

S.A.I.C: Segmentação Automática de Imagens do Cérebro

FRANÇOIS LANGEVIN²
JACQUES FACON¹

²UTC-CIMA - Université de Technologie de Compiègne
Centre d'Imagerie Médicale Avancé
Royallieu, BP 349
60206 Compiègne Cedex, França

¹CEFET-PR - Centro Federal de Educação Tecnológica do Paraná
CPGEI - Curso de Pós-Graduação em Engenharia Elétrica e Informática Industrial
Av. 7 de setembro, 3165
80230-901 Curitiba-PR, Brasil
b.facon@cefet.anpr.br

Abstract. Computed tomography and magnetic resonance imaging provide complementary characteristic and diagnostic information. This paper discusses the automatic segmentation of meaningful regions of the human brain. The images of the human brain present many details with small contrasts. We propose a hybrid method where the segmentation is performed through optimal edge detection and connected set analysis. We demonstrate the results of this process from poor contrasted dual-echo images.

1 INTRODUÇÃO

A ressonância magnética nuclear (RMN) é capaz de fornecer informações estruturais e funcionais de tecidos biológicos. Ela tem a vantagem de ser não invasiva, permitindo assim estudos do sistema orgânico sem risco de perturbar as funções fisiológicas. Dentre as imagens comumente analisadas de forma clínica aparecem as imagens tomográficas do cérebro (figura 1.a), onde acham-se misturadas as massas cinzenta (MC), branca (MB) e o líquido cefalorraquidiano (LCR). Uma das tarefas principais na análise destas imagens situa-se na extração automática de dados clínicos para melhorar o estudo da repartição local destes e possibilitar uma reconstrução volumétrica mais simples facilitando portanto o diagnóstico médico.

Apesar da necessidade atual da segmentação de regiões do cérebro com significado contextual, poucos artigos fazem referência à segmentação automática de imagens RMN do cérebro [Collins e al(1992)]. As técnicas existentes baseadas em métodos estatísticos de reconhecimento de padrões e de divisão-fusão (split and merge) [Sipila(1992)] fazem aparecer falhas devido à falta de contraste das imagens apresentadas e de uma relativa fraqueza dos algoritmos de segmentação. Técnicas de classificação automática do tipo ISODATA [Gerig et al(1992)] ou baseadas em redes neuronais [Toulson(1992)] demonstram a ro-

bustez dos resultados no caso de imagens de boa qualidade e com bom contraste.

De maneira geral, as técnicas de processamento de imagens médicas e mais particularmente as de segmentação devem seguir alguns princípios:

- elas devem dispor de um grande nível de automatização. A interação com o usuário deve ser a menor possível;
- As técnicas devem ser eficientes e disponíveis em computadores comuns;
- a influência das características fisiológicas de cada paciente devem ser minimizadas de maneira a dotar o sistema de robustez.

A abordagem proposta é baseada na extração das componentes conexas da região interna do cérebro e na dedução do conteúdo semântico de cada um deles. O acesso às componentes conexas é efetuado por um processo de segmentação mista contorno-região. Contornos fechados são detectados e localizados por um algoritmo de extração ótima de contorno baseado nos estudos de Canny [Canny(1983)] e de Deriche [Deriche(1987)]. Uma técnica de perseguição de contorno associada a um método rápido de fechamento é utilizada para agilizar a detecção da parte óssea do crânio. Esta parte óssea, pela

própria natureza, apresenta de forma geral um bom contraste em comparação às regiões que formam a parte interna do cérebro. O que pode causar interferência na determinação das regiões conexas. Para evitar isto, a região óssea do crânio é supressa. A nova imagem obtida é de novo analisada a partir dos métodos acima citados e uma análise em componentes conexas permite a colocação em evidência das massas cinzenta e branca.

2 DETEÇÃO ÓTIMA DOS CONTORNOS

Uma das tarefas principais no método de segmentação em massas cinzenta e branca consiste na localização e na detecção das bordas das imagens a serem analisadas. As imagens de RMN, de forma geral, contêm muitos detalhes, com mudanças de níveis de cinza raramente nítidas e abruptas. Isto tem como consequência que a maioria das técnicas gerais de derivação por operadores locais, de busca de pontos máximos, conhecidas na literatura, não permitem a obtenção de resultados satisfatórios sobre imagens de RMN. Uma nova abordagem do problema de detecção de bordas, baseada nos resultados das pesquisas de Deriche, permite a ótima colocação em evidência de bordas. As hipóteses que permitem a localização das bordas são:

- uma boa detecção: este critério consiste em maximizar o razão sinal-ruído,
- uma boa localização: isto consiste em minimizar a variância da posição das passagens por zero (zero-crossing),
- uma não multiplicidade das respostas: este critério consiste em limitar o número de pontos máximos locais detectados para uma única borda.

A partir destes critérios, Deriche estabeleceu equações recursivas de suavização e de detecção de bordas, abrindo caminhos para o processamento de imagens particulares que são as de RMN. A detecção de bordas é realizada por determinação do gradiente em cada pixel da imagem RMN (figura 1.b).

