

ALGORITMOS DE SEGMENTAÇÃO DE IMAGEM E SUA APLICAÇÃO EM IMAGENS DO SISTEMA CARDIOVASCULAR

Tatiana D. C. A. Silva, João Manuel R. S. Tavares

Faculdade de Engenharia da Universidade do Porto (FEUP) /
Instituto de Engenharia Mecânica e Gestão Industrial (INEGI)
Rua Dr. Roberto Frias 400, 4200-465 Porto, Portugal
tdsilva@inegi.up.pt, tavares@fe.up.pt

Palavras chave: Processamento de Imagem, Análise de Imagem, Imagem Médica, Ultrassons, Revisão

Resumo

Em grande parte dos países desenvolvidos, doenças cardiovasculares, como ataques cardíacos ou acidentes vasculares cerebrais, representam a maior causa de morte. O comportamento do sistema cardiovascular e as causas dos seus problemas têm vindo a ser alvo de diversos estudos. Para tal, é essencial o desenvolvimento de técnicas robustas e eficientes de processamento e análise de imagem que facilitem a compreensão, diagnóstico e tratamento do sistema cardiovascular.

Graças às novas técnicas de imagiologia, tais como Tomografia Computorizada (CT), Angiografia, Ressonância Magnética (MR) e Ultrassons (*Doppler*), tem vindo a ser possível a modelação geométrica 3D das estruturas do sistema cardiovascular, como vasos e coração. Contudo, devido à complexidade das imagens envolvidas, tal modelação ainda requer frequentemente a utilização de procedimentos e ajustes manuais de maneira a conseguir-se modelos realistas.

Técnicas de processamento de imagem permitem melhorar e realçar a informação contida nas imagens originais. Por seu lado, técnicas de análise de imagem, como de segmentação de imagem, têm um papel crucial na extracção de informação de alto-nível a partir das imagens pré-processadas. No que diz respeito à segmentação de imagem, uma das principais tarefas para a compreensão, análise e interpretação de imagens, o seu principal objectivo é a divisão da imagem original em regiões (ou classes) homogéneas relativamente a uma ou mais características.

O principal objectivo deste artigo é a apresentação e discussão de métodos de segmentação adequados para a análise de imagens do sistema cardiovascular, nomeadamente de imagens de *Doppler*.

1. Introdução

A capacidade de diagnóstico por imagem aumentou significativamente com a evolução das técnicas de aquisição de imagens médicas, tais como Tomografia Computorizada (CT), Ressonância Magnética (MR), Angiografia e Ultrassons (em particular, de Doppler), que fornecem, cada vez mais informações detalhadas do ponto de vista de resolução e distinção de tecidos. As técnicas de visualização, processamento e análise de imagem têm sofrido grandes desenvolvimentos nos últimos anos [1]. Estas técnicas permitem uma melhor visualização, classificação, análise e manipulação por parte dos clínicos, tanto em imagens bidimensionais como em volumes tridimensionais e mesmo em séries temporais de imagens [2], [3].

Técnicas de processamento de imagem pretendem melhorar e realçar a informação contida nas imagens originais como, por exemplo, diminuindo o efeito do ruído presente nas mesmas ou corrigindo distorções geométricas. Uma das técnicas utilizadas em análise de imagem é a segmentação, que permite a compreensão, análise e interpretação de imagens. O seu principal objectivo é a divisão da imagem original em regiões (ou classes) homogéneas relativamente a uma ou mais características. Cada uma das regiões pode ser processada em separado para extracção de informação [4, 5]. 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 objectivo é delinear as estruturas anatômicas e as regiões (provavelmente patológicas) de interesse [6]. Existem diversas aplicações de técnicas de segmentação de imagem na ciência médica, como na localização de tumores e de microcalcificações, delineação de células do sangue, o planeamento cirúrgico, atlas de correspondência, registo de imagens, classificação de tecidos e estimativa de volume tumoral [7], [8].

