

Segmentação de Imagens Ecocardiográficas Utilizando Mapas de Kohonen

Luciano Piccoli *

Caroline V. Gasperin †

Philippe O. A. Navaux ‡

Resumo

Este artigo apresenta a utilização de mapas de Kohonen na segmentação de imagens médicas. As imagens utilizadas tratam-se de ecocardiogramas de fetos humanos. Estes exames são de grande importância, pois tratam de informar se um feto terá ou não problemas cardíacos durante sua evolução. O processo de segmentação auxilia no reconhecimento das bordas do coração, possibilitando que problemas graves sejam tratados com grande antecedência, evitando-se possíveis situações perigosas mais tarde.

Para auxiliar na tarefa de diagnosticar problemas cardíacos, a segmentação da imagem ecocardiográfica representa o método mais adequado, sendo capaz de delimitar as cavidades do coração. Entretanto, atualmente, os chamados métodos convencionais não conseguem realizar esta tarefa satisfatoriamente. Isto deve-se as características intrínsecas às imagens ecocardiográficas, como a nitidez limitada.

Como alternativa a esta situação, propõe-se a utilização dos mapas de Kohonen [KOH89, KOH90]. Mapas de Kohonen são estruturas organizadas, geralmente em forma matricial, que são capazes de realizar tarefas semelhantes às do cérebro humano. Assim como o cérebro, onde existem regiões responsáveis pela fala, audição, entre outros, os mapas realizam o agrupamento de conhecimentos em regiões. Pode-se dizer que os mapas de Kohonen realizam uma redução dimensional do problema para duas dimensões, no caso de mapas bidimensionais.

Após treinamento do mapa através da apresentação de amostras de imagens ecocardiográficas, definem-se regiões distintas, cada qual capaz de reconhecer estruturas diferentes do coração. A partir do mapa treinado, é necessária a definição das regiões nele surgidas. Para tanto, utiliza-se o método de clusterização de imagens proposto por Coleman e Andrews [COL79]. Este método define o melhor número de clusters através da avaliação de um parâmetro de qualidade dos clusters (β). O critério utilizado é o produto entre as matrizes de dispersão entre clusters e intra clusters. Os resultados obtidos apresentam-se bons em relação a qualidade e ao tempo de processamento, sendo que as imagens resultantes mostram as cavidades cardíacas bem delimitadas.

Palavras-Chave: Mapas de Kohonen, Clusterização, Ecocardiografia, Segmentação

*Mestrando do CPGCC/UFRGS: Redes Neurais, Processamento de Imagens, Processamento Paralelo. E-mail: luciano@inf.ufrgs.br

†Bacharelanda em Informática - PUCRS: Redes Neurais, Processamento de Imagens. E-mail: caroline@inf.ufrgs.br

‡Professor CPGCC/UFRGS: Dr. Eng. em Informática (Instituto Nacional Politécnico de Grenoble - França 1979): Redes Neurais, Processamento Paralelo em Redes Neurais. E-mail: navaux@inf.ufrgs.br

1 Introdução

Na área médica existem inúmeras pesquisas com o objetivo de criar meios de auxiliar cada vez mais as pessoas que lidam neste ramo. Este auxílio é representado pela maior facilidade na diagnosticção de doenças e problemas congênitos. Considerando o grande número de diferentes estruturas no corpo humano, e que cada qual possui suas características próprias, necessita-se de diferentes metodologias que explorem tais características, de forma a evidenciar os problemas existentes.

Geralmente, para realizar uma diagnosticção, o especialista necessita de informações visuais da região em questão. Para tanto, existem diferentes formas de aquisição de imagens do corpo humano. Entre elas, pode-se destacar a tomografia computadorizada, a ressonância magnética, PET e o ultrassom. A tomografia computadorizada (CAT — *Computer Assisted Tomography*) permite a aquisição de imagens em três dimensões, a baixo custo. Entretanto utiliza uma fonte de raio-X para obter as imagens. A ressonância magnética (MRI — *Magnetic Resonance Imaging*) é uma tecnologia mais nova do que o CAT, obtendo os mesmos tipos de imagens. Nela, o paciente é submetido a intensos campos magnéticos. No método PET — *Positron Emission Tomography* — uma substância radioativa é injetada no paciente, que depois é colocado dentro de um detector que mede a radiação emitida do corpo. Por fim, o ultrassom adquire imagens através da utilização de energia acústica.

