

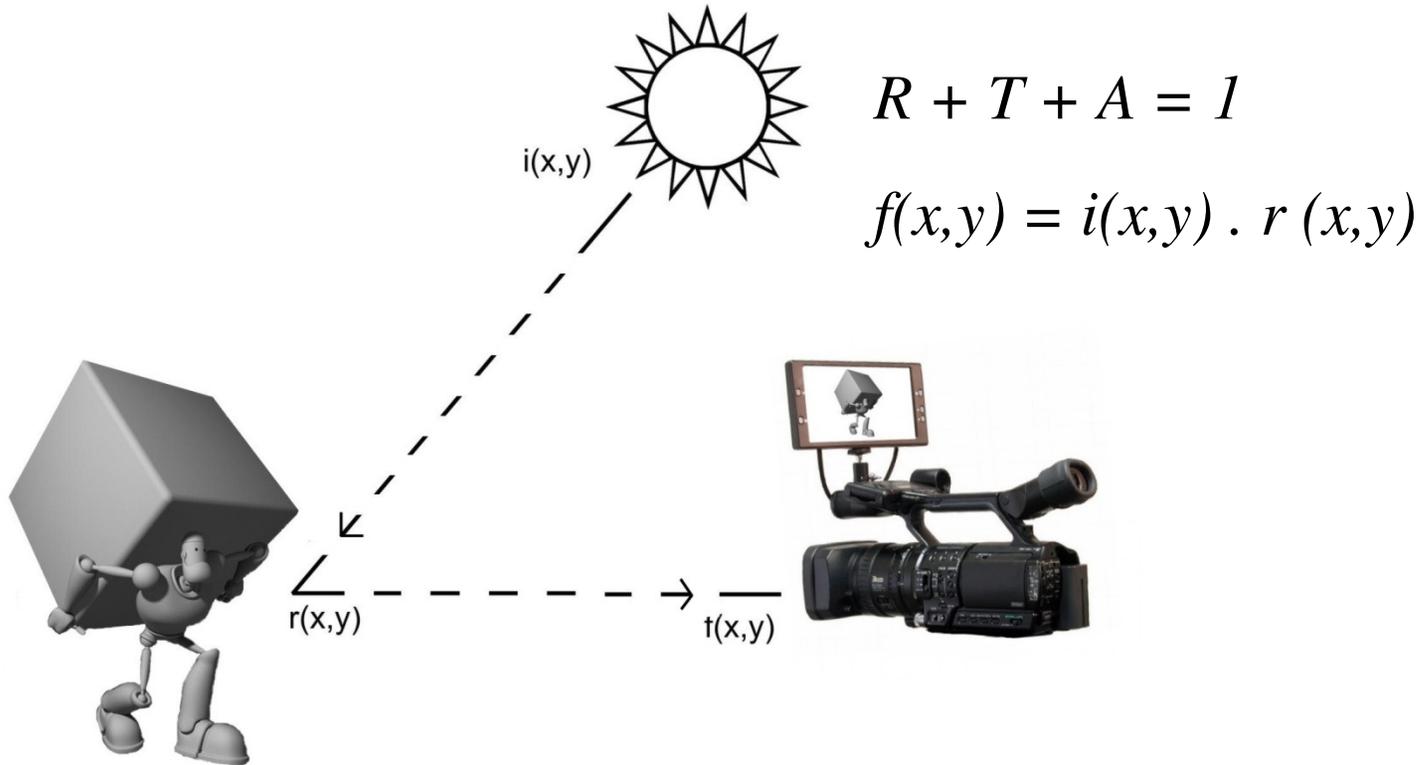


Aula 2 – importância do histograma em Análise de Imagens

Análise de Imagens - 2015

Aura Conci

Aquisição de Imagens



Aquisição da Imagem.

Amostragem e Quantização

- **Amostragem** (*sampling*) – refere-se ao número de pontos adquiridos (pixels) que são usados na imagem digitalizada (resolução espacial).
- **Quantização** - quantidade de tons que pode ser atribuído a cada ponto digitalizado (no. bits que representam cada pixel).

Imagens reais possuem um número **ilimitado** de cores ou tons. No processamento de **imagens computacionais** é necessário **limitar** os níveis de **cores ou tons** possíveis de serem atribuídos a cada *pixel* da imagem (tem uma **gradação tonal finita**).

