



SPOLM 2008

ISSN 2175-6295

Rio de Janeiro- Brasil, 05 e 06 de agosto de 2008.

## **AVALIAÇÃO DOS MÉTODOS PARA A SEGMENTAÇÃO AUTOMÁTICA DOS TECIDOS DO ENCÉFALO EM RESSONÂNCIA MAGNÉTICA**

**Flávio L. Seixas**

[fseixas@ic.uff.br](mailto:fseixas@ic.uff.br)

**Anita Martins**

[amartins@ic.uff.br](mailto:amartins@ic.uff.br)

**Arthur R. Stilben**

[gugarthur@uol.com.br](mailto:gugarthur@uol.com.br)

**Daniel Madeira**

[dmadeira@ic.uff.br](mailto:dmadeira@ic.uff.br)

**Rafael Assumpção**

[rafass@globocom.com.br](mailto:rafass@globocom.com.br)

**Saulo Mansur**

[saulobmansur@yahoo.com.br](mailto:saulobmansur@yahoo.com.br)

**Silvia M. Victer**

[silviavictor@globocom.com.br](mailto:silviavictor@globocom.com.br)

**Vilson B. Mendes**

[vberilli@yahoo.com.br](mailto:vberilli@yahoo.com.br)

**Aura Conci**

[aconci@ic.uff.br](mailto:aconci@ic.uff.br)

Universidade Federal Fluminense  
Rua Passo da Pátria, 156

### **RESUMO**

Os tecidos do encéfalo podem ser visualizados através de exames não-invasivos como a ressonância magnética (RM). Avaliações do volume dos diferentes tecidos do encéfalo possuem aplicações clínicas, em especial no diagnóstico de doenças neurológicas degenerativas. A segmentação ou a identificação dos tecidos do encéfalo é o primeiro passo neste contexto de prover informações auxiliares no diagnóstico, prognóstico e acompanhamento do progresso de uma doença neurológica. Contudo, a segmentação manual é uma técnica de alto custo, pois demanda tempo e requer experiência do radiologista. Assim, técnicas computacionais de segmentação são indicadas, visando melhorar a velocidade de obtenção dos dados e a acuidade do diagnóstico. Há diversas técnicas de segmentação automática de imagens com resultados muito variáveis e dependentes da aplicação. No presente artigo é analisado diferentes métodos de segmentação utilizando imagens de RM da seção sagital do crânio. O desempenho de cada método de segmentação é avaliado com base na sua identificação das áreas importantes do cérebro humano (líquor, substâncias cinzenta e branca) obtidas de formas automáticas e comparadas com um modelo padrão disponibilizado pelo projeto *Brainweb*[21]. Para segmentação foram utilizados os métodos: (i) limiarização em multiníveis de Otsu modificado por algoritmos genéticos, (ii) limiarização em multiníveis de Niblack, (iii) entropia máxima, (iv)

limiarização em multiníveis de Otsu com função GGM e (v) limiarização em multiníveis de Rosin. Na comparação entre os métodos, foram considerados métodos de teoria dos jogos.

**Palavras-Chaves:** Ressonância magnética, segmentação de imagens, tecidos do encéfalo, algoritmos genéticos, diagnóstico, doenças neurodegenerativas.

### ABSTRACT

Brain tissues can be evaluated by non-invasive procedures, such as magnetic resonance (MR) images. The brain tissue volume measurements have important clinical applications in the neurodegenerative disease diagnosis. The segmentation of the elements in the acquired brain image is the first step on the tissue volume measures to assist radiologists into neurodegenerative disease diagnosis, prognostic and patient treatment follow-up. However, manual segmentation demands great time and radiologist expertise. There are a number of automatic image segmentation techniques, but they provide distinct results depending on the application. In the present paper we compare distinct image segmentation methods usable in MR images (MRI). Computational experiments were performed to evaluate each approach. The results are assessed by comparison against tissues segmentation gold standard available by *Brainweb* project [21]. The used segmentation methods are (i) multi-level thresholding by Otsu optimized by genetic algorithms, (ii) multi-level thresholding by Niblack, (iii) maximal entropy, (iv) multi-level thresholding by Otsu using GGM function, (v) multi-level thresholding by Rosin. The method performance was measured based on gray matter area using a MRI. To compare the methods, game's theory techniques are considered to evaluate the best segmentation methodology.

**Keywords:** Magnetic resonance image; brain tissue segmentation; genetic algorithms; neurodegenerative disease; game theory;

## 1. INTRODUÇÃO

Doenças neurodegenerativas incluem uma variedade de doenças caracterizadas pelo mau funcionamento ou perda de células nervosas. São exemplos destas a esclerose múltipla, as doenças de Alzheimer, Huntington e Parkinson. A estimativa é que mais de 11 milhões de idosos (indivíduos com mais de 60 anos) estejam afetados por alguma delas nos países em desenvolvimento, considerando o último censo de 2000 [1]. A avaliação do volume das diversas estruturas do encéfalo através do uso de exames não invasivos como a ressonância magnética, é importante para a atividade clínica, pois permite a identificação e medição de atrofia ou na avaliação do progresso da doença [2]. O conjunto destas informações ajuda o especialista no diagnóstico, prognóstico e acompanhamento do paciente. Devido ao seu alto custo, a avaliação volumétrica não é uma técnica usual, pois demanda tempo, requer experiência do radiologista e é subjetiva. Segundo Marchetti *et al* [3], a segmentação manual das estruturas localizadas no lobo temporal médio demora aproximadamente 75 minutos por imagem por paciente. Ainda, dependendo da técnica de segmentação manual adotada, pode-se chegar a resultados muito dispares. Técnicas computacionais automáticas estão sendo estudadas visando reduzir o tempo de segmentação das imagens, estabelecendo um padrão e diminuindo a subjetividade das medições. Nas áreas de análise e processamento de imagens, estas técnicas são denominadas de técnicas de segmentação. É importante ressaltar, que quando se opta pela automatização, supõe-se que o sistema tomará decisões que satisfazem àquele usuário que não tem tempo suficiente para escolher a metodologia que melhor caberia ao seu caso em particular. Como, os métodos de segmentação apresentam diferentes resultados para situações distintas, cabe pensar no uso de uma avaliação mais criteriosa, como as disponibilizadas pela teoria dos jogos, para escolha da melhor metodologia de segmentação. Cinco métodos de segmentação baseados nos tons de cinza são comparados neste artigo: (i) limiarização em multiníveis de Otsu modificado por algoritmos genéticos, (ii) limiarização em multiníveis de Niblack, (iii) entropia máxima, (iv) limiarização em multiníveis de Otsu com função GGM e (v) limiarização em multiníveis de Rosin. O artigo é

