmonar a largura é em torno de 2000 a 4000 HU e centro em torno de -600 HU. O centro da janela fica na média das estruturas que é necessário ver melhor.

Quando é escolhida uma janela estreita, representa-se poucas unidades de densidade nos mesmos tons de cinza. Assim, perde-se os extremos e ganha-se em capacidade de ver detalhes em torno do centro escolhido. Novamente na analogia, é como se tivesse uma janela bem estreita, perdendo a visão do horizonte, mas, tendo uma pequena porção de cenário para ver, podendo-se ter maior detalhe do que está se vendo. No caso do tórax, é visto muito bem o mediastino e a musculatura.

Observa-se na figura 2.6 duas imagens de TC com janela de tecidos moles e uma janela de tecidos ósseos, na primeira, a imagem é mais acinzentada com maiores detalhes de regiões e na segunda o contraste entre o osso e as estruturas são mais visíveis, porém os detalhes não são tão nítidos.

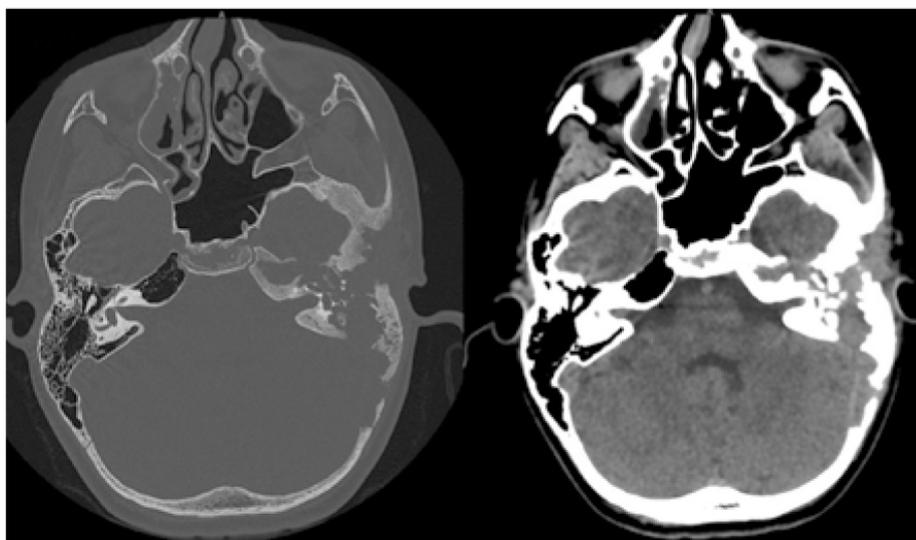


Figura 2.6: Janela de tecidos mole e ósseo
Fonte: Bento (2015)

2.1.2 Pré-processamento

A imagem resultante do passo anterior pode apresentar diversas imperfeições, tais como: presença de *pixels* ruidosos, contraste e/ou brilho inadequado, caracteres interrompidos ou indevida-

mente conectados. A função da etapa de pré-processamento é aprimorar a qualidade da imagem para as etapas subsequentes. As operações efetuadas nesta etapa são ditas de baixo nível porque trabalham diretamente com os valores de intensidade dos *pixels*, tais como redução de ruído, aumento de contraste e suavização de imagem.

A filtragem é realizada *pixel a pixel*, onde o novo nível de cinza de um ponto P qualquer depende do seu nível de cinza original e de outros pontos considerados como vizinhança de P . Em geral, os pontos mais próximos de P contribuem mais para o novo valor do nível de cinza do que os pontos mais afastados.

Os dois domínios da filtragem são: domínio espacial, que são procedimentos que operam diretamente sobre os *pixels* da imagem na sua forma original; e o domínio da frequência, que são procedimentos que operam sobre a Transformada de Fourier (TF) da imagem original.

Os tipos de filtros são os lineares, que suavizam, realçam detalhes da imagem e minimizam efeitos de ruído, sem alterar o nível médio de cinza da imagem, e os não lineares, que aplicam transformações sem o compromisso de manter o nível médio de cinza da imagem original.

Algumas filtragens no domínio da frequência são: passa baixo, passa alto, filtro circular não centrado na origem, filtro setor angular, filtro de Gabor, entre outros.

Algumas filtragens no domínio espacial são: lineares e não lineares, de suavização (passa baixa, filtro de média, gaussiano, de mediana), filtros passa alta ou de acentuação, gradiente ou derivada de imagens, filtro e operador de Sobel, de Roberts, de Prewitt, laplaciano, LoG ou laplaciano do gaussiano, canny, filtro passa banda e alto reforço.

2.1.3 Filtros de imagens

Segundo Marques Filho (1999), o principal objetivo das técnicas de realce é processar uma certa imagem, de modo que a imagem resultante seja mais adequada que a original para uma aplicação específica.

As técnicas de filtragem no domínio espacial são utilizadas para redução de ruído em imagens (ACHARYA, 2005). Estas técnicas atuam diretamente nos *pixels* e consiste na aplicação de uma máscara de filtro em cada ponto da (x,y) , utilizando relações predefinidas para o cálculo da resposta.

Deste modo, a aplicação destes operadores locais consiste na definição de um ponto central (m,n) , na execução de uma operação que envolve apenas os *pixels* numa vizinhança predefinida em torno desse ponto central, resultando na resposta do processo e no valor a ser escrito no *pixel* (m,n)

da imagem filtrada. Este processo é repetido para cada *pixel* da imagem.

Nos filtros de realce, os detalhes “finos” ou variações abruptas numa imagem, correspondem a componentes de alta frequência, enquanto os detalhes mais “grosseiros”, caracterizados por variações mais lentas, permitindo uma visualização menos detalhada da imagem, surgem como componentes de baixa frequência.

Nos filtros de suavização, os contornos e transições contribuem para a componente de altas frequências da TF de uma imagem. A suavização no domínio das frequências é realizada utilizando a atenuação de um determinado intervalo de componentes de altas frequências na transformada de uma imagem.

Um filtro passa-baixo, tal como o próprio nome evidencia, filtra as variações bruscas de cor da imagem, ou seja, as altas frequências.

Filtragem passa-baixo de uma imagem é uma operação de média (ACHARYA, 2005). Produz uma imagem de saída mais suavizada que a imagem de entrada, sem as suas componentes de altas frequências espaciais originais (regiões de bordas e/ou detalhes finos).

Substitui o valor de cada *pixel* pela média dos níveis de cinza na sua vizinhança, definida pela máscara utilizada, e produz uma imagem com transições mais suaves nos seus níveis de cinza. Todos os filtros passa-baixo têm um efeito de suavização, provocando um leve borramento. Este tipo de filtro é útil na remoção de ruído visual, que normalmente surge como pontos de alto brilho, provocando perda de precisão.

Filtros do tipo passa alto produzem uma imagem em que as componentes espaciais baixas são atenuadas, e, em função disto, realçam as bordas e regiões de alto contraste. A frequência limite a que as baixas frequências são atenuadas varia com a definição dos coeficientes utilizados. Este tipo de filtragem é utilizado para realce de bordas ou contornos, uma vez que os contornos estão relacionados com as altas frequências espaciais (GONZALEZ e WOODS, 2002).

Os tipos mais frequentes de filtros são: gaussiano, laplaciano, de média, mediana, LoG (Laplaciano do Gaussiano), *Unsharp*, Sobel e Prewitt e disk e descritos a seguir.

O filtro de média é um dos mais simples filtros lineares é implementado utilizando uma operação local de média, onde o valor de cada *pixel* é substituído pela média de todos os valores na sua vizinhança local. Alterando o único parâmetro possível, ou seja, a dimensão da janela utilizada, verifica-se que quanto menor for a janela, melhores são os resultados e maior é a aproximação à imagem original. Isto porque à medida que aumenta a janela, aumenta o número de *pixels* que vão

contribuir para a obtenção do resultado final (OLIVEIRA, 2005). Se a janela for suficientemente grande, dependendo também do conteúdo, a imagem ficará mais desfocada. Pode-se, em alguns casos (dependendo do tamanho da janela e da dimensão das partículas), eliminar o ruído existente à custa de uma pequena degradação na qualidade da imagem original, isto é, provocando uma pequena suavização.

O filtro *Unsharp* é obtido a partir do inverso do filtro Laplaciano. Recebe também alfa como único parâmetro, que determina a forma do filtro Laplaciano. Aplicando diferentes alfas em diversas imagens, observa-se que, com o seu aumento, a imagem parece manter o contraste, refletindo-se numa melhor preservação das orlas. Nota-se também uma degradação na qualidade. O filtro *Unsharp* é um simples operador de realce que recebe o seu nome por realçar orlas (e outras componentes de alta frequência), utilizando uma subtração de uma imagem suavizada à imagem original. Esta técnica é amplamente usada na indústria fotográfica e de impressão para realce de orlas (OLIVEIRA, 2005).

O filtro Mediana, tal como o próprio nome indica, corresponde a atribuir a cada ponto visitado, o mediano para uma determinada janela utilizada. O resultado da sua aplicação é uma suavização da imagem original, que se acentua quanto maior for o tamanho da janela utilizado e permite uma atenuação dos ruídos presentes. Assim, este filtro realiza uma operação não linear, sendo designado operador de ordem (procura estabelecer uma ordem nos valores abrangidos pela máscara de filtragem). O filtro de mediana, além de contribuir para a eliminação do ruído, preserva melhor as orlas quando comparado ao filtro de média. Uma imagem digital pode ser representada por uma matriz. Dada uma matriz A de inteiros positivos e ímpares p e q , o filtro da mediana produz uma matriz transformada M , com as mesmas dimensões de A , definida da seguinte maneira: para cada par de índices (i, j) , o elemento $M(i, j)$ da matriz transformada é a mediana dos elementos de $A_{i, j}$ (a vizinhança pxq em torno de (i, j)).

Os filtros de Sobel e Prewitt não recebem nenhum parâmetro, uma vez que as matrizes para efetuar a convolução já estão predefinidas. Este processo consiste na convolução de uma janela, para detectar as orlas horizontais. Paralelamente passa-se a janela transposta. A imagem final é a média desses dois resultados intermédios. Por análise das imagens conclui-se que também estes filtros se apresentam como uma boa ferramenta para detecção de orlas. Normalmente, é mais usado o filtro de Sobel que o de Prewitt, pois o primeiro apresenta maior imunidade ao ruído. Isto é facilmente verificado pela análise dos coeficientes de cada janela (OLIVEIRA, 2005).

O filtro gaussiano recebe como parâmetros a dimensão da janela e um valor para o desvio padrão máximo (sigma). Este filtro tem um comportamento similar ao filtro passa-baixo, isto é, a sua aplicação resulta numa suavização da imagem original. É tanto mais visível quanto maior for o desvio padrão (sigma) considerado, não dependendo muito do tamanho da janela utilizada. Desta forma, observa-se que o aumento de sigma traduz-se num aumento do número de *pixels* cujo valor é diferente de zero, o que implica no aumento da contribuição dos *pixels* vizinhos a cada ponto, apresentando uma maior suavização. Cabe salientar a pouca influência que tem a variação do tamanho da janela, e a alteração entre os diferentes espaços de cor, já que os resultados finais são muito semelhantes (OLIVEIRA, 2005). Usando a função Gaussiana para obter valores de uma máscara a ser definida digitalmente. O filtro gaussiano em 1-D tem a forma:

$$G(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (2.2)$$

onde σ é o desvio padrão. É assumido que a distribuição tem média zero (isto é, está centrada em $x = 0$).

Em 2-D, sua forma isotrópica (isto é, circularmente simétrica) é dada pela equação

$$G(x,y) = \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.3)$$

Considerando que a imagem é armazenada como uma coleção de *pixels* discretos precisa-se produzir uma forma discreta da distribuição Gaussiana para obter um núcleo de convolução (máscara ou kernel), este seria teoricamente infinitamente grande, mas na prática se zera aproximadamente a uma distância de três unidades (ou *pixels*) do centro. Os filtros Gaussianos são muito úteis também em Biologia Computacional e Visão, pois no processo de visão algumas células têm forma de resposta aproximadamente Gaussiana.

O filtro Laplaciano tem alfa como único parâmetro, controlando a forma dos coeficientes do filtro Laplaciano. Analisando os resultados correspondentes à variação deste parâmetro, observa-se que a diminuição de alfa se traduz numa ligeira melhoria na obtenção dos contornos dos objetos. Seja qual for o alfa utilizado, pode-se concluir que o uso deste filtro funciona como uma boa ferramenta para a obtenção dos contornos (OLIVEIRA, 2005).

O filtro LoG (Laplaciano do Gaussiano) é uma medida isotrópica 2-D da segunda derivada espacial de uma imagem, que destaca as regiões de mudança rápida de intensidade, sendo por isso

frequentemente usado na detecção de orlas. O laplaciano é frequentemente aplicado a imagens que previamente foram suavizadas com um filtro gaussiano, de forma a reduzir a sua sensibilidade ao ruído. Os parâmetros deste filtro são:

- dimensão da janela: criar uma matriz quadrada com a dimensão especificada;
- sigma: desvio padrão do filtro gerado.

O Laplaciano , $L(x,y)$, de uma imagem é a derivada segunda do valor da função que descreve a intensidade dos seus *pixels*, $I(x,y)$, sendo representado por:

$$L(x,y) = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2} \quad (2.4)$$

Considerando que a imagem é armazenada como uma coleção de *pixels* discretos, precisa-se produzir uma forma discreta da derivada segunda que é representada por um núcleo de convolução (máscara ou kernel). Como a imagem processada pelo filtro Laplaciano é muito sensível a ruídos, ela geralmente deve ser processada por um passa baixa como o filtro Gaussiano antes de aplicada na imagem.

No entanto como essas duas operações são lineares e associativas, podem ser aplicadas no kernel do filtro e depois na imagem, reduzindo bem o tempo de processamento, pois o tamanho de ambos é muito menor do que o da imagem.

Assim, surge o filtro que processa a derivada segunda da imagem processada pelo filtro de Gaussiano em uma só operação, usando a derivada segunda da máscara Gaussiana a ser usada. Este processo resulta no filtro Laplaciano do Gaussiano que é representada por:

$$LoG(x,y) = \frac{1}{\pi\sigma^4} \left[1 - \frac{x^2 + y^2}{2\sigma^2} \right] e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (2.5)$$

Como o LoG calcula as derivadas segundas de uma imagem, áreas com intensidades constantes (isto é, com gradiente = zero), terão valores de LoG também zero. Na vizinhança da mudança da *intensity*, a resposta do LoG sera positiva no lado mais escuro e negativa no lado mais claro.

É preciso prestar atenção nos valores dos *pixels* de saída, pois como estes podem ser negativos podem simplesmente deixar de ser representados ou serem representados por valores reais de forma inadequada, provocando *overflow* ou saturação nos limites.

O filtro Disk é um filtro circular passa-baixo com uma matriz quadrada de tamanho $2 * raio + 1$, onde raio é um parâmetro passado como argumento. Segundo Oliveira (2005), a partir de vários testes variando o raio, chegou-se à conclusão de que quanto maior ele for, maior será a suavização sofrida pela imagem original.

2.1.4 Histograma

A base de várias técnicas de processamento de imagem no domínio espacial é o histograma. O histograma de uma imagem é simplesmente um conjunto de números indicando o percentual de *pixels* naquela imagem que apresentam um determinado nível de cinza. A manipulação do histograma pode ser utilizada para o melhoramento de imagem, pois, em sua visualização, obtém-se uma indicação da qualidade da imagem quanto ao nível de contraste e quanto ao seu brilho médio (se a imagem é predominantemente clara ou escura).

A equalização de histograma é uma técnica que consiste no ajustamento da escala de níveis de cinza de uma imagem, para que o histograma da imagem de entrada seja mapeado num histograma uniforme (ACHARYA, 2005). Observa-se na figura 2.7 uma imagem e seu respectivo histograma equalizado.

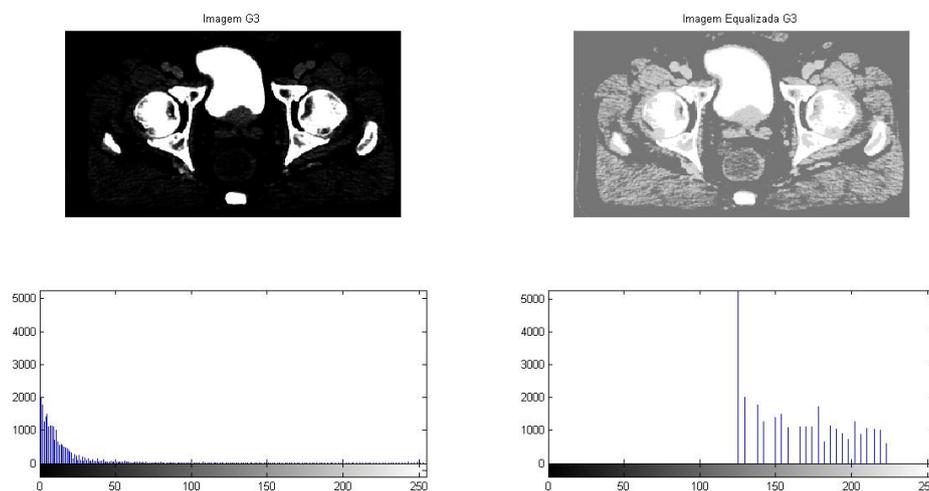


Figura 2.7: Imagens e seus respectivos histogramas

Fonte: A autora

O objetivo da equalização de histograma é a obtenção de um histograma uniforme a partir de uma imagem inicial. Sendo a variável r no intervalo de $[0:1]$, que indica o nível de cinza de uma imagem, $r = 0$ o preto e $r = 1$ o branco, a transformação:

$$s = T(r)$$

produz um nível s para cada *pixel* na imagem original. É assumido que $T(r)$ é uma função de valor único, aumentando monotonicamente no intervalo de $[0:1]$, e $T(r)$ toma valores entre 0 e 1. A primeira condição preserva a ordem da cor preta para o branco na escala de cinzas, e a segunda condição garante que a função seja consistente com intervalo definido para os valores das intensidade dos *pixels* (ACHARYA, 2005).

O método usado para gerar uma imagem processada com um histograma específico é chamado de especificação de histograma. Quando é pretendido um melhoramento automático da imagem, a equalização de histograma é uma boa opção, pois os resultados são previsíveis e o método é simples de implementar (GONZALEZ e WOODS, 2002). A especificação de histograma não considera a percepção do contraste, o que resulta numa degradação da qualidade subjetiva da imagem.

2.1.5 Segmentação

O principal objetivo da segmentação de imagens é o particionamento independente de uma imagem em um conjunto de regiões disjuntas que são visualmente diferentes, homogêneas e significativas em relação a algumas características como o nível de cinza, textura ou cor. A segmentação de imagens é uma ferramenta útil em muitos domínios, incluindo a indústria, cuidados de saúde, astronomia, e vários outros campos.

Os tecidos do corpo quando estão sendo preparados para um tratamento são divididos em três classes: tumor (T), tecidos saudáveis(S) e tecidos nobres (N). Para efeito do cálculo da dose, os tecidos são segmentados de forma a que se delimite as fronteiras entre cada tipo de tecido. Depois de segmentados, os tecidos são discretizados em unidades de cálculo cúbicas. As unidades cúbicas são tratadas através de seções planares denominadas *pixels*.

O processo é exemplificado na figura 2.8 em uma seção bidimensional. Na figura 2.8(a) observa-se uma imagem tomográfica, onde o tumor é marcado por uma seta. A segmentação e a discretização da imagem da figura 2.8(a) são mostradas, respectivamente, nas figuras 2.8(b) e 2.8(c). Várias seções bidimensionais são consideradas para uma reconstrução tridimensional. Uma vez discretizada, a imagem passa a ser representada por uma grade de dimensões L e C (figura 2.8(c)), onde cada elemento da grade é um quadrado correspondente a um elemento básico (*pixel*) (GOLDBARG,

2009).

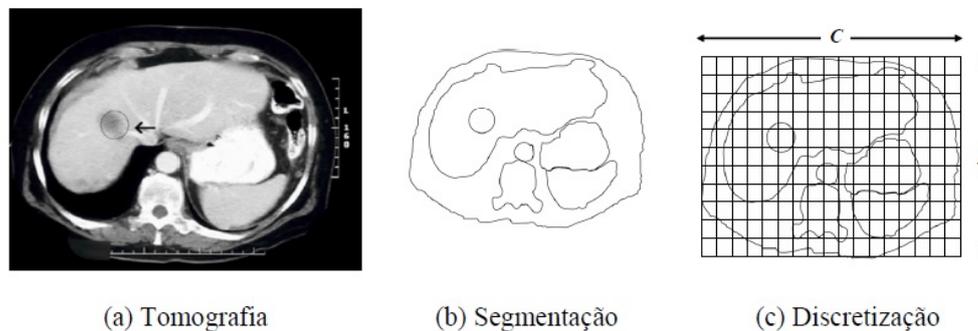


Figura 2.8: Segmentação e discretização
Fonte: Goldberg (2009)

O conceito de segmentação é uma idéia muito simples. Basta olhar para uma tomografia, pode-se dizer que regiões estão contidas em uma imagem. É um edifício, uma pessoa, uma célula, ou simplesmente um fundo. Visualmente é muito fácil de determinar o que é uma região de interesse e o que não é. Fazer isso com um algoritmo de computador, por outro lado não é tão fácil. Como você determina o que define uma região? Que características distinguem uma região de outra? O que determina quantas regiões que você tem em uma determinada imagem? Descontinuidade e semelhança / homogeneidade são duas propriedades básicas dos *pixels* em relação aos seus vizinhos locais usados em muitos métodos de segmentação.

A segmentação permite a compreensão, análise e interpretação de imagens. O principal objetivo é a divisão da imagem original em regiões (ou classes) homogêneas relativamente a uma ou mais características. A aplicação mais visível desta técnica em imagens médicas é a localização anatômica de órgãos, ou em termos genéricos, a região de delimitação de interesse, cujo principal objetivo é delinear as estruturas anatômicas e as regiões (patológicas) de interesse (GHISTA, 2008).

Segundo Rastgarpour e Shanbehzadeh (2011), as abordagens de segmentação de imagem estão divididas em categorias, com base em duas propriedades da imagem:

- Detecção de descontinuidades: significa particionar uma imagem baseada em mudanças bruscas de intensidade; o que inclui algoritmos de segmentação de imagens como a detecção de bordas.
- Detecção de similaridades: significar particionar uma imagem em regiões que são semelhantes, de acordo com um critério pré-definido; o que inclui algoritmos de limiarização,

crescimento de região, divisão e fusão de regiões.

Neste trabalho são utilizadas imagens em níveis de cinza, ou seja, a imagem é representada por um conjunto finito de números inteiros que vão de 0 a 255, onde cada valor é um nível de cinza, que representará cada ponto da imagem. Os algoritmos de segmentação de imagens em níveis de cinza geralmente são baseados em uma das duas propriedades: descontinuidade ou similaridade. Há um grande número de técnicas de segmentação, propostas e implementadas, mas ainda não há um *standard* que satisfaça todos os critérios.

Segundo Torres (2012), os métodos de segmentação podem ser divididos nas seguintes categorias:

- Binarização (ex. *threshold*);
- Baseados na região (ex. *Region Growing*, *watershed*);
- Métodos estatísticos (ex. *fuzzy C-means*, *K-means*);
- Métodos baseados em forma;
- Baseados no contorno (ex. *canny*).

Kamdi (2012) divide as diversas maneiras de segmentação como observado na figura 2.9.

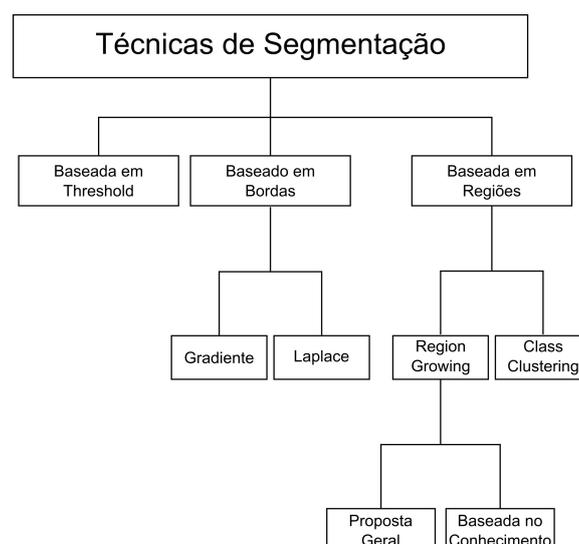


Figura 2.9: Técnicas de Segmentação

Fonte: Kamdi (2012)

2.1.6 Algoritmos de *threshold*

Este tipo de algoritmo baseia-se no princípio de que as estruturas ou órgãos de interesse têm características distintas quantificáveis, tais como a intensidade ou magnitude do gradiente da imagem. O processo de segmentação baseia-se na busca de *pixels* cujos valores estão dentro dos intervalos definidos pelos limiares (*thresholds*).

O método mais utilizado é a média de *thresholds* devido à sua simplicidade de implementação e propriedades intuitivas. Nesta técnica, um valor predefinido (*threshold*) é selecionado manual ou automaticamente, e uma imagem é dividida em grupos de *pixels* com valores iguais ou superiores ao limiar, e grupos de *pixels* com valores inferiores a esse limiar.

Quando apenas um limiar é selecionado para toda a imagem, com base no histograma da imagem, é usualmente chamado de *thresholding* global. Se o *threshold* depende de propriedades locais de algumas regiões da imagem, por exemplo, o valor médio local de cinza, o *threshold* é chamado local. Se os *thresholds* são selecionados de forma independente para cada *pixel* ou grupo de *pixels*, é chamado de dinâmico ou adaptativo (PHAM *et al.*, 2000).

Conforme Silva (2008) a abordagem mais intuitiva é *thresholding* global, sendo o método de Otsu o mais generalizado, simples e computacionalmente rápido. Baseia-se no pressuposto que uma imagem pode ser representada por um histograma bimodal e, conseqüentemente, pode-se obter a estrutura de interesse com uma simples operação que compara os valores da imagem com o valor definido para o *threshold*.

2.1.7 Algoritmos baseados em regiões

A partição da imagem baseada no conteúdo de grupos de *pixels* é chamada de segmentação orientada ou baseada em regiões. De uma maneira ideal, uma partição será associada a um padrão, objeto ou parte dele numa imagem. Portanto, para uma imagem ser interpretada corretamente, é necessário particioná-la em regiões que correspondam aos objetos ou padrões. O processo consiste na separação destas regiões.

As regiões devem possuir algumas propriedades ou predicados diferentes para ser possível segmentá-los. Esta propriedade deve permitir, por exemplo, destacar uma superfície que representa um osso dentro de uma radiografia, ou uma peça dentre várias sendo submetida a um controle de qualidade ou ainda uma área de estradas de uma imagem de satélite usada para planejamento urbano.

