# Capítulo 8

# Inicialização de Modelos Deformáveis

Um ponto crucial para a reconstrução de geometrias em imagens 2D ou 3D via modelos deformáveis, é a inicialização do modelo.

Como já ressaltado para o caso particular das snakes (Kass *et al.* , 1988), a energia do modelo é em geral não-convexa (Davatzikos & Prince, 1999; Giraldi & Oliveira, 1999) e portanto a solução final é muito dependente da posição inicial. Assim, um procedimento para obter uma primeira aproximação da borda pode melhorar a performance e a precisão do resultado final.

Em (Giraldi *et al.* , 2000e; Giraldi *et al.* , 2000a) nós apresentamos um novo método para inicializar modelos deformáveis baseado em propriedades da topologia e da escala espacial dos objetos de interesse. O método proposto adota uma metodologia de multiresolução tendo como base teórica os mesmos elementos das T-Snakes (*Triangulação, Função Característica e Snakes Discretas*), o que o torna ideal para inicializar o Dual-T-Snakes.

O enfoque dos trabalhos apresentados em (Giraldi *et al.* , 2000e; Giraldi *et al.* , 2000a) é na inicialização de snakes 2D, mas o mesmo procedimento pode ser estendido para 3D, como discutido abaixo.

## 8.1 Trabalhos Relacionados

Nossa metodologia de inicialização adota a filosofia básica de alguns métodos não-paramétricos multi-resolução para segmentação de imagens baseados em modelos de Pirâmides e Quadtree (Burt *et al.* , 1981; Bamford & Lovell, n.d.; Jolion & Montanvert, 1992). Estes métodos fazem uso de estruturas de dados apropriadas para representar uma imagem em diferentes níveis de resolução.

A idéia básica nestes casos, é que à medida que a resolução vai decrescendo pequenos artefatos no background tornam-se menos significativos em relação aos objetos de interesse. Assim, pode ser mais simples *detectar* os objetos no nível mais baixo para então fazer o tracking dos mesmos nos diferentes níveis da estrutura de dados.

Desta forma, é possível *delinear* as bordas em uma resolução mais baixa e re-estimá-las quando aumentamos a resolução (Jolion & Montanvert, 1992; Bamford & Lovell, n.d.).

No trabalho descrito nesta seção, a resolução mais baixa da imagem é definida atravéz de um conhecimento a priori da escala dos objetos, sendo adaptativo no sentido que a resolução é melhorada somente nas regiões onde for considerado necessário.

Para aumentar a resolução, nós simplesmente refinamos a malha e amostramos a imagem sobre os nós correspondentes à nova malha. Assim, a estrutura de refinamento é localmente uniforme e adaptativa (*local uniform nested refinement*) (Berger & Oliger, 1984), sendo representada na Figura 8.1. Estes métodos são bem conhecidos para solução numérica de equaçoes diferenciais parciais, tais como aquelas do método de conjuntos de níveis da seção 5.3.1 (Sethian, 1996). Contudo, não conhecemos referência anterior sobre aplicações destes esquemas para segmentação.

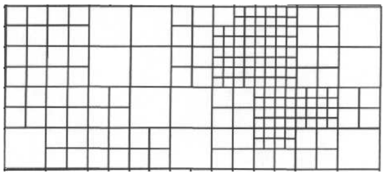

Figura 8.1: Representação do esquema de multi-resolução usado.

Métodos de multi-resolução podem ser particularmente úteis para problemas em análise de imagens e visão computacional que possam ser expressos como problemas de minimização de funções de energia. Em (Heitz *et al.* , 1994) nós encontramos um método deste tipo, chamado Relaxação Multi-escala (*Multiscale Relaxation)* o qual tem sido usado no contexto de snakes (Mignotte & Meunier, February, 2000). Neste método, o problema de otimização global é resolvido dentro de uma seqüência de subespaços do espaço original de configurações. Cada subespaço define uma função de energia (*coarse energy function*) cujos parâmetros são derivados da função objetivo original definida na resolução máxima. O problema de otimização vinculado (*constrained optimization*) é implementado em (Heitz *et al.* , 1994) usando-se uma estrutura de pirâmide.

Por outro lado, existem métodos de relaxação em malhas , tais como aquele apresentado em (Terzopoulos, 1986a). Neste caso, a resolução da imagem não é reduzida (é sempre a resolução máxima). Contudo, a resolução da malha usada para discretizar o problema de otimização vai sendo melhorada durante a execução do algoritmo.

