

Segmentação do Miocárdio do Ventrículo Esquerdo em Ressonância Magnética usando conectividade fuzzy e expansão de camadas

SÉRGIO S. FURUIE¹
GRISelda E. JARA²
MARINA F.S. REBELO¹
LUIZ C. PARZIANELLO¹
MARCO A GUTIERREZ¹

¹Divisão de Informática -- Instituto do Coração / HC.FMUSP
Av. Enéas C. Aguiar, 44, 05403-000 São Paulo, SP, Brasil
{furuie, rebele, gutierrez, parzianello}@incor.usp.br

²INPE--Instituto Nacional de Pesquisas Espaciais
Caixa Postal 515, 12201 São José dos Campos, SP, Brasil
griselda@dpi.inpe.br

Abstract. A truly 3D technique for segmentation of left ventricle (LV) myocardium in MRI is presented, based on fuzzy connectedness and incorporation of voxels with minimum cost. Direct segmentation of LV muscle based only on intensity or texture is difficult because of inhomogeneity and background with similar characteristics. We propose a two step technique: first, segmentation of LV cavity and then an orderly search of LV muscle keeping roughly the endocardium morphology. The LV cavity is extracted in all volumes applying competitive fuzzy connectedness between cavity and myocardium. From the endocardium surface, connected voxels with minimum insertion cost and below a given limit are incorporated in an orderly fashion (layers), emulating a balloon expansion model. The cost function for incorporating a voxel has three components: a) spatial gradient to avoid other objects with distinct boundaries; b) textures to allow some local inhomogeneities; c) shape similarity to the endocardium surface in order to restrict leaking to other organs with similar texture. Studies with phantoms (contrast=48 %) were carried out and presented good results (less than 6 % of misclassified voxels) for SNR up to 12 dB (Gaussian noise). The proposed technique was also applied to gated-MRI of heart, closely matching manually segmented LV myocardium in images with good quality.

Keywords: Image Segmentation, Left Ventricle, MRI.

1 Introdução

O amplo espectro de investigações biomédicas e clínicas em órgãos complexos como o coração requer ferramentas mais adequadas do que a simples visualização (bidimensional e tridimensional) e a inspeção de estruturas anatômicas propiciadas pelos modernos equipamentos médicos. Dados quantitativos precisos, reproduzíveis e relevantes devem ser extraídos para suportar a pesquisa, o diagnóstico, a terapia e mesmo a cirurgia. No caso cardíaco, por exemplo, informações quantitativas sobre a movimentação e a contração regional das paredes musculares são de extrema importância para o diagnóstico objetivo e a indicação precisa do tratamento. Contudo, um

dos grandes obstáculos à análise apropriada das estruturas médicas é a dificuldade de se identificar e isolar objetos de interesse de forma automática e efetiva.

Devido à dificuldade de se obter uma solução geral e robusta, tanto a segmentação quanto a classificação continuam sendo áreas de intensa pesquisa em processamento de imagens médicas [Collins,1992; Brummer,1993; Kapur, 1996]. Os processamentos associados a estas áreas dependem de vários fatores, tais como a modalidade do equipamento, órgão estudado, nível de contraste, resolução, relação sinal-ruído, espessura do corte, e uniformidade de intensidade, isto somente para citar apenas alguns dos mais importantes.




Figura 1. Exemplo de segmentação pelo critério da conectividade em uma imagem das câmaras cardíacas (a) através de RM (gradiente eco). Objetos classificados de forma “fuzzy”: b) VE; c) VD; d) miocárdio.

Diversos métodos automáticos e semi-automáticos têm sido propostos na literatura com sucesso limitado, os quais podem ser divididos em orientados por contorno e por região (isodensidade) [Joliot, 1993]. Elevada dependência com o nível de ruído e detecção de inúmeros contornos são dificuldades comuns do primeiro grupo, e detecção de diversos elementos ou agrupamentos isolados são complexidades típicas enfrentadas pela segunda técnica. Encontram-se também trabalhos [Xuan, 1995; Chakraborty, 1996] que integram as duas abordagens. Contudo, a segmentação, na prática clínica, ainda é realizada manualmente ou semi-automaticamente na grande maioria dos casos.

