

Detecção de nódulos mamários em imagens de simuladores ultrassonográfico e mamográfico

Breast nodules detection in images of ultrasonographic and mammographic simulators

Karem D. Marcomini¹, Homero Schiabel¹ e Antonio Adilton O. Carneiro²

¹Departamento de Engenharia Elétrica, Escola de Engenharia de São Carlos, Universidade de São Paulo (USP) – São Carlos (SP) Brasil.

²Departamento de Física, Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto, USP – Ribeirão Preto (SP), Brasil.

Resumo

Devido à alta taxa de incidência de câncer de mama em mulheres, muitos procedimentos têm sido desenvolvidos visando auxiliar no diagnóstico e detecção precoce. A mamografia e a ultrassonografia vêm se destacando como as principais técnicas de imagem da mama. Nesse âmbito, os esquemas de diagnóstico auxiliado por computador têm fornecido ao especialista uma segunda opinião mais precisa e confiável, minimizando a subjetividade visual entre observadores. Assim, nós propomos a aplicação de um método automático de segmentação, por meio da rede neural artificial SOM, que deve fornecer informações precisas quanto a borda da lesão. Os ensaios foram realizados em 100 imagens mamográficas e 70 ultrassonografias, ambos os casos obtidos por simuladores. A fim de verificar a precisão dos limites demarcados pelo detector automático, medidas quantitativas foram extraídas comparando essas imagens com a delineada manualmente por uma radiologista experiente. A técnica proposta apresentou altas taxas de precisão e sensibilidade, além de baixo erro na correta representação dos achados mamográficos e ultrassonográficos.

Palavras-chave: neoplasias da mama, processamento de imagem assistida por computador, mamografia, ultrassonografia mamária.

Abstract

Due to the high incidence rate of breast cancer in women, many procedures have been developed to assist in the diagnosis and early detection. Mammography and ultrasonography stand out as the main breast imaging techniques. In this context, the schemes of computer-aided diagnosis have provided to the specialist a more accurate and reliable second opinion by minimizing the visual subjectivity inter-observer. Thus, we propose the application of an automated method of segmentation, through the neural network SOM, to provide accurate information regarding the border of the lesion. The tests were employed in 100 mammographic images and 70 sonographic, both cases obtained by simulation. In order to verify the accuracy of the boundaries demarcated by the automatic detector, quantitative measurements were extracted to compare these images with the manually delineated by an experienced radiologist. The proposed technique presented high accuracy and sensitivity, and low error rate in correctly representing the mammographic and sonographic findings.

Keywords: breast neoplasms, computer-assisted image processing, mammography, mammary ultrasonography.

Introdução

O número de casos de câncer de mama tem aumentado em larga escala. No Brasil, a estimativa do Instituto Nacional do Câncer (INCA) para 2012 era de que 52.680 novos casos da doença sejam diagnosticados, respondendo por cerca de 12.000 mortes a cada ano.

A execução de tratamentos menos agressivos deve-se ao seu diagnóstico e tratamento precoce. Dentre os métodos por imagem disponíveis, encontra-se a mamografia.

Essa modalidade apresenta-se como instrumento mais efetivo no diagnóstico precoce, possibilitando reduzir de 18 a 30% a taxa de mortalidade¹. Além disso, oferece sensibilidade de 85 a 92%².

Diante da baixa especificidade diagnóstica da mamografia, são altas as chances de um falso-positivo levar a biópsias desnecessárias, e 80% dos casos resultam em alterações benignas. Dessa forma, a ultrassonografia tem despontado como principal técnica de triagem adjunta à mamografia. Tal procedimento ajuda na diferenciação de

Autor correspondente: Karem Daiane Marcomini – Departamento de Engenharia Elétrica, Escola de Engenharia de São Carlos/Universidade de São Paulo – Avenida Trabalhador São-carlense, 400 – Parque Arnold Schimidt – CEP: 13566-590 – São Carlos (SP), Brasil – E-mail: karem.dm@usp.br

nódulos sólidos e císticos, reduzindo de 25 a 35% o número de biópsias desnecessárias^{2,3}.

Os recursos computacionais também vêm sofrendo muitos avanços nessa área, visando auxiliar o radiologista na minimização da subjetividade visual devido à sobreposição de características. Os esquemas de diagnóstico auxiliado por computador (CAD) têm proporcionado a obtenção de informações adicionais, promovendo um diagnóstico mais conciso. Isso é decorrente da melhoria na qualidade da imagem, determinação morfológica do objeto de interesse, diferenciação dos achados, entre outros^{4,5}.

