

Aplicação de contornos ativos para a segmentação de nódulos em imagens de ultrassonografia da mama

Application of active contours for nodules segmentation in breast ultrasound images

Karem D. Marcomini¹, Homero Schiabel¹ e Luciana B. Verçosa¹

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

Resumo

Ultrassom é uma ferramenta de diagnóstico muito útil na distinção de massas benignas e malignas da mama, além de proporcionar avaliação mais detalhada em mamas densas. Diante da subjetividade na interpretação das imagens, os esquemas de diagnóstico auxiliado por computador têm oferecido alto desempenho, fornecendo ao médico uma segunda opinião de forma mais precisa e confiável. Com esse intuito, propomos a aplicação de um método de segmentação dado de forma automática, por meio da técnica de contorno ativo, para fornecer precisamente informações relativas à localização e determinação dos limites de possíveis achados suspeitos em exames de ultrassonografia da mama. Os testes de segmentação foram aplicados num total de 50 imagens clínicas, contendo algum tipo de lesão evidenciada em exames de rotina. A partir do contorno, o radiologista poderia ter maior compreensão dos aspectos morfológicos, possibilitando, portanto, um diagnóstico mais conciso. Com a finalidade de verificar a exatidão dos limites demarcados pela segmentação automática, as segmentações foram comparadas por meio de métricas de avaliação quantitativa com a área delimitada manualmente por uma radiologista. Os resultados obtidos com os valores médios revelaram taxas de aproximadamente 92% na acurácia, 73% em sensibilidade e 94% referente ao valor preditivo positivo.

Palavras-chave: câncer de mama, ultrassom, segmentação, contorno ativo, avaliação.

Abstract

Ultrasound is a useful diagnostic tool to distinguish benign from malignant masses of the breast, providing more detailed evaluation in dense breasts. Due to the subjectivity in the images interpretation, computer-aid diagnosis schemes have offered high performance, providing a second opinion more accurately and reliably to the physician. Thus, we propose to apply an automatic segmentation method by using the technique of active contour, which could provide precise information on localization and determination of the limits of possible suspicious findings in breast ultrasound exams. The segmentation was applied to 50 clinical images containing some type of lesions evidenced in routine exams. From the contour, the radiologist could have a greater knowledge of the morphological features, which allows a more accurate diagnosis. In order to verify the accuracy of the edges obtained by segmentation technique, the results were compared with the area manually delineated by a radiologist by using quantitative evaluation metrics. The results showed average rates of approximately 92% in accuracy, 73% in sensitivity and 94% relative to the positive predictive value.

Keywords: breast cancer, ultrasound, segmentation, active contour, evaluation.

Introdução

O câncer de mama é um dos maiores problemas de saúde pública, por ser uma das doenças de maior impacto devido à elevada e preocupante incidência, enormes custos sociais, elevadas consequências físicas e psicológicas, altas taxas de mortalidade. Este tipo de neoplasia ocupa o primeiro lugar entre os cânceres mais incidentes em mulheres. Conforme a previsão do Instituto Nacional do Câncer (INCA)¹ para 2012, estima-se a ocorrência de

52.680 novos casos no Brasil. Com isso, uma das maiores preocupações concentra-se na detecção precoce de lesões na mama, fator esse de extrema importância, pois permite o aumento das chances de sobrevivência das pacientes e possibilita a realização de tratamentos menos agressivos (redução da mastectomia)².

Atualmente, o instrumento mais efetivo para o diagnóstico precoce é a mamografia, principal modalidade por imagem para avaliação de alterações clínicas na mama^{3,4}. No entanto, mesmo apresentando alta sensibilidade na

Autor correspondente: Karem Daiane Marcomini – Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos (EESC) da Universidade de São Paulo (USP) – Avenida Trabalhador São-carlense, 400 – CEP: 13566-590 – São Carlos (SP), Brasil – Email: karem.dm@usp.br

detecção, sua especificidade é baixa em se tratando de casos de mamas densas. Dessa forma, são altas as chances de um falso-positivo levar a biópsias desnecessárias e, por conseguinte, é necessário investigar modalidades alternativas que aumentem a precisão diagnóstica e auxiliem a detecção precoce no exame mamário.

Com os avanços tecnológicos, a ultrassonografia vem despontando como valioso complemento diagnóstico para a mamografia. Atualmente, é a principal técnica de triagem adjunta à mamografia⁴, com eficácia de 95–100% na diferenciação de nódulos sólidos e císticos e proporcionando a redução de 25–35% no número de biópsias desnecessárias⁵, além de permitir a avaliação em pacientes jovens e em mamas densas. No entanto, não deve substituir a mamografia, devido a suas limitações na detecção e caracterização de calcificações, distorções arquiteturais e nódulos localizados em áreas nas quais predominem tecido adiposo³.

