

## Localização de Células em Imagens Histológicas usando Modelos baseados em Formas Activas

Luís Coelho\*, Augusto Silva

**Resumo** - A análise digital de imagem tem vindo a assumir um papel importante no desenvolvimento de diversas áreas. O presente artigo apresenta um estudo das técnicas de análise digital de imagens baseadas nos conceitos de forma activa e respectiva aplicação na localização de células em imagens histológicas.

O artigo começa por estabelecer qual o classe de objectos a modelar e quais as variações que estes pode ter. Segue-se a descrição da técnica de modelação estatística e do algoritmo de actualização usado para localizar os objectos em imagens alvo. Para finalizar são expostos os resultados obtidos, com a aplicação dos modelos construídos na segmentação de núcleo e citoplasma em várias imagens alvo.

**Abstract** - Digital image analysis is being increasingly used in many application areas. This paper presents a study of the Active Shape Models and their application for locating cells in histological images.

The paper begins with the choice of the class of objects to be modelled including their variations. It follows with the description of the statistical modelling technique and the iterative updating algorithm used to locate corresponding objects within the target image. The paper concludes with a results section where segmented nuclei and cytoplasm are presented within a set of different target images.

### I. INTRODUÇÃO

As ferramentas computacionais constituem uma ajuda importante na análise digital de imagem, sendo muitas as áreas que beneficiam destes métodos de análise. A investigação em Biologia é uma das áreas que mais recorre aos meios de imagem constituindo um desafio importante aos métodos de processamento digital.

A determinação de parâmetros e a identificação de estruturas que permitam caracterizar as imagens histológicas que se obtêm por microscopia, são exemplos de aplicação da análise digital de imagem. A caracterização rigorosa de populações de microorganismos é outro caso onde a aplicação das técnicas de análise digital, em conjugação com métodos de reconhecimento de padrões, também tem um contributo importante.

Na verdade, o processamento digital de imagens tem vindo a resolver uma quantidade cada vez maior de problemas, aumentando a precisão na detecção de estruturas de interesse em imagens cito e histológicas. Também as principais áreas da pesquisa em Medicina, tais como a pesquisa de tumores, são fortemente dependentes do desenvolvimento das técnicas de processamento de imagem, uma vez que necessitam de rapidez, rigor e objectividade nos seus diagnósticos [1].

Os modelos baseados em superfícies deformáveis permitem descrever uma grande variedade de superfícies lisas, tanto com contornos abertos como fechados, com um pequeno número de parâmetros e podem ser usados na detecção de objectos 3-D nas imagens médicas, tais como o cérebro e o coração, entre outros órgãos de interesse [2,3]. Os modelos activos de contorno (ACM), que são conhecidos por “Snakes” porque são atraídos às características da imagem, também têm aplicações nessa área [4].

Interessa para este artigo estudar os modelos baseados nos conceitos de forma activa (*Active Shape Models – ASM*), também pertencentes à “classe” dos Modelos Deformáveis. Estes modelos têm aplicações conhecidas na análise de imagens médicas e de outras estruturas biológicas e também na análise e reconstrução facial, [5,6,7,8]. Será feita a avaliação às potencialidades destes métodos quando usados na identificação de estruturas histológicas, nomeadamente na localização de células em imagens histológicas.

Estes modelos têm a característica de serem bastante versáteis e usarem como base o modelo de distribuição de pontos (PDM). A sua implementação passa por várias fases de execução: construção de um conjunto de treino; alinhamento do conjunto de treino; tratamento estatístico das nuvens de pontos encontradas; e aplicação do modelo construído na identificação de um objecto numa dada imagem.

Este artigo começa por estabelecer qual o objecto a modelar e quais as variações que este pode ter. Segue-se a descrição da modelação do objecto; o uso desta modelação para localizar o objecto numa imagem, assim como a apresentação dos resultados da aplicação dos modelos construídos. Finalmente, são apresentadas algumas conclusões e propostas para trabalhos futuros.

\* Financiado pela Unidade de Investigação 127/94 IEETA da Universidade de Aveiro.

## II. VARIAÇÕES NA FORMA DOS OBJECTOS

O algoritmo *Active Shape Models* (ASM) tem algumas aplicações a nível da detecção de estruturas de interesse em imagens médicas, no reconhecimento facial, entre outras de menor relevância.

Pela variedade das aplicações pode-se constatar que estes modelos possuem um elevado grau de adaptação às várias formas que cada objecto pode tomar. Veja-se: O coração humano não tem exactamente a mesma forma em todas as imagens. A sua forma varia durante o batimento cardíaco e com a idade, para além de outras variações possíveis. Também a forma facial é alvo de muitas variações. Varia de pessoa para pessoa, e num mesmo indivíduo varia conforme a sua expressão facial e idade.