A técnica de segmentação baseada em crescimento de regiões consiste em analisar a similaridade entre os *pixels* que tenham a mesma propriedade. O procedimento de desenvolvimento é aplicado em regiões de interesse pré-selecionadas que consiste em primeiro definir um *pixel* inicial que é denominado de "semente". Esta semente com coordenadas (x,y) é o ponto principal da imagem e a partir dele começam a crescer as regiões (GONZALEZ e WOODS, 2002).

Em seguida, é feita uma verificação nos *pixels* da vizinhança desta semente. Esta verificação depende de uma propriedade de seleção que deve ser predefinida pelo desenvolvedor. Esta propriedade que determina se um *pixel* faz parte ou não de uma região deve levar em consideração o grau de semelhança entre os *pixels*, como por exemplo, uma faixa de valor do nível de cinza (GONZALEZ e WOODS, 2002).

Alguns problemas precisam ser considerados no processo de crescimento de regiões. Inicialmente é necessário que a seleção de "sementes" represente adequadamente as regiões de interesse. Também é preciso selecionar adequadamente as propriedades para a inclusão de pontos nas várias regiões durante o processo de crescimento. Outro problema é o estabelecimento de um critério de parada. O crescimento de uma região deveria parar quando não houvesse mais *pixel* que satisfizesse os critérios de inclusão naquela região. Critérios como: intensidade, textura e cor são locais e estáticos por natureza, não consideram o histórico do processo de crescimento de região. Critérios adicionais que utilizam o conceito de tamanho, similaridade entre o *pixel* candidato e os *pixels* acrescidos até aquele momento e a forma da região sendo operada são desejáveis para aumentar o poder do algoritmo de crescimento de regiões.

Exemplo de opções que aumentam a capacidade do algoritmo são a inclusão das seções anteriores e posteriores em imagens médicas de ressonância magnética e tomografia, ou o uso das informações dos quadros posteriores e anteriores em análise de vídeos ou imagens em movimento.

Normalmente, o crescimento de regiões emprega um conjunto de descritores baseados em intensidade e em propriedades espaciais (como descritores de texturas) de uma única fonte de imagens. Porém, a informação de conectividade ou de adjacência deve ser considerada no processo de crescimento de regiões, pois o emprego destes descritores isoladamente pode conduzir a resultados enganosos (GONZALEZ e WOODS, 2002).

No caso de não ser possível a definição de um ponto semente inicial, todas as regiões da imagem pode ser consideradas sementes em relação ao predicado. No caso de serem obtidas diversas segmentações diferentes algum critério de decisão sobre a melhor forma final pode ser incluído.

As abordagens de segmentação baseadas em regiões fazem a análise de *pixels* de uma imagem e formam regiões disjuntas agrupando *pixels* vizinhos com propriedades de homogeneidade baseadas em critérios de similaridade predefinidos (MA *et al.*, 2010).

A técnica mais simples de segmentação baseada em regiões é chamada *Region Growing* (crescimento por regiões), e faz o agrupamento em segmentos de *pixels* que possuem propriedades similares. Esta técnica começa com um *pixel*, ou grupo de *pixels*, chamada(s) de semente(s), que pertence(m) à estrutura de interesse.

A(s) semente(s) pode(m) ser escolhida(s) pelo operador ou determinada(s) automaticamente. A seguir, a vizinhança de cada semente é inspecionada e os *pixels* semelhantes são adicionados à região da semente original, e assim, a região vai crescendo. O processo continua até que mais nenhum *pixel* possa ser acrescentado. É possível que alguns *pixels* possam permanecer sem rótulo, isto é, estarem isolados, quando pára o processo de crescimento (BANKMAN, 2000; WITHEY e KOLES, 2007).

Os resultados do *Region Growing* dependem da escolha do critério de homogeneidade. Se não for escolhido corretamente, as regiões escapam para áreas adjacentes e fundem-se com as regiões que não pertencem ao objeto de interesse. Outro problema desta técnica é que diferentes pontos de partida não podem crescer em regiões idênticas (MITCHELL *et al.*, 2002).

A vantagem da técnica de *Region Growing* é permitir a segmentação correta de regiões que têm as mesmas propriedades e estão espacialmente separadas, gerando ainda regiões conectadas entre si.

Os métodos de *Region Splitting* (divisão por regiões) têm uma estratégia oposta à do *Region Growing*. Estes métodos partem de toda a imagem e examinam os critérios de homogeneidade. Se os critérios não se encontram, a imagem (ou sub-imagem) é dividida em duas ou mais sub-imagens. Este processo termina quando todas as sub-imagens satisfazem os critérios de homogeneidade. Uma combinação de segmentação por *Region Splitting* e por *Region Growing* soma os benefícios de ambas as abordagens (WONG, 2005).

A segmentação por *watershed* (Método do Divisor de Águas) é uma técnica baseada em regiões que utiliza a morfologia da imagem (BANKMAN, 2000).

É necessário que se faça a seleção de pelo menos um marcador (semente) interior a cada objeto da imagem, incluindo tanto o fundo, como os objetos a segmentar. Usualmente, o utilizador é responsável pela seleção dos marcadores. Contudo, estes também podem ser selecionados por um

procedimento automático que considere conhecimentos específicos sobre os objetos.

A ideia básica do *watershed* é dada pela imagem da tradução em português do nome: um divisor de águas é uma cadeia de montanhas, que divide a água da chuva em regiões para onde ela escorre. O *watershed* utiliza os módulos dos gradientes, as variações locais de intensidade na imagem, como uma "topografia" montanhosa que separa regiões. Funde-se regiões aumentando a altura da água que "chove" na imagem. A grande vantagem deste método é a sua rapidez de processamento, permitindo que seja utilizado em aplicações interativas, mesmo quando as imagens a processar são grandes e complexas (WONG, 2005).

2.1.8 Algoritmos baseados em técnicas de *clustering*

A técnica de *clustering* é amplamente utilizada em antropologia, arqueologia, psiquiatria, zoologia, entre outras, sendo ainda a mais popular na segmentação de imagens médicas. O *clustering* é o processo de agrupamento de objetos semelhantes num único *cluster* (grupo), enquanto objetos com características semelhantes são agrupados em diferentes grupos com base em critérios de semelhança. A similaridade é quantificada em termos de uma medida de distância adequada. Uma medida de semelhança óbvia é a distância entre dois vetores no espaço (BANKMAN, 2000).

Cada *cluster* é representado pelo seu centróide (ou média) e variância, que indica a densidade dos objetos dentro do *cluster*, e sua formação é otimizada de acordo com uma função de custo que normalmente leva em consideração a semelhança dentro de cada *cluster*, e a dissimilaridade entre eles (BANKMAN, 2000).

A literatura propõe várias técnicas de agrupamento (BANKMAN, 2000; WONG, 2005; WITHEY e KOLES, 2007; McINERNEY e TERZOPOULOS, 1996). Este tipo de algoritmo pode ser dividido em: algoritmos de classificação supervisionados e algoritmos de classificação não-supervisionados.

As técnicas supervisionadas são: *k-nearest neighbor* (kNN) (VROOMAN *et al.*, 2006), *maximum likelihood (ML) algorithms* (SARTI *et al.*, 2005), *supervised artificial neural networks (ANN)* (JAMES, 1985), *support vector machines (SVM)* (JAMES, 1985), *active shape models (ASM)* (JAMES, 1985) e *active appearance models (AAM)*.

As não supervisionadas são: *CM algorithms fuzzy C-means (FCM)* (JACOBS *et al.*, 2000), *algorithms iterative self-organising data analysis technique algorithms (ISODATA)* e *unsupervised neural networks* (BANKMAN, 2000; MA, 2010).

Na aprendizagem supervisionada, fornece-se ao algoritmo uma resposta correta (saída) para

cada padrão de entrada. Os parâmetros do algoritmo são ajustados com o objetivo de permitir que sejam produzidas respostas tão próximas quanto possíveis das respostas corretas. Por outro lado, na aprendizagem não-supervisionada, não é necessária uma resposta correta associada com cada padrão de entrada no conjunto de dados avaliados. É explorada a estrutura subjacente aos dados, ou correlações entre padrões dos dados, organizando-os em categorias a partir destas correlações (MA, 2010).

2.1.8.1 Algoritmo *K-means*

O algoritmo de clusterização *K-means* poder ser também chamado de *K-médias*. Segundo Jain *et al.* (1999) o algoritmo *K-means* é popular por sua facilidade de implementação e sua ordem de complexidade $O(n)$, onde n é o número de padrões.

De acordo com Fontana e Naldi (2009), *K-means* utiliza o conceito de centróides como protótipos representativos dos grupos, onde o centróide representa o centro de um grupo, sendo calculado pela média de todos os objetos do grupo.

Para Pimentel *et al.*(2003) *K-means* é uma técnica que usa o algoritmo de agrupamento de dados por *K-médias* (*K-means clustering*). O objetivo deste algoritmo é encontrar a melhor divisão de P dados em K grupos C_i , $i = 1, \dots, K$, de maneira que a distância total entre os dados de um grupo e o seu respectivo centro, somada por todos os grupos, seja minimizada.

Jain *et al.* (1999) afirmam que, um dos maiores problemas do algoritmo *K-means* é a sensibilidade à seleção da partição inicial, e pode convergir a um mínimo local do valor da função de critério se a partição inicial não for devidamente escolhida.

O algoritmo *K-means* pode ser descrito pelos passos a seguir (Figuras 2.10, 2.11 e 2.12), de acordo com Fontana e Naldi (2009):

1. Atribuem-se valores iniciais para os protótipos seguindo algum critério, por exemplo, sorteio aleatório desses valores dentro dos limites de domínio de cada atributo;
2. Atribui-se cada objeto ao grupo cujo protótipo possua maior similaridade com o objeto;
3. Recalcula-se o valor do centróide (protótipo) de cada grupo, como sendo a média dos objetos atuais do grupo;
4. Repete-se os passos 2 e 3 até que os grupos se estabilizem.

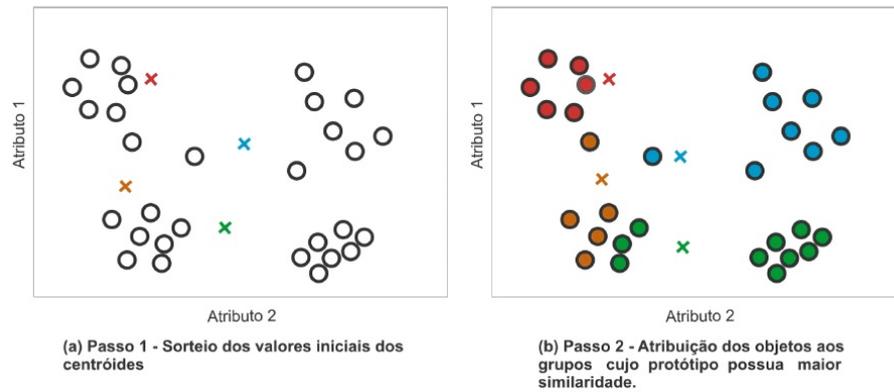


Figura 2.10: Exemplo do algoritmo *K-means*- parte 1
Fonte: Fonseca (2014)

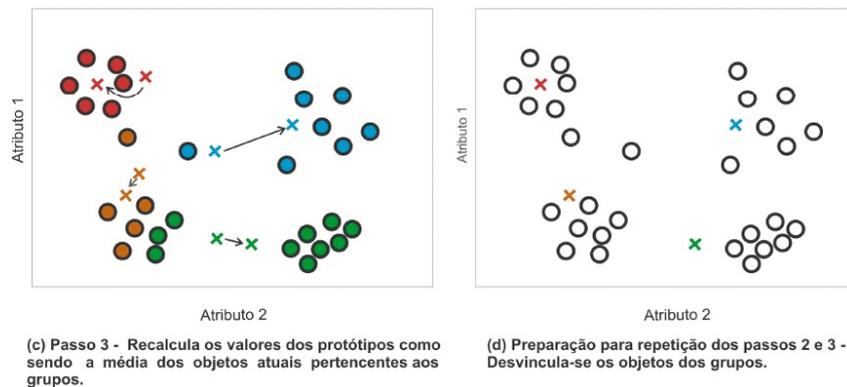


Figura 2.11: Exemplo do algoritmo *K-means*- parte 2
Fonte: Fonseca (2014)

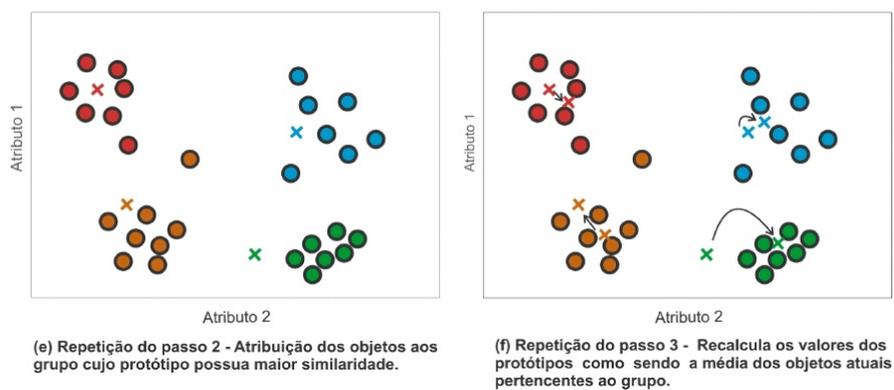


Figura 2.12: Exemplo do algoritmo *K-means* - parte 3
Fonte: Fonseca (2014)

2.1.9 Métodos baseados em contorno

Uma borda (ou contorno) é o limite ou fronteira entre duas regiões com propriedades relativamente distintas numa imagem. A sua detecção baseia-se na determinação dos pontos em que a intensidade muda repentinamente. Mudanças repentinas em imagens, geralmente refletem even-

tos importantes na cena, como a descontinuação da profundidade (transição entre a estrutura e o fundo), descontinuação da orientação de uma superfície, mudança das propriedades do material ou variações na iluminação da cena.

Os algoritmos baseados em contornos caracterizam-se, então, pela determinação do gradiente de intensidade (BANKMAN, 2000). Este gradiente, usado em vários algoritmos para detectar contornos em imagens, resulta da primeira derivada da função imagem.

Para Silva (2004), alguns dos algoritmos mais conhecidos e que se incluem nesta categoria são: de Prewitt, de Roberts, de Sobel, o Laplaciano e o de Canny .

O método de Canny difere dos outros filtros detectores de orlas porque usa dois *thresholds* diferentes (para detectar os contornos fortes e os fracos), e inclui as orlas mais leves no *output* (saída) apenas se estiverem ligadas às orlas principais. O método Canny é mais resistente ao ruído que os outros filtros, e é mais provável que detecte as verdadeiras orlas leves.

Este método procura por máximos locais no gradiente da imagem a analisar, sendo o gradiente obtido recorrendo à derivada de um filtro Gaussiano. Este filtro aceita como parâmetro de entrada um sigma, que representa o desvio padrão do filtro gaussiano, sendo o tamanho da matriz automaticamente calculado com base neste valor. O valor de *threshold* é automaticamente calculado pela função *edge* do *software* Matlab.

Os modelos de contornos ativos são técnicas que visam à extração das bordas dos objetos da cena. Estas técnicas se caracterizam pelo ajuste de uma curva (VSOLQH) sobre uma imagem definindo o contorno do objeto segmentado. Geralmente são aplicados conjuntamente com técnicas de filtragem para detecção de pontos de bordas. A inicialização é realizada com um contorno de configuração arbitrária que evolui até se ajustar ao objeto de interesse. Devido ao seu comportamento dinâmico, os contornos ativos são também conhecidos como “modelos deformáveis”. Para mais detalhes consultar os trabalhos de (LU; PLATANIOTIS e VENETSANOPOULOS, 2001 e GIRALDI; STRAUSS e OLIVEIRA, 2000).

2.1.10 Extração de características das imagens

A seguir, são apresentados os métodos mais comuns de formulação de consulta, de acordo com o tipo de informação a ser utilizada na caracterização do conteúdo da imagem (ZACHARY, 1999):

- Baseadas em atributos textuais: as informações textuais são normalmente obtidas com a análise de um especialista no domínio de conhecimento relacionado ao tipo de diagnóstico.

Apresenta alto índice de ambiguidade e é altamente dependente do conhecimento desse especialista.

- Baseadas em características pictóricas: consistem na extração de uma série de elementos gráficos que caracterizam o conteúdo da imagem. São exemplos: histograma, textura, descritores da forma, entre outros, exigindo a definição de uma semântica apropriada ao conjunto de informações ao domínio da aplicação (COLOMBO *et al.*, 1999).
- Baseadas em imagem-exemplo: consistem em utilizar uma imagem de referência para comparação com as imagens adquiridas.

O processo de extração das características das imagens permite relacionar de forma organizada as propriedades da imagem sobre os aspectos: forma, textura, distribuição de cores e relacionamento espacial, entre outros objetos presentes na imagem. Assim, a partir destas características, é possível indexar as imagens buscando a similaridade baseadas no seu conteúdo.

De forma mais ampla, esta indexação é associada ao reconhecimento de padrões pelo processo de segmentação (localização do objeto de forma isolada que está contido na imagem); extração (cálculo dos valores que descrevem propriedades quantitativas internas e externas); e classificação da imagem (como por exemplo, em relação aos tipos de exames que definem os objetos esperados).

2.2 RADIOTERAPIA

Convencionalmente, os tratamentos de radiação de feixe externo são entregues utilizando um acelerador linear, com um colimador multilâminas (MLC ou um formador de feixe) alojado na cabeça da unidade de tratamento (*gantry*) (ver figura 2.13 (a) e (b)). Este dispositivo pode girar 360 graus em uma direção e fazer várias paradas para irradiar raios-X. Várias formas bidimensionais do feixe podem ser construídas usando um computador controlando o MLC para conformar o feixe de radiação com a forma do tumor, a partir de qualquer ângulo dado. É possível determinar a quantidade ideal de irradiação para um conjunto fixo de ângulos (também chamado de campos) de tal forma que o plano de tratamento final pode fornecer uma dose letal de radiação para o alvo com a exposição à radiação mínima para os órgãos saudáveis.

As máquinas de tratamento, ou aceleradores lineares como são conhecidos, são dispositivos capazes de rodar em torno de um único eixo até 360°. A cama onde o paciente é posicionado também pode realizar esta revolução, e desta forma os feixes de radiação podem ser inseridos em qualquer região do enfermo. O ponto onde o feixe deve atacar é chamado na literatura de isocentro. Aparelhos modernos possuem o colimador, que pode conformar os feixes com elevado grau de precisão. Por exemplo, se a superfície alvo é convexa, então o colimador será ajustado para distribuir uma dose também convexa. Essas doses são chamadas de isodoses.

Uma abordagem de planejamento avançado de tratamento, conhecido como terapia de radiação de intensidade modulada (IMRT), permite flexibilidade significativa no fornecimento de radiação de cada ângulo de feixe. Em IMRT, um campo de radiação aberto é fracionado em centenas de subcampos chamados subfeixes (ou *beamlet*), ver Figura 2.13 (c). Para cada subfeixe é atribuído a sua própria intensidade, chamado de peso do subfeixe. Uma matriz de pesos dos subfeixes de cada feixe de orientação é muitas vezes referido como um mapa de fluência. Na figura 2.14 observa-se três configurações diferentes para um colimador multilâminas.

A abertura total do colimador é dividida em subcampos retangulares (chamados *bixels*) dispostos em um padrão $m \times n$, em que m é o número de lâminas e n representa a precisão de MLC, ou seja, número de paradas de uma lâmina (ver Figura 2.13 (c)).

É necessário saber a quantidade de radiação que o tumor, os órgãos de risco e os órgãos saudáveis estão recebendo. Para isso, é realizada uma discretização da imagem obtida na tomografia computadorizada (TC)(figura f2.15). A imagem digital é uma representação numérica de uma ima-

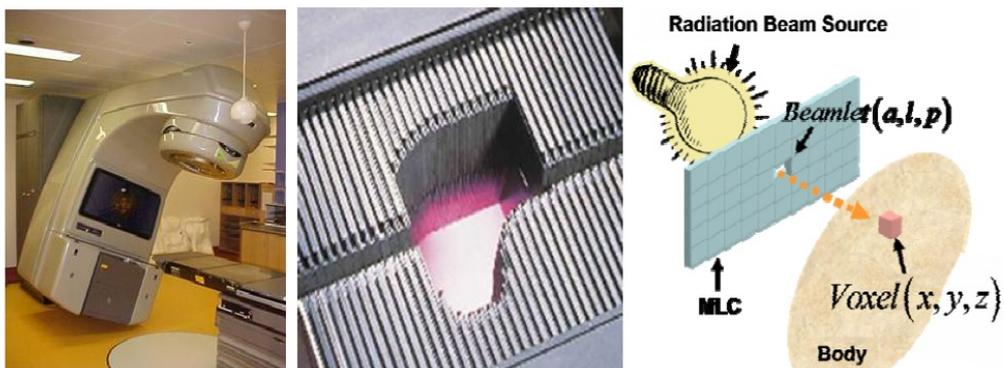


Figura 2.13: a) Acelerador linear b) Colimador multilâminas c) subfeixes
Fonte: Lim *et al.* (2007)

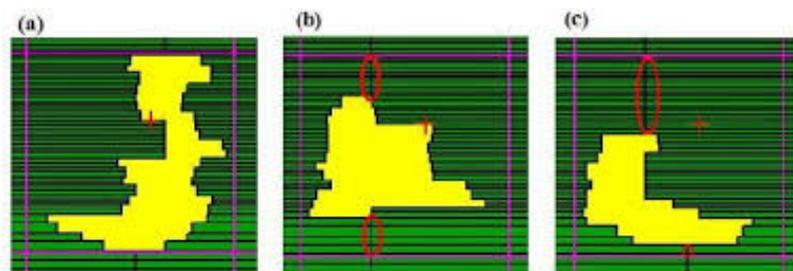


Figura 2.14: Colimador multilâminas: três configurações diferentes
Fonte: Liu *et al.* (2008)

gem real, ou seja, ao invés de átomos para formar a imagem, temos *pixels* e *voxels*. *Pixel* é o menor ponto bidimensional, enquanto *voxel* é o menor ponto tridimensional de uma imagem digital (figura 2.16).

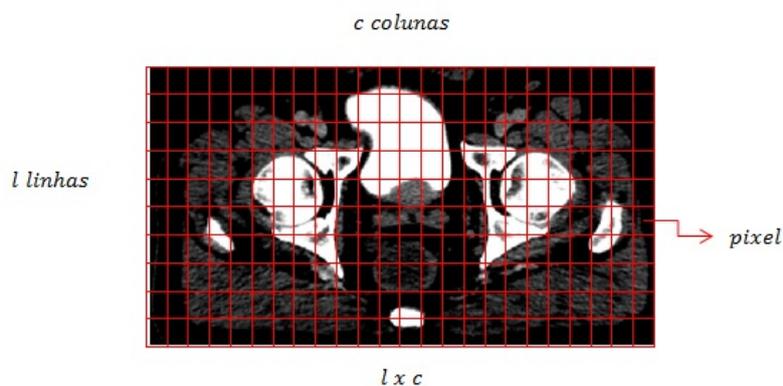


Figura 2.15: Exemplo de discretização da próstata com dimensão $l \times c$
Fonte: A autora

Segundo Wake *et al.* (2009) e Holder (2004), a efetividade no tratamento de radiação sobre regiões cancerígenas depende de muitos fatores, entre eles, a minimização do tempo total de trata-

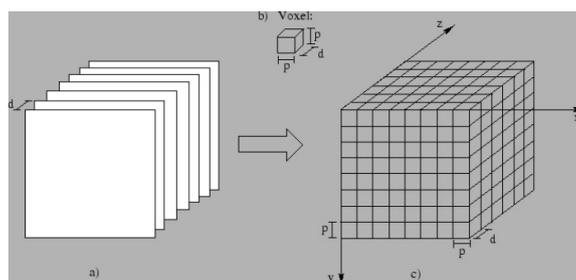


Figura 2.16: Representação de imagens utilizando *voxels*
 Fonte: Falcão (2008)

mento. Por sua vez, a duração do tratamento está relacionada com o tempo gasto reconfigurando os colimadores. Os colimadores são mecanismos ou sistemas contidos no *gantry* de controle, responsáveis pela modulação dos feixes de radiação de acordo com a forma do tumor a ser atingido. O colimador do IMRT, por exemplo, é controlado por válvulas de ar individuais (pneumaticamente) que fazem com que as folhas do colimador se abram ou se fechem em cerca de 30 a 40 milésimos de segundo.

2.2.1 *Gantry*

Segundo Ehr Gott *et al.* (2008), o planejamento ideal de um tratamento de radioterapia depende essencialmente da experiência do especialista médico. As seleções objetivas dos feixes de radiação podem amenizar o sofrimento no tratamento e, portanto, é primordial um estudo detalhado das variações angulares dos feixes que saem do *gantry*. A figura 2.17 ilustra os subfeixes que partem com certo ângulo “*a*” do *gantry* em relação à mesa e passam por uma anatomia que contém duas regiões/órgãos sensíveis e um alvo circular. Um dos grandes desafios da radioterapia está na seleção otimizada dos feixes que atingirão as células cancerígenas. Por sua vez, a escolha otimizada dos feixes, está relacionada com a variação angular do *gantry*. A figura 2.18 apresenta o *gantry* e uma configuração do colimador multilâminas.

2.2.2 Dose Absorvida

Como os efeitos químicos e biológicos da exposição de um tecido à radiação dependem da energia absorvida por esse tecido, e não da energia absorvida pelo ar, a dose absorvida é definida pela razão:

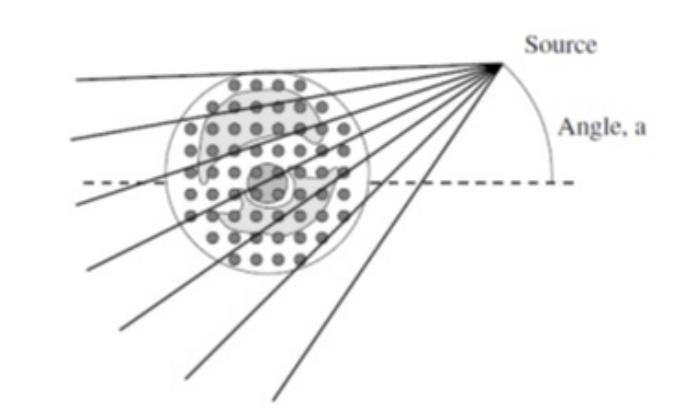


Figura 2.17: Subfeixes irradiados de um ângulo a do gantry
 Fonte: Ehr Gott *et al.* (2008)

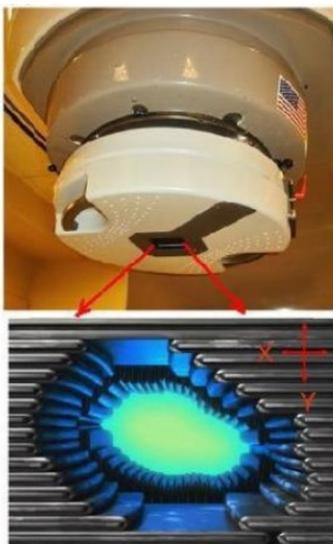


Figura 2.18: Gantry e colimador multilâminas
 Fonte: Liu *et al.* (2008)

$$D = \frac{E_{ef}}{V_m} \quad (2.6)$$

em que E_{ef} é a energia total que chega ao tecido diminuída de toda a energia que sai do acelerador, ou seja, a energia que efetivamente fica depositada no tecido. A sua unidade é o Gray (em SI), e V_m é o volume de ar de massa m sujeito a radiação.

