




Aula 3 – Segmentações, avaliações, e operações pontuais em imagens

Análise de Imagens - 2015

Aura Conci

Apresentação trabalho 1: posição da paciente na captura da imagem térmica



Formas de Captação da Imagem



TRABALHOS: 2015/2

Trabalho 1


Para 26/08:

- Cada aluno deve fazer um esquema (ou uma implementação simples) que relacione a distancia da paciente ate´ câmara, de modo que na distancia em que ela se posicione haja uma ocupaço de $x\%$ (por exemplo 90%) da largura da imagem , pela largura , L , do corpo da paciente, nas aquisiçes das imagens Infra-Vermelhas realizadas no HUAP.
- Recomendamos para isso assistir a apresentaço da tese de doutorado do Lincoln em 13/08/2015 `as 14 horas. Onde ele apresenta esse trabalho do curso como um dos trabalho futuros da nossa linha de pesquisa em detecço precoce de doenças da mama.
- O esquema ou trabalho implementado ´ para ser mostrado e explicado oralmente na sala de aula, como uma apresentaço rpida de alguns slides em .PPT.
- Os prprios alunos da turma verificaro os pontos fortes e fracos de cada trabalho discutindo-os em sala de aula.
- O trabalho mais completo receber a maior nota
- Trabalho com resultados errados no poder receber nota maior que 5.