Há um grande número de técnicas de segmentação que têm vindo a ser propostas e implementadas mas ainda não há um *standard* que satisfaça todos os critérios. Em geral, as técnicas de segmentação podem ser divididas em quatro classes:

- *Thresholding*;
- Segmentação baseada em contornos;
- Segmentação baseada em regiões;
- Classificação por pixéis.

A segmentação por *thresholding* é muitas vezes baseada no histograma de uma propriedade (em geral, o nível de cinzento) da imagem original. Na segmentação baseada em regiões é considerado o conteúdo dos pixéis da imagem, definindo regiões por inclusão dos pixéis que contenham certas características comuns. Por seu lado, a segmentação baseada em contornos baseia-se na definição geométrica dos elementos da imagem. Já a classificação por pixéis considera regularidades e repetição de características como critério de caracterização de uma região [2, 3].

2. Algoritmos de Segmentação

2.1 Baseados em *Thresholds*

Este tipo de algoritmos baseia-se no princípio de que as estruturas ou órgãos de interesse têm características distintas quantificáveis nas imagens a segmentar, tais como a intensidade ou magnitude do gradiente. Este processo de segmentação baseia-se na busca de pixéis cujos valores estão dentro dos intervalos definidos como limiares (*thresholds*). O método mais comum é a média de valores de *thresholds* devido à sua simplicidade de implementação e propriedades intuitivas. Nesta técnica, um valor predefinido (*threshold*) é seleccionado manualmente ou automaticamente, e uma imagem original é dividida em grupos de pixéis com valores iguais ou superiores ao limiar definido e grupos de pixéis com valores inferiores a esse limiar [2-4].

A abordagem mais intuitiva é o global *thresholding*, que é adequado para imagens bimodais. Quando apenas um limiar é seleccionado para toda a imagem, com base no histograma da imagem, é usualmente chamado de global *thresholding*. 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 seleccionados de forma independente para cada *pixel* ou grupo de pixéis, é chamado de dinâmico ou adaptativo [7, 9].

2.1.1 *Thresholding* Global

Quando apenas um único valor de *threshold* é seleccionado para uma imagem a segmentar, o *threshold* é considerado global. Este tipo de *threshold* é baseado no pressuposto de que a imagem a segmentar tem um histograma bimodal e, portanto, o objecto pode ser extraído do fundo da mesma por uma operação simples que compara os valores da imagem com o valor de *threshold* T definido [2]. Suponha-se uma imagem $f(x, y)$ com o histograma da Figura 1. Os pixéis do objecto e do fundo têm níveis de cinza agrupados em dois modos dominantes. Uma maneira óbvia para extrair o objecto do fundo é seleccionar um limiar T que separa estes modos.



Figura 1 Exemplo de um histograma bimodal com um *threshold* seleccionado T .

Se $f(x, y)$ é uma imagem com valor de *pixel* máximo I_{max} , e supondo que T denota a percentagem de *threshold* do máximo valor de pixéis acima da qual os pixéis serão seleccionados, então os pixéis com valor dado por ρ obedecendo a:

$$\frac{T}{100} I_{max} \leq \rho \leq I_{max}, \quad (1)$$

podem ser agrupados e uma imagem binária é obtida:

$$g(x,y) = \begin{cases} 1 & \text{se } f(x,y) \geq \rho \\ 0 & \text{caso contrário} \end{cases} \quad (2)$$

na qual os pixéis com valor 1 (um) correspondem a objectos e os pixéis com valor 0 (zero) correspondem ao fundo. O resultado da limiarização é uma imagem binária. O método de Otsu [10] é um método de *threshold* global que obtém de forma automática os valores de *threshold* com base no histograma da imagem a segmentar (Figura 2).




Figura 2 Imagem de uma bifurcação da carótida obtida por Doppler (a) resultado da aplicação do método de Otsu (b).

