

USO DE REDES NEURAIS PARA A DETECÇÃO AUTOMÁTICA DO CONTORNO DO VENTRÍCULO ESQUERDO EM IMAGENS DE MEDICINA NUCLEAR

C. Costa¹ e L. Moura²

RESUMO -- Neste trabalho apresentamos um método que faz uso de uma rede neural e informação geométrica para a detecção automática do contorno do ventrículo esquerdo (VE) em imagens de medicina nuclear. Embora o método tenha sido desenvolvido para detecção de contornos de VE, ele pode ser estendido a outras classes de estruturas e imagens. O aprendizado é feito alimentando-se o sistema com uma série de imagens e seus correspondentes contornos de VE traçados por um operador. O sistema extrai tanto informações geométricas como informações de vizinhança, que são utilizadas para treinar a rede neural. Uma vez treinada, a rede é capaz de automaticamente detectar o contorno do VE. São apresentados detalhes da operação e performance da rede neural, cujo desempenho é avaliado através de duas medidas de erro. Um importante detalhe do método é a detecção automática do centro do VE, cuja exatidão tem uma grande influência na minimização dos erros. Ao lado de apresentar erros que são compatíveis com os erros de outros métodos automáticos, o método presente tem a clara vantagem de armazenar informações geométricas e de intensidade de *pixel* que são aprendidas através de exemplos.

Palavras-chave: Rede Neural, Detecção Automática de Contorno, Ventrículo Esquerdo.

INTRODUÇÃO

No processamento de imagens médicas, um problema central é a identificação de órgãos e estruturas. Esta é uma etapa importante em muitas aplicações onde o objetivo é quantificar ou estimar parâmetros clínicos tais como fração de ejeção, volume cardíaco, áreas e distâncias, e também para avaliação do movimento do ventrículo esquerdo (VE) (Toscano, 1992). Embora o processo de segmentação da imagem possa ser feito manualmente, o mesmo é usualmente trabalhoso e requer sempre um técnico experiente para realizar esta tarefa. Assim, muitos esforços têm sido envidados no sentido de automatizar a etapa de segmentação de estruturas médicas (Friedland *et alia*, 1989; Bae *et alii*, 1993).

Os métodos e algoritmos utilizados na segmentação automática de estruturas médicas utilizam uma série de técnicas que vão desde a procura em grafos (Thedens *et alia*, 1995) a funções

¹Professor Assistente da Universidade do Amazonas, Aluno de Doutorado do Departamento de Engenharia Biomédica da Unicamp, e-mail: mccosta@dglnet.com.br.

²Pesquisador do Instituto do Coração do Hospital das Clínicas da Universidade de São Paulo, e-mail: lincoln@incor.br.

probabilísticas (Dias et alii, 1996). A grande maioria dos métodos automáticos são feitos sob medida para uma dada aplicação (Moura et alia, 1992), de tal forma que é praticamente impossível estender o seu uso para outras classes de imagens, mesmo que a estrutura a ser segmentada seja a mesma. Os métodos com melhor desempenho na segmentação de contornos de órgãos embutem um conhecimento “à priori” que é explicitamente declarado pelo projetista do algoritmo (Lilly et alii, 1989; Moura et alia, 1992).

Rede Neural é uma ferramenta que tem se mostrado bastante promissora tanto no reconhecimento de anormalidades em imagens (Floyd et alia, 1992) como na segmentação de estruturas em imagens médicas (Hall et alii, 1992). A grande característica das redes neurais é a capacidade de aprender através de exemplos. No entanto, essas aplicações usualmente levam em conta apenas informações derivadas do valor do *pixel*, tais como medidas locais de descontinuidade (magnitude do gradiente e Laplaciano) e intensidade de *pixel* (Moura et alia, 1992). Além disso, ignoram a relação espacial entre os mesmos, tratando as imagens como listas de *pixels*.

