

CLASSIFICAÇÃO DE IMAGENS MÉDICAS 3D BASEADO EM VETOR DE ATRIBUTOS

S. S. Furuie¹, L. A. Moura², J. K. Udupa³

RESUMO -- Este trabalho propõe uma técnica para a classificação de elementos de imagens 3D baseado em vetor de atributos. O objetivo deste trabalho é apresentar uma técnica rápida para a classificação de *voxels* e que permita utilizar as múltiplas imagens disponíveis sobre os objetos de uma forma eficiente. O trabalho é baseado na classificação dos *voxels* quanto à associação – no sentido *fuzzy* – dos mesmos a cada objeto identificado, o qual é caracterizado estatisticamente pelo aglomerado (*cluster*) dos vetores de atributos. A função de associação é calculada pela verossimilhança do vetor de atributos do *voxel* em relação ao cluster. São apresentadas algumas texturas para a classificação do ventrículo esquerdo em imagens 3D dinâmicas de Ressonância Magnética, em especial, a da posição do objeto e a da variabilidade dinâmica. Os resultados apresentam, em casos complexos, os problemas típicos da segmentação baseada em atributos, quais sejam, falsos positivos isolados, e falhas em alguns *voxels*, uma vez que esta técnica usa apenas informações locais. No entanto, a classificação pode ser significativamente melhorada através do refinamento pós-processamento, ou incluindo-se informações *a priori* sobre o objeto tais como contexto e conectividade.

Palavras-chave: Classificação, Segmentação, *clusters*, Verossimilhança, Textura

INTRODUÇÃO

Com os recentes avanços na área de equipamentos médicos, notadamente em Tomografia Computadorizada (CT), Ultra-som (US) e Ressonância Magnética (MRI), torna-se cada vez mais comum a disponibilidade de informações tridimensionais (anatômicas e funcionais) sobre as estruturas de interesse. No entanto, a visualização e análise 3D efetivas têm evoluído de forma bem mais lenta, sendo que a grande maioria das análises é ainda realizada em cortes ortogonais (sagital, coronal e transversal) e, em algumas situações, em planos arbitrários, apesar de se ter informações tridimensionais. A grande dificuldade reside na classificação dos elementos do volume (*voxels*), i.é., na associação de cada *voxel* às estruturas médicas. As imagens obtidas, em geral em tons de cinza, são apenas associações da intensidade ao fenômeno físico que está sendo medido (atenuação de raio-X, impedância acústica, tempo de relaxação etc.), e não codifica, em geral, univocamente as diferentes estruturas presentes no corpo humano.

¹ Divisão de Informática-Instituto do Coração, Av. Dr. Enéas de Carvalho Aguiar, 44, 05403-000 São Paulo - SP, e-mail: furuie@incor.usp.br

² Superintendência do Hospital das Clínicas, R. Ovídio Pires Campos, 255, 05403-010, São Paulo - SP, e-mail: lincoln@incor.usp.br

³ Medical Image Processing Group, University of Pennsylvania, Philadelphia PA 19104-6021, USA, e-mail: jay@mipg.upenn.edu

A qualidade da visualização, manipulação e análise de estruturas médicas tridimensionais, em diversas situações, depende dramaticamente da qualidade da segmentação e classificação (Udupa, 1991; Brummer, 1993) dos dados. Devido a este fato e à dificuldade de se obter uma solução geral e robusta, a segmentação e classificação continuam sendo áreas de intensa pesquisa em processamento de imagens médicas (Collins, 1992; Brummer, 1993). Estes tipos de processamento dependem de vários fatores, tais como modalidade do equipamento, órgão, contraste, resolução, relação sinal-ruído, espessura do corte, e uniformidade de intensidade para citar apenas alguns dos mais importantes. 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. Na literatura encontram-se também trabalhos (Xuan, 1995) que integram as duas abordagens.

A grande maioria das técnicas utiliza a intensidade e/ou gradiente dos *voxels* para a classificação. Texturas calculadas a partir das imagens originais têm sido também utilizadas (Wu, 1992), assim como a incorporação de informações *a priori*. Contudo, a segmentação na prática clínica, na grande maioria dos casos, ainda é realizada manualmente ou semi-automaticamente pelo usuário.