3 DETERMINAÇÃO DOS PONTOS MÁXIMOS DAS BORDAS

Uma imagem de gradiente contém, de forma geral, muita informação redundante, mais especificamente, muitos dos pontos localizados não são representativos das bordas detectadas. A análise e a supressão de um ponto $PT(i,j)$ de uma borda faz-se por estudo de seu gradiente e do gradiente nos pontos vizinhos. A imagem do gradiente permite definir, no ponto

$PT(i,j)$, a direção $D(i,j)$ da maior diferença de nível de cinza. Nesta direção $D(i,j)$ podem ser definidos os dois vizinhos mais próximos. Uma interpolação linear dos módulos de gradiente numa vizinhança de $PT(i,j)$ segundo a direção $D(i,j)$ permite determinar o valor dos módulos de gradiente dos dois pontos vizinhos mais próximos. O ponto $PT(i,j)$ caracteriza um ponto de gradiente relevante da borda se o seu módulo é superior aos módulos de seus dois vizinhos mais próximos.

4 LIMIAZIZAÇÃO DOS PONTOS MÁXIMOS DAS BORDAS

Apesar de dispor, após a determinação otimizada das bordas, de uma imagem de pontos de bordas relevantes, esta contém bordas cujos significado e interesse são irrelevantes. Um meio simples e eficiente de reduzir este conjunto de pontos guardando somente bordas significativas consiste em efetuar uma limiarização da imagem dos pontos máximos de gradiente (figura 1.c). Esta binarização efetua-se pela determinação de um limiar, avaliado em função da esperança e do desvio-padrão da imagem gradiente, como segue:

$$\text{limiar} = \text{esperança} - \text{desvio-padrão}$$

5 PERSEGUIÇÃO DE BORDAS

O objetivo da perseguição de bordas consiste na determinação, na imagem binarizada do gradiente, de contornos fechados cujo interesse será descrito posteriormente. O método de perseguição é baseado na busca otimizada e orientada, para um ponto da borda já definido, de um possível sucessor. O algoritmo inspira-se dos resultados de Kitchin [Pugh(1983)] e usa a codificação de Freeman [Freeman(1961)]. Para um ponto do contorno $PT(n)$ dado, e em função de seu predecessor $PT(n-1)$, um vetor de freeman $V(n)$, dito de progressão, é determinado. A busca otimizada de um vizinho faz-se por determinação, a partir do vetor $V(n)$, das direções preferenciais de investigação. Quando um novo ponto $PT(n+1)$ é detectado, o processo é reiterado por determinação do novo vetor de progressão $V(n+1)$, etc...

Como de forma geral as bordas não são contínuas, mas apresentam interrupções, pode acontecer que nenhum ponto novo $PT(n+1)$ seja localizado. Neste caso, um algoritmo de fechamento de contorno faz-se indispensável. Ele consiste em acessar, no ponto de parada $PT(n)$ da imagem binarizada do gradiente, os pontos vizinhos da imagem não binarizada do gradiente e os seus valores de gradiente correspondentes. Um caminho na imagem gradiente não limiarizada é portanto definido por busca dos

pontos de maior valor de gradiente, de tal maneira a determinar o caminho ótimo ligando o ponto de parada $PT(n)$ com um novo ponto na imagem binarizada do gradiente. O algoritmo de perseguição é então reativado até a detecção de uma nova extremidade, onde o processo de fechamento é novamente empregado.

A perseguição de uma borda termina quando o ponto inicial de partida é de novo encontrado, o que significa a determinação de um contorno fechado de tamanho mínimo. Caso contrário, a porção de contorno localizada é eliminada. O processo é repetido até encontrar todos os contornos fechados da imagem. A figura 1.d ilustra a detecção das regiões através da visualização de seus contornos.

6 EXTRAÇÃO DA REGIÃO MASSA CINZENTA/MASSA BRANCA

A figura 1.a mostra que a região massa MC/massa MB possui muitos detalhes e apresenta pouco contraste em relação às outras partes que são a região óssea do crânio e o líquido LCR. Em termos de processamento, essas regiões, pelo bom contraste que apresentam, podem perturbar a análise estatística da região de interesse. O próximo passo, para facilitar a tarefa de segmentação, consiste em detectar e suprimir a parte óssea do crânio e o líquido LCR.

7 SIMPLIFICAÇÃO DA IMAGEM INICIAL

A figura 1.d demonstra com clareza que o maior contorno periférico corresponde à região a ser suprimida. A interpretação das informações obtidas anteriormente nesta imagem permite a supressão na figura 1.a da parte óssea do crânio e do líquido LCR.

A partir deste momento, dispomos na figura 1.e de uma nova imagem contendo a região mais interna da figura 1.a. A vantagem do tratamento desta imagem simplificada é ilustrada na figura 1.f. Usamos uma seqüência de processos idêntica à que foi descrita anteriormente. Podemos constatar que o algoritmo de perseguição de bordas fornece resultados mais nítidos em termos de definição do contorno da componente massa cinzenta, massa branca. Estes resultados vão permitir uma melhor delimitação da componente conexa.