Nesse âmbito, propomos a utilização da rede neural artificial *Self-Organizing Map* (SOM) na segmentação, bem como a investigação de sua eficiência, na detecção automática do contorno de lesões presentes em imagens mamográficas e ultrassonográficas adquiridas por simuladores.

Banco de Imagens

O banco de imagens que vem sendo utilizado neste trabalho consiste de dois grupos distintos. O primeiro é formado por 70 ultrassonografias modo-B procedentes de simuladores da mama, já o segundo grupo consiste de 100 imagens mamográficas simuladas.

O simulador ultrassonográfico foi desenvolvido por Vieira⁶. O material foi exposto a feixes de ultrassom (US), utilizando o aparelho portátil da *General Electric* modelo *Logic Book* pertencente ao Grupo de Inovação em Instrumentação Médica e Ultrassom da Universidade de São Paulo (GIIUMUS – FFCLRP/USP), operando numa faixa de frequência entre 1-10 Megahertz. A Figura 1A ilustra o modelo atual desse simulador, já na Figura 1B é exibida a imagem resultante de sua exposição a feixes de US.

Já o simulador mamográfico em questão foi desenvolvido por Stemberg⁷. Sua representação é dada pela

Figura 2A. As aquisições dessas imagens foram produzidas a partir de exposições nos mamógrafos *Lorad Mill* (pertencente ao Centro Integrado de Diagnóstico por Imagem, na Irmandade Santa Casa da Misericórdia de São Carlos, SP) e *GE Senographe DMR* (pertencente ao Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto, SP – HCRP/USP). Na Figura 2B é representada a imagem resultante da exposição do simulador ao mamógrafo.

Processamento Digital

Para cada imagem adquirida, uma radiologista determinou a localização dos achados suspeitos e, em seguida, realizou os recortes que jugou necessário. Esses recortes são denominados de regiões de interesse (*Regions of Interest – ROIs*), possuem formato retangular e incluem a lesão e os tecidos adjacentes.

Aplicação de técnicas de pré-processamento

Com a finalidade de remover o ruído indesejado e melhorar os dados constituintes da imagem, foi empregado um pré-processamento sobre as ROIs.

O *speckle* é um tipo de ruído característico em imagens de US, que degrada qualitativamente a imagem e dificulta a discriminação precisa dos limites da lesão. Para buscar minimizá-lo, as ROIs foram, inicialmente, submetidas à filtragem de *wiener*, com janela de vizinhança 5x5, para minimização do ruído aditivo. Em seguida, o contraste foi aumentado através da equalização da imagem. E por fim, realizou-se a filtragem pela mediana, com janela de vizinhança 7x7, permitindo a suavização do ruído ocasionado pelo alargamento de contraste⁸.

Já quando consideramos as imagens mamográficas, é notória a diferença na qualidade, quando comparada as ultrassonográficas. Diante disso, um pré-processamento




Figura 1. Ultrassonografia: (A) *Phantom* ultrassônico; (B) Imagem de ultrassom obtida pelo simulador.

diferenciado foi empregado, sendo necessária apenas a equalização da imagem, visando realçar a diferença de contraste entre o objeto de interesse e o fundo.

Segmentação

As redes neurais artificiais (RNAs) vêm sendo amplamente utilizadas na resolução de problemas de segmentação de imagens médicas⁹. Com o intuito de verificar essa aplicabilidade, a rede SOM foi empregada na detecção de lesões presentes em imagens simuladas adquiridas por ultrassom e mamografia, verificando, assim, o comportamento do algoritmo quando submetido a diferentes tipos de imagens.

A rede foi estruturada com topologia quadrada, em que, as 10 unidades sensoriais da camada de entrada estão totalmente conectadas a grade de 10x10 neurônios. A partir daí, o processo inicia com a aleatoriedade dos pesos iniciais e a amostragem dos padrões de treinamento. Padrões esses correspondentes aos valores das intensidades mínima e máxima dos níveis de cinza (no presente caso, correspondem às cores branca — equivalendo a 255 — e preta — a zero), para os quais os dados de saída devem convergir durante a etapa de treinamento. Na sequência, o neurônio vencedor é encontrado (o mais similar entre os padrões apresentados), bem como sua área de influência — raio para o qual ocorre atualização dos pesos dos neurônios envolvidos. A convergência deve ser realizada em no máximo 1.000 ciclos⁹.

Por fim, a rede recebe a imagem de entrada e a classifica de acordo com os valores obtidos na etapa anterior, convergindo o mapa de borda em apenas duas classes⁹.

Pós-Processamento

Após a binarização da imagem é necessária à remoção de alguns artefatos que são prejudiciais a fase de classificação. Para isso foi desenvolvido um algoritmo,

descrito por Marcomini e Schiabel⁸, que visa à eliminação dos ruídos remanescentes.