organizado da seguinte forma: na Seção 2 é feita uma revisão bibliográfica de alguns métodos da literatura. Na Seção 3 são descritos os métodos de segmentação utilizados neste artigo. A Seção 4 apresenta os resultados dos experimentos computacionais. Os resultados e conclusões são comentados na Seção 5.

## 2. REVISÃO BIBLIOGRAFICA

Visando a separação ou segmentação de um objeto na imagem, Otsu [4] desenvolveu um método de seleção automática do nível de limiar, de modo a distinguir o melhor possível os níveis de cinza pertencentes ao fundo dos níveis de cinza componentes do objeto. Algumas extensões do método de Otsu foram propostas visando reduzir o custo computacional quando na seleção de mais de um nível de limite. Esses métodos podem ser classificados em parametrizados e não-parametrizados [5]. Os métodos parametrizados são baseados na idéia de que a distribuição dos níveis de cinza de uma classe ou objeto segue uma distribuição gaussiana. A segmentação acontece pela estimativa dos parâmetros da distribuição gaussiana que melhor se ajustam aos níveis de cinza do objeto [6]. Nos métodos não parametrizados o objetivo é estimar os nível de cinza que separe uma região da imagem de outra, conforme algum critério de discriminação, como a variância entre classes [4], entropia [7] ou entropia cruzada [8]. Tanto utilizando métodos parametrizados como não parametrizados, o custo computacional cresce exponencialmente com número de níveis de limites desejado, tornando um problema de conhecer esses limites em multi-níveis caro computacionalmente. Alguns métodos heurísticos e lineares de otimização foram propostos visando reduzir o custo computacional. Synder *et al* [6] apresentou um método alternativo de alinhamento de curvas baseado em um modelo heurístico denominado *tree annealing*. Cheng *et al* [9] aplicou um método baseado lógica fuzzy, selecionando automaticamente os níveis de limites de modo a maximizar a função de entropia. Yin [10] propôs um algoritmo de seleção dos níveis de limiarização utilizando algoritmo genéticos.

O objetivo deste artigo é descobrir o melhor método para identificação das regiões importantes do cérebro: o líquido, as substâncias cinzenta e branca do encéfalo, identificadas a partir de uma seção sagital do encéfalo de ressonância magnética ponderada em T1 do crânio. A identificação desta substância tem grande valor clínico no diagnóstico e acompanhamento de doenças neurológicas degenerativas [2]. Com a região segmentada, é possível avaliar a área do cérebro correspondente relacionando a área de cada pixel com as dimensões físicas da imagem. A teoria dos jogos aplica-se quando as conseqüências de uma decisão dependem de fatores não controláveis pelo *decisor*, simbolizados pela figura de um jogador oponente. Na *teoria dos jogos clássicos*, o oponente também toma decisões que maximizam os seus ganhos. No caso em estudo, essa teoria deve ser reinterpretada: o oponente sendo as imagens do cérebro cujo diagnóstico está em análise, portanto não toma nenhuma decisão consciente. Mesmo assim, o operador, ou primeiro jogador, não sabe qual o melhor método a ser usado e, portanto pode-se pensar em aplicar as técnicas da teoria dos jogos, em particular o uso de estratégias conservadoras. Reforça-se que, como o oponente não reage às estratégias, não tem sentido falar em *jogo com repetição* nem *estratégias mistas*. Neste sentido vale a pena investigar se essa teoria seria aplicável ou não no contexto em questão, isto é, em na análise de imagens do interior do corpo humano. O resultado pode vir certamente a surpreender.

## 3. MÉTODOS

As sub-seções seguintes descrevem os métodos de segmentação e os métodos de escolha da melhor metodologia utilizando teoria dos jogos.

### 3.1. Método de Otsu

O método proposto por Otsu [4] é baseado nas características de distribuição dos tons das imagens. Trata-se de um método não-paramétrico e não-supervisionado, que procura selecionar automaticamente os limites dos níveis de cinza que melhor separam ou segmentam os

elementos de interesse em uma imagem de uma classe específica.

