
Método de investigação de possíveis áreas com EM do SNC em uma IRM a partir do método de segmentação Fuzzy Conectedness aliado à Binarização Otsu

A. L. C. Arruda*, H. A. de Amorim*, M. C. Moraes*

*Departamento de Ciência e Tecnologia/Instituto de Ciência e Tecnologia da UNIFESP,
São José dos Campos, Brasil

a.arruda@unifesp.br

Abstract

Multiple sclerosis (MS) is a disease that affects the central nervous system and affects thousands of people worldwide. One way to investigate this disease is by Magnetic Resonance Imaging. But the analysis of this image is still very subjective about MS. Therefore, we propose a segmentation method for MRI images. The method consists of two steps: Fuzzy Conectedness, which is the MS area is segmented, and the first phase object Binarization. The combination of these methods have shown promising results with VP near of 90%; PF under of 5% and OP over 90%. Consequently, may prove to be an alternative to MS segmentation and evaluation.

Keywords: *Sclerosis, image, segmentation, object*

Introdução

Estima-se que aproximadamente 300 a 350 mil pessoas sejam portadoras de Esclerose Múltipla (EM) nos Estados Unidos e 2,5 milhões em todo o mundo [1]. A EM é uma doença inflamatória crônica, degenerativa, desmielinizante e autoimune que acomete preferencialmente adultos jovens (25 a 35 anos) [2]. Supõe-se que seja caracterizada pela produção de anticorpos que degradam a bainha de mielina dos axônios [3].

A EM é definida pelo aparecimento de lesões de massa branca no sistema nervoso central (SNC), visualizadas no exame de imagem de ressonância magnética (IRM) [3]. Além da destruição da mielina, ocorrem também danos ao axônio e nas células das glias, juntamente com presença de um infiltrado inflamatório constituído por células de defesa como linfócitos e macrófagos [3].

Uma das ferramentas mais utilizadas para investigação dessa doença é a IRM [4]. Porém, apesar de ser uma ferramenta robusta de coleta de dados, a IRM fornece apenas informação subjetiva acerca da EM. Por

isso a técnica de segmentação é uma técnica importante na análise quantitativa da doença.

Segmentação é o processo de dividir uma imagem em múltiplas regiões ou objetos relacionados. O objetivo é simplificar ou mudar a representação de uma imagem para facilitar a sua análise e consequente terapia ou intervenção [5]. Um dos objetivos da segmentação de IRM é determinar áreas e volumes de órgãos, tecidos e lesões de um paciente. A análise da imagem com o acompanhamento ao decorrer do tempo pode ajudar no diagnóstico, prognóstico e tratamento de pacientes. Todavia, uma segmentação manual do lobo temporal médio delonga 75 minutos, aproximadamente, por imagem [6].

Algumas técnicas de segmentação nessa área são: pós-processamento baseado na segmentação automática de imagens para eliminar estruturas aprimorantes, como o complexo coróideo [7], segmentação local derivada das operações morfológicas de abertura e reconstrução para identificação de lesões e não lesões [8] e utilização de Fuzzy Conectedness [9]. No entanto, uma das maiores dificuldades encontradas ao aplicar técnicas de segmentação em IRM é a heterogeneidade dos níveis de intensidade observados em tecidos de composição idêntica. Isso é causado por variações nas sensibilidades da instrumentação usada na obtenção de imagens de ressonância magnética [10].

Dessa maneira, neste artigo é apresentada uma proposta alternativa de investigação aliada à IRM utilizando o método de segmentação **Fuzzy Conectedness** [12] e **Binarização**.

Materiais e Métodos

O presente artigo tem como objetivo demonstrar a viabilidade do método proposto na segmentação semi-automática de IRM de EM. E de forma complementar o resultado das segmentações serão confrontados com seus *Gold Standard* feitos manualmente por especialistas. A metodologia é composta por duas partes principais (Figura 1. A primeira parte consiste em selecionar uma região da Imagem Original (*I_o*) que apresenta EM para ser

empregado o método **Fuzzy Connectedness**. A segunda é fundamentada pela **Binarização** da **matriz de conectividade** criada na primeira fase, resultando no objeto binarizado e segmentado (O_s). Finalmente, a imagem segmentada é avaliada através de 3 parâmetros de acurácia propostos por UDUPA [11].