2.1.2 Thresholding Local e Adaptativo

Quando o fundo da imagem a segmentar não é constante, o contraste dos objectos representados varia ao longo do mesmo e o método de *thresholding* global pode não funcionar satisfatoriamente em algumas áreas. Se as variações forem descritas por uma função conhecida, é possível corrigi-las usando técnicas de correcção de níveis de cinzento, depois das quais um único *threshold* deverá funcionar de forma satisfatória. Outra solução é a aplicação de algoritmos de *thresholding* adaptativos. Este tipo de *threshold* pode ser definido da seguinte forma:

- 1) Dividir a imagem original em sub-imagens e determinar os limiares de *threshold* para cada sub-imagem; ou
- 2) Examinar as intensidades da imagem original na vizinhança de cada *pixel*.

No primeiro método, a imagem é normalmente dividida em sub-imagens rectangulares sobrepostas e os histogramas são calculados para cada um. As sub-imagens utilizadas devem ser dimensões suficientes para incluir tanto o objecto como pixéis do fundo da imagem. Se a sub-imagem tem um histograma bimodal, o limiar local

deve ser o mínimo entre os picos desse histograma. Se o histograma é unimodal, o limite deve ser posteriormente calculado por interpolação a partir dos limiares locais encontrados para as sub-imagens seguintes. No final, uma segunda interpolação é usada para encontrar os limites correctos em cada *pixel*. No segundo método, o limiar é seleccionado usando o valor médio da distribuição de intensidade local.

Os métodos de *threshold* local e adaptativo são computacionalmente mais exigentes do que o *threshold* global. No entanto, têm se revelados úteis para segmentar objectos em imagens com fundos não constantes, e para a extracção de regiões que pequenas e esparsas [2].

2.2 Baseados em contornos

Na detecção de bordas (ou contornos), analisa-se as descontinuidades nos níveis de cinza da imagem original. Uma borda é o limite entre duas regiões com propriedades relativamente distintas de nível de cinza. As bordas da imagem caracterizam os contornos dos objectos representados na mesma e são bastante úteis para a segmentação e identificação dos mesmos. Pontos de borda podem ser entendidos como as posições dos pixéis com variações abruptas de níveis de cinza que podem ser reflectidos por um gradiente [11]. Os pontos de borda caracterizam as transições entre objectos distintos. Para uma dada imagem $f(x,y)$, é possível calcular a magnitude do gradiente como:

$$|G| = \sqrt{G_x^2 + G_y^2} = \sqrt{\left[\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2\right]}, \quad (3)$$

e a direcção do gradiente como:

$$D = \tan^{-1}\left(\frac{G_y}{G_x}\right), \quad (4)$$

onde G_x e G_y são os gradientes nas direcções x e y , respectivamente.

Existem vários métodos de segmentação baseados na identificação de bordas. Os mais simples são aqueles em que as bordas são detectadas por operadores de gradiente, como o operador de Sobel, de Canny [12] e Laplaciano [13] (Figura 3).

A segmentação baseada em contornos é computacionalmente rápida e não exige informação prévia sobre o conteúdo da imagem a segmentar. Um problema comum deste método é que muitas vezes as bordas não incluem totalmente o objecto [4]. Para evitar este problema é necessário formar fronteiras fechadas em torno das regiões de interesse: uma etapa de pós-processamento que faz a ligação ou o agrupamento de arestas que correspondem a um limite único [2]. Em geral, a ligação das bordas detectadas é computacionalmente exigente e não muito confiável. Para solucionar este problema, é útil fazer a ligação das bordas de forma semi-automática, permitindo que o utilizador defina ou rectifique a borda final quando o rastreamento automático não é totalmente correcto [2, 9].




Figura 3 Resultado dos operadores de Sobel (a), Canny (b) e Laplaciano (c) aplicados imagem da Figura 2a.

2.3 Baseados em 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 [4].

A técnica mais simples de segmentação baseada em regiões é chamada de *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 inspeccionada 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. Deste modo é possível que alguns pixels possam permanecer sem rótulo, isto é, estarem isolados, quando pára o processo de crescimento [2, 14].

Os resultados do *region growing* dependem fortemente da escolha do critério de homogeneidade. Se não for escolhido correctamente, as regiões podem escapar para

áreas adjacentes e fundirem com as regiões que não pertencem ao objecto de interesse. Outro problema desta técnica é que diferentes pontos de partida não podem crescer em regiões idênticas [15].