A dose absorvida num tecido ou órgão é dada por:

$$D_t = \frac{\epsilon_t}{m_t} \quad (2.7)$$

em que ϵ_t é a energia total que atravessa um tecido ou órgão, e m_t é a massa do tecido ou órgão

irradiado.

Existe também a dose equivalente, que é o produto da dose absorvida por um fator de qualidade (FQ), que varia com a transferência linear de energia e que reflete o fato de diferentes radiações implicarem diferentes eficiências.

A dose efetiva é o produto entre a soma das doses equivalentes para cada tecido/órgão e os fatores de correção para o órgão.

Como os feixes de radiação ionizante nos aceleradores lineares são pulsados, é necessário monitorar constantemente esses feixes para garantir a eficácia do tratamento e segurança do paciente. Isto é feito utilizando duas câmaras de ionização localizadas no *gantry*. Ao ser depositada a dose desejada, essas câmaras comunicam ao sistema que a dose foi alcançada e o tratamento terminado. Assim, em radioterapia, é usado o termo unidade monitora (UM) associado à dose em cGy (centigrays) por meio de fatores de correção. É uma prática comum ajustar a calibração do acelerador linear de forma que uma unidade monitora seja equivalente a 1 cGy.

2.2.3 Composição de campos segundo ajuste do colimador

O plano de tratamento é individualizado para cada paciente de acordo com a localização do tumor. O número de campos e os ângulos de irradiação são variáveis. Além disso, a posição do tumor e a anatomia do paciente influenciam na intensidade de irradiação de cada ângulo de tratamento, pois o objetivo é a obtenção de uma solução de distribuição de dose homogênea. Estas intensidades, ou pesos dos feixes, são ajustadas manualmente em planejamento de radioterapia convencional, dependendo da profundidade do tumor, a partir de cada ângulo do feixe e da diferença nas densidades dos tecidos entre a superfície da anatomia e o tumor. O plano de tratamento conformal geralmente contém três ou quatro ângulos de abertura diferentes. No planejamento IMRT também é utilizada uma composição de campos para a obtenção da dose desejada.

Silveira *et al.* (2009) destaca (figura 2.19), uma composição de campos paralelos congruentes de largura 1 cm cobrindo uma região com o colimador ajustado a 0° , e nas figuras 2.20 e 2.21, mostra uma composição utilizando 5 campos diferentes.

2.2.4 Isocentro

O isocentro mecânico é a interseção do eixo de rotação do *gantry* com o eixo de rotação do colimador da unidade de tratamento, ou seja, é um ponto no espaço que depende do equipamento

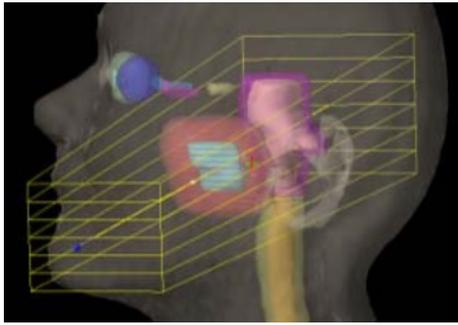


Figura 2.19: Colimador a 0 graus
Fonte: Silveira *et al.* (2009)

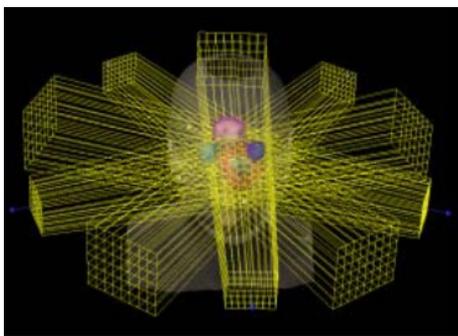


Figura 2.20: Composição de cinco campos
Fonte: Silveira *et al.* (2009)

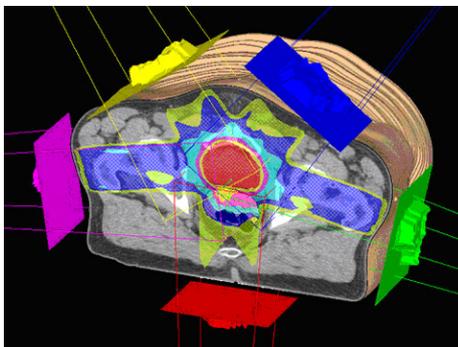


Figura 2.21: Região da próstata com 5 feixes de radiação
Fonte: Silveira *et al.* (2009)

envolvido.

Um acelerador linear é uma máquina isocêntrica, ou seja, que permite a irradiação segundo várias direções de incidência cujos eixos centrais se interceptam num mesmo ponto de espaço (isocentro), situado normalmente a 100 cm do foco do feixe. Também os outros movimentos possíveis (do colimador e da mesa) respeitam, segundo os eixos que lhes correspondem, a coincidência neste ponto (Fig. 2.22). Esta é a configuração básica dos aceleradores lineares operacionais até hoje.

É necessário definir um isocentro de radiação, que reside na marcação do ponto de referência

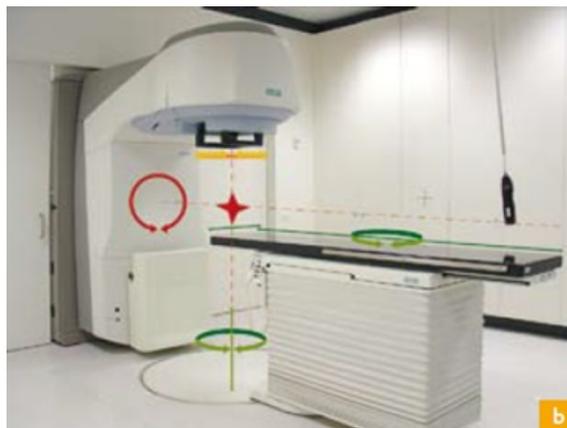


Figura 2.22: Movimento de rotação dos componentes (vermelho - gantry; amarelo - colimador; verde - mesa). No cruzamento dos eixos de rotação do gantry e do colimador encontra-se o isocentro (estrela vermelha)

Fonte: Lopes (2007)

para as direções dos feixes constantes no plano de tratamento. Em um dos cortes das imagens de TC é marcado um ponto de referência, o isocentro provisório, que possui coordenadas tridimensionais. Quando o físico inicia o processo de planejamento, poderá ser necessário efetuar um deslocamento, nos casos em que o ponto de referência da TC não coincide com o isocentro de tratamento. Em muitos trabalhos o isocentro de tratamento é considerado como o centro de massa do volume alvo que é, em geral, o tumor. Entretanto, não existem evidências que o centro de massa considerado como o isocentro seja a melhor estratégia (Holder e Salter, 2005).

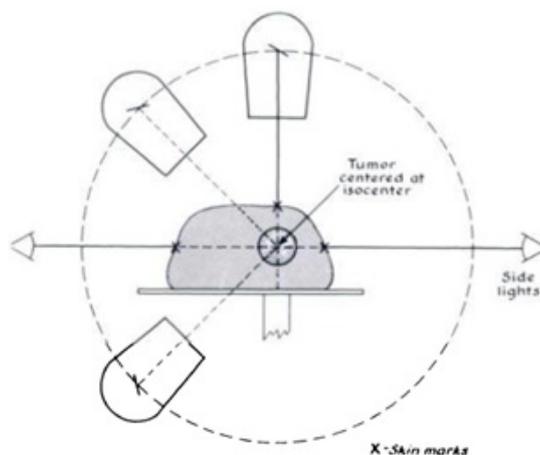


Figura 2.23: *Set-up* de tratamento mostrando o acelerador vertical para o posicionamento do paciente e ângulos para o tratamento. As luzes laterais e a marca lateral na pele são usadas para estabelecer a posição vertical do paciente.

Fonte: Carvalho (2009)

O posicionamento do paciente e a localização dos campos de tratamento são pontos cruciais no

processo da radioterapia. Deles depende a administração da dose no local correto e, consequentemente, o sucesso do tratamento. Assim, para cada tratamento, o paciente é deitado na mesa do Acelerador Linear e, posteriormente, é posicionado, alinhado e imobilizado, utilizando os mesmos acessórios e pontos de referência que foram usados quando da realização da Tomografia Computadorizada (TC), garantindo a reprodutibilidade do tratamento. O isocentro mecânico e o isocentro de radiação precisam ser posicionados em um mesmo ponto do espaço tridimensional (Figura 2.23).

2.3 REVISÃO DE LITERATURA

São apresentados nesta seção os trabalhos relacionados ao tema proposto com o objetivo de contextualizar o trabalho.

2.3.1 Segmentação da Região da Próstata

Abordagens de segmentação semi-automáticas e automáticas da região pélvica masculina e da próstata são descritos na literatura.

No ano de 2007, Pasquier propõe a avaliação tridimensional (3D) com uma abordagem de modelo deformável e um algoritmo *Region Growing* (sem sementes) para delineamento automático da próstata e órgãos de risco, respectivamente, em imagens de ressonância magnética. O delineamento manual e automático foram comparados em 24 pacientes usando uma sequência sagital ponderada em T2 (T2-w) *turbo spin echo* (TSE) e uma sequência axial T1 (T1-w) 3D *fast-field echo* (FFE). Para a avaliação quantitativa, os seguintes parâmetros foram utilizados: proporção em volume (V_r) (automático / manual), a sobreposição do volume (V_o) (relação do volume de intersecção com o volume de união; valor ideal=1), e o volume corretamente delineado (V_c) (razão percentual do volume de intersecção com o volume definido manualmente, valor ótimo=100). Os resultados para o CTV (clinical target volume), o V_r , V_o , e V_c foram 1,13 (desvio padrão de 0,1), 0,78 (desvio padrão de 0,05), e 94,75 (desvio padrão de 3,3), respectivamente. Para o reto, o V_r , V_o , e V_c foram de 0,97 (desvio padrão de 0,1), 0,78 (desvio padrão de 0,06), e 86,52 (desvio padrão de 5), respectivamente. Para bexiga, o V_r , V_o , e V_c foram de 0,95 (desvio padrão de 0,03), 0,88 (desvio padrão de 0,03), e 91,29 (desvio padrão de 3,1), respectivamente. Os resultados mostram que o método de modelo de órgãos é robusto, e resulta na reprodutibilidade da segmentação da próstata com baixas correções interativas. Para o delineamento automático de bexiga e reto as imagens de ressonância magnética com contraste de tecido mole permitem a utilização do método *Region Growing*.

Haas (2008) apresenta um projeto, algoritmos e validação de um novo software para a segmentação automática de imagens TC utilizados para o planejamento do tratamento de radioterapia. A abordagem consiste na pré-segmentação, orientação anatômica e estrutura de segmentação. Não se tem entrada do usuário ou informação *a priori* do conteúdo da imagem. Na etapa de pré-segmentação, o contorno do corpo, os ossos e tecido equivalente de pulmão são detectados. A orientação anatômica reconhece posição, orientação e o sexo do paciente e cria um mapeamento

elástico com as posições da seção para uma escala de referência. A segmentação de estrutura é dividida em localização, delineando requinte e realizada por procedimentos com conhecimento anatômico implícitos usando operações de processamento de imagem padrão. O software foi desenvolvido e testado em um conjunto de mais de 600 seções de TC para planejamento de radioterapia. Na validação quantitativa, foram considerados sete casos selecionados aleatoriamente e delineados manualmente comparando as estruturas delineadas automaticamente com estruturas segmentadas por especialistas em 2D e 3D. Os resultados indicam que a precisão dos algoritmos está dentro da largura de banda do manual de segmentação por especialistas, exceto em situações específicas. Apesar de revisão manual e correções de estruturas segmentadas automaticamente o que pode ser esperado que, devido à velocidade do software apresentado e a qualidade de seus resultados, a sua introdução no planejamento de tratamento de radioterapia levará a uma redução considerável de tempo comparado ao delineamento manual.

No ano de 2010, Feng *et al.*, apresentaram um método duplo: em primeiro lugar, uma combinação ponderada de gradiente e recursos da função de distribuição de probabilidade (PDF) é usada para construir o modelo de aparência para orientar o modelo de deformação. Os pontos fortes de cada tipo de recurso são enfatizados, ajustando dinamicamente o peso entre as características de gradiente baseados em perfil, e dos recursos PDF com base-local-região durante o processo de otimização. Um aspecto novo adicional dos recursos baseados em gradiente é que, para aliviar o efeito do recurso inconsistência nas regiões do gás e do osso adjacentes à próstata, o comprimento do perfil ideal de cada marco é calculado por meio da investigação estatística do perfil de intensidade no conjunto de treinamento. O recurso combinado gradiente-PDF resultante produz mais segmentações precisas e robustas do que as características gerais de gradiente. Em segundo, uma aprendizagem *on-line* é usada para construir estatísticas de forma e de aparência para capturar com precisão variações intrapacientes.

Chen *et al.* (2011) afirmam que uma segmentação automática da próstata e do reto, a partir de imagens de tomografia computadorizada (TC) 3D, ainda é um problema desafiador, e é crítico para aplicações de terapia guiada por imagem. Apresentam um novo algoritmo de segmentação, automático, com base em modelos de órgãos deformáveis construído a partir de dados de treinamento (regiões segmentadas anteriormente por algum método ou pelo dosimetrista). As principais contribuições deste trabalho são uma nova função de custo de segmentação baseado em uma estrutura bayesiana, que incorpora as restrições anatômicas dos ossos circundantes e um novo modelo

de aparência que aprende uma distribuição não-paramétrica da intensidade dentro e fora de histogramas de contornos de órgãos. Relatam os resultados de segmentação em 185 conjuntos de dados do local da próstata, o que demonstra melhora no desempenho em relação aos modelos anteriores.

No trabalho de Shi *et al.* (2013), um método de segmentação semi-automático da próstata é apresentado. Especificamente, para o segmento na próstata na imagem de tratamento, o médico leva primeiro alguns segundos para especificar manualmente a primeira e a última fatia da próstata no espaço de imagem. Em seguida, a próstata é segmentada automaticamente pela proposta em duas etapas : 1) A primeira etapa é a estimativa de verossimilhança para prever a probabilidade de próstata para cada *voxel* na imagem atual do tratamento, com o objetivo de gerar um mapa de probabilidade da próstata em 3D pela proposta *Spatial-CONstrained Transductive Lasso (SCOTO)*; 2) A partir do planejamento e imagens anteriores do tratamento, a segunda etapa de multi-atlas, com base na fusão de rótulos, gera o resultado final. O resultado experimental demonstrou que o método proposto supera vários métodos *state-of-the-art* na segmentação de próstata em um conjunto de dados TC da próstata real composta por 24 pacientes com 330 imagens. Além disso, é também clinicamente viável, pois o método exige apenas o médico para passar alguns segundos sobre a especificação manual das primeiras e últimas seções da próstata.

Schulz (2014) propõe uma abordagem intuitiva para modelagem 3D da próstata por seções transversais elípticas empilhadas para facilitar o processo de delimitação (MBFE). O método se enquadra na categoria de malhas deformáveis e refere-se à parametrização geométrica, onde o foco é o desenvolvimento de um modelo estatístico para segmentação da próstata. Um banco de dados com um conjunto de treinamento de 23 pacientes foi usado para calcular resultados do modelo. Resultados adicionais mostram uma melhoria moderada dos resultados MBFE após o método de Monte Carlo via Cadeias de Markov (MCMC). Os resultados enfatizam o potencial do método proposto de modelar a próstata por montagem de elipses, mostra a robustez e a reprodutibilidade do modelo.

Uma estratégia automática de segmentação da próstata foi apresentada por Jimenéz (2014) na qual seleciona as próstatas mais similares em comparação com uma imagem de ressonância magnética de próstata e combina as delineações dessas imagens para estimar a delineação da imagem teste. Uma análise multiescala robusta permite estabelecer e definir o conjunto das próstatas mais parecidas com a base de dados, independente do protocolo de aquisição. As imagens selecionadas são registradas de forma não rígida com respeito a imagem de teste e depois são fundidas medi-

ante uma combinação linear. O enfoque proposto foi avaliado utilizando um conjunto público de imagens de ressonância magnética de pacientes com hiperplasia benigna ou câncer, com diferentes protocolos de aquisição, isto é, 26 externas e 24 endoretais. Este trabalho foi avaliado sob um esquema *leave-one-out*, cujos resultados mostraram segmentações confiáveis, obtendo DSC (métrica de medição de dados) média de 79% quando comparados a resultados obtidos com as delimitações manuais de especialistas.

Qiu *et al.* (2014) propõe uma nova abordagem baseada na otimização global para segmentação 3D da próstata utilizando ultra-som transretal (TRUS) e imagens de ressonância magnética (RM) ponderadas em T2, reforçando a simetria axial inerente das formas da próstata para ajustar uma série de segmentação em corte 2D em um sentido 3D "global". Mostra que o problema de otimização combinatória é desafiador e pode ser resolvido globalmente e exatamente por meio de relaxamento convexo. Neste contexto, propôs um novo modelo de fluxo contínuo coerente (CCMFM), que deriva um novo algoritmo eficiente baseado em dualidade, levando a uma implementação baseada em GPU para alcançar altas velocidades computacionais. Experimentos com 25 imagens 3D TRUS e 30 3D T2 imagens de RM do conjunto de dados e 50 imagens 3D T2 MR de uma base de dados público, demonstram que a abordagem proposta pode segmentar uma próstata 3D TRUS MR dentro de 5 - 6 segundos incluindo 4 - 5 segundos para inicialização e resultando em um DSC médio de $93,2\% \pm 2,0\%$ para imagens 3D TRUS e $88,5\% \pm 3,5\%$ para imagens 3D MR. O método proposto também produz variabilidade intra e inter-observador introduzida pela inicialização manual, sugerindo alta reprodutibilidade, independente dos observadores.

2.3.2 Segmentação de imagens: *Region Growing*

Abordagens de segmentação de imagens utilizando o método *Region Growing* são descritos na literatura em diversas áreas do conhecimento pois oferece várias vantagens sobre as técnicas de segmentação convencionais. Ao contrário dos métodos gradiente e laplaciano, as fronteiras das regiões encontradas por *Region growing* são perfeitamente finas (já que só adicionam-se *pixels* ao exterior da região) e conectados. O algoritmo é também muito estável em relação ao ruído.

Tonnies (2002) apresenta uma abordagem do crescimento da região adaptativa podendo ser estendida a um método de segmentação completamente automático e completo de imagens médicas. Nesse caso, os *pixels* são selecionados como pontos sementes que têm o menor comprimento de gradiente e que ainda não fazem parte de uma região de imagem segmentada. Usando o menor

valor de gradiente como ponto de semente inicial, pode-se ter certeza de que o ponto semente está sempre dentro de uma região, porque a variação dos valores de cinza dentro das regiões é assumida como menor do que a variação entre regiões. As regiões sobrepostas não são permitidas durante o processo. Em comparação com a segmentação manual obteve $1,09\% \pm 0,06\%$ para o erro médio, $3,62\% \pm 0,34\%$ para a distância Hausdorff, $1,46\% \pm 0,30\%$ para a porcentagem dos *pixels* super segmentados e $5,66\% \pm 0,71\%$ para a porcentagem dos *pixels* não segmentados pelo método proposto. A robustez do método para um modelo simples de homogeneidade obteve bons resultados em muitos testes.

Para Anastácio *et al.* (2014) o câncer de fígado é considerado de alta complexidade para ser detectado e tratado. Dessa forma, é proposto um sistema de auxílio ao diagnóstico para segmentação e volumetria hepática, a partir de imagens de Tomografia Computadorizada (TC) da região abdominal. Foram utilizadas 882 imagens de TC no padrão DICOM, que correspondem a cinco exames. Para realizar a segmentação é utilizado o algoritmo de crescimento de região (*Region Growing*) com uma técnica de lançamento automático de semente, baseada em centróide. Também foi solicitado a um especialista que realizasse a segmentação manual destas mesmas imagens para que fosse realizada a comparação com a segmentação automática. O resultado do método proposto foi de 81,13% em média das taxas de acerto comparando entre o volume manual e o automático, a média do Erro Quadrático Médio (EQM) encontrado foi de $17,34 \text{ cm}^3$. A melhor taxa de acerto encontrada foi de 99,06% com EQM de $0,41 \text{ cm}^3$, e o pior resultado para taxa de acerto foi 55,54% com EQM de $53,93 \text{ cm}^3$. Considerando que a média do volume do fígado segmentado manualmente é de $1588,64 \text{ cm}^3$, é observado que a média do EQM representa 1,1% deste volume, porém são necessárias algumas correções no algoritmo para alcançar um volume hepático mais fidedigno e um erro menor.

2.3.3 Pixel Semente

Feng *et al.* (2005) propuseram uma abordagem para a seleção automática de sementes utilizando uma rede neural competitiva. Em uma abordagem proposta por Shan *et al.* (2008), os pontos de semente são automaticamente selecionados com base em características textural e espacial. Malek *et al.* (2010) propuseram um método baseado em operações morfológicas, no qual os máximos regionais e locais são empregados na determinação do ponto de semente inicial. Yashpal e Gokhale (2012) propuseram um algoritmo no qual as sementes iniciais são determinadas usando

a propriedade sem borda e suavidade do *pixel* da imagem. Se o *pixel* não está na borda e tem alta similaridade com seus vizinhos, então ele é alocado como um *pixel* semente. A mesma abordagem é também aplicada por Mundhada *et al.* (2014) para a segmentação de imagem colorida.

Saad *et al.* (2012) aplicaram a técnica de limiar de histograma para automatizar o processo de seleção de sementes. Meenalosini *et al.* (2012) usam uma abordagem baseada em histograma, na qual a análise do histograma é feita para calcular o ponto semente inicial.

Gu *et al.* (2013) apresenta uma abordagem de segmentação de conjunto de um único clique (SCES) baseada no algoritmo existente *Click & Grow*. O novo algoritmo faz uso do algoritmo original usando um ponto semente original para definir uma área, dentro do qual múltiplos pontos sementes são gerados automaticamente. Uma segmentação conjunto pode ser obtida a partir das múltiplas regiões que foram obtidas. Foi avaliado um conjunto de 129 imagens de tumor pulmonar de TC utilizando um índice de similaridade (SI). A média de SI está acima de 93%, utilizando 20 diferentes sementes iniciais, mostrando estabilidade. A média de SI para 2 especialistas diferentes foi de 79,53 %. O algoritmo SCES comparado com os dois especialistas, o algoritmo de *level set* e o algoritmo de *skeleton graph cut* obtendo uma média de SI de 78,29%, 77,72%, 63,77% e 63,76%, respectivamente. Pode-se concluir que o algoritmo de segmentação de lesão pulmonar, desenvolvido recentemente, é estável, preciso e automatizado.

Yuvaraj e Ragupathy (2013) propuseram uma abordagem baseada em características, na qual as características estatísticas são extraídas nas várias regiões selecionadas. Se os recursos extraídos coincidem com os recursos pré definidos, então um ponto de semente é fixado nessa região. Este algoritmo é robusto contra o ruído, mas será difícil e demorado predefinir os recursos.

Singh e Singh (2013) propuseram uma abordagem de extração regional, que inclui dividir a imagem em regiões de interesse (ROI) e extrair os pontos de semente como o centróide de cada ROI. Esse método falha para fornecer bons resultados, quando o primeiro plano e plano de fundo são mesclados, e as regiões de interesse (ROI) não são derivadas eficientemente.

Segundo Kansal *et al.* (2015) o algoritmo de crescimento da região de semente é o método mais eficaz e robusto para a segmentação de imagens, mas a escolha dos pontos semente é a principal preocupação para este algoritmo, de modo a conseguir uma segmentação de imagem eficiente. Propõe um algoritmo para seleção automática de sementes, que depende completamente da informação da imagem. O algoritmo proposto calcula os pontos de sementes com base na frequência de ocorrência na imagem, e posteriormente os funde para obter pontos de semente adequados, evitando assim a

super segmentação. Além disso, utilizando estes pontos de semente, um algoritmo de crescimento de região é implementado para conseguir a segmentação de imagem. O algoritmo proposto foi implementado no MATLAB e produziu bons resultados para a segmentação de imagens, podendo ser utilizado em futuras aplicações de reconhecimento de objetos. O algoritmo elimina o problema de sobre e sub-segmentação, e não requer nenhuma interferência humana.

Diante dos trabalhos expostos, observa-se a necessidade de estudos referentes a busca automática de *pixels* sementes para o método *Region Growing* para segmentação dos órgãos de interesse na região pélvica masculina. Com isso, a ênfase dessa tese é propor um algoritmo de busca desses *pixels* automaticamente para a segmentação dos ossos pélvicos, bexiga e reto.

Nos trabalhos descritos na literatura de imagens médicas e utilização do método *Region Growing* observa-se que apenas uma região de interesse é delimitada automaticamente. O diferencial deste trabalho é delinear as três estruturas de interesse para o planejamento de radioterapia de câncer de próstata de forma automática e concomitantemente.

Capítulo 3

Metodologia

A proposta do emprego de métodos de processamento digital de imagens (PDI), aliado a radio-terapia IMRT, podem auxiliar no saneamento do nível de subjetividade imposto pelo dosimetrista e clínico avaliador. Neste processo, o sistema de PDI pode ser usado para análise computacional das imagens da cavidade pélvica masculina, classificando-as e produzindo resultados baseados em suas informações de cor, forma e aspectos geométrico-morfológicos associados.

Para o desenvolvimento desta tese foram utilizadas 300 imagens (seções) correspondentes a dez exames de Tomografia Computadorizada da região pélvica masculina. As imagens foram coletadas no Hospital Erasto Gaertner, e adquiridas no tomógrafo da marca GE Medical Systems modelo HiSpeed e gravadas em formato DICOM.