Métodos de Avaliação

A precisão da detecção foi aferida através do uso de medidas quantitativas derivadas da comparação de cada ROI segmentada automaticamente com o “padrão ouro” correspondente. Esse padrão foi gerado pelo delineamento manual do contorno, em que uma radiologista experiente, utilizando o *software ImageJ* 1.45 identificou e delimitou a região suspeita.

Dentre as principais medidas utilizadas, destacam-se as seguintes: acurácia (A), taxa de erro (Err), razão de verdadeiros positivos (RVP) — também conhecida como sensibilidade —, razão de falsos positivos (RFP), verdadeiro preditivo positivo (VPP), quality (Q), area overlap measure (AOM), area under-segmentation (AUM), area over-segmentation (AVM) e combination measure (CM)¹⁰⁻¹³.

Resultados e Discussões

O processamento de imagens médicas é um desafio devido à interferência do ruído e da dificuldade com a discriminação de algumas características. Esse fator leva a considerar essa fase como a maior razão de imprecisão de muitos esquemas CAD.

Em imagens obtidas por ultrassom, esse fator se agrava ainda mais devido à interferência do ruído *speckle*. Buscando minimizar esse efeito foram empregadas algumas técnicas de suavização precedentes a segmentação, sendo elas: filtro de *wiener*, equalização e filtro da mediana. Os resultados de sua aplicação podem ser vistos pela Figura 3.




Figura 2. Mamografia: (A) Visualização superior do simulador mamográfico; (B) Imagem mamográfica proveniente do simulador.

Já as imagens mamográficas são fortemente diferenciáveis das de ultrassom, pois não possuem o padrão granuloso ocasionado pelo ruído *speckle*, assegurando um aspecto mais uniforme. Contudo, em alguns casos, o objeto pode ser facilmente confundido com o fundo devido à baixa diferença de contraste. Para tentar suplantar esse problema, ocorreu um pré-processamento por meio da equalização da imagem, como é exemplificado pela Figura 4.

Concluída a fase de pré-processamento, as imagens foram submetidas à detecção automática por meio da rede neural SOM. O efeito da segmentação em *phantoms*

ultrassonográficos e mamográficos são representados pelas Figuras 5 e 6.

Mediante a subjetividade visual e dependência constante de um observador na verificação da precisão do detector em questão, foram estudados métodos que quantificassem a proximidade entre a demarcação manual, proporcionada por uma radiologista, e a automática, fornecida pelo segmentador.

Então, a área obtida pelo delineamento da radiologista foi comparada com a produzida pelo detector. O resultado de tal comparativo executado nos dois conjuntos de imagens é apresentado pela Tabela 1.




Figura 3. Imagens ultrassonográficas simuladas: (A) Original; (B) Após a filtragem de wiener; (C) Equalizada; (D) Com filtro da mediana.




Figura 4. Imagens mamográficas simuladas: (A) Original; (B) Equalizada.




Figura 5. Imagens ultrassonográficas simuladas: (A) segmentada pela rede SOM; (B) Sobreposição do contorno após o pós-processamento.

Conclusões

A principal razão de imprecisão em muitos esquemas CAD está relacionada a falhas durante a etapa de processamento digital da imagem. Isso ocorre em virtude da dificuldade na determinação precisa das fronteiras do objeto provocada; principalmente, pela interferência negativa exercida por ruído ou pela falta de definição devido ao baixo contraste da imagem. Para minimizar esse problema, algumas técnicas de pré-processamento precederam a segmentação. O agravante na sua aplicação em ultrassonografias foi devido ao borramento das estruturas, afetando, sobretudo, as bordas da lesão. Contudo, a imagem de saída tornou-se mais uniforme, realçando o contraste entre o objeto de interesse e o fundo, o que auxiliou positivamente na detecção. Já em mamografias, a imagem de saída obteve aspecto mais ruidoso quanto ao aparecimento de pontos brilhantes devido à equalização, porém contribuiu na distinção do objeto favorecendo o reconhecimento.

A rede neural SOM produziu contornos suaves, resposta rápida e precisa, permitindo uma melhor compreensão das diferenças morfológicas entre lesões benignas e malignas.