O método descrito abaixo é multigride/multiresolução quando segmentamos a imagem mas não quando aplicamos o modelo deformável para extrair as bordas. Este modelo (T-Snakes, seção 5.3.2) é usado no final do processo apenas. Nós não necessitamos usar métodos de relaxacão multi-escala neste passo final uma vez que tomamos sempre a resolução máxima da imagem para evoluir as T-Snakes. Além disto, ao aplicarmos T-Snakes estamos supondo que a resolução da malha é suficiente para fornecermos uma aproximação inicial das bordas. Assim, nós não necessitamos usar métodos de relaxação multigrid durante a evolução das T-Snakes.

## 8.2 Método Multi-resolução

Nesta seção, nós estaremos interessados em aplicações onde os padrões de intensidade de um objeto $O$ (ou do background) possam ser caracterizadas por um limiar $T$ ou uma estatística (média $\mu$ e variância $\sigma$) da intensidade de imagem $I$ (McInerney & Terzopoulos, 1999). Isto é:

$$p \in O \Longrightarrow I(p) > T \ or \ \ |I(p) - \mu| \leq k\sigma \tag{8.1}$$

onde $k$ é uma constante definida a priori.

Se a intensidade de imagem não for apropriada ou tivemos uma imagem multivariada (imagem colorida, com texturas, etc), qualquer outro campo escalar derivado da imagem pode ser usado (Jones & Metaxas, June, 1998; Giraldi *et al.* , 2000e).

Primeiramente, nós assumimos uma *Propriedade de Escala Local*: dado um ponto $p \in O$, existe uma bola $B_p$ com raio $r_p > 1$, a qual contem $p$ e pertence inteiramente ao objeto ($p$ não é necessariamente o centro da bola). Assim, uma vez que o conjunto de pontos (pixels) em uma imagem digital é finito, existe um raio $r_l$ tal que $r_p \leq r_l$, para todo $p \in O$.

$$r_l \geq r_p, \text{ para todo } p \in O. \tag{8.2}$$

Esta propriedade de escala local implica que nós podemos reduzir a resolução da imagem para $r_l \times r_l$ sem alterar a topologia dos objetos de interesse. Esta é a idéia básica do método, representada na Figura 8.2.

Nesta figura, nós usamos um limiar para a intensidade de imagem o qual identifica o objeto ($T < 150$). Na Figura 8.2.b nós temos uma triangulação CF com resolução $10 \times 10$, e a imagem binária correspondente.

Agora, nós podemos definir uma função simples, a qual chamaremos *Função Característica do Objeto*, como segue:

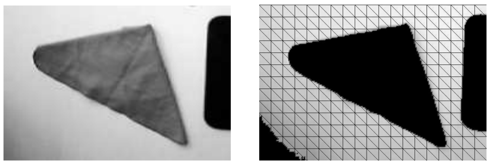

(a) (b)

Figura 8.2: (a)Imagem original. (b)Malha e imagem truncada pelo limiar.

$$\chi : D \subset \Re^2 \to \{0,1\} \tag{8.3}$$

onde $\chi(p) = 1$ se $p$ satisfaz (8.1) e $\chi(p) = 0$ caso contrário, sendo $p$ um nó da triangulação. Para o caso 3D a definição é análoga.

Podemos ir um passo além, como mostra a Figura 8.3.b, onde temos a curva gerada pela aplicação do algoritmo *Door-In-Door-Out* da seção 4.3.2. Observe que esta curva é uma aproximação (grosseira) da borda procurada.

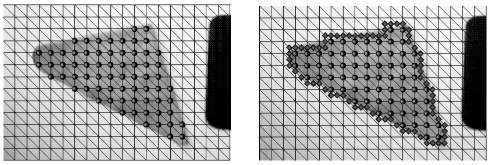

(a) (b)

Figura 8.3: (a)Função Característica. (b)Aproximação obtida.

A idéia agora, é usar um método que possa melhorar esta aproximação bem como a sua suavidade. O método das T-Snakes é o mais indicado, como veremos a seguir.

