

# Segmentação de Vasos Sanguíneos do Pulmão em Imagens de Tomografia Computadorizada do Tórax

Alyson B. N. Ribeiro, Paulo C. Cortez, Tarique S. Cavalcante, Pedro P. Rebouças Filho

Departamento de Teleinformática – Universidade Federal do Ceará (UFC)  
Fortaleza – CE – Brasil

alysonb01@yahoo.com.br cortez@lesc.ufc.br, tarique@lesc.ufc.br,  
pedrosa\_rf@hotmail.com

**Abstract.** *Several studies confirmed the benefits of medical image analysis through computer vision. Segmentation of the lung blood vessels is very useful to detect some diseases, among which highlighted the embolism and the pulmonary hypertension. In this paper the blood vessels were segmented from lung CT images using two methodologies. The first method refers to a combination of 3D Region Growing controlled by a Gaussian membership function and thresholding, the second is targeting a hybrid Fuzzy Connectivity and thresholding. Finally, we present satisfactory results of blood vessels segmentation.*

**Resumo.** *Diversos estudos comprovam os benefícios da análise de imagens médicas por meio de visão computacional. A segmentação de vasos sanguíneos do pulmão é de bastante auxílio na detecção de diversas patologias, entre as quais se destacam a hipertensão pulmonar e o embolismo. Neste trabalho, foram segmentados os vasos sanguíneos pulmonares de imagens de TC do tórax utilizando-se de duas metodologias. A primeira trata-se de uma combinação de Crescimento de Regiões 3D controlado por uma função de pertinência gaussiana e limiarização, a segunda um híbrido de segmentação por Conectividade Fuzzy e limiarização. Por fim, são apresentados resultados satisfatórios da segmentação dos vasos sanguíneos.*

## 1. Introdução

A análise de imagens médicas por meio de técnicas de visão computacional tornou-se bastante promissora pelo fato de aperfeiçoar a acurácia diagnóstica de diversas patologias [Doi, 2006]. Em pneumologia, diversos projetos de visão computacional são desenvolvidos com intuito de prover um auxílio eficaz ao diagnóstico de patologias pulmonares, tal como podem ser observados nos trabalhos de Félix (2007), Rebouças Filho (2010), Cavalcante (2010) e Kaftan *et al.* (2008).

A importância do estudo de patologias pulmonares é evidente, visto a ocorrência em grande parte da população mundial em que é fundamental a necessidade de um diagnóstico exato dessas patologias de forma precoce e, assim, detectar os reais estágios das doenças pulmonares, nas quais por muitos casos a identificação dos vasos sanguíneos é um fator determinante [Robbins e Cotran, 2005].

Os vasos sanguíneos pulmonares são importantes objetos de estudo, visto que sua segmentação, visualização em três dimensões e extração de atributos tornou bem

mais prática a detecção de doenças, por exemplo, o câncer [Tozaki *et al.*, 1996], hipertensão pulmonar [Linguraru *et al.*, 2008] e embolismo [Masutani *et al.*, 2002].

No trabalho desenvolvido por Kaftan *et al* (2008) foi utilizada a teoria de Conectividade *Fuzzy* para efetuar a segmentação dos vasos. Inicialmente é aplicada uma limiarização combinada com Crescimento de Regiões para segmentar o pulmão. Após essa etapa é realizada a determinação de sementes através da transformada da distância. Por fim, essas sementes serão parâmetros na análise de Conectividade *Fuzzy* na identificação dos vasos sanguíneos.

Já Sato *et al* (1998) segmentou os vasos utilizando filtragem multi-escalar linear 3D baseada em uma combinação dos autovalores da matriz de Hessian. Essa integração é formulada tomando a máxima resposta do filtro, em que suas características são examinadas para a seleção de parâmetros da formulação.

A proposta de Zhu (2009) foi desenvolver um contorno ativo com algoritmo *level set* (VOLES: *Vascularity-Oriented Level Set algorithm*). Primeiramente segmenta-se o pulmão por meio de Crescimento de Regiões 3D para, deste modo, utilizar o VOLES na segmentação dos vasos, na qual há uma análise dos autovalores da matriz de Hessian como fator determinante na identificação das estruturas a serem segmentadas.