Amostragem e Quantização

$$f(x, y) = z$$

Amostragem (*sampling*) \rightarrow número de pixels = $x \times y$.

Quantização \rightarrow (no. bits que representam z) .

Segmentação

Objetivo



Isolar **regiões da imagem** (conjunto de pontos) de interesse por serem pertencentes a objetos ou partes importantes para posterior análise (como extração de atributos e cálculo de parâmetros descritivos) .

Extração de Atributos ou Características

Objetivo



A partir de imagens já segmentadas (em objeto e fundo) ou binárias busca obter **dados relevantes** ou atributos, das regiões ou objetos destacados.

Os tipos de atributos ou características mais comuns são: número total de objetos; **dimensões; geometria; propriedades de cor, luminosidade e textura.**

Classificação e Reconhecimento

Distinguir objetos na imagem agrupando-os, classificando-os ou reconhecendo-os segundo parâmetros dependentes da aplicação

Os objetos são:

reconhecidos como pertencentes a um mesmo grupo e então sejam classificados de acordo com uma **base de dados ou imagens.**

apresentados para o sistema, que compara suas **características** com aquelas de classes previamente estabelecidas.

Decisão

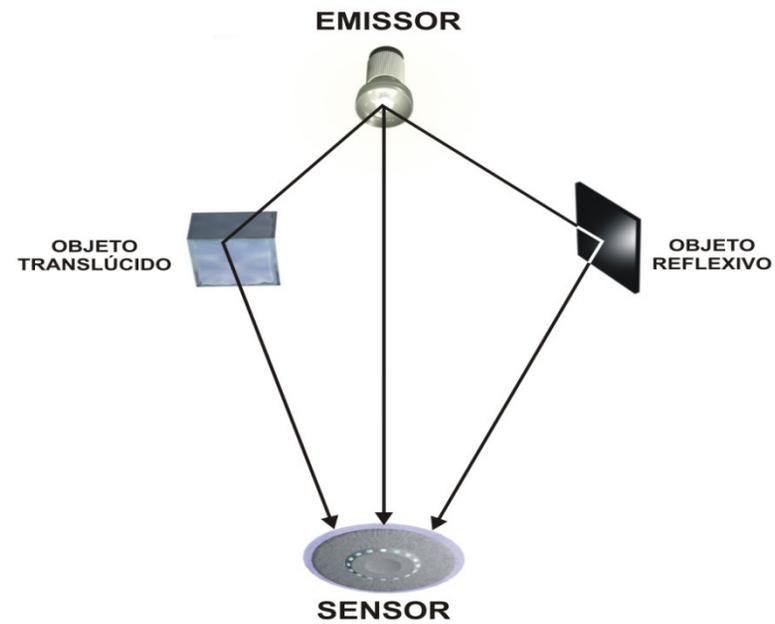
O objetivo de um sistema de VC é tomar decisões a partir da **extração de informações** do mundo real através de imagens.

A tomada de decisão pode ser feita a partir de **análises simples** (*menores distâncias, funções discriminantes, técnicas de clusterização, etc.*) ou de algoritmos mais complexos de **Inteligência Artificial** – IA (*SVM, redes neurais, fuzzy, etc.*) .

