

Modelo de Contorno Ativo Crisp Adaptativo 2D aplicado na segmentação dos pulmões em imagens de TC do tórax de voluntários saudáveis e pacientes com enfisema pulmonar

Pedro Pedrosa Rebouças Filho*, Paulo César Cortez, John Hebert da Silva Félix, Tarique da Silveira Cavalcante, Marcelo Alcantara Holanda

Resumo **Introdução:** Dentre as doenças que afetam a população mundial, destaca-se a preocupação com a Doença Pulmonar Obstrutiva Crônica (DPOC), que, segundo a Organização Mundial de Saúde, pode se constituir na terceira causa de morte mais importante em todo mundo no ano de 2030. Visando contribuir com o auxílio ao diagnóstico médico, esta pesquisa centraliza seus esforços na etapa de segmentação dos pulmões, visto que esta é a etapa básica de sistema de Visão Computacional na área de pneumologia. **Métodos:** Este trabalho propõe um novo método de segmentação dos pulmões em imagens de Tomografia Computadorizada (TC) do tórax chamado de Método de Contorno Ativo (MCA) Crisp Adaptativo 2D. Este MCA consiste em traçar automaticamente uma curva inicial dentro dos pulmões, que se deforma por iterações sucessivas, minimizando energias que atuam sobre a mesma, deslocando-a até as bordas do objeto. O MCA proposto é o resultado do aperfeiçoamento do MCA Crisp desenvolvido previamente, visando aumentar a sua exatidão, diminuindo o tempo de análise e reduzindo a subjetividade na segmentação e análise dos pulmões dessas imagens pelos médicos especialistas. Este método por iterações sucessivas de minimização de sua energia, segmenta de forma automática os pulmões em imagens de TC do tórax. **Resultados:** Para sua validação, o MCA Crisp Adaptativo é comparado com os MCAs THRMulti, THRMod, GVF, VFC, Crisp e também com o sistema SISDEP, sendo esta avaliação realizada utilizando como referência 24 imagens, sendo 12 de pacientes com DPOC e 12 de voluntários saudáveis, segmentadas manualmente por um pneumologista. Os resultados obtidos demonstram que o método proposto é superior aos demais. **Conclusão:** Diante dos resultados obtidos, pode-se concluir que este método pode integrar sistemas de auxílio ao diagnóstico médico na área de Pneumologia.

Palavras-chave Auxílio ao diagnóstico médico, Método de Contorno Ativo, Segmentação do pulmão, Tomografia computadorizada.

Adaptive 2D Crisp Active Contour Model applied to lung segmentation in CT images of the thorax of healthy volunteers and patients with pulmonary emphysema

Abstract **Introduction:** Among the diseases that affect the world's population, there is concern about Chronic Obstructive Pulmonary Disease (COPD), that, according to the World Health Organization, could be the leading cause of death worldwide by the year 2030. Aiming to contribute to aid medical diagnosis, this research focuses its efforts on the segmentation of the lungs, since this is the basic step system in the area of Computer Vision pulmonology. **Methods:** This paper proposes a new method for segmentation of lung images in Computed Tomography (CT) of the chest called Active Contour Method (MCA) Crisp Adaptive 2D. This MCA is to draw a curve starting inside an object of interest. This curve is deformed by successive iterations, minimizing energies that act on it, moving it to the edges of the object. The MCA is the improvement of the proposed MCA Crisp previously developed, aiming to increase the accuracy, decreasing analysis time and reducing the subjectivity in the segmentation and analysis of the lungs of these images by pulmonologists. This method is automatically initialized in the lungs and on successive iterations to minimize this energy, this MCA automatically targets the lungs in chest CT images. **Results:** To evaluate the proposed method, the MCA Adaptive Crisp is compared with MCAs THRMulti, THRMod, GVF, VFC, Crisp and also with the system SISDEP, this assessment is performed using reference images 24, 12 COPD patients and 12 volunteers healthy, manually segmented by a pulmonologist. The results show that the proposed method is superior to the others. **Conclusion:** Based on the results, it can be concluded that this method can integrate systems aid in the medical diagnosis of Pulmonology.

Keywords Aid diagnostic, Active Contour Models, Lung segmentation, Chest CT images.

*e-mail: pedrosarf@gmail.com

Recebido: 19/05/2013 / Aceito: 17/09/2013

Introdução

Dentre as doenças que afetam a população mundial, grande parte se localiza nos pulmões. Deste modo, as pesquisas na área de Pneumologia tem grande importância na saúde, em que se destaca a preocupação com a Doença Pulmonar Obstrutiva Crônica (DPOC) (Fortaleza, 2006; Winkeler, 2006).

A Organização Mundial de Saúde (OMS) estima que, em 2005, 210 milhões de pessoas tinham DPOC em todo o mundo, causando a morte de mais de 300 milhões de pessoas (Organização..., 2008). Estudos recentes revelam que a DPOC está presente no grupo etário de 20 a 45 anos, embora caracterize-se por ser uma doença de pessoas com idade superior a 50 anos. Neste sentido, a OMS estima que o número de mortes por DPOC deva aumentar 30% até 2015, e que em 2030 a DPOC seja a terceira causa de morte em todo o mundo (Marco *et al.*, 2004).

Neste contexto, é de fundamental importância para saúde pública realizar diagnósticos precoces e corretos para detectar os estágios reais de doenças pulmonares. O auxílio ao diagnóstico mostra-se importante tanto do ponto de vista clínico quanto em pesquisa. Dentre os fatores que contribuem para isto, pode-se citar o aumento da precisão do diagnóstico do médico especialista à medida que aumenta o número de informações sobre o estado do paciente. Deste modo, certas doenças podem ser detectadas precocemente, inclusive salvando vidas em alguns casos. Além disto, algumas técnicas desenvolvidas permitem que o quadro clínico evolutivo da doença seja devidamente acompanhado (Félix, 2007; Liang *et al.*, 2008).

Considerando-se um sistema de Visão Computacional (VC) na área de Pneumologia, constata-se que a etapa de segmentação é essencial para o auxílio ao diagnóstico médico correto e preciso, visto que esta etapa delimita a área dos pulmões em imagens de TC do tórax que deve ser analisada pelo sistema ou pelo médico especialista. Portanto, técnicas de segmentação dos pulmões são desenvolvidas buscando otimizar esta etapa. Dentre estas, Sluimer *et al.* (2005) obtém a segmentação dos pulmões em imagens de TC através de crescimento de região.

Já Félix (2007), Hu *et al.* (2001) e Silva *et al.* (2006) combinam morfologia matemática, crescimento de região, limiarização e detecção de bordas para obter resultados mais precisos.

Silva (2005) e Itai *et al.* (2007) utilizam técnicas de MCA Tradicionais para segmentar os pulmões, enquanto Shojai *et al.* (2005) utiliza transformada *Watershed* para obter a segmentação dos pulmões.

Os métodos tradicionais de segmentação baseados em Limiarização, Crescimento de Regiões, detecção de

bordas, *Watershed* não costumam apresentar resultados consistentes em imagens de TC do tórax (Félix, 2011; Rebouças Filho, 2010). Isto acontece, no primeiro caso, pela identificação das bordas das estruturas internas do pulmão como bordas pulmonares. Exemplo destas estruturas internas são veias, artérias e vias aéreas (Cavalcante, 2010). Já no segundo caso, doenças pulmonares ou ruídos podem distorcer as densidades radiológicas expressas em Unidade Hounsfield (UH) dos pulmões (Félix, 2011). Além disso, técnicas de segmentação que utilizam as informações de bordas ou características de regiões separadamente, em geral, apresentam resultados insuficientes e são adequados somente para casos específicos (Félix, 2011). Estas técnicas incluem estruturas que não fazem parte do tecido pulmonar, o qual se deseja analisar, tais como: a traqueia, o hilo e parte da cavidade do tórax (Félix *et al.*, 2008; Hu *et al.*, 2001; Silva *et al.*, 2001; Silva *et al.*, 2006).

Com o objetivo de contornar restrições de técnicas anteriormente mencionadas, destacam-se as técnicas: segmentação desenvolvidas no Sistema de Detecção de Enfisema Pulmonar (SISDEP) (Félix, 2007) o Método de Contorno Ativo Crisp (Rebouças Filho, 2010), os métodos de Contornos Ativos Hilbert 2D, *Gradient Vector Flow* (GVF) e *Vector Field Convolution* (VFC), inicializados de forma automática pelo método de inicialização automática de contornos ativos denominado INAUTO (Félix, 2011).

Baseando-se na análise descrita anteriormente, este trabalho propõe o MCA Crisp Adaptativo 2D, resultado da evolução do MCA Crisp (Rebouças Filho, 2010), visando reduzir os erros e o tempo de processamento na segmentação dos pulmões em imagens de TC. Este método é avaliado e comparado com o sistema SISDEP e com os MCAs GVF, VFC, Crisp e os MCAs baseados na transformada de Hilbert quanto à qualidade e eficiência na segmentação dos pulmões em imagens de TC do tórax.

Métodos

Nesta Seção é descrita a metodologia de aquisição das imagens utilizadas no desenvolvimento e na avaliação dos resultados. Além disto, os métodos avaliados são apresentados.