Este último representa a fonte das imagens analisadas neste trabalho. Suas vantagens recaem sobre o fato de não representarem perigo para o paciente que realiza o exame. Outros métodos requerem a injeção de substâncias nocivas ou então necessitam que o paciente seja submetido a bombardeios de raios-X. Os pontos negativos das imagens ecocardiográficas são a grande presença de ruídos do tipo *speckle* [BUR78], a pouca nitidez e a definição precária das bordas.

Este trabalho está focado em imagens de ultrassom obtidas do coração de fetos humanos. O seu objetivo é permitir ao observador a correta visualização das bordas das cavidades cardíacas, possibilitando o posterior cálculo de área e volumes das cavidades. Assim pode-se estabelecer a variação de volumes entre a sístole e a diástole do coração, além da detecção de cavidades maiores ou menores do que o normal.

O processo de delimitação das bordas cardíacas é também conhecido como segmentação. Através da segmentação torna-se possível a visualização de regiões distintas em uma imagem, permitindo a identificação de diferentes órgãos e de regiões diferentes dentro do órgão. Existem vários métodos para realizar esta tarefa, sendo classificados em interativos ou semi-automáticos e automáticos. Nos primeiros, existe a necessidade de interferência humana para completar a segmentação. Já os métodos automáticos, realizam a segmentação de forma independente, tendo como vantagem sobre os métodos semi-automáticos a velocidade de processamento, pois não há interferência humana.

Paralelamente, existe um grande crescimento no espectro das aplicações de métodos baseados em Redes Neurais Artificiais (RNA). RNAs tem sido utilizadas com sucesso na aproximação da melhor solução de diversos tipos de problemas, como por exemplo problemas do tipo NP-completo [JAG95]. Dentre as classes de RNAs, os mapas de Kohonen mostram uma vasta aplicabilidade, como a máquina de escrever fonética [FRE91], controle de movimentos de um braço mecânico [FRE91] e classificação de nuvens [VIS95]. Na área de segmentação de imagens, os mapas de Kohonen são utilizados em [MOR96] e em [NUN94, NUN95], onde são utilizadas imagens coloridas e imagens multispectrais. Também realizam com sucesso a segmentação de imagens exteriores [CAM97]. Trabalhos voltados à segmentação de imagens ecocardiográficas são apresentados em [DAH98], [KOT94] e em [SÜS95], que utilizam medidas de textura para quantificar as imagens e uma rede neural do tipo *backpropagation* para segmentar a imagem.

As seções seguintes mostram a aplicação de mapas de Kohonen na segmentação de imagens ecocardiográficas extraídas de fetos humanos. A seção 2 discute as imagens utilizadas, mostrando suas características e forma de aquisição. A seção 3 coloca o método utilizado para realizar a segmentação das ecocardiografias. Os resultados obtidos pela aplicação dos mapas de Kohonen

são mostrados na seção 4. Por fim, são apresentadas as conclusões dos autores.

2 Imagens Utilizadas

As imagens empregadas neste trabalho são obtidas através da aplicação de feixes de ultrassom na região de interesse no paciente. Estes feixes são produzidos por uma fonte, normalmente a uma frequência entre 3 e 10 Megahertz. A energia acústica é refletida pelos tecidos internos e detectada por um transdutor próximo da fonte, formando uma imagem. A fonte e o transdutor estão normalmente montados em um mesmo equipamento. Grande parte das máquinas de ultrassom possuem um conjunto linear de transdutores, produzindo imagens no formato de um pedaço de pizza. Uma vantagem do ultrassom é a produção de imagens em tempo real.

A aquisição de imagens de ultrassom revela muitos problemas na visualização. Um destes é oriundo do fato de que o transdutor geralmente apresenta-se móvel, gerando dados não homogêneos. Mesmo havendo a fixação do mecanismo de leitura, sabendo-se sua posição e orientação, os dados continuam a ser obtidos de forma irregular, pois depende da estrutura interna de cada paciente. Com isto, as imagens geradas apresentam uma grande porção de ruídos do tipo speckle, tornando mais problemática a identificação das estruturas internas.