Neste sentido, com intuito de obter um modelo flexível de segmentação, foram extraídos vasos sanguíneos pulmonares de imagens de tomografia computadorizada do tórax utilizando-se duas metodologias. A primeira trata-se de uma combinação de Crescimento de Regiões 3D controlado por uma função de pertinência gaussiana e limiarização, a segunda um híbrido de segmentação por Conectividade *Fuzzy* e limiarização.

Na seção 2 é realizada uma breve revisão dos trabalhos que abordam a segmentação dos vasos sanguíneos pulmonares bem como são discutidas as características dos métodos de segmentação utilizados no presente estudo. Na seção 3 são apresentadas as etapas do processo de segmentação dos vasos sanguíneos. Na seção 4 são apresentados os resultados obtidos referentes a cada um dos algoritmos. Por fim, na seção 5 são feitas conclusões relativas aos resultados obtidos da aplicação dos algoritmos.

## **2. Fundamentação Teórica**

As imagens de tomografia podem ser obtidas em plano axial e coronal. Após a sua obtenção, recursos computacionais podem permitir reconstruções no plano sagital ou reconstruções tridimensionais, em que essa análise de seções transversais do corpo é um dos motivos que torna vantajosa a utilização de imagens de TC na análise de patologias que afetam o pulmão. Nas imagens de tomografia computadorizada do tórax é possível a visualização de diversas estruturas, como vasos sanguíneos, vias aéreas, hilo, pleura e parênquima pulmonar (Cavalcante, 2010).

### **2.1. Segmentação do Pulmão**

A primeira etapa para identificação dos vasos sanguíneos é a segmentação do pulmão. Trata-se de uma importante etapa de pré-processamento, em que se reduz consideravelmente o custo computacional e simplifica a identificação dos vasos ao

eliminar as estruturas externa do pulmão. Utilizou-se o Método de Contorno Ativo Crisp proposto por Rebouças Filho (2010) para efetuar essa segmentação.

### 2.1.1. Método de Contorno Ativo Crisp


O método de Contorno Ativo (MCA) Crisp foi desenvolvido com o objetivo de otimizar a segmentação do pulmão em imagens de TC do tórax, visto as limitações do MCA tradicional em realizar essa tarefa (Rebouças Filho, 2010).

Baseando-se na identificação das densidades radiológicas internas do pulmão o MCA Crisp propõe uma inicialização automática do contorno no interior do pulmão e uma força externa a ser incorporada a versão do MCA Balão desenvolvido por Mackiewicz (1995). A energia  $E_{crisp}$  do MCA Crisp é descrita de acordo com a equação (Rebouças Filho, 2010)

$$E_{crisp}[c(s)] = w_{cont} F_{cont}[c(s)] + w_{bal} F_{bal}[c(s)] + w_{crisp} F_{crisp}[c(s)], \quad (1)$$

em que  $F_{cont}[c(s)]$  é a força de continuidade, a mesma que caracteriza o MCA tradicional desenvolvido por Kass *et. al.* (1988),  $F_{bal}[c(s)]$  é a força Balão. O termo  $F_{crisp}[c(s)]$  trata-se da força Crisp baseada no conhecimento específico das densidades pulmonares obtidas em imagens de TC e identifica quais estruturas encontradas através do operador Sobel são as bordas do pulmão. Os termos  $w_{cont}$ ,  $w_{bal}$  e  $w_{crisp}$  são referentes aos pesos de cada força na composição da energia do MCA Crisp.

Na Figura 1 é possível verificar um exemplo de segmentação e renderização por meio do método descrito.



**Figura 1. Aplicação do MCA Crisp na segmentação pulmonar (a) visualização em duas dimensões da segmentação do pulmão utilizando o MCA Crisp; (b) renderização da segmentação por MCA Crisp.**

## 2.2. Segmentação dos Vasos Sanguíneos

Segmentação de imagens utilizando Lógica Nebulosa tem sido extensivamente aplicada em diversas áreas [Acharya e Ray, 2005]. A teoria de lógica *Fuzzy* parte do princípio que tudo pode ser tratado como um problema de grau de associação entre objetos [Acharya e Ray, 2005].