Aquisição das imagens

Neste processo de aquisição de imagens, é utilizado a Tomografia Computadorizada de Alta Resolução (TCAR). Estas imagens foram obtidas em parceria com o Hospital Walter Cantídio da Universidade Federal do Ceará, cedidas por um estudo anterior (Fortaleza, 2006; Winkeler, 2006). Este estudo foi

avaliado e aprovado pelo Comitê de Ética em Pesquisa da UFC – COMEPE (Protocolo nº 35/06) e incorporado às exigências da Resolução nº 196/96 do Conselho Nacional de Saúde, a respeito de pesquisas em seres humanos.

As imagens são obtidas a partir de voluntários saudáveis e de pacientes com Doença Pulmonar Obstrutiva Crônica (DPOC). Os cortes tomográficos são realizados na posição supina, considerando três níveis de regiões: ápice, hilo e base (Fortaleza, 2006; Winkeler, 2006).

Para a leitura destas imagens, que estão no formato DICOM (*Digital Imaging and Communications in Medicine*), é utilizada a biblioteca livre DCMTK (*Dicom ToolKit*) fornecida pela OFFIS. Esta biblioteca é compatível com a linguagem de programação C++, a mesma utilizada no desenvolvimento deste trabalho.

Método de contornos ativos

O MCA foi introduzido em 1987 por Kass *et al.* (1987). Este método permite realizar a segmentação de objetos em imagens digitais por meio da detecção de bordas obtidas por informações da imagem, como exemplo, a intensidade dos níveis de cinza. Tal método tem superado as técnicas tradicionais, até então desenvolvidas, como Limiarização, Crescimento de Regiões, detecção de bordas, *Watershed*, dentre outros.

Um MCA consiste em traçar uma curva inicial em torno ou dentro de um objeto de interesse. Esta curva se deforma, conforme algumas forças que atuam sobre o mesmo, deslocando-o até as bordas do objeto. Este processo é realizado por iterações sucessivas de minimização de uma dada energia, associada à curva. De acordo com Souza Júnior (2006), a curva se comporta como uma fita elástica que, uma vez solta em volta de um objeto, molda sua forma para melhor se adaptar a este.

Isto é possível analisando a vizinhança de cada ponto, calculando as energias envolvidas e movendo-o para a coordenada que possui a menor energia total em sua vizinhança (Amini *et al.*, 1990). Os contornos ativos são baseados em métodos variacionais, considerados modelos deformáveis porque são descritos por uma função de energia E que varia segundo a equação (Kass *et al.*, 1987)

$$E = \sum_{s=0}^N (E_{int}[c(s)] + E_{ext}[c(s)]) \quad (1)$$

em que o termo E_{int} representa as energias internas da curva, E_{ext} o termo da energia associado com as energias externas, c a curva e N o número de pontos da mesma, no qual a posição de cada ponto $c(s)$ na imagem é determinada pelas coordenadas $x(s)$ e $y(s)$ (Kass *et al.*, 1987).

A energia interna é proveniente das forças internas da curva, relativa apenas à geometria desta, relacionada com sua forma e a posição de seus pontos (Itai *et al.*, 2007). Esta energia interna E_{int} é definida por (Kass *et al.*, 1987)

$$E_{int}(s) = \alpha(s) \left| \frac{dc(s)}{ds} \right|^2 + \beta(s) \left| \frac{d^2c(s)}{ds^2} \right|^2 \quad (2)$$

em que $\alpha(s)$ especifica o peso da força interna que define a elasticidade da curva ou resistência ao se esticar, enquanto $\beta(s)$ atribui o valor do peso da força interna que caracteriza a rigidez ou resistência ao se torcer a curva. O termo $\left| \frac{dc(s)}{ds} \right|^2$ tende a espaçar igualmente os pontos, já o termo $\left| \frac{d^2c(s)}{ds^2} \right|^2$ tende a retirar a curvatura entre os pontos da curva, resultando na diminuição dos ângulos da curva.

Já a energia externa E_{ext} é proveniente das características da imagem e está associada às informações obtidas a partir desta (Kass *et al.*, 1987). Esta energia geralmente é obtida a partir de um operador gradiente, dentre os quais o Sobel é o mais utilizado (Gonzales e Woods, 2008; Nixon e Aguado, 2002).

O MCA Tradicional apresenta limitação na segmentação de regiões com saliências e bifurcações, além de necessitar ser inicializado próximo às bordas do objeto de interesse. Neste contexto, surgem novos MCAs que visam superar tais limitações, alguns propondo novas energias internas, como o MCA Balão (Cohen, 1991; Mackiewicz, 1995). Enquanto outros MCAs, propõem novas energias externas, como, por exemplo, o GVF (Xu e Prince, 1997), o VFC (Li e Acton, 2007) e os baseados na Transformada de Hilbert Radial, destacando o modular THRMod e o multidirecional THRMulti (Félix, 2011).

Método de Contorno Ativo Crisp Adaptativo 2D

O MCA Crisp Adaptativo 2D é uma nova técnica de segmentação de imagens e surge visando superar as limitações observadas na aplicação do MCA Crisp, proposto por Rebouças Filho (2010), na segmentação dos pulmões em imagens de TC do tórax. Neste sentido, este novo método baseia-se no funcionamento do MCA Crisp, porém substituindo a força Balão proposta por Cohen (1991) por uma nova força Balão Adaptativa proposta, além de substituir a energia Crisp proposta por Rebouças Filho (2010) por uma nova energia externa denominada energia Crisp Adaptativa. A junção destas duas novas energias, propostas neste trabalho, gera um MCA denominado MCA Crisp Adaptativo (MCA CRAD). Este MCA visa identificar as bordas

pulmonares, além de não possuir limitações quanto à segmentação de objetos com concavidades, saliências ou bifurcações. Assim, a energia total de um ponto $c(s)$ do MCA CRAD é dada por

$$E_{CRAD}[c(s)] = E_{int_{adap}}[c(s)] + E_{ext_{CRAD}}[c(s)] \quad (3)$$

as quais $E_{int_{adap}}$ é a energia interna adaptativa e $E_{ext_{CRAD}}$ é a energia externa Crisp Adaptativa.

Esta nova energia interna proposta do MCA Crisp Adaptativo 2D visa superar as limitações dos demais MCAs na segmentação de objetos com formas tubulares, saliências e bifurcações, além de suprir a dependência de inicialização próxima às bordas (Cavalcante, 2010; Rebouças Filho, 2010). Neste sentido, o MCA Crisp Adaptativo 2D propõe uma nova energia interna dada por

$$E_{int_{adap}}[c(s)] = w_{cont} F_{cont}[c(s)] + w_{adap} F_{adap}[c(s)] \quad (4)$$

em que F_{cont} é a força de Continuidade e F_{adap} é a força Balão Adaptativa e os parâmetros w_{cont} e w_{adap} são pesos associados a cada uma das forças. Tais pesos permitem ajustar a importância de cada uma destas forças em seus respectivos termos no cálculo da energia interna $E_{int_{adap}}$. A força de continuidade F_{cont} tende a deixar os pontos igualmente espaçados, sendo calculada por

$$F_{cont}[c(s)] = \left| DM - \sqrt{|x(s) - x(s-1)|^2 + |y(s) - y(s-1)|^2} \right| \quad (5)$$

em que DM é a distância média entre os pontos da curva, $[x(s), y(s)]$ são as coordenadas de $c(s)$ e $[x(s-1), y(s-1)]$ são as coordenadas de $c(s-1)$, vizinho anterior de $c(s)$.

Já a força Balão Adaptativa utiliza informações da topologia da curva para expandir o contorno. Estas informações são específicas para cada ponto e partem do princípio de que a curva possui formas distintas ao longo de sua topologia. Deste modo, a força Balão Adaptativa desloca cada ponto da curva de maneira distinta em direção às bordas do objeto de interesse, adaptando-se à topologia local em que está inserido. No cálculo dessa nova força interna, as informações utilizadas sobre a topologia de cada ponto são geradas a partir de duas fontes de informação: de seus vizinhos e de sua posição em relação à curva atual. A primeira fonte é obtida com base nas coordenadas de seus vizinhos imediatos para cálculo do ponto médio destes; e a segunda informação determina de que forma, aditiva ou subtrativa, a contribuição deste ponto médio participa no cálculo da força F_{adap} . Assim, esta força é calculada por

$$F_{adap}[c(s)] = \sqrt{E_x^2 + E_y^2} \quad (6)$$

em que as componentes E_x e E_y são dadas por

$$E_x = |x(s) \pm x_m| \quad (7)$$

e

$$E_y = |y(s) \pm y_m| \quad (8)$$

em que $x(s)$ e $y(s)$ são as coordenadas do ponto $c(s)$ onde F_{adap} está sendo calculada, x_m e y_m definem o ponto médio dos vizinhos; e o sinal utilizado nas Equações 7 e 8, é negativo quando a posição do ponto é externo à curva e positivo quando o ponto é interno. Neste caso, para determinar se um ponto está dentro da curva é usado o Teorema da Curva de Jordan (Berg *et al.*, 1975).