Etapas do processamento de imagem digital: SEGMENTAÇÃO




Segmentação de Lesões de Pele



Lesão Maligna



Dermatologista A

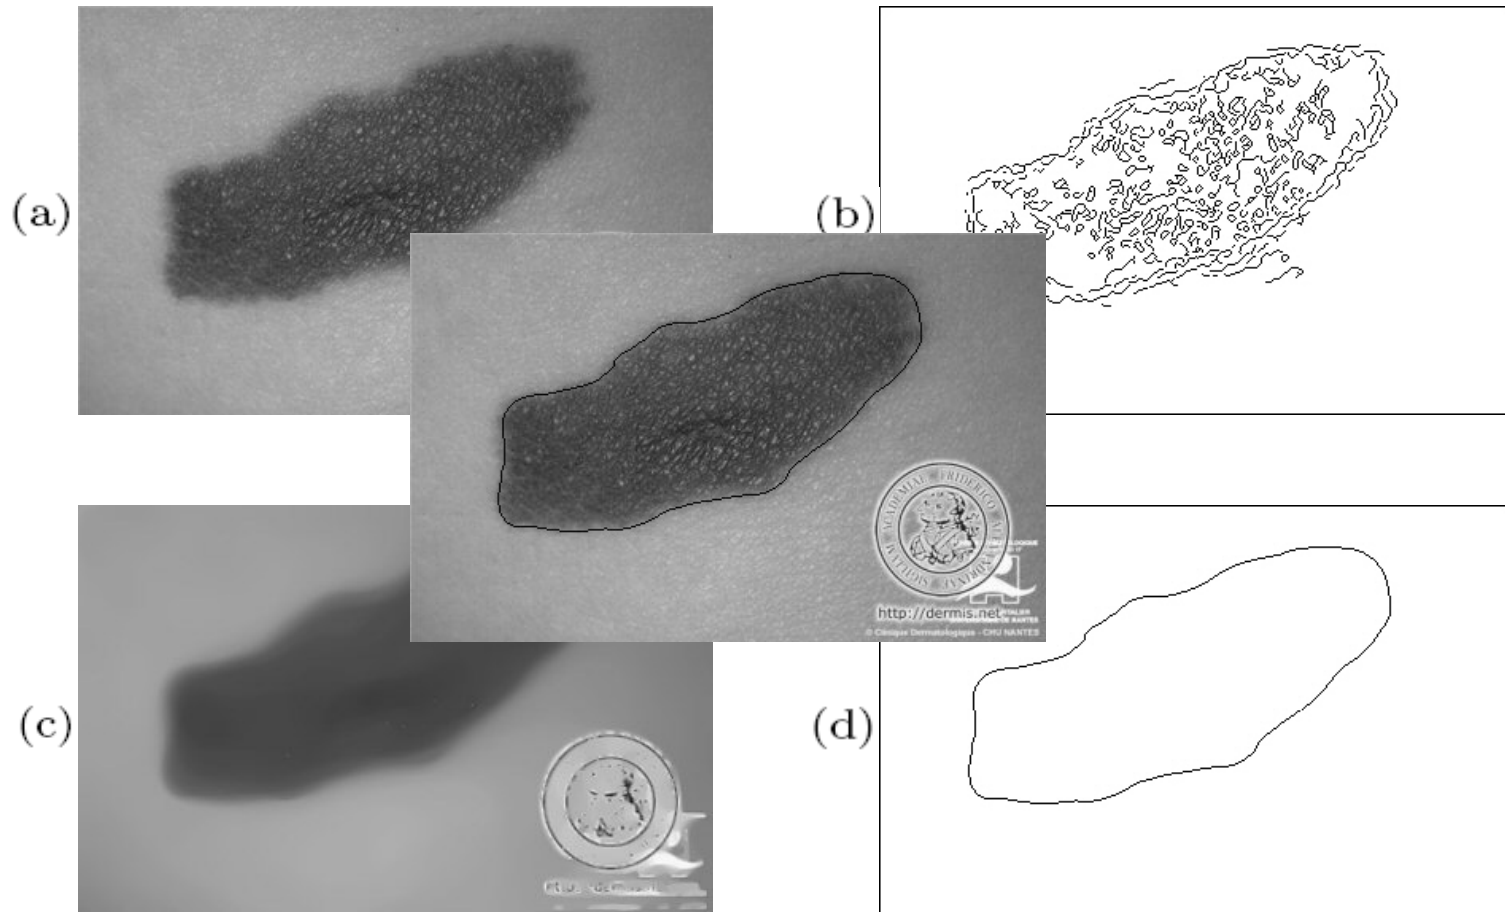


Dermatologista B

Descrição do Problema

- **Irregularidade das bordas** - é o fator de diagnóstico mais significativo para análise clínica do melanoma maligno;
- **O delineamento do contorno da lesão depende da subjetividade humana;** dificuldades em avaliar visualmente a irregularidade das bordas de uma lesão principalmente em regiões onde a transição da lesão para a pele circunvizinha é muito suave.
- Foi pedido para 5 dermatologistas que marcassem as bordas de 25 imagens. Esta experiência foi repetida três vezes com o intervalo de alguns dias. O exemplo anterior mostrou desenhos manuais de 2 dermatologistas.
- **Mas mesmo o mesmo especialista dificilmente fará 2 x a mesma segmentação**
- Assim é importante ter :
 - Um conjunto verdade (ground truth ou gold standard)
 - Formas de comparar os diversos resultados


Resultados (Lesão Benigna), segmentadas por técnicas diversas




Resultados (Lesão Benigna)



(a)



(b)




(c)

Resultados (Lesão Maligna)



(a)




(b)



(c)


Resultados (Lesão contaminada com ruídos)



(a)



(b)




(c)


Resultados (Lesão com pelos)




(a)



(b)



(c)



(d)

What is **gold standard** and what is **ground truth**?

- *"What has not been examined impartially, has not been well examined. Scepticism is therefore the first step towards truth."* (Denis Diderot, Philosopher)
- <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC4296658/>

Aspectos a considerar:

- reference standard data;
- assess the accuracy of tests;
- evidence-based practice (EBP).
- gold standard for decision-making.
- derive relevant information from databases
- the concept of **ground truth**, which is a set of measures known to be **more accurate than** the measurements of the system you are testing.

Cont.

- The term **gold standard** refers to a **benchmark** that is the available under reasonable conditions.
- It is not the perfect test, but merely the best available one that has a standard with known results.
- The correct interpretation of a test demands to specific concepts such as sensitivity, specificity, prevalence, positive and negative predictive values.

Cont.

- The sensitivity of a test is defined as the proportion of people with the inherent disease who test positive (true-positive).
- The specificity of a test is the proportion of people without the disease that have a negative test (true-negative).
- In some literature, one can find the term 1-specificity that is defined as the rate of false positives (in other words, the percentage of the sample incorrectly identified as positive).
- Typically, a Receiver Operating Characteristic curve (ROC) is used as a graphical representation of the rate of sensitivity and specificity.
- The area under the curve represents the accuracy of the test. The closer the value is to one, the greater the test accuracy.

Cont.

- An ideal diagnostic method hypothetically presents a sensitivity of 100% with respect to detection of injury or illness (identifying all cases of injury or disease in all specimens evaluated or individuals with no false negatives) and a specificity of 100% (without false positives, pointing to injury or illness where there is none).

Cont.


- Higher sensitivity values increase negative predictive values.
- Higher specificity values increase positive predictive values.
- Thus, if the test has higher values of sensitivity and specificity, all people having a positive test result have the disease, while all patients who have a negative test do not have the disease.
- Therefore, there is a trade off between these values.

Cont.

- For example, in Medicine, angiography (arteriography) by contrast was a former gold standard for heart disease.
- A recent study reported the sensitivity of angiography to be 66.5% and the specificity to be 82.6%.
- Now magnetic resonance angiography (MRA) has become the new gold standard, with a reported sensitivity of 86.5% and a specificity of 83.4%

Cont.


- As for ground truth, it can signify the mean value from the collection of data from a particular experimental model (that preferentially uses gold standard method) representing behavioral reference.