Em trabalho anterior (Costa et alia, 1995), apresentamos um método automático para detecção do contorno do VE no qual informações referentes a intensidade do *pixel* e informações geométricas eram fornecidas a uma rede neural. Após o treinamento, a rede neural armazenava um protótipo do contorno do VE. Partindo da informação do centro do VE, a rede detectava o contorno do mesmo. Embora o método tenha sido desenvolvido para a detecção do contorno do VE em imagens de *blood pool*, uma de suas principais características é a facilidade de adaptação a outras classes de imagens. No trabalho atual introduzimos uma nova técnica de detecção do centro do VE; aprofundamos a análise da operação da rede, incluindo gráficos da variação do erro de convergência em função do número de iterações no treinamento e valores para o tempo de treinamento em função das diferentes regiões do ventrículo esquerdo; apresentamos também resultados da sensibilidade do método de detecção do contorno do VE em relação à variação da posição do centro e discutimos com mais detalhes as medidas de erro e os resultados apresentados.

AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS

As imagens de *blood-pool* foram obtidas de 60 pacientes homens utilizando uma Gamma Câmara Siemens, no Instituto do Coração do Hospital das Clínicas da Universidade de São Paulo. Cada paciente recebeu uma dose de 1mg de Pirofosfato de Estanho seguida, 30 minutos depois, por uma aplicação intravenosa no braço de 740 Mbq ^{99m}Tc-Sestamibi. As imagens foram adquiridas 1 minuto após a injeção, com uma resolução espacial de 64x64 *pixels* e com uma profundidade de 16 bits. A aquisição foi sincronizada com o eletrocardiograma resultando em 32 imagens por ciclo cardíaco. Apenas a primeira imagem de cada série - a imagem que corresponde a diástole - foi considerada neste trabalho. Após a aquisição, as imagens foram ampliadas para 256x256 *pixels*, através de interpolação bilinear (Gonzalez et alia, 1987). Embora a interpolação não aumente a quantidade de informação, ela reduz o tamanho do *pixel*, aumentando a resolução quando se determina o contorno do VE. Foi realizado um estiramento do histograma consistindo de estirar 99% do histograma da imagem não processada a fim de se adequar a toda a faixa, como proposto por Moura et alia (1992).

DESCRIÇÃO DO CONTORNO DO VE

Presume-se neste trabalho que o o contorno do VE pertença a uma classe geral de contornos que podem ser representados pela coordenada de seu centro e por uma série de raios $R(\theta)$, onde θ é o ângulo entre um dado raio e o eixo-x, como ilustrado pela Figura 1. Um contorno que pode ser representado desta maneira foi chamado de contorno- θ (Moura *et alia*, 1987). A única restrição a este tipo de contorno é que para um dado θ exista apenas um $R(\theta)$. Não necessariamente o contorno- θ tem que ser convexo, porém não pode ter dobras que interceptem um raio.

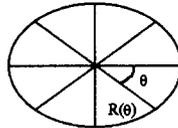


Figura 1: Representação esquemática de um contorno- θ .

DETECÇÃO AUTOMÁTICA DO CENTRO

As 60 imagens de *blood-pool* foram divididas nos grupos 1 e 2, com 20 e 40 imagens, respectivamente. As imagens do grupo 1 foram utilizadas tanto para o treinamento como para o teste do sistema, enquanto que as imagens do grupo 2 foram utilizadas apenas para o teste do sistema. Para todas as 60 imagens, o contorno do VE e os centros de ambos os ventrículos foram extraídos manualmente por um técnico experiente em medicina nuclear com o propósito de servirem como padrão ouro.

A partir das coordenadas dos centros do VE e do ventrículo direito (VD) extraídas manualmente foram calculados os centros médios de ambos os ventrículos. A mediatriz do segmento de reta que une estes dois centros médios foi utilizada como um divisor inicial entre os *pixels* pertencentes aos ventrículos esquerdo e direito. O centróide dos *pixels* situados à esquerda desta mediatriz com intensidades maiores que um determinado limiar fornece-nos uma primeira estimativa para o centro do VE. Na Figura 2b mostramos a mediatriz referente a imagem da Figura 2a, os *pixels* com intensidade maior que o limiar de 200 e o centro do VE obtido através deste procedimento.