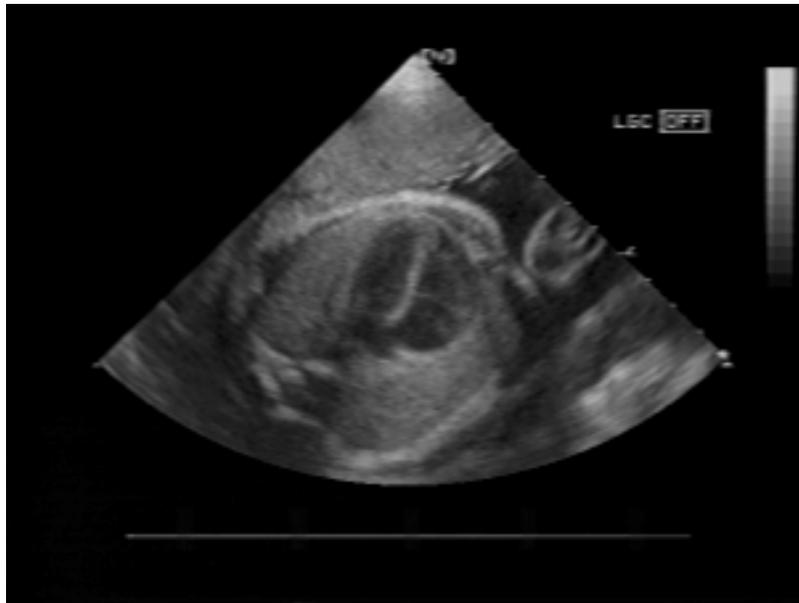


Figura 1: Ecocardiografia fetal, corte quatro câmaras

Considerando-se que a segmentação é realizada em imagens obtidas do coração de uma criança antes de seu nascimento, estes problemas são mais evidenciados, já que envolve a posição do bebê dentro da mãe, além de todas as estruturas existentes entre o coração do feto e a fonte emissora do ultrassom.

A posição do transdutor utilizada permite a obtenção de uma imagem conhecida como “corte quatro câmaras”, onde as cavidades cardíacas ficam bem evidenciadas. A imagem permite a medição de diversos parâmetros, permitindo a diagnosticção de um grande número de cardiopatias congênitas. A figura 1 ilustra uma ecocardiografia fetal utilizando o corte quatro câmaras.

3 Metodologia

Para realizar a tarefa de segmentação da imagem ecocardiográfica, propõe-se o uso de redes neurais artificiais, mais especificamente estruturas do tipo auto-organizáveis, também conhecidos co-

mo mapas de Kohonen [KOH90]. As subseções seguintes descrevem a estrutura da rede neural utilizada, o método de clusterização do mapa de Kohonen e a sequência de aplicação do método.

3.1 Mapas de Kohonen

Os mapas de Kohonen são representados por estruturas matriciais, onde cada elemento é denominado de neurônio. Um neurônio mantém relações com os elementos vizinhos, tornando possível o armazenamento de conhecimentos semelhantes em regiões fisicamente próximas. Esta organização estrutural também está presente no cérebro humano, mais especificamente na região do córtex. Nele, regiões fisicamente distintas são responsáveis pelo processamento de informações diferentes, como por exemplo a fala, a audição e a visão.

Formalmente a função realizada por um mapa de Kohonen consiste no mapeamento de dados de entrada dispostos em um espaço \mathbb{R}^n em uma matriz bidimensional. Devido às relações de vizinhança existentes entre os elementos processadores m_i , a topologia apresentada no espaço de características é preservada na estrutura do mapa.

A fase de treinamento do mapa consiste na apresentação em ordem randômica dos elementos x do espaço de amostras ao mapa. Para cada elemento m_i , é medida a distância Euclidiana entre m_i e x . Dentre todos os neurônios, aquele que possuir a menor distância para o vetor x é considerado como elemento vencedor (m_c).

Os pesos do neurônio vencedor são atualizados de forma a se aproximar mais do vetor x . Além dos pesos do elemento m_c , aqueles presentes em sua vizinhança também são atualizados. A região de vizinhança de um neurônio pode ser vista na figura 2. Esta característica faz com que a topologia do espaço de amostras seja preservada.

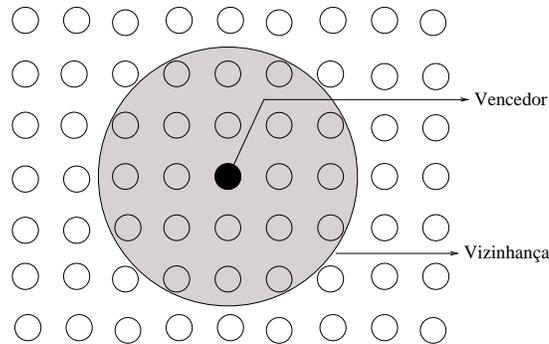


Figura 2: Região vizinha ao neurônio vencedor

Existem duas principais funções que determinam o percentual de atualização para os neurônios contidos na vizinhança do vencedor. A primeira é a função bolha, figura 3(a), onde todos os elementos vizinhos recebem uma atualização igual ao vencedor. Uma função mais complexa, mas que apresenta melhores resultados finais, é a função Gaussiana, mostrada na figura 3(b). Nela, quanto maior a distância do centro, menor o ganho.