As imagens utilizadas são de simetria axial inerente da forma de próstata, ajustando uma série de segmentações de seções de 2D em um sentido 3D global.

Utilizou-se o *software* MATLAB para o desenvolvimento de algoritmo de segmentação proposto. O MATLAB é um sistema interativo e uma linguagem de programação para computação técnica e científica em geral. Ele integra a capacidade de fazer cálculos, visualização gráfica e programação em um ambiente fácil de usar, em que os problemas e as soluções são expressos em uma linguagem matemática familiar. O elemento de dados básico é uma matriz que não requer dimensionamento. Isso permite solucionar muitos problemas computacionais, principalmente os que envolvem formulações matriciais ou vetoriais, em uma fração do tempo que seria necessário para escrever um programa em uma linguagem como C ou FORTRAN (NEVES, 2001).

O contorno manual foi considerado a referência para comparação, mas não pode ser considerado a perfeita "verdade absoluta" por causa da variabilidade entre os dosimetristas (observadores).

Foram utilizadas as mesmas imagens para os delineamentos manuais e automáticos nos 10 pacientes com câncer de próstata.

A aquisição das imagens, o pré-processamento, a extração do *pixel* semente, filtragem, delineamento, as regiões a serem segmentadas da região pélvica, o tempo de delineamento pelo dosimetrista e o pós processamento das imagens são as fases no processo de segmentação final.

3.1 PRÉ-PROCESSAMENTO

Embora o *voxel* do TC utilize 12-bit na escala de cinza ($2^{12} = 4096$ tons), os monitores e as impressoras utilizam 8 bits ($2^8 = 256$). Com isso, cada seção é submetida ao processo de janelamento. As informações necessárias para realizar o janelamento são lidas nas *tags* DICOM 0028-1050 e 0028-1051, contidas nas imagens, que correspondem aos valores de centro da janela (*WC*) e do tamanho (largura) da janela (*WS*), respectivamente, para que então se calcule o valor de cada *pixel* da seção conforme a Equação 3.1.

$$PxOut = \begin{cases} WC - (\frac{WS}{2}), & se \quad PxIn \leq (WC - \frac{WS}{2}) \\ WC + (\frac{WS}{2}), & se \quad PxIn \geq (WC + \frac{WS}{2}) \\ PxIn, & caso \quad contrario. \end{cases} \quad (3.1)$$

onde *PxOut* é o valor do *pixel* de saída, *PxIn* o valor do *pixel* de entrada, *WC* o valor do centro da janela, *WS* o valor do tamanho da janela.

Em sequência, as imagens são recortadas conforme a anatomia do paciente. O tamanho da imagem original é 512×512 *pixels* passando a ter um tamanho médio de 220×420 *pixels*. O conjunto de dados é pré-processado utilizando um filtro de mediana, conforme descrito na seção 2.1.3.

Operações de suavização são usadas para diminuir efeitos espúrios resultantes do processo de aquisição da imagem (ruídos, por exemplo). Várias técnicas podem ser definidas para esta finalidade. A técnica utilizada neste trabalho é a filtragem mediana. No entanto, observa-se que é comum derivar métodos a partir dessas técnicas para atingir objetivos específicos nesta categoria de imagens e a fim de permitir uma visualização mais adequada do efeito da técnica. Um exemplo típico de filtro passa-baixa não-linear é o filtro da mediana, que suaviza a imagem sem contudo diminuir

sua resolução.

No filtro da mediana, os pontos da vizinhança de (x,y) , dentro de uma janela na imagem, são ordenados e o valor mediano desta ordenação é tomado como novo valor para (x,y) . É uma técnica de suavização na qual cada *pixel* da imagem final é substituído pelo nível de cinza mediano em uma vizinhança do *pixel*. O nível mediano m de um conjunto de valores é tal que metade dos valores no conjunto são menores que m e a outra metade é constituída de valores maiores que m . Uma das vantagens desta técnica é a eliminação de ruídos aleatórios com o borramento mínimo das bordas que compõem os objetos representados na imagem.

As técnicas de realce de imagens produzem justamente o efeito contrário ao provocado pela suavização. Têm o objetivo de destacar bordas e detalhes procurados na imagem. Algumas das técnicas são executadas a partir do histograma da imagem, conforme já mencionado. Também é muito comum empregar o conceito matemático de diferenciação para o realce de imagens, visto que o objetivo é destacar as diferenças entre os *pixels* da imagem. A técnica utilizada é a equalização do histograma.

A obtenção de um histograma mais uniforme é a regra para o realce de contraste pela técnica de equalização. Vários métodos podem ser empregados para a redistribuição dos níveis de cinza dos *pixels* na imagem, de modo a espalhá-los ao longo da escala de cores utilizada. O método utilizado parte de conceitos estatísticos. Para descobrir o novo nível de cinza (q) de um *pixel* que possui um determinado valor k de nível de cinza são utilizadas as equações 3.2 e 3.3. Primeiro, encontra-se a quantidade ideal de *pixels* para cada valor de nível de cinza, de acordo com a escala de cores utilizada, conforme a equação 3.2. Em seguida, calcula-se o novo nível de cinza q , isto é, o valor para o qual os *pixels* do nível de cinza atual serão movidos.

$$I = \frac{n.m}{g} \quad (3.2)$$

$$q = \max \left\{ 0, \text{arred} \left(\frac{\sum_{j=0}^k n_j}{I} \right) - 1 \right\}, 0 \leq k \leq g \quad (3.3)$$

onde:

I - quantidade ideal de *pixels* em cada nível de cinza da escala usada

n - quantidade de linhas da imagem

m - quantidade de colunas da imagem

g - quantidade total de níveis de cinza da escala

q - novo nível de cinza procurado

n_j - quantidade de *pixels* no nível de cinza j

arred - indica o arredondamento do resultado obtido pela expressão que constitui seu argumento

A segmentação é uma fase de processamento e tem o objetivo de identificar as formas significativas de uma imagem a fim de fornecer informações para a sua interpretação. Em Gonzalez e Woods (2002) define-se a segmentação como "o processo que subdivide uma imagem em suas partes ou objetos constituintes".

É necessário considerar as regiões de interesse como tecidos nobres (reto, bexiga e cabeça de fêmur), tumor (próstata) e tecidos saudáveis (demais regiões). Essas regiões podem ser observadas na figura 3.1. A região do tumor é segmentada pelo médico e está fora do escopo desta tese.

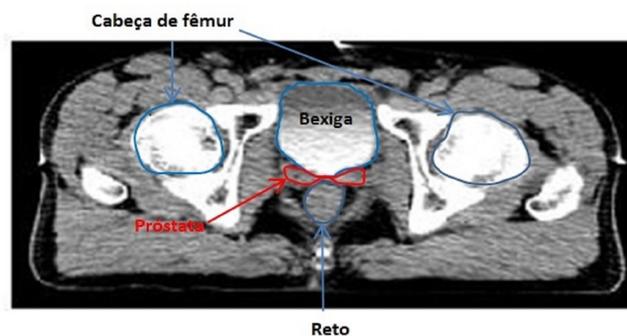


Figura 3.1: Regiões de interesse: tecidos nobres e tumor
Fonte: Volpi *et al.* (2013)

3.2 MÉTODO *REGION GROWING*

O algoritmo utilizado é o *Region Growing* que necessita da introdução de sementes e a definição de um intervalo que limita a propagação da região de interesse. A definição do intervalo é conhecida como *thresholding*, a limiarização é a técnica que divide a imagem em duas ou mais partes considerando valores limiares. Consiste, basicamente, em alterar os valores dos *pixels* de uma imagem deixando-a com uma quantidade menor de níveis com o objetivo de separar estruturas de interesse do fundo da imagem.

Tal como apresentado na seção 2.1.7, as abordagens de *Region Growing* operam em cada iteração sobre regiões fechadas, portanto no final da segmentação tem-se trivialmente regiões fechadas. Começando por uma única região (que pode ser um *pixel*), ou múltiplas regiões, estas regiões

crescem seguindo um critério de homogeneidade. As regiões iniciais, ponto de partida para a segmentação, são chamadas de semente e podem ser especificadas manualmente ou automaticamente seguindo uma determinada heurística (NUNES, 2008).

A característica principal de uma região extraída a partir de um histograma é que histogramas não oferecem informação espacial (apenas a distribuição de intensidades). *Region Growing* explora o fato que *pixels* que estão próximos têm valores semelhantes. O algoritmo base é simples:

- 1) Escolher o *pixel* semente;
- 2) Analisar os *pixels* vizinhos e adicioná-los à região se forem semelhantes à semente;
- 3) Repetir o passo 2 para cada *pixel* adicionado; parar se não existirem mais *pixel* para serem adicionados.

O algoritmo *Seeded Region Growing* de Adams e Bischof (1994) utiliza a abordagem de *Region Growing* com base numa propriedade estatística dos *pixels*, a média das intensidades. Uma lista ordenada mantém os *pixels* candidatos a adicionar às regiões. Os *pixels* são ordenados de acordo com uma métrica que mede a diferença do *pixel* candidato com a média de intensidades da região. Desta forma, tem-se uma região final homogênea.

A métrica de junção permite às sementes convergirem suavemente para regiões de intensidade semelhante, enquanto diminui a difusão de *pixels* com intensidades díspares, a taxa de difusão é regida apenas pelas características da imagem. O algoritmo de segmentação utilizado é baseado em Adams e Bischof (1994) mas foi adaptado de forma que apenas se extraia uma região no final de cada iteração.

Supondo que $V(t, x, y)$ representa a intensidade do *pixel* (t) na posição x, y . Dado as sementes escolhidas pelo utilizador, considerando que são n sementes e estão representadas da seguinte forma A_1, A_2, \dots, A_n que perfazem i conjuntos. Em cada iteração do algoritmo um *pixel* é adicionado a um conjunto A_i .

A dada altura do algoritmo, os *pixels* ainda não selecionados mas que são fronteira com as regiões, fazem parte do conjunto T que se define da seguinte forma:

$$T = \{x \notin \cup_{i=1}^n A_i \mid N(x) \cap \cup_{i=1}^n A_i \neq \emptyset\}$$

onde $N(x)$ é o conjunto dos vizinhos imediatos do *pixel* x (6 para grade hexagonal e 4 ou 8 para malha quadrada). Um único passo do algoritmo envolve examinar os vizinhos de cada $x \in T$ por

sua vez. Se $N(x)$ intercepta uma região A_j , então é calculada uma medida $\delta(x)$, da diferença (similaridade) entre x e a região interceptada. A função que mede a diferença dos *pixels* candidatos das n regiões é dada por:

$$\delta(x) = |g(x) - \text{mean}_{y \in A_i(x)}[g(y)]|$$

onde $g(x)$ é a intensidade de cinza do *pixel* x . Se $N(x)$ intercepta mais de uma região, então A_j é considerada a região para a qual $\delta(x)$ é um mínimo (alternativamente, o *pixel* x pode ser sinalizado como um *pixel* limite para fins de exibição). Dessa maneira, um valor δ é determinado para cada $x \in T$. Finalmente, o *pixel* $z \in T$ que satisfaça:

$$\delta(z) = \min_{x \in T} \{\delta(x)\}$$

é adicionado à região correspondente a $\delta(z)$. A nova região A_i constitui a entrada para a próxima iteração. O processo é repetido até que não existam mais *pixels* no conjunto T .

Em termos gerais o algoritmo é o seguinte:

Passo 1: Marcar as sementes de acordo com o seu conjunto inicial;

Passo 2: Colocar os vizinhos das sementes na lista ordenada T ;

Passo 3: Enquanto T não está vazia

x = remover o primeiro *pixel* de T

Testar os vizinhos de x

Se todos os vizinhos de x que já se encontram marcados são da mesma região

Adicionar x a esse conjunto

Recalcular a média de valores dessa região

Adicionar os vizinhos ainda não marcados de x a T e que respeitam o limite indicado pelo utilizador

Caso Contrário

Marcar x como fronteira

3.3 PROPOSTA DE ALGORITMO DE SELEÇÃO DE *PIXELS* SEMENTES - ABS

Para a segmentação automática da região pélvica masculina utilizando o método *Region Growing* é necessário a escolha dos *pixels* sementes, que é realizada observando a imagem e selecionando manualmente pontos na região de interesse que se quer segmentar. O objetivo é que esses pontos sejam escolhidos de forma automática, sem a interferência do observador. Para isso, é proposto um algoritmo de seleção de *pixels* sementes para a segmentação automática da região pélvica masculina, isto é, as regiões de ossos pélvicos direito e esquerdo, bexiga e reto, considerados tecidos nobres para a etapa de planejamento da radioterapia.

A seleção apropriada de sementes é a principal consideração em uma segmentação *Region Growing*. Os *pixels* sementes selecionados devem preencher os seguintes critérios:

- Os *pixels* semente devem ser altamente semelhantes aos seus *pixels* vizinhos;
- Pelo menos um *pixel* semente deve ser gerado para cada região de interesse da imagem;
- As sementes para regiões diferentes não devem ser conectadas (unidas por algum *pixel*).

Nas imagens de TC o profissional marca uma ou duas imagens que são chamadas de isocentro, consideradas como referências para o posicionamento do paciente quando receberá a dose de radiação na radioterapia e também no algoritmo como as imagens centrais. Utilizma-se 30 imagens para cada paciente, então, o isocentro ocupa a 15ª posição.

Esse processo é realizado seção por seção da TC de forma automática, sendo que a primeira parte deste algoritmo é a seleção da estrutura óssea, baseado no nível de cinza da escala de Hounsfield para o osso, posteriormente para a bexiga e reto. Para um dado paciente, o algoritmo para calcular os pontos de semente é o seguinte:

Passo 1: Ler as n imagens de TC.

Passo 2: Dividir cada imagem em 4×4 (16 quadrantes), proporcionais em relação à altura e a largura da imagem.

Passo 3: (*Área de Busca Semente (ABS) Fêmur*): A área de busca do *pixel* semente para fêmur esquerdo é reduzida apenas a porção central esquerda da seção de TC e a área de busca do *pixel* semente para fêmur direito é reduzida a porção central direita da seção de TC, pelo conhecimento *à priori* da região onde se localiza a cabeça de fêmur.

Fixe os *pixels* centrais que é a interseção da segunda linha e primeira coluna e segunda linha e quarta coluna para os fêmures esquerdo e direito, respectivamente. Partindo desses pontos centrais, definir a área de busca da semente (ABS) pelas coordenadas obtidas anteriormente, definindo uma área retangular, selecionando uma porcentagem de área nas quatro direções (direita, esquerda, superior e inferior).

Passo 4: (*Área de Busca Semente (ABS) Bexiga*): A área de busca do *pixel* semente para a bexiga é reduzida apenas a porção central superior da seção de TC, pelo conhecimento *à priori* da região onde se localiza a bexiga.

Fixe o *pixel* central que é a interseção da primeira linha e segunda coluna da imagem dividida. Partindo deste ponto central, definir a área de busca da semente (ABS) pelas coordenadas obtidas anteriormente, definindo uma área retangular, selecionando uma porcentagem de área nas quatro direções (direita, esquerda, superior e inferior).

Passo 5: (*Área de Busca Semente (ABS) Reto*): A área de busca do *pixel* semente para a reto é reduzida apenas a porção central inferior da seção de TC, pelo conhecimento *à priori* da região onde se localiza o reto.

Fixe o *pixel* central que é a interseção da terceira linha e segunda coluna da imagem dividida. Partindo deste ponto central, definir a área de busca da semente (ABS) pelas coordenadas obtidas anteriormente, definindo uma área retangular, selecionando uma porcentagem de área nas quatro direções (direita, esquerda, superior e inferior).

Passo 6: Compute os níveis de cinza presentes nas ABS's da seguinte forma:

Para o fêmur, se nível de cinza do *pixel* for maior que o nível de cinza 200, *pixel* recebe 255.

Para a bexiga, se nível de cinza do *pixel* for maior que 100 e menor do que 200, *pixel* recebe 255.

Para o reto, se nível de cinza do *pixel* for maior que 80 e menor do que 150, *pixel* recebe 255.

Caso contrário, recebe 0.

Passo 7: Crie uma lista mestre (LM) para cada região com os *pixels* que tenham nível de cinza 255 encontrados no passo 4.

Enquanto $LM \neq \emptyset$, $i = 1, 2, \dots, n$ para fêmur e reto e $i = 1, 2, \dots, \frac{n}{2}$ para bexiga:

Se o *pixel* da imagem i coincide com o *pixel* da imagem $i + 1$, armazene as coordenadas

do *pixel* na LM.

Caso contrário, exclua o *pixel* da LM.

Passo 8: Calcule a média das coordenadas dos *pixels* da LM, e esse será o *pixel* semente para cada região.

Observa-se na figura 3.2 o fluxograma descrevendo o algoritmo proposto.

Portanto, os *pixels* sementes obtidos no algoritmo ABS proposto são utilizados no algoritmo *Region Growing* para a segmentação da imagem, como apresentado na figura 3.3.

Na tabela 3.1 observa-se a comparação das fases de delineamento com e sem a utilização do algoritmo proposto. A aquisição das imagens, a extração do *pixel* semente, filtragem, delineamento, as regiões a serem segmentadas da região pélvica, o tempo de delineamento pelo dosimetrista e o pós processamento das imagens são as fases no processo de segmentação final. Na fase de pós processamento, os dosimetristas suavizam as curvas delimitadas pelo programa ou segmentam manualmente as regiões. No algoritmo proposto essa fase não foi abordada.

Tabela 3.1: Comparativo Algoritmo Proposto

Fases	Dosimetrista	Com algoritmo
Aquisição de imagens	DICOM	DICOM
Extração do Semente	Manualmente	Algoritmo ABS
Filtragem	Sem filtro/escolha manual	Filtro Mediana 2D
Delineamento	Manualmente/Software	<i>Region Growing</i>
Regiões	Segmentadas uma a uma	3 regiões delineadas automaticamente
Tempo	30 minutos	1 minuto
Pós processamento	Sim	Não

Nos trabalhos descritos na literatura (seção 2.3.2) de imagens médicas e utilização do método *Region Growing*, observa-se a necessidade de estudos referentes a busca automática de *pixels* se-

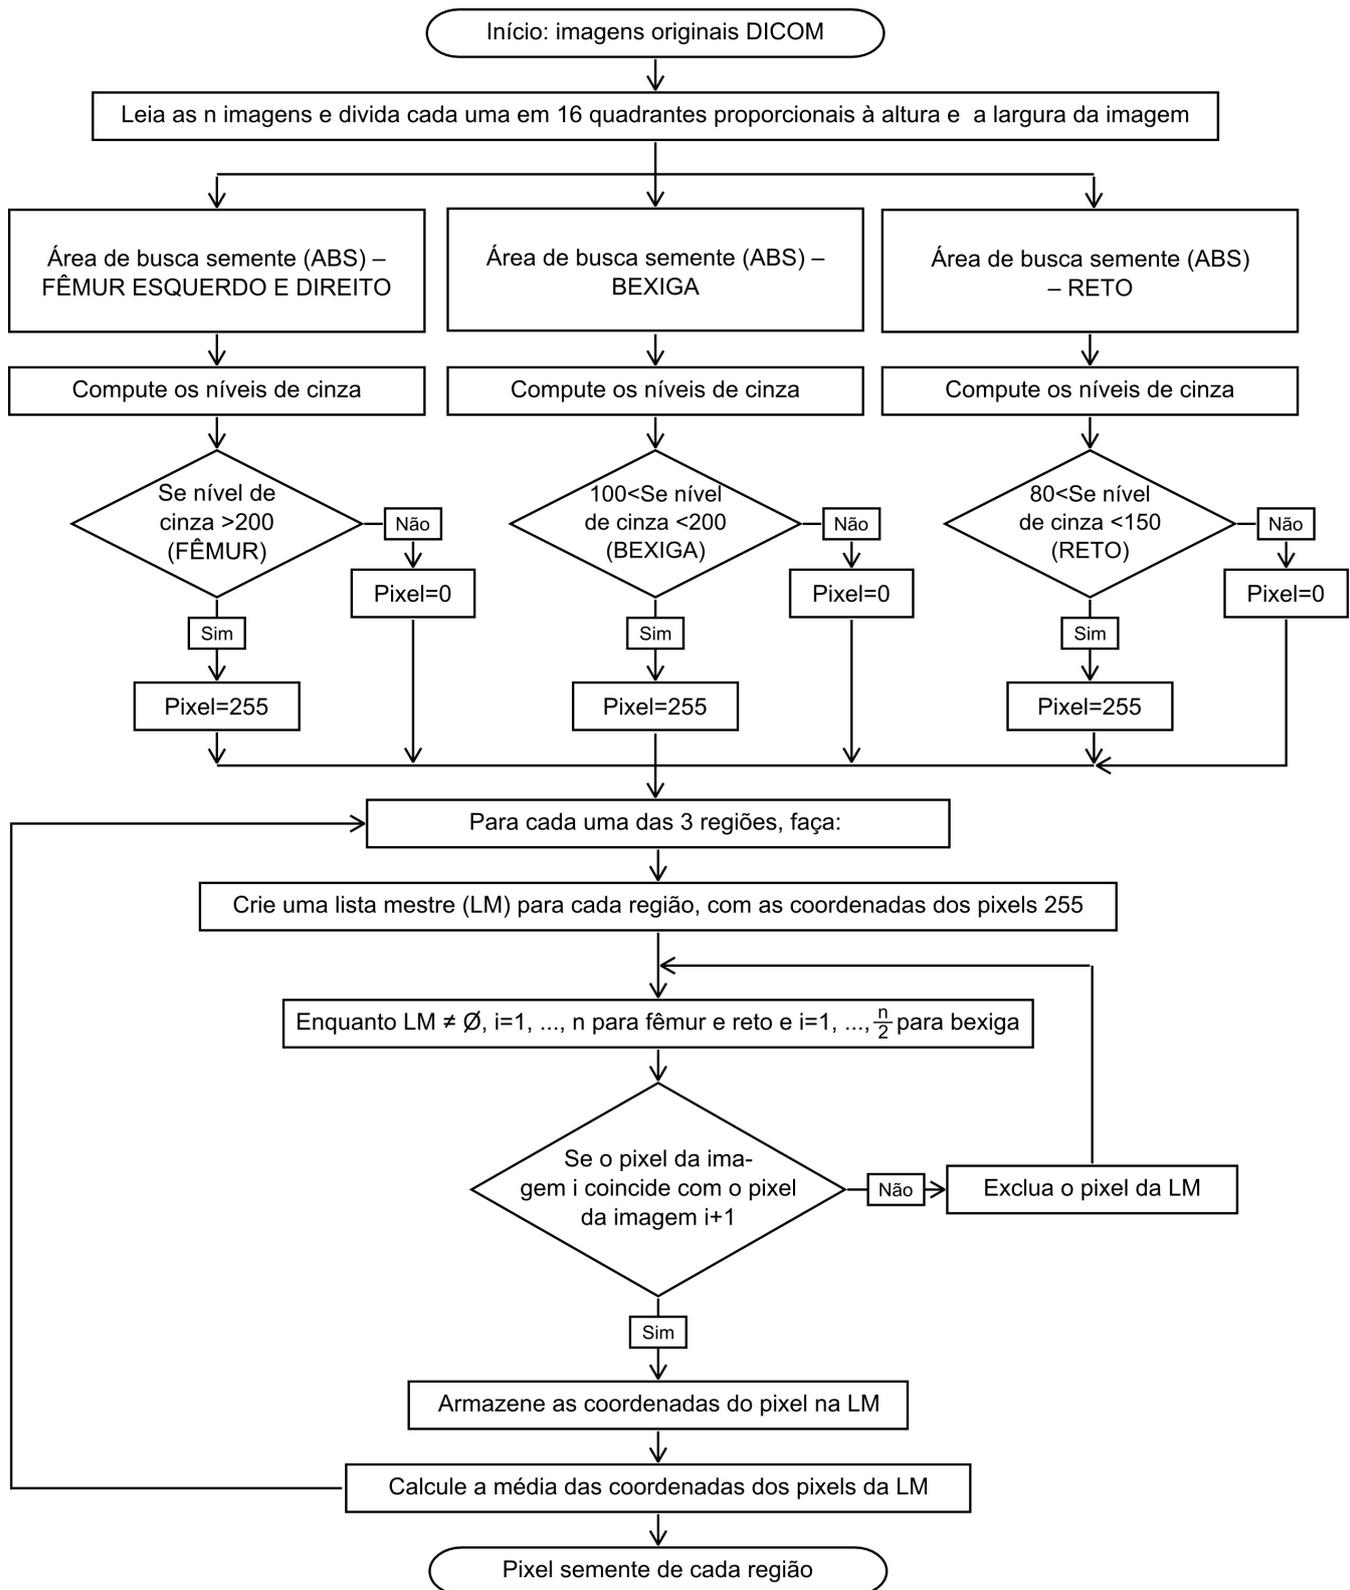


Figura 3.2: Fluxograma Algoritmo ABS

mentos no método *Region Growing* para segmentação dos órgãos de interesse na região pélvica masculina e que nestes estudos apenas uma região é delimitada automaticamente. A ênfase dessa

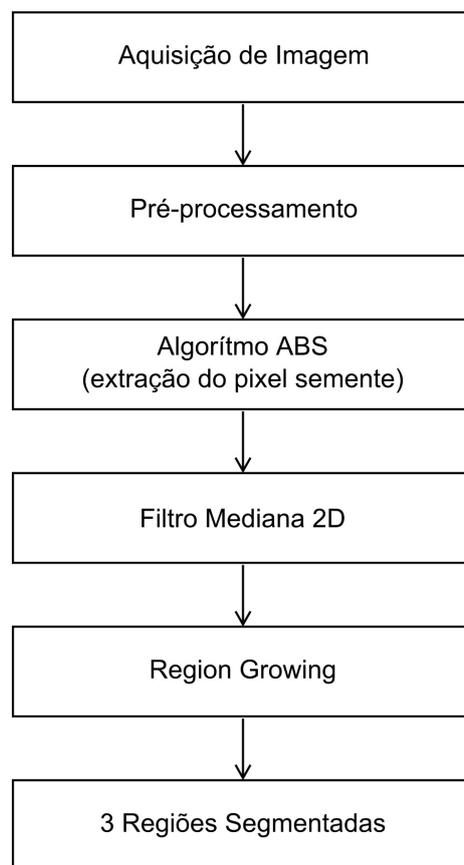


Figura 3.3: Algoritmo Proposto - Segmentação Região Pélvica Masculina

tese é propor um algoritmo de busca desses *pixels* automaticamente e concomitantemente para a segmentação das três regiões de maior interesse (cabeças femorais, bexiga e reto) para o planejamento de radioterapia de câncer de próstata.