Se os pixels de uma dada imagem forem representados por  $L$  níveis de cinza, então o número de pixels com nível  $i$  é descrito por  $n_i$  e o número total de pixels por  $N = n_1 + n_2 + \dots + n_L$ . O histograma normalizado é uma função de distribuição de probabilidade (Equação 1). As Equações 2, 3 e 4 mostram a probabilidade de ocorrência, o nível médio e o desvio padrão por classe, ou região segmentada, respectivamente, onde  $d$  representa a classes e  $T_d$  são os limites dos níveis de cada classe.

$$p_i = \frac{n_i}{N}; p_i \geq 0; \sum_{i=1}^L p_i = 1 \quad (1)$$

$$q_d = \sum_{i=T_{d-1}+1}^{T_d} p_i \quad (2)$$

$$\mu_d = \sum_{i=T_{d-1}+1}^{T_d} \frac{i \cdot p_i}{q_d} \quad (3)$$

$$\sigma_d^2 = \sum_{i=T_{d-1}+1}^{T_d} \frac{(i - \mu_d)^2 \cdot p_i}{q_d} \quad (4)$$

Assim, o critério de seleção do limite dos níveis de cinza ou tons ótimos é baseado na minimização da expressão da variância intra-grupo (Equação 5).

$$\text{Min } f(T_1, T_2, \dots, T_{d-1}) = \sum_{i=1}^d q_i \cdot \sigma_i^2 \quad (5)$$

Como  $f(T_1, T_2, \dots, T_{d-1})$  trata-se de uma função discreta, o objetivo é identificar os limites dos níveis  $T_1, T_2, \dots, T_{d-1}$  que a função obtém seu valor mínimo. Há diversos métodos para seleção dos níveis de limiarização que minimizam a Equação 5. A Seção 4 detalha um método para seleção destes limites utilizando um método heurístico conhecido como algoritmos genéticos.

### 3.2. Algoritmos Genéticos

Proposto inicialmente por Holland [11], a popularização dos algoritmos genéticos (AGs) têm sido explicada pelas referências às adaptações evolutivas das espécies encontradas na teoria genética. O princípio associado a AGs é manter uma população de possíveis soluções (indivíduos) codificadas na forma de genes e cromossomos, submetendo a população a um processo evolutivo até que algum critério de parada seja satisfeito. Cada indivíduo é avaliado através de uma função denominada *fitness*. Os indivíduos com melhores avaliações terão maior probabilidade de serem selecionados para reprodução, fazendo parte da próxima geração. A Figura 1 mostra a codificação das soluções dentro da terminologia aplicada aos algoritmos genéticos.

Como descrito na Seção 1, tem-se a necessidade da segmentação de quatro regiões do encéfalo, ou seja, a seleção de três limites de níveis de cinza. No modelo de algoritmo genético, cada gene representa um nível de limiarização. O conjunto de genes forma o cromossomo, ou indivíduo. O conjunto de indivíduos forma a população. A população inicial é randômica, obedecendo aos limites superiores e inferiores configurados como mostra a Figura 2. Isto significa que, em um primeiro momento, os três níveis de cinza são escolhidos randomicamente seguindo os limites pré-estabelecidos. A população inicial é composta 20 indivíduos.

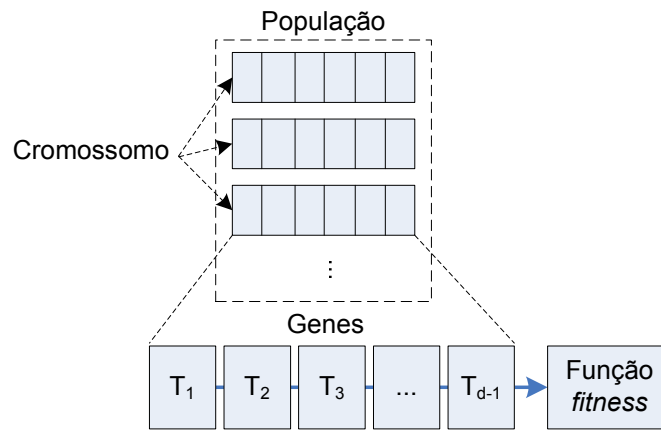


Figura 1. Espaço solução utilizando os termos aplicados a algoritmos genéticos

	T <sub>1</sub>	T <sub>2</sub>	T <sub>3</sub>
Limite inferior	20	70	144
Limite superior	40	90	164

Figura 2. Limites inferior e superior definidos pelos 3 níveis de cinza (T<sub>1</sub>, T<sub>2</sub>, T<sub>3</sub>) para segmentação, admitindo os níveis de cinza no intervalo (0; 255)

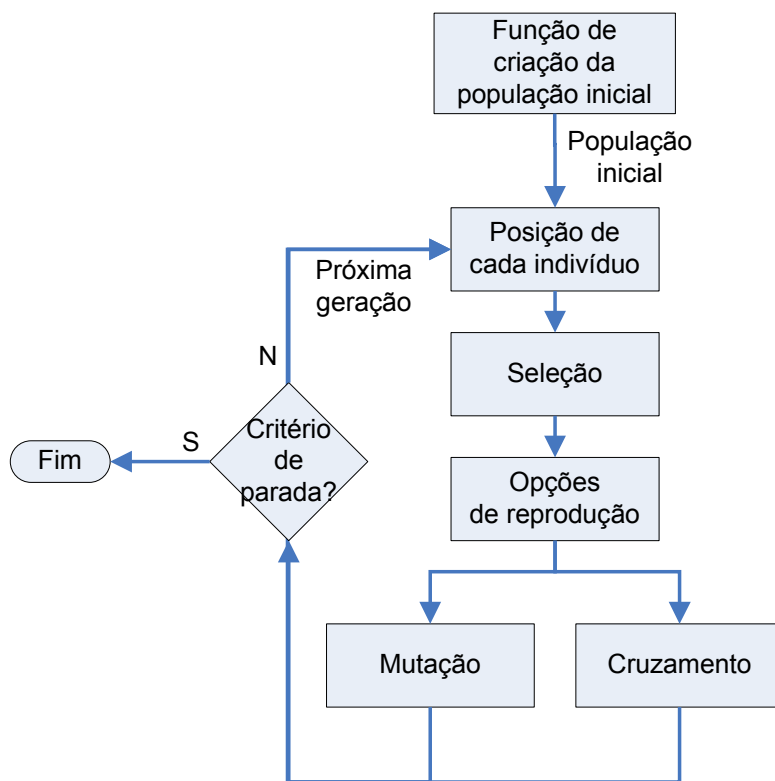
A qualidade da solução ou indivíduo é avaliada por uma função *fitness*. A função *fitness* é calculada com base na Equação 5 da Seção 2. As qualidades das soluções são comparadas uma com as outras através da função *fitness*. O objetivo, portanto, é identificar uma solução, ou indivíduo, que produza uma função *fitness* mínima pela configuração de seus genes. Uma função de *ranking* determina a posição de cada indivíduo com base em sua avaliação. A seleção dos indivíduos para reprodução é baseada no método estocástico de distribuição uniforme [12]. Como opção de reprodução, foi atribuída um percentual de 80% de indivíduos sendo gerados para próxima geração a partir da função de cruzamento e função de mutação. A função de cruzamento tem por objetivo embaralhar os genes de dois pais (indivíduos da geração anterior), formando um filho (indivíduo da próxima geração). A função de mutação tem por objetivo, além de embaralhar os genes de dois pais que geram um filho, modificar os valores dos seus genes. Como função de mutação, um número aleatório é escolhido a partir de uma distribuição Gaussiana centrada em zero, sendo adicionado um vetor de entrada aos valores dos genes para cada indivíduo. A função de cruzamento cria um número binário aleatório. Os genes do primeiro pai são selecionados onde o vetor indicar 1, em contrapartida, os genes do segundo pai são selecionados onde o vetor indicar 0. O critério de parada adotado foi 10 gerações. A Figura 3 apresentando na forma de um esquema o fluxo utilizado no algoritmo genético.