8 DEFINIÇÃO DA COMPONENTE CONEXA

O resultado da localização do contorno fechado reside na obtenção de uma imagem binária onde, por exemplo, os pontos de contorno são codificados como 1 e as regiões como 0. Interessa-nos o conteúdo

da região delimitada pelo contorno definido anteriormente, fazendo-se necessária a determinação da componente conexa relacionada a este contorno. Na literatura, podemos encontrar vários algoritmos de estudo de conectividade [Rosenfeld(1966)], [Haralick(1981)], cuja desvantagem reside no fato de efetuarem duas passagens na imagem. Nossa proposta consiste no uso da codificação por Freeman do contorno, cuja originalidade é ser reutilizável de forma simples. O algoritmo de determinação da componente conexa consiste, linha por linha, em definir e preencher a porção de linha da região delimitada pelo contorno (figura 1.g). Este algoritmo é portanto simples e rápido na medida em que a região de interesse seja destacada por uso de um método seqüencial em uma única passagem.

9 SEPARAÇÃO EM MASSAS CINZENTA E BRANCA

O conhecimento exato do conjunto conexo permite o estudo de seu conteúdo. A região apresenta de forma geral pouco contraste, mas a presença de um pico (figura 1.h) no histograma da repartição dos níveis de cinza mostra que uma das componentes, massa cinzenta ou massa branca, será sempre majoritária. Este pico constitui, portanto, o limiar de segmentação da região de interesse em duas sub-regiões que são a massa cinzenta e a massa branca.

Os resultados experimentais demonstram a eficiência do processo, especificamente no caso de imagens com pouco contraste, obtidas a partir do segundo eco do método spin-eco (figura 1.i).

10 CONCLUSÕES

A exploração dos trabalhos mais recentes de Deriche e de Canny em termos de detecção de bordas permitiu o desenvolvimento de uma técnica eficiente e relativamente simples de extração de regiões apresentando pouco contraste em imagens RMN do cérebro. O processamento das imagens do segundo eco do método spin-eco sobre estações NEXT mostraram que a extração de dados clínicos é confiável e rápida (na ordem de 10s). O processo de eliminação da parte óssea do crânio e do líquido LCR não prejudicou a análise da parte de interesse e demonstrou que técnicas simples como o uso do histograma podiam ser empregadas com alto grau de confiabilidade.

A simplicidade dos procedimentos e o desempenho do método em termos de qualidade de segmentação e de tempo de processamento podem constituir uma nova base de pesquisa para os trabalhos sobre a atenuação em SPECT (Single Photon Emission Computed Tomography), o estudo da localização

das fontes elétricas do cérebro e o ajuste de novas técnicas de representação 3D das diferentes partes deste.

Este projeto recebeu o apoio do CNPq, processo n 480028/92.7 CCDT/DPE

11 REFERÊNCIAS BIBLIOGRÁFICAS

- [Canny(1983)] Canny J.F, "Finding Edges and Lines in Images", MIT Artificial Intelligence Laboratory, TR-720, 1983
- [Collins et al(1992)] Collins D.L, Petres T.M, Evans A.C, "Multiresolution Image Registration and Brain Structure Segmentation", 3D Advanced Image Processing in Medecine, Rennes, France, 19-92
- [Deriche(1987)] Deriche R, "Optimal Edge Detection Using Recursive Filtering", Proceedings First International Conference on Computer Vision, London, 8-12 June, 1987
- [Pugh(1983)] Pugh A, Robot Vision, IFS Publication, UK, Springer-Verlag, 1983
- [Freeman(1961)] Freeman H, "On the encoding of arbitrary geometric configurations", IRE Trans. on Electronic Computer, june 1961
- [Gerig e al(1992)] Gerig G, Martin J, Kikinis R, Kubler O, Shenton M, Jolesz F.A, "Unsupervised tissue type segmentation of 3D dual-echo MR head data", Image and Vision Computing, vol 10, N 6, july, august 1992
- [Haralick(1981)] Haralick R.M, "Some Neighborhood operators in real time, parallel computing image analysis" , Eds Penum Press, New York, 1981
- [Rosenfeld(1966)] Rosenfeld A, Pfaltz J.L, "Sequential operations in digital image processing", JACM, vol 13, N4, 1966
- [Sipila(1992)] Sipila O, Vehkomaki T, "General Tools for Segmentation" , 3D Advanced Image Processing in Medecine, Rennes, France, 1992
- [Toulson(1992)] Toulson D.L, Boyce J.F, "Segmentation of MR images using neural nets", Image and Vision Computing, vol 10, N 5, june 1992




Figure 1: a) Imagem original, b) Determinação da imagem do módulo do gradiente, c) Limiarização dos pontos máximos das bordas, d) Determinação dos contornos fechados, e) Simplificação da imagem original, f) Localização da borda da região massa cinzenta, massa branca, g) Determinação da componente conexa, h) Histograma do conteúdo da componente conexa, i) Segmentação em massa cinzenta e massa branca