No caso específico de estruturas 3D dinâmicas de Ressonância Magnética (RM), o problema é agravado pelo elevado volume de dados (centenas de imagens por exame no caso de "gated-MRI"), sugerindo a necessidade de técnicas que minimizem a interação com o usuário e otimizem algoritmos de segmentação e classificação. Por outro lado, o contraste entre o miocárdio e o tecido que o cerca é baixo, além da não-homogeneidade de intensidade do mesmo nas imagens de RM.

O objetivo deste trabalho é apresentar uma técnica n-dimensional robusta para a segmentação do miocárdio do ventrículo esquerdo (VE) em imagens tridimensionais dinâmicas de Ressonância Magnética. O processo envolve basicamente 2 passos: a) determinação do endocárdio (superfície 3D interna do miocárdio) baseado em classificação competitiva; e b) obtenção do epicárdio pela expansão da superfície interna mantendo aproximadamente a forma original.

2 Material e Método

O objeto da segmentação é o miocárdio do VE – músculo responsável pela função mecânica do coração – a partir de um conjunto de imagens tomográficas do tórax (figura 1a). As imagens são sincronizadas com o eletrocardiograma (ECG) de modo a se obter uma sequência de volumes que represente a dinâmica cardíaca com melhor relação sinal/ruído. No presente estudo, foram adquiridos 12 volumes com 12 cortes cada (espessura de 7 mm), sendo que cada corte foi representada pela matriz de 103 x 101 pixels (1,64 x 1,64 mm).

O objeto de interesse apresenta baixo contraste em relação ao material circundante, dificultando o emprego de técnicas n-dimensionais como o “region growing” e o “thresholding”. Por outro lado, métodos baseados em contornos apresentam sérias dificuldades na extensão para dimensões maiores do que 2.

Neste trabalho estamos propondo a identificação do miocárdio em duas fases: a) segmentação da cavidade do VE, de modo a capturar a parede interna (endocárdio); e b) determinação do objeto através da expansão do endocárdio.

Hipóteses básicas

- Possibilidade de treinar o sistema através de uma amostra dos objetos com características aproximadamente homogêneas. O usuário delinea, por exemplo, através de um “mouse”, uma região do objeto de interesse em um dos cortes quaisquer da imagem tridimensional. Havendo número suficiente de "voxels", torna-se possível estimar os parâmetros do "cluster" que caracteriza o objeto em questão.
- Os parâmetros estimados, através de um corte (treinamento), são válidos para todo o objeto, incluindo a terceira dimensão espacial e, no caso 3D dinâmico, o tempo.
- A forma do epicárdio é semelhante ao do endocárdio.

Determinação do endocárdio

A cavidade apresenta não-homogeneidade de intensidade (figura 1.a), além de conter estruturas dispersas na região (músculos papilares) com textura semelhante ao miocárdio. Técnicas tradicionais tenderiam a apresentar falsos positivos (ventrículo direito) e falsos negativos (músculos papilares).

A presente proposta envolve a associação competitiva de um voxel pertencer à cavidade (CAV) ou ao miocárdio (MIOC), incluindo-se a restrição de conectividade. O usuário fornece amostras dos dois objetos para a caracterização estatística dos “clusters” de CAV e MIOC [Furuie, 1996a]. Pode-se então determinar o “fuzzy subset” de cada objeto, onde a função de associação é baseada em conectividade à região inicial e afinidade às características dos clusters correspondentes [Udupa, 1995].

Cálculo da função de associação

Seja D um subconjunto do espaço Euclidiano n -dimensional, representando o domínio da imagem. Pode-se então definir um “fuzzy subset” A de D por um conjunto de pares ordenados [Bezdek, 1992],

$$A = \{ (x, f_A(x)) / x \in D \}$$

onde $f_A : D \rightarrow [0,1]$ representa a função de associação do objeto A em D e x é o vetor de coordenadas.