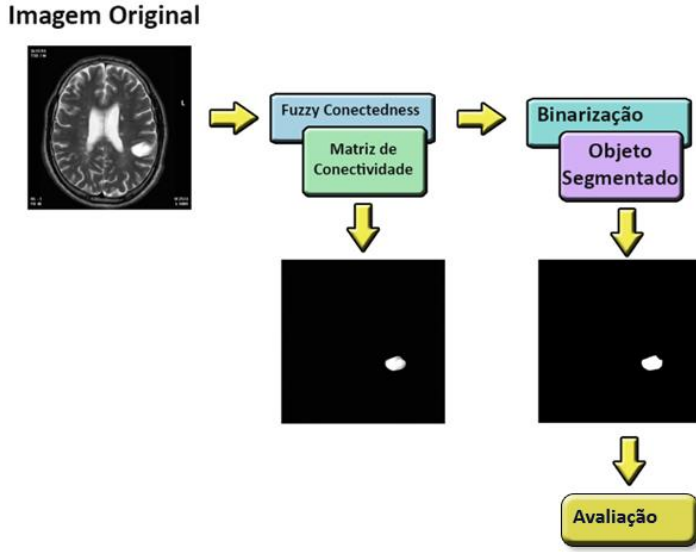


Figura 1: Diagrama de materiais e métodos

Fuzzy Connectedness




Figura 2: (a) Imagem original – I_o ; (b) Região de interesse selecionada; (c) Matriz de Conectividade obtida na primeira etapa do método; (d) Objeto binarizado e segmentado (O_s), resultado da segunda etapa do método; (e) Comparação entre I_o e O_s ; (f) *Gold Standard* de I_o .

Como a área de EM em uma IRM possui padrões particulares de intensidade e variabilidade, a primeira etapa é selecionar a região na qual será aplicada o método **Fuzzy Connectedness**. A Figura 2(a) mostra uma IRM utilizada

nesse projeto e a Figura 2(b) indica a região selecionada para ser segmentada.

Quando a região de interesse é selecionada, uma semente é “plantada” no pixel central dessa região. Após isso, é calculado a média e desvio padrão da Intensidade (μ_I, σ_I) e Homogeneidade (μ_H, σ_H) da área selecionada [12] através de:

$$\mu_I = \text{mean2}(0.5|I(\text{semente}) + I(\text{região})),$$

$$\sigma_I = \text{std2}(0.5|I(\text{semente}) + I(\text{região})),$$

$$\mu_H = \text{mean2}(0.5|I(\text{semente}) - I(\text{região})),$$

$$\sigma_H = \text{std2}(0.5|I(\text{semente}) - I(\text{região})),$$

nos quais mean2 e std2 são a média e desvio padrão 2D, $I(\text{semente})$ é o valor de I_o nas coordenadas da semente plantada e $I(\text{região})$ são os valores de I_o na região selecionada. Nesta etapa de inicialização, a semente possui afinidade e conectividade iguais a 1 com ela mesma e 0 com os outros pixels porque ainda serão analisados.

A próxima etapa é computar a afinidade pontual μ_α da semente com os quatro vizinhos. Para isso, são calculados os valores de Homogeneidade e Intensidade de cada pixel com a semente atual através de:

$$\text{Hom}(\text{pix}) = e^{-\frac{1}{2} \left(\frac{|I(\text{semente}) - I(\text{pix})| - \mu_H}{\sigma_H} \right)^2},$$

$$\text{Int}(\text{pix}) = e^{-\frac{1}{2} \left(\frac{0.5[I(\text{semente}) + I(\text{pix})] - \mu_I}{\sigma_I} \right)^2},$$

no qual $I(\text{pix})$ é o valor de I_o na posição do pixel analisado. Consequentemente, a matriz de afinidade entre a semente atual e os pixels analisados obtidos é obtida através de:

$$\mu_\alpha = w_h \times \text{Hom}(\text{pix}) + w_i \times \text{Int}(\text{pix}),$$

nos quais w_h e w_i são os pesos complementares atribuídos à homogeneidade e intensidade que são respectivamente iguais 0.75 e 0.25. Esses valores foram encontrados empiricamente visando o valor que fornecia o melhor resultado de segmentação.