Esta primeira estimativa para o centro do VE é então refinada. Utilizando os contornos traçados manualmente, obtivemos, para as 60 imagens de *blood-pool*, a intensidade média dos *pixels* de borda localizados nas extremidades esquerda, inferior e superior do VE, correspondentes as coordenadas do centro. *Pixels* com essas intensidades são designados, respectivamente como 1, 2 e 4 na Figura 2d. Um quarto *pixel* auxiliar para o refinamento, situado no lado direito do VE, é obtido a seguir. Inicialmente determinamos um segmento de reta que passa pelo centro estimado do VE e que termina em *pixels* cujas intensidades são iguais a intensidade do *pixel* 1. Este segmento de reta é mostrado na Figura 2c. Num segundo instante obtém-se o histograma médio das intensidades dos *pixels* situados sobre este segmento e sobre outros 5 segmentos adjacentes situados à cima e à baixo. Na Figura 2e é mostrado este histograma. Para as 60 imagens estudadas, observamos que o ponto de inflexão mínimo do histograma situa-se na região do septo. Este ponto é designado como 3

na Figura 2d. O valor refinado da coordenada x do centro é obtido através de uma média das coordenadas x dos pontos 1 e 3, enquanto que o valor refinado da coordenada y do centro é obtido através de uma média das coordenadas y dos pontos 2 e 4. Na Figura 2d mostramos a localização do centro refinado e os pontos utilizados na sua determinação.

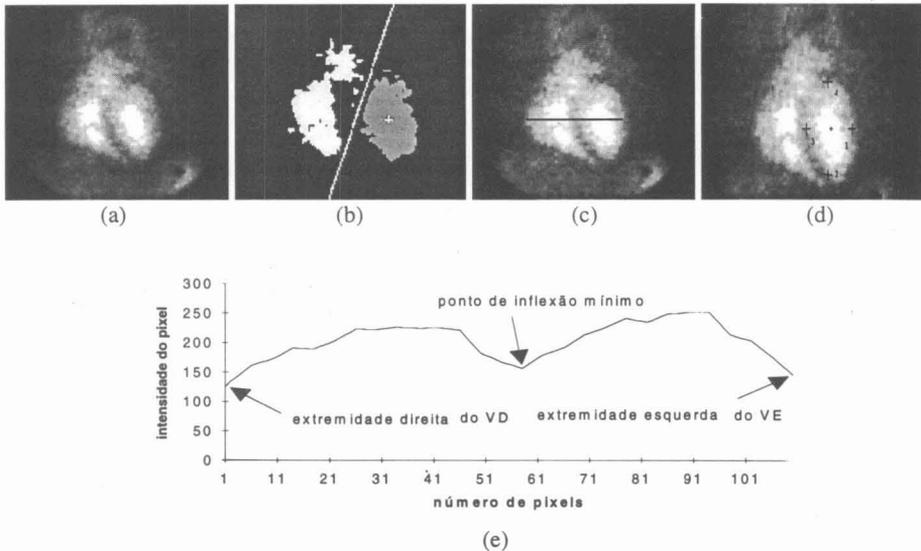


Figura 2: (a) imagem inicial; (b) mediatriz e *pixels* com intensidade superior a um limiar de 200; (c) segmento de reta passando pelo centro do VE ; (d) centro refinado e pontos auxiliares usados no seu cálculo; (e) histograma médio dos pontos localizados sobre o segmento de reta do item 'c' e de segmentos adjacentes acima e abaixo.

Na Tabela 1 mostramos valores de erros percentuais médios obtidos para as 60 imagens de *blood-pool*. O erro $E_x(E_y)$ corresponde ao erro percentual médio obtido pela razão entre a diferença das coordenadas x(y) do centro obtido automaticamente e do centro obtido manualmente pelo raio do ventrículo, definido como a distância entre o centro do mesmo e sua borda esquerda.

ARQUITETURA E TREINAMENTO DA REDE NEURAL

A rede neural utilizada é uma rede de três camadas, *feedforward*, tipo *Perceptron*, cuja arquitetura é mostrada na Figura 3. A rede testada apresenta 20 nós na camada intermediária e 1 nó de saída. Neste trabalho testamos uma rede com três nós de entrada e outra com quatro nós de entrada.

Para cada imagem do conjunto de treinamento traça-se, a partir do centro do VE, uma série de 64 raios igualmente espaçados. Cada raio define o que chamamos de "orientação". Cada orientação é definida por seu ângulo θ e é associada a uma rede neural.