A vantagem da técnica de *region growing* é que permite a segmentação correcta de regiões que têm as mesmas propriedades e estão espacialmente separadas e também gera regiões conectadas entre si (Figura 4).

Os métodos de *region splitting* (divisão por regiões) têm uma estratégia oposta à do *region growing*. Estes métodos partem de toda a imagem e examinam os critérios de homogeneidade. Se os critérios não se verificam, a imagem (ou sub-imagem) é dividida em duas ou mais sub-imagens. Este processo termina quando todas as sub-imagens satisfazem os critérios de homogeneidade.

Uma combinação de segmentação por *region splitting* e por *region growing* soma os benefícios de ambas as abordagens [3].



Figura 4 Resultado da aplicação de um algoritmo de *region growing* à imagem da Figura 2a.

2.3.1 Watershed Algorithm

A segmentação por *watershed* (método do divisor de águas) é uma técnica de segmentação de imagem que tem vindo a ser usada com sucesso em várias aplicações. É uma técnica baseada em regiões que utiliza a morfologia da imagem [2]. Neste caso, é necessário que se faça a selecção de pelo menos um marcador (semente) interior a cada objecto da imagem, incluindo tanto o fundo da imagem, como os objectos a segmentar. Usualmente, o utilizador é responsável pela selecção dos marcadores, contudo estes também podem ser seleccionados por um procedimento automático que considere conhecimentos específicos sobre os objectos a segmentar.

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 esta “escorre”. O método de *watershed* utiliza os módulos dos gradientes, as variações locais de intensidade na imagem, como uma “topografia” montanhosa que separa regiões, fundindo regiões de forma a aumentar 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 interactivas, mesmo quando as imagens a processar são de grandes dimensões e complexidade [3].

2.4 Classificação por pixels

Recorde-se que o passo fundamental dos métodos de *threshold* descritos anteriormente é a escolha dos limiares

de classificação que é normalmente realizada manualmente ou de forma semi-automática com base nas estatísticas locais, como o máximo, média ou mínima da imagem dada (ou sub-imagens). O conceito básico da selecção limiar pode ser generalizado, levando a um paradigma orientado a dados, que determina o limiar automaticamente com base em técnicas de agrupamento ou redes neuronais artificiais.

Os métodos de classificação por pixéis, que utilizam as estatísticas do histograma para definir um único ou vários valores de *threshold* para classificar uma imagem, podem ser considerados como uma generalização das técnicas de *thresholding*. Tais métodos são particularmente úteis quando os pixéis a segmentar têm múltiplos atributos, que podem ser expressos por um vector multidimensional em função do espaço. Por exemplo, o vector de características pode consistir em nível de cinza, textura local e componentes de cor para cada *pixel* da imagem a segmentar.

Assim, os pixéis de cada imagem podem ser divididos em distintas classes de pixéis semelhantes. Por exemplo, os pixéis de uma imagem médica podem ser divididos em pixéis que pertencem a tecidos duros e a tecidos moles, ou a um tumor e tecidos sãos.

No caso de existirem várias imagens de exemplo em que um perito tenha estabelecido marcadores de classe, que constituem um *training set* (conjunto treino), pode-se deduzir características da imagem que vão permitir a distinção entre pixéis de diferentes classes. Estas características podem, por exemplo, ser baseadas na intensidade de pixéis ou na média de intensidade da vizinhança. Para um *pixel* numa nova imagem, pode-se comparar as suas características com a distribuição de características do *training set* e estimar a probabilidade desse pixel pertencer a certa classe. A este processo chamamos classificação por pixéis [2, 3].

2.4.1 Técnicas de Agrupamento (*Clustering*)

A técnica de *Clustering* tem vindo a ser amplamente aplicada em várias áreas, como em antropologia, arqueologia, psiquiatria e zoologia [3, 4]. Esta técnica é das mais comuns na segmentação de imagens médicas. O *Clustering* é o processo de agrupamento de objectos semelhantes num único *cluster* (grupo), enquanto objectos 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 vectores num dado espaço [3].