Posteriormente, a afinidade do caminho μ_k , entre a semente e os outros pixels de I_o , é definida por:

$$\mu_k(\text{pix}) = \min[\mu_\alpha(\text{pix}), \mu_K(\text{seed})],$$

no qual $\mu_\alpha(\text{pix})$ é o valor da afinidade pontual do pixel com a semente e $\mu_K(\text{seed})$ é o valor da conectividade da semente atual.

Finalmente, a matriz de Conectividade μ_K é atualizada por:

$$\mu_K(\text{pix}) = \max[\mu_K(\text{pix}), \mu_k(\text{pix})].$$

Uma nova semente é definida dinamicamente e o processo se repete. Para não realizar essa análise na imagem integralmente, foi estabelecido um limiar de conectividade ($L_k = 0.63$, determinado através de testes) com o intuito de diminuir o custo computacional e não avaliar regiões que provavelmente não apresentam EM. Ao final dessa etapa, é criada então a matriz de conectividade exibida na Figura 2(c).

Binarização

Por último, para poder quantificar a região extraída e realizar a binarização da matriz de conectividade, resultando no objeto segmentado (Os) Figura 2(d), foi utilizado o método de **Binarização Otsu** [13]. Otsu foi escolhido, pois como a matriz de conectividade pode produzir variações em seus valores dependendo da imagem, um limiar fixo poderia não ser adequado para a matriz de conectividade. A Figura 2(e) mostra o objeto segmentado na imagem original.

Resultados

A avaliação foi realizada em 14 imagens desafiadoras obtidas em um banco de IRM online do Departamento de Ciência da Computação da Universidade de Cyprus (*eHealth Laboratory*) [14]. O resultado de 3 imagens pode ser observado na Figura 3.




Figura 3: Segmentação obtida através do método proposto (Direita). Segmentação manual (Esquerda).

O custo computacional foi baseado em um computador ORO com processador Intel Core i7, 3,50 GHz, 16 GB de RAM, Windows 8.1 de arquitetura de 64-bit do Windows e o software MATLAB. O tempo nas avaliações foi de aproximadamente $2,13 \pm 1,76$ segundos. Os parâmetros de acurácia utilizados para esta avaliação foram verdadeiro positivo (VP), falso positivo (FP) e falso negativo (FN) [11], além de precisão inter-observador (PO). A média e desvio padrão desses valores desses parâmetros para as 14 imagens avaliadas estão contidos na Tabela 1.

Tabela 1 – Parâmetros avaliados no projeto.

VP (%)	FP (%)	FN (%)	PO (%)
87,68	4,42	12,38	90,54
$\pm 7,23$	$\pm 3,82$	$\pm 7,52$	$\pm 9,37$

Com os valores de VP próximo de 90% e FP menor que 5%, é possível observar que o método proposto mostrou-se extremamente promissor quanto a sua alta acurácia, até mesmo com diferentes observadores realizando a segmentação de acordo com o valor extremamente alto de PO. Dessa forma, por ser semi-automático, a avaliação e determinação de possíveis áreas com EM em uma IRM de um paciente será rápida e variará muito pouco com diferentes especialistas.

Discussão e Conclusão

Um dos mecanismos mais empregados para exame de EM é a IRM. No entanto, esse tipo de imagem fornece informação subjetiva acerca da EM ao especialista que analisa a imagem. Dessa forma, o método de segmentação de imagem é essencial para o diagnóstico dessa doença.

O método proposto nesse trabalho é composto por duas partes principais (Figura 1). A primeira parte consiste em aplicar **Fuzzy Connectedness** em uma região de interesse com EM. A segunda é a **Binarização** do resultado da primeira parte, gerando o objeto binarizado e segmentado. Para avaliar **Os** foram empregados 3 parâmetros propostos por UDUPA[11].

Os resultados desse projeto são estimulantes, pois os valores de VP, FP e FN computados foram de acordo com o esperado para versão inicial do trabalho.

Com esse trabalho algumas contribuições na área de pesquisa de segmentação de EM foram criadas: (i) utilização de **Fuzzy Connectedness** para esse tipo de

investigação, (ii) definição dos melhores pesos para computar afinidade com pesos fixos.