Tabela 1: Erros no processo de determinação do centro

	Ex		Ey	
	média	desvio padrão	média	desvio padrão
antes do refinamento	9,14	7,92	11,67	10,14
depois do refinamento	5,70	4,85	6,69	5,90

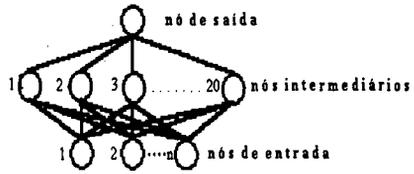


Figura 3: arquitetura da rede neural

Durante o treinamento são apresentados, para cada orientação, dois *pixels* que não pertencem ao contorno. Um reside no interior do contorno e o outro fora do contorno. Adicionalmente, um terceiro *pixel*, desta vez sobre o contorno, é também apresentado a rede. As variáveis de entrada da rede são parâmetros extraídos destes *pixels*. Inicialmente foram escolhidas as seguintes variáveis: 1. distância do *pixel* ao centro do VE; 2. intensidade do *pixel*; 3. derivada ao longo da orientação; 4. magnitude do gradiente.

Dois parâmetros importantes no treinamento são as distâncias dos *pixels* internos e externos em relação ao centro do VE. Neste trabalho essas distâncias são normalizadas em função da distância do *pixel* de contorno em relação ao centro do VE. Na Figura 4a mostramos, para o conjunto de imagens de treinamento, a distribuição da variável 1 para distâncias dos *pixels* internos iguais a 0,8 e para distâncias dos *pixels* externos iguais a 1,2. Neste gráfico, para os *pixels* interno, externo e de contorno de uma orientação, são apresentados três valores: valor médio do *pixel* e valor médio do *pixel* ± 1 desvio padrão. Na Figura 4b as distâncias dos *pixels* internos e externos são, respectivamente 0,7 e 1,3. As quatro regiões em que os gráficos da Figura 4 estão divididos são mostradas na Figura 5. A região 1 corresponde a um ângulo de $\pm 45^\circ$; a região 2 corresponde a um ângulo na faixa entre 45° e 135° ; a região 3 corresponde a um ângulo na faixa entre 135° e 225° e a

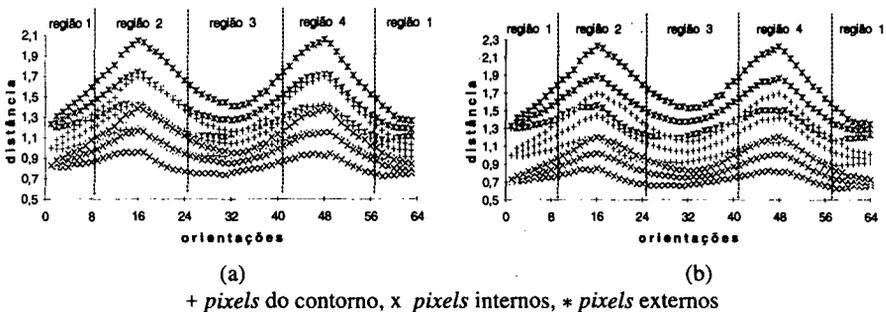


Figura 4: (a) gráfico da distância normalizada para distâncias de 0,8 (pixels internos) 1,0 (pixels do contorno) e 1,2 (pixels externos) vezes a distância do pixel de contorno. Para cada orientação e para cada distância são plotados três pontos: valor médio e valor médio ± 1 desvio padrão. (b) similar ao item (a) para distâncias de 0,7, 1,0 e 1,3.

região 4 corresponde a um ângulo entre 225° e 15°. Como observamos na Figura 4, as curvas correspondentes às regiões 1 e 3 encontram-se mais separadas que as curvas correspondentes às regiões 2 e 4. Observamos também que as curvas estão mais separadas na Figura 4b do que na Figura 4a. No treinamento, escolhemos as distâncias dos *pixels* internos e externos de 0,7 e 1,3, respectivamente. Ao utilizarmos as distâncias de 0,8 e 1,2, a rede não convergia em muitas orientações. Acreditamos que isso seja devido à natureza *fuzzy* da borda do VE associada à falta de uma melhor separação das curvas acima mencionadas. Ao obtermos um gráfico semelhante para a variável 4, não observamos separação entre as curvas anteriormente citadas. Devido a isso, essa variável não foi utilizada no treinamento.