Cada *cluster* é representado pelo seu centroide (ou média) e variância, que indica a densidade dos objectos dentro do *cluster*, e a formação dos *clusters* é optimizada de acordo com uma função de custo que normalmente leva em conta a semelhança dentro de cada *cluster* e dissimilaridade entre *clusters* [2].

Há várias técnicas de agrupamento propostas na literatura [2, 3, 5, 16], usualmente divididas em: algoritmos de classificação supervisionados e algoritmos de classificação não-supervisionados. As técnicas supervisionadas são o *k-nearest neighbor* (kNN) [17], *maximum likelihood* (ML) *algorithms* [18], *supervised artificial neural networks* (ANN) [19], *support vector machines* (SVM) [19], *active shape models* (ASM) [19] e *active appearance models* (AAM) [19]. Por seu lado, as não supervisionadas são a *CM algorithms fuzzy C-means*

(FCM) [20], os *algorithms iterative self-organising data analysis technique algorithms* (ISODATA) [20] e as *unsupervised neural networks* [2, 4].

Na aprendizagem supervisionada, fornece-se ao algoritmo uma resposta correcta (saída) para cada padrão de entrada devidamente identificado. Os parâmetros do algoritmo são então ajustados na fase de treino com o objectivo de permitir que sejam produzidas respostas tão próximas quanto possíveis das respostas correctas.

Por seu lado, na aprendizagem não-supervisionada não é necessária uma resposta correcta associada com cada padrão de entrada no conjunto de dados avaliados. Sendo explorada a estrutura subjacente aos dados, ou correlações entre padrões dos próprios e organizados os mesmos em categorias a partir das correlações estabelecidas [4].

2.4.2 Modelos Deformáveis

A segmentação baseada em modelos deformáveis tem sido considerada na Visão Computacional como grande sucesso, sendo a Imagem Médica um dos campos onde se tem revelado eficaz [21].

Grande parte dos métodos de segmentação de imagem baseados em modelos deformáveis passa pela optimização de funções objectivo, procurando encontrar um compromisso entre um termo de energia baseado na imagem e outro termo relacionado com uma energia interna ou modelo de forma (tipicamente a suavidade de pontos adjacentes de um modelo). Uma alternativa aos modelos baseados na optimização de uma função objectivo, consiste em formular a deformação de um contorno como uma frente de onda que se propaga, que pode ser considerada como uma iso-linha de uma função envolvente. Pode-se dividir, então, os modelos deformáveis em dois tipos: Modelos Paramétricos, como os contornos Activos ou *Snakes* [22], e Modelos Geométricos ou *Level Set*.

A - Contornos Activos ou *Snakes*

Em Visão Computacional, o modelo de contornos activos, também conhecido por *Snake*, tem sido utilizado de forma eficaz para implementar o contorno de segmentação e extrair características do objecto de interesse, sendo considerado um sucesso em várias aplicações de análise de imagem médica [2].

De forma simplificada, um modelo de *Snake* pode ser considerada como uma curva com uma função de energia. Usualmente, para acompanhar o contorno de um objecto desejado numa imagem, alguns pontos da curva inicial devem ser inicialmente especificados perto da fronteira do objecto. Quando o algoritmo é aplicado, a *Snake* vai “mover-se” gradualmente sob determinadas restrições em direcção às posições nas quais se localiza o contorno do objecto a segmentar. Este processo de deformação é geralmente realizado por procura iterativa de um mínimo local de uma função de energia. No entanto, um problema bem conhecido do modelo clássico de *Snake* é que este pode ficar preso num local de soluções mínimas provocadas, por exemplo, por ruído ou má inicialização [22].

Depois da representação da curva deformável por uma função de energia, segue-se a optimização do processo de segmentação, guiada por uma minimização da energia do

contorno, o que faz com que a curva deformável evolua gradualmente a partir do contorno inicial para o limite desejado do objecto mais próximo [23]. A função de energia contém duas parcelas: energia interna, E_{int} , e energia externa, E_{Ext} .