Imagem Digital

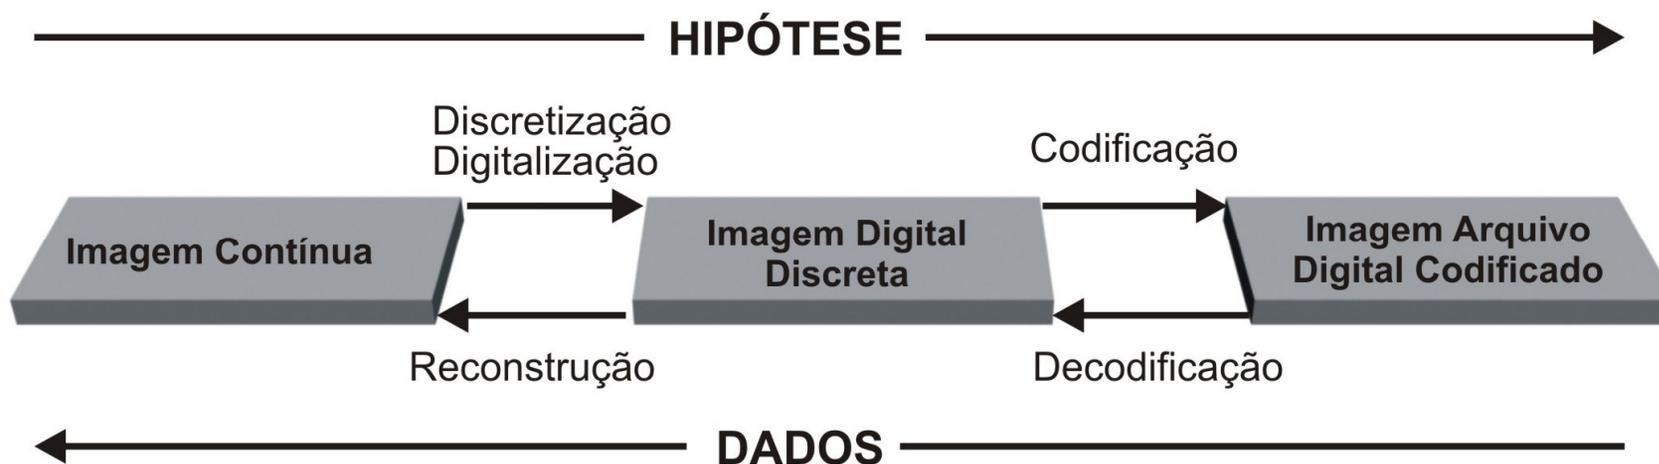
- Do latim *imago* - representação visual de um objeto.
- Em grego é chamada de *eidos* (raiz etimológica do termo *idea* ou *eide*) – considera a *idea* da coisa a sua imagem, seria uma projeção na mente.
- Imagem pode ser **adquirida** ou **gerada** pelo ser humano.
- Em sentido amplo uma imagem consiste em qualquer **forma visual de expressão de uma idéia.**

Formas de captação de uma imagem



Formas de Captação da Imagem por Radiação

Etapas do processamento de imagem digital



Discretização - conversão da imagem na forma contínua em uma representação discreta.

Reconstrução - processo inverso da discretização.

Codificação - a partir da representação da imagem, gera-se um conjunto de dados representativos dela, estes que podem ser transformados em **arquivos**.

Decodificação - processo oposto à codificação no qual acessam-se informações codificadas para mostrá-la novamente como imagem.

Discretização e Reconstrução

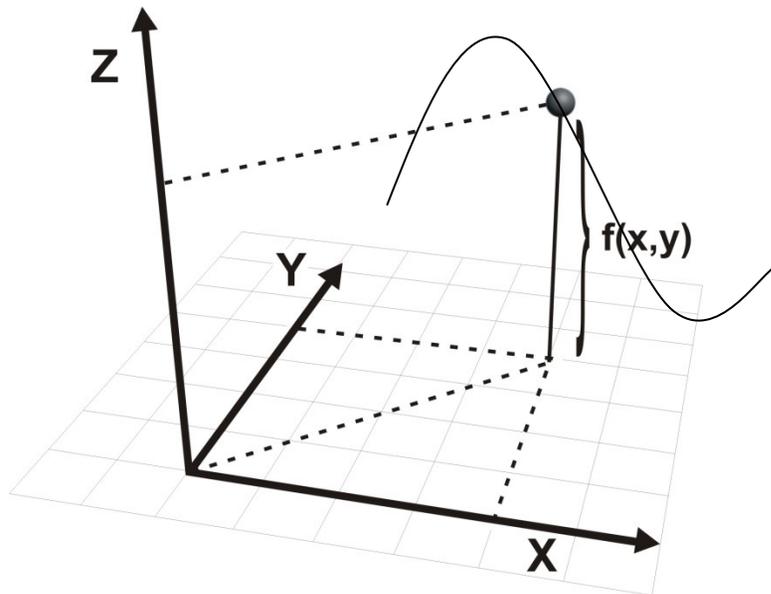
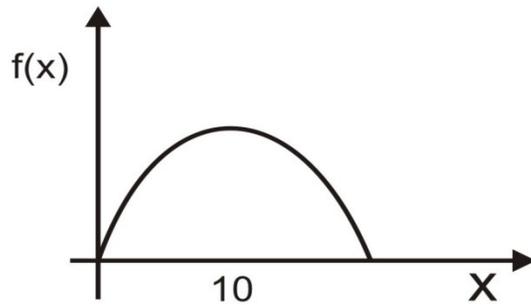


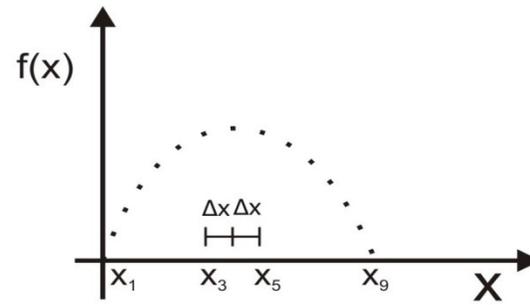
Gráfico de uma imagem contínua.