Apesar das variações descritas, a forma dos objectos de cada caso obedece a um certo padrão que se mantém em todas as imagens, de outra forma não seria possível usar, com sucesso, o algoritmo ASM para localizar estes objectos.

Também no caso das células pode encontrar-se um padrão, apesar da variação da sua forma ser muito superior à dos objectos apresentados anteriormente. Contudo, todas têm núcleo e citoplasma, sendo que o núcleo apresenta uma forma relativamente circular. Assim, pode-se usar algoritmo ASM para modelar um determinado tipo de células, de modo a localizar células desse tipo em diversas imagens histológicas.

Para se conseguir modelar as variações da forma de um determinado objecto é necessário possuir uma série de imagens, onde o objecto possua ligeiras variações na sua forma. A este conjunto de imagens dá-se o nome de conjunto de treino ("*Training Set*"). É necessário fazer uma escolha cuidadosa do conjunto de treino para construir um bom modelo do objecto.

A forma de cada objecto do conjunto de treino é representada por um conjunto de pontos do seu contorno, designados por *landmarks*. O número de *landmarks* tem de ser escolhido de forma a representar, não só a variação geral da forma do objecto, mas também alguns detalhes que se revelem necessários. Cada objecto terá de ser representado por um número predefinido de pontos, tendo em conta a sua complexidade e o grau de pormenor com que se pretende representar.

Como os objectos são representados por pontos, a modelação da forma dos objectos é feita de segundo o Modelo de Distribuição de Pontos (PDM). No entanto, não basta só fazer a modelação da forma dos objectos, é igualmente importante fazer a modelação da variação dos níveis de cinzento em torno de cada ponto do objecto [8,9]. Esta modelação contribui para a criação de um sistema robusto de localização dos objectos numa imagem.

Descrevem-se, de seguida, as modelações feitas aos objectos: a modelação da forma e a modelação dos níveis de cinzento.

## III. MODELAÇÃO DA VARIAÇÃO DA FORMA DOS OBJECTOS

A obtenção do PDM para um objecto obedece a três etapas de execução: a etiquetagem, o alinhamento e a captura das estatísticas do conjunto de treino. Segue-se a descrição detalhada de cada etapa.

### *Etiquetagem do Conjunto de Treino*

A marcação dos pontos representativos de cada objecto obedece a determinadas regras. Uma das mais importantes tem a ver com o número de pontos que define cada objecto do conjunto de treino, que tem de ser o mesmo para todos os objectos. O número de pontos é escolhido tendo em conta a precisão com que se pretende representar o objecto.

Na marcação dos pontos é necessário estabelecer critérios de modo a que cada ponto marque características semelhantes em todos os objectos. Existem três tipos de *landmarks* que podem ser usados [5,6]:

- *Application-dependent landmarks*;
- *Application-independent landmark*;
- *Landmarks* interpolados a partir dos anteriores.

Os *landmarks* do primeiro tipo são usados para marcar aspectos que dependem de outros, por exemplo, o centro do olho num modelo da face ou um vértice de um objecto de cantos afiados. Os do segundo tipo são usados para marcar aspectos que não dependem de outros, por exemplo, o ponto mais elevado de um determinado objecto. E os pontos do terceiro tipo são igualmente espaçados de uma determinada distância entre dois pontos do tipo 1 ou do tipo 2. Na maior parte dos casos são os pontos do tipo 3 os responsáveis por caracterizar a maior parte do contorno dos objectos.

Denotando-se o número de pontos de cada objecto por  $n$  e o número de imagens do conjunto de treino por  $N$ , então o  $i^{\text{ésimo}}$  objecto pode ser representado por:

$$X_i = [x_{i0}, y_{i0}, x_{i1}, y_{i1}, \dots, x_{in-1}, y_{in-1}] \text{ com } 1 \leq i \leq N \quad (1)$$

No final da marcação de todos os pontos em todos os objectos do conjunto de treino obtém-se uma matriz  $X$  de dimensões  $N \times 2n$ .

$$X = \begin{bmatrix} x_{10} & y_{10} & x_{11} & y_{11} & \dots & x_{1n-1} & y_{1n-1} \\ x_{20} & y_{20} & x_{21} & y_{21} & \dots & x_{2n-1} & y_{2n-1} \\ & & & & \dots & & \\ x_{N0} & y_{N0} & x_{N1} & y_{N1} & \dots & x_{Nn-1} & y_{Nn-1} \end{bmatrix} \quad (2)$$

### *Alinhamento do Conjunto de Treino*

Para que se estudem as variações da posição de cada *landmark*, em todos os objectos do conjunto de treino, é

necessário fazer o alinhamento de cada um dos objectos do conjunto. O alinhamento consiste em escalar, rodar e fazer a translação de cada um dos objectos, de modo a que todos os objectos fiquem numa posição semelhante, isto é, de modo a que os pontos de um objecto estejam tão próximo quanto possível dos pontos do outro objecto. O objectivo é minimizar a soma dos quadrados das distâncias entre pontos equivalentes em objectos diferentes [5].