No caso específico de estruturas 3D dinâmicas, o problema é agravado pelo elevado volume de dados envolvido (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.

Na área médica, é crescente a disponibilidade de múltiplas imagens de um mesmo objeto, seja utilizando uma única modalidade de equipamento, como é o caso da ressonância magnética onde comumente são fornecidas múltiplas imagens (T1, T2, transferência de magnetização, densidade de prótons), ou então diversas combinações (imagens multimodais) entre MRI, PET, SPECT, CT, ultra-som etc. Esta multiplicidade de imagens pode ser utilizada, também, para melhorar a precisão na classificação, fazendo uso de informações independentes existentes nas outras imagens. Adicionalmente, pode-se também obter imagens (texturas), através de processamento, que refletem pelo menos parte das informações de interesse para a segmentação/classificação.

O objetivo deste trabalho é apresentar uma técnica rápida para a classificação e que permita utilizar as múltiplas imagens disponíveis sobre os objetos de uma forma eficiente. O trabalho é baseado na classificação dos *voxels* quanto à pertinência – no sentido *fuzzy* – do mesmo a cada objeto identificado. Dessa forma, tendo-se M imagens 3D sobre o mesmo objeto (por exemplo, imagens de Ressonância Magnética T1 e T2 tridimensionais do coração na diástole), pode-se associar (classificar) cada elemento do espaço *voxel* em relação à pertinência aos objetos VE (ventrículo esquerdo), VD (ventrículo direito), etc. A presente proposta visa estender uma ferramenta poderosa (*clustering*) para a classificação dos elementos. A contribuição do trabalho está nos seguintes aspectos:

- Classificação dos elementos no sentido *fuzzy* baseado na verossimilhança;
- Possibilidade de facilmente incorporar e adicionar informações *a priori* como conectividade e morfologia para aumentar a separabilidade dos *clusters*;

- Classificador com pouca intervenção do usuário;
- Utilização de múltiplas imagens e remoção automática de dependência.

METODOLOGIA

O problema em questão é determinar, para cada *voxel*, o grau de associação do mesmo a um determinado objeto presente na imagem. Busca-se uma generalização da classificação binária (segmentação), permitindo que um mesmo *voxel* tenha diferentes graus de pertinência em relação a vários objetos. A teoria dos conjuntos nebulosos (Bezdek, 1992; Boudraa, 1993) propicia uma base adequada para esta classificação. Para um dado conjunto X , define-se um subconjunto nebuloso (*fuzzy set*) A de X por um conjunto de pares ordenados (Udupa, 1995),

$$A = \{(x, f_A(x)) \mid x \in X\}$$

onde $f_A : X \rightarrow [0, 1]$ representa a função de associação de A .

Estamos propondo que a função de associação do *fuzzy set* seja baseada na probabilidade condicional do *voxel* pertencer à classe do objeto.

No caso de múltiplas imagens (M), cada *voxel* do objeto é caracterizado por um vetor de M elementos, associando-se, portanto, um vetor de atributos a cada *voxel*. Supondo que o vetor de atributos de cada classe de objetos tem distribuição normal multivariada, e adotando-se também que parte do objeto seja conhecida (por exemplo, parte da região delimitada pelo usuário), torna-se possível estimar as características estatísticas de cada classe de objetos. Qualquer classificador de *voxels* é naturalmente dependente da caracterização dos objetos. A possibilidade de treinar (estimar características dos objetos de interesse) o classificador para cada objeto é uma opção interessante pois os atributos são afetados por diversos fatores tais como equipamento (modalidade, calibração, escala ect.), órgão, resolução, ruído, e até mesmo a variabilidade natural entre pacientes.

Reformulando o problema: dado um conjunto de M imagens n -dimensionais contendo um ou mais (J) objetos, classificar cada elemento do espaço n -dimensional em função da sua associação a cada objeto definido na fase de treinamento.

