

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

Vania Gryczak Gevert (Universidade Federal do Paraná-UFPR) [vaniagg2@hotmail.com](mailto:vaniagg2@hotmail.com)  
Thalita Monteiro Obal (UTFPR) [thaliobal@gmail.com](mailto:thaliobal@gmail.com)  
Neida Maria Patias Volpi (Universidade Federal do Paraná-UFPR) [neidavolpi@gmail.com](mailto:neidavolpi@gmail.com)  
Volmir Eugenio Wilhelm (Universidade Federal do Paraná-UFPR) [volmirw@gmail.com](mailto: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).

### 2.3 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, 2007; McINERNEY, 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, 2006), *maximum likelihood* (ML) *algorithms* (SARTI, 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) (JAMES, 1985).

As não supervisionadas são: *CM algorithms fuzzy C-means* (FCM) (JACOBS, 2000), *algorithms iterative self-organising data analysis technique algorithms* (ISODATA) (JACOBS, 2000) 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).

### 2.4 Algoritmo *K-means*

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.

## 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.

Utilizou-se o *software* MATLAB para o desenvolvimento dos algoritmos de segmentação e otimização. A região utilizada para a validação dos algoritmos implementados foi a da próstata (região pélvica masculina), e as imagens obtidas em formato DICOM.

Para a etapa de pré-processamento, foi utilizada a equalização do histograma. Técnicas de filtragem de imagens também foram aplicadas para comparar os resultados de segmentação.

Os filtros utilizados foram: filtro de média, laplaciano, gaussiano, laplaciano do gaussiano (loG), *unsharp*, *prewitt*, *sobel* e *disk*.

Os algoritmos de segmentação aplicados baseiam-se em similaridades: limiarização (*thresholding*), crescimento de regiões (*region growing*) e aglomeração (*clustering*).

#### 4. Resultados e discussões

Os testes realizados utilizaram a região pélvica masculina (região da próstata), considerando apenas um paciente com imagens bidimensionais de TC (Figura 1). É necessário considerar as regiões de interesse como tecidos nobres (reto, bexiga e cabeça de fêmur), tumor (próstata) e tecidos saudáveis (demais regiões), delineadas na figura 1. A imagem inicial tem 512x512 *pixels*, mas foi recortada para que se aproximasse da anatomia do paciente, alterando seu tamanho para 191x341 *pixels*.




Figura 1 - Regiões de interesse

Para ajustar o contraste e luminosidade, foi utilizada a função *imadjust* do Matlab. Os parâmetros de entrada dessa função são: [*low in*; *high in*], [*low out*; *high out*]. Esses valores têm que estar no intervalo 0 e 1 tanto para a luminosidade como para o contraste.

As imagens alterando o contraste e luminosidades foram obtidas com os parâmetros:  $g1 = imadjust(I, [0 \ 1], [1 \ 0])$ ;  $g2 = imadjust(I, [0.5 \ 0.75], [0 \ 1])$ ;  $g3 = imadjust(I, [ \ ], [ \ ], 2)$ .

Terminada a etapa de equalização e ajuste de contraste e luminosidade, utilizou-se a filtragem para redução de ruídos e suavização das imagens e posteriormente a segmentação das regiões de interesse (nobres, saudáveis e tumor).

Para avaliação da imagem, compararam-se os *pixels* da região segmentada pelo dosimetrista e os *pixels* da imagem segmentada pelo algoritmo escolhido. Chamou-se de erro aos *pixels* que não foram classificados como o dosimetrista e acerto aos *pixels* equivalentes, embora a classificação feita pelo dosimetrista possa não estar correta.

##### 4.1 Resultados da Segmentação com algoritmo *threshold*

O *threshold* utilizado foi o método de Otsu, para a imagem original,  $g1$ ,  $g2$ ,  $g3$ , filtradas e equalizadas. É necessário escolher o número de divisões da imagem, e nos testes realizados utilizou-se 3 regiões.

A tabela 1 apresenta os percentuais totais de acertos e erros de *pixels*, a quantidade de *pixels* classificados erroneamente nos tecidos tumor e nobres (TN) e tecidos saudáveis (S), e a quantidade de *pixels* classificados corretamente no TN e o no tecido S.

Imagem	Acertos (%)	Erros (%)	Erro TN	Erros S	Acertos TN	Acertos S
disk	92,88	7,12	499	253	1117	8680
g2	92,84	7,16	443	313	1173	8620
g3	92,85	7,15	432	323	1184	8610
gaussiano	92,98	7,01	353	387	1263	8546
gaussianoeqg2	92,84	7,16	419	337	1197	8596
medianag2	93,03	6,97	420	316	1196	8617
original	93,03	6,97	360	376	1256	8557
media	93,01	6,99	338	400	1278	8533

Fonte: O autor (2014)

Tabela 1 – Comparação dos pixels da imagem segmentada dosimetrista e Otsu

As três imagens com maior porcentagem de acerto foram: imagem original (figura 2), média (figura 3) e medianag2. A imagem medianag2 (imagem g2 com filtro de mediana) foi descartada, pois não foi possível a visualização da região do reto e da próstata.




Figura 2 – *Threshold* Otsu imagem original




Figura 3 - *Threshold* Otsu imagem original com filtro de média

As três imagens apresentam três regiões distintas (vermelho, azul e verde). Observa-se que a região do reto (tecidos nobres) teria que estar classificada na mesma região que bexiga e cabeça de fêmur (vermelho). Para contornar esse problema, foi segmentado manualmente o reto e a próstata, classificando essas duas regiões em nobres e tumor, respectivamente.

O algoritmo atende as expectativas de segmentação de imagens.