A primeira tarefa a fazer, antes de se alinhar o conjunto, é determinar a matriz dos pesos de cada ponto, pois esta será importante para o alinhamento do conjunto. O cálculo da matriz dos pesos de cada ponto é efectuado de modo a

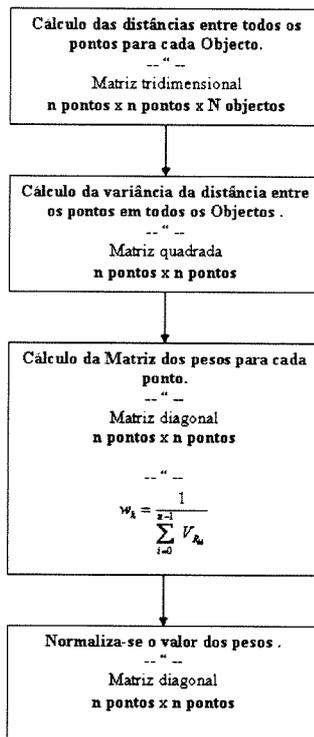


Fig. 1 - Fluxograma do algoritmo de escolha dos pesos de cada ponto.

atribuir maior peso aos pontos que tendem a ser mais estáveis, e um peso mais reduzido aos que tendem a variar dentro do conjunto [5,6]. O valor do peso de cada ponto é inversamente proporcional à variância desse ponto dentro do conjunto de treino. Na figura 1 está representado o fluxograma do algoritmo da escolha dos pesos.

O vector dos pesos pode ser determinado pela seguinte expressão:

$$W = \text{diag} (w_k) \quad (3)$$

Alinhar dois objectos,  $X_i$  e  $X_j$ , consiste em determinar o valor do factor de escala  $S$ , do ângulo de rotação  $\theta$ , e da translação em ambas as dimensões  $(t_x, t_y)$  a aplicar a  $X_j$  de modo a que este fique alinhado com  $X_i$ . A matriz dos pesos  $W$  é aplicada de forma a dar mais significado aos

pontos mais estáveis [5]. A estabilidade de um ponto é a medida da variação desse ponto em relação aos outros, de objecto para objecto.

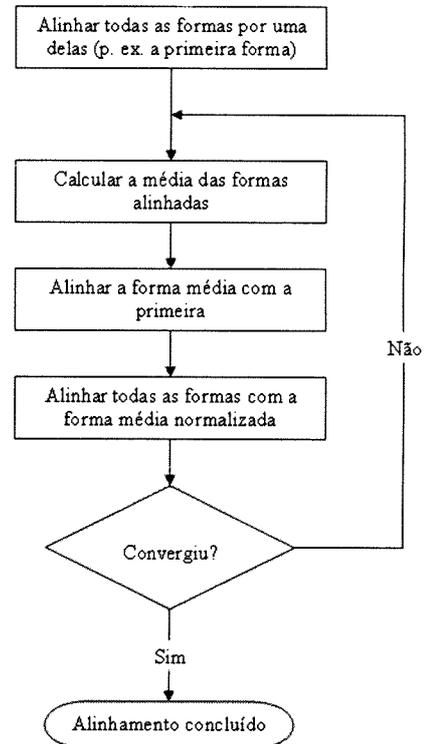


Fig. 2 - Fluxograma do algoritmo de alinhamento do conjunto de treino.

Generalizando, o alinhamento dos  $N$  objectos do conjunto de treino obedece ao seguinte algoritmo [9]:

O critério de convergência escolhido foi,  $S_{min} = 0.001$ ;  $\theta_{min} = 0.001^\circ$ ;  $t_{x\ min} = t_{y\ min} = 0.01$ , de modo a que o valor do erro

$$E = (X_i - M(S, \theta)[X_j] - t)^T W (X_i - M(S, \theta)[X_j] - t),$$

seja mínimo e em que  $M(S, \theta)$  uma matriz de transformação que depende apenas dos factores de escala e de rotação [5].

#### Captura das Estatísticas do Conjunto de Treino

Após o alinhamento do conjunto de treino verifica-se a existência de uma nuvem difusa de pontos em torno de cada *landmark*, o que equivale a dizer que o objecto representado apresenta alguma variabilidade. O PDM procura modelar a variação destas nuvens através de um processamento estatístico do conjunto de treino.

A captura das estatísticas de um conjunto de objectos alinhados permite obter a forma média dos objectos, assim como os *vector*es próprios e respectivos *valores próprios*, capazes de explicar uma percentagem razoável da variação total da forma dos objectos do conjunto.