Assumindo  $Z$  como o conjunto dos números inteiros, portanto  $Z^n$  trata-se de uma representação espacial  $n$ -dimensional cujos elementos básicos são definidos como *spels* (*Spatial elements*) (Lage, 2010). Neste trabalho, como  $n = 3$ , representa-se o *spel* por *voxel*. Um subconjunto  $A$ , definido em  $Z^n$  é um conjunto de pares ordenados descritos por

$$A = \{(x, \mu_A(x)) \mid x \in Z^n\}, \quad (2)$$

em que,  $\mu_A(x): Z^n \rightarrow [0,1]$  representa uma função, cujo valor indica o grau de pertinência do elemento  $x$  a  $A$ . Uma relação *fuzzy*  $\rho$  é um subconjunto de  $Z^n$  definido por (Udupa and Samarasekera, 1996)

$$\rho = \left\{ \left( (x, y), \mu_\rho(x, y) \right) \mid x, y \in Z^n \right\} \quad (3)$$

em que, em que,  $\mu_\rho(x, y): Z^n \rightarrow [0,1]$ . A relação *fuzzy*  $\rho$  é considerada reflexiva se  $\forall x \in Z^n, \mu_\rho(x, x) = 1$ ; simétrica, se  $\forall x, y \in Z^n, \mu_\rho(x, y) = \mu_\rho(y, x)$ .

Uma relação que seja simultaneamente simétrica e reflexiva definida no domínio de uma cena é dita afinidade *fuzzy* representada por  $j$  (Lage, 2010). O grau de pertinência dessa relação é definido por  $\mu_j(x, y)$ , cujo valor indica o quão similar é a intensidade dos *voxels*  $x$  e  $y$ .

A relação de adjacência *fuzzy* associa a cada par de *voxels*  $(x, y)$  um valor entre zero e um, definidos no domínio do espaço digital. Esse valor indica a proximidade espacial entre os elementos comparados.

Neste sentido, baseando-se nesses conceitos de adjacência e afinidade *fuzzy* utilizam-se as teorias de conectividade *fuzzy* e Crescimento de Regiões como principais fatores para segmentar os vasos sanguíneos.

### 2.2.1. Conectividade *Fuzzy*

A partir da combinação dos conceitos de afinidade e adjacência *fuzzy*, deduz-se que é possível encontrar uma conectividade global entre dois *voxels*  $x$  e  $y$  no domínio de uma cena *fuzzy*, a partir de uma sequência de afinidades locais (Udupa and amarasekera, 1996). Essa sequência pode ser interpretada como caminho.

Existem inúmeros caminhos passando somente por adjacências unitárias que unem esses dois *voxels*. Essa conectividade global é definida como Conectividade *Fuzzy* (*Fuzzy Connectedness*), representada por  $k$  e sua função de pertinência entre  $x$  e  $y$  por  $\mu_k(x, y)$  (Lage, 2010).

Considerando o caminho  $c_{xy} = \{s_1, s_2, s_3, \dots, s_N\}$  entre os *voxels*  $s_1 = x$  e  $s_N = y$ . A afinidade local entre dois *voxels* vizinhos  $s_1$  e  $s_2$  pode ser definida por  $\mu_{kl}(s_1, s_2)$ . Portanto a afinidade deste caminho é dada por (Kaftan *et al.*, 2008)

$$\mu_k(c_{xy}) = \min[\mu_{kl}(s_1, s_2), \mu_{kl}(s_2, s_3), \dots, \mu_{kl}(s_{N-1}, s_N)], \quad (4)$$

ou seja, a afinidade mais fraca é que representa a melhor afinidade para este caminho. Contudo existem vários possíveis caminhos entre dois *voxels* e para calcular a conectividade global deve-se considerá-los. Faz-se necessária então, uma seleção da maior afinidade de caminho como melhor representação da afinidade global. Portanto, assumindo que  $C_j$  seja o conjunto de todos os caminhos  $c_{xy}$ , a conectividade global entre  $x$  e  $y$  pode ser definida como (Kaftan *et al.*, 2008)

$$\mu_k(x, y) = \max[\mu_k(C_j)] \forall j. \quad (5)$$

Dessa forma, a definição de uma função de pertinência é dependente da definição de afinidade local entre os elementos que a compõe.