A atualização dos elementos processadores é dada por:

$$m_i(t + 1) = m_i(t) + h_{ci}(t)[x(t) - m_i(t)]$$

onde t representa a unidade discreta de tempo e $h_{ci}(t)$ representa o núcleo da vizinhança.

3.2 Clusterização

Os mapas de Kohonen fazem o agrupamento do conhecimento em regiões fisicamente próximas, entretanto não existe a definição real das regiões definidas. Esta etapa é necessária, pois durante a utilização do sistema, os vetores x são apresentados ao mapa, o qual responde apenas informando

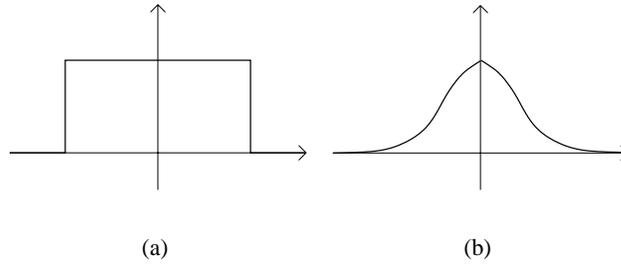


Figura 3: Funções de vizinhança. 3(a) função bolha. 3(b) função Gaussiana

qual neurônio é o vencedor. Além do conhecimento do elemento vencedor, deve-se conhecer a que *classe* o neurônio vencedor pertence.

Apesar das imagens ecocardiográficas terem certas regiões conhecidas, como as partes internas e externas às cavidades, existe a possibilidade de reconhecimento de classes adicionais, como por exemplo classes que representem regiões de borda. Necessita-se de um procedimento de *clusterização* não supervisionada [LAN98] do mapa obtido.

Para suprir esta necessidade, é utilizado o método proposto por Coleman e Andrews [COL79], o qual estabelece um critério de avaliação sobre a qualidade da clusterização (β). O mapa é primeiramente dividido em duas principais classes, e calculado o critério de qualidade. A cada classe adicionada, é novamente calculada a qualidade da clusterização, até que seja atingido um ponto máximo de qualidade, como mostrado na figura 4. O melhor número de classes é então determinado, e o mapa está pronto para ser utilizado na segmentação.

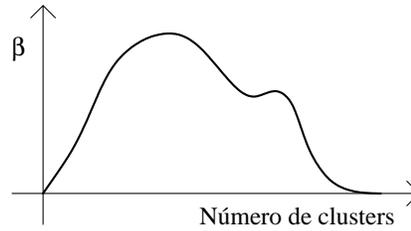


Figura 4: Formato esperado para β versus número de clusters

O valor de β é obtido através do produto das matrizes de dispersão entre clusters e intra clusters. Formalmente, β é obtido através de 1

$$\beta = \text{tr}[S_b] \cdot \text{tr}[S_w] \quad (1)$$

onde S_w representa a matriz de dispersão intra clusters, dada por 2, e S_b é a matriz de dispersão entre clusters, mostrada em 3.

$$S_w = \frac{1}{K} \sum_{k=1}^K \frac{1}{M_k} \sum_{\mathbf{x}_i \in S_k} [\mathbf{x} - \mu_k][\mathbf{x} - \mu_k]^t \quad (2)$$

$$S_b = \frac{1}{K} \sum_{k=1}^K [\mu_k - \mu_0][\mu_k - \mu_0]^t \quad (3)$$

$$\mu_0 = \frac{1}{M} \sum_{i=1}^M \mathbf{x}_i$$

Acima, \mathbf{x} é o vetor característica, μ_k é a média do k -ésimo cluster, M_k é o número de elementos no k th cluster, K representa o total de clusters, S_k representa o conjunto de elementos do

cluster k , μ_0 é a média de todo o mapa e M representa o número total de pontos a serem clusterizados. Após determinar-se os centros dos clusters, todos os elementos do mapa são atribuídos a um cluster de acordo com a menor distância Euclidiana.