### 3.3. Método de Niblack

Um método de limiarização local de bom desempenho é o proposto por Niblack [13], cuja ideia principal é construir uma superfície limite, baseada na média local,  $m$ , e um desvio padrão  $s$ , de valores de cinza computado em uma vizinhança pequena ao redor de cada pixel (Equação 6):

$$T = m + k \cdot s \quad (6)$$

onde  $k$  é uma constante. Esse método, entretanto, tende a produzir uma grande quantidade de ruídos em imagens com muitos tons de cinza. Como resultado, um processamento posterior intenso computacionalmente é requerido para reduzir ou remover os ruídos antes de uma análise precisa.



**Figura 3. Esquema mostrando a seqüência de processamento a cada iteração dos AGs**

O método de Niblack tem ainda desvantagens relacionadas a definição do tamanho da vizinhança. Esse tamanho deve ser pequeno suficiente para preservar detalhes locais mas grande o suficiente para suprimir ruídos. Feng *et al* [14] consideram um método de binarização adaptativa aplicado a extração de informação textual em imagens de documentos de baixa qualidade. Neste trabalho usa-se limiarização Niblack multinível como o processo para segmentar RMI em várias regiões importantes do cérebro. Os passos do algoritmo Niblack multinível são mostrados no Algoritmo 1. Observe que temos no final os limites de cada nível que se queira segmentar, tornando o Algoritmo 1 a nossa proposta de um Niblack multinível. Esse algoritmo não verifica as extremidades da direita e inferior fora da janela, mas para o experimento em questão (RMI) não há problemas, pois esse pequeno número de pixel descartado não são de interesse para a nossa segmentação.

1. define-se o tamanho da janela  $w$ ,  $n$  linhas  $\times$   $m$  colunas (janela essa que será deslizada ao redor do pixel em questão de onde serão calculados os valores da média local  $m$  e desvio padrão  $s$ ). Essa janela obviamente deve ser inferior ao tamanho em pixels da imagem original. Define-se o valor da constante  $k$  da fórmula do threshold adaptativo.
2. calcula  $p1 = n \times m$ ;
3. lê a imagem  $I$  em tons de cinza que se queira segmentar;
4. obtém o número de linhas e colunas dessa imagem  $I$  ( $i$  linhas  $\times$   $j$  colunas)
5. desliza essa janela  $w$  pela imagem  $I$  até obter o novo valor de tom para cada pixel em  $I$ , de acordo com os passos a seguir:
  - a. faz-se um loop A varrendo todas as linhas da imagem
  - b. faz-se um loop B variando todas as colunas da imagem
  - c. faz-se um loop C varrendo todas as linhas da janela
  - d. fazer um loop D varrendo todas colunas da janela
  - e. soma todos os tons de cinza de cada pixel  $I$  [posição  $x + z$ , posição  $y + v$ ] e armazena esse resultado da soma em uma variável chamada somaPixel. Ex:  $somaPixel = somaPixel + pixel\ I\ [x+z,y+v]$  (com somaPixel iniciando com valor 0).
  - f. calcula a média =  $somaPixel/p1$ ;
  - g. calcula o desvio padrão  $s = (somaPixel^2 - (somaPixel/p1)^2) / (p1 - 1)$
  - h. calcula o valor de  $T = média + k*s$ .
  - i. atribui ao pixel  $[x,y]$  o valor  $T$ .
  - j. repete o item b até varrer todas as colunas para uma linha  $x$ .
  - k. repete o item a até varrer todas as linhas. (após esse passo tem-se uma nova imagem com valores dos tons dos pixels alterados.
  - l. verifica todos os valores dos thresholds e armazena em um array, as faixas de limiarizações.
6. em outro loop varrer a imagem considerando uma faixa de cada vez e armazenando em vários arquivos para cada

faixa. Como tem-se três faixas que queremos verificar a limiarização (faixas T1 para o liquor, T2 para a substância cinzenta e T3 para a substância branca, são feitos loops para varrer cada faixa considerando que os píxeis de valor dentro da faixa será atribuído o valor 255 (branco) e os demais fora da faixa atribuído o valor 0 (preto).