3.4 MÉTRICAS

A métrica de erro de área foi utilizada para avaliar o desempenho da abordagem de segmentação proposta. A métrica de erro de área inclui a razão verdadeiro positivo (TPR) (equação 3.4), a razão falso positivo (FPR)(equação 3.5) e a relação de similaridade (SI) (equação 3.6).

$$TPR_{m,a} = \frac{|A_m \cap A_a|}{|A_m|} \quad (3.4)$$

$$FPR_{m,a} = \frac{|(A_m \cup A_a) - A_m|}{|A_m|} \quad (3.5)$$

A fórmula do índice de similaridade:

$$SI_{m,a} = \frac{|A_m \cap A_a|}{|A_m \cup A_a|} \quad (3.6)$$

foi utilizada para avaliar a segmentação tumoral, na qual, A_m é o conjunto de *pixels* da área delimitada manualmente pelo dosimetrista e A_a é o conjunto de *pixels* da área gerada pelo método ABS proposto. A segmentação automática do algoritmo proposto foi testado na região pélvica masculina, que continha 10 pacientes no total. Selecionou-se 30 imagens de cada paciente, totalizando 300 imagens para o conjunto de dados, pois esses casos requerem muitas interações humanas (incluindo vários cliques e edição manual).

O cálculo da área é realizado pela soma dos *pixels* com valor de intensidade de níveis de cinza diferentes de zero nas imagens segmentadas e então, considerando os valores presentes no cabeçalho DICOM, em "*Pixel Spacing*" referente ao tamanho do pixel (em milímetros). Assim é obtida a área em milímetros quadrados (mm^2). Para fins de comparação com a literatura a área é convertida para centímetros quadrados (cm^2). A equação 3.7 representa o cálculo da área, onde *ImSeg* refere-se à imagem da região segmentada, *PS* se refere ao "*Pixel Spacing*", *l* o número de linhas da imagem e *m* o número de colunas da imagem.

$$Area = \frac{\sum_{i=0}^l \sum_{j=0}^m (ImSeg(i, j) * PS)}{100} \quad (3.7)$$

Para ter um padrão de comparação, é utilizada a segmentação manual de um especialista no mesmo conjunto de imagens, mas não pode ser considerado a perfeita "verdade absoluta" por causa da variabilidade entre os dosimetristas (observadores).

Capítulo 4

Resultados e Discussões

A tese apresenta uma metodologia para localizar automaticamente as estruturas da região pélvica masculina a partir de uma imagem de tomografia computadorizada (TC), tarefa complexa devido a diversos aspectos discutidos no texto, dentre os quais está a baixa qualidade das imagens. Para o desenvolvimento e obtenção dos resultados, diversos testes foram realizados com o intuito de avaliar o método ou escolher procedimentos complementares. Dentre esses procedimentos pode-se citar a métrica de erro, que incluem a razão verdadeiro positivo (TPR), a razão falso positivo (FPR) e a relação de similaridade (SI) entre as áreas delineadas pelo dosimetrista e pelo método proposto. Os resultados preliminares foram apresentados por Gevert *et al.* (2014) e o respectivo artigo está anexado no Apêndice A.

Neste capítulo serão apresentados e discutidos os testes realizados com a metodologia proposta. Ao longo dos testes foi utilizado um conjunto de 300 imagens de TC, considerando 10 pacientes com 30 imagens bidimensionais. As imagens iniciais tinham 512×512 *pixels*, mas foram recortadas para que se aproximasse da anatomia de cada paciente. A figura (4.1) mostra um seção axial de tomografia de um paciente.

As figuras (4.2) e (4.3) apresentam o conjunto de imagens utilizadas nos testes. A apresentação dessas imagens junto ao texto, embora em uma resolução menor, serve para que o leitor perceba algumas peculiaridades e diferenças visuais entre elas. As imagens foram cedidas pela equipe do Hospital Erasto Gaertner (Curitiba-PR), com projeto aprovado pelo comitê de ética na pesquisa, adquiridas no tomógrafo da marca GE Medical Systems modelo HiSpeed e gravadas em formato DICOM.



Figura 4.1: Imagem da TC região da próstata
Fonte: Hospital Erasto Gaertner (2016)

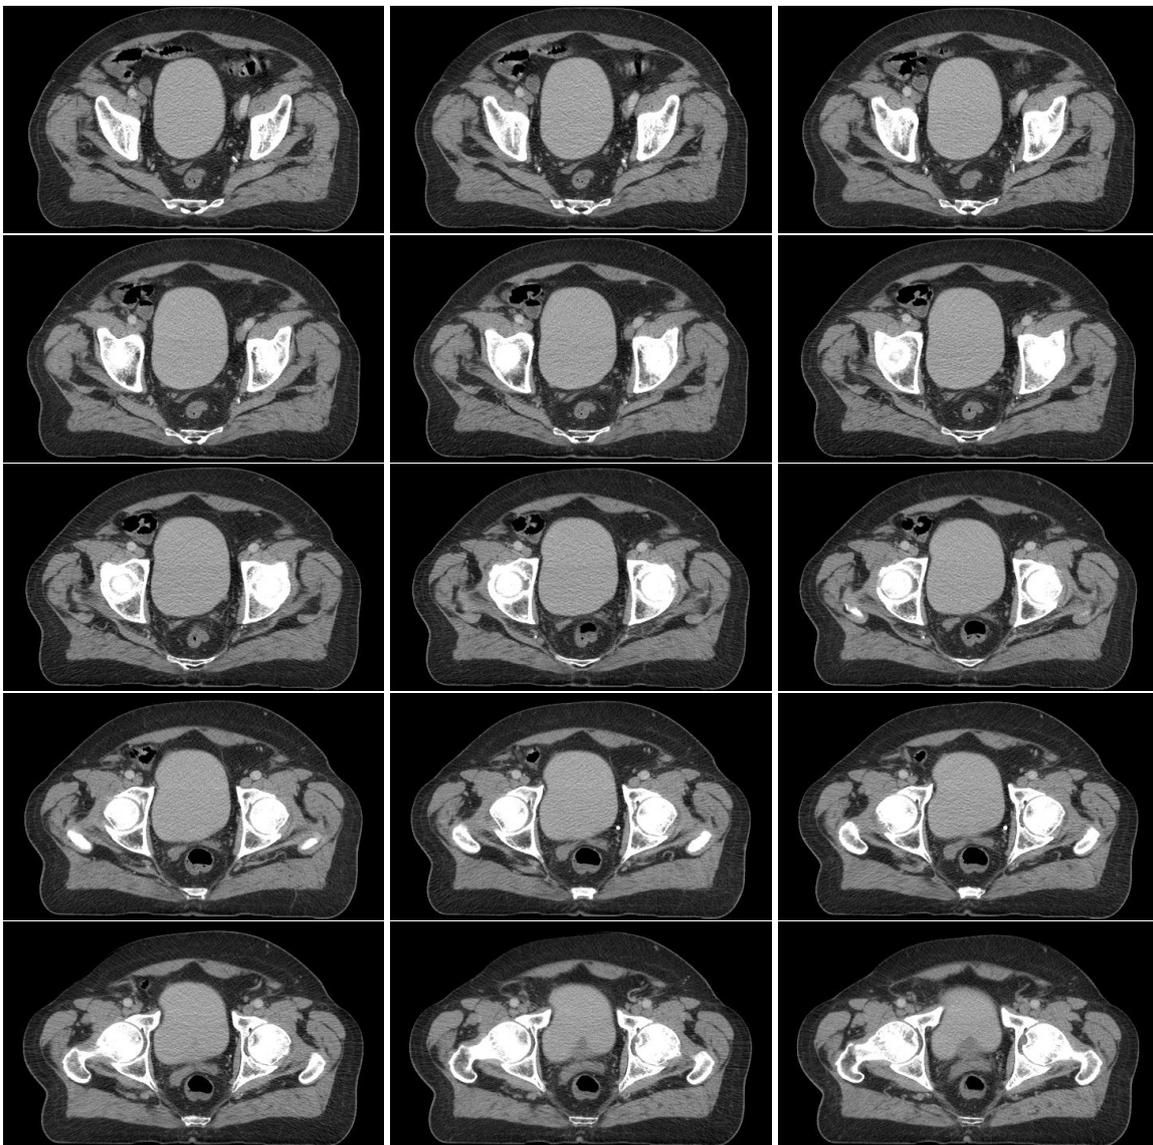


Figura 4.2: Primeiro conjunto de 15, das 30 utilizadas nos testes de um paciente
Fonte: Hospital Erasto Gaertner (2016)

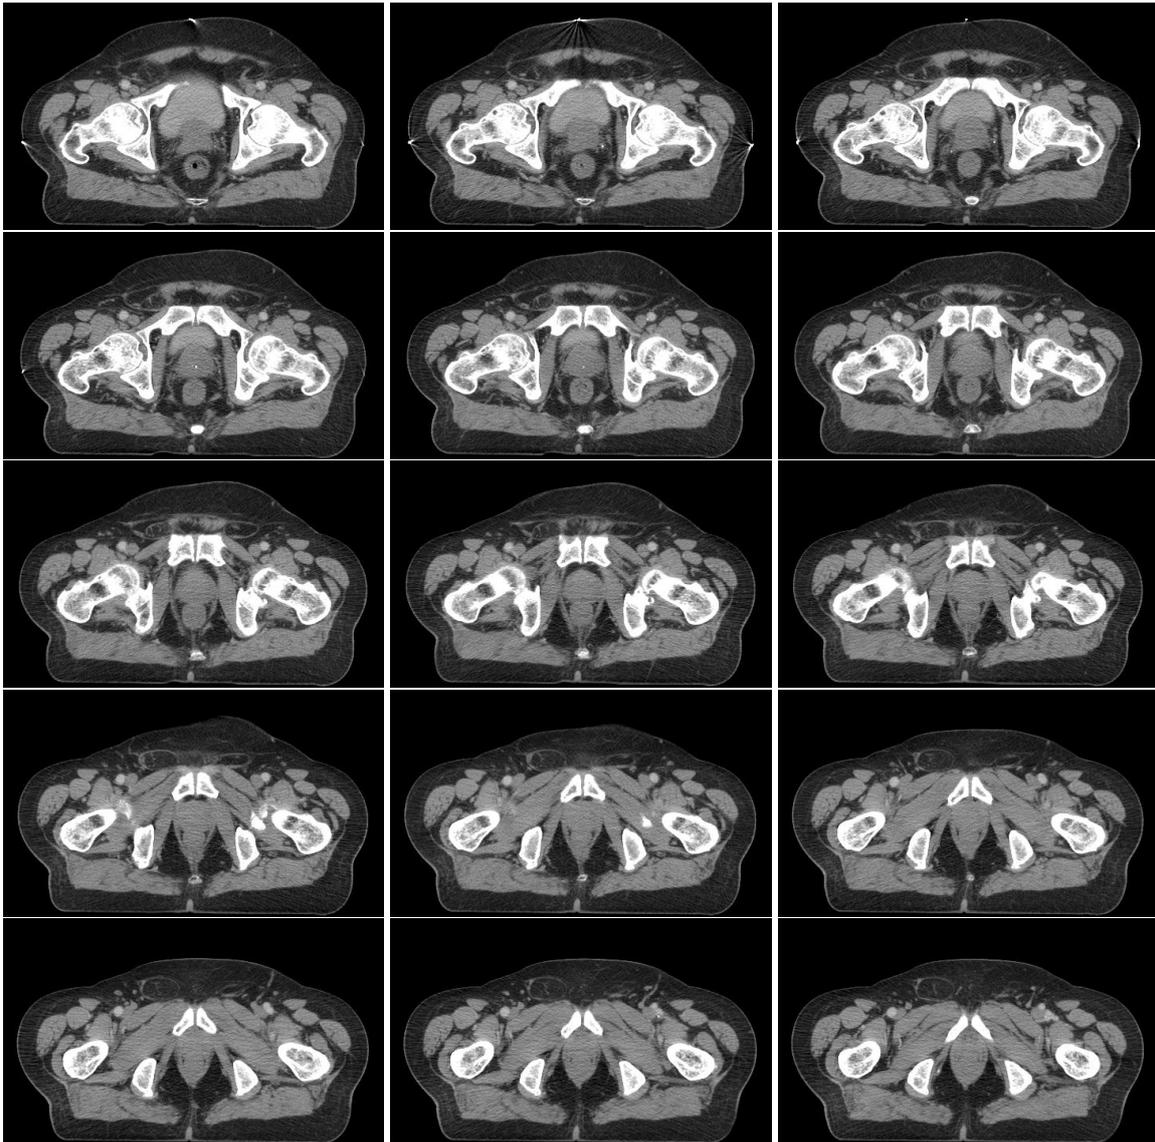


Figura 4.3: Segundo conjunto de 15, das 30 utilizadas nos testes de um paciente
Fonte: Hospital Erasto Gaertner (2016)

4.1 AMBIENTE DE TESTES

Foram selecionadas as três principais regiões na região pélvica masculina e essa escolha é justificada por serem estruturas importantes (tecidos nobres) no planejamento da radioterapia de câncer de próstata. Os testes de segmentação basearam-se nas seguintes estruturas:

- ossos pélvicos (direito e esquerdo);
- bexiga;
- reto.

Os ossos pélvicos foram a estrutura escolhida, pois é a região onde se localizam as cabeças femurais, consideradas como tecidos nobres no planejamento. Como não existe uma distinção dos níveis de cinza para ossos, a região a ser delineada é toda estrutura de ossos pélvicos.

Para a implementação da metodologia foi utilizado o ambiente MatLab, o qual é especializado no processamento de matrizes. Essa característica do MatLab não é uma novidade, sendo sua utilização comum em projetos sobre processamento de imagens.

As próximas seções apresentam como foram desenvolvidos os testes para a validação dos resultados e descrevem as etapas do processo.

4.2 PRÉ-PROCESSAMENTO

Nesta etapa foi realizado o janelamento, conforme descrito na seção 2.1.1, pois cada conjunto de imagens de testes dos 10 pacientes estudados podem apresentar WC e WS diferentes, conforme a tabela 4.1.

Tabela 4.1: Valores da largura da janela (*window width*) (WS) e do centro da janela (*window center*) (WC))

Pacientes	WS	WC
P1	250	40
P2	400	40
P3	400	40
P4	250	40
P5	250	40
P6	250	40
P7	250	40
P8	400	40
P9	400	40
P10	400	40

Observa-se na figura 4.4 a diferença entre contrastes da imagem antes do janelamento e depois o janelamento. As duas imagens tem dimensões 512×512 pixels.

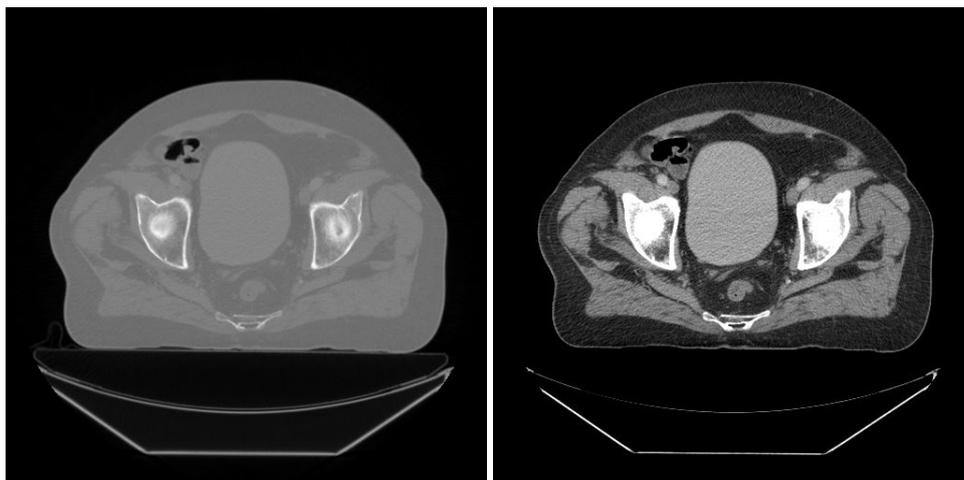


Figura 4.4: Imagem sem janelamento e com janelamento
Fonte: Hospital Erasto Gaertner (2016)

Se toda a escala Hounsfield fosse apresentada em uma única imagem, seria visível apenas uma

massa de tecidos moles, alguma musculatura e ossos, e regiões com ar. O dosimetrista não poderia visualizar todas as diferenças densitométricas mensuráveis pelo computador, e importantes informações para o diagnóstico seriam perdidas. Com isso, após o janelamento, as imagens foram transformadas da Escala Hounsfield para a escala de níveis de cinza, pois o olho humano normalmente só pode distinguir entre 20 a 30 tons diferentes.

As imagens iniciais tinham dimensão 512×512 *pixels*, mas observa-se na figura 4.4 que na parte superior temos uma região com *pixels* pretos e na parte inferior o formato da mesa. Com isso, realizou-se o recorte e as imagens passaram a ter as seguintes dimensões para cada um dos pacientes (tabela 4.2).

Tabela 4.2: Dimensões da imagem recortada

Pacientes	Dimensão (<i>pixels</i>)
P1	246 × 420
P2	236 × 411
P3	241 × 429
P4	242 × 443
P5	267 × 465
P6	219 × 397
P7	249 × 411
P8	302 × 474
P9	296 × 480
P10	268 × 468

Foram realizados testes nas segmentações das imagens utilizando o histograma equalizado. Porém, os resultados não foram satisfatórios para esse conjunto de dados.

4.3 ALGORITMO ABS

A seleção dos *pixels* sementes é uma operação delicada e influencia todo o processo de delineamento da região. A proposta é usar o algoritmo ABS para encontrar automaticamente essas sementes. No passo dois do algoritmo, apresentado em 3.3, a imagem é dividida em 16 quadrantes proporcionais à altura e largura (Figura 4.5).

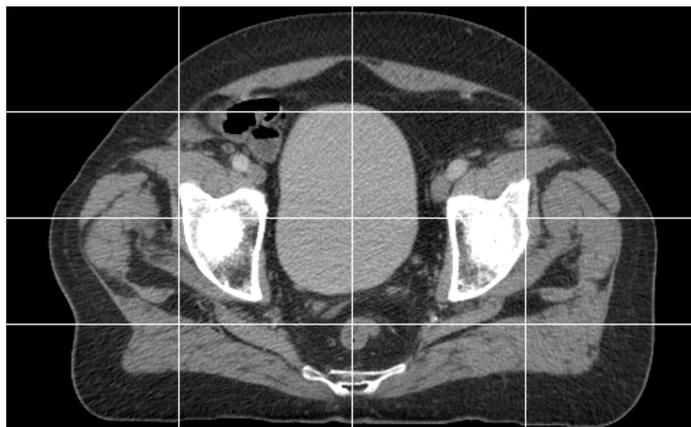


Figura 4.5: Imagem dividida em 16 quadrantes

No passo 3 do algoritmo é definida a área de busca semente (ABS) para a região do fêmur esquerdo (ossos pélvicos), reduzida apenas a porção central esquerda da seção de TC e a área de busca do *pixel* semente para fêmur direito (ossos pélvicos), reduzida a porção central direita da seção de TC, pelo conhecimento *à priori* da região onde se localizam os ossos pélvicos.

Fixou-se os *pixels* centrais esquerdo e direito, interseção da segunda linha e primeira coluna e segunda linha e quarta coluna para os fêmures esquerdo e direito, respectivamente. Partindo destes pontos centrais, definiu-se a área de busca da semente (ABS) pelas coordenadas obtidas anteriormente, criando uma área retangular com 20% do tamanho da imagem, nas quatro direções (direita, esquerda, superior e inferior). Na figura 4.6 (a) é apresentada a imagem original e 4.6 (b) a área de busca da semente definida automaticamente a partir da imagem original para ossos pélvicos direito e esquerdo.

No passo 4 do algoritmo é definida a área de busca do *pixel* semente (ABS) para a região da bexiga, reduzida apenas a porção central superior da seção de TC, pelo conhecimento *à priori* da região onde se localiza a bexiga.

Fixou-se o *pixel* central que é a interseção da primeira linha e segunda coluna da imagem dividida. Partindo destes pontos centrais, definiu-se a área de busca da semente (ABS) pelas coor-

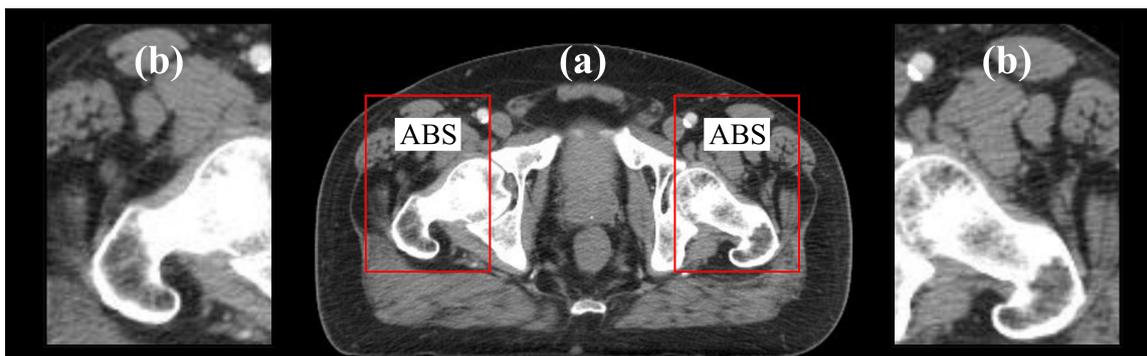


Figura 4.6: (a) Imagem original (b) Área de busca semente (ABS) para ossos pélvicos definida automaticamente a partir da imagem original

Fonte: A autora

denadas obtidas anteriormente, criando uma área retangular com 30% do tamanho da imagem, nas quatro direções (direita, esquerda, superior e inferior). Na figura 4.7 (a) é apresentada a imagem original e 4.7 (b) a área de busca da semente definida automaticamente a partir da imagem original para a bexiga.

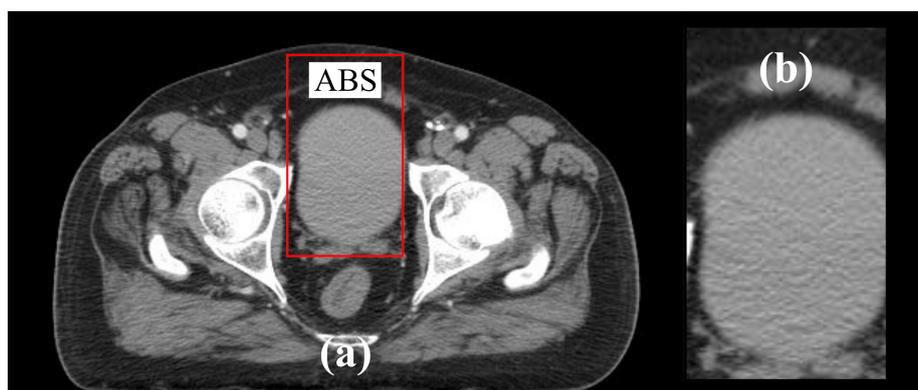


Figura 4.7: (a) Imagem original (b) Área de busca semente (ABS) para a bexiga definida automaticamente a partir da imagem original

Fonte: A autora

No passo 5 do algoritmo é definida a área de busca do *pixel* semente (ABS) para a região do reto, reduzida apenas a porção central inferior da seção de TC, pelo conhecimento *à priori* da região onde se localiza o reto.

Fixou-se o *pixel* central que é a interseção da terceira linha e segunda coluna da imagem dividida. Partindo destes pontos centrais, definiu-se a área de busca da semente (ABS) pelas coordenadas obtidas anteriormente, criando uma área quadrada com 12% da altura da imagem, nas quatro direções (direita, esquerda, superior e inferior) Na figura 4.8 (a) é apresentada a imagem original e 4.8 (b) a área de busca da semente definida automaticamente a partir da imagem original para o

reto.

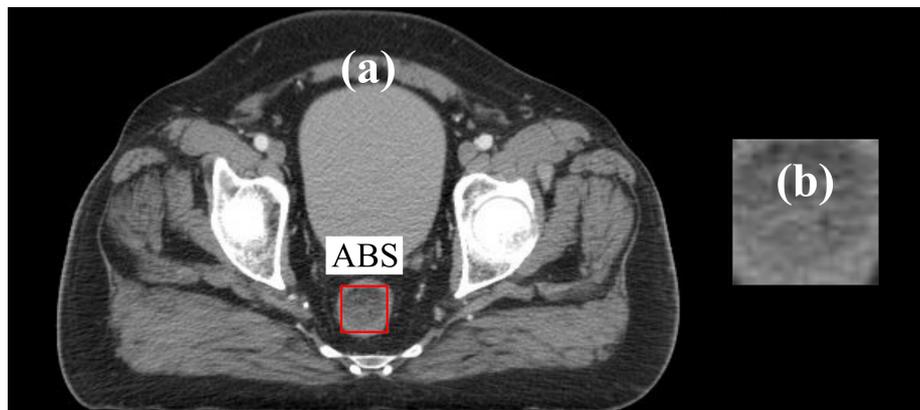


Figura 4.8: (a) Imagem original (b) Área de busca semente (ABS) para o reto definida automaticamente a partir da imagem original

Fonte: A autora

No passo 6, foram computados os níveis de cinza presentes nas ABS's das três regiões, considerando: para ossos pélvicos, se o nível de cinza do *pixel* for maior que o nível de cinza 200, o *pixel* recebe 255; para a bexiga, se nível de cinza do *pixel* for maior que 100 e menor do que 200, o *pixel* recebe 255 e para o reto, se nível de cinza do *pixel* for maior que 80 e menor do que 150, o *pixel* recebe 255. Caso contrário, em todas as ABS's, o *pixel* recebe 0. Na figura 4.9 observa-se a imagem binária nas ABS's com os *pixels* brancos ou pretos, para a criação da lista mestre (LM) com os *pixels* interseção nas 30 imagens utilizadas para cada paciente.

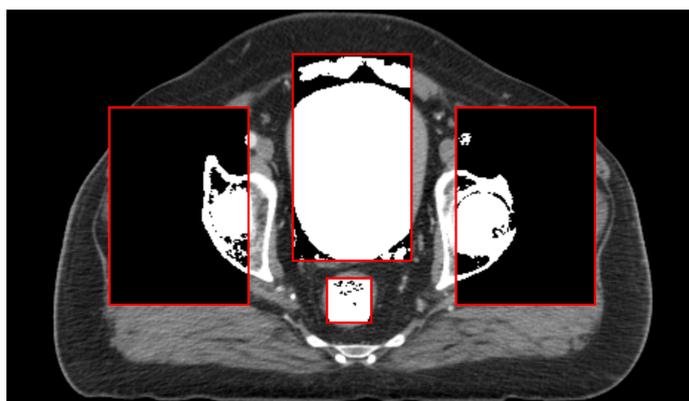


Figura 4.9: *Pixels* brancos e pretos na ABS em cada uma das três regiões

Fonte: A autora

Na tabela 4.3 são apresentados os *pixels* sementes propostos para cada região, considerando: os níveis de cinza para ossos pélvicos (> 200), bexiga ($100 < cinza < 200$) e reto ($80 < cinza < 150$); área de busca com porcentagens (20%, 30% e 12%), respectivamente; número de imagens variando de 1 até 30 para ossos pélvicos e reto, e de 1 até 15 para bexiga criando a lista mestre (LM) com os

pixels de interseção contidos em todas as imagens.