## 8.3 Método para Inicialização de Snakes

A seção anterior propriamente exemplifica os passos básicos do método de inicialização para snakes 2D proposto em (Giraldi *et al.* , 2000e; Giraldi *et al.* , 2000a):

1)Extração de estatísticas dos objetos ou do background;

2)Triangulação do domínio;

3)Definição das Funções Características dos Objetos;

4) Aplicação do algoritmo *Door-In-Door-Out*;

5)Aplicação de T-Snakes para suavizar as aproximações obtidas.

As estatísticas (ou limiares) podem ser obtidos pelos procedimentos usuais de análise de histograma ou técnicas de reconhecimento de padrões (em (Jain *et al.* , 2000) encontramos uma revisão recente do assunto).

A aplicação eficiente do *Door-In-Door-Out* pressupõe certas restrições para a topologia das bordas dos objetos de interesse. Especificamente, supomos que estas podem ser representadas por curvas (superfícies) com as seguintes propriedades: (a) Fechadas, (b)Orientadas, (c) Conexas.

Com estas propriedades assumidas, nós não necessitamos nos preocupar com o interior das curvas fechadas assim geradas pelo passo (4). A Figure 8.4.b, a qual é o resultado obtido pela aplicação dos passos (1)-(4) à imagem mostrada na Figura 8.4.a, esclarece este fato.

Uma vez que nós não temos splits de objetos devido a propriedade local de escala, não precisamos efetuar merge de regiões. Assim, podemos usar as curvas fechadas geradas para obter uma aproximação grosseira das bordas procuradas. Este é o ponto principal deste trabalho.

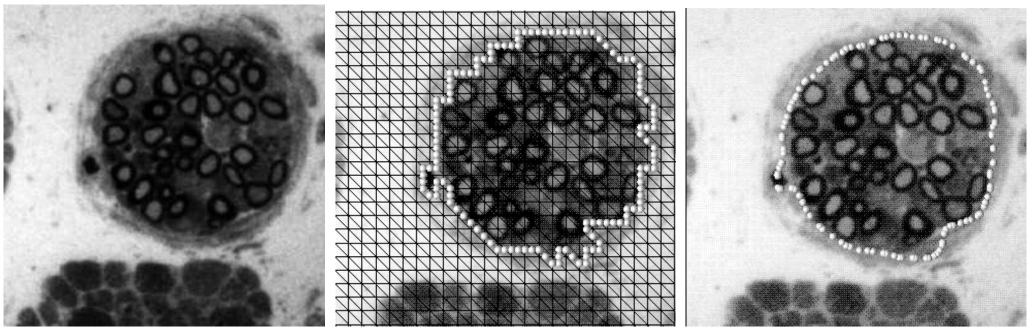

(a) (b) (c)

Figura 8.4: (a) Célula de mielina. (b)Variedade Linear gerada. (c)Resultado final do método.

Observe que, de acordo com a propriedade Cíclica da seção 4.3.2, o algoritmo *door-in-door-out* gera curvas fechadas ou curvas que iniciam e terminam nas fronteiras da imagem (Allgower & Georg, 1990). Assim, uma inspeção simples descarta curvas abertas. Além disto, ambas as propriedades (a) e (b) da seção 4.3.2 garantem que as curvas poligonais geradas são simples (Allgower & Georg, 1990). Logo, a propriedade (b) acima é sempre satisfeita.

As curvas restantes satisfazem (a)-(c) acima, como podemos observar na Figura 8.4.b.

Contudo, algumas destas curvas podem limitar uma região de área muito pequena devido a artefatos ou ruídos no background. Logo, elas deverão ser descartadas. A Figura 8.5 mostra um exemplo deste comportamento.

Além disto, algumas curvas podem conter mais de um objeto de interesse, como é o caso mostrado na Figura 8.6.b.

Agora, nós podemos usar um conjunto de características pré-definidas tais como área e perímetro (Samtaney *et al.* , 1994). Para cada uma destas características,

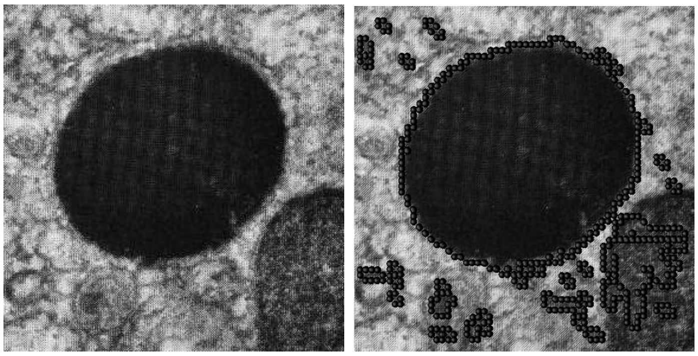

(a) (b)