Hipóteses adotadas

- Possibilidade de treinar o classificador através de uma amostra do objeto com características aproximadamente homogêneas. A Figura 1 ilustra este procedimento para imagens 3D: o usuário delinea, por exemplo, através de um *mouse*, uma região do objeto de interesse em um dos cortes da imagem tridimensional. Havendo número suficiente de *voxels*, torna-se possível estimar os parâmetros do *cluster* que caracteriza todo o objeto em questão.
- Os parâmetros estimados, através de um corte (treinamento), são válidos para todo o objeto, incluindo a terceira dimensão espacial e o tempo se for o caso;

Cálculo da função de associação

Seja $x \in R^M$ um vetor de atributos correspondente a um elemento (*voxel*) do volume ($n=3$) proveniente das M imagens disponíveis.

Dada a região de treinamento de um objeto j ($j=1, J$), podem-se estimar alguns parâmetros estatísticos (Johnson, 1992), tais como o vetor médio (\bar{x}_j) e a matriz de covariância (S_j) amostral do aglomerado (*cluster*) do objeto j . Para o subconjunto nebuloso j pode-se definir a função de associação do elemento x à classe do objeto j por:

$$f_j: R^M \rightarrow [0,1]$$

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

$$d_j^2(x) = (x - \bar{x}_j)^T \cdot S_j^{-1} \cdot (x - \bar{x}_j) \quad (2)$$

\bar{x}_j : vetor médio da classe j

onde $d_j(x)$ corresponde à distância estatística, também conhecida por distância de Mahalanobis (Johnson, 1992), a qual é normalizada em relação à estrutura da covariância. Esta distância é escalar e remove os possíveis efeitos da dependência (correlação) entre atributos, assim como da dispersão dos *clusters*. Se o vetor de atributos de um elemento estiver próximo do centro de um *cluster* j , então o valor da função será próximo de 1,0. Por outro lado, se a distância for 1,96 (limite do intervalo de confiança de 95 % para distribuição normal), o valor da função decresce para 0,146.

É de se esperar que a função (1) dê bons resultados, pois a mesma está relacionada com a probabilidade condicional (verossimilhança) do elemento x pertencer a uma classe j em uma distribuição normal multivariada. De fato, a função de densidade de probabilidade de uma distribuição normal multivariada é dada por (Johnson, 1992):

$$p_j(x) = \frac{1}{(2\pi)^{\frac{M}{2}} \cdot |Cov_j(X)|^{\frac{1}{2}}} \cdot \exp\left(-\frac{1}{2} \cdot (x - \mu_j)^T \cdot Cov_j^{-1}(X) \cdot (x - \mu_j)\right) \quad (3)$$

onde μ_j e $Cov_j(X)$ correspondem, respectivamente, ao vetor médio e à matriz de covariância da população j . Como, em geral, não se dispõem de informações necessárias para o cálculo da matriz de covariância para cada objeto j , $Cov_j(X)$, utiliza-se uma estimativa (amostral) da mesma denotada por S_j .

A hipótese de distribuição normal multivariada é bastante aceitável pois as estruturas procuradas, em geral, têm atributos aproximadamente homogêneos.

O algoritmo, para um dado objeto de interesse, consiste portanto em:

1. Estimar os parâmetros estatísticos (média e covariância) do *cluster* correspondente ao objeto através dos *voxels* de uma região fornecida pelo usuário;
2. Calcular a matriz de covariância inversa (S_j^{-1});
3. Para cada *voxel*, calcular a distância estatística e a função de associação a cada objeto j ;

Esta técnica pode ser empregada em imagens simples, assim como em imagens múltiplas (múltiplas imagens de um mesmo objeto, como as imagens multi-espectrais), e em imagens 3D ou de maior dimensão.