A forma de representar o mundo contínuo ou uma função contínua no computador é **discretizando-a**.

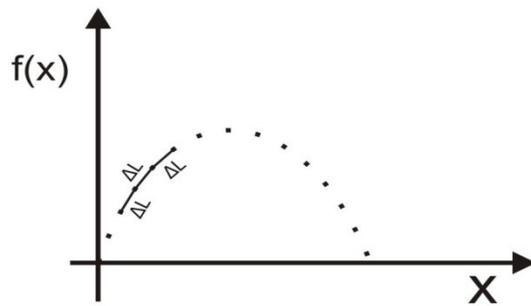
A operação que a partir dos valores discretos retorna uma aproximação da função contínua inicial é chamada de **reconstrução**.



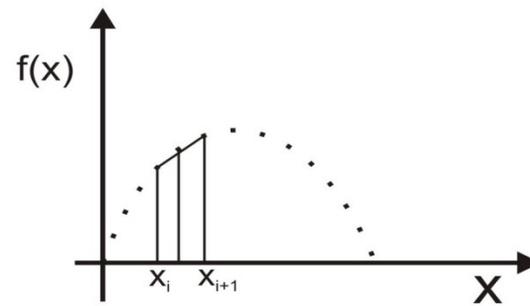
Representação Contínua



Representação Discreta a Intervalos Constantes em x



Amostragem a Intervalos Constantes em Relação a Distância entre os pontos $(x, f(x))$

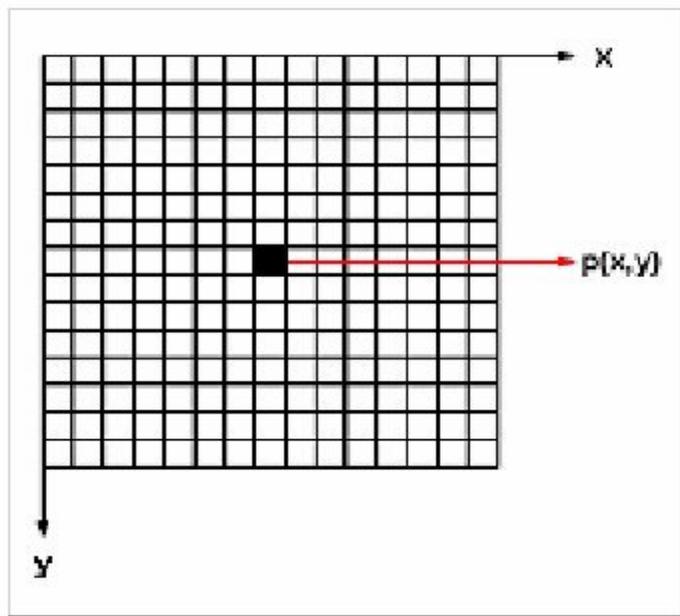


Reamostragem Criando Valores Intermediários por Interpolação Linear por Pares de Valores Anteriores