Figura 8.5: (a) Células de lisossomos. (b)Aproximações lineares por partes obtidas para resolução $5 \times 5$.

a idéia é encontrar limites superior e inferior baseados em conhecimento a priori dos objetos de interesse. Neste trabalho nós usamos apenas área da região interior às curvas. Pela propriedade de escala local e a triangulação usada nós podemos estabelecer como limite inferior para a área o valor $4\,(r_l)^2$, onde $r_l$ está definido na expressão 8.2.

A definição para o limite superior é muito dependente da aplicação. Por exemplo, para imagens médicas poderíamos usar dados anatômicos sobre as estruturas de interesse.

É importante ressaltar que o limite superior não é um ponto essencial para o método. O papel deste parâmetro é somente evitar esforço computacional para processar regiões onde as poligonais envolvem um único objeto.

Dentre as curvas resultantes, uma simples inspeção descarta aquelas que envolvem regiões cujas áreas estão abaixo do limite inferior. Quanto àquelas cujas áreas correspondentes ultrapassam o limite superior, estas devem ser processadas em uma resolução mais fina.

De fato, em imagens como a da Figura 8.6.a, a escala *exterior* correspondente à separação entre os objetos pode ser mais fina que aquela definida pela propriedade de escala local dos mesmos. O problema correspondente se enquadra na categoria conhecida como *Problemas de Duas-Escalas.*

Uma característica comum destes problemas é que as escalas espaciais podem variar dramaticamente de uma região para outra da imagem. Isto acontece nas regiões da Figura 8.6.b onde a segmentação ainda não está completa. Nestas regiões, a escala exterior pode ser mais fina que a escala local dos objetos. Assim, na resolução mais grossa $(5 \times 5)$ não conseguimos *separar* os objetos. Para corrigir este resultado, nós aumentamos a resolução (apenas) nestas regiões para melhorar o nível de detalhe.

Para malhas uniformes do tipo daquela da Figura 8.1 isto pode ser implementado

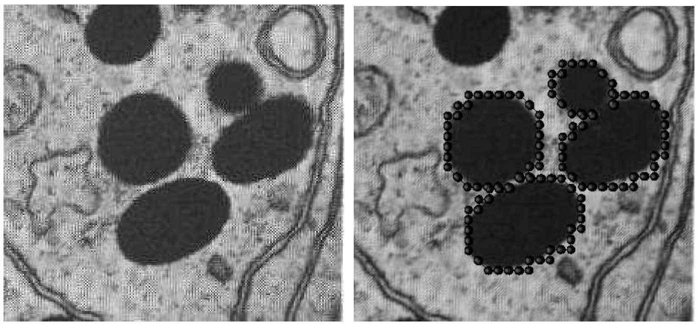

(a) (b)

Figura 8.6: (a) Escala de separação entre objetos mais fina que a escala interna. (b) Aproximações lineares por partes obtidas com resolução $5 \times 5$.

por um esquema de multi-resolução cuja estrutura de dados subjacente é aquela de um *Refinamento Adaptativo de Malhas* (Berger & Oliger, 1984).

Nestas estruturas cada nó no nível de refinamento $l$ sofre split em $\eta^n$ nós no nível $l+1$, onde $\eta$ é o *fator de refinamento* e $n$ é a dimensão do espaço ($\eta = 2$ e $n = 2$, no presente caso). Assim, em 2D, a estrutura de nós possui $\eta^2$ ponteiros para os filhos, $\eta^2$ ponteiros para os nós vizinhos e um ponteiro para o pai.