A forma média dos objectos é determinada usando:

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i \quad (4)$$

O desvio de cada objecto em relação à média é dado pela seguinte expressão:

$$dX_i = X_i - \bar{X} \quad (5)$$

Assim, é possível determinar a matriz de covariância usando:

$$C_x = \frac{1}{N} \sum_{i=1}^N dX_i dX_i^T \quad (6)$$

Os métodos de Análise em Componentes Principais (PCA) permitem determinar um conjunto de variáveis, chamadas de Componentes Principais, a partir da decomposição em *vectores/valores próprios* da matriz de covariância [9]. Assim, a diferença  $dX_i$  pode ser representada como uma combinação linear dos componentes principais.

$$dX_i = b_{i0}p_0 + b_{i1}p_1 + \dots + b_{i2n-1}p_{2n-1} = Pb_i \quad (7)$$

Com,  $b_i = [b_{i0} \ b_{i1} \ \dots \ b_{i2n-1}]^T$

e  $P = [p_0 \ p_1 \ \dots \ p_{2n-1}]$

A partir da expressão (5) e (7), pode-se escrever

$$X_i = \bar{X} + dX_i = \bar{X} + Pb_i \quad (8)$$

Portanto, um objecto também pode ser representado como uma combinação linear dos componentes principais.

A vantagem da utilização destes métodos é que os *valores próprios* e os correspondentes *vectores próprios* são determinados por ordem decrescente de importância, o que quer dizer que os primeiros valores determinados são os responsáveis pela maior parte da variação total dos objectos. Assim, assumindo uma percentagem relativamente elevada da variância total, pode-se reduzir muito a dimensão dos dados.

Considerando que os primeiros  $t$  componentes principais explicam essa percentagem da variação total dos dados originais, obtém-se uma nova representação para um objecto,

$$X = \bar{X} + Pb \quad (9)$$

Onde  $b = [b_0 \ b_1 \ \dots \ b_{t-1}]^T$  e  $P = [p_0 \ p_1 \ \dots \ p_{t-1}]$ .

Note-se no entanto que cada componente do vector  $b$  tem de ser restringido a um intervalo, cujos limites adequados são:

$$-3\sqrt{\lambda_i} \leq b_i \leq 3\sqrt{\lambda_i}, \quad \text{para } 0 \leq i \leq t-1 \quad (10)$$

Com esta aproximação obtém-se uma representação fiel da variação da forma do objecto, com um volume de dados consideravelmente menor. O volume de dados reduz de  $2n \times 2n$  para  $2n \times t$ , e  $t \ll 2n$ .

#### IV. MODELAÇÃO DOS NÍVEIS DE CINZENTO EM TORNO DO OBJECTO

Para além do armazenamento do valor das coordenadas dos pontos (informação acerca da forma de cada objecto), é necessário também o armazenamento da informação da variação dos níveis de cinzento em torno de cada ponto. Esta informação tornar-se-á útil no momento da aplicação do algoritmo na procura de um objecto numa imagem, em particular no cálculo do movimento desejável para cada ponto. Esse movimento tem o objectivo de aproximar o modelo ao objecto que se pretende detectar.

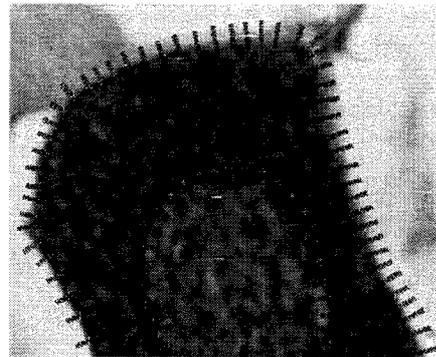


Fig. 3 - Segmentos de recta normais ao contorno.

Em termos técnicos, será guardada a informação da variação dos níveis de cinzento ao longo de um segmento de recta normal ao contorno do objecto, em todos os seus pontos. O tamanho do segmento de recta normal é escolhido pelo utilizador do sistema no momento em que guardar o primeiro objecto do modelo. Na figura 3 está representado um exemplo das normais a cada ponto para o caso de uma célula.

Assumindo que o comprimento do segmento de recta normal é  $n_p$  pixels. Para o *landmark*  $j$  da imagem  $i$ , obtém-se os seguintes níveis de cinzento ao longo da recta (perfil),

$$g_{ij} = [g_{ij0} \ g_{ij1} \ \dots \ g_{ijn_p-1}] \quad (11)$$

Aproximando a derivando da expressão anterior tem-se,

$$dg_{ij} = [g_{ij1} - g_{ij0} \ g_{ij2} - g_{ij1} \ \dots \ g_{ijn_p-1} - g_{ijn_p-2}] \quad (12)$$

Normalizando a derivada do perfil,

$$y_{ij} = \frac{dg_{ij}}{\sum_{k=0}^{n_p-2} |dg_{ijk}|} \quad (13)$$

Saliente-se que, para imagens ruidosas, pode-se efectuar uma média ortogonal aos níveis de cinzento, de forma a reduzir os efeitos do ruído [11]. (Ver figura 4).