3.3 Sequência de Aplicação

Para tornar possível a implementação do sistema, é utilizado o ambiente Khoros [KON94, SIL94] para processamento de imagens e o pacote de programação SOM_PAK [KOH95]. O sistema Khoros é um ambiente bastante agradável e flexível, permitindo facilmente a integração de componentes externos a sua estrutura original. Além das bibliotecas já implementadas, o software da rede neural é integrado ao sistema, deixando seu uso transparente.

O sistema possui quatro diferentes etapas: amostragem, treinamento, clusterização e a segmentação propriamente dita. A fase de amostragem consiste na obtenção de forma aleatória de um número finito de amostras de um conjunto de imagens selecionadas. As amostras obtidas tornam-se entradas para a etapa de treinamento do mapa, onde procura-se definir a melhor configuração possível. A clusterização consiste na aplicação do método descrito na seção anterior ao mapa gerado pela fase de treinamento, sendo o vetor x_i das equações 2 e 3 representado pelo neurônio m_i do mapa de Kohonen.

Por fim, a geração da imagem final ocorre na etapa de segmentação. É selecionada uma imagem de interesse, sobre a qual é realizado o processamento. Uma janela móvel desloca-se ponto a ponto por toda imagem, tendo como origem o canto superior esquerdo. A classe do ponto central da janela é atribuída de acordo com a classificação da janela que o contém pelo mapa de Kohonen clusterizado. Assim, ao final do processamento é obtida uma máscara que divide a imagem original em um número finito de regiões. A partir da máscara gerada é possível realizar cálculos envolvendo áreas e volumes das regiões cardíacas, além de possibilitar ao profissional da área uma visualização bem definida das bordas do órgão.

4 Experimentos

Para a realização dos experimentos, selecionou-se algumas imagens como fonte de amostras para o treinamento do mapa de Kohonen. Como a região de interesse representa uma pequena parte da imagem total adquirida pelo equipamento, apenas o trecho onde é destacado o coração do feto é utilizado, tanto na amostragem como no processo de segmentação.

Na etapa de aquisição de amostras, foram utilizadas 4 imagens, das quais foram retiradas de forma aleatória 100 amostras de cada. Cada amostra consiste de uma janela de tamanho fixo 5×5 . Para o treinamento do mapa, várias configurações foram testadas, sendo os melhores parâmetros obtidos utilizados nos testes a seguir. Em termos gerais, utiliza-se topologia hexagonal, vizinhança do tipo Gaussiana e inicialização randômica.

As imagens utilizadas para segmentação são mostradas na figura 5, sendo que as imagens 5(a) e 5(b) fazem parte do grupo de onde as amostras foram retiradas.

Uma primeira abordagem na segmentação das imagens ecocardiográficas, é a utilização dos pixels diretamente. A única transformação sobre os mesmos é a normalização entre -1 e 1. Para tanto, os pontos presentes nas janelas 5×5 são colocados em um vetor de 25 posições. Este vetor x é utilizado no treinamento e na segmentação da imagem. Considerando que são extraídas 25 características da imagem, o tempo esperado para a segmentação é alto, pois existe um grande custo na determinação do neurônio vencedor. As imagens mostradas na figura 6 mostram as imagens originais segmentadas pelo sistema.

Para o teste seguinte, ao invés da utilização dos pixels diretamente, é extraída uma característica de cada janela. Esta característica é representada pela média, ou energia, da janela. Esta característica foi escolhida por que mostra-se bastante representativa neste tipo de imagem. A importância da média é evidenciada através da análise das imagens geradas utilizando esta caracte-