Seja $\underline{v}(x)$ o vetor de atributos associado ao voxel $x \in D$. A afinidade entre dois voxels quaisquer x_1 e x_2 pode ser obtida por alguma medida de similaridade entre os seus atributos. No presente trabalho estamos utilizando como afinidade a verossimilhança do voxel pertencer à classe do objeto em questão. O cálculo da verossimilhança é obtido a partir das características estatísticas da classe [Johnson, 1992],

$$afin_j(x) = \exp\left(-\frac{1}{2} \cdot d_j^2(x)\right) \quad (1)$$

onde $d_j(x)$ corresponde à distância estatística de x à classe j ,

$$d_j^2(x) = \left(\underline{v}(x) - \underline{\mu}_j\right)^T \cdot Cov_j^{-1} \cdot \left(\underline{v}(x) - \underline{\mu}_j\right) \quad (2)$$

$\underline{\mu}_j$: vetor médio de atributos da classe j

Cov_j : matriz de covariância correspondente ao vetor de atributos da classe j

Para cada objeto pode-se escolher uma semente fixa s (da região da amostra) que efetivamente pertença ao



Figura 2. Segmentação da cavidade do VE usando associação competitiva entre a cavidade (figura 1b) e o miocárdio (figura 1d).

objeto. Definindo-se $f_A(x)$ como a conectividade de x com s , o qual por sua vez pode ser definida [Udupa, 1995] como o maior vínculo entre todos os possíveis caminhos estabelecidos entre x e s . O vínculo entre dois pontos por um determinado caminho pode ser obtido como sendo a menor afinidade entre dois voxels adjacentes quaisquer do caminho. Através da programação dinâmica [Udupa, 1995] pode-se calcular a conectividade para todos os voxels adjacentes à superfície inicial e, progressivamente, para todo o volume.

A Figura 1 mostra o resultado em uma imagem cardíaca (corte transversal) obtida por Ressonância Magnética (gradiente eco). O algoritmo foi empregado considerando-se apenas um atributo (intensidade) por voxel, e 3 objetos treinados: ventrículo esquerdo (VE), ventrículo direito (VD) e miocárdio. As figuras 1b, 1c e 1d mostram os resultados da classificação fuzzy para os três objetos. Note também a boa qualidade na determinação do VE através do interior do miocárdio (figura 1d).

Uma vez calculados $f_{CAV}(x)$ e $f_{MIOC}(x)$, procede-se à fase de decisão competitiva. Se $f_{CAV}(x) \geq f_{MIOC}(x)$, então x pertence à CAV. A figura 2 ilustra o resultado considerando-se as figuras 1b e 1d para a extração da CAV.

Em resumo, a identificação da cavidade envolve as seguintes fases: a) caracterização estatística da intensidade dos voxels da CAV e do MIOC baseado nas amostras de cada objeto (aprendizagem supervisionada); b) cálculo da conectividade (fuzzy) de todos os voxels a cada objeto; c) extração da CAV baseado na comparação das funções de associação. A superfície da cavidade auxiliará na obtenção da superfície externa (epicárdio), conforme descrito a seguir.

Determinação do Epicárdio

Sendo baixo o contraste entre o miocárdio e as estruturas que o cercam, é necessário a inclusão de informações *a priori* (como a morfologia ventricular, por exemplo) para se obter uma técnica mais robusta. Note na figura 1d que a conectividade do MIOC com o músculo do ventrículo direito e estruturas inferiores é elevada, dificultando a segmentação somente do miocárdio do VE.

A abordagem proposta neste trabalho envolve a expansão ordenada das camadas sobre o endocárdio segundo uma função de custo [Furuie, 1996b], de modo a preservar, aproximadamente, a forma ventricular.