The masks from manual segmentations (a-c) and the GT generated by combining them by a voting policy (d).

Cont.

- In conclusion, **gold standard** data or method is related to something that has already been checked (histologically, microscopically, chemically, etc.) and presents the best accuracy (sensitivity and specificity).
- **Ground truth** means data and/or method related to more consensus or reliable values/aspects that can be used as references,



Overlapping automatic segmentation and GT. The TP , TN , FP and FN areas of the ROI are the green, blue, red and orange regions, respectively.



$$Acurácia = \frac{VP + VN}{N}$$

$$Sensibilidade = \frac{VP}{VP + FN}$$

$$Especificidade = \frac{VN}{VN + FP}$$

Cont.

- The accuracy (**ACC**) indicates the proportion of true results (both true positives and true negatives).

$$ACC = (TP + TN) / (FN + FP + TN + TP)$$

Cont.

- Specificity (***ESP***) measures the proportion of negative results that are correctly classified
- $ESP = TN / (TN + FP)$

Cont.

- The calculation of predictive positive ***PDP*** (or predictive negative ***PDN***) aims to show the rate of positive (or negative) relative to the total ratings positive (or negative) provided by the algorithm.
- $PDP = TP / (TP + FP)$
- $PDN = TN / (TN + FN)$

cont

- As this great number of values turns the comparisons rather complex combinations of these have been proposed, as the named Efficiency (***EFI***) and Youden index (***Y-index***):
 - $EFI = \frac{1}{2}(SEN+ESP)$
 - $Y-index = (SEN+ESP-1)$


Nossos próximos exercícios

- Segmentar por diversos métodos de limiarização automática o corpo caloso, cada aluno estuda, apresenta e implementa uma forma de limiarização ,
- E comparar os resultados na mesma imagem de MR do cérebro.
- Por diferença simétrica e
- as medidas anteriores




<http://www.cerebromente.org.br/n15/mente/lateralidade.html>


- os dois hemisférios cerebrais têm funções especializadas e diferentes
- o corpo caloso tem, como uma das principais funções, permitir a comunicação entre os dois hemisférios, transmitindo a memória e o aprendizado.




Planos de corte:




Body Planes



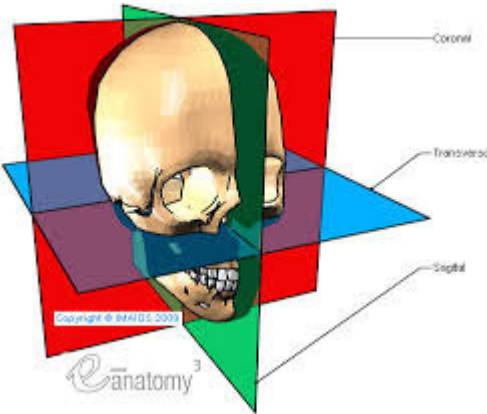
Sagittal/Anteroposterior Plane



Frontal/Lateral Plane



Horizontal/Transverse Plane



Coronal

Transverse

Sagittal

Copyright © 2011

anatomy³

TRABALHOS: 2015/2

Trabalho 2 e 3

Para 02/09 3 09/09

- Trabalho 2(Para 02/09☺)
- Cada aluno deve ler e apresentar um dos métodos de limiarização comentados a seguir em sala .
- Cada aluno tem o tema de um método diferente.
- Deve descrever a ideia básica do método e do seu o algoritmo .
- Depois fazer a sua implementação.
- O trabalho é para ser entregue escrito e apresentado em ppt. , com pontos suficientes para que o mesmo seja implementado.
- O que será o **Trabalho 3**, para a aula seguinte (09/09/2015)
- Essa ainda será avaliado em um grupo de imagens de RM a ser fornecidas pela professora.
- Queremos verificar que métodos dão resultados mais semelhantes, pelas medidas de comparação.

Segmentação baseada no histograma

Limiarização (Thresholding):

Manual

Automática:

Método de Otsu, Método de Niblack, Entropia máxima (Pun) , Equilíbrio do histograma; Análise da Concavidade do Histograma, Rosin

<http://www.ppgia.pucpr.br/~facon/Binarizacao/LimiarOstuNovo3.PDF>

O histograma de uma imagem:

- representa a frequência relativa de ocorrência dos diferentes níveis de cinza na imagem. Ele pode ser calculado pela função discreta: $h(r_k) = n_k$,
- onde :
- r_k corresponde ao k-ésimo nível de cinza e
- n_k é o número de pixels com intensidade r_k presentes na imagem

A limiarização **converte** uma imagem de entrada:

$f(x, y)$ de N níveis de cinza

em uma imagem $g(x, y)$, chamada de imagem limiarizada (ou **posterizada**), com número de níveis de cinza menor do que N .