Tabela 4.3: Coordenadas dos *pixels* sementes para cada região em cada paciente

Paciente	Fêmur esquerdo	Fêmur direito	Bexiga	Reto
P1	(120, 106)	(122, 327)	(111, 223)	(166, 221)
P2	(140, 107)	(134, 309)	(114, 207)	(165, 207)
P3	(150, 104)	(137, 329)	(140, 207)	(171, 218)
P4	(121, 112)	(118, 329)	(111, 220)	(167, 222)
P5	(154, 116)	(145, 352)	(107, 231)	(184, 237)
P6	(113, 98)	(120, 299)	(97, 202)	(155, 200)
P7	(146, 114)	(146, 301)	(128, 208)	(173, 207)
P8	(192, 117)	(198, 353)	(140, 237)	(214, 239)
P9	(177, 117)	(182, 363)	(136, 238)	(211, 242)
P10	(145, 128)	(155, 345)	(142, 240)	(187, 237)

Com essas coordenadas dos *pixels* sementes, encontradas automaticamente, pode-se utilizar o método *Region Growing* para delinear as regiões de tecidos nobres. No processo realizado pelo dosimetrista, conforme orientação da equipe de física-médica do hospital Erasto Gaertner, ou os pontos sementes são selecionados clicando em um *pixel* da imagem no *software* e este contorna a região automaticamente, ou o profissional contorna manualmente a região de interesse. Na metodologia proposta, o processo de escolha do *pixel* semente é automatizado, que é o diferencial da tese.

4.4 REGION GROWING

Terminada a etapa de pré-processamento e aplicação do algoritmo ABS, utilizou-se a filtragem (filtro de mediana) para redução de ruídos e suavização das imagens e posteriormente a segmentação das regiões de interesse (tecidos nobres). Observa-se na figura 4.10 a diferença entre as bordas das regiões suavizadas da imagem antes e depois da filtragem mediana.

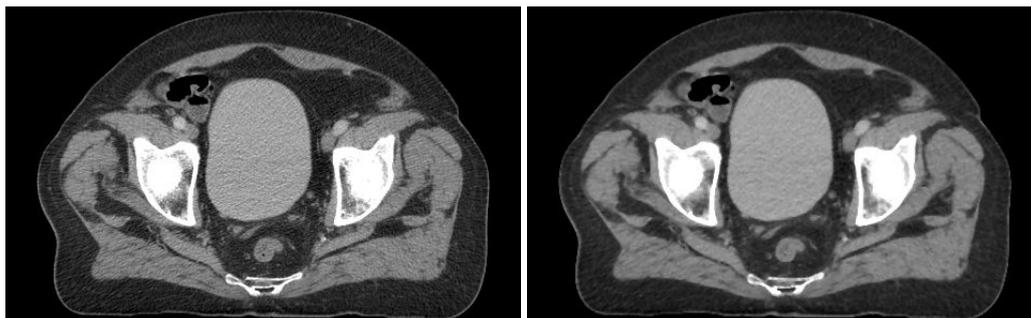


Figura 4.10: Imagem sem filtro e com filtro mediana

Fonte: A autora

Os resultados da segmentação utilizando o método de *Region Growing*, capaz de segmentar corretamente regiões que possuem propriedades semelhantes e separadas espacialmente, são apresentados nesta seção.

A tabela 4.5 apresenta a razão de similaridade entre a área segmentada manualmente pelo dosimetrista e a área segmentada pelo algoritmo proposto. Para o cálculo da área da região utilizou-se o tamanho do *pixel* (em milímetros) e que difere de paciente para paciente, conforme apresentado na tabela 4.4 considerando os valores presentes no cabeçalho DICOM, em "*Pixel Spacing*".

Observa-se nas figuras 4.11 e 4.12 algumas imagens que foram obtidas como saída do processo de segmentação automática e manual, sendo as imagens da primeira coluna resultantes da segmentação manual e as imagens da segunda coluna resultantes da segmentação automática. Tem-se bons resultados visuais, e validados pelos profissionais do Hospital Erasto Gaertner. No Apêndice B, encontram-se as 30 imagens segmentadas do paciente 8. Observa-se os pontos de semente destacados em vermelho, que são os pontos iniciais para a etapa de segmentação.

No trabalho de Gu *et al.* (2013) é apresentado uma abordagem de segmentação de 93 tumores benignos e 91 tumores malignos, comparando um algoritmo existente com um algoritmo proposto (conforme descrito na seção 2.3.3). Foi avaliado um conjunto de 129 imagens de tumor pulmonar de TC utilizando um índice de similaridade (SI). Vale destacar que a média de SI para 2 especialistas (dosimetristas) diferentes foi de 79,53 %. Com isso, confirma-se que não existe uma "verdade" ab-

Tabela 4.4: Tamanho do *pixel* em milímetros

Pacientes	(<i>Pixel Spacing</i>)
P1	$9,765625.10^{-1}$
P2	$9,765625.10^{-1}$
P3	$9,765625.10^{-1}$
P4	$9,765625.10^{-1}$
P5	$9,375.10^{-1}$
P6	$9,765625.10^{-1}$
P7	$9,765625.10^{-1}$
P8	$8,80859.10^{-1}$
P9	$9,10156.10^{-1}$
P10	$9,765625.10^{-1}$

soluta para comparação e que o ideal é que vários especialistas delineassem as mesmas regiões para que a metodologia fosse comparada e obtivesse resultados mais precisos.

Os resultados adquiridos com o índice de similaridade (SI) entre a segmentação manual e a segmentação da metodologia proposta para a bexiga e reto podem ser observadas na tabela 4.5. O índice de similaridade não foi calculado para cabeça de fêmur, pois a região delimitada automaticamente são ossos pélvicos e a região delimitada manualmente é apenas cabeça de fêmur, não sendo possível a comparação entre as duas.

A média do SI para bexiga foi de 81,46% e para o reto de 60,10% com desvio padrão de 9,15% e 7,07%, respectivamente. A segmentação automática do reto tem que lidar com uma grande variabilidade de tamanho, forma e distribuição de intensidade da parte interna do órgão. Com a utilização apenas dos níveis de cinza seu delimitamento é dificultado, pois ele se funde a outras regiões com a mesma intensidade de níveis de cinza, como exemplo musculatura e gorduras. O próprio dosimetrista em algumas seções de TC, não consegue visualizar a região e acaba delimitando empiricamente. Na figura 4.13 apresenta-se uma imagem onde a região do reto se funde com outras, uma imagem da segmentação manual e uma imagem da segmentação pela metodologia proposta. Observa-se que mesmo não tendo uma região bem delimitada, a segmentação automática se aproximou da segmentação realizada pelo dosimetrista.

Na tabela 4.6 observa-se as métricas *true positive ratio* (TPR) e *false positive ratio* (FPR). As altas médias de TPR (83,99% e 76,77%), respectivamente para bexiga e reto, demonstram que as

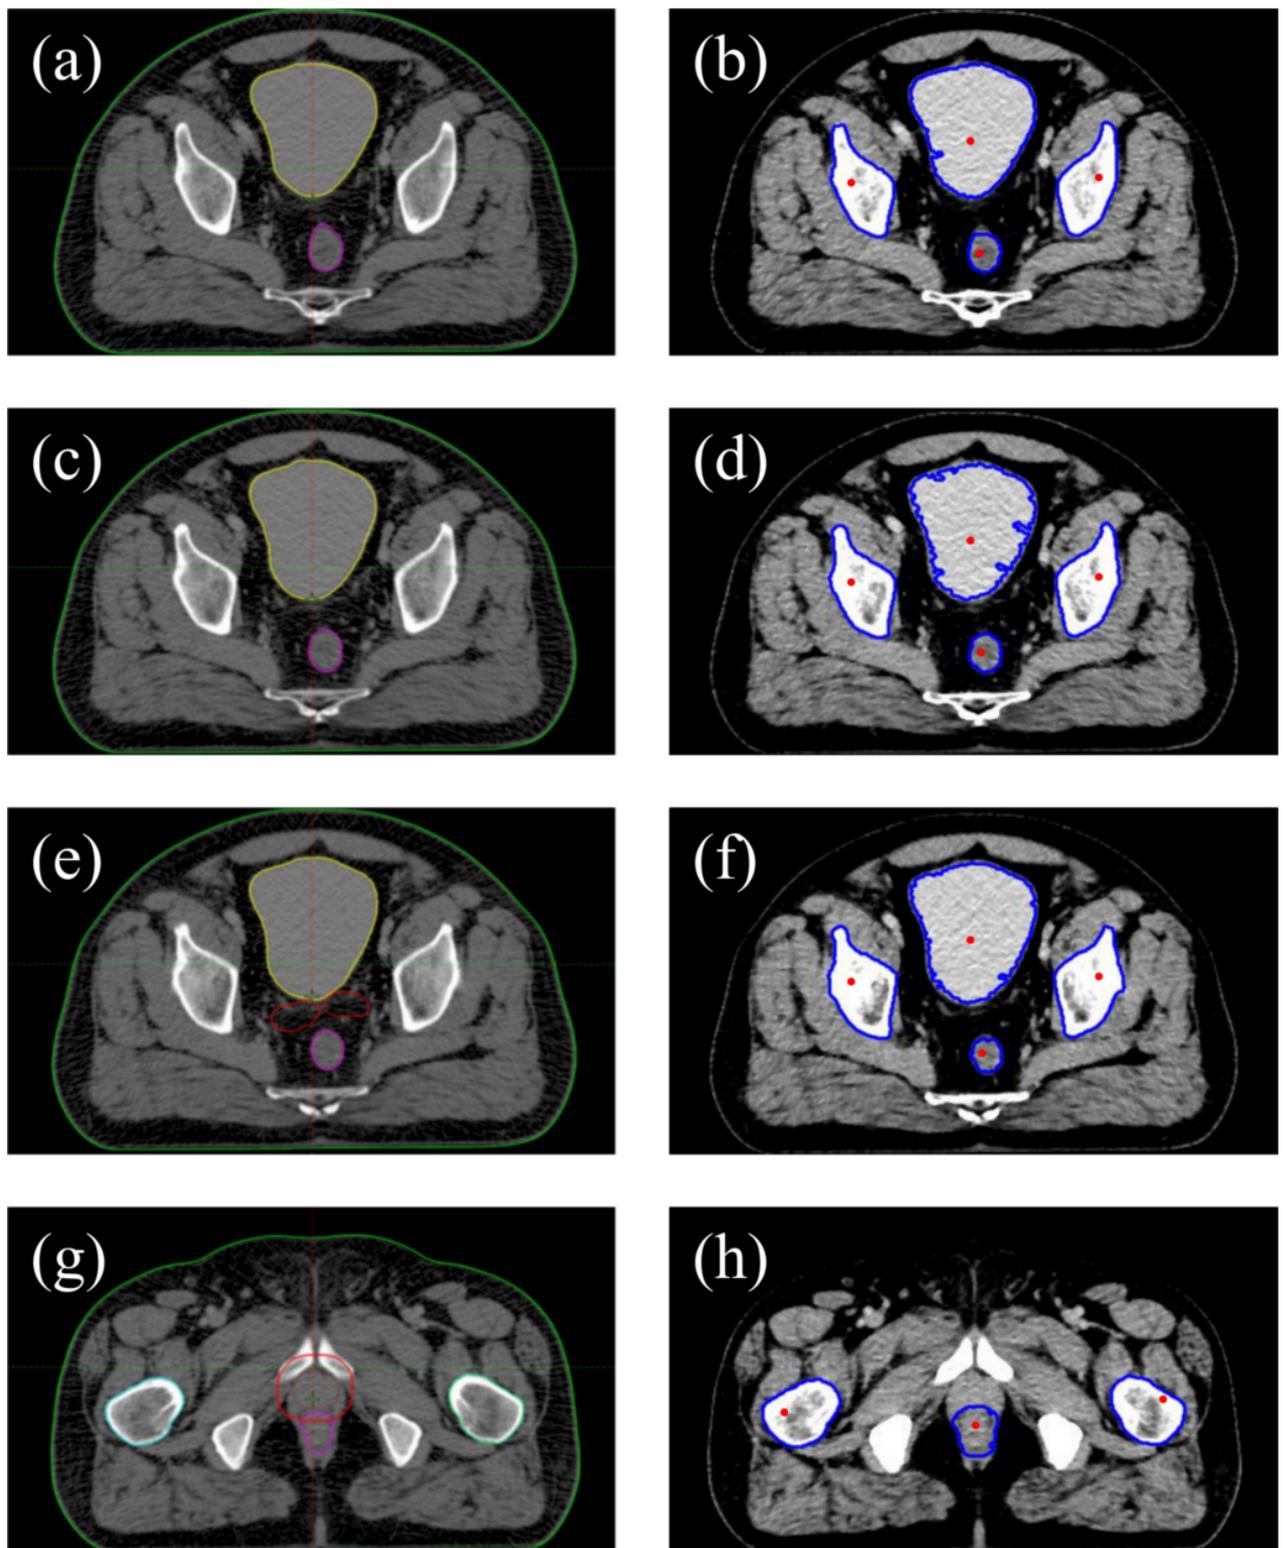


Figura 4.11: Em (a, c, e, g) são as seções segmentadas manualmente, enquanto em (b, d, f, h) são as seções segmentadas de forma automática, com o ponto de semente destacado em vermelho - paciente 5

Fonte: A autora

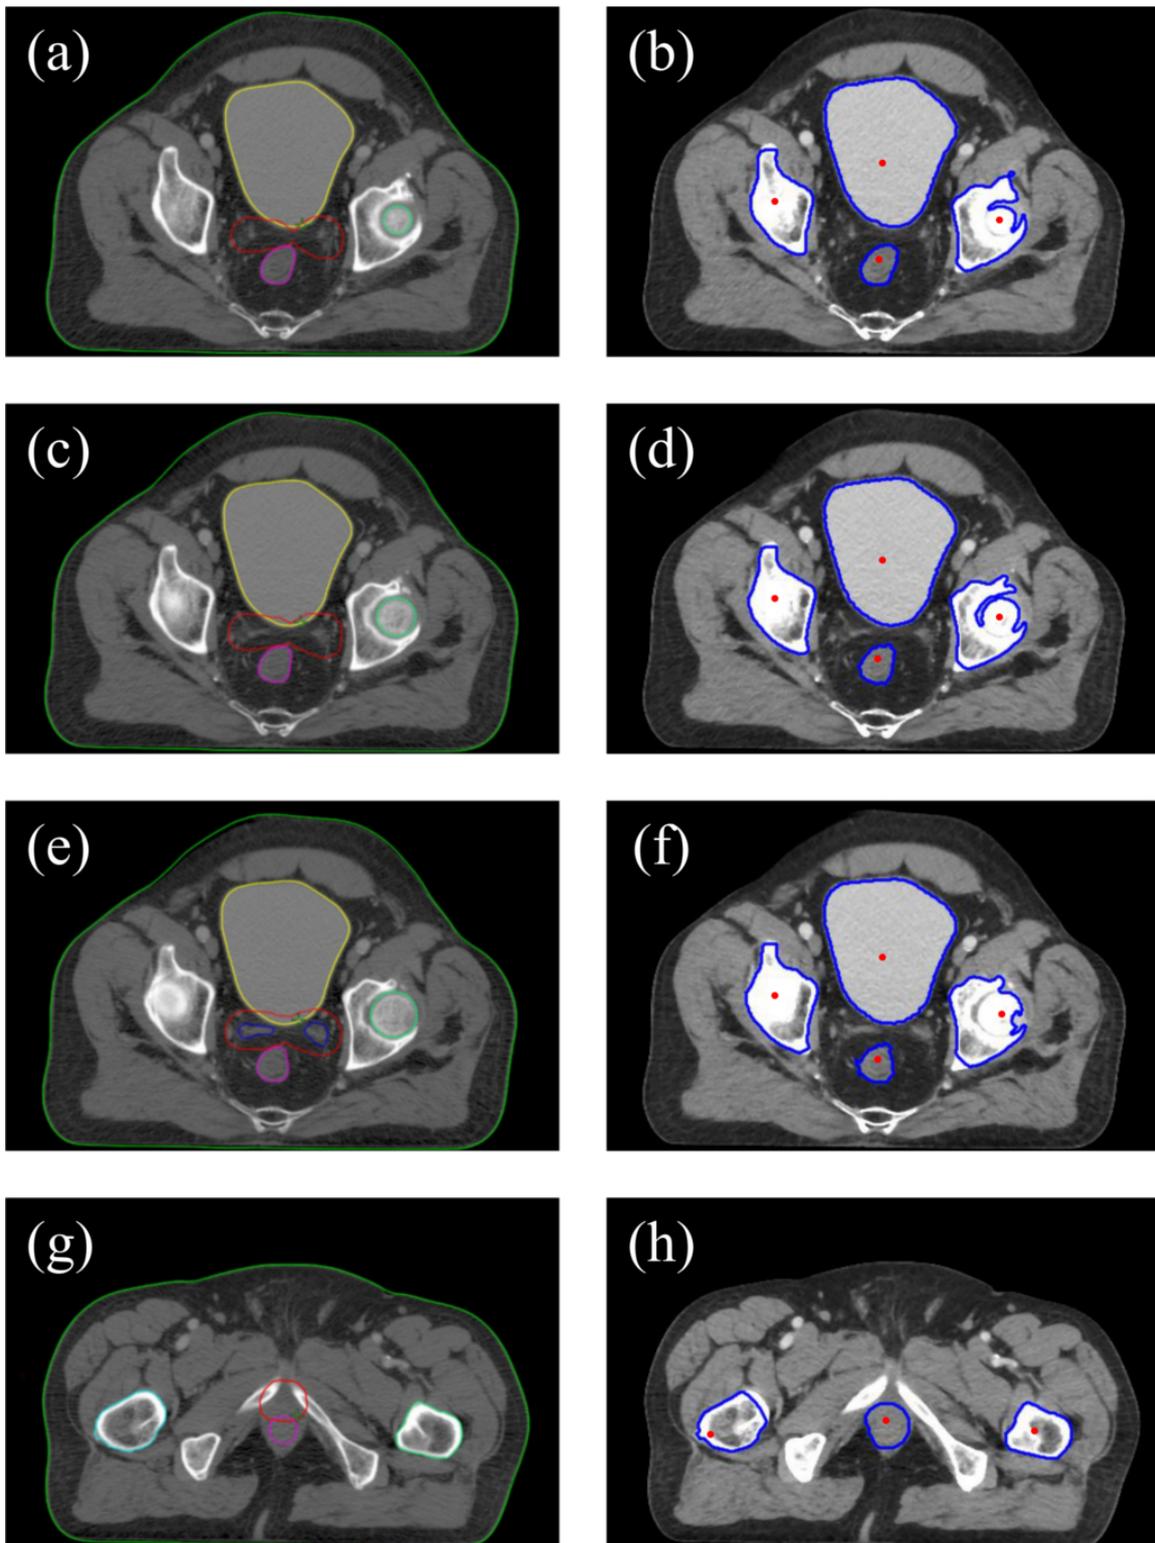


Figura 4.12: Em (a, c, e, g) são as seções segmentadas manualmente, enquanto em (b, d, f, h) são as seções segmentadas de forma automática, com o ponto de semente destacado em vermelho - paciente 8

Fonte: A autora

Tabela 4.5: Razão de similaridade (SI) entre a segmentação manual e a segmentação do algoritmo proposto

Paciente	SI(%) Bexiga	SI(%) Reto
P1	85,00	69,00
P2	77,25	62,37
P3	82,36	49,02
P4	75,12	50,29
P5	93,56	69,11
P6	72,29	56,59
P7	70,78	63,12
P8	89,95	58,62
P9	95,45	57,02
P10	72,96	65,86
Média	81,46	60,10
Desvio padrão	9,15	7,07

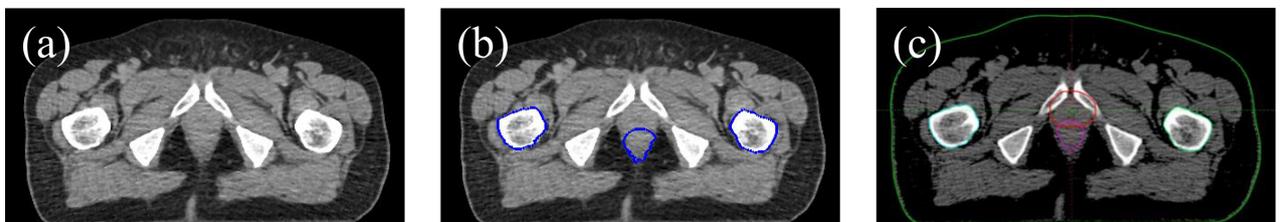


Figura 4.13: (a) imagem original fundida a outras regiões (b) segmentação manual pelo dosimetrista (c) segmentação automática pela metodologia proposta

Fonte: A autora

regiões geradas pela metodologia proposta, sobrepôs a "verdadeira" região da bexiga e reto com elevada porcentagem. As médias de FPR (16,31% e 22,82%) demonstram também que algumas regiões foram segmentadas sem pertencerem a região correta.

Outra observação a ser apontada é que o dosimetrista realiza uma etapa de pós-processamento das regiões para suavizar os contornos, e no caso das cabeças de fêmur direita e esquerda, delimitar apenas a região interna de ossos pélvicos. Essa fase não foi abordada nesta tese.

A tabela 4.7 apresenta os tempos computacionais para segmentar as 30 imagens de cada paciente. O tempo médio de segmentação para os pacientes foi de 21,16 segundos com desvio padrão

Tabela 4.6: Razão verdadeiro positivo (TPR) e razão falso positivo (FPR)

Paciente	TPR (%) Bexiga	FPR(%) Bexiga	TPR (%) Reto	FPR (%) Reto
P1	82,00	28,04	85,35	27,92
P2	71,03	31,61	76,35	30,21
P3	82,03	24,93	43,84	22,61
P4	96,00	2,32	69,14	24,61
P5	95,59	5,77	93,40	6,04
P6	57,02	37,83	36,99	67,89
P7	76,85	13,00	95,13	4,10
P8	90,59	11,76	95,12	4,54
P9	96,62	3,47	79,18	35,05
P10	93,19	4,36	93,20	5,24
Média	83,99	16,31	76,77	22,82
Desvio padrão	12,90	13,14	21,15	19,83

de 2,8 segundos. Vale destacar que o dosimetrista demora aproximadamente 30 minutos para delinear as regiões de tecidos nobres para cada paciente. Assim, houve uma diminuição significativa no tempo para o delineamento das regiões consideradas utilizando a metodologia proposta.

Tabela 4.7: Tempo (s) da segmentação de cada região para cada paciente

Paciente	Tempo (s)
P1	20,04
P2	19,95
P3	16,35
P4	19,64
P5	22,04
P6	20,35
P7	20,45
P8	24,82
P9	26,32
P10	21,66
Média	21,16
Desvio padrão	2,80

Por conseguinte, a utilização de sistemas assistidos por computador torna-se necessário para superar a demora nesta etapa do planeamento da radioterapia. É introduzido um algoritmo ABS com crescimento de regiões (automatizado) para delineamento de tecidos nobres, que permite uma redução significativa do tempo necessário para o contorno.

Capítulo 5

Considerações Finais e Trabalhos

Futuros

Os números atuais do Sistema Único de Saúde (SUS) apontam, segundo relatório de novembro de 2011, divulgado pelo Tribunal de Contas da União (TCU), que pacientes diagnosticados com câncer levam, em média, 113,4 dias para iniciar a radioterapia. Grande parte desta demora se deve ao tempo que se leva para o planejamento da radioterapia.

O primeiro passo no planejamento é delinear (segmentar) a imagem adquirida na TC, delimitando a região do tumor e dos órgãos nobres que devem ser protegidos da radiação.

Nos trabalhos descritos na literatura (seção 2.3.2) de imagens médicas e utilização do método *Region Growing* observa-se a necessidade de estudos referentes a busca automática de *pixels* sementes para o método *Region Growing* para segmentação dos órgãos de interesse na região pélvica masculina e que nestes estudos apenas uma região é delineada automaticamente.

Visualmente é fácil de determinar o que é uma região de interesse e o que não é. Fazer isso com um algoritmo de computador, por outro lado não é tão fácil. Assim, a proposta é auxiliar no planejamento da radioterapia da região pélvica masculina, no que se refere ao processamento de imagens médicas reduzindo o tempo de planejamento e melhorando o seu desempenho. A ênfase dessa tese é propor um algoritmo (ABS) de busca desses *pixels* automaticamente e concomitantemente para a segmentação das três regiões de interesse (ossos pélvicos, bexiga e reto) para o planejamento de radioterapia de câncer de próstata, considerando assim, o processamento de imagens bidimensionais. Pretende-se estender o conceito para o caso tridimensional.

Este algoritmo não requer interferência humana e nenhuma informação inicial para obter os

pontos de semente. Os pontos de semente são gerados automaticamente com base no conhecimento da composição da imagem. Esta abordagem pode ser aplicada a um vasto número de imagens, uma vez que a computação dos pontos de semente depende apenas da informação da imagem (níveis de cinza).

De um modo geral a aplicação satisfaz todos os objetivos inicialmente propostos no início desta tese. Seguidamente são apresentados os pontos fortes das abordagens e os pontos que poderiam ter sido mais ambiciosos.

Verificou-se que o algoritmo de crescimento de regiões com lançamento automático de sementes teve um índice de similaridade médio, considerando todos os exames estudados de 81,46% para a bexiga e de 60,10% para o reto.

Durante a execução do algoritmo *Region Growing* foi percebido que pela ocorrência de grandes variações no nível de cinza nas imagens da região pélvica masculina, o algoritmo acabou desconsiderando alguns *pixels* pertencentes às regiões causando dessa forma erro na área de interesse. Além disso, o algoritmo proposto fornece um resultado, livre de sobre e sub-segmentação. Várias pequenas regiões são divididas para a busca dos pontos de semente, evitando assim a super-segmentação. O algoritmo continua a segmentação nas diferentes regiões (ABS), isso evita a sub-segmentação.