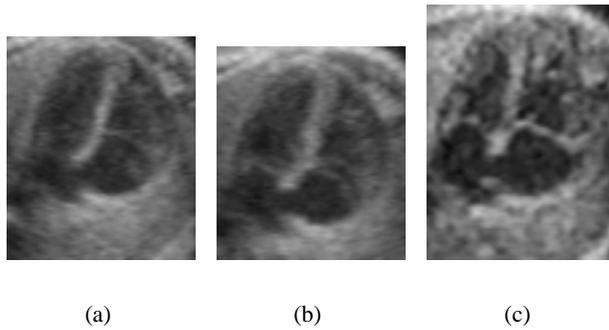


Figura 5: Imagens ecocardiográficas originais

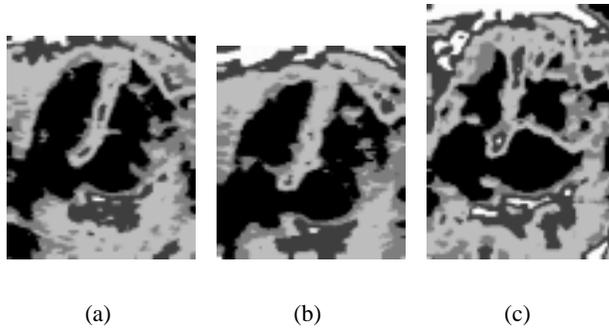


Figura 6: Imagens segmentadas utilizando diretamente os pontos

terística. A figura 7 ilustra os resultados obtidos. Em comparação com os resultados utilizando diretamente os pixels, as imagens segmentadas apresentam basicamente as mesmas características. Porém, no mapa treinado apenas com a média foram identificadas 3 classes, enquanto na primeira abordagem são verificadas 4 classes. Então, pode-se afirmar que no primeiro caso, o mapa extrai a característica média da imagem, e se organiza principalmente a partir dela. As informações posicionais dos pontos no primeiro caso são ignoradas, pois os resultados apresentam-se praticamente iguais. Entretanto, o custo computacional exigido para o processamento de apenas uma característica mostra-se mais viável.

Um fator importante, e que deve ser abordado, é a aplicação de filtros sobre as imagens de interesse em um passo anterior a amostragem e a segmentação. Para isto, são selecionados dois tipos de filtros: o filtro da mediana [GON93] e a técnica de Crimmins [CRI85] para a remoção de ruídos speckle. A aplicação do filtro da mediana é realizada sobre todos os pontos da imagem,

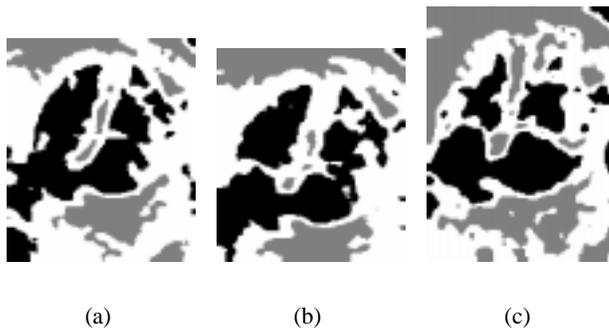


Figura 7: Imagens segmentadas utilizando a média dos pontos

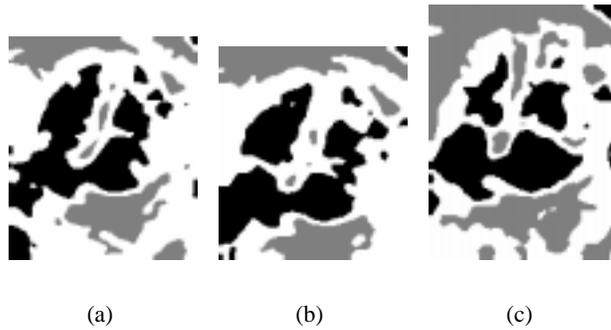


Figura 8: Imagens segmentadas utilizando a média e pré-processamento com filtro da mediana

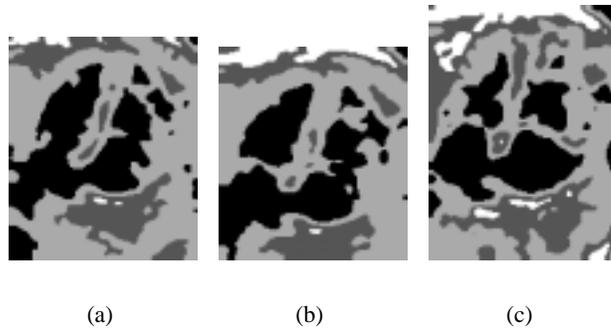


Figura 9: Imagens segmentadas utilizando a média e pré-processamento de Crimmins

sendo considerada uma vizinhança de tamanho fixo. Os pontos contidos neste intervalo são ordenados, e o valor posicionado no meio é atribuído ao ponto central da janela. Este filtro realiza basicamente o mesmo procedimento do filtro da média, entretanto é capaz de preservar detalhes importantes da imagem. A figura 8 mostra as imagens ecocardiográficas segmentadas após pré-processamento por um filtro de mediana. Como a média mostra-se como característica relevante, ela foi utilizada nos testes utilizando filtros.