No limite, $g(x, y)$, terá só dois níveis de cinza, como na equação:

$$g(x, y) = \begin{cases} R_1 & \text{se } f(x, y) \leq T \\ R_2 & \text{se } f(x, y) > T \end{cases}$$

Entropia

- A entropia foi originalmente introduzida como uma medida macroscópica da organização de sistemas termodinâmicos.
- Mais tarde foi aplicada na Teoria da Informação por Claude Shannon .
- A entropia é freqüentemente utilizada para indicar a quantidade de informação contida em uma determinada fonte. Mas também é utilizada para graduar a desordem (incerteza) de um conjunto de dados.

entropia

- informação atribuída ao evento i é inversamente relacionada à probabilidade de sua ocorrência, ou seja, quanto mais incomum for o evento i , maior será sua contribuição para o aumento da entropia.
- Considerando a imagem como resultado de um processo aleatório, a probabilidade p_i corresponde à probabilidade de um pixel em uma imagem digital assumir um valor de intensidade i ($i=1, \dots, G$).
- O histograma dos níveis de intensidade da imagem se transforma na função densidade de probabilidade (fdp) da imagem, dividindo cada número de pixels de intensidade i , g_i , pelo número de pixels na imagem, N .

entropia

$$H = -\sum_{i=1}^G p_i \log p_i, \quad \sum_{i=1}^G p_i = 1, \quad p_i = \frac{g_i}{N}$$

Sendo:

g_i é a quantidade de pixels com intensidade i .

G é o número de níveis de cinza na imagem (ou no canal).

p_i representa a probabilidade do nível de cinza i ser encontrado na imagem.

N é a quantidade total de pixels da imagem (altura x largura).

H é a entropia da imagem.

O menor valor para a entropia é zero, isso ocorre quando todos os pixels são de uma mesma intensidade k , isto é, a probabilidade $p_k=1$ e $p_i=0$ para $i \neq k$, deixando de existir incerteza.

No outro extremo, a máxima entropia ocorre quando uma imagem contém a mesma quantidade de pixels para todas as intensidades (ruído branco), isto é, todas as intensidades têm a mesma probabilidade de ocorrerem.


- a entropia não está relacionada com a disposição espacial da informação.



(a) $H = 0$



(b) $H = 1$



(c) $H = 1$

Métodos de Limiarização


• <https://www.youtube.com/watch?v=qoB9cBeVUPA>

Principais Métodos Automáticos :

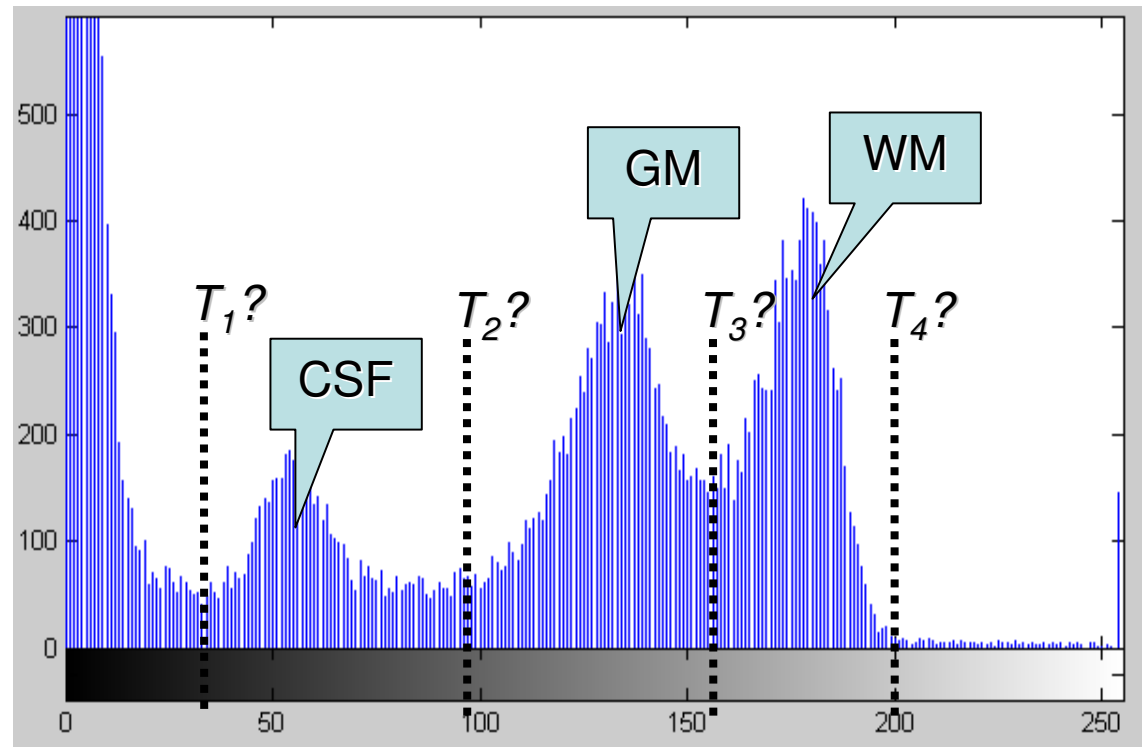
1. Limiarização por equilíbrio do histograma;
- 2. Limiarização em multiníveis de Otsu;**
- 3. Limiarização em multiníveis de Niblack;**
- 4. Entropia máxima;**
- 5. Limiarização em multiníveis de Rosin.**
6. Busque mais alguns:

Experimentação

Seção RM do Crânio



Histograma



Estruturas do encéfalo:
CSF: líquido
GM: subst. cinzenta
WM: subst. branca

$T_n?$ → Nível teórico de
limiarização de cada
estrutura

Fonte: Projeto *Brainweb*

<http://brainweb.bic.mni.mcgill.ca/brainweb/>

Método de Otsu

A operação de limiarização é considerada como sendo o particionamento da imagem com L níveis de cinza em duas classes C_0 e C_1 , que representam o **objeto** e o fundo, ou vice-versa, sendo que esta partição se dará no **nível de cinza t** , *que maximiza a razão da variância entre as classes e a variância total*

C_0 = pixels da imagem com tons de 0 a t

C_1 = pixels da imagem com tons de t a l

Método de Otsu para escolher o melhor *threshold*: T .

Se baseia no **histograma normalizado** (da imagem)., que pode ser visto como uma função de **densidade de probabilidade discreta**

(histograma normalizado)

$$p_r(r_q) = \frac{n_q}{n}, q = 0, 1, 2, \dots, L - 1$$

onde n é o número total de píxeis na imagem, n_q é o número de píxeis que tem intensidade r_q

O **método de Otsu** escolhe o threshold de valor T *que maximiza*:

$$\sigma_B^2 = \omega_0(\mu_0 - \mu_T)^2 + \omega_1(\mu_1 - \mu_T)^2$$

$$\sigma_B^2 = \omega_0(\mu_0 - \mu_T)^2 + \omega_1(\mu_1 - \mu_T)^2$$

onde,
$$w_0 = \sum_{q=0}^{k-1} p_q(r_q)$$

$$W_0 = \sum_{q=k}^{L-1} p_q(r_q)$$

$$m_1 = \sum_{q=k}^{L-1} qp_q(r_q)/\omega_1$$

$$m_0 = \sum_{q=k}^{L-1} p_q(r_q)$$

$$m_T = \sum_{q=0}^{L-1} qp_q(r_q)$$

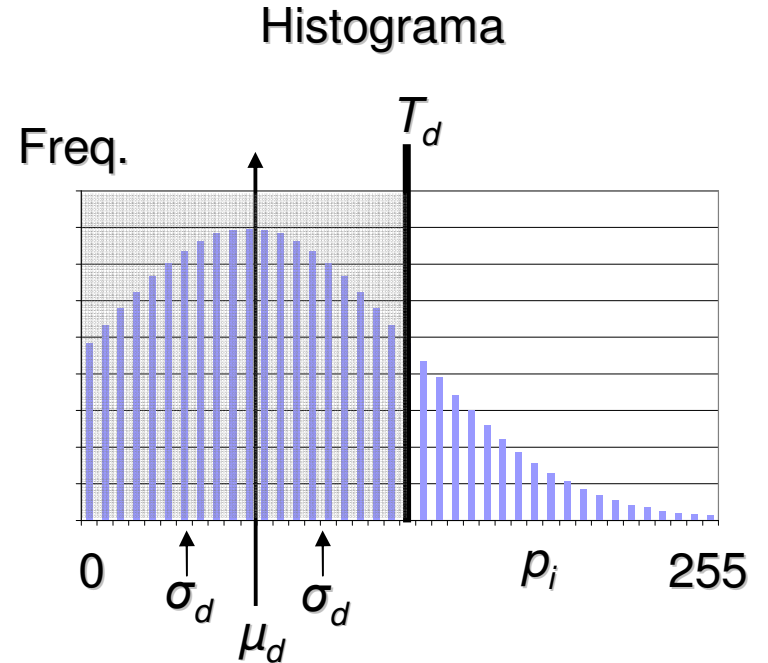
Métodos de Otsu:

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

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

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

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



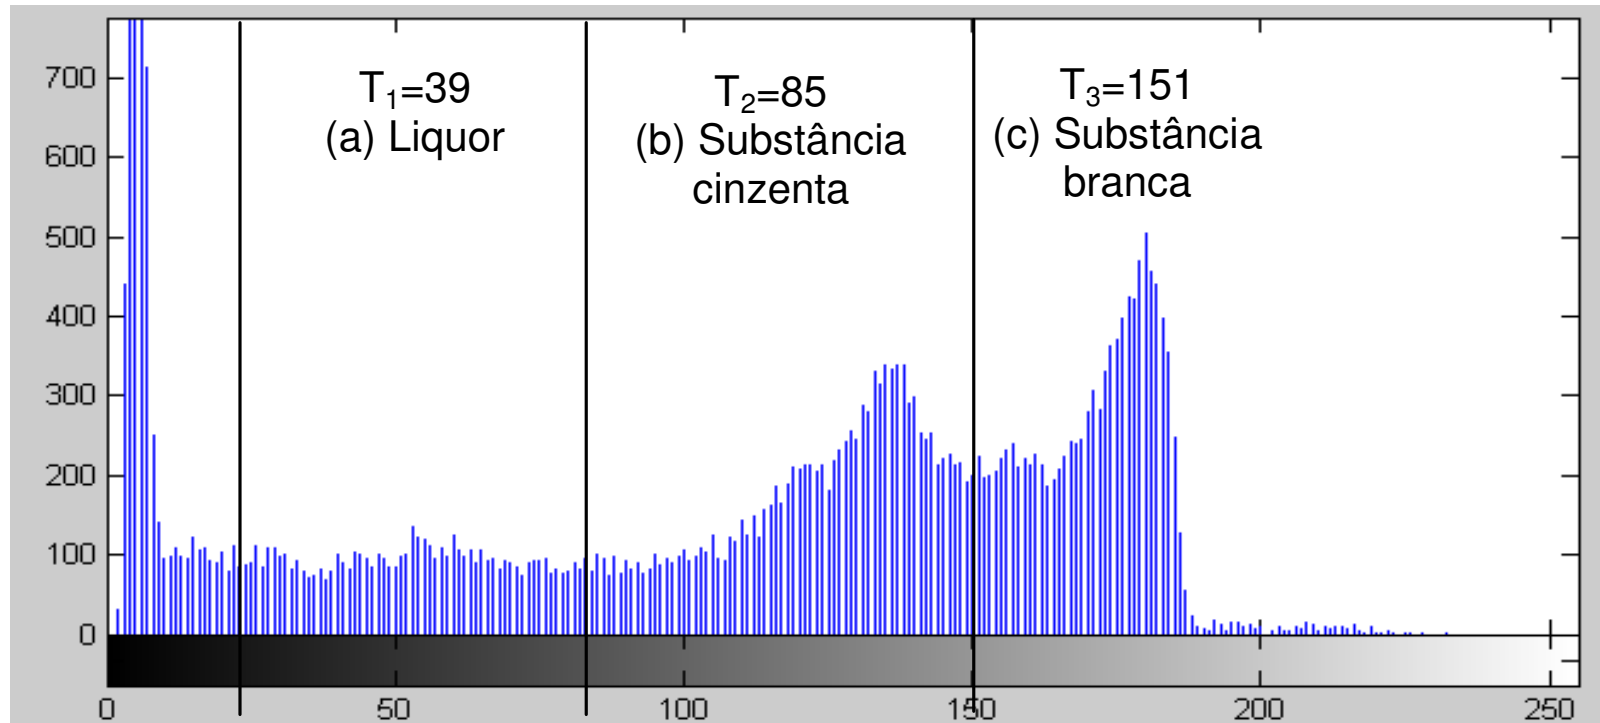
Função Objetivo: $\text{Min } f(T_1, T_2, \dots, T_{d-1}) = \sum_{i=1}^d q_i \cdot \sigma_i^2$

Segmentação utilizando método de Otsu:

Considerações:


Três níveis de limiarização T_1 , T_2 e T_3

Histograma




comparação dos Resultados

Imagens binárias geradas pela segmentação por limiarização, utilizando os níveis encontrados pelo método de Otsu:



Unir as áreas para calcular volumes


Considerando a conectividade das regiões:



Líquor



Subst. cinzenta



Subst. branca

Imagens binárias geradas pela segmentação por limiarização, utilizando os níveis encontrados pelo método de Limiarização em Multiníveis de Niblack:

Os resultados encontrados através da aplicação do algoritmo de Niblack para seleção dos limites de cada região (segmentação) foram: $T_1 = 39$, $T_2 = 77$, $T_3 = 149$.