Mostra-se na Figura 1 uma curva para exemplificar a aplicação da F_{adap} em duas situações distintas, analisando os casos do ponto médio dos vizinhos está interno ou externo à curva, considerando os pontos A e F , respectivamente.

Analisando-se o ponto A da Figura 1, constata-se que este possui como vizinhos imediatos os pontos O e B , em que a média de suas coordenadas resulta no ponto M_{OB} . Já o ponto F , possui como vizinhos imediatos os pontos E e G , e a média das coordenadas destes pontos geram o ponto M_{EG} . Considerando-se os pontos M_{EG} e M_{OB} e aplicando o método descrito por Berg *et al.* (1975), tem-se que o ponto M_{OB} é considerado dentro da curva, enquanto M_{EG} é dito como ponto externo.

Desse modo, sabendo as informações da topologia local da curva em que os pontos A e F estão inseridos, têm-se que o resultado da Equação 6 nestes pontos deve expandir a curva na direção e sentido demonstradas, respectivamente, pelas forças $F_{adap}(A)$ e $F_{adap}(F)$, conforme demonstrado em azul na Figura 1.

A partir dos argumentos expostos, tem-se que a Força Adaptativa é de fundamental importância por expandir a curva, principalmente quando esta se encontra em regiões homogêneas da imagem, pois a força externa é nula e as únicas forças que interferem na evolução da curva são as forças internas. Neste caso, a Força Adaptativa deforma o contorno para que este se aproxime das bordas por iterações sucessivas do método.

A nova energia $E_{ext_{CRAD}}$ proposta utiliza o conceito de Análise das Densidades Pulmonares (ADP) de uma vizinhança para determinar a origem das bordas pulmonares encontradas pelo operador gradiente Sobel, do mesmo modo que o MCA Crisp (Rebouças Filho, 2010). A diferença é que o MCA Crisp determina esta origem por uma regra fixa, enquanto a nova energia proposta neste trabalho utiliza para esta tarefa uma Rede Neural Artificial (RNA) do tipo *Multi Layer Perceptron* (MLP).

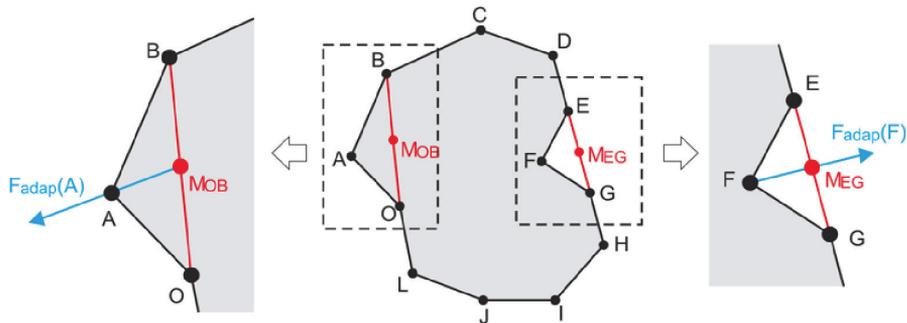


Figura 1. Exemplos de cálculo da força Balão Adaptativa.
Figure 1. Exemplos of adaptive balloon force calculation.

O método ADP (Rebouças Filho, 2010) consiste em obter os percentuais das 6 classes u_i , em que i varia de 0 a 5, na qual cada classe representa uma estrutura em imagens de TC do tórax distinta, sendo estas (Gevenois e Yernault, 1995):

- u_0 - hiperaeradas (-1000 a -950 UH) ;
- u_1 - normalmente aeradas (-950 a -500 UH);
- u_2 - pouco aeradas (-500 a -100 UH);
- u_3 - não aeradas (-100 a 100 UH);
- u_4 - osso (600 a 2000 UH);
- u_5 - áreas não classificadas (nenhuma das demais).

Deste modo, considerando uma matriz de densidades pulmonares D , as coordenadas (x, y) nas quais a vizinhança é analisada, tem-se que a função que determina a quantidade de pontos com densidades presente em cada classe u_i , é determinada por

$$f(x, y, u_i) = \sum_{l=-4}^4 \sum_{m=-4}^4 R(x-l, y-m) \quad (9)$$

no qual

$$R(x, y) = \begin{cases} 1, & \lim_{\text{inf}}(u_i) < D(x, y) < \lim_{\text{sup}}(u_i) \\ 0, & \text{caso contrário} \end{cases} \quad (10)$$

em que $\lim_{\text{inf}}(u_i)$ e $\lim_{\text{sup}}(u_i)$ representam os limites inferior e superior da faixa de densidade, definida em UH, para a classe u_i . Ao calcular os percentuais de cada classe, desconsidera-se a classe 5, visto que as áreas não classificadas não devem compor o cálculo. Logo, o percentual P_i de cada classe i é definido por (Rebouças Filho, 2010)

$$P_i = \frac{f(x, y, u_i)}{\sum_{j=0}^4 f(x, y, u_j)} \quad (11)$$

O MCA Crisp (Rebouças Filho, 2010) utiliza uma regra fixa para identificar a origem das bordas, em que as bordas pulmonares são as que possuem $P_3 > 0,2$ e $P_4 > 0,15$. Entretanto, esta classificação possui falhas, seja por falsos positivos ou por falsos negativos. Para contornar as restrições da energia externa Crisp, esta nova energia incorpora uma

RNA MLP para determinar a origem de cada borda encontrada em imagens de TC do tórax.

As entradas dessa rede MLP são os seis percentuais das classes u_i encontradas pelo método ADP, existindo apenas uma saída para indicar se as bordas encontradas em imagens de TC do tórax são ou não das paredes pulmonares. Neste método, utiliza-se apenas uma camada oculta na topologia da MLP, em que esta camada é a responsável pela resolução de problemas não separáveis linearmente. Para determinar a quantidade de neurônios na camada oculta HN é utilizada a solução descrita por (Yin *et al.*, 2005)

$$HN = \frac{2 \times \max(M_1, M_2)}{3} \quad (12)$$

em que M_1 e M_2 são as quantidades de neurônios na entrada e na saída, respectivamente. Neste trabalho, utilizando M_1 sendo os seis percentuais das classes u_i e M_2 sendo apenas a única saída para determinar se a borda é ou não do pulmão, obtém-se uma topologia 6/4/1, ou seja, 6 neurônios na entrada, 4 neurônios na camada oculta e 1 neurônio na saída. A topologia especificada é verificada pelo método de validação cruzada (Haykin, 1999), no qual um conjunto de exemplos é separado aleatoriamente, sendo um conjunto utilizado para o treinamento da rede neural e o outro para experimento. O conjunto de dados utilizados neste treinamento é extraído de imagens de pacientes com DPOC e de voluntários sadios nas posições de ápice, hilo e base dos pulmões em imagens de TC do tórax.

Para a fase de treinamento, os dados são selecionados manualmente, buscando obter uma maior representação possível das estruturas do pulmão. Em média, 150 pixels são adicionados por imagem, indicando quais bordas encontradas pelo operador Sobel pertencem ou não às paredes pulmonares, estando neste último conjunto as bordas: ossos, vasos, vias aéreas, ar e outras estruturas que não sejam os pulmões. São utilizados nesta etapa 500 imagens de diferentes exames, doenças e vários níveis de corte.

Utilizando a rede neural MLP, previamente treinada, tem-se que em sua fase de execução que sua saída é dada pela função

$$f_{mlp}(u) = \begin{cases} 1, & \text{quando a borda detectada} \\ & \text{constituir a parede pulmonar} \\ 0, & \text{caso contrário} \end{cases} \quad (13)$$

Utilizando a função f_{mlp} para determinar a origem das bordas encontradas em imagens de TC do tórax, tem-se que a energia externa $E_{extCRAD}$, definida na Equação 3, é dada por

$$E_{extCRAD} = \begin{cases} S(x, y), & f_{mlp}(u) = 1 \\ 1, & \text{caso contrário} \end{cases} \quad (14)$$

em que $S(x, y)$ é o operador Sobel, e u é o vetor de percentuais do método ADP obtidos pela Equação 11, utilizando as coordenadas (x, y) do *pixel* em análise. Esta energia externa é capaz de identificar a origem das bordas de pulmões com DPOC e sadios. Isto porque a RNA MLP é treinada para reconhecer estes padrões, visto que são os casos de maior incidência nos pulmões em imagens de TC do tórax. Para exemplificar este funcionamento, a Figura 2 apresenta as etapas para obtenção da energia externa Crisp Adaptativa em uma imagem de paciente com DPOC e uma imagem de voluntário sadio.

Inicialização automática, adição e remoção de pontos da curva

Os métodos de inicialização automática, adição e remoção de pontos da curva são os mesmos propostos por Rebouças Filho (2010). A inicialização busca encontrar dois pontos, um esquerdo de coordenadas (x_e, y_e) e outro direito de coordenadas (x_d, y_d) . Estes pontos são usados como centroides de um polígono regular, em que o raio e a quantidade de pontos são definidos na inicialização.

