

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

**Tatiana D. C. A. Silva<sup>1</sup>, João Manuel R. S. Tavares<sup>1</sup>**

1: 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  
e-mail: tdsilva@inegi.up.pt, tavares@fe.up.pt

**Palavras-chave:** Processamento de Imagem, Biomecânica, Ultrassons, Revisão.

### **Resumo**

*Em grande parte dos países desenvolvidos, doenças cardiovasculares como ataques cardíacos ou acidentes vasculares cerebrais representam a maior causa de morte. Recentemente, o comportamento do sistema cardiovascular e as causas dos seus problemas estão a ser alvo de vários estudos. Para o sucesso desses estudos, é essencial o desenvolvimento de técnicas robustas e eficientes de análise de imagem médica que permitam a compreensão, diagnóstico e tratamento de disfunções cardiovasculares.*

*Graças às novas técnicas de aquisição de dados em imagem médica, tais como Tomografia Computorizada (CT), Angiografia, Ressonância Magnética (MR) e Ultrassons (nomeadamente de Doppler), tem vindo a ser possível a modelação geométrica de vasos sanguíneos e do coração. Contudo, esta modelação ainda implica a utilização de vários procedimentos manuais de forma a obter-se modelos de elevada qualidade.*

*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 processadas. No que concerne 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. Neste trabalho, várias técnicas de segmentação de imagem são introduzidas e aplicadas em 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 [2]. 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 [1], [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 informações [4, 5]. A aplicação mais visível desta técnica em imagens médicas é a localização anatómica de órgãos, ou em termos genéricos, a região de delimitação de interesse, cujo principal objectivo é delinear as estruturas anatómicas e as regiões (patológicas) de interesse [6]. Existem diversas aplicações de técnicas de segmentação de imagem na ciência médica, como na localização de tumores e de microcalcificações, delimitação 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 [1, 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, tais como a intensidade ou magnitude do gradiente da

imagem. O processo de segmentação baseia-se na busca de pixels cujos valores estão dentro dos intervalos definidos pelos limiares (*thresholds*). O método mais comum é a média de *thresholds* devido à sua simplicidade de implementação e propriedades intuitivas. Nesta técnica, um valor predefinido (*threshold*) é seleccionado manual ou automaticamente, e uma imagem é dividida em grupos de pixels com valores iguais ou superiores ao limiar e grupos de pixels com valores inferiores a esse limiar [1, 3, 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 pixels, é chamado de *dinâmico* ou *adaptativo* [7, 9].

### 2.1.1 Thresholding Global

Quando apenas um único limite é seleccionado para uma determinada imagem, o *threshold* é global para toda a imagem. Este tipo de *threshold* é baseado no pressuposto de que a imagem tem um histograma bimodal e, portanto, o objecto pode ser extraído do fundo por uma operação simples, que compara os valores da imagem com um valor de *threshold*  $T$  [1]. Suponha-se na imagem  $f(x, y)$  com o histograma da Figura 1. Os pixels 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  $T$  (retirado de [1]).


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 pixels acima da qual os pixels serão seleccionados, então os pixels com valor dado por  $\rho$  dado por:

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

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* usando o histograma da imagem (Figura 2b).



**Figura 2** (a) Imagem de uma bifurcação da carótida obtida por Doppler; (b) Resultado da aplicação do método de Otsu à imagem da Figura 2a.

### 2.1.2 *Thresholding* Local e Adaptativo

Quando o fundo da imagem a segmentar não é constante, o contraste dos objectos varia ao longo do mesmo e o *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 do algoritmo de *thresholding adaptativo*. Este tipo de *threshold* pode ser determinado da seguinte forma:

- 1) Dividir a imagem original em sub-imagens e os determinar os limiares para cada sub-imagem ou
- 2) Examinar as intensidades da imagem original na vizinhança de cada pixel. No primeiro método, a imagem é dividida em sub-imagens rectangulares sobrepostas e os histogramas são calculados para cada um deles. As sub-imagens utilizadas devem ser 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 do histograma. Se o histograma é unimodal, em seguida, o limite deve ser 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 *thresholdings* local e adaptativo são computacionalmente mais exigentes do que o *thresholding* global. No entanto, são úteis para segmentar objectos em imagens com fundos não constantes, e para a extracção de regiões que pequenas e esparsas [1].

## 2.2 Baseados em bordas

Na detecção de bordas (ou contornos), analisa-se as discontinuidades 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 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 na direcção  $x$  e  $y$ , respectivamente.

Existem várias técnicas de segmentação baseadas em bordas. As mais simples são aquelas em que as bordas são detectadas pelos operadores de gradiente, como o operador de Sobel (Figura 3b), de Canny [12] (Figura 3c) e Laplaciano [13] (Figura 3d).