Líquor



Subst. cinzenta




Subst. branca

Este método iterativo:
descrito por:

1. **Selecione** um tom T_i inicial (entre o valor da intensidade mínima e máxima da imagem.)
2. **Segmente** imagem usando T_i . Isto é, divida-a em **dois grupos**: (G1) formado com os pixels cujos valores são $> T$ e (G2) com os pixels com tons $< T$.
3. Calcule a **intensidade média** dos grupos: μ_1 e μ_2
4. Calcule o **novo threshold**: $T_{i+1} = \frac{1}{2} (\mu_1 + \mu_2)$
5. Repita os passos **2 até 4** até que $T_{i+1} - T_i < (\text{parâmetro pré-definido})$

- A **limiarização por equilíbrio do histograma** é muito simples e automático.
- Na mesma linha do método de **Otsu** é baseado no histograma da imagem: assumindo que a imagem se divide em duas classes: o fundo e o objeto.
- Procura encontrar o nível de limiarização *pesando* o histograma.
- Depois remove peso do lado mais pesado até que este se torne o mais leve.
- Repete a mesma operação até que os se equilibrem.



em C

```
int BHThreshold(int[] histogram) {
    i_m = (int)((i_s + i_e) / 2.0f); // Base da balança I_m
    w_l = get_weight(i_s, i_m + 1, histogram); // peso na esquerda W_l
    w_r = get_weight(i_m + 1, i_e + 1, histogram); // peso na direita W_r
    while (i_s <= i_e) {
        if (w_r > w_l) { // mais peso à direita
            w_r -= histogram[i_e--];
            if (((i_s + i_e) / 2) < i_m) {
                w_r += histogram[i_m];
                w_l -= histogram[i_m--]; } }
        else if (w_l >= w_r) { // mais peso à esquerda
            w_l -= histogram[i_s++];
            if (((i_s + i_e) / 2) > i_m) {
                w_l += histogram[i_m + 1];
                w_r -= histogram[i_m + 1];
                i_m++; } } }
    return i_m; }
```

Limiarização em Multiníveis de Niblack

Método de limiarização local de bom desempenho.

Constrói 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:

$$T = m + k \cdot s$$

onde k é uma constante

Niblack multinível \rightarrow segmenta RMI em várias regiões importantes do cérebro.

Algoritmo Niblack Multinível

1. Define-se o tamanho da janela w .
2. Define-se o valor da constante k de limiarização adaptativa.
3. Lê a imagem I em tons de cinza que se queira segmentar.
4. Obtém o número de linhas e colunas dessa imagem.
5. Desliza essa janela w pela imagem I até obter o novo valor de tom para cada pixel em I .
6. Calcula a média e o desvio padrão e em seguida o valor de T .
7. Verifica todos os valores de limiarização e armazena as faixas de limiarizações.
8. Percorre toda a imagem considerando uma faixa de cada vez e armazena os valores para cada faixa. São três faixas para verificar a limiarização: faixas T_1 para o liquor, T_2 para a substância cinzenta e T_3 para a substância branca.
9. Percorre 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).

Limiarização em Multiníveis de Niblack

- Desvantagens:
 - produz uma grande quantidade de ruídos em imagens com muitos tons de cinza.
 - processamento posterior intenso computacionalmente para redução ou remoção de ruídos.
 - Definição do tamanho da vizinhança → deve ser pequeno suficiente para preservar detalhes locais mas grande o suficiente para suprimir ruídos

O histograma de uma imagem:

- representa a frequência relativa de ocorrência dos diferentes níveis de cinza na imagem. Ele pode ser calculado pela função discreta: $h(r_k) = n_k$,
- onde :
- r_k corresponde ao k-ésimo nível de cinza e
- n_k é o número de pixels com intensidade r_k presentes na imagem

Equalização de Histograma

Na equalização global do histograma a intensidade de cada pixel da imagem é substituída pela integral do histograma da imagem até aquele pixel.

A nova intensidade s para todos os pixels com intensidade r da imagem original é calculada a partir da transformação : $T(r)$ representada pela equação:

$$s = T(r) = \sum_{j=0}^k p_r(r_j), \quad k = 0, 1, 2, 3, \dots, L$$

Cont.

- onde L é o total de níveis de cinza e $p(r)$ é a probabilidade de ocorrência do nível de
- Cinza r na imagem, que pode ser obtido através do histograma da imagem. Após a
- aplicação da transformação $T(r)$ a imagem resultante apresentará um histograma mais uniforme.

Características da Equalização

- Em geral, esta técnica funciona bem se a distribuição das intensidades dos pixels é similar em toda a imagem.
- Caso contrário, a equalização do histograma global da imagem pode aumentar demasiadamente o brilho de regiões mais luminosas e não iluminar suficientemente pequenas regiões escuras.
- Dar uma aparência falsa as imagens.

Operações pontuais em imagens

Global x local

Uma operação pontual **global** m uma imagem digital r é a função $f(r)$ aplicada a **todo** *pixel* da imagem:

$$r: s = f(r)$$


Outras operações globais baseadas em histograma

Equalização

O objetivo da equalização de imagens é a **melhoria** do seu contraste.