Com a finalidade de combater o agravamento clínico da doença, têm surgido sistemas computacionais úteis no auxílio ao diagnóstico, os quais permitem identificar e caracterizar anormalidades encontradas em um exame de imagem médica, do qual advém o termo CAD (*Computer-Aided Diagnosis*). Contudo, um dos maiores problemas desse tipo de sistema, quando consideradas imagens de ultrassom, advém da baixa qualidade da imagem, influenciada pelo *speckle*, e o baixo contraste entre as áreas de interesse, que dificulta a segmentação (etapa essencial do processamento). A elevada taxa de insucesso na determinação dos limites e na caracterização do tecido se deve, frequentemente, a falha na segmentação⁶. Em virtude disso, este trabalho investiga um algoritmo que permite a detecção e delimitação, de maneira automática, de possíveis achados ultrassonográficos, bem como a eficiência do método apresentado, comparando-o com o delineamento manual realizado por um radiologista.

Material e Métodos

Para a realização dos presentes testes, houve necessidade da formação de um banco de imagens ultrassonográficas de mama, que acabou consistindo em 83 imagens clínicas adquiridas durante procedimentos de rotina para o diagnóstico da mama, procedentes do Centro Integrado de Diagnóstico por Imagem, na Irmandade Santa Casa da Misericórdia de São Carlos – São Paulo.

A aquisição foi realizada pelo aparelho Siemens G50, com transdutor de matriz linear de 7.5 MHz modo-B. A imagem foi capturada com sinal de vídeo de 8 bits de resolução (256 níveis de cinza).

Com o auxílio do software ImageJ 1.45, um radiologista determinou a localização de uma ou mais massas suspeitas, presentes em cada imagem, e realizou os recortes que julgou necessários. Esses recortes, ou regiões de interesse (ROIs – *Regions of Interest*), possuem

formato retangular e incluem a lesão e os tecidos adjacentes. No total, foram determinadas 50 ROIs.

Depois de obtidas as ROIs, foram aplicadas técnicas de processamento digital, utilizando o ambiente de desenvolvimento MATLAB 7.11.0 (2010b), com a finalidade de identificar a região que possui algum tipo de achado suspeito e delimitar, de forma mais precisa possível, seus limites.

Dessa forma, efetuou-se então a segmentação, utilizando a técnica de contorno ativo, também chamada de *snakes*, cujo objetivo é minimizar a energia através da deformação de um contorno inicial em um conjunto de forças internas e externas^{7,8}. A energia interna depende da forma do contorno e sua localização; já a energia externa depende do gradiente da imagem^{9,10}.

A energia funcional é a adição de uma função de energia interna do contorno (E_{int}) e a energia externa da imagem (E_{ext}) no conjunto de pontos ($v(s)$) que compõem o contorno ativo nas coordenadas x e y desses pontos¹¹. A energia funcional (E_{snake}) é mais bem exemplificada na Equação 1.

$$E_{snake}(v(s)) = \int_{s=0}^1 \{E_{int}(v(s)) + E_{ext}(v(s))\} ds \quad (1)$$

Ao substituir a função da energia interna da imagem, temos a soma de diferenciais de primeira e segunda ordem para cada ponto procurado na vizinhança local do ponto de contorno selecionado. Já a energia externa remete a características de borda¹¹. Portanto, a Equação 1 pode ser reescrita na Equação 2.

$$E_{snake} = \int_{s=0}^1 \left\{ \left[\alpha(s) \left| \frac{dv(s)}{ds} \right| + \beta(s) \left| \frac{d^2v(s)}{ds^2} \right|^2 \right] + \left(-|\nabla G_\sigma(x,y)| I(x,y)^2 \right) \right\} ds \quad (2)$$

O contorno é definido parametricamente como $v(s)=[x(s),y(s)]$ onde $s \in [0,1]$ é o comprimento do arco normalizado ao longo do contorno. A energia elástica de alongamento é controlada pelo espaçamento de ponto $\alpha(s)$, que rege a continuidade do contorno (espaçamento dos pontos representados — quanto mais alto for seu valor, mais espaçados serão os pontos representados). Já a energia de curvatura é controlada por $\beta(s)$, o qual, se representado por alto valor, implica formas com cantos mais agudos, enquanto baixo valor remete a contornos mais suaves⁹⁻¹¹.