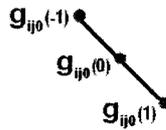


Fig. 4 - Esquema da filtragem ortogonal.

Neste caso, os níveis de cinzento ao longo do perfil são obtidos pela seguinte expressão:

$$g_{ij} = [g_{ij0} \ g_{ij1} \ \dots \ g_{ijn_p-1}] \quad (14)$$

Onde  $g_{ij0}$ , por exemplo, vai tomar o seguinte valor:

$$g_{ij0} = 0,25g_{ij0}(-1) + 0,5g_{ij0}(0) + 0,25g_{ij0}(1) \quad (15)$$

A partir dos valores da derivada normalizada (13) será efectuada a modelação da variação dos níveis de cinzento, de forma a caracterizar as variações desses níveis em torno dos contornos do objecto.

A média da derivada do perfil para cada *landmark*, em todo o conjunto de treino é dada por,

$$\bar{y}_j = \frac{1}{N} \sum_{i=1}^N y_{ij} \quad (16)$$

Agora determina-se a matriz de covariância da derivada do perfil normalizada,

$$C_{yj} = \frac{1}{N} \sum_{i=1}^N (y_{ij} - \bar{y}_j)(y_{ij} - \bar{y}_j)^T \quad (17)$$

Com estes dados detém-se a informação necessária e suficiente sobre a variação do aspecto do objecto em torno dos seus contornos.

## V. LOCALIZAÇÃO DE UM OBJECTO NUMA IMAGEM

Já foi referido que se pode representar a forma de qualquer objecto como a soma entre a forma média dos objectos do conjunto de treino e uma combinação linear dos primeiros  $t$  componentes principais.

Assim, e usando o modelo de distribuição de pontos, é possível identificar o objecto modelado numa determinada imagem. Para uma melhor compreensão, dividiu-se o processo de localização em quatro fases a descrever:

### Estimativa Inicial

O algoritmo de localização de um objecto numa determinada imagem inicia-se com a sobreposição da forma média sobre a área onde se encontra esse objecto. Depois é necessário fazer uma estimativa das principais características do objecto (Factor de escala e ângulo de rotação iniciais), que facilitará o arranque do algoritmo.

Pode-se então escrever a expressão da estimativa inicial,

$$X_{mit} = M(S_i, \theta_i) [\bar{X}] + t_i \quad (18)$$

Onde  $S_i$  é o factor de escala inicial,  $\theta_i$  é o ângulo de rotação inicial e  $t_i$  são as coordenadas do ponto onde se descarregou a forma média ( $\bar{X}$ ). Note-se que,  $t_i$  pode ser expresso por um vector de comprimento  $2n$ , sendo  $n$  o número de *landmarks*,  $t_i = [t_{x1} \ t_{y1} \ t_{x2} \ t_{y2} \ \dots \ t_{xn} \ t_{yn}]^T$ .

### Determinação dos movimentos de cada "landmark"

A determinação dos movimentos desejados para cada *landmark*, pode ser feita de várias formas. Uma das formas consiste em percorrer o segmento de recta normal ao contorno do objecto em cada ponto e determinar a variação máxima do nível de cinzento. Este método poderá ser eficaz para imagens sem ruído e com boa resolução, mas para imagens com ruído e com baixa resolução este método poderá falhar. Um método alternativo, consiste em usar a modelação da variação dos níveis de cinzento em torno de cada *landmark*, para determinar esses movimentos desejados [9,10].

Usando a modelação da variação dos níveis de cinzento em torno de cada *landmark*, é possível determinar a deslocação necessária a cada *landmark* ( $dX_i$ ), de modo a ajustar o modelo ao contorno do objecto.

Assim, será retirada a informação da variação dos níveis



Fig. 5 - Segmentos de recta normais ao contorno de cinzento ao longo da normal ao contorno do objecto, em todos os pontos. No entanto, agora o tamanho do segmento de recta normal tem de ser maior que o tamanho usado para a modelação. Na figura 5 está representado um exemplo dos segmentos de recta usados para a procura de um objecto.