#### Algoritmo 1. Niblack multinível

### 3.4. Método de Rosin

O algoritmo de Rosin [15] assume que há uma população dominante na imagem (que produz um pico principal) e uma população secundária. Esta última categoria pode ou não ser representada por um pico discernível, mas precisa ser razoavelmente separada do pico maior a fim de evitar ser inundada por ele. Uma reta  $r$  é traçada no histograma. Essa reta começa no pico (intensidade com maior número de pixels acumulados) e termina na primeira intensidade sem pixels (vazia). O limiar estabelecido é a intensidade que maximiza o segmento de reta perpendicular à reta  $r$  com origem na reta e fim no nível de cinza, conforme Figura 4. Este método gera uma subdivisão recursiva para determinar a aproximação poligonal de uma curva [16].




Figura 4. Processo de determinação limiar de intensidade histograma

O algoritmo de Rosin [15] proposto inicialmente, faz a limiarização de imagens bimodais, neste trabalho, ele será estendido para imagens multimodais, mais especificamente, para imagens de ressonância magnética dos tecidos do encéfalo. Neste contexto, a busca pelo limiar foi realizada repetindo a função Rosinthreshold para encontrar cada limiar. Após uma execução, os valores da região encontrada são transformados em 0 e a função é executada novamente até que cada um dos picos tenha sido identificado e a imagem completamente segmentada. As duas primeiras passadas são descartadas, servindo apenas para separar fundo e crânio do cérebro, nas 3 passadas seguintes, são determinados as regiões do liquor, da massa cinzenta e massa branca. O método mostrou-se ineficiente em separar a região do liquor e a região da massa cinzenta, por não haver uma separação clara entre as duas modas do histograma que representam esta região, porém a região da massa branca foi bem identificada (limiarizada).

### 3.5. Método de Otsu com GGM

O método de Otsu utiliza apenas a informação do histograma da imagem, não oferecendo informação sobre a localização dos seus pontos, sendo através dele impossível discriminar, por exemplo, se os pixels correspondentes a determinado tons estão no interior ou nas bordas de um órgão do corpo humano. O método descrito por Shuhong *et al* [17] visa estender o método de Otsu, tornando-o menos sensível a ruídos e principalmente associando o tom à posição deste na imagem. O método utiliza não somente o histograma, como o método de Otsu clássico, mas também mapeia os gradientes dos pixels da imagem, criando uma relação entre o gradiente de cada pixel e seu respectivo tom de cinza (Equação 7).

$$T(i) = \frac{\sum_{(x,y) \in R_i} G(x,y)}{n_i}, i \in [0,1,\dots,L-1] \quad (7)$$

O método foi criado e testado pelos autores para imagens bimodais. Neste trabalho aplica-se este método em uma segmentação multinível e estuda-se sua aplicabilidade na segmentação das imagens cerebrais. Os Passos do algoritmo Otsu com função GGM utilizados são apresentados no Algoritmo 2.

1. escolhe-se um operador para cálculo do gradiente.
2. lê a imagem I que se queira segmentar;
3. calcula-se o gradiente da imagem;
4. calcula-se a média dos gradientes para os pixels com o mesmo tom de cinza
5. com esses dados, cria-se a função GGM, e aplica-se o método de Otsu multinível, minimizando a variância entre-classes:

$$\sigma_0^2 = \sum_{i=0}^t (T_i - \mu_0)^2$$

6. com os limiares calculados, cria-se as imagens binárias de saída, uma para cada seção criada pelos limiares.

### Algoritmo 2. Otsu com função GGM

Para cálculo do gradiente, foi aplicado o filtro de Sobel. O método se mostrou ineficiente na segmentação das RM, devido ao fato da transição entre os tons de cinza das diferentes áreas do cérebro ser suave, diminuindo a capacidade do algoritmo de processar corretamente os gradientes. Com isso, seus resultados foram desconsiderados na avaliação final.

### 3.6. Método de Entropia Máxima

O conceito de entropia já existe há mais de 150 anos. Entretanto somente no início século XX foi difundido nas mais diversas áreas do saber. Shannon (1948) introduziu o conceito de entropia em teoria da informação. Kapur e Pun [18] especificaram um valor de corte  $t$  entre duas medidas de entropia a fim de se obter a máxima entropia possível [19].

De acordo com Shannon, o conceito de entropia refere-se à incerteza de uma distribuição de probabilidade e a medida que propôs destinava-se a quantificar essa incerteza. Matematicamente, a medida de entropia é definida conforme (Equação 8):

$$S(\mathbf{p}) = -\sum_{i=1}^n p_i \ln p_i \quad (8)$$

Baseado no algoritmo de Pun [19], é possível construir um algoritmo que usa a entropia máxima para limiarização em multiníveis. São escolhidos  $n$  valores de corte,  $t_1, \dots, t_n$ , que subdividem todo o espectro de tons de cinza em pequenas regiões. A cada região é associado um tom de cinza. O cálculo das respectivas entropias é mostrado na Equação 9:

$$H_1 = -\sum_0^{t_1} p_i \cdot \log(p_i)$$

$$H_2 = -\sum_0^{t_2} p_i \cdot \log(p_i) \quad (9)$$

$$K H_n = -\sum_0^{t_n} p_i \cdot \log(p_i)$$

onde  $H_j$ ,  $j = 1, 2, \dots, n+1$  são os valores das entropias de cada região;  $p_i$  é probabilidade do pixel possuir o tom  $i$ . No presente estudo esse algoritmo não chegou a ser testado. O seu objetivo é encontrar valores para  $t_1, \dots, t_n$  de forma que a maximizar a soma (Equação 10):

$$\sum_1^n H_i \quad (10)$$

### 3.7. Método de Chow e Kaneko

O método de Chow e Kaneko [20] consiste basicamente na subdivisão da imagem em blocos menores, onde as informações locais serão conectadas de forma a gerar uma imagem final segmentada. Esse método não foi implementado por não apresentar diretamente uma solução para segmentação multiníveis de uma RMI. O algoritmo segue as etapas apresentadas no Algoritmo 3.