Observou-se que, utilizando métodos de segmentação comparadas com a segmentação manual realizada pelo dosimetrista, obteve-se bons resultados confirmados pela equipe de física-médica do hospital Erasto Gaertner. Outra observação a ser apontada é que o dosimetrista realiza uma etapa de pós-processamento das regiões para suavizar os contornos, e no caso das cabeças de fêmur direita e esquerda, delimitar apenas essa região interna contida na região de ossos pélvicos. Essa fase não foi abordada nesta tese.

São necessários testes para a região pélvica masculina considerando: a região de outros pacientes, a segmentação de outro profissional, métodos de segmentação não abordados neste trabalho e diferentes tipos de filtragem para suavizar ruídos nas imagens.

O algoritmo para seleção automática de pontos de semente para a segmentação da região semeada é proposto nesta tese. Os resultados da implementação mostram resultados satisfatórios para a segmentação de imagens. Isto implica que o algoritmo proposto pode ser utilizado com sucesso para conseguir a segmentação automática de imagens e pode ser utilizado em vários algoritmos de reconhecimento de objetos. No futuro, esta técnica pode ser implementada com imagens a cores, proporcionando espaço de cores apropriados.

O importante componente deste trabalho é permitir a mínima intervenção humana enquanto a delimitação das regiões permanece precisa e consistente como resultado da segmentação de conjunto. Isso pode ser especialmente útil para o trabalho em lote ou para usuários novatos no computador. A carga de trabalho de segmentação da região pélvica masculina tem sido reduzida (em outras palavras, pode-se economizar uma quantidade significativa de tempo valioso para dosimetristas / oncologistas / radiologistas na segmentação de região de interesse).

O objetivo do algoritmo é fornecer uma ferramenta de delimitação que possa ser usada por muitos dosimetristas para obter os mesmos resultados de segmentação. Considerando que a segmentação não deve diferir muito de delimitações manuais fornecidas por diversos especialistas.

É evidente que o algoritmo proposto é capaz porque são utilizadas regiões específicas para produzir *pixels* sementes. No entanto, o algoritmo proposto tem inconvenientes. Somente a intensidade de *pixel* e sua posição são extraídas como características e usadas como critérios para selecionar sementes e fazer crescer a região.

O algoritmo será uma ferramenta ainda mais poderosa se puder ser testado em ambiente clínico e também será muito útil em futuros ensaios clínicos multi-centros, principalmente para os especialistas que estão iniciando na vida profissional.

Referências

[1] ACHARYA, T.; RAY, A.K. Image Enhancement and Restoration. **Image Processing - Principles and applications**, New Jersey: John Willey and Sons, Inc; 2005:105-128.

[2] ADAMS, R., and BISCHOF, L.. Seeded region growing. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 16, 6, 641-647, 1994.

[3] ALTEROVITZA, R., LESSARD, E., POULIOT, J., HSU, C.J., BRIEN, J.F., and GOLDBERG, K. Optimization of HDR brachytherapy dose distributions using linear programming with penalty costs. **Medical Physics**, 33(11), 4012-20, 2006.

[4] ANASTACIO, R., MANERE, L.R., CÂNDICO, M.R., MACEDO, T.A.A., PATROCÍNIO, A.C. Volumetria e segmentação hepática automática. XXIV Congresso Brasileiro de Engenharia Biomédica **CBEC**, 2014.

[5] AUBRY, J., BEAULIEU, F., SEVIGNY, C., BEAULIEU, L., and TREMBLAY, D. . Multi-objective optimization with a modified simulated annealing algorithm for external beam radiotherapy treatment planning. **Medical Physics**, 33, 4718-29, 2006.

[6] BANKMAN, I.N. ed. **Handbook Medical Imaging Processing Analysis**. 2000, Academic Press: San Diego/London.

[7] BEDDOE, G., PETROVIC, S., and LI, J. A hybrid metaheuristic case-based reasoning system for nurse rostering. **Journal of Scheduling**, 12(2), 99-119, 2009.

[8] BENTO, F. C. S.; GOMES, R. L. E. **Hospital das Clínicas da FMUSP** Disponível em: <<http://spr.org.br/caderno-2-fevereiro-de-2015/>>. Acesso em 12/12/2016.

[9] BERGER, J. (1994). Roentgen: radiation therapy and case based reasoning. **Proceedings of 10th conference on artificial intelligence applications**, 171-177.

- [10] BOMFORD, C., **Kunkler I - Textbook of Radiotherapy**- 6ª Edição. Churchill Livingstone, 2003.
- [11] BRASIL. MINISTÉRIO DA SAÚDE. Secretaria de Atenção à Saúde. Instituto Nacional de Câncer. Coordenação de Prevenção e Vigilância de Câncer. **Estimativas 2008: Incidência de Câncer no Brasil**. Rio de Janeiro: INCA, 2007.
- [12] CANNY, J. A computational approach to edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 8(6): p. 679-698, 1986.
- [13] CARVALHO, A.L.S. **Implementação de um sistema de dosimetria "in-vivo" em Radioterapia Externa - aplicação no cancro da mama**. Tese de Mestrado Física dos Materiais Avançados, Universidade do Minho, Portugal, 2009.
- [14] CHEN, Z., MA, C.M., PASKALAV, K., LI, J., RICHARDSON, T., PALACIO, L., XU, X., and CHEN, L. Investigation of MR image distortion for radiotherapy treatment planning of prostate cancer. **Physics in Medicine and Biology**, 51, 1393-1403, 2006.
- [15] CHEN, A. ; LOVELOCK, D.; RADKE, R.J. Segmenting the prostate and rectum in CT imagery using anatomical constraints. **Medical Image Analysis**, 15 (2011) 111.
- [16] COLOMBO, C. DEL BIMBO, A. PALA, P. Semantics in visual information retrieval. **IEEE Multimedia**, 6: 38-53, 1999.
- [17] COTRUTZ, C., LAHANAS, M., KAPPAS, C., and BALTAS, D. . A multi-objective gradientbased dose optimization algorithm for external beam conformal radiotherapy. **Physics in Medicine and Biology**, 46, 2161-75, 2001.
- [18] COTRUTZ, C., and XING, L. Segment-based dose optimization using a genetic algorithm. **Physics in Medicine and Biology**, 48, 2987-2998, 2003.
- [19] DEB, K. **Multi-objective optimization using evolutionary algorithms**. Wiley, 2009.
- [20] EHRGOTT, M., HOLDER, A., REESE, J. Beam Selection in Radiotherapy Design. **Linear Algebra and its Applications**, 428 (2008), p.1272-1312, 2008.
- [21] ENGEL, K., and TABBERT, E. Fast Simultaneous Angle, Wedge, and Beam Intensity Optimization in Inverse Radiotherapy Planning. **Optimization and Engineering**, 6(4), 393-419.

(2005).

[22] FARIA, D. **Análise e processamento de imagem**. Dissertação de Mestrado, Faculdade de Engenharia da Universidade do Porto, 2010.

[23] FAN, J., YAU, E., and AREF. Automatic image segmentation by integrating color-edge extraction and seeded region growing. **IEEE Transactions on Image Processing**, vol.10, no.10, pp.1454 – 1466, Oct. 2001.

[24] FAN, J., ZENG, G., BODY, M., and HACID, M. Seeded region growing: an extensive and comparative study. **Pattern Recognition Letters**, 26, 1139-1156, 2005.

[25] FALCÃO, A. X. **Imagem tomográfica**. Disponível em «<http://www.ic.unicamp.br/cpg/material-didatico/mo815/9802/curso/node11.html>». Acesso em 18/05/2014.

[26] FENG, Y., FANG, H., and JIANG, J. Region Growing with Automatic Seeding for Semantic Video Object Segmentation. **ICAPR 2005**, LNCS 3687, 542-594, 2005.

[27] FERLAY, J. *et al.* **GLOBOCAN 2012 v1 0, cancer incidence and mortality worldwide**. Lyon, France: IARC, 2013. (IARC CancerBase, 11). Disponível em: <<http://globocan.iarc.fr>>. Acesso em: 10 dez de 2013.

[28] FIORENTINI, S., LARRABIDE, I., and VENERE, M.. A simple 3d image segmentation technique over medical data. **In Proceedings of SIS**, 2003.

[29] FONSECA, F. C. S.; BELTRAME, W. A. R. **Aplicações Práticas dos Algoritmos de Clusterização Kmeans e Bisecting K-means**. Disponível em: «<http://www.inf.ufes.br/claudine/courses/paa10/seminarios/seminario4.pdf>». Acesso em 12/04/2014.

[30] FONTANA, A., NALDI, M. C. **Estudo de Comparação de Métodos para Estimação de Números de Grupos em Problemas de Agrupamento de Dados**. Universidade de São Paulo. ISSN - 0103-2569, 2009.

[31] GHISTA, D. N. **Applied Biomedical Engineering Mechanics**. 2008, New York: CRC Press. 592.

[32] GIRALDI, G.A.; STRAUSS, E.; OLIVEIRA, A.F. A Boundary Extraction Method Based

on Dual-T-Snakes and Dynamic Programming, **In Proc.of IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, (CVPR'2000), 2000.

[33] GOLDBARG, M.C., GOLDBARG, E.F.G., MENDES, C.R.A, ARAUJO, F.S.L.N., CORSO, G. Algoritmo evolucionário para otimização do plano de tratamento em radioterapia conformal 3D. **Pesquisa Operacional**, v.29, n.2, p.239 – 267, 2009.

[34] GONZALEZ, R., WOODS, R. Image enhancement in the spatial domain. **Digital Image Processing**, 2 ed. New Jersey: Prentice Hall; 2002:75-147.

[35] GRADY, L., SCHWARTZ, E. L. Random walks for image segmentation. **IEEE Transactions on pattern analysis and machine intelligence**, vol. 28, N. 11, Nov. 2006.

[36] GU, Y., KUMAR, V., HALL, L.O., GOLDFOG, D.B., LI, C., KORN, R., BENDTSEN, C., VELASQUEZ, E.R., DEKKER, A., AERTS, H., LAMBIN, P., LI, X., TIAN, J., GATENBY, R.A., GILLIES, R.J. Automated delineation of lungs tumors from CT images using a single click ensemble segmentation approach. **Pattern Recognition**, 46, 2013: 692-702.

[37] HAAS, B.; CORADI, T.; SCHOLZ, M.; KUNZ, P.; HUBER, M.; OPPITZ, U.; ANDRÉ, L.; LENGKEEK, V.; HUYSKENS, D.; VAN ESCH, A. and REDDICK, R. Automatic segmentation of thoracic and pelvic CT images for radiotherapy planning using implicit anatomic knowledge and organ-specific segmentation strategies. **Phys. Med. Biol.** 53 (2008) 17511771.

[38] HOLDER, A. G. and SALTER, B. A Tutorial on Radiation Oncology and Optimization. **Mathematics Faculty Research**, Paper 37, 2004.

[39] HOLDER, A. SALTER, B. **A tutorial on radiation oncology and optimization**. In: *Tutorials on Emerging Methodologies and Applications in Operations Research*, Springer, 4-1-4-46, 2005.

[40] HOLDER, A. (2004). Radiotherapy treatment design and linear programming, *Operations research and health care*. **Kluwer's Academic publishers**, 741-774.

[41] HONG T, RITTER M, HARARI P. Intensity-modulated radiation therapy: emerging cancer treatment technology. **British Journal of Cancer**, 92: 1819-1824, 2005.

[42] INSTITUTO NACIONAL DE CÂNCER JOSÉ ALENCAR GOMES DA SILVA (Inca).

Coordenação de Prevenção e Vigilância Estimativa 2014: Incidência de Câncer no Brasil /

Instituto Nacional de Câncer José Alencar Gomes da Silva, Coordenação de Prevenção e Vigilância.

Rio de Janeiro: INCA, 2014. 124p. : il. col., mapas.

[43] JACOBS, M.A., RA, R.A.K., SOLTANIAN-ZADEH, H., ZG, Z.G.Z., GOUSSEV, A.V., PECK, D.J., WINDHAM, J.P. and CHOPP, M. Unsupervised segmentation of multiparameter MRI in experimental cerebral ischemia with comparison to T2, diffusion, and ADC MRI parameters and histopathological validation. **JMRI**, 11(4): p. 425-437, 2000.

[44] JAFFRAY, D., HERK, M., LEBESQUE, J., and MARTINEZ, A. Image Guided Radiotherapy of the Prostate. **Lecture Notes in Computer Science**, 2208,1075-80, 2001.

[45] JAMES, M. *Classification algorithms*. NY: Wiley-Interscience, 1985.

[46] JAIN, A. K., MURTY, M. N., and FLYNN, P. J. Data clustering: a review. **ACM Computer Survey**, 264-323, 1999.

[47] JIMENÉZ, C. A., *Automatic 3D segmentation of the prostate on magnetic resonance images for radiotherapy planning*. Mestrado Engenharia Biomédica, Universidade Nacional de Colômbia, Colômbia, 2014.

[48] KAMDI, S., KRISHNA, R. K.. Image Segmentation and Region Growing Algorithm. **International Journal of Computer Technology and Electronics Engineering (IJCTEE)**, pág. 103107, 2012.

[49] KANSAL, S.; JAIN, P.; GARG, A.K. Automatic seed selection algorithm for image segmentation using region growing. **International Journal of Advances in Engineering Technology**, June, 2015.

[50] KIRKPATRICK, F., GELATTE, C. D., and VECCHI, M. P. Optimization by simulated annealing. **Science**, 220, 671-780, 1983.

[51] LAHANAS, M., BALTAS, D., and ZAMBOGLOU, N. Anatomy-based three-dimensional dose optimization in brachytherapy using multi-objective genetic algorithms, **Medical Physics**, 26, 1904-1918, 1999.

[52] LAHANAS, M., BALTAS, D., and ZAMBOGLOU, N. A hybrid evolutionary algorithm

for multi-objective anatomy based dose optimization in HDR brachytherapy. **Physics in Medicine and Biology**, 48, 399-415, 2003.

[53] LAHANAS, M., BALTAS, D., and ZAMBOGLOU, N. Intensity Modulated Beam Radiation Therapy Dose Optimization with Multi-objective Evolutionary Algorithms, **Lecture Notes in Computer Science**, 2632, 648-61, 2003.

[54] LI, Y., YOA, J., and CHEN, W. A particle swarm optimization algorithm for beam angle selection in intensity modulated radiotherapy planning. **Physics in Medicine and Biology**, 50, 3492-3514, 2005.

[55] LIM, G.; CHOI, J.; MOHAN, R. (2007) *Iterative solution methods for beam angle and fluence map optimization in intensity modulated radiation therapy planning*, Technical report, Department of Industrial Engineering, University of Houston, Houston, Texas.

[56] LIU, Y. SHI, C., TYNAN, P. and PAPANIKOLAOU, N. Dosimetric characteristics of dual-layer multileaf collimation for small-field and intensity-modulated radiation therapy applications. **Journal Of Applied Clinical Medical Physics**, Volume 9, Number 2, Spring 2008.

[57] LOPES, M. C. Um Século de terapia com radiação. **Gazeta de Física**, Coimbra, vol.30, fascículo 1, artigo 3, jan.2007.

[58] LORENCETTI, A.; SIMONETTI, J. P. As estratégias de enfrentamento de pacientes durante o tratamento de radioterapia. **Rev Latino-am Enfermagem**, v.13, n.6, p.944-950, 2005.

[59] LU, J.; PLATANIOTIS, K.N.; VENETSANOPOULOS, A.N. Face recognition using feature optimization and mu-support vector learning, neural networks for signal processing XI, **Proceedings of the IEEE signal, processing society workshop**. 373-382, 2001.

[60] MA, M., TAVARES, J., JORGE, R. and MASCARENHAS, T. A review of algorithms for medical image segmentation and their applications to the female pelvic cavity. **Computer Methods in Biomechanics and Biomedical Engineering**, 13(2): p. 235-246, 2010.

[61] MALEK, A.A., RAHMAN, W.E.Z.W.A., IBRAHIM, A., MAHMUD, R. An automated seed point selection for seed based region growing in segmenting Microcalcifications. **IRAST International Congress on Computer Applications and Computational Science (CACCS, 2010)**.

[62] McINERNEY, T. and TERZOPOULOS, D. Deformable Models in Medical Image Analysis: A Survey. **Medical Image Analysis**, 1: p. 91-108, 1996.

[63] MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.

[64] MEYER, J., PHILLIPS, M.H., CHO, P.S., KALET, I., and DOCTOR, J.N. Application of influence diagram to prostate intensity-modulated radiation therapy plan selection. **Physics in Medicine and Biology**, 49, 1637-1653, 2004.

[65] MEENALOSINI, S., JANET,J. and KANNAN, E. Segmentation Of Cancer Cells In Mammogram Using Region Growing Method And Gabor Features, **International Journal of Engineering Research and Applications (IJERA)** Vol. 2, Issue 2, pp.1055-1062, Mar-Apr 2012.

[66] MITCHELL, S., BOSCH, J.G., LELIEVELDT, B.P.F., GEEST, R.J.V.D., REIBER, J.H.C. and SONKA, M. 3-D Active Appearance Models: Segmentation of Cardiac MR and Ultrasound Images. **IEEE Transactions on Medical Imaging**, 21, 2002.

[67] MUNDHADA, P., NAPHADE, S., BONDRE, K., and GOKHALE, A.V. Color image segmentation based on automatic seed selection, region growing and region merging using CIELab color space, **International Conference on Computer & Communication Technologies 2K14**, March 28-29, 2014, Hyderabad, INDIA.

[68] NUNES, N. M. C. F. **Visualização e Segmentação de dados médicos**. Dissertação de Mestrado em Engenharia Informática e de Computadores. Instituto Superior Técnico: Universidade Técnica de Lisboa, 2008.

[69] OBAL, T. M. **Uma abordagem multiobjetivo ao problema da intensidade de dose em planejamentos do tratamento de câncer por radioterapia**. Dissertação de Mestrado, Programa de Pos-Graduação em Métodos Numéricos em Engenharia, PPGMNE, UFPR, 2011.

[70] OLIVEIRA, M. G., OLIVEIRA, E., and MARCHESI, M. Z. Um QAsystem para Interação de Alunos em Avaliações Somativas a Distância. **Anais do Simpósio Brasileiro de Informática na Educação**, Florianópolis, SC. SBC, 2009.

[71] OLIVEIRA, B.F.S., MAGALHÃES, F.T.A. Filtragem de imagens fixas usando MatLab.

Relatório Televisão Digital, Faculdade de Engenharia da Universidade do Porto. Porto: 2005.

[72] PARRAGA, A. **Atlas anatômico da região da cabeça e do pescoço: em direção à radioterapia adaptativa**. Tese de Doutorado em Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

[73] PASQUIER, D.; LACORNERIE, T.; VERMANDEL, M.; ROUSSEAU, J.; LARTIGAU, E. and BETROUNI, N. Automatic Segmentation of pelvic structures from magnetic resonance images for prostate cancer radiotherapy. **Int. J. Radiation Oncology Biol. Phys.**, Vol. 68, No. 2, pp. 592600, 2007

[74] PAWLICKI, T.; JIANG, S. B.; LI, J. S.; DENG, J.; MOK, E.; KAPUR, A.; XING, L.; MA, L. and BOYER, L. Monte Carlo verification of IMRT dose distributions from a commercial treatment planning optimization system. **Phys. Med. Biol.**, v.45, 2000.

[75] PHAM, D.L.; XU, C.; PRINCE, J.L. Current Methods in Medical Image Segmentation. **Annual Review in Biomedical Engineering**, 2000.

[76] PEARSON, S.; LADAPO, J.; PROSSER, L. Intensity Modulated Radiation Therapy (IMRT) for Localized Prostate Cancer. **Institute for Clinical and Economic Review. Final Appraisal Document**, 2007.

[77] PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais - princípios, algoritmos e aplicações**. 1 ed. São Paulo: Thompson Learning, 2007.

[78] PIMENTEL, E. P.; FRANÇA, V. F.; and OMAR, N. (2003). A identificação de grupos de aprendizes no ensino presencial utilizando técnicas de clusterização. **Anais do Simpósio Brasileiro de Informática na Educação**, Rio de Janeiro, RJ. SBC.

[79] PEREIRA, R. Apostila de tomografia computadorizada. **Curso de Ciências Biológicas na UEG**. Disponível em:
«<http://www.ebah.com.br/content/ABAAAAtZoAL/apostila-tomografia-computadorizada?part=7>»
acesso em: 30/10/2016.

[80] PUGACHEV, A., and XING, L. Incorporating prior knowledge into beam orientation optimization in IMRT. **International Journal Radiation Oncology Biology Physics**, 54(5), 1565-

1574, 2002.

[81] PUGACHEV, A. Role of beam orientation optimization in intensity-modulated radiation therapy. **International Journal Radiation Oncology Biology Physics**, 50(2), 551-560. (2001).

[82] QUI, W., YUAN, J., UKWATTA, E., SUN, Y., RAJCHL, M. Prostate Segmentation: An Efficient Convex Optimization Approach with Axial Symmetry Using 3D TRUS and MR Images. **IEEE TRANSACTIONS ON MEDICAL IMAGING**, 2014.

[83] RASTGARPOUR, M.; SHANBEHZADEH, J. Application of AI Techniques in Medical Image Segmentation and Novel Categorization of Available Methods and Tools. **Proceedings of the International MultiConference of Engineers and Computer Scientists**, 2011 Vol I, IMECS 2011, March 16-18, 2011, Hong Kong.

[84] RHODEN, E.L.; AVERBECK, M.A. Câncer de próstata localizado. **Revista da AMRIGS**, Porto Alegre, 54 (1): 92-99, jan.-mar. 2010.

[85] ROMEIJN, H.E.; AHUJA, R.K.; DEMPSEY, J.F.; and KUMAR, A. A New Linear Programming Approach to Radiation Therapy Treatment Planning Problems. **Operations Research**, 54 (2), 201-216, 2006.

[86] SAAD, N.M., ABU-BAKAR, S.A.R., MUDA, S., MOKJI, M., ABDULLAH, A.R. Automated Region Growing for Segmentation of Brain Lesion in Diffusion-weighted MRI, **Proceedings of the International Multiconference of Engineers and Computer Scientists**, 2012, vol. I, IMECS 2012, Mar 14-16, 2012, Hong Kong.

[87] SARTI, A.; CORSI, C. ; MAZZINI, E. and LAMBERTI, C. Maximum likelihood segmentation of ultrasound images with Rayleigh distribution. **IEEE Trans Ultrason Ferroelect Freq Control**, 52(6): p. 947-960, 2005.

[88] SCHREIBMANN, E.; and XING, L. Feasibility study of beam orientation class solutions for prostate IMRT. **Medical Physics**, 31(10), 2863-2870, 2004.

[89] SCHULZ, J.; SKROVSETH, S.O.; TOMMERAS, V.K.; MARIENHAGEN, K. and GODTLIEBSEN, F. A semiautomatic tool for prostate segmentation in radiotherapy treatment planning. **BMC Medical Imaging**, 2014, 14:4.

- [90] SHARER, G. Analysis of Fuzzy Information. **Belief Functions and Possibility Measures**, 51-83, 1976.
- [91] SHAN, J., CHENG, H.D., WANG, Y. A completely automatic segmentation method for breast ultrasound images using region growing, **JCIS-2008 Proceedings**, 2008.
- [92] SHI, Y.; LIAO, S.; GAO, Y.; ZHANG, D.; GAO, Y.; SHEN, D. Prostate Segmentation in CT Images via Spatial-Constrained Transductive Lasso. **Computer Version Foundation**, 2013.
- [93] SIQUEIRA, M. L. **Reconhecimento automático de padrões em imagens ecocardiográficas**. Tese de doutorado, Universidade Federal do Rio Grande do Sul. Programa de Pós Graduação em Computação, Porto Alegre, 2010.
- [94] SILVA, F. C. **Um estudo sobre algoritmos genéticos, lógica fuzzy e técnicas para segmentação e classificação em imagens médicas**. Trabalho Individual I. Pelotas, 2008.
- [95] SILVA, J.S.; SANTOS, B.S.; SILVA, A. e MADEIRA, J. Modelos Deformáveis na Segmentação de Imagens Médicas: uma introdução. **Revista do DETUA**, 4(3), 2004.
- [96] SILVEIRA, T. B., BRUNING, F. F., Trinca, W. C., CALDEIRA FILHO, A. M., BATISTA, D. V. S.. IMRT com otimização de campos diretos no Eclipse. **In: XIV CONGRESSO BRASILEIRO DE FÍSICA MÉDICA**, São Paulo, 2009.
- [97] SINGH, P., SINGH, J. Automatic Seed Placement in Region Growing Image Segmentation, **Journal of Engineering, Computers & Applied Sciences (JEC&AS)**, Volume 2, No.7, July 2013.
- [98] SONG, X.; PETROVIC, S., AQND SUNDAR, S. A Case-Based Reasoning Approach to Dose Planning in Radiotherapy, Workshop Proceedings, **The Seventh International Conference on Case-Based Reasoning ICCBR 07**, Belfast, Northern Ireland, 348-357, 2007.
- [99] SROUGI, M. **Câncer da próstata: uma opinião médica**. Disponível em <<http://www.uronline.unifesp.br/uronline/ed1098/caprostata.htm>> acesso em: 30/04/2014.
- [100] STEINBACH, M.; KARYPIS, G.; KUMAR, V. A comparison of document clustering techniques. **KDD workshop on text mining**, 2000.
- [101] SURI, J.; WILSON, D.L.; LAXMINARAYAN, E S. eds. **Handbook of Biomedical**

Image Analysis. Vol. 2. 2005, Kluwer Academic/ Plenum Publishers: New York.

[102] TONNIES, K.D. Segmentation of Medical Images Using Adaptive Region Growing. **Proceedings of SPIE - The International Society for Optical Engineering**, · January 2002.

[103] TORRES, A.S. A. **Segmentação de imagens médicas visando a construção de modelos médicos**. Dissertação apresentada à Escola Superior de Tecnologia e Gestão. Instituto Politécnico de Bragança: novembro/2012.

[104] VAN DEN STEEN D, HULSTAERT F, CAMBERLIN C. Intensity-modulated radiotherapy (IMRT). **Health Technology Assessment (HTA)**. Brussels: Belgian Health Care Knowledge Centre (KCE); 2007. KCE reports 62C (D/2006/10.273/34).

[105] VOLPI, N. M. P.; OBAL, T.M.; GEVERT, V. G.; WILHELM, V. Um modelo de otimização integrado para os problemas da escolha de feixes de radiação e do mapa de fluência em radioterapia. **Simpósio Brasileiro de Pesquisa Operacional: A pesquisa operacional na busca de eficiência nos serviços públicos e/ou privados**. Natal: 2013.

[106] VROOMAN, H.A.; CA, C.A.C.; STOKKING, R.; ARFAN, I.M.; VEMOOIJ, M.W.; BRETELER, M.M.; NIESSEN, W.J. kNN-based multi-spectral MRI brain tissue classification: manual training versus automated atlas-based training. **SPIE Medical Imaging**, 2006.