Assumindo que a recta normal terá  $n_s$  pixels, com  $n_s > n_p$ . Para o landmark  $i$ , obtêm-se os seguintes níveis de cinzento do perfil,

$$s_i = [s_{i0} \ s_{i1} \ \dots \ s_{i_{n_s-1}}] \quad (19)$$

Aproximando a derivada da expressão anterior como,

$$ds_i = [s_{i1} - s_{i0} \ s_{i2} - s_{i1} \ \dots \ s_{i_{n_s-1}} - s_{i_{n_s-2}}] \quad (20)$$

Normalizando a derivada do perfil,

$$y_{si} = \frac{ds_i}{\sum_{k=0}^{n_s-2} |ds_{ik}|} \quad (21)$$

Dividindo a derivada do perfil normalizada (21),  $y_{si}$ , em vários subintervalos com o mesmo tamanho do vector  $\bar{y}_i$  determinado na expressão (16), e assumindo que a cada um desses subintervalos se representa por  $\mathbf{h}(\mathbf{d})$ . Pode-se determinar o valor de  $\mathbf{d}$  correspondente ao subintervalo  $\mathbf{h}(\mathbf{d})$  mais similar ao vector  $\bar{y}_i$ .

Esse valor é determinado através da expressão do erro quadrático, que será mínimo quando o modelo se ajustar ao contorno do objecto,

$$f(\mathbf{d}) = (\mathbf{h}(\mathbf{d}) - \bar{y}_i)^T C_{yi}^{-1} (\mathbf{h}(\mathbf{d}) - \bar{y}_i) \quad (22)$$

Onde  $C_{yi}^{-1}$  representa o inverso da matriz de covariância de  $y_i$ , determinada na expressão (17).

Assim, determinou-se o ponto para o qual o landmark  $i$  deve ser deslocado. Seguindo o mesmo procedimento para os restantes, obtêm-se o vector dos movimentos desejados

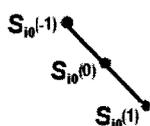


Fig. 6 - Esquema da filtragem ortogonal para cada landmark ( $dXi$ ).

Note-se que também se pode efectuar uma média ortogonal aos níveis de cinzento de forma a reduzir os efeitos do ruído. Neste caso cada elemento da expressão (19) será dado pela seguinte expressão:

$$S_{i0} = 0,25S_{i0}(-1) + 0,5S_{i0}(0) + 0,25S_{i0}(1) \quad (23)$$

*Determinação dos novos parâmetros do objecto*

A partir do vector dos movimentos para cada landmark ( $dXi$ ), pode-se ajustar a posição (rodar, fazer a translação e mudar a escala) do objecto do modelo, de forma a

ajustar a forma estimada  $X_{mit}$  tanto quanto possível de  $X_{mit} + dX_i$ . De forma simbólica, pode-se escrever

$$X_{mit} = M(S_i, \theta_i) [\bar{X}] + t_i \xrightarrow{(1+ds), d\theta, dt} X_{mit} + dX_i \quad (24)$$

Ou,

$$M(S_i(1+ds), \theta_i + d\theta) [\bar{X}] + t_i + dt \longrightarrow X_{mit} + dX_i \quad (25)$$

Sabendo os valores dos parâmetros  $1 + ds$ ,  $d\theta$  e  $dt$ , é necessário resolver a seguinte equação em ordem a  $dX$ :

$$M(S_i(1+ds), \theta_i + d\theta) [\bar{X} + dX] = X_{mit} + dX_i - (t_i + dt) \quad (26)$$

Se  $X_{mit} = M(S_i, \theta_i) [X_m] + t_i$ , obtêm-se,

$$M(S_i(1+ds), \theta_i + d\theta) [\bar{X} + dX] = M(S_i, \theta_i) [\bar{X}] + dX_i - dt \quad (27)$$

Como  $M^{-1}(s, \theta) [\dots] = M(s^{-1}, -\theta) [\dots]$ , da expressão (27) obtêm-se,

$$\bar{X} + dX = M((S_i(1+ds))^{-1}, -(\theta_i + d\theta)) [M(S_i, \theta_i) [\bar{X}] + dX_i - dt] \quad (28)$$

Assim,

$$dX = M((S_i(1+ds))^{-1}, -(\theta_i + d\theta)) [M(S_i, \theta_i) [\bar{X}] + dX_i - dt] - \bar{X} \quad (29)$$

Se se escrever  $dX = Pdb$ , e sabendo que os vectores de  $P$  são ortogonais entre si ( $P^T = P^{-1}$ ), obtêm-se,

$$db = P^T dX \quad (30)$$

*Actualização do objecto*

Com a informação determinada no ponto anterior, pode-se actualizar os parâmetros da forma do objecto e respectiva posição para a estimativa inicial, obtendo assim uma nova estimativa  $X_{mit}^{(1)}$ , em que,

$$X_{mit}^{(1)} = M(S_i(1+ds), \theta_i + d\theta) [X + Pdb^T] + t_i + dt \quad (31)$$

Ou dito de outra maneira,

$$\begin{aligned} t_{xi} &\rightarrow t_{xi} + dt_x \\ t_{yi} &\rightarrow t_{yi} + dt_y \\ S_i &\rightarrow S_i(1+ds) \\ \theta_i &\rightarrow \theta_i + d\theta \\ b &\rightarrow b + db \end{aligned} \quad (32)$$

Analogamente, também se pode obter outra nova estimativa  $X_{init}^{(2)}$  a partir de  $X_{init}$ , e assim sucessivamente, até que não se registem variações significativas.