DESEMPENHO E CARACTERÍSTICAS DO TREINAMENTO

No treinamento utilizamos uma rede neural com três entradas: intensidade do *pixel*, distância do *pixel* ao centro do VE e derivada ao longo da orientação.

A saída da rede foi feita bipolar, de tal forma que *pixels* sobre o contorno forcem a saída da rede para +1, enquanto que *pixels* fora do contorno forcem a saída da rede para -1. A rede neural foi treinada utilizando-se o algoritmo de treinamento de retro-propagação (Rumelhart, 1986). Com o objetivo de evitar mínimos locais, as imagens foram apresentadas randomicamente à rede. Adotou-se também um algoritmo de aprendizado tipo *batch*. A atualização dos pesos é feita apenas após a apresentação das 20 imagens do grupo de treinamento. Com o objetivo de acelerar a convergência da rede, utilizou-se o método de adaptação global da taxa de aprendizado (Cichocki *et alia*, 1993). Neste método, a taxa de aprendizado η da rede é atualizada de acordo com a seguinte equação iterativa.

$$\eta^k = \begin{cases} a \cdot \eta^{(k-1)}, & \text{se } E(w^k) < E(w^{(k-1)}) \\ b \cdot \eta^{(k-1)}, & \text{se } E(w^k) \geq \alpha \cdot E(w^{(k-1)}) \\ \eta^{(k-1)}, & \text{caso contrário} \end{cases} \quad (1)$$

onde: k = iteração de ordem k e $E(w^k)$ = erro médio quadrático da saída da rede para as 20 imagens

No gráfico da Figura 6, mostramos a variação do erro médio quadrático para vários valores dos parâmetros a e b , para a orientação correspondente a 22,5°. O valor de α utilizado foi de 1,04 e o valor inicial de η de 0,0001. Em algumas orientações, um valor de a grande e um valor pequeno de b produziram instabilidade no treinamento, porém quando isto não ocorria este par de valores produzia uma convergência mais rápida, como pode ser visto na Figura 6. Objetivando minimizar o tempo do treinamento, adotamos a seguinte estratégia: em cada orientação começávamos o treinamento com um valor de a grande e um valor de b pequeno. Se o erro médio quadrático tornava-se menor do que 0,2 considerávamos o treinamento concluído. Caso a rede se tornasse instável, reiniciávamos os valores dos pesos, aumentávamos o valor de a , diminuíamos o valor de b , e refazíamos o treinamento naquela orientação. O tempo de treinamento variou muito em função da orientação. Na Tabela 3, mostramos o tempo médio em segundos e o número de ciclos por treinamento para cada uma das regiões mostradas na Figura 5. Esses tempos foram obtidos em um 486DX2, 66 MHz.

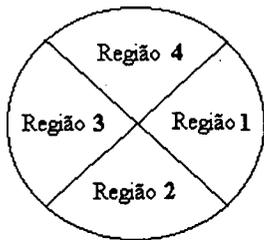


Figura 5: Regiões do ventrículo.

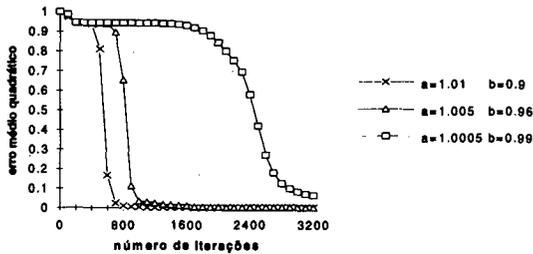


Figura 6: Variação do erro quadrático médio para um treinamento da rede (orientação de 22,5°).

USANDO A REDE NEURAL

A fim de serem submetidas a uma extração de contorno, as imagens de teste foram primeiramente pré-processadas e o centro do VE foi determinado como explicado anteriormente. As 64 orientações foram então calculadas. Num primeiro passo, foi determinado o raio do contorno para a orientação de 0°. Para esta orientação, a rede utilizada tem apenas duas variáveis de entrada: a intensidade do *pixel* e a derivada linear.