### 2.2.2. Função de Pertinência

A afinidade local  $\mu_{kl}$  definida na seção 2.2.1 é determinada a partir de uma função de densidade de probabilidade gaussiana limitada entre  $-600 UH$  e  $100 UH$ , tal como pode ser observado na Figura 2. Esta determina o grau de pertinência entre o *voxel*  $x$  e a semente  $y$ . O eixo das abscissas informa a variação em Unidade Hounsfield (UH), já o eixo das ordenadas informa o grau de pertinência do *voxel* à classe vasos sanguíneos. Neste trabalho, utiliza-se a definição de componente de intensidade determinada por [Udupa e Samarasekera, 1996]

$$g(x, y) = e^{\frac{-1}{2\sigma^2}\left(\frac{x+y}{2}-\mu\right)^2}, \quad (6)$$

em que  $\mu$  e  $\sigma$  representam a média e desvio padrão das densidades do objeto respectivamente. O valor esperado da densidade  $\mu$  é estimado calculando-se o valor médio das densidades das sementes. O desvio padrão foi definido  $\sigma = 200$ , porem não é um valor crucial, visto que possíveis alterações em decorrência de ruídos na imagem podem ser confundidas com os objetos de interesse.




Figura 2. função de pertinência gaussiana determinada utilizando-se o valor médio das densidades da sementes  $\mu = -200 UH$ .

### 2.2.3. Crescimento de Regiões 3D

O Crescimento de Regiões 3D é uma técnica que agrupa *voxels* ou sub-regiões em regiões maiores baseando-se em algum critério predefinido de agregação (Gonzalez and Woods, 2008). Para aplicação do algoritmo Crescimento de Regiões, é fixada uma região de interesse  $R$  podendo esta ser subdividida em  $n$  regiões  $R_1, R_2, R_3, \dots, R_n$  com as seguintes características (Gonzalez and Woods, 2008):

$$\cup_{i=1}^n R_i = R \quad (7)$$

$$R_i \text{ é uma região conectada, } i = 1, 2, 3, \dots, n \quad (8)$$

$$R_i \cap R_j = \emptyset, \text{ para todo } i \text{ e } j, i \neq j, \quad (9)$$

$$P(R_i) = \text{VERDADEIRO para } i = 1, 2, \dots, n, \quad (10)$$

$$P(R_i \cup R_j) = \text{FALSO para } i \neq j \quad (11)$$

A propriedade  $P(R_i)$  é uma definição lógica sobre um conjunto de pontos  $R_i$ . A equação 7 indica que a segmentação deve ser completa, isto é, todos os *voxels* da imagem devem pertencer a uma região. A equação 8 informa que os pontos de uma região devem ser obrigatoriamente conectados. A equação 9 indica que as regiões

devem ser disjuntas. Percebe-se na equação 10 que as propriedades dos *voxels* de uma mesma região devem ser semelhantes. Finalmente, a equação 11 informa que não existem regiões com propriedades idênticas.

### 3. Metodologia

As imagens utilizadas foram obtidas a partir de voluntários sadios por meio de uma TC multi-detectores. O tomógrafo trata-se de um *GE MEDICAL SYSTEMS* modelo *LightSpeed 16*. As imagens são quantificadas em 16 bits e armazenadas no padrão DICOM (*Digital Imaging and Communications in Medicine*).

A etapa de pré-processamento consiste em efetuar a segmentação do pulmão. Foi utilizado o MCA crisp na execução desta tarefa. A inicialização automática do contorno é executada através de um algoritmo baseado na análise de densidades pulmonares proposto por Rebouças Filho (2010).

Para segmentar os vasos sanguíneos aplicando a teoria de Conectividade *Fuzzy*, primeiramente foi aplicada uma limiarização atribuindo-se um limiar  $L = -300 \text{ UH}$ . Deste modo, todos os *voxels* cuja densidade seja superior ao limiar serão pertencentes à classe vasos sanguíneos. Portanto, obtêm-se uma segmentação parcial dos vasos. Os *voxels* que na limiarização foram agregados à classe vasos sanguíneos, são denominados de sementes.

A conectividade local é calculada segundo a função de pertinência descrita na seção 2.2.2. Os parâmetros de entrada da função são a média das densidades das sementes, e as densidades em UH dos *voxels* vizinhos.

Portanto, são calculadas as conectividades dos caminhos para, enfim, determinar as conectividades globais entre as sementes e os *voxels* pertencentes à região pulmonar. Se o valor da conectividade global for superior a 0.5 considera-se que esse *voxel* pertença à classe vasos sanguíneos. De acordo com a necessidade da aplicação, um limiar apropriado deve ser escolhido.