#### 4.2 Resultados do *region growing*

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.

Os *pixels* semente escolhidos na imagem, eixo x e eixo y, respectivamente, foram (56, 170) para a região da bexiga, (85, 84) para cabeça de fêmur à esquerda, (85,258) para cabeça de fêmur à direita, (140, 173) para reto e (99,178) para a próstata.

Igualmente a segmentação Otsu, comparou-se os *pixels* da região segmentada pelo dosimetrista e os *pixels* da imagem segmentada pelo método *region growing*. A tabela 2 apresenta os percentuais totais de acertos e erros de *pixels*, a quantidade de *pixels* classificados erroneamente nos tecidos tumor e nobres (TN) e tecidos saudáveis (S), e a quantidade de *pixels* classificados corretamente no TN e o no tecido S.

Imagem	Acertos (%)	Erros (%)	Erro TN	Erros S	Acertos TN	Acertos S
Original	97,53	2,47	192	69	1424	8864
g1	97,53	2,47	192	69	1424	8864
g3	96,57	3,43	329	32	1287	8901
Media	96,95	3,05	306	16	1310	8917

Fonte: O autor (2014)

Tabela 2 – Comparação dos pixels da imagem segmentada dosimetrista e método *region growing*

As três imagens com maior porcentagem de acerto foram média (figura 4), g1 (figura 5) e imagem original (figura 6). Dentre estas possibilidades, as imagens escolhidas poderiam ser a original e a g1, com 97,53% de acertos nos *pixels*.




Figura 4 – *Region growing* da imagem original *threshold* igual a vinte e as regiões segmentadas




Figura 5 - *Region growing* da imagem original *threshold* igual a vinte, com filtro de média, e as regiões segmentadas




Figura 6 - *Region growing* da imagem G1 *threshold* igual a vinte e as regiões segmentadas

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. 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. Outra desvantagem prende-se com o fato de sementes colocadas em regiões iniciais diferentes poderem originar segmentações distintas para uma mesma imagem.

#### 4.3 Resultados do *K-means clustering*

Para a técnica de clusterização, é necessária a escolha da imagem e a quantidade de regiões que ela deve ser segmentada, neste caso, três regiões.

A tabela 3 apresenta a comparação entre os *pixels* classificados na região segmentada pelo dosimetrista e os *pixels* da imagem segmentada pelo método escolhido.

Imagem	Acertos (%)	Erros (%)	Erro TN	Erros S	Acertos TN	Acertos S
mediana	93,05	6,95	340	393	1276	8540
media	93,03	6,97	337	399	1279	8534
sharpened	92,83	7,17	379	378	1237	8555
prewitt	83,58	16,42	1537	196	79	8737
equalizada	73,89	26,11	158	2597	1458	6336
gaussiano	93,03	6,97	343	393	1273	8540
laplaciano	84,52	15,48	1615	18	1	8915

Fonte: O autor (2014)

Tabela 3 – Comparação dos *pixels* da imagem segmentada dosimetrista e método *K-means*

A imagem escolhida foi a original com filtro mediana (figura 7).




Figura 7 – Segmentação *k-means* da imagem original com filtro de mediana e número de *clusters* igual a três

A imagem apresenta três regiões distintas (vermelho claro, vermelho escuro e azul). Observa-se, assim como no método de Otsu, que a região do reto (tecidos nobres) teria que estar classificada na mesma região que bexiga e cabeça de fêmur (vermelho escuro). Foi segmentado manualmente o reto e a próstata, classificando essas duas regiões em nobres e tumor, respectivamente.

## 5. Considerações finais

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

A segmentação automática de estruturas em imagens médicas constitui um desafio, devido a fatores como o tamanho dos conjuntos de dados envolvidos, a complexidade e variabilidade das estruturas a segmentar e outros inerentes às limitações típicas dos dados utilizados.

Existe um grande número de algoritmos de segmentação de imagem para detecção de tais estruturas, e todos eles possuem de uma forma ou de outra, variadas aplicações na área médica. Contudo, os modelos de *region growing*, são os que apresentaram melhores resultados com 97,53% de acertos nos *pixels* quando comparados à segmentação do dosimetrista.

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 espera dos pacientes.

## 6. Agradecimentos

Agradecemos à Equipe de radioterapia do Hospital Erasto Gaertner (Curitiba-Pr), o apoio da Capes e a Universidade Federal do Paraná – UFPR.

## Referências

- BANKMAN, I.N.** *Handbook Medical Imaging Processing Analysis*. 2000, Academic Press: San Diego/London.
- FONTANA, A., NALDI, M. C.** *Estudo de Comparação de Métodos para Estimativa de Números de Grupos em Problemas de Agrupamento de Dados*. Universidade de São Paulo. ISSN - 0103-2569, 2009.
- GHISTA, D. N.** *Applied Biomedical Engineering Mechanics*. 2008, New York: CRC Press. 592.
- 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.
- 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.
- JAMES, M.** *Classification algorithms*. NY: Wiley-Interscience, 1985.
- JAIN, A. K., MURTY, M. N., and FLYNN, P. J.** *Data clustering: a review*. ACM Computer Survey, 264-323, 1999.
- 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.
- 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.

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

**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.

**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.

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

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

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

**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.

**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.

**SILVA, P.F.; MA, Z.; TAVARES, J.M.** *Segmentação de imagem médica: algoritmos para a aplicação à cavidade pélvica feminina.* CIBEM 10, Oporto, Portugal, 2011.

**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.

**VROOMAN, H.A.; CA, C.A.C.; STOKKING, R.; ARFAN, I.M.; VEMOOLJ, 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.

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

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

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