Implementação

Considerando a possibilidade da matriz de covariância (S_j) ser singular (sistema mal condicionado devido à dependência entre as M imagens), a melhor abordagem para o cálculo da associação (1) é obter um conjunto de imagens linearmente independentes (ortogonais) a partir das M imagens dadas, e utilizar apenas as r -componentes principais ($r \leq M$) que efetivamente contribuem com informação independente e relevante. Em outras palavras, utilizaremos um outro conjunto de eixos, ortogonais, dado por (Fukunaga, 1992):

$$y = L^T \cdot x \quad (4)$$

onde $y \in \mathbf{R}^r$, $L = (e_1, e_2, \dots, e_r)$ e e_i é o i -ésimo autovetor da $Cov(X)$, com r autovalores maiores do que um determinado limiar. O limiar utilizado nos experimentos foi de 1% da soma de todos os autovalores. Os autovetores (matriz L) e autovalores λ_i são obtidos resolvendo-se a Equação $Cov(X) \cdot e_i = \lambda_i \cdot e_i$. A matriz diagonal $Cov(Y)$ é formada pelos elementos λ_i . Portanto, a matriz inversa correspondente $Cov^{-1}(Y)$ é:

$$\left[Cov^{-1}(Y) \right]_i = \frac{1}{\lambda_i} \quad (5)$$

Desconsiderando os erros de aproximação e de truncagem ($r \leq M$), a distância é equivalente, pois ocorreu apenas uma rotação. A distância pode ser calculada por:

$$d^2(y) = (y - \bar{y})^T \cdot Cov^{-1}(Y) \cdot (y - \bar{y}) \quad (6)$$

onde \bar{y} : vetor médio

No entanto, pode-se evitar o cálculo explícito das r componentes principais, considerando-se as Equações (4) e (6):

$$d^2(y) = (x - \bar{x})^T \cdot L \cdot Cov^{-1}(Y) \cdot L^T \cdot (x - \bar{x}) \quad (7)$$

Portanto, uma vez estimada a $Cov(X)$ na fase de treinamento, pode-se obter $L \cdot Cov^{-1}(Y) \cdot L^T$ e então aplicar as Equações (7) e (1) para cada elemento. O treinamento consiste apenas na estimativa da matriz de covariância, utilizando-se a amostra fornecida pelo usuário.

Chegaríamos ao mesmo resultado da Equação (7) se aplicássemos o conceito de pseudo-inversa (Fukunaga, 1992) na Equação (2).

Dessa forma, para J objetos definidos, podem-se obter os J subconjuntos nebulosos, i.é., calcular o grau de associação de cada *voxel* a cada um dos objetos. A partir desta etapa, pode-se então classificar cada *voxel* na forma tradicional, associando o *voxel* à classe com o maior valor da

função de associação, ou manipular os *voxels* considerando a informação nebulosa. Nesta última abordagem, o *voxel* seria visualizado, por exemplo, com intensidade proporcional a sua pertinência à classe, podendo, dessa maneira, mostrar melhor a fronteira entre diferentes estruturas.

As vantagens esperadas desta implementação são:

- Pequena necessidade de interação (apenas na fase de treinamento) com delineamento de amostra do objeto em um único corte 2D da imagem n-dimensional;
- Treinamento específico do classificador para cada objeto, considerando-se o conjunto de imagens disponíveis;
- Possibilidade de utilizar informações adicionais provenientes de outras imagens adquiridas e derivadas (texturas), considerando inclusive conectividade e morfologia;
- Possibilidade de automaticamente remover as dependências (imagens redundantes) e de trabalhar com graus de pertinência em contraste à classificação binária;
- Possibilidade de atribuir pesos à separabilidade entre parâmetros;

A classificação obtida no estágio acima descrito apresenta dois problemas fundamentais:

- a) Como o processo de *clustering* é uma abordagem intrinsecamente pontual, *voxels* desconectados, porém com vetores próximos ao centro do *cluster*, podem ser classificados como pertencentes ao objeto (falsos positivos);
- b) Parte dos *voxels* pertencentes ao objeto podem não ser classificados (falsos negativos) devido a ruído, volume parcial, ou sobreposição com outros objetos. Por exemplo, em MRI, na segmentação da cavidade cardíaca, estruturas diferentes (músculos papilares, Figura 3.1) presentes na cavidade alteram o contorno da segmentação em diversos cortes e regiões, deixando lacunas na segmentação.