Na aplicação do Algoritmo Crescimento de regiões, foram utilizadas múltiplas sementes, determinadas através da mesma metodologia utilizada na segmentação parcial citada anteriormente. Dessa forma, os *voxels* conectados às sementes são adicionados à região caso as propriedades consideradas sejam semelhantes.

O algoritmo Crescimento de Regiões trata-se de um processo iterativo e, no caso deste trabalho, finaliza quando não há mais *voxels* aptos a participarem da região vasos sanguíneos. O grau de semelhança foi determinado através da função de pertinência descrita na seção 2.2.2. Os parâmetros de entrada  $\mu$  e  $\gamma$  da função de pertinência são a média das densidades de todos os *voxels* classificados como sementes, já o parâmetro  $\alpha$  a densidade do *voxel* candidato a agregar-se a região. Dessa forma, deve-se estabelecer um limiar de pertinência apropriado para efetuar a classificação.

### 4. Resultados e Discussões

Foram utilizadas 750 imagens de um exame de TC do tórax. Na Figura 3 verifica-se a determinação das sementes (segmentação parcial) através da limiarização. Nessa etapa é segmentada uma parte dos vasos, mas com descontinuidades que são corrigidas por meio da aplicação de Crescimento de Regiões e Conectividade Fuzzy. Observou-se que a quantidade de sementes influencia no custo computacional dos algoritmos. Quanto menor o número de sementes maior o tempo de execução dos algoritmos.

Os vasos que não são identificados por meio de limiarização também são segmentados através dos métodos em questão. A seguir são discutidos os desempenhos dos métodos utilizados para segmentar os vasos sanguíneos.



**Figura 3. Segmentação inicial dos vasos sanguíneos por limiarização.**

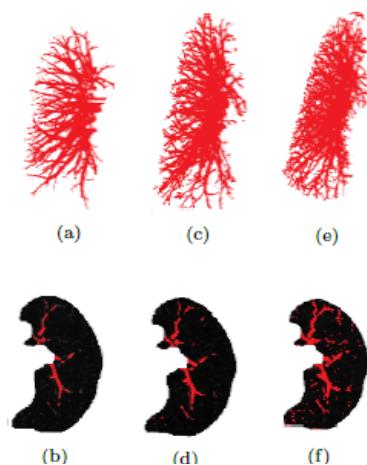
#### 4.1 Crescimento de Regiões 3D

Para avaliar o desempenho do algoritmo Crescimento de Regiões 3D, foram realizadas três execuções com mudanças dos parâmetros de pertinência  $\mu_N$ . Na Figura 4 observam-se os resultados da segmentação do pulmão esquerdo utilizando-se de diferentes parâmetros de pertinência  $\mu_N = 0.8$ ,  $\mu_N = 0.5$  e  $\mu_N = 0.3$ .

Parametrizando a função de pertinência atribuindo  $\mu_N = 0.8$  percebe-se poucos vasos de pequeno calibre incluídos na região. Na Figura 4(a) observa-se a renderização das imagens no plano frontal após a segmentação. O custo computacional, nessa configuração, é o menor dos que foram testados devido ao fato de esse limiar de pertinência alto causar a menor quantidade de iteração. Se o objetivo é uma visualização somente de vasos de grande e médio calibre, essa configuração é viável para realização dessa tarefa. Na Figura 4(b) nota-se a visualização em duas dimensões da segmentação dos vasos sanguíneos pulmonares para esse parâmetro de pertinência.

Diminuindo o limiar de pertinência para  $\mu_N = 0.5$ , já é possível a visualização de mais vasos sanguíneos de pequeno calibre. Configurando o algoritmo desse modo, nota-se a existência de alguns pontos segmentados desconectados da árvore de vasos. Isso é consequência de falha na determinação das sementes, a qual será foco estudo com objetivo de otimização. Essa configuração possui um custo computacional intermediário e é indicada quando há necessidade de uma extração de atributos mais precisas dos vasos. A renderização no plano frontal pode ser observada na Figura 4(c). A visualização em duas dimensões pode ser vista na Figura 4(d).

Adotando o valor de  $\mu_N = 0.3$ , observa-se uma ainda maior agregação de vasos de pequeno calibre, contudo o custo computacional aumenta e os pontos segmentados desconexos são mais frequentes nessa configuração, tal como pode ser visto na Figura 4(e). Foram obtidos resultados similares às aplicações descritas na seção 1.