Geralmente, a energia interna E_{int} apenas impõe restrição à suavidade da curva, como o comportamento da elasticidade e curvatura; enquanto a energia externa E_{Ext} é responsável por “puxar” a curva da *Snake* na direcção dos limites do objecto a segmentar. Estas duas energias são normalmente formuladas por uma expressão da energia que é minimizada deformando o contorno num processo de optimização:

$$E_{Snake} = \sum_{i=1}^N [E_{int}(i) + E_{ext}(i)], \quad (5)$$


$$E_{int}(i) = \alpha_i \|v_i - v_{i-1}\|^2 + \beta_i \|v_{i-1} - 2v_i + v_{i+1}\|^2, \quad (6)$$

onde N é o número total de pontos da *Snake*; $v_i = (x_i, y_i)$ é uma coordenada de i ésimo ponto de *Snake*. O parâmetro α_i é uma constante que impõe a restrição de tensão entre dois pontos adjacentes da *Snake*. Quanto maior o α_i , menor será o contorno obtido. O parâmetro β_i é uma restrição de ajuste à curvatura entre todos os três pontos consecutivos da *Snake*. De um modo geral, quanto maior o valor de β_i , mais suave é o contorno resultante. Em diversas aplicações nas quais o tamanho do objecto desejado e as curvaturas podem variar, os valores de α_i e β_i têm necessidade de ser ajustados [2].

Um algoritmo de *Snake* muito usado foi proposto *Yezzi* [24] e assume que uma imagem consiste num número finito de regiões, caracterizadas por um conjunto predeterminado de características (média ou textura, por exemplo) que podem ser estimadas a partir dos dados da imagem. Um exemplo de uma aplicação deste algoritmo numa imagem Doppler de bifurcação da carótida pode ser visto na Figura 5.



a)



b)

Figura 5 Contorno inicial usado (a) para aplicação do algoritmo de *Yezzi* (*Snake*) à imagem da bifurcação da carótida (b).

B – Modelos Geométricos ou *Level Set*

Os modelos geométricos ou de *level set* constituem uma alternativa aos modelos baseados na optimização de uma função objectivo. Nestes métodos, a deformação do contorno é formulada como uma frente de onda que se propaga e que pode ser considerada como *level set* de valor zero de uma função envolvente. Esta função envolvente pode ser expressa na forma de uma equação diferencial parcial em que um termo de velocidade força a paragem da propagação de acordo com informação obtida a partir da imagem. Os esforços nesta área iniciaram-se em [25] e têm sido aplicados a imagem médica por vários autores [4, 26, 27]. Estes métodos fornecem a base para o processo numérico usado pelos métodos designados em [23] por modelos geométricos.

O processo de segmentação incorpora uma curva inicial que é o *level set* de nível zero de uma superfície de dimensão superior e faz evoluir esta superfície para que o *level set* de nível zero convirja para o objecto a segmentar. A perspectiva usada corresponde a uma formulação Euleriana do movimento e não Lagrangiana como é o caso dos modelos paramétricos [23], [25]. Uma propriedade útil desta abordagem é o facto da função de *level set* se manter válida mesmo quando a curva altera a sua topologia, uma vantagem em relação aos modelos paramétricos.

Uma das características mais notáveis desta aproximação é a facilidade de generalização a dimensões superiores [28]. No entanto, a facilidade de adaptação da topologia, útil em muitas aplicações, pode por vezes, conduzir a resultados indesejáveis, produzindo formas com topologia não consistente com a do objecto a detectar.

Em [29], usando uma formulação de minimização de energia, foi demonstrado, primeiro para 2D [30] e depois para 3D [29], a relação existente entre modelos que utilizam funções velocidade induzidas por forças potências (o que acontece na maior parte das variantes) e modelos paramétricos que não incluem o termo de rigidez. Mais tarde, *Xu et al.* [23] obtiveram uma relação matemática explícita entre uma formulação de força dinâmica para modelos deformáveis paramétricos e uma formulação para modelos geométricos, permitindo a utilização de funções velocidade derivadas de forças não potenciais, isto é, forças que não podem ser expressas como o negativo do gradiente de funções de energia potencial.