Para determinar os pontos de inicialização, Rebouças Filho (2010) divide a imagem em regiões e cada coordenada x de inicialização é determinada por

$$InicX(x) = \sum_{y=L1Y}^{LSY} s(y) \cdot s(y) = \begin{cases} 1, & -1000 < I(x, y) < -500 \\ 0, & \text{caso contrário} \end{cases} \quad (15)$$

em que a coluna x que obtém a maior saída da função $InicX$ dentro da região em análise é dita como coordenada de inicialização do eixo x para aquela região, sendo x_e para região esquerda e x_d para região direita. Já a coordenada de inicialização no eixo das ordenadas é dada por

$$InicY(y) = \sum_{x=L1X}^{LSX} s(x) \cdot s(x) = \begin{cases} 1, & -1000 < I(x, y) < -500 \\ 0, & \text{caso contrário} \end{cases} \quad (16)$$

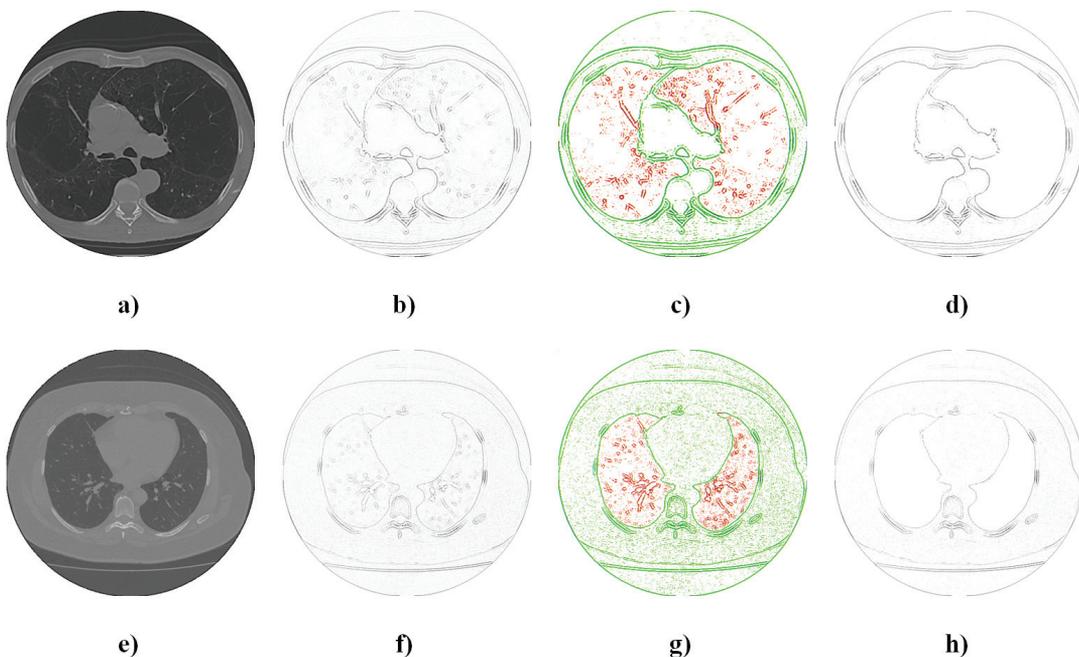


Figura 2. Etapas para obtenção da energia externa Crisp Adaptativa: a) e e) imagens originais de pacientes com DPOC voluntário sadio, respectivamente; b) e f) representação da energia externa tradicional em uma imagem; c) e g) classificação da MLP para determinar origem das bordas; d) e h) representação da energia externa Crisp Adaptativa em uma imagem.

Figure 2. Steps for obtaining external power Adaptive Crisp: a) and e) original images of DPOC patients healthy volunteers, respectively; b) and f) representation of the traditional external energy in an image; c) and g) classification of MLP to determine the origin of the edges; d) and h) representation of the Adaptive Crisp external energy in an image.

em que o princípio é o mesmo da Equação 15, na qual a linha y que possuir a maior saída da função $InicY$ dentro da região em teste é dita como coordenada de inicialização do eixo y para aquela região, sendo y_e para região esquerda e y_d para região direita.

As coordenadas utilizadas neste trabalho para limitar as regiões de busca dos pontos de inicialização são as mesmas propostas por Rebouças Filho (2010). Deste modo, para a região esquerda são usadas as coordenadas θ para LIX , 256 para LSX , 180 para $LIIY$ e 360 para LSY . Já para a região Direita, as coordenadas são 256 para LIX , 512 para LSX , 180 para $LIIY$ e 360 para LSY .

O método de adição de pontos se baseia na distância Euclidiana entre dois pontos consecutivos do contorno. Quando esta distância é maior do que uma distância máxima entre pontos, um novo ponto é adicionado entre estes, aumentando a sensibilidade do contorno. O valor 5 pixels é adotado como distância máxima, o mesmo usado por Rebouças Filho (2010).

Já o método de remoção de pontos baseia-se na remoção de pontos que possuem variação brusca de coordenadas em relação aos seus vizinhos, amenizando erros existentes. Esta variação é detectada a partir do ângulo formado entre o ponto analisado e seus vizinhos. O valor 60° é adotado como ângulo mínimo, o mesmo usado por Rebouças Filho (2010).

Segmentação automática dos pulmões em imagens de TC do tórax

A segmentação automática dos pulmões em imagens de TC do tórax utiliza os métodos inicialização automática da curva, os métodos de adição e remoção de pontos e o método MCA Crisp Adaptativo descritos anteriormente. Estes métodos são executados seguindo o fluxograma apresentado na Figura 3, em que exemplos de cada etapa são apresentados ao lado de sua representação no fluxograma. Nas imagens que contém a curva, os pontos são apresentados em azul e suas conexões em vermelho.

O primeiro passo para segmentar os pulmões de forma automática em imagens de TC é abrir a imagem DICOM. Para isto, usa-se a biblioteca livre *Dicom Toolkit* (DCMTK) (Barcelos Junior, 2012). Em seguida, a força externa da imagem é calculada utilizando o método ADP e uma RNA MLP para detectar o tipo de bordas obtidas pelo operador Sobel. Neste passo, as bordas do operador detectadas dentro do pulmão são excluídas do cálculo da força externa.

A curva é inicializada automaticamente através do método desenvolvido por Rebouças Filho (2010) determinando o centroide de inicialização da curva. Este ponto é usado para inicializar um polígono regular utilizado como inicialização da curva.

Esta curva move-se por iterações sucessivas da sequência de três métodos: MCA Crisp Adaptativo minimizando sua energia movimentando os pontos da curva, remoção de pontos baseada no ângulo e adição de pontos baseado da distância entre pontos consecutivos da curva. No fluxograma da Figura 3, esta sequência é chamada de ciclos, e a letra n indica a ordem de resultados obtidos em cada ciclo n .

A curva é rotulada estável quando o perímetro não varia após duas iterações consecutivas. Quando isto acontece, a segmentação do pulmão está concluída, e o polígono gerado pela curva é o resultado de sua segmentação.

Resultados

O método proposto é aplicado em imagens de TCAR utilizando imagens de pacientes com DPOC e voluntários sadios. Neste sentido, para avaliar a eficácia do MCA proposto, os resultados obtidos são comparados com um padrão obtido junto a um pneumologista utilizando a métrica de ajuste de forma proposta por Delves *et al.* (1992). Além disso, os resultados obtidos são comparado com os métodos de segmentação automática proposto no sistema SISDEP, além dos MCAs com energia Hilbertiana e dos MCAs VFC, GVF e Crisp.

Avaliação comparativa dos métodos usando um padrão ouro

Na avaliação realizada neste trabalho, o MCA Crisp Adaptativo 2D é comparado na segmentação dos pulmões em imagens de TC com os MCAs THRMulti, THRMod, GVF, VFC e Crisp, além do sistema SISDEP. Cada um dos métodos é inicializado de forma distinta, no qual sua inicialização conduz ao seu melhor resultado. Deste modo, os MCAs GVF, VFC, THRMod e THRMulti são inicializados conforme a proposta de Félix (2011) utilizando o método INAUTO, inicializando-se próximo às bordas. Enquanto isto, o sistema SISDEP conforme proposto por Félix (2007) e os MCAs Crisp e Crisp Adaptativo são inicializados de acordo com Rebouças Filho (2010).

Os métodos citados geram uma segmentação automática dos pulmões em imagens de TC e são avaliadas de forma quantitativa, utilizando para tanto os valores de ajuste de forma (Delves *et al.*, 1992). Para esta avaliação, o padrão-ouro da segmentação dos pulmões é obtido através da segmentação manual realizada por um médico pneumologista.