Na figura 7, mostramos uma saída típica da rede. Para todas as orientações, aqueles *pixels* que apresentavam uma saída maior do que 0,8 foram considerados *pixels* “candidatos” ao contorno. A escolha de um *pixel* de contorno foi então efetuada utilizando um entre os três critérios seguintes: 1) O *pixel* de contorno é o *pixel* para o qual a primeira derivada ao longo de uma orientação é máxima. 2) O *pixel* de contorno é dado pela média das coordenadas x e y de todos os *pixels* candidatos e 3) O *pixel* de contorno é dado pela média das coordenadas dos *pixels* obtidos através dos critérios 1 e 2. O desempenho desses critérios é apresentado posteriormente neste trabalho.

Tabela 3: Dados de treinamento

	Região			
	1	2	2	4
No. médio de ciclos por treinamento	4000	6000	3000	6000
Tempo médio de treinamento (s)	2	3	1,5	3

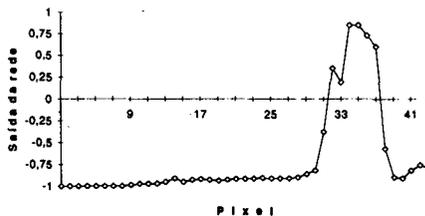


Figura 7: Saída da rede para a orientação de 22,5°.

RESTRIÇÕES GEOMÉTRICAS E FILTRAGEM

Utilizando os contornos traçados manualmente para as imagens do grupo 1, foi possível obter, para cada orientação, um raio médio e um desvio padrão. Com o objetivo de confinar a busca dos *pixels* de contorno a um intervalo que inclui 99% dos *pixels* prováveis, decidimos restringir a busca dos *pixels* de contorno a um segmento de reta definido pelo raio médio de uma dada orientação $\pm 3,0$ desvios padrões para esta orientação. Os 64 *pixels* de contorno obtidos definem um contorno- θ que é suavizado simplesmente usando o seguinte filtro móvel de médias para o raio:

$$R_k = (r_{k-2} + 2r_{k-1} + 4r_k + 2r_{k+1} + r_{k+2}) / 10 \quad \text{para } k = 0, 1, 2, \dots, N \quad (2)$$

onde: r_k = raio a ser suavizado, R_k = raio suavizado correspondendo ao contorno suavizado e $+N = 63$.

Uma vez que o contorno é circular, pode ser observado que $r_{-i} = r_{N+1-i}$ e $r_{N+i} = r_{i-1}$.

Na Figura 8 mostramos um exemplo da seqüência de procedimentos que resultam na detecção automática do contorno do VE. A Figura 8a mostra uma imagem amostrada com 16 das 64 orientações computadas. A Figura 8b mostra os *pixels* de contorno que foram detectados utilizando o critério #3. Na Figura 8c é possível ver o contorno do VE obtido através de uma filtragem dos *pixels* detectados e na Figura 8d vemos o contorno do VE após a suavização.

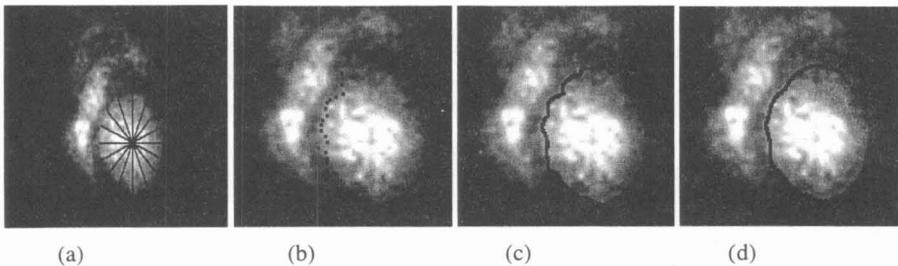


Figura 8: Um exemplo de detecção de contorno do VE. (a) imagem inicial com 16 raios sobrepostos; (b) contorno inicial detectado através do critério #3; (c) contorno após filtragem; (d) contorno após suavização.