Uma forma de minimizar estes efeitos é incluir informações *a priori* ao resultado do estágio da segmentação por *clustering*. Outra forma é adicionar às M imagens, simultaneamente, novas imagens que reflitam texturas e informações *a priori* sobre os objetos, tais como conectividade e morfologia, e então aplicar a técnica proposta. Estas imagens geradas numericamente a partir das imagens originais e aquelas geradas a partir das informações *a priori* serão denominadas, genericamente, por "texturas".

Texturas

Neste trabalho estão sendo incluídas duas medidas de textura, além da imagem que representa o módulo do gradiente para cada *voxel*. A primeira contém informação aproximada da posição do objeto de interesse, através de uma função do tipo gaussiana, localizada no centro da região de treinamento delineado pelo usuário, e com desvio padrão selecionável (Figura 3.3). A segunda textura (faixa dinâmica) visa medir a variabilidade associada a cada *voxel* ao longo do tempo, procurando ressaltar os *voxels* com maior atividade dinâmica, como é o caso dos *voxels* do VE e do VD (Figura 3.4). A faixa dinâmica para um dado *voxel* é calculada simplesmente pela diferença entre o máximo e o mínimo associado a este *voxel* ao longo do tempo.

Avaliação

A avaliação pode ser feita usando-se a região de treinamento de cada objeto (Johnson,1992), supondo-se que todos os elementos pertençam a esta classe, e utilizando-se o parâmetro *correct classification rate* (Wu, 1992):

$$CR = \sum_j \frac{c_j}{T_j} \quad (8)$$

onde c_j , ($j=1, J$) representa o número de elementos classificados corretamente como objeto j (considerando-se, para efeito de avaliação, classificação correta aquele com o maior valor da função de associação), e T_j representa o número de elementos considerados para a classe j .

Em uma avaliação mais completa e precisa, torna-se necessário utilizar *phantoms* numéricos e/ou observadores humanos.

RESULTADOS

A presente proposta foi implementada (linguagem C) e testada dentro do ambiente 3DVIEWNIX (Udupa, 1994), o qual é um sistema geral e aberto para processamento de imagens médicas n-dimensionais em plataformas Unix (X-window). Os resultados obtidos são exemplificados a partir do estudo de um caso 3D dinâmico, proveniente do exame de Ressonância Magnética *gated MRI* cardíaco, contendo 12 volumes (fases do ciclo cardíaco), cada volume com 12 cortes, e cada corte com 103 x 101 *pixels*.

A Figura 1 mostra a tela de interação com o usuário. Na parte esquerda da janela são mostradas duas imagens (cortes) quaisquer das M imagens n-dimensionais. Neste exemplo específico, estamos considerando duas (multiplicidade $M=2$) imagens 3D dinâmicas (dimensionalidade $n=4$) provenientes de *gated MRI* da mesma estrutura (cavidades cardíacas), subdividido em 12 fases do ciclo cardíaco. Cada imagem 3D é composta de 12 cortes (espessura de 7 mm), sendo que cada corte é representado pela matriz de 103 x 101 *pixels* (1,64 x 1,64 mm). A primeira seqüência de imagens 3D representa a imagem original filtrada por um filtro do tipo gaussiano 3D com valor correspondente ao desvio padrão de 1,5 *pixels* na resposta impulsiva do filtro. A segunda seqüência representa o módulo da amplitude do gradiente 3D da imagem filtrada. A Figura 1 ilustra o mesmo corte nas 2 imagens em uma determinada fase do ciclo cardíaco, e o programa permite visualizar qualquer corte de qualquer imagem. Uma vez escolhido o corte que contém parte do objeto de interesse, o usuário pode então delimitar (região sombreada retangular) na figura superior esquerda uma região do objeto (através do *mouse*) no corte para que o sistema possa estimar as características estatísticas do *cluster*. Uma projeção 2D da distribuição (histograma M -dimensional) é mostrada no centro da tela, para quaisquer dois atributos. Baseado nesta distribuição, o sistema calcula a função de associação para esta classe. O programa permite definir e treinar até 8 classes. O resultado da classificação é mostrado no lado direito da tela, normalizado na faixa entre 0 e 255. Percebe-se que grande parte do VE foi identificada, assim como parte do VD pelo fato dos mesmos apresentarem atributos semelhantes.