Um exemplo de uma aplicação de *level set* numa imagem de Doppler de bifurcação da carótida pode ser visto na figura 6, onde foi utilizado o algoritmo de *Chan-Vese*, [31] com um contorno inicial semelhante ao da Figura 5a.




Figura 6 Resultado da aplicação do algoritmo de *Chan Vese (Level Set)* à imagem da bifurcação da carótida.

3. Conclusão

A maioria dos algoritmos necessitam de combinar várias técnicas de processamento e segmentação de imagem para melhorar os resultados obtidos. Por esta razão, não existe uma classificação universal para algoritmos de segmentação. Neste artigo, classificou-se os algoritmos de segmentação em quatro categorias e resumiu-se as suas características principais.

Os métodos de segmentação computadorizados demonstraram a sua grande utilidade em aplicações de análise de imagem médica e são usados actualmente para melhor compreensão, diagnóstico e tratamento de disfunções.

A investigação nesta área continua activa, procurando-se obter algoritmos de segmentação cada vez mais robustos ao ruído e à inicialização, bem como a outras características da imagem que dificultam a segmentação.

Futuras pesquisas na segmentação de imagens médicas vão ser direccionadas para melhorar a exactidão, precisão e velocidade computacional de métodos de segmentação existentes, bem como reduzir a quantidade de interacção manual requerida. Exactidão e precisão podem ser melhoradas, por exemplo, através da incorporação de informação prévia de um atlas que reúna conhecimento prévio dos objectos a segmentar e combinando diferentes técnicas de segmentação.

Agradecimentos

Este trabalho foi parcialmente desenvolvido no âmbito dos projectos “Simulação computacional do sistema cardiovascular tendo em vista aplicação hospitalar”, “Imagiologia Modelação e Simulação do Sistema Cardiovascular - SIMCARD” e “Metodologias para Análise de Órgãos a partir de Imagens Médicas Complexas – Aplicações à Cavidade Pélvica Feminina”, com as referências PTDC/SAU-BEB/102547/2008, UTAustin/CA/0047/2008 e PTDC/EEA CRO/103320/2008, respectivamente, financiados pela Fundação para a Ciência e a Tecnologia (FCT).