Uma segunda alternativa de pré-processamento é a utilização da técnica de Crimmins para a remoção de ruídos speckle, típicos de imagens de ultrassom. O algoritmo utiliza uma redução de ruídos não linear, a qual compara a intensidade de cada ponto com a intensidade dos 8 vizinhos mais próximos. Conforme os valores dos pontos vizinhos, o pixel central tem seu valor aumentado ou diminuído, tornando-se o mais representativo de sua região. Apesar de ser computacionalmente mais complexo, este filtro mostrou melhores resultados do que o filtro da mediana. As mesmas regiões ficam melhor definidas, como visualizado na figura 9.

A utilização de filtros na etapa de pré-processamento é fundamental na obtenção de melhores resultados na segmentação das imagens ecocardiográficas. De um modo geral, os resultados obtidos mostram-se bons, pois além de distinguir partes interiores e exteriores às cavidades cardíacas, houve a segmentação de regiões entre as cavidades. Entretanto, estas regiões que representam válvulas do coração apresentam-se móveis, gerando dificuldades para o sistema em reconhecê-las. Existe uma grande dependência do instante em que a imagem é lida, pois os dados mostram-se muito variáveis.

Em comparação com trabalhos semelhantes, as características evidenciadas acima podem ser observadas. Em [DAH98], onde a imagem é classificada em regiões internas e externas às cavidades, as bordas aparecem bem definidas. Entretanto, o sistema não consegue avançar em regiões representadas pelas válvulas cardíacas.

Da mesma forma, os resultados obtidos em [SÜS95], mostram-se inferiores aos aqui apresen-

tados. Em [SÜS95] é proposta a segmentação e detecção semi-automática de bordas em imagens ecocardiográficas, a partir da utilização de redes neurais backpropagation e o mapa de Kohonen. Como parâmetros para o aprendizado das redes, são utilizados além da média, a variância, o contraste, a uniformidade e a entropia da imagem, extraídos da matriz de co-ocorrência de níveis de cinza. Apesar da abordagem apresentada não utilizar tais parâmetros adicionais, os resultados apresentam-se superiores.

Um ponto positivo desta abordagem apresentada é a inexistência da necessidade de um operador exclusivo para a aquisição de amostras. Isto deve-se ao fato de que o aprendizado é realizado de forma não supervisionada, ou seja, as amostras não necessitam ser rotuladas. Isto evita que situações contraditórias onde as mesmas amostras sejam rotuladas de forma distinta por operadores diferentes.

5 Conclusão

Este trabalho abordou o problema de segmentação de imagens ecocardiográficas fetais. Existem tradicionalmente algoritmos de segmentação que não são capazes de delimitar com precisão as regiões presentes em imagens deste tipo. Como método alternativo, buscou-se utilizar redes neurais artificiais, mais especificamente os conhecidos mapas de Kohonen.

Imagens ecocardiográficas apresentam certas características próprias, o que limita a utilização de métodos convencionais de segmentação de imagens. Mais especificamente a falta de nitidez, o que dificulta a delimitação das bordas.

A utilização da característica média mostra que é desnecessário o processamento diretamente sobre todos os pontos da imagem, já que os resultados obtidos pelas duas abordagens mostrou-se muito semelhante. Além disso, a carga computacional do processamento apenas da média é consideravelmente menor do que o processamento direto sobre todos os pontos. A segmentação utilizando apenas a característica média revelou-se cerca de 4 a 5 vezes mais rápida do que o mesmo procedimento utilizando diretamente os pixels. Este é um fator importante, pois permite maior agilidade no processo total de diagnóstico de problemas cardíacos, evitando cansaço do especialista, o que acarreta possíveis erros.

Como complemento, os filtros utilizados na fase de pré-processamento mostraram-se importantes, pois permitiram que as imagens geradas apresentassem uma melhor definição das regiões de interesse, principalmente graças a utilização da técnica de Crimmins. Apesar da fase de clusterização ter estabelecido um menor número de clusters para o mapa resultante da aplicação do filtro da mediana, os resultados obtidos pela técnica de Crimmins definem melhor as regiões de borda, assim como os avanços sobre as partes onde estão presentes as válvulas cardíacas. Para o cálculo de áreas e volume, um objetivo futuro, quanto mais precisas forem as regiões de borda, mais confiáveis serão as medidas realizadas.

Como perspectivas futuras, está prevista a utilização de outras técnicas de pré-processamento e extração de outras características que se evidenciem em imagens ecocardiográficas. Também pretende-se estabelecer uma metodologia matemática para a avaliação dos resultados obtidos. Atualmente esta qualificação é estabelecida visualmente por pessoas da área.