Para tanto, o ideal é que os níveis de cinza sejam representados de **maneira uniforme e distribuída**.

A equalização de histograma consiste na **redistribuição dos valores** de nível de cinza em uma imagem, de forma que todos os *pixels* tenham a probabilidade de aparecer mais **equalitária possível**.



(a) Imagem com baixo contraste e seu histograma.

(b) Imagem após equalização e seu histograma.

Especificação Direta

A equalização de histogramas procura distribuir igualmente para todos os níveis de *pixels* da imagem o que **não permite estabelecer parâmetros de mudança capazes de ressaltar faixas de níveis de cinza** na imagem.

Esta pode ser realizada por outra técnica chamada de especificação direta de histograma.





Imagem original e seu histograma normalizado (mais proximo de um distribuição normal)

Normalização do Histograma

Na normalização global do histograma a intensidade de cada pixel da imagem é substituída pela integral do histograma de uma curva normal (conhecida também como Distribuição de Gauss ou Gaussiana) até aquele pixel.

A nova intensidade s para todos os pixels com intensidade r da imagem original é calculada da comparação entre os 2 histogramas acumulados.



Se $\mu = 0$ e $\sigma = 1$, a distribuição é chamada de **distribuição normal padrão** e a função de densidade de probabilidade reduz-se a



$$f(x) = \frac{1}{\sqrt{2\pi}} e^{\left(-\frac{x^2}{2}\right)}.$$

Em uma **distribuição normal**, a área azul escura representa cerca de 68% , enquanto a em azul médio e escuro representa cerca de 95%. Em azul claro, médio e escuro tem-se cerca de 99.7%.

Equalização com limitação de contraste

- Para contornar o problema de amplificação de ruído e aumento excessivo de contraste surgiu , a técnica de equalização do histograma com limitação de contraste (*CLHE - Contrast Limited Histogram Equalization*) que corta, no histograma local, todas as intensidades em que o número de pixels esteja acima de um limite definido, e as redistribuí no histograma.

Como se representa o processo CLHE.



AHE - Adaptive Histogram Equalization

- Para superar esta limitação, surgiram as técnicas de equalização adaptativa de histograma.
- Nessas técnicas, em vez do histograma global, é calculado um histograma local para vizinhança de cada pixel, por exemplo de 7×7 , 15×15 , etc. ao redor do pixel.
- A qualidade do resultado depende das características da imagem e vizinhança usada!

Características do AHE


- Esse método melhora o contraste local da imagem, realçando ainda mais os detalhes.
- Porém, existe a tendência de ampliar o ruído em regiões relativamente homogêneas da
- imagem.
- Contrastes em menor escala são reforçados enquanto que contraste em maior escala são reduzidos.

Equalização adaptativa de histograma com limitação de contraste


: *CLAHE - Contrast Limited Adaptive Histogram Equalization*)

- O CLAHE foi inicialmente utilizado em imagens médicas tendo um sucesso considerável (Pizer et al., 1987).
- Em geral, o CLAHE produz melhores resultados do que a equalização adaptativa sem limitação de contraste.
- A seguir um comparativo de um exemplo de uma mamografia em seu formato original, com equalização de histograma global e com a aplicação do CLAHE para janelas de 8x8


Exemplo de como fica para cada janela:



(a) Sem realce



(b) Equalização global de histograma



(c) CLAHE

Operações pontuais em imagens

Operações pontuais baseadas na curva de tom

Operações baseadas em histograma

Técnicas com operações ponto a ponto em imagens

Sobrando tempo em sala:

- Explicar os não mencionados na aula 2: slides 17 a 34.

Bibliografia Complementar:

<http://www.ic.uff.br/~aconci/OTSUeOutras.pdf>

Limiarização de Pun e Kapur: .../~aconci/curso/binari~3.htm

Chow e Kaneko: <http://www.ic.uff.br/~aconci/limiarizacao.htm>

Otsu : tese Leonardo Hiss Monteiro do IC:2002

Dissertação: Jonh Edson Ribeiro de Carvalho “Uma Abordagem de Segmentação de Placas de Automóveis baseada em Morfologia Matemática- 2006

F. L. Seixas, A. Martins, A. R. Stilben, D. Madeira, R. Assumpção, S. Mansur, S. M. Victor, V. B. Mendes e A. Conci, AVALIAÇÃO DOS MÉTODOS PARA A SEGMENTAÇÃO AUTOMÁTICA DOS TECIDOS DO ENCÉFALO EM RESSONÂNCIA MAGNÉTICA <http://www.ic.uff.br/~aconci/pub2008.html>

<http://eof.alunos.dcc.fc.up.pt/wiki/index.php/Otsu>