A segmentação baseada em contornos é computacionalmente rápida e não exige informações prévias sobre o conteúdo da imagem. 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 ligação ou agrupamento de arestas que correspondem a um limite único [1]. Em geral, a ligação por bordas é computacionalmente exigente e não muito confiável. Para solucionar este problema, é útil fazer-se a ligação por bordas semi-automaticamente, permitindo que o utilizador defina ou rectifique a borda quando o rastreamento automático não é totalmente correcto [1, 9].



**Figura 3** (a) Imagem de uma bifurcação da carótida obtida por Doppler; Operadores de Sobel, Canny e Laplaciano aplicados imagem da Figura 3a), b), c) e d), respectivamente.

### 2.3 Baseados em regiões

As abordagens de segmentação baseadas em regiões fazem a análise de pixéis de uma imagem e formam regiões disjuntas agrupando pixéis vizinhos com propriedades de homogeneidade baseadas em critérios de similaridade pré-definidos [4].

A técnica mais simples de segmentação baseada em regiões é chamada *region growing* (crescimento por regiões), e faz o agrupamento em segmentos, de pixéis que possuem propriedades similares. Esta técnica começa com um pixel ou grupo de pixéis, 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 pixéis semelhantes são adicionados à região da *semente* original, e assim, a região vai crescendo. O processo continua até que mais nenhum pixel possa ser acrescentado. É possível que alguns pixéis possam permanecer sem rótulo, isto é, estarem isolados, quando pára o processo de crescimento [1, 14].

Os resultados do *region growing* dependem fortemente da escolha do critério de homogeneidade. Se não for escolhido correctamente, as regiões escapam-se para áreas adjacentes e fundem-se 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 esta 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 encontram, a imagem (ou sub-imagem) é dividida em duas ou mais sub-imagens. Este processo termina quando todas as sub-imagens satisfazem os critérios de homogeneidade.

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



**Figura 4** Resultado da aplicação de um algoritmo de *region growing* à imagem da Figura 3a.

### 2.3.1 Watershed Algorithm

A segmentação por *watershed* (Método do Divisor de Águas) é uma ferramenta interessante de segmentação de imagem. É uma técnica baseada em regiões que utiliza a morfologia da imagem [1]. 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 ideia básica do *watershed* é dada pela imagem da tradução em português do nome: um divisor de águas é uma cadeia de montanhas, que divide a água da chuva em regiões para onde ela escorre. O *watershed* utiliza os módulos dos gradientes, as variações locais de intensidade na imagem, como uma “topografia” montanhosa que separa regiões. Funde-se regiões aumentando a altura da água que “chove” na imagem. A grande vantagem deste método é a sua rapidez de processamento, permitindo que seja utilizado em aplicações interactivas, mesmo quando as imagens a processar são grandes e complexas [3].

### 2.4 Classificação por pixéis

Recorde-se que o passo fundamental das técnicas de *threshold* descritas anteriormente é a escolha dos limiares que é determinada 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 *thresholds* para classificar uma imagem podem ser considerados como uma generalização das técnicas de *thresholding*. São particularmente úteis quando os pixéis 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.

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 ao osso e tecidos moles, ou a um tumor e tecido são. Se tivermos várias imagens de exemplo em que um perito tenha estabelecido marcadores de classe, conhecidos como *training set* (conjunto treino), pode-se deduzir características da imagem que vão permitir a distinção entre pixéis de diferentes classes. Estas características podem ser intensidade de pixéis, média de intensidade da vizinhança, etc. 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 [1, 3].

### 2.4.1 Técnicas de Agrupamento (*Clustering*)

A técnica de *Clustering* tem vindo a ser amplamente aplicada em antropologia, arqueologia, psiquiatria, e zoologia, etc.. Esta técnica é a mais popular 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 no 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* [1].

Há várias técnicas de agrupamento propostas na literatura [1, 3, 5, 16]. A seguir é apresentada a divisão deste tipo de algoritmos 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] and *active appearance models* (AAM) [19]. Por seu lado, as não supervisionadas são *CM algorithms fuzzy C-means* (FCM) [20], *algorithms iterative self-organising data analysis technique algorithms* (ISODATA) [20] e *unsupervised neural networks* [1, 4].

Na aprendizagem supervisionada, fornece-se ao algoritmo uma resposta correcta (saída) para cada padrão de entrada. Os parâmetros do algoritmo são então ajustados 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 dados e organizados os mesmos em categorias a partir destas correlações [4].

### 2.4.2 Modelos Deformáveis

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

Grande parte dos métodos usados pelos 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). 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: Contornos Activos ou *Snakes* [22] e Modelos Geométricos ou *Level Set*.

## A- Contornos Activos ou *Snakes*

Na visão computacional e imagem/processamento de vídeo, o modelo de contornos activos, também conhecido por *Snake*, tem sido utilizado como uma abordagem eficaz para implementar o contorno de segmentação e uma forma de acompanhamento na extracção de características do objecto de interesse. Sendo considerado um sucesso em aplicações de análise de imagens médicas [1].