**Figura 4. Aplicação da segmentação Por Crescimento de Regiões 3D. a),c),e) vasos sanguíneos visualizados no plano frontal da segmentação no pulmão esquerdo com limiar de conectividade  $\mu_N = 0.8$ ,  $\mu_N = 0.5$ ,  $\mu_N = 0.3$ , respectivamente; b),d),f) visualização em duas dimensões da segmentação para  $\mu_N = 0.8$ ,  $\mu_N = 0.5$ ,  $\mu_N = 0.3$ , respectivamente**

#### 4.2 Conectividade *Fuzzy*

A avaliação do método de segmentação por Conectividade *Fuzzy* foi realizada por meio de três execuções alterando o limiar de conectividade global  $\mu_k$ . Os resultados da segmentação utilizando este método foram considerados inferiores aos obtidos por meio do Crescimento de Regiões. Isto é devido à falha já citada na detecção das sementes, visto que esse método mostrou-se mais dependente de uma segmentação inicial exata. Na Figura 5 observa-se a segmentação dos vasos alterando o limiar de conectividade  $\mu_k = 0.8$ ,  $\mu_k = 0.5$  e  $\mu_k = 0.2$ .

Utilizando um limiar de conectividade  $\mu_k = 0.8$  verificaram-se falhas na segmentação dos vasos presentes na região basilar e presença de alguns pontos segmentados desconectados da árvore de vasos. Nessa configuração, vasos de pequeno calibre dificilmente são segmentados. Observa-se na Figura 5(a) a renderização no plano frontal da segmentação dos vasos para  $\mu_k = 0.8$  e na Figura 5(b) a visualização em duas dimensões da segmentação.

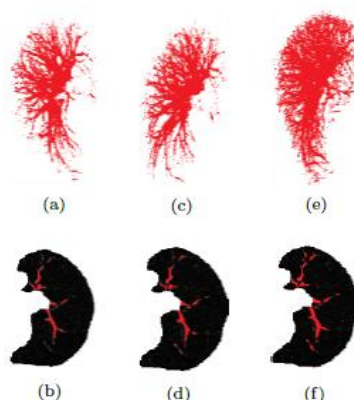
Atribuindo o valor de  $\mu_k = 0.5$  os vasos sanguíneos da base pulmonar foram segmentados, mas com exatidão inferior a observada pela segmentação por crescimento de Regiões 3D. A renderização pode ser observada na Figura 5(c) e visualização em duas dimensões na Figura 5(d).

Por fim, reduzindo o limiar de conectividade para  $\mu_k = 0.2$  verifica-se que vasos de pequeno calibre foram segmentados, entretanto a segmentação dos vasos da região da base é um obstáculo. A renderização pode ser observada na Figura 5(e) e visualização em duas dimensões na Figura 5(f). No trabalho desenvolvido por Kaftan *et al* (2008) foi realizada uma segmentação inicial baseada na transformada da distância que propiciou melhores resultados que aplicação proposta neste trabalho.

O custo computacional de utilizar a segmentação por Conectividade *Fuzzy* é maior que o custo observado na segmentação por Crescimento de Regiões 3D. Essa situação é verificada devido ao fato de a determinação das conectividades globais necessitarem de uma verificação de afinidade entre todos os *voxels* candidatos de todos



os caminhos possíveis e as sementes. Já a análise de afinidade por crescimento de regiões 3D é somente na máscara volumétrica  $3 \times 3 \times 3$ .



**Figura 5. Aplicação da segmentação por Conectividade *Fuzzy*. a),c),e) vasos sanguíneos visualizados no plano frontal da segmentação no pulmão esquerdo com limiar de conectividade  $\mu_k = 0.8$ ,  $\mu_k = 0.5$ ,  $\mu_k = 0.2$ , respectivamente; b),d),f) visualização em duas dimensões da segmentação para  $\mu_k = 0.8$ ,  $\mu_k = 0.5$ ,  $\mu_k = 0.3$ , respectivamente**

## 5. Conclusões

Neste trabalho é mostrada a aplicação de Conectividade *Fuzzy* e Crescimento de Regiões 3D na segmentação dos vasos sanguíneos pulmonares. A aplicação da técnica de crescimento de Regiões 3D obtém melhores resultados que a utilização de Conectividade *Fuzzy*. A vantagem de utilizar uma análise por lógica *fuzzy* em relação aos métodos crisp é fato de obter modelos flexíveis de segmentação para diferentes aplicações. A perspectiva para futuros trabalhos está voltada para melhoria da determinação das sementes e otimização dos referidos métodos de segmentação. Sugere-se também para trabalhos futuros efetuar uma extração de atributos que possam auxiliar o diagnóstico de cardiopatias pulmonares.