[107] WAKE, G. M. G. H., BOLAND, N., JENNINGS, L. Mixed integer programming approaches to exact minimization of total treatment time in câncer radiotherapy using multileaf collimators. **Computer and Operational Research**, v.36, p.795-810, 2009.

[108] WEBB, S. Optimization of conformal radiotherapy dose distributions by simulated annealing. **Physics in Medicine and Biology**, 34,1349-1369, 1989.

[109] WITHEY, D.J.; KOLES, Z.J. Medical Image Segmentation: Methods and Software. **IEEE/IET Electronic Library (IEL)**, 2007.

[110] WONG, K. P. **Handbook of Biomedical Image Analysis**, ed. E. Micheli-Tzanakou. Vol. II - Segmentation Models. New Jersey: Kluwer Academic / Plenum Publishers, 2005.

[111] WORLD, Health Organization. Policies and managerial guidelines for national cancer control programs. **Rev Panam Salud Publica**, 12(5), 2002.

[112] WU, Q.; DJAJAPUTRA, D.; LAUTERBACH, M.; WU, Y.; MOHAN, R. Fast dose calculation method based on table lookup for IMRT optimization. **Physics in Medicine and Biology**, 48, 159-166, 2003.

[113] WU, D. Supplier selection in a fuzzy group setting: A method using grey related analysis and Dempster-Shafer theory. **Expert Systems with Applications**, 36, 8892-8899, 2009.

[114] YANG, R.; DAI, J.; YANG, Y.; HU, Y. Beam orientation optimization for intensity-modulated radiation therapy using mixed integer programming. **World Congress on Medical Physics and Biomedical Engineering**, 14, 1758-62, 2006.

[115] YASHPAL, G. M.; GOKHALE, A.V. Color Image Segmentation Based on Automatic Seed Pixel Selection, **IJCEM International Journal of Computational Engineering & Management**, Vol. 15 Issue 3, May 2012.

[116] YU, Y.; ZHANG, J.B.; CHENG, G.; SCHELL, M.C.; OKUNIEFF, P. Multi-objective optimization in radiotherapy: applications to stereotactic radiosurgery and prostate brachytherapy. **Artificial Intelligence in Medicine**, 19, 39-51, 2000.

[117] YUVARAJ, K. and RAGUPATHY, U.S. Automatic Mammographic Mass Segmentation based on Region Growing Technique, 3rd International Conference on Electronics, **Biomedical Engineering and its Applications (ICEBEA'2013)**, April 29-30, 2013 Singapore.

[118] ZACHARY JM, I. Content-based image retrieval systems. **Proceedings of the IEEE Symposium on Application-Specific Systems and Software Engineering and Technology**, 136-43, 1999.

[119] ZHANG, Y.J. An overview of image and video segmentation in the last 40 years. In: Zhang, Y.J. (Ed.), **Advances in Image and Video Segmentation**. IRM Press, 1-15, 2006.

Apêndice A



IV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO
Ponta Grossa, PR, Brasil, 03 a 05 de Dezembro de 2014

Artigo ConbRepro 2014

Processamento de imagens médicas na radioterapia: algoritmos de segmentação para região pélvica masculina

Vania Gryczak Gevert (Universidade Federal do Paraná-UFPR) vaniggz@hotmail.com
Thalita Monteiro Ohal (UTFPR) thalital@gmail.com
Neida Maria Patias Volpi (Universidade Federal do Paraná-UFPR) neidavolpi@gmail.com
Volmir Eugenio Wilhelm (Universidade Federal do Paraná-UFPR) volmirw@gmail.com

Resumo:

Nos últimos anos, o aumento da incidência de casos de câncer de próstata vem se tornando um desafio para a ciência médica. Uma das modalidades de tratamento é a radioterapia de intensidade modulada, IMRT, que permite conformar a dose de radiação em imagens de duas ou três dimensões. Uma das fases do planejamento consiste na segmentação das estruturas de interesse, tais como tumor e órgãos nobres e saudáveis, que é realizada manualmente, tarefa que demanda tempo do especialista, limitando o número de planejamentos efetuados. O objetivo principal deste trabalho é o processamento e análise de imagens da região da próstata (região pélvica masculina). A pesquisa contou com o envolvimento de profissionais do Hospital Erasto Gaertner, que forneceram as imagens de tomografia computadorizada dos pacientes em tratamento. Na segmentação das estruturas de interesse, foi realizado um pré-processamento das imagens (filtragem e equalização), em seguida, aplicou-se alguns métodos de segmentação, como crescimento de regiões (*region growing*, *clustering*) e métodos baseados em forma. Os resultados apresentam os diversos tipos de filtragem e segmentação de imagens médicas da região da próstata. Contudo, os modelos de *region growing*, são os que apresentaram melhores resultados com 97,53% de acertos nos *pixels* quando comparados à segmentação manual.

Palavras chave: Processamento de imagens, Algoritmos de segmentação, Radioterapia.

Medical imaging processing in radiotherapy: segmentation algorithms for male pelvic region

Abstract

In recent years, the increasing incidence of prostate cancer has become a challenge to the medical science. One of the treatment modalities is intensity-modulated radiotherapy, IMRT, allowing conform the radiation dose images in two or three dimensions. One stage of planning is the segmentation of structures of interest, such as tumor and noble and healthy organs, which is performed manually, a task that takes time specialist and limit the number of plans. The objective of this work is the processing and analysis of images of the prostate region (male pelvic region). The research included the involvement of professionals Erasto Gaertner Hospital, who provided the CT images of patients in treatment. To the segmentation of the interest structures, a pre-processing of the images (filtering and equalization) was done, and then, we applied some segmentation methods such as region growing, clustering and methods based on shape. The results show the various types of filtering and segmentation of medical images of the prostate region. However, models of region growing are the ones that showed the best results with 97.53% accuracy in pixels compared to the manual segmentation.

Key-words: Medical imaging processing, segmentation algorithms, radiotherapy.

1. Introdução

O câncer é um problema de saúde pública em países desenvolvidos e em desenvolvimento. Responsável por mais de seis milhões de óbitos a cada ano, representa cerca de 12% de todas as causas de morte no mundo (WORLD HEALTH ORGANIZATION, 2002).

De acordo com estimativas mundiais do projeto Globocan 2012, da Agência Internacional para Pesquisa em Câncer (IARC do inglês *International Agency for Research on Cancer*) da Organização Mundial da Saúde (OMS), foram registrados 14,1 milhões de novos casos, e um total de 8,2 milhões de mortes por câncer em todo o mundo naquele ano.

No Brasil, a estimativa para o ano de 2014, que será válida também para o ano de 2015, aponta para a ocorrência de aproximadamente 576 mil novos casos, incluindo os de pele não melanoma, reforçando a magnitude do problema do câncer no país. O câncer de pele do tipo não melanoma (182 mil casos novos) será o mais incidente na população brasileira, seguido pelos tumores de próstata (69 mil), mama feminina (57 mil), cólon e reto (33 mil), pulmão (27 mil), estômago (20 mil) e colo do útero (15 mil).

O câncer de próstata é o segundo mais comum entre os homens (atrás apenas do câncer de pele não-melanoma). Em valores absolutos, é o sexto tipo mais comum no mundo e o mais prevalente em homens, representando cerca de 10% do total. O único fator de risco bem estabelecido para o desenvolvimento do câncer de próstata é a idade. Aproximadamente 62% dos casos diagnosticados no mundo ocorrem em homens com 65 anos ou mais. Com o aumento da expectativa de vida mundial, é esperado que o número de casos novos aumente cerca de 60% até o ano de 2015 (INCA, 2014).

A teleterapia, ou radioterapia externa, é uma modalidade de tratamento que objetiva a administração de uma dose de radiação ionizante, num volume tumoral previamente definido, buscando diminuir ou erradicar o tumor, minimizando os danos nos tecidos adjacentes. Pode ser utilizada individualmente, ou agregada em outras estratégias de tratamento.

O primeiro passo no planejamento da radioterapia externa é delinear (segmentar) previamente a forma do tumor e dos órgãos nobres que devem ser protegidos da radiação, garantindo assim, a aproximação da dose prescrita no volume alvo.

As consequências clínicas por imprecisão incluem uma subdosagem em volumes alvos (aumentando os riscos de recorrência do tumor) e uma superdosagem nos tecidos normais (com aumento no risco de complicações). Atualmente o contorno dos órgãos é feito de forma manual por um radioterapeuta ou dosimetrista. Tratando-se de imagens tridimensionais, esta tarefa pode ser desgastante e demanda tempo do especialista.

Desta forma, a segmentação adequada de imagens médicas representa uma etapa crucial no desenvolvimento de modelos biomecânicos realistas que auxiliem os profissionais de saúde, tanto no apoio à tomada de decisão como no treino desses profissionais e na consequente redução de custos (SILVA, 2011). Além disso, com o crescente número de pacientes e a demanda de especialistas em cuidados da saúde não acompanhando este crescimento, faz com que seja imprescindível a implementação de estratégias de aceleração do planejamento, tais como a segmentação automática (ou semi automática) das imagens.

2. Processamento digital de imagens médicas

O avanço tecnológico dos métodos de diagnóstico por imagem evoluiu consideravelmente. O diagnóstico por imagem revolucionou a medicina de tal forma que hoje é praticamente inviável a detecção de muitos problemas sem a utilização de algum tipo de imagem. A área de diagnóstico por imagem tem acompanhado a evolução tecnológica digital (SIQUEIRA, 2010).

Para a manipulação de imagens utilizando ferramentas computacionais, podem ser necessárias etapas no processamento de imagens, dentre elas, a aquisição, o pré-processamento, a segmentação e a análise de imagens (PEDRINI; SCHWARTZ, 2007).

A etapa de aquisição consiste na obtenção das imagens a serem processadas; o pré-processamento visa à melhora da qualidade da imagem (redução de ruído, aumento de contraste, suavização) e sua adequação às fases posteriores; o objetivo da segmentação é identificar regiões similares; a análise e reconhecimento é a etapa onde as informações presentes na imagem são interpretadas.

A aquisição de imagens médicas consiste em obter imagens do corpo humano. Essa etapa do processamento não é implementada em *software* e necessita de *hardware* especializado. Os dispositivos de captura de imagens (*scanners*) variam conforme o tipo das imagens de interesse (Tomografia Computadorizada, Ressonância Magnética, Ultra-Som, Raio-X, entre outros) (SIQUEIRA, 2010).

As imagens deste trabalho foram adquiridas com o uso da tomografia computadorizada (TC) e são disponibilizadas no formato DICOM, uma plataforma em que é possível visualizar e manipular imagens médicas.

Os tecidos do corpo são divididos em três classes: tumor (T), tecidos saudáveis(S) e tecidos nobres (N). Para efeito do cálculo da dose, os tecidos são segmentados de forma a que se delimitem as fronteiras entre cada tipo de tecido. Depois de segmentados, os tecidos são discretizados em unidades de cálculo cúbicas. As unidades cúbicas são tratadas utilizando seções planares denominadas *pixels*.

A imagem resultante do passo anterior pode apresentar diversas imperfeições, tais como: presença de *pixels* ruidosos, contraste e/ou brilho inadequado, caracteres interrompidos ou indevidamente conectados. A função da etapa de pré-processamento é aprimorar a qualidade da imagem para as etapas subsequentes. As operações efetuadas nesta etapa são ditas de baixo nível porque trabalham diretamente com os valores de intensidade dos *pixels*, tais como redução de ruído, aumento de contraste e suavização de imagem.

A filtragem é realizada *pixel a pixel*, onde o novo nível de cinza de um ponto P qualquer depende do seu nível de cinza original e de outros pontos considerados como vizinhança de P. Em geral, os pontos mais próximos de P contribuem mais para o novo valor do nível de cinza do que os pontos mais afastados.

Nos filtros de realce, os detalhes “finos” ou variações abruptas numa imagem, correspondem às componentes de alta frequência, enquanto os detalhes mais “grosseiros”, caracterizados por variações mais lentas, permitindo uma visualização menos detalhada da imagem, surgem como componentes de baixa frequência.

Nos filtros de suavização, os contornos e transições contribuem para a componente de altas frequências da Transformada de Fourier (TF) de uma imagem. A suavização no domínio das frequências é realizada utilizando a atenuação de um determinado intervalo de componentes de altas frequências na transformada de uma imagem.

A segmentação permite a compreensão, análise e interpretação de imagens. O principal objetivo é a divisão da imagem original em regiões (ou classes) homogêneas relativamente a uma ou mais características. A aplicação mais visível desta técnica em imagens médicas é a localização anatômica de órgãos, ou em termos genéricos, a região de delimitação de interesse, cujo principal objetivo é delinear as estruturas anatômicas e as regiões (patológicas) de interesse (GHISTA, 2008).

O processo de segmentação de uma imagem consiste na divisão de seus elementos *pixels* em

múltiplas regiões, analisando suas características comuns, ou seja, extraindo objetos ou áreas de interesse presentes na imagem.

De acordo com Parraga (2008), com o avanço dos equipamentos de auxílio ao diagnóstico e sistemas cirúrgicos cada vez menos invasivos, novos métodos de segmentação automática também são propostos para automatizar a tarefa manual e torná-la mais precisa e reproduzível. Para que estes métodos sejam usados clinicamente, auxiliando no diagnóstico, planejamento e tratamento de patologias por imagem, os algoritmos ainda devem ser exaustivamente testados e melhorados tornando-se mais precisos, rápidos e automáticos.

Neste trabalho são utilizadas imagens em níveis de cinza, ou seja, a imagem é representada por um conjunto finito de números inteiros que vai de 0 a 255, onde cada valor é um nível de cinza, que representará cada ponto da imagem. Os algoritmos de segmentação de imagens em níveis de cinza geralmente são baseados em uma das duas propriedades: descontinuidade e similaridade. Há um grande número de técnicas de segmentação, propostas e implementadas, mas ainda não há um *standard* que satisfaça todos os critérios.

Segundo Torres (2012), os métodos de segmentação podem ser divididos nas seguintes categorias:

- Binarização (ex. *threshold*);
- Baseados na região (*region growing*, *watershed*);
- Métodos estatísticos (*fuzzy C-means*, *K-means*);
- Métodos baseados em forma;
- Baseados no contorno (ex. *canny*).

Cada um destes métodos está descrito nos itens 2.1 a 2.4.

2.1 Algoritmos de *threshold*

Este tipo de algoritmo baseia-se no princípio de que as estruturas ou órgãos de interesse têm características distintas quantificáveis, tais como a intensidade ou magnitude do gradiente da imagem. O processo de segmentação baseia-se na busca de *pixels* cujos valores estão dentro dos intervalos definidos pelos limiares (*thresholds*).

O método mais utilizado é a média de *thresholds* devido à sua simplicidade de implementação e propriedades intuitivas. Nesta técnica, um valor predefinido (*threshold*) é selecionado manual ou automaticamente, e uma imagem é dividida em grupos de *pixels* com valores iguais ou superiores ao limiar, e grupos de *pixels* com valores inferiores a esse limiar.

Quando apenas um limiar é selecionado para toda a imagem, com base no histograma da imagem, é usualmente chamado de *thresholding* global. Se o *threshold* depende de propriedades locais de algumas regiões da imagem, por exemplo, o valor médio local de cinza, o *threshold* é chamado local. Se os *thresholds* são selecionados de forma independente para cada *pixel* ou grupo de *pixels*, é chamado de dinâmico ou adaptativo (PHAM, 2000).

Conforme Silva (2011) a abordagem mais intuitiva é *thresholding* global, sendo o método de Otsu o mais generalizado, simples e computacionalmente rápido. Baseia-se no pressuposto que uma imagem pode ser representada por um histograma bimodal e, conseqüentemente, pode-se obter a estrutura de interesse com uma simples operação que compara os valores da imagem com o valor definido para o *threshold*.

2.2 Algoritmos baseados em regiões

A partição da imagem baseada no conteúdo de grupos de *pixels* é chamada de segmentação orientada ou baseada em regiões. De uma maneira ideal, uma partição será associada a um padrão, objeto ou parte dele numa imagem. Portanto, para uma imagem ser interpretada corretamente, é necessário particioná-la em regiões que correspondam aos objetos ou padrões. O processo consiste na separação destas regiões.

As abordagens de segmentação baseadas em regiões fazem a análise de *pixels* de uma imagem e formam regiões disjuntas agrupando *pixels* vizinhos com propriedades de homogeneidade baseadas em critérios de similaridade pré-definidos (MA, 2010).

A técnica mais simples de segmentação baseada em regiões é chamada *region growing* (crescimento por regiões), e faz o agrupamento em segmentos de *pixels* que possuem propriedades similares. Esta técnica começa com um *pixel*, ou grupo de *pixels*, chamada(s) de semente(s), que pertence(m) à estrutura de interesse.

A(s) semente(s) pode(m) ser escolhida(s) pelo operador ou determinada(s) automaticamente. A seguir, a vizinhança de cada semente é inspecionada e os *pixels* semelhantes são adicionados à região da semente original, e assim, a região vai crescendo. O processo continua até que mais nenhum *pixel* possa ser acrescentado. É possível que alguns *pixels* possam permanecer sem rótulo, isto é, estarem isolados, quando pára o processo de crescimento (BANKMAN, 2000; WITHEY, 2007).

Os resultados do *region growing* dependem da escolha do critério de homogeneidade. Se não for escolhido corretamente, as regiões escapam para áreas adjacentes e fundem-se com as regiões que não pertencem ao objeto de interesse. Outro problema desta técnica é que diferentes pontos de partida não podem crescer em regiões idênticas (MITCHELL, 2002).

A vantagem da técnica de *region growing* é permitir a segmentação correta de regiões que têm as mesmas propriedades e estão espacialmente separadas, gerando ainda regiões conectadas entre si.

Os métodos de *region splitting* (divisão por regiões) têm uma estratégia oposta à do *region growing*. Esses métodos partem de toda a imagem e examinam os critérios de homogeneidade. Se os critérios não se encontram, a imagem (ou sub-imagem) é dividida em duas ou mais subimagens. Este processo termina quando todas as sub-imagens satisfazem os critérios de homogeneidade. Uma combinação de segmentação por *region splitting* e por *region growing* soma os benefícios de ambas as abordagens (WONG, 2005).

A segmentação por *watershed* (Método do Divisor de Águas) é uma técnica baseada em regiões que utiliza a morfologia da imagem (BANKMAN, 2000).

É necessário que se faça a seleção de pelo menos um marcador (semente) interior a cada objeto da imagem, incluindo tanto o fundo, como os objetos a segmentar. Usualmente, o utilizador é responsável pela seleção dos marcadores. Contudo, estes também podem ser selecionados por um procedimento automático que considere conhecimentos específicos sobre os objetos.

A ideia básica do *watershed* é dada pela imagem da tradução em português do nome: um divisor de águas é uma cadeia de montanhas, que divide a água da chuva em regiões para onde ela escorre. O *watershed* utiliza os módulos dos gradientes, as variações locais de intensidade na imagem, como uma “topografia” montanhosa que separa regiões. Fundem-se regiões aumentando a altura da água que “chove” na imagem. A grande vantagem deste método é a sua rapidez de processamento, permitindo que seja utilizado em aplicações interativas, mesmo quando as imagens a processar são grandes e complexas (WONG, 2005).

Apêndice B

Segmentação Paciente 8

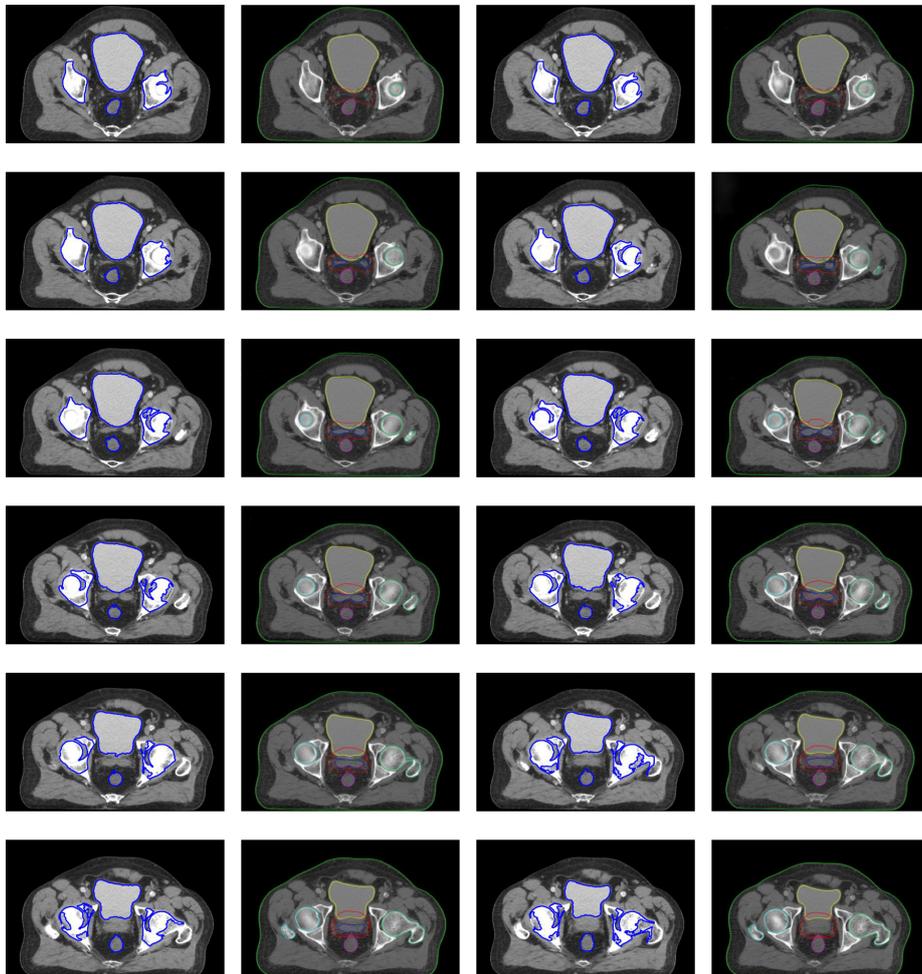


Figura B.1: 12 imagens com segmentação manual pelo dosimetrista (colunas 1 e3) comparadas com a segmentação automática pela metodologia proposta (colunas 2 e 4)

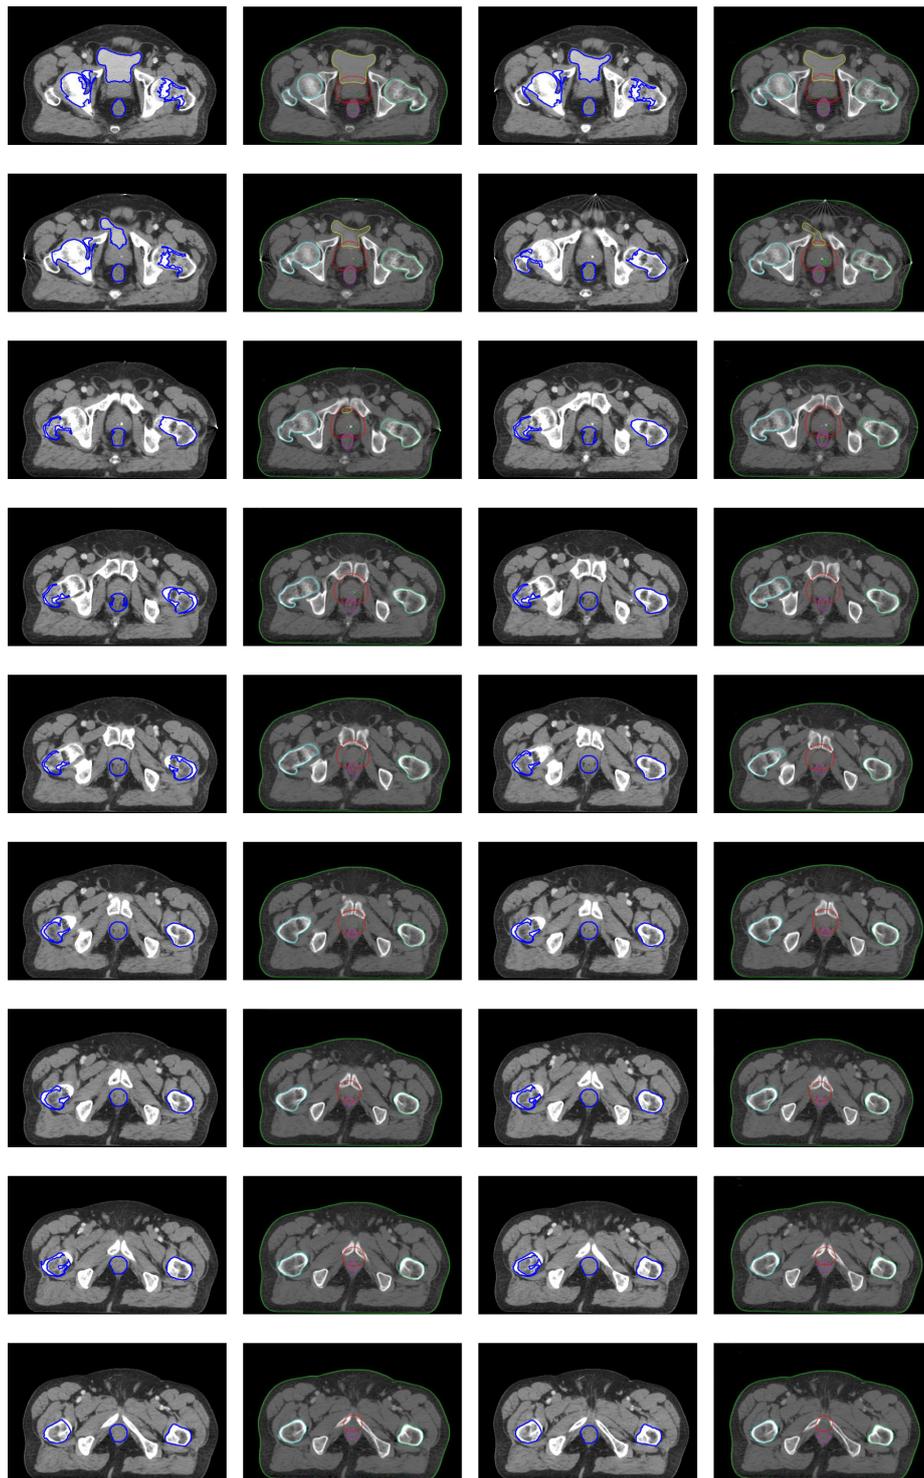


Figura B.2: 18 imagens com segmentação manual pelo dosimetrista (colunas 1 e3) comparadas com a segmentação automática pela metodologia proposta (colunas 2 e 4)