A energia externa atrai o *snake* para característica de baixo nível, como brilho ou informações referentes à borda¹¹. Isso é dado pelo nível de cinza da imagem ($I(x,y)$) e pela função de borramento ($G_\sigma(x,y)$) perpendicular à orientação do contorno nas coordenadas (x,y) ¹⁰.

O fluxo do vetor gradiente, obtido por meio do cálculo de um campo de forças, conduz o contorno ativo ao alongamento e flexão, mediante a aplicação das equações apresentadas, criando um mapa de borda da imagem. A Figura 1 representa o exemplo dado¹², da evolução do contorno ativo após algumas interações, quando aplicado a um objeto ruidoso.

O contorno ativo foi desenvolvido com base no algoritmo apresentado¹³, em que o contorno inicial é dado por meio de um retângulo localizado no centro da imagem, cuja dimensão varia de acordo com o tamanho da imagem, pois significa que, quanto maior for a ROI, maior deverá ser o nódulo presente. O tamanho do retângulo utilizado aqui foi de 60% da quantidade de *pixels* correspondentes à altura e largura, ou seja, para uma imagem de 160x200 *pixels*, o retângulo apresenta-se disposto em seu centro e deverá corresponder a 96x120 *pixels*.

Após definido o tamanho, o contorno tende a ser alongado ou flexionado, de acordo com a similaridade encontrada na região. Para que fosse possível obter maior adequação do contorno ao objeto, o processo se constituiu de mil interações, com energia de curvatura equivalente a 0,005.

Após a definição dos limites do objeto, foi aplicado um pós-processamento, buscando eliminar os *pixels* indesejados. Para isso, levou-se em consideração que cada ROI deveria possuir apenas uma lesão, e que esta seria a região com maior área (região em branco). A partir daí, seriam analisados todos os componentes conectados. Caso o *pixel* vizinho ao *pixel* sob análise possuísse conectividade com a região de maior área, ele seria mantido na imagem resultante; caso contrário, seria considerado como ruído e removido. Também foi verificada a presença de vales internos na região assinalada: em os havendo, esses *pixels* seriam adicionados à área segmentada, formando, dessa forma, uma única região.

Buscando medir quantitativamente a precisão do método de segmentação proposto, além de reduzir a subjetividade visual da análise, foram utilizadas algumas métricas. Uma radiologista traçou manualmente o contorno sobre a massa suspeita. Essa área é denominada *ground truth* (GT), e foi comparada com a obtida automaticamente pelo segmentador proposto. Caso a região segmentada coincidissem com o GT, era denominada como verdadeiro-positivo (VP); se o classificador, porém, a considerasse como região negativa, contava-se como falso-positivo (FP). Por outro lado, se os *pixels* não pertenciam ao GT e assim foram classificados, contavam como verdadeiros-negativos (VN); por fim, estando presentes na segmentação (incorreta, portanto), foram definidos como resultados falsos-negativos (FN). A partir disso, derivaram-se três métricas de avaliação: acurácia, sensibilidade e valor preditivo positivo (VPP)¹⁴.

A acurácia mede a proporção de classificações corretas em relação ao total de elementos classificados, conforme Equação 3.

$$\text{Acurácia} = \frac{(VP+VN)}{(VP+VN+FP+FN)} \quad (3)$$

A sensibilidade representa a proporção de elementos apresentados no GT que foram identificados corretamente, conforme Equação 4.

$$\text{Sensibilidade} = \frac{VP}{(VP+FN)} \quad (4)$$

Por fim, foi calculado o VPP, o qual mede a proporção de *pixels* da região segmentada que foi classificada corretamente, exibida na Equação 5.

$$\text{VPP} = \frac{VP}{(VP+FP)} \quad (5)$$

Resultados

As ROIs foram submetidas à técnica de segmentação por contorno ativo, objetivando a localização automática e delimitação precisa dos limites das massas suspeitas apresentadas. A Figura 2 destaca uma lesão suspeita em uma ROI clínica de ultrassonografia da mama, seguida pela segmentação, aplicação do pós-processamento e, por fim, sobreposição do contorno sobre a imagem original.

Buscando minimizar a subjetividade dada pela inspeção visual promovida por especialistas, foram utilizadas métricas para avaliar o resultado de forma quantitativa. Este processo verificou a exatidão da segmentação nas 50 imagens selecionadas, nas quais a radiologista traçou manualmente o contorno de cada massa suspeita. A partir do contorno, pôde ser demarcada sua área (a Figura 3 apresenta o traço da especialista e a determinação da área), a qual posteriormente foi comparada com a adquirida pelo segmentador proposto.

O resultado obtido com a aplicação das métricas comparativas é exposto na Tabela 1, que exhibe os valores médios percentuais obtidos por cada método de avaliação.