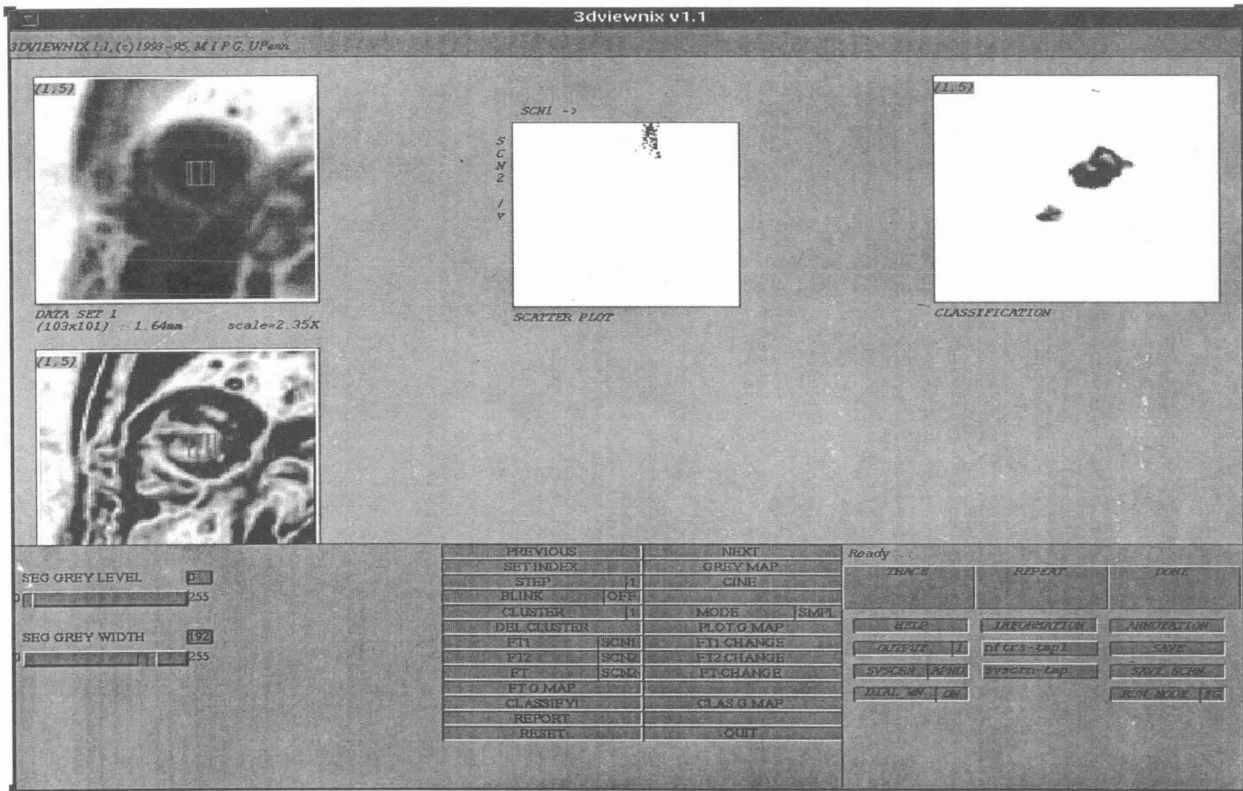


Figura 1. Exemplo da classificação (janela superior direita) do Ventrículo Esquerdo, mostrando apenas 1 corte. A classificação é realizada automaticamente em todo o espaço *voxel*. As duas janelas à esquerda mostram cortes de 2 imagens 3D dinâmicas utilizadas (imagem levemente suavizada e módulo do gradiente 3D). A janela do centro representa o histograma 2D dos *voxels* na região de treinamento.