Formas de **Amostragem** e de **Re-amostragem** de uma função

$$y = f(x) .$$

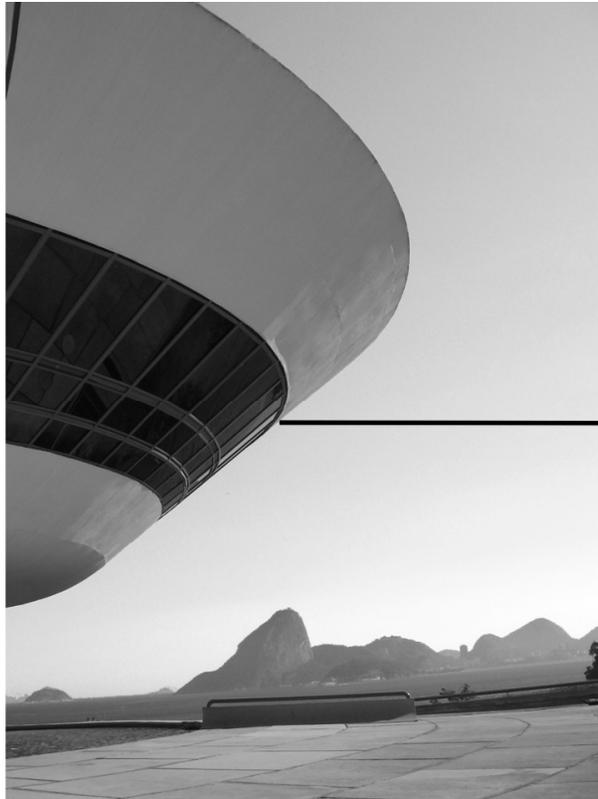
Amostragem e Quantificação



Reticulado uniforme da representação matricial da imagem.

Uma imagem digital é descrita por uma matriz $N \times M$ de valores de *pixel* ($p(x,y)$) inteiros positivos, que indica a intensidade de cor z em cada posição (x,y) da imagem.

Um *pixel* é caracterizado pelo valor de **intensidade** de cor e pela sua **localização** na imagem.

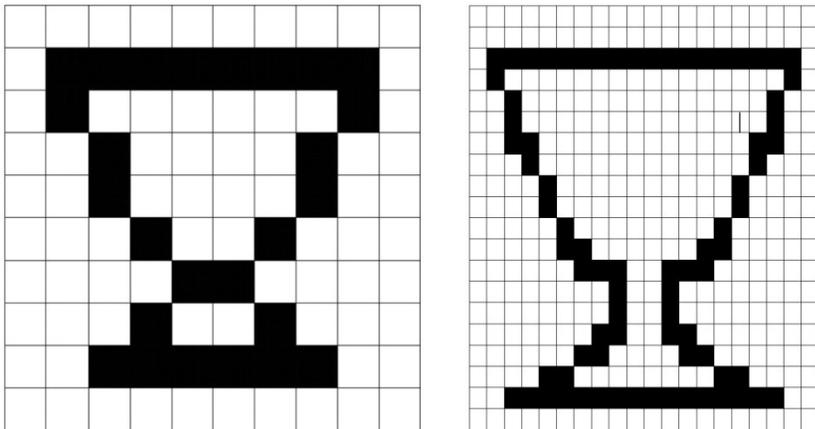


47	52	64	132	153
51	58	121	149	142
49	99	143	144	164
94	135	161	170	199
138	165	180	212	213

Representação matricial de uma região da imagem.

Resolução Espacial

Ao ser digitalizada a imagem assume um **tamanho adimensional**, em *pixels*.



Mesma imagem em duas resoluções, mas exibido no seu tamanho original.

Pode-se conhecer o tamanho da amostragem, conhecendo-se a razão entre o número de *pixels* obtido e um comprimento da imagem real.

A isso chama-se de resolução espacial, que em geral é medida **em pontos por polegada ou dpi** (*dots per inch*).

Imagens reais - > Digitais

Para que sejam representadas no meio digital, seu formato **analógico** (contínuo) tem que ser convertido numa série de valores **discretos** (descontínuos).

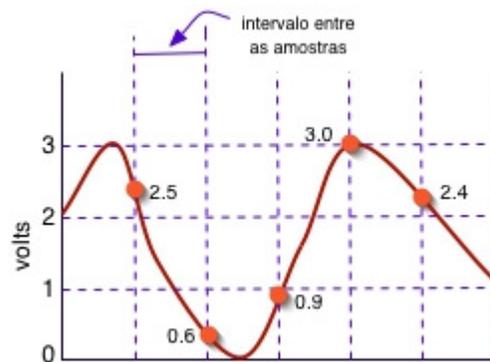
Esses valores são números (**dígitos**) que representam amostras (***samples***)

Amostragem

A conversão do **sinal analógico** para o digital é realizada por uma sequência de amostras da **variação de intensidade** do sinal original.

Cada amostra é arredondada para o número mais próximo da escala usada e depois convertida em um **número digital binário** (formado por "uns" e "zeros") para ser armazenado.