Tabela 1. Métricas de avaliação da segmentação.

	Acurácia	Sensibilidade	VPP
Contorno Ativo	91,76%	72,59%	93,93%




Figura 1. Curso evolutivo do contorno ativo.

Discussão e Conclusões

A segmentação é uma difícil tarefa em imagens de ultrassom devido à presença do ruído *speckle*, que degrada significativamente a sua qualidade e dificulta a discriminação de alguns detalhes. Por isso, a grande maioria dos métodos de segmentação apresentados para realizar tal atividade é aplicada após o emprego de técnicas de pré-processamento, com a finalidade de tentar minimizar o ruído. O uso desse procedimento torna a imagem de saída mais uniforme para que possa, então, ser submetida à segmentação.

Alguns testes de pré-processamento foram aplicados. Contudo, ao utilizar o contorno ativo para segmentar essas imagens, a borda da lesão deixava de ser reconhecida, na maioria dos casos. Isso se deve ao fato de que a imagem passava a apresentar fronteiras mais suaves e níveis de cinza mais uniformes entre o objeto e o fundo, tornando o método não tão eficiente quanto o desejado. Diante disso, a técnica passou a ser aplicada diretamente sobre a ROI de entrada, ou seja, com ausência de qualquer tipo de processamento inicial. Isso fez com que não ocorressem distorções quanto aos limites da massa suspeita, bem como em seu aspecto morfológico. Contudo,

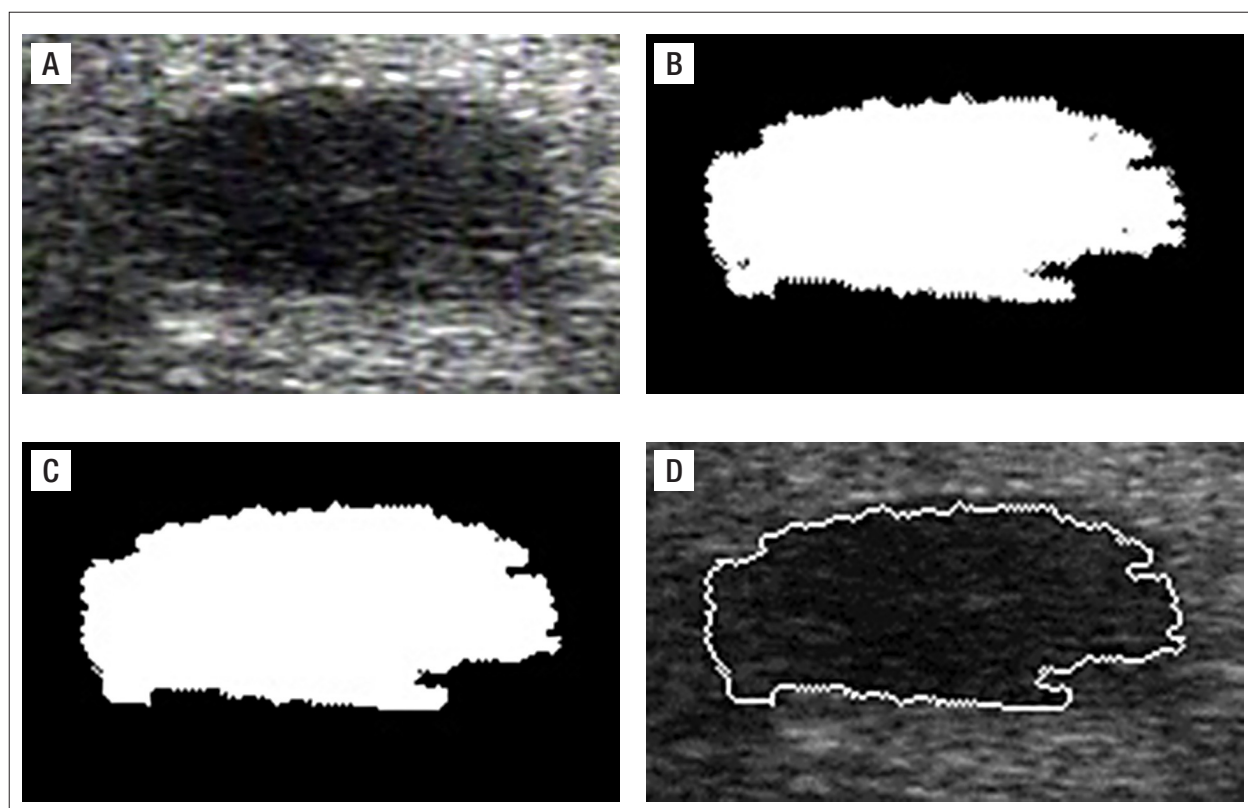


Figura 2. Imagem de entrada (A), aplicação da segmentação (B) e remoção das regiões adjacentes (C); em seguida, o contorno é sobreposto à imagem original (D).