RESULTADOS

Desempenho dos Critérios

Duas medidas de erro são usadas neste trabalho para avaliar o erro dos contornos automáticos:

$$erro_1 = \frac{|M| - |A|}{|M|} \cdot 100 \quad (3)$$

$$erro_2 = \left\{ \frac{|M \cap \bar{A}|}{|M|} + \frac{|\bar{M} \cap A|}{|M|} \right\} \cdot 100 \quad (4)$$

onde: M e \bar{M} = Conjunto de pixels dentro do contorno manual e seu complemento, A e \bar{A} = Conjunto de pixels dentro do contorno detectado automaticamente e $|M|$ e $|A|$ = áreas das superfícies de M e A , respectivamente.

A primeira dessas medidas considera apenas a diferença absoluta das áreas definidas pelos contornos manual e automático, enquanto que a segunda delas considera todas as regiões onde não houve superposição das áreas definidas por ambos os contornos. A segunda medida fornece uma melhor indicação da qualidade do método proposto.

A Tabela 4 mostra os erros medidos para as 60 imagens de *blood pool*, usando os três critérios definidos anteriormente. O critério #3 conduz aos melhores resultados. Os erros mostrados na tabela 4 são equivalentes aos obtidos por Friedland *et alia* (1989), em imagens de radiografia digital.

Sensibilidade do erro com a variação do centro

Para avaliarmos a influência da variação da posição do centro sobre o erro na detecção do contorno automático adotamos o seguinte procedimento. Escolhemos 4 imagens com valores baixos de *erro*, e determinamos o contorno através do critério #3. Deslocamos então a coordenada do centro na direção horizontal e vertical de ± 4 pixels e avaliamos o valor do *erro*. Os resultados são mostrados na Tabela 5.

Tabela 4: Erros médios para as imagens nos Grupos 1 e 2

	erro 1		erro 2	
	Grupo 1	Grupo 2	Grupo 1	Grupo 2
Critério #1	5,90	4,56	12,41	12,99
Critério #2	7,47	8,89	13,98	13,81
Critério #3	4,81	4,80	11,57	11,52

Tabela 5: Erros com a variação da posição do centro

Deslocamento em pixels	Erro Médio	
	Coordenada horizontal	Coordenada vertical
0	1,15	1,15
+1	2,58	1,53
+2	5,55	1,73
+3	9,22	2,87
+4	11,23	3,91

DISCUSSÃO E CONCLUSÕES

Em relação aos resultados apresentados na tabela 4 faremos os seguintes comentários:

- Os resultados são comparáveis aos valores obtidos por Lilly *et alia* (1989) para o erro percentual (entre 4% e 9%) e para o erro soma (entre 10% e 15%), ao trabalhar com imagens radiográficas do miocárdio.

- Os resultados apresentados para o Grupo 1, constituído por imagens de treinamento, mostram que a rede foi capaz de aprender através de exemplos.
- Os resultados apresentados para o Grupo 2, constituído por imagens de teste, são comparáveis àqueles obtidos para o Grupo 1, demonstrando que a rede foi capaz de generalizar o conteúdo aprendido através de exemplos.

A modelagem do VE como um contorno (θ) permitiu que inseríssemos variáveis geométricas na entrada da rede neural de uma maneira elegante e efetiva. O fato da vizinhança ao longo do contorno de um órgão diferir bastante de um ponto para outro, reflete a situação normalmente encontrada em imagens médicas e raramente levada em conta. O VE em imagens de *blood pool* é um excelente exemplo do que foi exposto. A linha que vai do centro do VE em direção ao lado direito da imagem encontra uma parede livre, caracterizada por um bom contraste, enquanto que a linha que vai do centro do VE em direção ao ventrículo direito, encontra o septo, marcado por um contraste pobre.

O método para determinação automática do centro mostrou-se preciso e robusto, apresentando bons resultados para as 60 imagens analisadas. Por outro lado, a rede neural demonstrou baixa sensibilidade com relação a variações da posição do centro, principalmente em relação a coordenada vertical do centro.

A grande vantagem do método proposto é sua habilidade em utilizar informações geométricas que são aprendidas através de exemplos. Os autores acreditam firmemente que este trabalho contribui com uma nova visão para a detecção de órgãos e estruturas em imagens médicas. Em trabalhos futuros pretendemos enfatizar o processo de escolha das variáveis, salientando o importante papel desempenhado pela variável geométrica, bem como pretendemos também acrescentar novas informações geométricas relevantes à entrada da rede.