1. subdividir a imagem em blocos menores sobrepostos (por exemplo blocos de 64x64 pixels com 50% de sobreposição)
2. para cada bloco, definir os pontos de corte por aproximação de duas curvas gaussianas



- |  |
|--|
| 3. para os blocos onde não foi encontrado um ponto de corte significativo, definimos esse corte como nulo<br>4. interpolar os pontos de corte por toda a imagem e utilizar os valores obtidos para segmentar a imagem original |
|--|

**Algoritmo 3. Chow e Kaneko**

### 3.8. Método de Decisão

Para as decisões serem tomadas com foco na qualidade e na credibilidade da informação, resultado de um processo de análise, utilizando elementos de teoria da decisão e teoria dos jogos, a análise terá como base, as áreas de três regiões diferentes do cérebro, obtidas a partir das RMI usando as diversas metodologias apresentadas e as suas diferenças quando comparadas com as áreas apresentado em *Brainweb* [21] (lógica fuzzy) que será tomado como referência em nossos experimentos. Portanto, será pensado em definir a melhor metodologia de segmentação automática utilizando a tabela de diferenças obtidas. Para se decidir pela melhor metodologia com base nos resultados pensa-se em uma comparação entre a estratégia *minmax* e a estratégia *do menor arrependimento*. A utilização da *minmax* como estratégia seria uma atitude conservadora clássica, uma vez que com esta decide-se pela menor perda entre as maiores de uma determinada *matriz de pagamentos*. É uma estratégia que garante que, se tudo correr mal, o resultado obtido não será mau.

A estratégia *minmax* consiste em escolher uma metodologia determinando qual fornece menor diferença entre as maiores diferenças obtidas pelo conjunto de metodologias. A estratégia de *menor arrependimento* consiste em escolher a metodologia que o radiologista se arrependerá menos com o resultado obtido, para o pior caso, isto é, que objetiva decidir pelo método em que, para uma dada imagem do cérebro, o radiologista se arrependerá menos de ter escolhido um em detrimento de outro que daria um melhor resultado.

Tomando-se como matriz de pagamento, que é o conjunto de valores absolutos que um determinado jogador tem que pagar dependendo da estratégia utilizada, como a tabela de diferenças que relaciona as metodologias desenvolvidas com os casos apresentados (diferença entre áreas), a estratégia *minmax* resume-se em determinar as maiores diferenças para cada metodologia e posteriormente indicar a metodologia cuja maior diferença é a menor entre as demais. Por outro lado, a estratégia do menor arrependimento, consiste na aplicação do método *minmax* em uma matriz auxiliar, que é obtida a partir da matriz de pagamentos, isto é, a matriz auxiliar é resultante da diferença entre as diferenças obtidas e as menores diferenças em cada metodologia.

Supondo uma matriz de diferenças M, com 3 linhas (definidas por três situações, imagem 1, 2 e 3) e 3 colunas (definidas por 3 metodologias desenvolvidas), composta pelos seguintes elementos:

$$M = \begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix}$$

Para determinar a metodologia padrão segundo a estratégia *minmax*, primeiro determina-se o vetor dos maiores erros:  $M_{aE} = |b_1 \ b_2 \ b_3|$  onde,  $b_1$  = maior valor entre  $a_{11}$ ,  $a_{21}$  e  $a_{31}$ ;  $b_2$  = maior valor entre  $a_{12}$ ,  $a_{22}$  e  $a_{32}$ ; e  $b_3$  = maior valor entre  $a_{13}$ ,  $a_{23}$  e  $a_{33}$ . Em seguida, decide-se pelo método cujo valor de  $b_i$  é o menor.

Para determinar a metodologia padrão segundo o critério *do menor arrependimento*, primeiro determina-se o vetor das menores diferenças:  $M_{eE} = |c_1 \ c_2 \ c_3|$  onde,  $c_1$  = menor valor entre  $a_{11}$ ,  $a_{21}$  e  $a_{31}$ ,  $c_2$  = menor valor entre  $a_{12}$ ,  $a_{22}$  e  $a_{32}$  e  $c_3$  = menor valor entre  $a_{13}$ ,  $a_{23}$  e  $a_{33}$ . Em seguida determinam-se os elementos da matriz auxiliar:

$$AUX = \begin{vmatrix} (a_{11} - c_1) & (a_{12} - c_2) & (a_{13} - c_3) \\ (a_{21} - c_1) & (a_{22} - c_2) & (a_{23} - c_3) \\ (a_{31} - c_1) & (a_{32} - c_2) & (a_{33} - c_3) \end{vmatrix}$$

E aplica-se o  $\Pi$  X para determinação da melhor metodologia, calculando as maiores diferenças para cada metodologia, que são os maiores valores para cada coluna da matriz AUX e escolhe-se a metodologia cujo valor é o menor entre os maiores encontrados. É importante ressaltar que, o método *minmax* é sempre importante, pois

mesmo que não seja utilizado como uma estratégia independente, ele faz parte das etapas do método do *menor arrependimento*.

#### 4. EXPERIMENTOS

A imagem da seção transversal de uma ressonância magnética do crânio do projeto *BrainWeb* [21] pode ser vista na Figura 5a. *BrainWeb* [21] é uma base pública de imagens usada neste trabalho com o objetivo fornecer um padrão de validação para as diversas técnicas de segmentação analisadas. A Figura 5b mostra a distribuição de tons de cinza ou histograma da imagem da Figura 5a.