O MCA Crisp Adaptativo 2D é usado na segmentação dos pulmões em imagens de TC do tórax e para uma avaliação detalhada, este trabalho faz a comparação dos métodos utilizando apenas

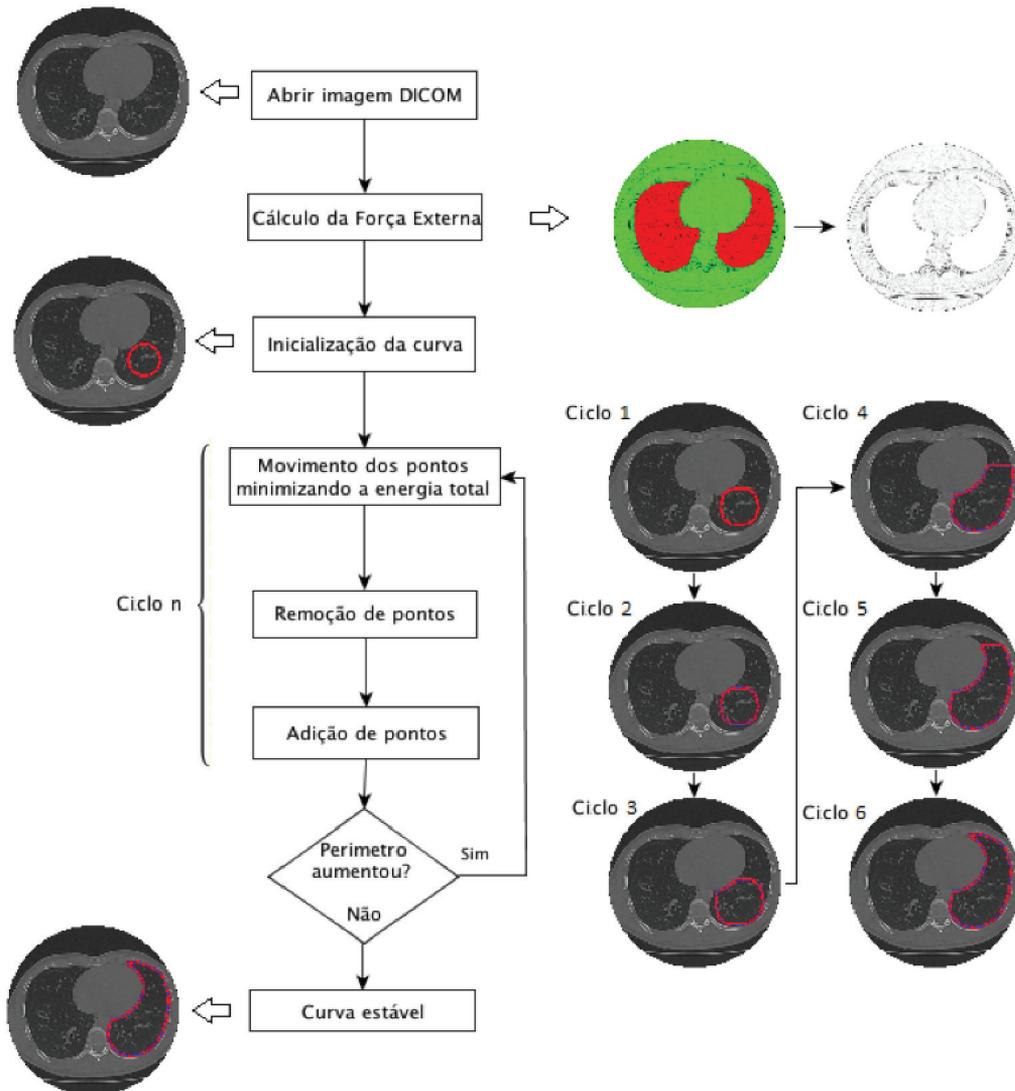


Figura 3. Demonstração do fluxograma de execução do método MCA Crisp Adaptativo 2D.

Figure 3. Demonstration of the flowchart for the execution of the 2D Adaptive Crisp MCA method.

24 imagens de TC do tórax, sendo 12 imagens de voluntários saudáveis e 12 imagens de pacientes com DPOC, considerando os níveis de corte ápice, hilo e base. Ressalta-se que, para apresentar os valores obtidos nas métricas de avaliação quantitativas utilizadas nas 24 imagens de TC são considerados 48 pulmões de teste, em que cada imagem possui 2 destes pulmões. Além disso, nos testes são considerados os níveis de corte ápice, hilo e base. Deste modo, as Figuras 4 e 5 apresentam exemplos de resultados nos níveis ápice, hilo e base de voluntários saudáveis e pacientes com DPOC, respectivamente.

Para avaliar os resultados obtidos utilizando a métrica de ajuste de forma, a Figura 6 apresenta os índices obtidos pelos métodos avaliados utilizando as

imagens de voluntários saudáveis e pacientes com DPOC. Uma média geral de todos os valores apresentados em cada gráfico é ilustrado na cor preta em cada figura. Estes valores são utilizados como referência para comparar os métodos em uma avaliação preliminar.

A média geral de todos os valores em cada gráfico é 90,86% para voluntários saudáveis e 87,73% para os pacientes com DPOC. Utilizando estes valores como referência na avaliação dos métodos, conclui-se que o método MCA Crisp Adaptativo 2D possui valores superiores às médias em todas as imagens, sendo seguido pelo método SISDEP que se encontra com valores abaixo da média em poucas imagens. Já os MCAs THRMulti, THRMod, GVF, VFC e Crisp oscilam, dependendo do pulmão analisado. Para

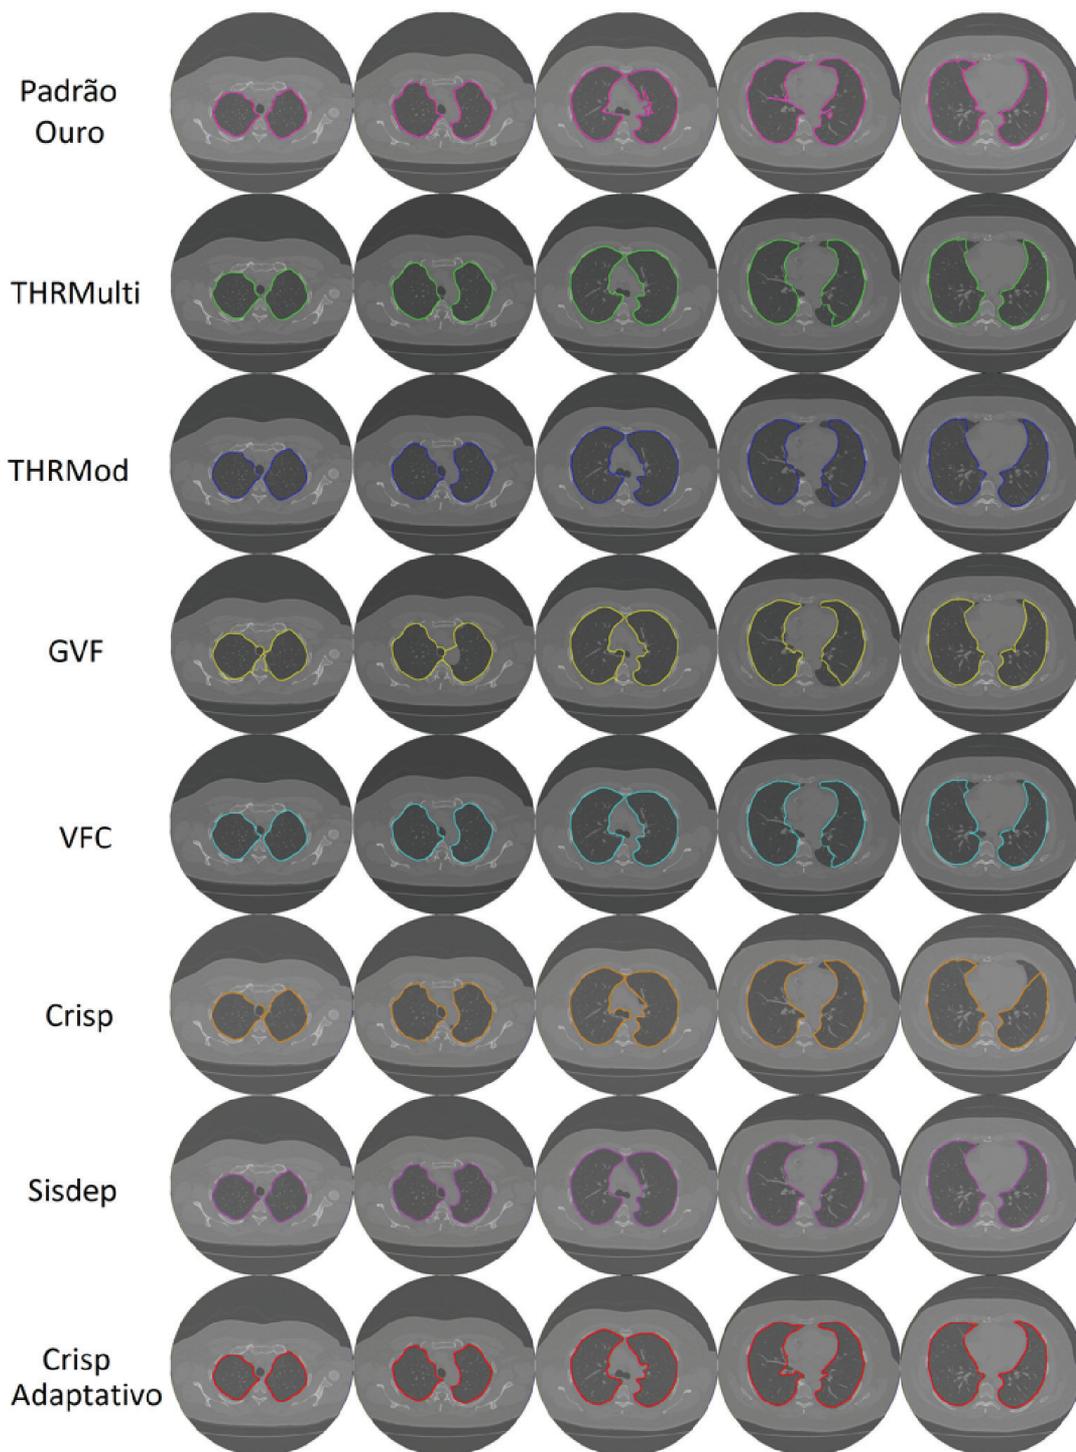


Figura 4. Exemplos de segmentação dos pulmões em imagens de TC do tórax de voluntários saudáveis obtidas pelo médico especialista, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP e MCA Crisp Adaptativo 2D, apresentadas em cada linha de cima para baixo, respectivamente.