Referências

1. A. Quarteroni and M. Veneziani, "Computational Vascular Fluid dynamics: problems, models and methods". *Computer and Visualization in Science*. 2000
2. I.N. Bankman. *Handbook of Medical Imaging*. Vol. II. San Diego/ London: Academic Press, 2000.
3. K.-P. Wong. *Handbook of Biomedical Image Analysis*. Edited by E. Micheli-Tzanakou. Vol. II - Segmentation Models. New Jersey: Kluwer Academic / Plenum Publishers, 2005.
4. Z. Ma, J. Tavares, R. Jorge and T. Mascarenhas, "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
5. D.J. Withey and Z.J. Koles, "Medical Image Segmentation: Methods and Software". *International Conference on Functional Biomedical Imaging*. p. 140-143. 2007
6. D.N. Ghista. *Applied Biomedical Engineering Mechanics*. New York: CRC Press, 2008.
7. J.S. Suri, D.L. Wilson and S. Laxminarayan, eds. *Handbook of Biomedical Image Analysis*. Vol. 2. 2005, Kluwer Academic/ Plenum Publishers: New York.
8. R. Himeno, "Blood Flow Simulation toward Actual Application at Hospital". *The 5th Asian Computational Fluid Dynamics*. 2003
9. D.L. Pham, C. Xu and J.L. Prince, "Current Methods in Medical Image Segmentation". *Annual Review in Biomedical Engineering*. 2000
10. N. Otsu, "A threshold selection method from gray-level histograms". *IEEE Transactions on Systems, Man, and Cybernetics*. **9**(1): p. 62-66. 1979
11. G. Fung, *A Comprehensive Overview of Basic Clustering Algorithms*. 2001.
12. J. Canny, "A computational approach to edge detection". *IEEE Transactions on Pattern Analysis and Machine Intelligence*. **8**(6): p. 679-698. 1986
13. L.S. Davis, "A survey of edge detection techniques". *Computer Graphics and Image Processing*. **4**(3): p. 248-270. 1975
14. D.J. Withey and Z.J. Koles, "Medical Image Segmentation: Methods and Software". *IEEE/IET Electronic Library (IEL)*. 2007
15. S. Mitchell, J.G. Bosch, B.P.F. Lelieveldt, R.J.v.d. Geest, J.H.C. Reiber, and M. Sonka, "3-D Active Appearance Models: Segmentation of Cardiac MR and Ultrasound Images". *IEEE TRANSACTIONS ON MEDICAL IMAGING*. **21**. 2002
16. T. McInerney and D. Terzopoulos, "Deformable Models in Medical Image Analysis: A Survey". *Medical Image Analysis*. **1**: p. 91-108. 1996
17. H.A. Vrooman, C.A.C. CA, R. Stokking, I.M. Arfan, M.W. Vemooij, M.M. Breteler, and W.J. Niessen, "kNN-based multi-spectral MRI brain tissue classification: manual training versus automated atlas-based training.". *SPIE Medical Imaging*. 2006
18. A. Sarti, C. Corsi, E. Mazzini and C. Lamberti, "Maximum likelihood segmentation of ultrasound images with Rayleigh distribution.". *IEEE Trans Ultrason Ferroelect Freq Control*. **52**(6): p. 947-960. 2005
19. M. James. *Classification algorithms*. NY: Wiley-Interscience, 1985.

20. M.A. Jacobs, R.A.K. RA, H. Soltanian-Zadeh, Z.G.Z. ZG, A.V. Goussev, D.J. Peck, J.P. Windham, and M. Chopp, "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
21. J.S. Silva, B.S. Santos, A. Silva and J. Madeira, "Modelos Deformáveis na Segmentação de Imagens Médicas: uma introdução". *Revista do DETUA*. **4**. 2004
22. M. Kass, A. Witkin and D. Terzopoulos, "Snakes: active contour models". *Int J Comp Vis*. **1**(4): p. 321-331. 1987
23. C. Xu, D.L. Pham and J.L. Prince. *Image Segmentation Using Deformable Models (cap. III)*. in *SPIE: The International Society for Optical Engineering*. 1999.
24. A. Yezzi, J.A. Tsai and A. Willsky. *A Statistical Approach to Snakes for Bimodal and Trimodal Imagery*. 1999. The Proceedings of the Seventh IEEE International Conference and Computer Vision.
25. S. Osher and J.A. Sethian, "Fronts Propagation with Curvature Dependent Speed: Algorithms Based on Hamilton- Jacobi Formulations". *Journal of Computational Physics*. **79**: p. 12-49. 1988
26. D. Jayadevappa, S.S. Kumar and D.S. Murty, "A New Deformable Model Based on Level Sets for Medical Image Segmentation". *IAENG International Journal of Computer Science*. **36**(3). 2009
27. J. Schmid and N. Magnenat-Thalmann, "MRI bone segmentation using deformable models and shape priors.". *Medical Image Computing and Computer-Assisted Intervention*. **11**(1): p. 119-126. 2008
28. J.A. Sethian, "Level Set methods: An Act of Violence". *American Scientist*. **85**. 1997
29. V. Caselles, R. Kimmel, G. Sapiro and C. Sbert, "Minimal Surfaces Based Object Segmentation". *IEEE Transactions on Pattern Analysis and Machine Intelligence*. **19**: p. 394-398. 1997
30. V.C.R.K.G. Sapiro, *Geodesic Active Contours*, in *International Journal of Computer Vision*. 1997. p. 61-79.
31. T.F. Chan and L.A. Vese, "Active Contours Without Edges". *IEEE Transactions on Image Processing*. **10**(2). 2001