Figura 5. (a) Seção transversal de uma RMI típica do crânio; (b) histograma de (a)

O método de Otsu modificado utilizando algoritmo genético foi implementado em MATLAB. Para melhorar a convergência do algoritmo, foi aplicado um filtro gaussiano de suavização utilizando matriz  $5 \times 5$  com desvio padrão 0,5. Os resultados encontrados através da aplicação do AG para seleção dos limites de cada região foram:  $T_1 = 39$ ,  $T_2 = 85$ ,  $T_3 = 151$  (limiares). A Figura 6 mostra os resultados representando as três substâncias do encéfalo: o líquido (a), a substância cinzenta (b) e branca (c).




Figura 6. As substâncias do encéfalo segmentadas pelo algoritmo de Otsu modificado utilizando algoritmo genético: (a) líquido; (b) substância cinzenta; (c) substância branca

Posteriormente, foi aplicado um algoritmo de agrupamento de regiões considerando conectividade ortogonal. A região considerada foi a de maior área. Assim, as regiões não pertencentes ao encéfalo, como a região do crânio, foram retiradas da imagem, resultando imagens mais acuradas das três substâncias do encéfalo, conforme mostra Figura 7. A Figura 8 mostra o histograma da imagem após o filtro de suavização gaussiano, indicando os níveis de limites de tons de cinza encontrados.

O algoritmo de Niblack foi implementado em Java, utilizando um microcomputador T7250 2GHz, memória de 2Gb. Foi utilizada uma janela  $w$   $5 \times 5$  e um valor de  $k$  de 0.4. Os resultados encontrados através da aplicação do algoritmo de Niblack para seleção dos limites de

cada região (segmentação) foram:  $T_1 = 39$ ,  $T_2 = 77$ ,  $T_3 = 149$ . A Figura 9 mostra os resultados obtidos usando esses valores.




Figura 7. As substâncias do encéfalo, aplicando agrupamento de regiões pela conectividade dos pixels, representando (a) líquido; (b) substância cinzenta; e (c) substância branca

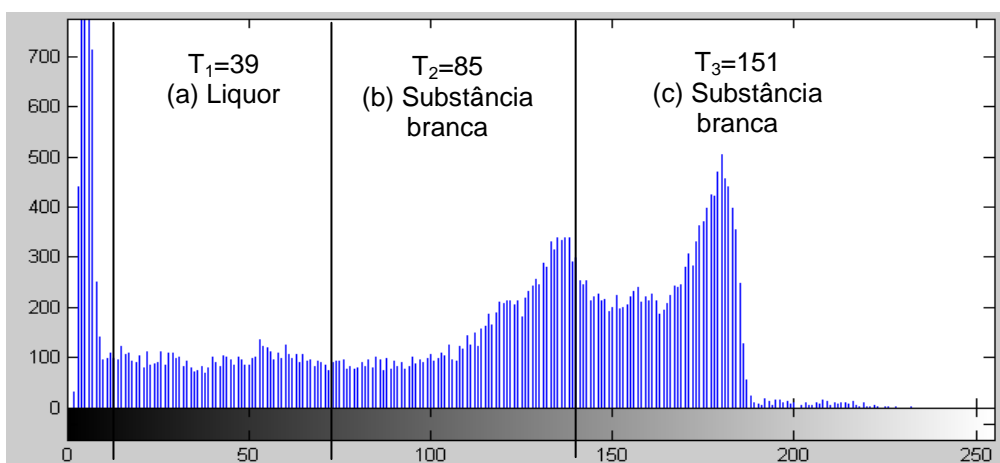


Figura 8. Histograma mostrando os níveis de tons selecionados automaticamente pelo algoritmo genético (AG)




Figura 9. As substâncias do encéfalo segmentadas pelo algoritmo de limiarização, representando as regiões: (a) líquido; (b) substância cinzenta; (c) substância branca

O algoritmo de Rosin levou aos seguintes limites:  $T_1 = 21$ ,  $T_2 = 132$ ,  $T_3 = 162$ . A Figura 10 mostra os resultados da limiarização, representando as três substâncias do encéfalo: o líquido (a), a substância cinzenta (b) e a substância branca (c).




Figura 10. As substâncias do encéfalo segmentadas pelo algoritmo de limiarização, representando as regiões: (a) líquido; (b) substância cinzenta; (c) substância branca

## 5. AVALIAÇÃO DOS RESULTADOS E TRABALHOS FUTUROS

A Figura 11 mostra os três tecidos do encéfalo segmentados através do método de segmentação baseado em lógica *fuzzy* proposto por Collins *et al* [22].




Figura 11. As substâncias do encéfalo segmentadas manualmente por um especialista: (a) líquido; (b) substância cinzenta; (c) substância branca

A Tabela 1 apresenta os resultados das áreas superficiais das substâncias do encéfalo obtidas pelos métodos mostrados neste artigo e o método desenvolvido em [22]. Calculando-se os módulos das diferenças entre áreas obtidas pelos três primeiros métodos e as áreas obtidas pelo método baseado em lógica *fuzzy*, obtemos a matriz de pagamentos apresentada na tabela 2. A matriz de pagamentos da tabela 2 não deixa qualquer dúvida sobre ser a escolha do método Otsu otimizado por AG sempre a melhor escolha. Ou em outras palavras é obvio que qualquer metodologia de decisão [23] irá escolher este método conforme a tabela 2. No entanto, mesmo uma comparação visual simples entre as imagens das figuras de 6 a 11, mostra que nenhum dos resultados poderia substituir o segmentador humano especializado (figura 11). O que nos leva a concluir que ainda muito precisa ser pesquisado para que uma definição automática destas áreas do cérebro seja obtida. Nos próximos trabalhos passaremos a pesquisar métodos de segmentação não apenas baseados nos tons de cinza, mas também na textura da região e de sua localização nas imagens de RM em estudo. O aspecto mais importante aqui é que o segmentador humano retirou da imagem a região de interesse (ROI) e considerou as áreas apenas desta região. Ou seja, mesmo antes de partir-se para metodologias mais complexas deveremos partir para um pré-processamento de eliminação das áreas desnecessárias (como a caixa craniana) e identificação previa das regiões de interesse da imagem [24].