Nota-se também, como mencionado anteriormente, a presença de falsos negativos (lacunas) no VE, e alguns falsos positivos isolados na imagem. Os falsos positivos podem ser removidos parcialmente considerando-se um conjunto maior de atributos. Os falsos negativos na classificação se devem ao fato da segunda hipótese não ser plenamente atendida, ou seja, o VE não é suficientemente homogêneo (grande variabilidade no valor de pertinência) em relação aos atributos.

A Figura 2 mostra os resultados para $M = 4$, onde foram incluídas a informação da posição geométrica do objeto (Figura 3.3) através da distribuição gaussiana, e a informação de atividade temporal de cada *voxel* (Figura 3.4). Percebe-se neste caso, que a classificação do VE foi mais específica em relação a $M = 2$, devido à inclusão de atributos adicionais.




Figura 2. Resultado da classificação do VE para o mesmo corte da figura 1, usando $M = 4$ atributos mostrados na Figura 3.

A Figura 3 mostra os ($M = 4$) atributos utilizados na classificação da Figura 2: a) imagem filtrada; b) gradiente; c) informação de posição, e d) informação dinâmica. As duas primeiras foram obtidas da mesma forma descrita anteriormente para a Figura 1. As duas últimas foram calculadas conforme descritas na secção texturas.

CONCLUSÃO E DISCUSSÃO

A abordagem proposta é rápida envolvendo apenas operações simples, permitindo utilizar eficientemente as informações contidas nas múltiplas imagens, porém apresenta, em casos complexos, os problemas típicos da segmentação baseada em atributos, qual seja, falsos positivos isolados, e falhas em alguns *voxels*, uma vez que esta técnica usa apenas informações locais. No entanto, a classificação pode ser significativamente melhorada, incluindo-se informações *a priori* sobre o objeto tais como posição, contexto, morfologia e conectividade. A pesquisa por atributos e texturas mais adequadas é uma área de intensa investigação (Lobregt, 1995) em diversos grupos.

A presente técnica permite a segmentação em duas fases: a) pré-classificação rápida dos *voxels* baseada nos atributos, e b) refinamento da segmentação usando técnicas recentes como *Simulated Annealing*, operações morfológicas, modelos volumétricos deformáveis (Ashton, 1995; Malladi, 1995). Estamos atualmente investigando a incorporação da informação de conectividade e morfologia, além de refinamentos de pós-processamento. O sistema apresentado possibilita a inclusão de inúmeros atributos, facilitando a pesquisa nesta área. Pretendemos também, no futuro, aplicar esta abordagem em imagens de outras modalidades como as imagens de Medicina Nuclear, Ultra-som e raio-X.




Figura 3. Atributos utilizados na classificação da Figura 2: 1) imagem levemente suavizada (filtro gaussiano 3D); 2) módulo do gradiente 3D; 3) informação de posição do VE; 4) textura correspondente à variação dinâmica dos *voxels*.

Mais esforço também deve ser dedicado à avaliação objetiva e automática da classificação binária e *fuzzy* em imagens *n*-dimensionais, tentando remover o caráter subjetivo e extremamente trabalhoso das avaliações dos algoritmos nesta área.

AGRADECIMENTOS

Agradecemos à FAPESP (processo 92-0310-1), ao CNPq (460319/95.7) e à Fundação E. J. Zerbini pelo apoio recebido para a realização deste trabalho.

REFERÊNCIAS

- ASHTON, E. A., PARKER, K. J., BERG, M. J. and CHEN, C. W. (1995). "A novel volumetric feature extraction technique, with applications to MR images", *Proceedings of the International Conference on Image Processing*, Washington DC: IEEE Press, p. 564-567.
- BEZDEK, J. C. and PAL, S. K. (1992). *Fuzzy models for pattern recognition*, N. York: IEEE Press.