O algoritmo tem como entrada uma superfície inicial, no caso uma camada externa da cavidade. A partir desta região inicial há a expansão considerando-se o custo da incorporação de cada voxel vizinho. Incorpora-se aquele voxel *conectado* com o menor custo, enquanto o custo de incorporação estiver abaixo de um limite imposto pelo usuário. A definição da função de custo desempenha papel fundamental no sucesso da segmentação. A função de custo deve considerar as bordas (gradientes), textura, informações *a priori* sobre o objeto tais como morfologia da estrutura, posição, tamanho, etc. O custo deve ser tanto maior quanto maior for a discrepância esperada para um voxel pertencente ao objeto.

Deste modo, para efeito deste trabalho, podemos considerar a seguinte função custo para incorporar o voxel i :

$$custo(i) = \alpha \cdot grad^2(i) + \beta \cdot textura(i) + \gamma \cdot forma(i) \quad (3)$$

onde

$grad^2(i)$: representa o gradiente espacial 3D ao quadrado no voxel i , o qual deve ser pequeno na região interna do objeto, aumentando à medida que se aproxima da borda;

$textura(i)$: distância do atributo local de i em relação à média da amostra;

$forma(i)$: medida da morfologia após inclusão do voxel i ;

α, β, γ : são os pesos associados a cada atributo;

As duas primeiras parcelas são baseadas em informações locais, sendo que a terceira utiliza informações globais. Note que também estamos utilizando a informação de posição, pois a superfície inicial (semente) é fornecida pelo usuário.



Figura 3. Identificação do miocárdio através da expansão do endocárdio segundo os pesos mencionados no texto.

O $grad^2(i)$ pode ser obtido por vários métodos [Gonzalez, 1992]. Estamos utilizando o algoritmo de Sobel, que simplesmente calcula as derivadas espaciais em cada eixo e as soma. Para o caso 2D, teríamos:

$$grad^2(i) = \left(\frac{dv_i}{dx} \right)^2 + \left(\frac{dv_i}{dy} \right)^2 \quad (4)$$

onde v_i é o valor do voxel na posição i

Para a medida da $textura(i)$, calcula-se a distância entre o valor da média local da intensidade e a média da amostra:

$$textura(i) = (\bar{v}_i - \mu)^2 \quad (5)$$

onde μ é a média do valor do atributo na região inicial e

\bar{v}_i : média local do atributo no voxel i para uma dada janela (neste trabalho utilizamos janela 3x3);

Uma medida da morfologia do objeto é bastante complexa de ser definida, uma vez que se busca representar, em poucos números, as nuances de um contorno. Uma implementação simples é o grau de compactação definida pela razão entre o volume e a área da superfície. No caso 2D pode-se utilizar, por exemplo, a relação (adimensional) entre o perímetro e a área, definida por:

$$\frac{perimetro^2}{area}$$

que no caso de um círculo perfeito deve resultar em 4π . A função $forma(i)$ pode ser definida por:

$$forma(i) = \left| \frac{perimetro^2}{area} - k \right| \quad (6)$$



Figura 4. Resultado da segmentação com o peso ($\gamma=0$) do formato igual a zero.

onde k é o grau de compactação da superfície inicial.

Os pesos α , β e γ devem ser balanceados para evitar que um desses fatores predomine na segmentação, seja devido à escala, seja devido a diferentes unidades. Os valores utilizados neste trabalho foram [Furuie, 1996b]:

$$\alpha = \beta/2$$

$$\beta = 1/\sigma^2$$

$$\gamma = 1/3,43$$

onde σ^2 é a variância da intensidade nos voxels da superfície inicial.

3 Resultados

No sentido de se reduzir o tempo de processamento, utilizou-se uma implementação simplificada da solução ótima. Para cada iteração (camada), todos os voxels cujos custos de incorporação estavam abaixo de um dado limiar foram agregados ao MIOC. Estudos realizados em simulações numéricas (“phantoms”) com contraste de 48%, apresentaram bons resultados (erro de classificação menor do que 6% para ruído gaussiano aditivo da ordem de 12 dB). A figura 3 mostra os resultados no caso 2D em RM cardíaca a partir do endocárdio, enquanto que a figura 4 mostra os resultados quando se remove ($\gamma=0$) a influência da forma do objeto, ilustrando a importância de se utilizar informações morfológicas.