## 6. Referências

- Acharya, T. and Ray, A. K. (2005). *Image Processing: Principles and Applications*, 1 edn, Wiley-Interscience.
- Cavalcante, T. (2010). Técnica para segmentação automática de vias aéreas em imagens de tomografia computadorizada do tórax, Master's thesis, Universidade Federal do Ceará.
- Doi, K. (2006). *Diagnostic imaging over the last 50 years: research and development in medical imaging science and technology.*, *Physics in Medicine and Biology* 51(13): R5-27.
- Félix, J. H. S. (2007). Sistema de visão computacional para detecção e quantificação de enfisema pulmonar, Master's thesis, Universidade Federal do Ceará.
- Gonzalez, R. C. and Woods, R. E. (2008). *Digital Image Processing, 3 edn*, Prentice-Hall, Inc.
- Kaftan, J. N., Kiraly, A. P., Bakai, A., Das, M., Novak, C. L. and Aach, T. (2008). *Fuzzy pulmonary vessel segmentation in contrast enhanced ct data*, in J. M. Reinhardt and J. P. W. Pluim (eds), *Medical Imaging 2008: Image Processing*, Vol. 6914, SPIE, San Diego, USA, pp. 69141Q-1-12.

- Kass, M., Witkin, A. and Terzopoulos, D. (1988). *Snakes: active contours models*, *International Journal of Computer Vision* 1(4): 321-331.
- Lage, D. M. (2010). Visibilização das artérias coronárias epicárdicas em imagens ecocardiográficas tridimensionais com contraste de microbolhas, *PhD thesis*, Faculdade de Medicina da Universidade de São Paulo.
- Lingurar, M. G., Orandi, B. J., Van Uitert, R. L., Mukherjee, N., Summers, R. M., Ladwin, M. T., Machado, R. F. and Wood, B. J. (2008). *Ct and image processing non-invasive indicators of sickle cell secondary pulmonary hypertension*, *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, pp. 859 - 862.
- Mackiewicz, B. (1995). *Intracranial boundary detection and radio frequency correction in magnetic resonance images*, *Master's thesis*, School of Computing Science.
- Masutani, Y., MacMahon, H. and Doi, K. (2002). *Computerized detection of pulmonary embolism in spiral ct angiography based on volumetric image analysis*, *Medical Imaging, IEEE Transactions on* 21(12): 1517-1523.
- Rebouças Filho, P.P. (2010). Mca crisp: nova técnica de segmentação dos pulmões em imagens de tomografia computadorizada baseada no método de contorno ativo, *Master's thesis*, Universidade Federal do Ceará.
- Robbins, S. L. and Cotran, R. S. (2005). *Patologia- Bases Patológicas das Doenças*, 7 edn, Saunders Elsevier, Rio de Janeiro.
- Sato, Y., Nakajima, S., Shiraga, N., Atsumi, H., Yoshida, S., Koller, T., Gerig, G. and Kikinis, R. (1998). *3D multi-scale line filter for segmentation and visualization of curvilinear structures in medical images*.
- Shaw, L. S. and Simões, M. G. (2010). *Controle e Modelagem Fuzzy*, 2 edn, Edgard Blucher
- Tozaki, T., Kawata, Y., Niki, N., Ohmatsu, H., Eguchi, K. and Moriyama, N. (1996). *Threedimensional analysis of lung areas using thinslice CT images*, *Pattern recognition, 1996., Proceedings of the 13th International Conference on*, Vol. 3, pp. 548 -552 vol.3.
- Udupa, J. K. and Samarasekera, S. (1996). *Fuzzy connectedness and object definition: Theory, algorithms, and applications in image segmentation*. *CVGIP: Graphical Model and Image Processing* pp. 246-261.
- Zhu, X., Xue, Z., Gao, X., Zhu, Y. and Wong, S. (2009). *Voles: Vascularity-oriented level set algorithm for pulmonary vessel segmentation in image guided intervention therapy*, *Biomedical Imaging: From Nano to Macro, 009. ISBI '09. IEEE International Symposium on*, pp. 1247 - 1250.