De forma simplificada, um modelo de *Snake* pode ser considerada como uma curva com uma função de energia. Para acompanhar o contorno de um objecto desejado na imagem, alguns pontos ou curvas devem ser inicialmente especificados perto da fronteira do objecto. Quando o algoritmo é aplicado, a *Snake* vai "mover-se" gradualmente em direcção às posições nas quais se localiza o contorno do objecto a segmentar sob determinadas restrições. 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 *Snake* é que este pode ficar preso num local de soluções mínimas provocadas 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.

Estas duas parcelas de energia são formuladas por uma expressão da energia que é minimizada deformando o contorno num processo de optimização. As definições são dadas como:

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

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

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  $\alpha_i$  é uma constante que impõe a restrição de tensão entre dois pontos adjacentes da *Snake*. Quanto maior o  $\alpha_i$  é, menor será o contorno do objecto. O parâmetro  $\beta_i$  é uma restrição de ajuste à curvatura entre todos os três pontos consecutivos da *Snake*. De um modo geral, quanto maior valor de  $\beta_i$  mais suave será o contorno. Em diversas aplicações onde o tamanho do objecto desejado e as curvaturas podem variar, os valores de  $\alpha_i$  e  $\beta_i$  têm necessidade de ser ajustados [1].

### **B – Modelos Geométricos ou *Level Set***

Os modelos geométricos ou *level set* constituem uma alternativa aos modelos baseados na optimização de uma função objectivo; 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 têm as suas raízes em [24] e têm sido aplicados a imagem médica por vários autores. Este método fornece 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] [24]. Uma propriedade útil desta abordagem é o facto da função *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 [25]. 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 [26], usando uma formulação de minimização de energia, demonstraram, primeiro para 2D [27] e depois para 3D [26], 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 [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.

### **3. CONCLUSÃO**

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

A maioria dos algoritmos necessitam de combinar múltiplas técnicas de segmentação para melhorar os resultados do processamento da imagem. Por esta razão, não existe uma classificação definida 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.

#### 4. AGRADECIMENTOS

Este trabalho foi parcialmente desenvolvido no âmbito dos projectos “Simulação computacional do sistema cardiovascular tendo em vista aplicação hospitalar” 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 e PTDC/EEA-CRO/103320/2008, respectivamente, financiados pela Fundação para a Ciência e a Tecnologia (FCT).

#### Referências:

- [1] I.N. Bankman, *Handbook of Medical Imaging*. Vol. II. 2000, San Diego/ London: Academic Press.
- [2] A. Quarteroni and M. Veneziani, *Computational Vascular Fluid dynamics: problems, models and methods*. Computer and Visualization in Science, 2000.
- [3] K.-P. Wong, *Handbook of Biomedical Image Analysis*, ed. E. Micheli-Tzanakou. Vol. II - Segmentation Models. 2005, New Jersey: Kluwer Academic / Plenum Publishers.
- [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, 2010. **13**(2): p. 235-246.
- [5] D.J. Withey and Z.J. Koles, *Medical Image Segmentation: Methods and Software*. International Conference on Functional Biomedical Imaging, 2007: p. 140-143.
- [6] D.N. Ghista, *Applied Biomedical Engineering Mechanics*. 2008, New York: CRC Press. 592.
- [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, 1979. **9**(1): p. 62-66.

- [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, 1986. **8**(6): p. 679-698.
- [13] L.S. Davis, *A survey of edge detection techniques*. Computer Graphics and Image Processing, 1975. **4**(3): p. 248-270.
- [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, 2002. **21**.
- [16] T. McInerney and D. Terzopoulos, *Deformable Models in Medical Image Analysis: A Survey*. Medical Image Analysis, 1996. **1**: p. 91-108.
- [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, 2005. **52**(6): p. 947-960.
- [19] M. James, *Classification algorithms*. 1985, NY: Wiley-Interscience.
- [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, 2000. **11**(4): p. 425-437.
- [21] J.S. Silva, B.S. Santos, A. Silva and J. Madeira, *Modelos Deformáveis na Segmentação de Imagens Médicas: uma introdução*. Revista do DETUA, 2004. **4**.
- [22] M. Kass, A. Witkin and D. Terzopoulos, *Snakes: active contour models*. Int J Comp Vis, 1987. **1**(4): p. 321-331.
- [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] S. Osher and J.A. Sethian, *Fronts Propagation with Curvature Dependent Speed: Algorithms Based on Hamilton- Jacobi Formulations*. Journal of Computational Physics, 1988. **79**: p. 12-49.
- [25] J.A. Sethian, *Level Set methods: An Act of Violence*. American Scientist, 1997. **85**.
- [26] V. Caselles, R. Kimmel, G. Sapiro and C. Sbert, *Minimal Surfaces Based Object Segmentation*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997. **19**: p. 394-398.
- [27] V.C.R.K.G. Sapiro, Geodesic Active Contours, in *International Journal of Computer Vision*. 1997. p. 61-79.