## VI. RESULTADOS EXPERIMENTAIS

Para testar o desempenho dos métodos descritos, implementou-se uma interface que contempla todas as funcionalidades inerentes ao ASM. Foram construídos vários modelos de células afim de testar o desempenho destes métodos na localização de células em imagens histológicas.

De seguida são apresentados alguns resultados obtidos para dois dos modelos construídos.

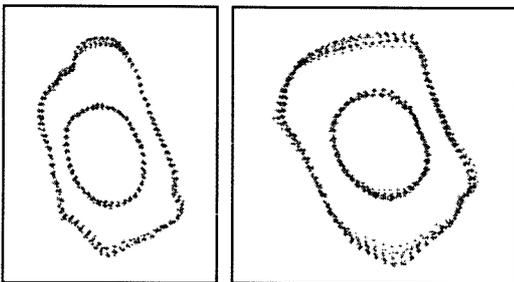


Fig. 7 - Conjunto de Treino alinhado de dois modelos.

### A. Conjunto de Treino alinhado

A partir de um conjunto de 12 imagens construiu-se os conjuntos de treino que testaram o desempenho destes métodos de análise de imagem. Cada célula do conjunto de treino foi definida por 124 *landmarks* (43 para o núcleo e 81 para o citoplasma). Na figura 7 estão representados dois conjuntos de treino alinhados.

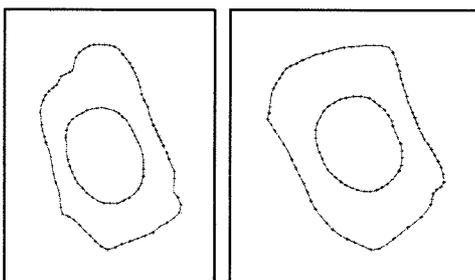


Fig. 8 - Forma média de dois modelos.

### B. Forma média do conjunto de treino

Da análise estatística ao conjunto de treino resultou, para além de outros dados, a forma média dos objectos. Na figura 8 estão representadas as formas médias dos dois conjuntos de treino.

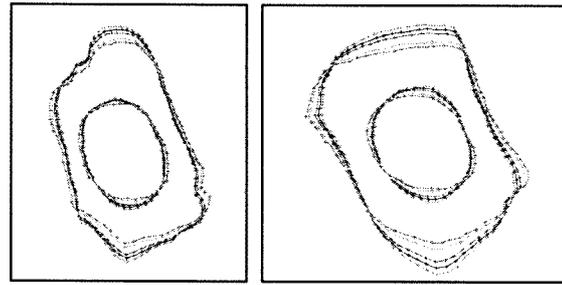


Fig. 9 - Variação do primeiro modo.

### C. Variabilidade do Modelo

Para além da forma média, da análise estatística resultaram também os modos de variação do modelo. Na figura 9 está representado o efeito do primeiro modo na variação do objecto, para os dois modelos.

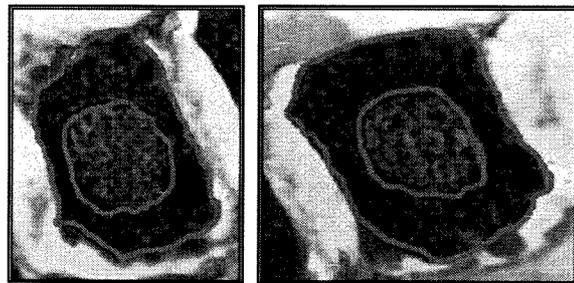


Fig. 10 - Resultado da procura de um Objecto.

### D. Resultado da Procura de um Objecto

Em cumprimento de um dos objectivos do estudo, foi efectuada uma avaliação ao desempenho destes métodos quando aplicados na localização de uma determinada célula numa imagem histológica. Na figura 10 estão representados os resultados desta localização para duas imagens distintas.

O desempenho dos modelos construídos é bastante bom, alcançando a convergência de cerca de 92% dos seus pontos e num pequeno número de iterações.

O tempo despendido por cada iteração é dependente do número de pontos de cada objecto. Para os modelos construídos (124 pontos) foi cerca de 0,4 segundos por iteração.

## VII. CONCLUSÕES E TRABALHO FUTURO

Com os resultados obtidos neste trabalho pode-se confirmar a possibilidade de identificar qualquer objecto numa determinada imagem, usando ASM.