Embora os resultados tenham sido representativos, trabalhos futuros visarão a combinação de parâmetros para aumentar a precisão e exatidão do método proposto. Os valores dos pesos de intensidade, homogeneidade e limiar de conectividade serão melhor calibrados e diferentes funções de afinidade serão testadas. Adicionalmente, para corrigir a falta de informação (elevada similaridade entre diferentes tecidos) e presença de ruído, será incluído uma etapa de pós processamento com morfologia matemática binária.

Como continuação desse projeto, espera-se obter parceria com banco de dados de EM, com o intuito de garantir maior número de imagens para serem avaliadas. Deseja-se também gerar uma imagem tridimensional do cérebro de um paciente com possíveis locais afetados por EM, podendo ajudar no diagnóstico e avaliação de áreas lesionadas.

Agradecimentos

LABPIB Laboratório de Processamento de Imagens Biomédicas do Instituto de Ciência e Tecnologia da UNIFESP (ICT-UNIFESP)

Conselho Nacional de Desenvolvimento Científico e Tecnológico (**CNPq**)

E-Health Laboratory, Computer Science Department @ UCY.

Referências

[1] SILVA, Décio Fragata da. ESCLEROSE MÚLTIPLA: IMUNOPATOLOGIA, DIAGNÓSTICO E TRATAMENTO. Interfaces Científicas - Saúde e Ambiente, Aracaju, v. 3, n. 2, p.81-96, jun. 2014.

[2] TERAPIA DE CÉLULAS TRONCO NA ESCLEROSE MÚLTIPLA Ana Lina Scholz; Sayonara Rangel Oliveira.

[3] A IMPORTÂNCIA DA RESSONÂNCIA MAGNÉTICA NO DIAGNOSTICO DA ESCLEROSE MÚLTIPLA. Jeniffer Vieira de Almeida

[4] MORALES, Rogério de Rizo et al. QUALIDADE DE VIDA EM PORTADORES DE ESCLEROSE MÚLTIPLA. Arq Neuropsiquiatr, Uberlândia, v. 2, n. 65, p.454-460, fev. 2007.

[5] WU, Ying et al. Automated segmentation of multiple sclerosis lesion subtypes with multichannel

MRI. Neuroimage: Elsevier, Evanston, v. 1, n. 6, p.1205-1225, jun. 2006.

[6] SEIXAS, Flávio L., MARTINS, Anita, STILBEN, Arthur R., ASSUMPCÃO, Rafael. AVALIAÇÃO DOS MÉTODOS PARA A SEGMENTAÇÃO AUTOMÁTICA DOS TECIDOS DO ENCÉFALO EM RESSONÂNCIA. Brain. II. 11 – 15. 2008.

[7] BEDELL, B.J., NARAYANA, P.A., 1998. Automatic segmentation of gadolinium enhanced multiple sclerosis lesions. Magn. Reson. Med. 39, 935 – 940.

[8] HE, R., NARAYANA, P.A., 2002. Automatic delineation of Gd enhancements on magnetic resonance images in multiple sclerosis. Med. Phys. 29, 1536 – 1546.

[9] SAMARASEKERA, S., UDUPA, J.K., MIKI, Y., WEI, L., GROSSMAN, R.I., 1997. A new computer-assisted method for the quantification of enhancing lesions in multiple sclerosis. J. Comput. Assist. Tomogr. 21, 145 – 151.

[10] JOHNSTON, B. et al. Segmentation of Multiple Sclerosis Lesions U I in Intensity Corrected Multispectral MRI. Ieee: TRANSACTIONS ON MEDICAL IMAGING, Estados Unidos, v. 2, n. 15, p.154-169, abr. 1996.

[11] UDUPA, JK. et al. A framework for evaluating image segmentation algorithms. Comput Med Imaging Graph 2006, 30(2):75–87. 16.

[12] UDUPA, JK, SAMASEKERA S: Fuzzy connectedness and object definition: theory, algorithms, and applications in image segmentation. Graphical Models and Image Processing 1996, 58(3):246–261.

[13] OTSU N. A threshold selection method from gray-level histograms. IEEE Trans Syst Man Cybern C Appl Rev 1979;9:62–66.

[14] E-Health Laboratory, Computer Science Department @ UCY. <http://www.medinfo.cs.ucy.ac.cy>