- BOUDRAA, A. E. O., MALLET, J. J., BESSON, J. E., BOUYOUCHEF, S. E. and CHAMPIER, J. (1993). "Left ventricle automated detection method in gated isotopic ventriculography using fuzzy clustering", *IEEE Transactions on Medical Imaging*, v. 12, n. 3, p. 451-465, Sep.
- BRUMMER, M. E., MERSEREAU, R. M., EISNER, R. L. and LEWINE, R. R. J. (1993). "Automatic detection of brain contours in MRI data sets", *IEEE Transactions on Medical Imaging*, v. 12, n. 2, p. 153-166, June.
- COLLINS, D. L., PETERS, T. M. and 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, p. 105-109.
- FUKUNAGA, K. (1992). *Introduction to Statistical Pattern Recognition*, London: Academic Press, 2nd edition.
- GUSTAFSON, D. E. and KESSEL, W. C. (1979). "Fuzzy clustering with a fuzzy covariance matrix", *Proc. IEEE CDC*, San Diego, CA, p. 761-766, January 10-12.
- JOHNSON, R. A. and WICHERN, D. W. (1992). *Applied Multivariate Statistical Analysis*, Englewood Cliffs: Prentice Hall, Third Edition.
- JOLIOT, M. and MAZOYER, B. M. (1993). "Three-dimensional segmentation and interpolation of magnetic resonance brain images", *IEEE Transactions on Medical Imaging*, v. 12, n. 2, p. 269-277, June.
- LOBREGT, S. and VIERGEVER, M. A. (1995). "A discrete dynamic contour model", *IEEE Transactions on Medical Imaging*, v. 14, n. 1, p.12-24, March.
- MALLADI, R., SETHIAN, J. A. and VEMURI, B. C. (1995). "Shape modeling with front propagation: a level set approach", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 17, n. 2, p. 158-175, Feb.
- UDUPA, J.K. and HERMAN, G.T. (1991). *3D Imaging in Medicine*, Boca Raton: CRC Press.
- UDUPA, J. K., ODHNER, D., SAMARASEKERA, S., GONCALVES, R., IYER, K., VENUGOPAL, K. and FURUIE, S., (1994). "3DVVIEWNIX: an open, transportable, multidimensional, multimodality, multiparametric imaging software system", *SPIE*, v. 2164, p. 58-73.
- UDUPA, J. K. and SAMARASEKERA, S. (1995). "Fuzzy Connectedness and object definition, Proceedings of the Medical Imaging", *Society of Photo-Optical Instrumentation Engineers*, San Diego, v. 2431, p. 2-11 e 26-28. Feb.
- WU, C., CHEN, Y. and HSIEH, K. (1992). "Texture features for classification of ultrasonic liver images", *IEEE Transactions on Medical Imaging*, v. 11, n. 2, p. 141-152, June.
- XUAN, J., ADALI, T. and WANG, Y. (1995). "Segmentation of Magnetic Resonance brain image: integrating region growing and edge detection", *Proceedings of the International Conference on Image Processing*, Washington: IEEE Press, p. 544-547.

3D MEDICAL IMAGE CLASSIFICATION BASED ON FUZZY CLUSTERINGS. S. Furuie¹, L. A. Moura², J. K. Udupa³

ABSTRACT -- This work presents a technique for classifying elements in 3D medical images based on fuzzy clustering of feature vectors. This approach is fast and allows efficient use of all available (multiple) images of an object. Each object is statistically characterized by an estimated cluster derived from a sample of the object. The membership function is calculated using the likelihood of the feature vector in relation to the object cluster. Some additional textures are presented for the classification of cardiac left ventricle in gated 3D MRI images, one conveying approximated object position information and the other representing dynamic variability of each voxel. The results present, for complex cases, the typical problems of segmentation based on features, such as false positives and false negatives since this technique uses only local information. However the classification can be significantly improved via post processing refinement, or including more *a priori* information about the object such as context, morphology and connectivity.

Key-words: Classification, Segmentation, Clusters, Likelihood, Texture

¹ Divisão de Informática-Instituto do Coração, Av.Dr. Enéas de Carvalho Aguiar, 44, 05403-000 São Paulo - SP, e-mail: furuie@incor.usp.br

² Superintendência do Hospital das Clínicas, R. Ovídio Pires Campos, 255, 05403-010, São Paulo - SP, e-mail: lincoln@incor.usp.br

³ Medical Image Processing Group, University of Pennsylvania, Philadelphia PA 19104-6021, USA, e-mail: jay@mipg.upenn.edu