REFERÊNCIAS

- BAE, K.T., GIGER, M.L., CHEN, C. T. and KAHN, C. E. (1993). "Automatic segmentation of liver structure in CT images", *Medical Physics*, v. 20, p. 71-78.
- CICHOCKI, A. and UNBEHAUEN, R. (1993). *Neural Networks for Optimization and Signal Processing*, First Edition, John Wiley & Sons, Chichester, England.
- COSTA, C. and MOURA, L. (1995). "Automatic detection of LV contours in nuclear medicine using geometrical information and a neural net", *Computers in Cardiology*, p. 557-560.
- DIAS, J.M.B and LEITÃO J.M.N. (1996). "Wall position and thickness estimation from sequences of echocardiographic images", *IEEE Transactions on Medical Imaging*, v. 15, p. 25-38.
- FLOYD, C. E. and TOURASS, G. D. (1992). "An artificial neural network for lesion detection on SPECT images", *Investigative Radiology*, v. 27, p. 667-672.

- FRIEDLAND, N. and ADAM, D. (1989). "Automatic ventricular boundary detection from sequential ultrasound images using simulated annealing", *IEEE Transactions on Medical Imaging*, v. 8, p. 344-353.
- FU, K.S. and MUI, J. K. (1981). "A survey on image segmentation", *Pattern Recognition*, v. 13, p 3-16.
- GONZALEZ, R. C. and WINTZ, P. (1987). *Digital Image Processing*, Second Edition, Addison Wesley Publishing Company, California, U.S.A.
- HALL, L. O., BENSAD, A.M., CLARKE, L.P. and VELTHUIZEN, R. P. (1992). "A comparison of neural and fuzzy clustering techniques in segmenting MR images of the brain", *IEEE Transactions on Neural Networks*, v. 3, p. 672-682.
- LILLY, P., JENKINS, J. and BOURDILLON, P. (1989). "Automatic contour definition on left ventriculograms by image evidence and a multiple template-based model", *IEEE Transactions on Medical Imaging*, v. 8, p. 173-185.
- MOURA, L. and KITNEY, R. (1992). "Automatic reconstruction of 3D coronary artery segments", *Automedica*, v. 15, p. 97-121.
- RUMELHART, D.E., MCCLELLAND, J.L.(1986). *Parallel distributed processing: Exploration in the microstructure of cognition*, v. 1: Foundations, M.I.T. Press, Cambridge.
- THEDENS, D.R., SKORTON, D.J. and FLEAGLE, S.R. (1995). "Methods of graph searching for border detection in image sequences with application to cardiac magnetic resonance imaging", *IEEE Transactions on Medical Imaging*, v.14, p. 42-55.
- TOSCANO, M. (1992). "A microcomputer-based system for the analysis of left ventricle function", *Automedica*, v. 15, p. 163-175.

USING NEURAL NETS FOR AUTOMATIC DETECTION OF LV CONTOURS IN NUCLEAR MEDICINE IMAGESC. COSTA¹ e L. MOURA²

ABSTRACT-- In this paper we present a method that makes use of an artificial neural network for the automatic detection of left ventricle (LV) contours in nuclear medicine images. The images were obtained from 60 male patients using a Gamma Camera. Although the method has been developed for LV contour detection, it can be extended to other classes of structures and images. Learning is carried out by feeding the system with a series of images and their corresponding LV contours drawn by an operator. The system extracts both pixel value and geometrical information that is used for training the neural network. Once trained the network is able to automatically detect LV contours. In this paper we present details of the neural network operation and performance, which is evaluated through the use of two error measurement criteria. One important feature of the method is the automatic detection of the LV center, which plays an important role in minimizing the error values. Apart from presenting errors that are compatible with several other automatic detection techniques, the present method has the clear advantage of being able to store geometrical and pixel intensity information that is learned from examples.

Key-words: Neural Net, Automatic Contour Detection, Left Ventricle

¹ Dept. of Biomedical Engineering of Unicamp, São Paulo, Brazil and University of Amazonas, Manaus, Amazonas, Brazil.

² São Paulo University, Medical School Hospital, São Paulo, Brazil