Com isto, podemos melhorar o resultado apresentado na Figura 8.6.b. Usando agora uma resolução $3 \times 3$ obtém-se o resultado mostrado na Figura 8.7

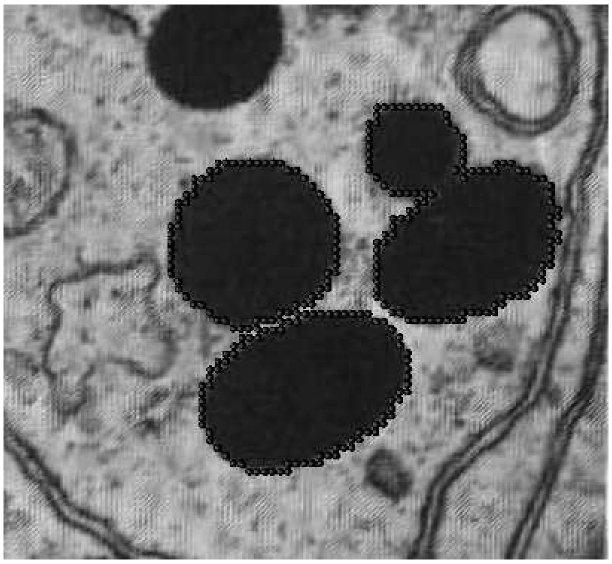

Figura 8.7: Resultado obtido com resolução $3 \times 3$, a partir da imagem 8.6.b

Em alguns casos, apesar de usarmos a resolução da própria imagem, algumas curvas ainda podem limitar regiões com área maior que o limite superior, como é o caso da curva limitando as duas células do canto direito superior da Figura 8.7.

Se nós temos uma estatística como na expressão (8.1), então podemos relaxar o limiar ($T \to T \pm \Delta T$) e aplicar os passos (2)-(5) novamente, mas somente nas regiões onde for identificada tal necessidade. Contudo, no caso da Figura 8.7 este procedimento não seria eficiente pois comprometeria o resultado obtido nas regiões onde a aproximação está satisfatória.

Nestes casos, nos parece mais eficiente uma metodologia semi-automática com ferramentas interativas para corrigir o defeito observado. Nos Capítulos 9 e 10 voltaremos a esta questão.

Dentre as curvas resultantes, pode ocorrer que algumas delas ainda correspondam a pequenos artefatos, muito próximos no background. Em geral, estas curvas somente podem ser descartadas aumentando a resolução.

Após aplicar os passos (1)-(4) nós temos como resultado uma aproximação grosseira das bordas procuradas. A idéia é usar agora um modelo de snake para obter a aproximação final. O modelo das T-Snakes foi escolhido, primeiramente, porque ele pode lidar naturalmente com as auto-intersecções que podem ocorrer durante a evolução das curvas obtidas as quais podem apresentar regiões irregulares e com curvatura muito elevada (Figura 6.5).

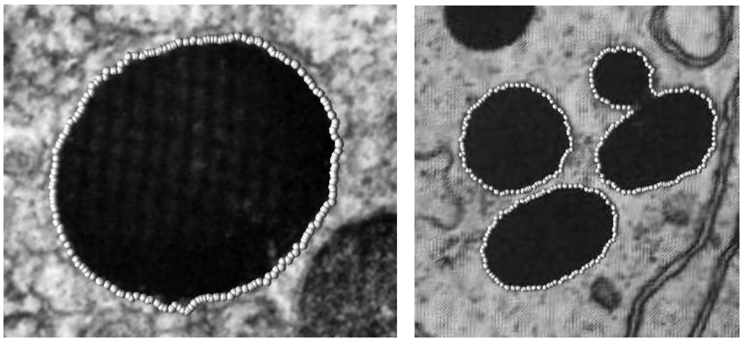

(a) (b)

Figura 8.8: Resultado final dos passos (1)-(5) para as imagens das Figuras 8.5.a e 8.7. As resoluções usadas são $5 \times 5$ para o resultado (a) e $3 \times 3$ para (b).

Segundo, porque escolhendo T-Snakes, os passos (1)-(5) compõem uma metodologia unificada, baseada em Triangulação, Limiares e Funções Características, para inicialização de modelos deformáveis.

O algoritmo de continuação *door-in-door-out* usado tem muito em comum com métodos usados para geração de iso-superfícies em malhas hierárquicas. Contudo, estes métodos não usam as restrições de escala e topologia acima, as quais formalizam nosso *conhecimento a priori* das estruturas de interesse.

A extenção do método desta seção para 3D é direta. Para isto, basta usar as T-Superfícies (seção C.3) no passo (5) e uma extenção para 3D do algoritmo *Door-In-Door-Out* para gerar as superfícies procuradas (Variedades Lineares por Partes bidimensionais). Procedendo desta forma, as restrições topológicas (a)-(c) da seção anterior serão automaticamente respeitadas, o que pode ser demonstrado pela teoria subjacente descrita no Apêndice C.