Referências

- [BUR78] BURCKHARDT, Christoph B. Speckle in ultrasound *b*-mode scans. **IEEE Transactions on Sonics and Ultrasonics**, v.SU-25, n.1, p.1–6, Jan. 1978.
- [CAM97] CAMPBELL, Neill W.; THOMAS, Barry T.; TROSCIANKO, Tom. Automatic segmentation and classification of outdoor images using neural networks. **Special Issue on Neural Networks for Computer Vision Applications**, p.137–144. 1997.

- [COL79] COLEMAN, Guy B.; ANDREWS, Harry C. Image segmentation by clustering. **Proceedings of the IEEE**, v.67, n.5, p.773–785, Mai. 1979.
- [CRI85] CRIMMINS, Thomas R. Geometric filter for speckle reduction. **Applied Optics**, v.24, n.10, p.1438–1443. 1985.
- [DAH98] DAHMER, Alessandra. **Segmentação de imagens ecocardiográficas utilizando redes neurais e medidas de textura**. Porto Alegre: Curso de Pós-Graduação em Ciência da Computação, 1998. Dissertação de Mestrado.
- [FRE91] FREEMAN, James A.; SKAPURA, David M. **Neural networks, algorithms, applications and programming**. [S.l.]: Addison-Wesley, 1991. 401p.
- [GON93] GONZALEZ, Rafael C.; WOODS, Richard E. **Digital image processing**. [S.l.]: Addison-Wesley, 1993. 716p.
- [JAG95] JAGOTA, Arun. Approximating maximum clique with a hopfield network. **IEEE Transactions on Neural Networks**, v.6, n.3, p.724–735, Mai. 1995.
- [KOH95] KOHONEN, Teuvo; HYNNINEN, Jussi; KANGAS, Jari; LAAKSONEN, Jorma. **The self-organizing map program package: version 3.1**. Rakentajanaukio 2 C, SF-02150 Espoo, Finland: [s.n.], 1995.
- [KOH89] KOHONEN, Teuvo. **Self-organization and associative memory**. Berlin: Springer-Verlag, 1989. 312p.
- [KOH90] KOHONEN, Teuvo. The self-organizing map. **Proceedings of the IEEE**, v.78, n.9, p.1464–1480, Set. 1990.
- [KON94] KONSTANTINIDES, Konstantinos; RASURE, John R. The Khoros software development environment for image and signal processing. **IEEE Transactions on Image Processing**, v.3, n.3, p.243–252, Mai. 1994.
- [KOT94] KOTROPOULOS, C.; MAGNISALIS, X.; PITAS, I.; STRINTZIS, M. G. Nonlinear ultrasonic image processing based on signal-adaptative filters and self-organizing neural networks. **IEEE Transactions on Image Processing**, v.3, n.1, Jan. 1994.
- [LAN98] LANGAN, David A.; MODESTINO, James W. Cluster validation for unsupervised stochastic model-based image segmentation. **IEEE Transactions on Image Processing**, v.7, n.2, p.180–195, Fev. 1998.
- [MOR96] MOREIRA, Jander; COSTA, Luciano da Fontoura. Neural-based color image segmentation and classification using self-organizing maps. In: PROCEEDINGS OF IX SIBGRAPI, 1996, Caxambu. **Anais...** 1996. p.47–54.
- [NUN94] NUNES, Rodrigo Vanini; ENGEL, Paulo Martins. Classificação multiespectral utilizando kohonen cúbico. In: ANAIS I SIMPÓSIO BRASILEIRO DE REDES NEURAIS, 1994. **Anais...** 1994. p.133–138.
- [NUN95] NUNES, Rodrigo Vanini. **Uma abordagem neural para tratamento de imagens multiespectrais**. Porto Alegre: Curso de Pós-Graduação em Ciência da Computação, 1995. Dissertação de Mestrado.
- [SIL94] SILVA, Ana Maria Marques da; D'ORNELLAS, Marcos C.; TAMIOSSO, Fabiana Saldanha. Realce e segmentação de imagens médicas usando o sistema Khoros. In: ANAIS DO IV CBIS, 1994, Porto Alegre. **Anais...** 1994. p.44–46.
- [SÜS95] SÜSSNER, M.; BUDIL, Th.; PORENTA, G. Segmentation and edge-detection of echocardiograms using artificial neuronal networks. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE EANN, 1995. **Anais...** 1995.
- [VIS95] VISA, Ari; IIVARINEN, Jukka; VALKEALAHTI, Kimmo; SIMULA, Olli. Neural network based cloud classifier. **International Conference on Artificial Neural Networks**, Out. 1995.