Um fator que deve ser levado em consideração é que as RNAs são baseadas na simulação de vida, em que um conjunto inicial de amostragem é apresentado

e, em seguida, é realizado o treinamento neural. Inicialmente, as ligações sinápticas entre os neurônios são fornecidas aleatoriamente, sendo ajustadas, durante o treinamento, até que haja a conversão dos dados. A finalização do processo é representada pelo aprendizado do sistema, o qual é constituído pelo conhecimento adquirido do meio externo. Contudo, a aleatoriedade inicial pode modificar o processo de conversão, refletindo, neste caso, em pequenas variações nos limites da lesão. Ou seja, caso a mesma imagem seja novamente submetida à segmentação, é possível a ocorrência de modificações na borda do objeto. Esse aspecto assemelha-se à visualização por diferentes observadores, em que cada indivíduo vê elementos importantes de maneira distinta, como é o caso da delimitação manual, em que se for delimitada novamente ou por outro observador, é possível que haja mudanças nos limites do objeto. Ainda assim, esse não é um fator prejudicial ao processo, pois não provoca grandes discrepâncias no resultado final.

Agradecimentos

À FAPESP pelo apoio financeiro, ao GIIMUS pelo fornecimento das imagens e ao auxílio da especialista Luciana Buffa Verçosa na determinação e delimitação das lesões.




Figura 6. Imagens mamográficas simuladas: (A) segmentada pela rede SOM; (B) Sobreposição do contorno após o pós-processamento.

Tabela 1. Métricas de avaliação da segmentação.

	AOM (%)	AUM (%)	AVM (%)	CM (%)	RVP (%)	VPP (%)	Q (%)	A (%)	Err (%)	RFP (%)
Phantoms Ultrassonográficos	82,50	13,17	5,17	88,05	86,82	94,82	82,50	94,32	5,67	2,02
Phantoms Mamográficos	88,22	1,70	10,13	92,13	98,30	89,86	88,22	99,26	0,74	1,38
Desejado	100	0	0	100	100	100	100	100	0	0

Referências

1. Borghesan DHP, Baraúna M, Pelloso SM, Carvalho MDB. Auto-exame das mamas: conhecimento e prática entre profissionais da área da saúde de uma instituição pública. *Acta Sci, Health Sci.* 200;25(1):103-13.
2. Louveira MH, Souza IRMF, Castro IM, Elias S, Szejnfeld J, Kemp C. Avaliação e classificação ultra-sonográfica dos nódulos mamários: revisão da literatura e aspectos atuais. *Revista Imagem.* 2003;23(2):123-28.
3. Kemp C, Elias S, Borelli K, Narvaiza DG, Kemp CGM, Schor AP. Punção aspirativa por agulha fina orientada por ultra-sonografia em lesões não-palpáveis. *Rev Bras Ginecol Obstet.* 2001;23(5):321-7.
4. Stavros AT. New advances in breast ultrasound: computer-aided detection. *Ultrasound Clin.* 2009;4(3):285-90.
5. Drukker K, Pesce LL, Giger ML. Repeatability and classifier bias in computer-aided diagnosis for breast ultrasound. *Med Phys.* 2010;37(6):2659-69.
6. Vieira SL. Desenvolvimento de um "phantom" para treinamento de biópsia de mama guiada por ultra-som. [Dissertação de Mestrado]. Ribeirão Preto: Faculdade de Filosofia Ciências e Letras de Ribeirão Preto, Universidade de São Paulo; 2005.
7. Stemberg D. Desenvolvimento de um simulador mamográfico para avaliação de esquemas CAD. [Dissertação de Mestrado]. São Carlos: Escola de Engenharia de São Carlos, Universidade de São Paulo; 2010.
8. Marcomini KD, Schiabel H. Nodules Segmentation in Breast Ultrasound using the Artificial Neural Network Self-Organizing Map. In: *World Congress on Engineering (2012 International Conference of Signal and Image Engineering)*; 2012; Londres; UK. *Proceedings of World Congress on Engineering 2012, v. II.* p. 1152-5, jul. 2012a.
9. Zhu C, Ni J, Li Y, Gu G. General Tendencies in Segmentation of Medical Ultrasound Images. In: *IEEE Fourth International Conference on Internet Computing for Science and Engineering*, Harbin, China, *Proceedings of ICICSE'2009*, p. 113-117, dez. 2009b.
10. Pei C, Wang C, Xu S. Segmentation of the breast region in mammograms using marker-controlled watershed transform. In: *2nd International Conference on Information Science and Engineering*, Hangzhou, China, *Proceedings of ICISE'2010*, p. 2371-2374, dez. 2010.
11. Wirth M, Nikitenko D, Lyon J. Segmentation of the breast region in mammograms using a rule-based fuzzy reasoning algorithm. *ICGST-GVIP Journal.* 2005;5(2):45-54.
12. Fawcett T. An introduction to ROC analysis. *Pattern Recognition Letters.* 2006;27(8):861-74.
13. Boaventura IAG. Números fuzzy em processamento de imagens digitais e suas aplicações na detecção de borda. [Tese de Doutorado], São Carlos: Escola de Engenharia de São Carlos, Universidade de São Paulo; 2010.