Confirma-se que a aplicação destes métodos conduzem a resultados muito satisfatórios. No entanto, estes métodos apresentam algumas limitações. Os modelos criados não são universais para todas as células, uma vez que é necessário haver informação prévia acerca da forma dos objectos. Logo, para cada tipo de células tem de ser criado um modelo próprio.

Para resolver esta situação, é legítimo pensar-se que se forem introduzidas mais imagens no conjunto de treino, misturando vários tipos de células, se obtêm mais modos de variação, e portanto melhores resultados. Esta afirmação não é de toda verdade porque se não se tiver cuidado na escolha das imagens, o elevado número de modos de variação pode degradar (toldar) o modelo, conduzindo o algoritmo a piores resultados.

Assim, são necessários alguns cuidados na implementação destes modelos, nomeadamente na marcação dos pontos para a construção do conjunto de treino, na escolha das imagens para o conjunto de treino e posteriormente na inicialização da forma média no momento da localização de objectos numa imagem.

De uma maneira geral, em termos de velocidade estes métodos revelam-se bastante rápidos, o que constitui uma vantagem. No entanto, não se verifica grande versatilidade nestes métodos quando aplicados na análise de células, pois o citoplasma apresenta grandes variações na sua forma. Apesar disso, estes métodos serão muito vantajosos quando aplicados a imagens cuja variação não é muito significativa, como por exemplo reconhecimento facial e detecção de estruturas em ecocardiogramas.

Como trabalho futuro, poder-se-ia combinar estes métodos com outros já conhecidos, por exemplo "Snakes", e usar o melhor de cada um para construir um sistema mais versátil e viável.

Mais tarde poder-se-á avançar para plataformas de desenvolvimento de alto nível como por exemplo *Delphi*, *Visual Basic*, ou *Visual C++*, que permitem desenvolver boas interfaces com o utilizador; aproveitando no entanto as bibliotecas de funções construídas neste trabalho.

#### AGRADECIMENTOS

Agradece-se à Unidade de Investigação 127/94 IEETA da Universidade de Aveiro, o financiamento do projecto.

#### REFERÊNCIAS

- [1] G. Parmigianni, E. S. Garret, R. Anbazhagan and E. Gabrielson, "A Statistical Framework for Expression-Based Molecular Classification in Cancer", J Royal Statistical Society, 2002.
- [2] L. H. Staib and J. S. Duncan, "Parametrically Deformable Contour Models", IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego, pp. 427 - 430, 1989.
- [3] L. H. Staib and J. S. Duncan, "Model-based deformable surface finding for medical images", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 15, n.º 5, 1996.
- [4] M. Kass, A. Witkin and D. Terzopoulos, "Snakes: Active Contour Models", First International Conference on Computer Vision, IEEE Computer Society Press, pp. 259 - 268, 1987.
- [5] T. F. Cootes, C. J. Taylor, D. H. Cooper and J. Graham, "Active Shape Models - Their Training and Application", Computer Vision and Image Understanding, Vol. 61, n.º 1, pp. 38 - 59, 1995.
- [6] T. F. Cootes, C. J. Taylor, D. H. Cooper and J. Graham, "Training models of shape from sets of examples", Proceedings of the British Machine Vision Conference, Springer-Verlag, pp. 9 - 18, 1992.
- [7] T. F. Cootes, C. J. Taylor and A. Lanitis, "Active Shape Models: Evaluation of a Multi-Resolution Method for Improving Image Search", Proceedings of the British Machine Vision Conference, pp.327 - 336, 1994.
- [8] T. F. Cootes, A. Hill, C. J. Taylor and J. Haslam, "The Use of Active Shape Models for Locating Structures in Medical Images", Image and Vision Computing, Vol. 12, n.º 6, pp. 355 - 366, 1994.
- [9] G. Hamarneh, R. Abu-Gharbieh, and T. Gustavsson, "Review - Active Shape Models - Part I: Modelling Shape and Gray Level Variation", Swedish Symposium on Image Analysis, pp. 125 - 128, 1998.
- [10] R. Abu-Gharbieh, G. Hamarneh and T. Gustavsson, "Review - Active Shape Models - Part II: Image Search and Classification", Swedish Symposium on Image Analysis, pp. 129 - 132, 1998.
- [11] Active Shape Models (ASM), [http://www.isbe.man.ac.uk/courses/Computer\\_Vision/downloads/L15\\_ASMs.pdf](http://www.isbe.man.ac.uk/courses/Computer_Vision/downloads/L15_ASMs.pdf), (Jun 2004)
- [12] A. Hill, T. F. Cootes and C. J. Taylor, "Active Shape Models and the shape approximation problem", Image and Vision Computing, pp. 601 - 608, 1996.
- [13] M. Rogers and J. Graham, "Robust active shape model search", In Proceedings of the European Conference on Computer Vision, 2002.