Figura 3. Delimitação do contorno pela especialista (A) e extração da área da lesão demarcada (B).

a imagem ficou mais suscetível ao ruído, o que permitiu a representação de bordas mais irregulares e espiculadas.

A grande dificuldade encontrada no método apresentado dá-se na escolha do tamanho do retângulo, o qual dará início ao *snake*. Todavia, considera-se que a dimensão escolhida foi adequada para o processo retratado, além de permitir que ele ocorra automaticamente. Outro problema apresentado se deve à complexidade algorítmica, na qual o processo decorre do uso de muitas operações numéricas, e requer uma grande quantidade de interações, até atingir a convergência dos dados. Com isso, é uma técnica que exige um alto custo computacional e torna o processo relativamente lento, levando em torno de 30 segundos para processar cada ROI.

O resultado apresentado pela comparação da imagem delimitada pela radiologista com a obtida pelo segmentador apresentou-se satisfatório e, com isso, verifica-se que a segmentação por contorno ativo desponta como uma interessante ferramenta no processo de segmentação de massas mamárias em imagens clínicas ultrassonográficas digitais.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo apoio financeiro; e ao Hospital Irmandade Santa Casa da Misericórdia de São Carlos, pelo fornecimento das imagens.

Referências

1. Instituto Nacional do Câncer (INCA). Estimativa 2012: incidência do câncer no Brasil. Rio de Janeiro: Inca; 2011.
2. Yap MH, Edirisingue EA, Bez HE. Object boundary detection in ultrasound images. IEEE 3rd Canadian Conference on Computer and Robot Vision 2006. Proceedings of CRV'06; 2005 Jun; Quebec; Canadá. p. 53-8.
3. Chala LF, Barros N. Avaliação das mamas com métodos de imagem. Radiologia Brasileira. 2007;40(1):4-6.
4. Yu D, Lee S, Lee JW, Seunghwan K. Automatic lesion detection and segmentation algorithm on 2D breast ultrasound images. Medical Imaging 2011: Computer-Aided Diagnosis. Proceedings of SPIE 2011, 2011 Feb; Orlando, Flórida, 7963:79631Y-1–79631Y-6.
5. Louveira MH, Souza LRMF, Castro IM, Elias S, Szejnfeld J, Kemp C. Avaliação e classificação ultrassonográfica dos nódulos mamários: revisão da literatura e aspectos atuais. Revista Imagem. 2003;23(2):123-8.
6. Huang YL, Chen DR, Jiang YR, Kuo SJ, Wu HK, Moon WK. Computer-aided diagnosis using morphological features for classifying breast lesions on ultrasound. Ultrasound in Obstetrics and Gynecology. 2008;32:565-72.
7. Aléman-Flores M, Aléman-Flores P, Álvarez-León L, Esteban-Sánchez MB, Fuentes-Pavón R, Santana-Montesdeoca JM. Semiautomatic snake-based segmentation of solid breast nodules on ultrasonography. In: EUROCAST 2005: Lecture Notes in Computer Science (LNCS). Springer: Heidelberg. 2005;6136:39-45.
8. Cvanarova M, Albregtsen F, Brabrand K, Samset E. Segmentation of ultrasound images of liver tumors applying snake algorithms and GVF. In: International Congress Series, 2005, Berlin. Proceedings of the 19th International Congress and Exhibition 2005;1281:218-23.
9. Rafiee A, Salimi A, Roosta AR. A novel prostate segmentation algorithm in TRUS images". World Academy of Science. Engineering and Technology. 2008;45:120-4.
10. Liu W, Zagzebski JA, Varghese T, Dyer CR, Techavipoo U, Hall T.J. Segmentation of elastographic images using a coarse-to-fine active contour model. Ultrasound. In: Medicine and Biology. 2006;32(3):397-408.
11. Nixon M, Aguado A. Feature extraction and image processing. 2. ed. San Diego: Academic Press, 2008.
12. Zhu L, Fan B, Tang Y. Two-step active contour method based on gradient flow. Industrial Robot: An International Journal. 2010;37(4):364-71.
13. Sandhu R, Georgiou T, Tannenbaum A. A new distribution metric for image segmentation. Medical Imaging 2008: Image Processing. Proceedings of the SPIE 2008; 2008 Feb; Marseille; França, v. 6914, p. 691404-1–691404-9.
14. 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 da Universidade de São Paulo; 2010.