Tabela 1. Comparação das áreas obtidas por métodos de segmentação distintos [mm<sup>2</sup>]

Estrutura do encéfalo	baseado Otsu otimizado por AG	baseado Niblack	baseado Rosin	baseado em lógica <i>fuzzy</i>
Substância cinzenta	8.765	13.276	6.570	9.950
Substância branca	9.342	9.106	9.027	9.595
Líquor	2.398	5.187	1.1969	3.214

**Tabela 2. Matriz de pagamento obtida através da comparação entre às áreas da tabela1 [mm<sup>2</sup>]**

Estrutura do encéfalo	Método de Otsu otimizado por AG	Método baseado em Niblack	Método baseado em Rosin
Substância cinzenta	1,185	3,326	3,380
Substância branca	0,253	0,489	0,568
Líquor	0,816	1,973	2,018

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] M. Prince, "Dementia in developing countries: a consensus statement from the 10/66 Dementia Research Group", *International Journal of Geriatric Psychiatry*, vol. 15, pp. 14-20, 2000.
- [2] A. S. d. Souza, "Espectroscopia de prótons na demência de Alzheimer e no comprometimento cognitivo," *Faculdade de Medicina*. Universidade de São Paulo, 2005.
- [3] R. L. Marchetti, C. M. C. Bottino, D. Azevedo, S. K. N. Marie, and C. C. d. Castro, "Confiabilidade de medidas volumétricas de estruturas temporais mesiais," *Arquivos de Neuro-Psiquiatria*, vol. 60, 2002.
- [4] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE Transactions on Systems*, vol. 9, pp. 62-66, 1979.
- [5] C. A. Glasbey, "An analysis of histogram-based thresholding algorithms," *Graphical Models and Image Processing*, vol. 55, pp. 532-537, 1993.
- [6] W. Synder, G. Bilbro, A. Logenthiran, and S. Rajala, "Optimal thresholding a new approach," *Pattern Recognition Letters*, vol. 11, pp. 803-810, 1990.
- [7] J. Kapur, P. Sahoo, and A. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," *Computer Vision, Graphics and Image Processing*, vol. 29, pp. 273-285, 1985.
- [8] C. H. Li and C. K. Lee, "Minimum cross entropy thresholding," *Pattern Recognition*, vol. 26, pp. 617-625, 1993.
- [9] H. D. Cheng, Y. H. Chen, and X. H. Jiang, "Thresholding using two-dimensional histogram and fuzzy entropy principle," *IEEE Transactions on Image Processing*, vol. 9, pp. 732-735, 2000.
- [10] P. Y. Yin, "A fast scheme for optimal thresholding using genetic algorithms," *Signal Processing*, vol. 72, pp. 85-95, 1999.
- [11] J. Holland, *Adaptation in Natural and Artificial Systems*: The University of Michigan Press, 1975.
- [12] E. D. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*: Wesley Longman, 1989.

- [13] W. Niblack, "An introduction digital image processing," E. Cliffs, Ed. New York: Prentice Hall, 1986, pp. 115-116.
- [14] M.-L. Feng and Y.-P. Tan, "Contrast adaptive binarization of low quality document images," *IEICE Electronics Express*, vol. 1, pp. 501-506, 2004.
- [15] P. Rosin, "Unimodal thresholding," *Pattern Recognition*, vol. 34, pp. 2083-2096, 2001.
- [16] U. Ramer, "An iterative procedure for the polygonal approximation of plane curves," *CGIP*, vol. 1, pp. 244-256, 1972.
- [17] J. Shuhong, L. Xuenguang, and L. Xin, "An improved Ostu method for image segmentation," *ICSP Proceedings*, vol. 2, pp. 16-20, 2006.
- [18] T. Pun, "Entropic thresholding: a new approach," *Computer Graphics and Image Processing*, vol. 16, pp. 210-239, 1981.
- [19] R. S. d. Mattos and Á. Veiga, "Otimização de entropia: implementação computacional dos princípios maxent e minxent," *Pesquisa Operacional*, vol. 22, pp. 37-59, 2002.
- [20] L. R. Long and G. R. Thoma, "Indexing of image content in spine x-ray," *Proceedings of SPIE Storage and Retrieval for Image and Video Databases*, vol. 8, pp. 55-63, 2000.
- [21] C. A. Cocosco, V. Kollokian, R. K. S. Kwan, and A. C. Evans, "BrainWeb: online interface to a 3D MRI simulated brain database," *Proceedings of 3D International Conference on Functional Mapping of the Human Brain*, vol. 5, pp. 425-430, 1997.
- [22] D. L. Collins, A. P. Zijdenbos, V. Kollokian, J. G. Sled, N. J. Kabani, C. J. Holmes, and A. C. Evans, "Design and construction of a realistic digital brain phantom," *IEEE Transactions on Medical Imaging*, vol. 17, pp. 463-468, 1998.
- [23] Mendes Vilson Berilli, Leta Fabiana Rodrigues, "Escolha de um método padrão para medição automática de Dureza" In: *XXXV Sipiósio Brasileiro de Pesquisa Operacional*, Anais do XXXV SBPO, 2003.
- [24] Renata Martins Nogueira e Renata da Silva Barros, "Análise de Imagens Médicas Por Texturas", Monografia de fim de curso , IC/UFF - 6/7/2007