Figure 4. Examples of segmentation of lungs in CT images of thorax of healthy volunteers obtained by the medical specialist, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP and 2D Adaptive Crisp MCA, presented in each row from top to bottom, respectively.

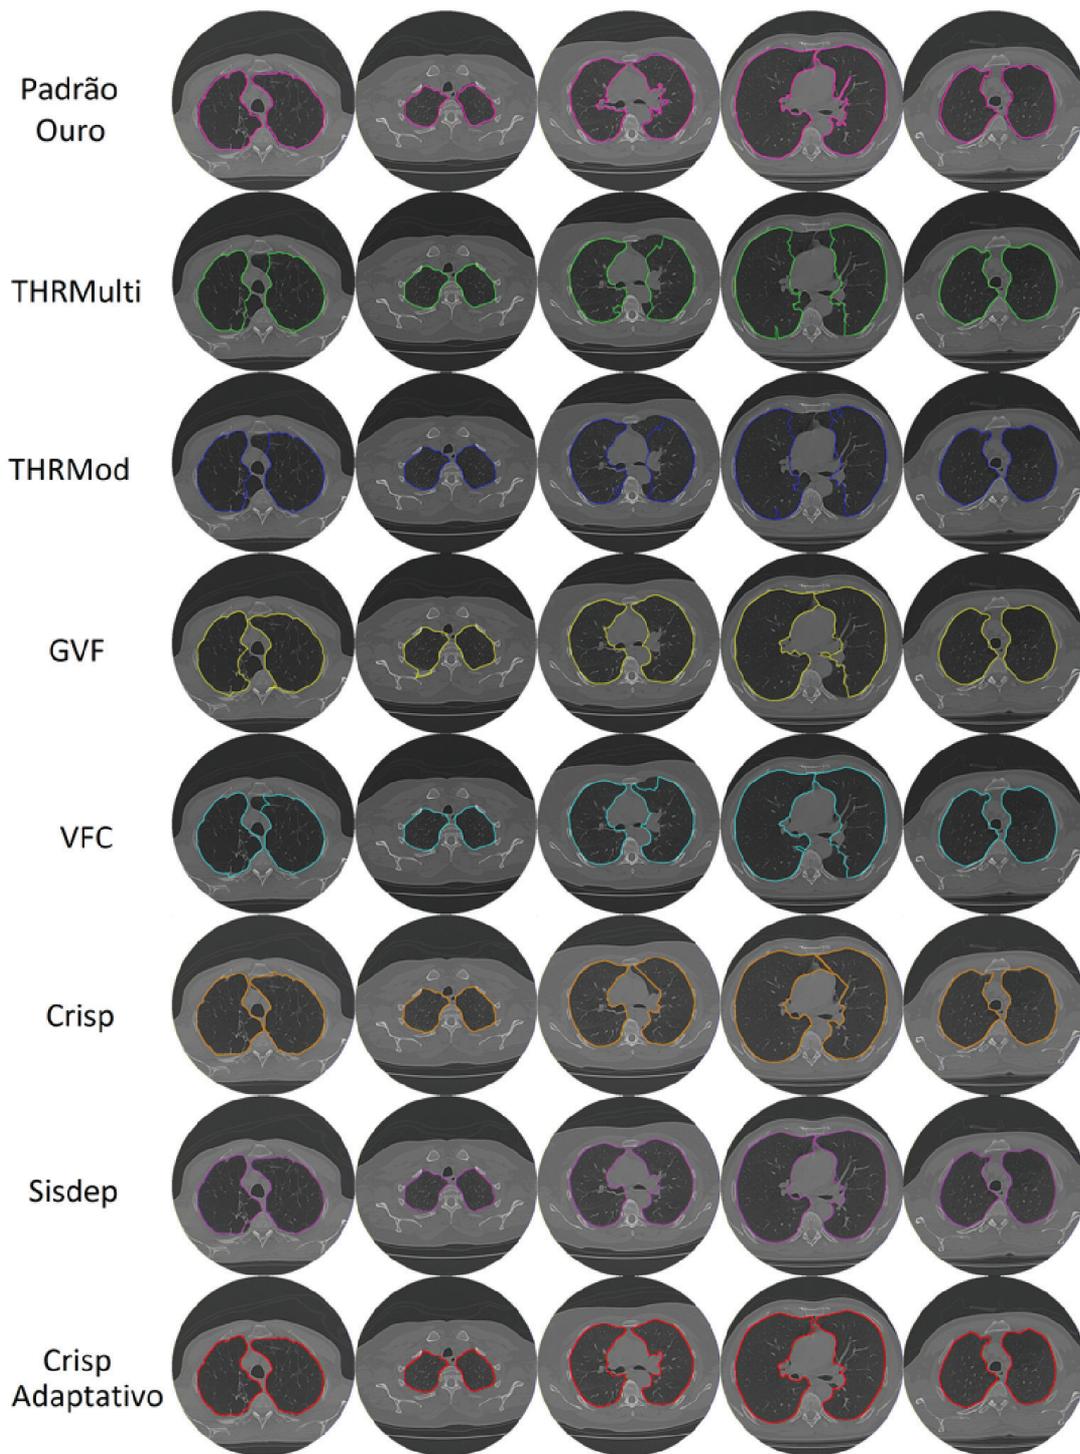


Figura 5. Exemplos de segmentação dos pulmões em imagens de TC do tórax de pacientes com DPOC obtidas pelo médico especialista, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP e MCA Crisp Adaptativo, apresentadas em cada linha de cima para baixo, respectivamente.

Figure 5. Examples of segmentation of lungs in CT images of the chest in patients with COPD found by medical specialist, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP and Adaptive Crisp MCA, presented in each line from top to bottom, respectively.

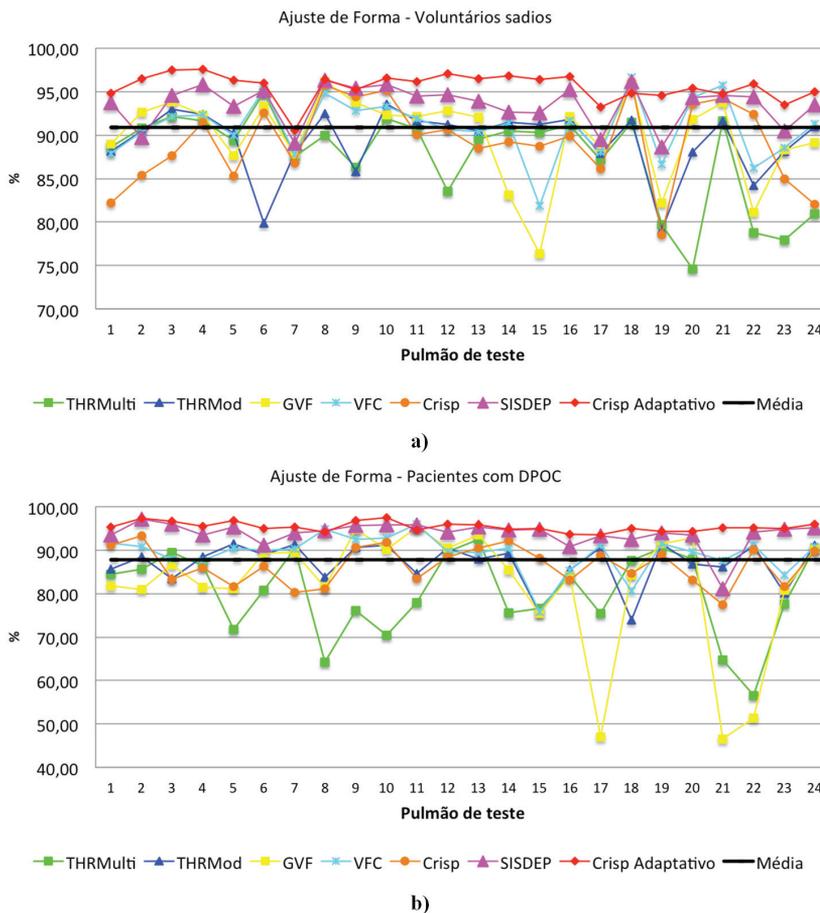


Figura 6. Índices de ajuste de forma obtidos em cada um dos 24 pulmões de teste, utilizando os MCAs THRMMod, THRMulti, GVF, VFC, Crisp, SISDEP e Crisp Adaptativo 2D: a) em voluntários sadios e b) pacientes com DPOC.
Figure 6. Adjustment indices of form, obtained in each one of the 24 test lungs, using the MCAs THRMMod, THRMulti, GVF, VFC, Crisp, SISDEP and 2D Adaptive Crisp: a) in healthy volunteers and b) patients with COPD.

complementar esta análise, a média e o desvio-padrão dos índice de ajuste de forma dos resultados obtidos por cada método avaliado são apresentados na Tabela 1.