4 Discussão e Conclusão

Esta abordagem permite utilizar eficientemente as informações eventualmente contidas nas múltiplas imagens (multi-banda), incorporar algumas informações *a priori*, e garantir a conectividade entre os voxels. O algoritmo calcula a conectividade em todas as dimensões, podendo ser empregado para imagens 3D dinâmicas. A

possibilidade de treinar o classificador para um dado objeto é uma opção interessante pois minimiza-se a influência de fatores tais como equipamento (modalidade, calibração, escala), órgão, resolução, ruído, e a variabilidade natural entre pacientes. Contudo, pesquisas ainda devem ser dedicadas à otimização no sentido de agilizar a segmentação em casos 3D ou de maior dimensão, definição de novas afinidades, e aperfeiçoamento das função de custo de modo a melhor refletir morfologias e informações *a priori*.

5 Agradecimentos

Agradecemos à FAPESP, ao CNPq e Fundação E.J.Zerbini pelo apoio recebido para a realização deste trabalho.

Referências

- Bezdek J.C., Pal S.K. (1992) *Fuzzy models for pattern recognition*, New York: IEEE Press, 1992.
- Brummer M.E., Mersereau R.M., Eisner R.L., Lewine R.R.J. (1993) "Automatic detection of brain contours in MRI data sets", *IEEE Transactions on Medical Imaging*, volume 12, number 2, pages 153-166, June 1993.
- Chakraborty A, Staib LH, Duncan JS, "Deformable boundary finding in Medical Images by Integrating Gradient and Region Information", *IEEE Trans. Medical Imaging*, vol. 15(6):859-870, Dec. 1996.
- Collins D.L., Peters T.M., Evans A.C. (1992) "Multiresolution image registration and brain structure segmentation", *Proc. of the Satellite Symposium on 3D Advanced Image Processing in Medicine*, Rennes, France, Nov.2-4, 1992, pp. 105-109.
- Furuie SS, Moura LA, Udupa JK (1996a), "Classificação de imagens médicas 3D baseado em vetor de atributos", *Revista Brasileira de Engenharia - Caderno de Engenharia Biomédica*, v.12(3): 75-86, out 1996.
- Furuie SS, Jara GE, Rebelo MFS, Melo CP (1996b), "Segmentação do ventrículo esquerdo cardíaco usando modelo de expansão de balão", *Revista Brasileira de Engenharia - Caderno de Engenharia Biomédica*, v.12(3): 99-107, out 1996.
- Gonzales RC, Woods R - *Digital image Processing - Third Edition*, Addison Wesley, 1992.

- Johnson R.A., Wichern D.W. (1992) *Applied Multivariate Statistical Analysis*, Englewood Cliffs: Prentice Hall, Third Edition, 1992.
- Joliot M., Mazoyer B.M. (1993) "Three-dimensional segmentation and interpolation of magnetic resonance brain images" ,*IEEE Transactions on Medical Imaging*, volume 12, number 2, pages 269-277, June 1993.
- Kapur T, Grimson WEL, Wells III V, Kikinis R "Segmentation of brain tissue from magnetic resonance images", *Medical Image Analysis* (1996), vol. 1(2):109-127.
- Udupa JK, Samarasekera, S "Fuzzy connectedness and object definition", *SPIE* volume 2431, 1995, pg 1-11.
- Wu C., Chen Y., Hsieh K. (1992) "Texture features for classification of ultrasonic liver images", *IEEE Transactions on Medical Imaging*, volume. 11, number 2, pages 141-152, June 1992.
- Xuan J., Adali T., Wang Y. (1995) "Segmentation of Magnetic Resonance brain image: integrating region growing and edge detection", *Proceedings of the International Conference on Image Processing*, Washington DC, IEEE Press, 1995, pages 544-547.