Na avaliação quanto ao tempo de processamento de cada método avaliado, são considerados os tempos médios de segmentação dos pulmões das 24 imagens de teste de TC do tórax. O tempo foi contabilizado em todos os métodos desde a inicialização até a estabilização do perímetro da curva. Caso ultrapassasse 500 ciclos de minimização da energia, o método também era dito estável e a contagem do tempo se encerra. Os testes são realizados em um MacBook Pro Core i5 com 2.4 GHz e 8 GB de memória RAM, obtendo os resultados em segundos na ordem decrescente apresentados nas Tabela 2.

Discussão

Considerando os resultados obtidos na seção anterior, algumas análises podem ser realizadas.

Analisando as medidas de ajuste de forma dos voluntários sadios apresentadas na Tabela 1, conclui-se que o MCA Crisp Adaptativo 2D e o SISDEP se destacam, obtendo os valores $95,5 \pm 1,5$ e $93,5 \pm 2,3$, respectivamente. Os demais métodos obtêm valores de índices de ajuste de forma menores, em que o menor é $87,5 \pm 5,2$ obtido pelo MCA THRMulti. Já analisando as medidas de ajuste de forma dos pacientes com DPOC mostradas na mesma Tabela, conclui-se que os MCAs Crisp, Crisp Adaptativo 2D e o SISDEP se destacam, obtendo os valores $96,5 \pm 4,3$, $95,3 \pm 1,0$ e $93,7 \pm 1,2$, respectivamente. Os demais métodos obtêm valores de índices de ajuste de forma menores que os citados, sendo o menor destes $80,2 \pm 9,4$ obtido pelo MCA THRMulti. Os métodos MCA Crisp Adaptativo 2D e o SISDEP destacam-se por mostrarem ser menos influenciados pela forma e posição de corte dos pulmões, além de apresentarem menos influência das estruturas internas dos pulmões.

A correlação entre as médias do ajuste de forma de todos os métodos aplicados nos valores dos voluntários sadios com os valores dos pacientes com DPOC é 0,68. Isto indica que a DPOC afeta todos os métodos. Entretanto, os métodos MCA Crisp Adaptativo 2D e o SISDEP destacam-se pelos altos índices de ajuste de forma, sempre com médias superiores a 93,2% e 92,2%, respectivamente. Além disso, ressalta-se que o MCA Crisp Adaptativo 2D, além de obter a maior média em todas as imagens, mostra-se mais estável em relação aos demais métodos, visto que não altera significativamente seus valores quando aplicado em imagens com DPOC. Isto pode ser observado na Tabela 1, em que este método obtém os valores $95,5 \pm 1,5$ e $95,3 \pm 1,0$ em imagens de voluntários sadios e pacientes com DPOC, respectivamente.

Por fim, conclui-se que o método desenvolvido no sistema SISDEP e o MCA Crisp Adaptativo 2D aplicados na segmentação dos pulmões apresentam-se superiores aos demais métodos quando aplicados na segmentação dos pulmões em imagens de TC de voluntários sadios e pacientes com DPOC. Dentre

as razões dos altos índices das medidas de ajuste obtidos pelo MCA Crisp Adaptativo 2D, podem ser citadas a eficiência das energias internas e externas deste método. A energia externa determina de forma eficaz as fronteiras que devem ser encontradas por cada ponto da curva. Isto é possível pelo emprego da RNA MLP para determinar os tipos de bordas presentes em imagens de TC do tórax, indicando quais destas bordas estão dentro dos pulmões. Quanto ao tempo médio de processamento de cada método, o MCA Crisp Adaptativo 2D é duas vezes menor do que o método do sistema SISDEP, e pelo menos quinze vezes menor do que os demais métodos, quando aplicado na segmentação dos pulmões em imagens de TC do tórax. Embora seja mais lento do que o MCA Crisp, a relação custo/benefício continua maior, visto que a velocidade é próxima deste e a precisão é maior quanto às medidas de ajuste de forma.

Dentre os principais fatores que aumentam a velocidade do MCA Crisp Adaptativo 2D em relação aos demais métodos é a maneira usada para calcular a energia interna, caracterizada pela adaptabilidade da curva na segmentação de topologias complexas. Para demonstrar essa afirmativa, a Figura 7 mostra o passo a passo da evolução deste método desde a sua inicialização, apresentada na Figura 7a até sua estabilização do resultado final mostrado na Figura 7f. Nesta Figura, os pontos são apresentados em azul, suas conexões em vermelho, formando a curva, e a direção da energia interna Balão Adaptativa é apresentada em verde. Esta energia parte de cada ponto em direção ao local onde possui valor mínimo para a topologia apresentada em sua vizinhança. O contorno demonstrado é desenhado sobre a ilustração da energia externa Crisp Adaptativa 2D.

Analisando a convergência do MCA Crisp Adaptativo 2D mostrado na Figura 7, a partir de sua inicialização até sua estabilização, pode-se concluir que a energia interna do MCA Crisp Adaptativo 2D gera uma convergência rápida por três motivos:

- cada energia interna é direcionada para um destino distinto dos demais pontos;
- nenhuma direção aponta para dentro da curva, diminuindo seu tempo de processamento e aumentando sua eficácia; e
- em regiões homogêneas e distantes das bordas, a direção sempre aponta para as bordas dos objetos.

Estes tópicos em conjunto explicam a velocidade de convergência do método, já que cada ponto é direcionado para uma direção diferente. Além disso, explica a adaptabilidade às diferentes topologias dos pulmões, visto que sempre existe pelo menos um ponto na direção do restante do objeto que ainda não faz

Tabela 1. Média (μ) e desvio-padrão (σ) dos índices de ajuste de forma obtidos pelos métodos THRMulti, THRMod, GVF, VFC, SISDEP, Crisp e Crisp Adaptativo 2D, na segmentação dos pulmões em imagens de TC do tórax.

Table 1. Mean (μ) and standard deviation (σ) of the form adjustment indices obtained by the methods THRMulti, THRMod, GVF, VFC, SISDEP, Crisp and 2D Adaptive, in the segmentation of lungs in CT images of the thorax.

Método de Segmentação	Sadio		DPOC	
	μ (%)	σ (%)	μ (%)	σ (%)
THRMulti	87,5	5,2	80,2	9,4
THRMod	89,3	3,7	87,0	4,7
GVF	89,9	4,8	81,9	13,6
VFC	90,9	3,3	89,2	4,2
SISDEP	93,5	2,3	93,7	3,0
Crisp	89,2	4,5	96,5	4,3
Crisp Adaptativo	95,5	1,5	95,3	1,0

Tabela 2. Tempo médio de segmentação dos pulmões obtidos pelos métodos THRMulti, THRMod, GVF, VFC, SISDEP, Crisp, Crisp Adaptativo 2D.

Table 2. Average time for the segmentation of lungs obtained by methods THRMulti, THRMod, GVF, VFC, SISDEP, Crisp and 2D Adaptive Crisp.

Método	Tempo (s)
GVF	240
THRMod	150
THRMulti	150
VFC	30
SISDEP	4
MCA Crisp Adaptativo 2D	2
Crisp	1,5

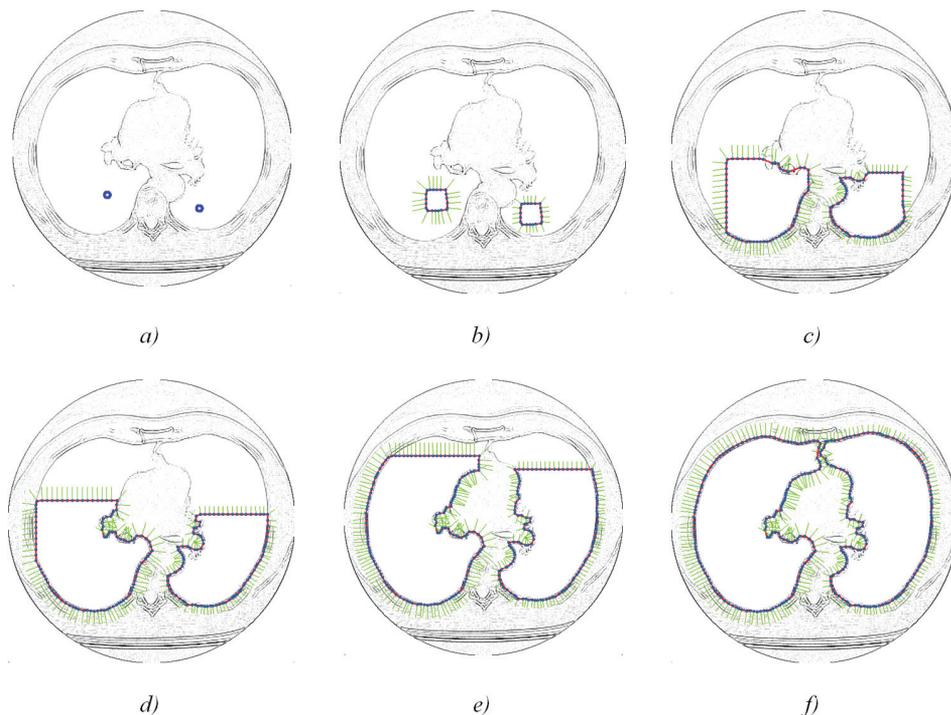


Figura 7. Exemplo das etapas de aplicação do MCA Crisp Adaptativo 2D, sobre a representação da energia externa deste método e apresentando a direção da energia interna Balão Adaptativa em verde: a) inicialização; b-e) passo a passo da evolução da curva; e f) resultado da segmentação.
Figure 7. Example of the steps for implementing 2D Adaptive Crisp MCA, on the representation of the external energy of this method and showing the direction of internal energy Adaptive Balloon in green: a) start; b-e) step by step of the evolution of the curve; and f) segmentation result.

parte do interior do contorno. Além disso, a energia externa gerada por uma RNA aumenta a eficácia no reconhecimento das bordas pulmonares.

Deste modo, pode-se concluir que o MCA Crisp Adaptativo 2D pode integrar sistemas de auxílio ao diagnóstico médico na área de Pneumologia de forma satisfatória, visto que apresenta-se superior aos demais métodos avaliados.

Referências

Amini A, Weymouth T, Jain RC. Using dynamic programming for solving variational problems in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1990; 12:855-67. <http://dx.doi.org/10.1109/34.57681>

Barcelos Júnior CL. Concepção, desenvolvimento e implantação de uma ferramenta par uso de laudo estruturado no padrão DICOM SR em sistemas de telemedicina de larga escala. Santa Catarina: Universidade Federal de Santa Catarina; 2012.

Berg G, Julian W, Mines R, Richman F. The constructive Jordan Curve Theorem. *Rocky Mountain Journal of Mathematics*. 1975; 5(2):225:36.

Cavalcante TS. Técnica para segmentação automática de vias aéreas em imagens de tomografia computadorizada do tórax. Fortaleza: Universidade Federal do Ceará; 2010.

Cohen LD. On active contour models and balloons. *CVGIV: Image Understanding*. 1991; 53:211-8. [http://dx.doi.org/10.1016/1049-9660\(91\)90028-N](http://dx.doi.org/10.1016/1049-9660(91)90028-N)

Delves LM, Wilkinson R, Oliver CJ, White RG. Comparing the performance of SAR image segmentation algorithms. *International Journal of Remote Sensing*. 1992; 13(11):2121-49. <http://dx.doi.org/10.1080/01431169208904257>

Félix JHS. Sistema de visão computacional para detecção e quantificação de enfisema pulmonar. Fortaleza: Universidade Federal do Ceará; 2007.

Félix JHS, Cortez PC, Holanda MA. Um novo algoritmo de segmentação automática de imagens tomográficas dos pulmões. In: *CBIS'2008: Anais do XI Congresso Brasileiro de informática em Saúde – CBIS; 2008; Campos do Jordão*. São Paulo: Sociedade Brasileira de Informática em Saúde; 2008. p. 1-6.

Félix JHS. Métodos de contornos ativos Hilbert 2D aplicados na segmentação de imagens dos pulmões em Tomografia Computadorizada do Tórax. Fortaleza: Universidade Federal do Ceará; 2011.

Fortaleza SCB. Efeitos da administração de pressão positiva contínua em vias aéreas de modo não invasivo sobre a aeração do parênquima pulmonar em pacientes com doença pulmonar obstrutiva crônica. Fortaleza: Universidade Federal do Ceará; 2006.

- Gevenois PA, Yernault JC. Can computed tomography quantify pulmonary emphysema. *European Respiratory Journal*. 1995; 5:843-8.
- Gonzales RC, Woods R. *Digital image processing*. 3th ed. New Jersey: Pearson Prentice Hall; 2008.
- Haykin, S. *Neural Networks: A comprehensive foundation*. 2nd ed. EUA: Prentice-Hall, 1999.
- Hu S, Hoffman EA, Reinhardt JM. Automatic lung segmentation for accurate quantitation of volumetric x-ray CT images. *IEEE Transactions on Medical Imaging*. 2001; 20(6):490-8. PMID:11437109. <http://dx.doi.org/10.1109/42.929615>
- Itai Y, Kim H, Ishikawa S. A segmentation method of lung areas by using snakes and automatic detection of abnormal shadow on the areas. *International Journal of Innovative Computing Information and Control*. 2007; 3(2):277-84.
- Kass M, Witkin A, Terzopoulos D. Snakes: active contours models. *International Journal of Computer Vision*, 1987.
- Li B, Acton ST. Active Contour External Force Using Vector Field Convolution for Image Segmentation. *IEEE Transactions on Image Processing*. 2007; 16(8):2096-106. <http://dx.doi.org/10.1109/TIP.2007.899601>
- Liang TK, Tanaka T, Nakamura H, Shirahata T, Sugiura H. An automated 3D emphysema extraction method using lung CT. In: *SICE Annual Conference 2008: Proceedings of SICE Annual Conference*; 2008; Tokyo. Tokyo: University Electro-Communications, 2008. p. 3110-4. <http://dx.doi.org/10.1109/SICE.2008.4655199>
- Marco R, Ceveri I, Corsico A, Sunyer J, Neukirch F, Kunzli N, Leynaert B, Janson C, Gislason T, Vermeire P, Svanes C, Burney P. An international survey of chronic obstructive pulmonary disease in young adults according to gold stages. *Thorax*. 2004; 59:120-5. PMID:14760151 PMID:1746950. <http://dx.doi.org/10.1136/thorax.2003.011163>
- Mackiewicz B. *Intracranial boundary detection and radio frequency correction in Magnetic Resonance Images*. Burnaby: School of Computing Science; 1995.
- Nixon MS, Aguado AS. *Feature extraction and image processing*. Woburn: Newnes, 2002.
- Reboças Filho PP. *MCA Crisp: Nova técnica de segmentação dos pulmões em imagens de Tomografia Computadorizada baseada no Metodo de Contorno Ativo*. Fortaleza: Universidade Federal do Ceará; 2010.
- Organização Mundial da Saúde - OMS. *Global strategy for the diagnosis, management and prevention of chronic obstructive pulmonary disease*. OMS; 2008.
- Silva A, Carvalho PC, Nunes AR, Gattas M. Segmentation and reconstruction of the pulmonary parenchyma. In: *WIM'2006: Anais do VI Workshop de Informática Médica – WIM*; 2006; Vila Velha. Vila Velha: WIM; 2006, p. 73-82.
- Silva A, Silva JS, Santos BS, Ferreira C. Fast pulmonary contour extraction in x-ray CT images: A methodology and quality assessment. In: *SPIE Conference on Medical Imaging: Proceedings of SPIE Conference on Medical Imaging: Physiology and Function from Multidimensional Images*; 2001; San Diego. San Diego: SPIE; 2001. v. 4321, p. 216-24. <http://dx.doi.org/10.1117/12.428139>
- Silva JSS. *Segmentação pulmonar em estudos de Tomografia Axial Computorizada*. Portugal: Universidade de Aveiro; 2005.
- Shojaii R, Alirezaie J, Babyn P. Automatic lung segmentation in CT images using Watershed Transform. *IEEE International Conference on Image Processing-ICIP*. 2005; 2:1270-3.
- Sluimer I, Prokop M, Van B. Toward automated segmentation of the pathological lung in CT. *IEEE Transactions on Medical Imaging*. 2005; 24(8):1025-38. PMID:16092334. <http://dx.doi.org/10.1109/TMI.2005.851757>
- Souza Júnior OS. *Método de reconhecimento pessoal através da íris usando funções geoestatísticas*. São Luís: Universidade Federal do Maranhão; 2006.
- Winkeler GFP. *Efeitos agudos da administração de pressão positiva contínua em vias aéreas de modo não invasivo sobre o parênquima pulmonar de voluntários sadios nas posições supina e prona: Alterações na Tomografia Computadorizada de alta resolução*. Fortaleza: Universidade Federal do Ceará; 2006.
- Xu C, Prince J. *Snakes, shapes and gradient vector flow*. Baltimore: Barton Hall; 1997.
- Yin XC, Liu CP, Han Z. Feature combination using boosting. *Pattern Recognition Letters*. 2005; 25(14):2195-205. <http://dx.doi.org/10.1016/j.patrec.2005.03.029>

Autores

Pedro Pedrosa Reboças Filho*

Departamento da Indústria, Instituto Federal de Educação, Ciência e Tecnologia do Ceará – IFCE, Av. Parque Central, s/n, Distrito Industrial I, CEP 61939-140, Maracanaú, CE, Brasil.

Paulo César Cortez, John Hebert da Silva Félix, Tarique da Silveira Cavalcante

Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará – UFC, Fortaleza, CE, Brasil.

Marcelo Alcantara Holanda

Departamento de Pneumologia, Hospital Universitário Walter Cantídio, Universidade Federal do Ceará – UFC, Fortaleza, CE, Brasil.