As amostras são medidas em **intervalos fixos.**

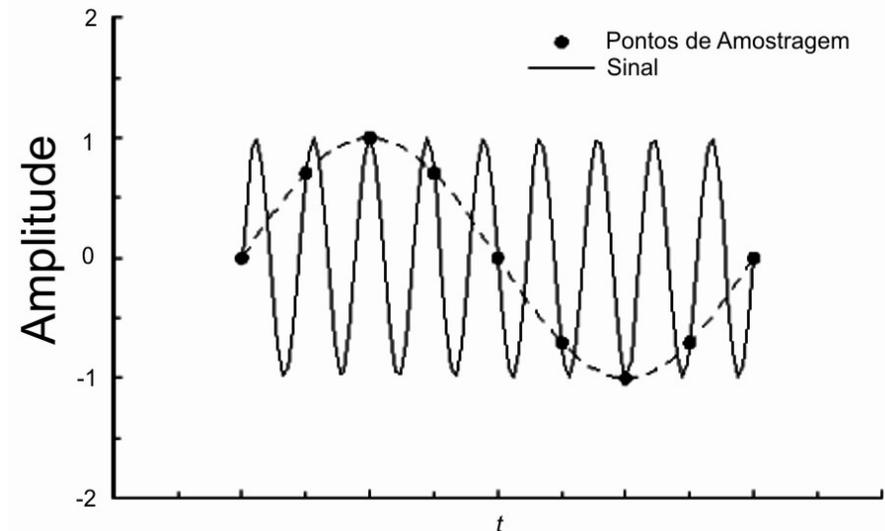


valores das amostras				
2.5	0.6	0.9	3.0	2.4
valores quantizados				
2	0	1	3	2
valores convertidos em dígitos binários				
10	00	01	11	10

O número de vezes em que se realiza a amostragem em uma unidade de tempo é a **taxa de amostragem**

Aliasing

Ocorre quando a **frequência de amostragem é inferior** à frequência de Nyquist.



O sinal digitalizado fica completamente diferente do sinal original devido a sua **baixa frequência de amostragem**.

Teorema de Nyquist

A **taxa de amostragem** deve ser pelo menos **duas vezes a maior** que a frequência que se **deseja registrar**.

Esse valor é conhecido como **frequência de Nyquist**.

Ao se tentar reproduzir uma frequência menor do que a frequência de Nyquist ocorre o fenômeno de **aliasing** (ou *foldover*)

Cuidado os erros se propagam por não se verificar!!

- Ponha no <http://translate.google.com/>
- O texto: “Nyquist was born in the Stora Kil parish of Nilsby, Värmland, Sweden.”
- Peça para ele traduzir para o Sueco e mande ele ler o texto em Inglês e em Sueco.
- Sempre a pronuncia é Nicuist. Logo

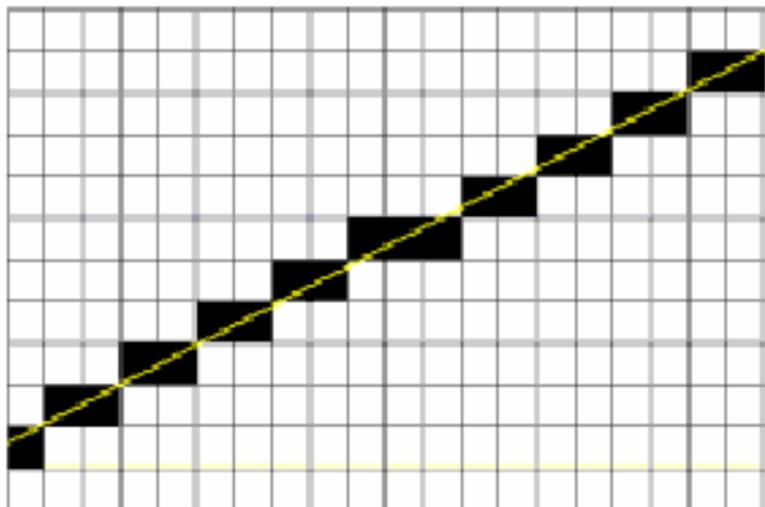
Vejam no site oficial dele:

- He entered the [University of North Dakota](#) in 1912 and received the B.S. and M.S. degrees in electrical engineering in 1914 and 1915, respectively. He received a [Ph.D.](#) in physics at [Yale University](#) in 1917.

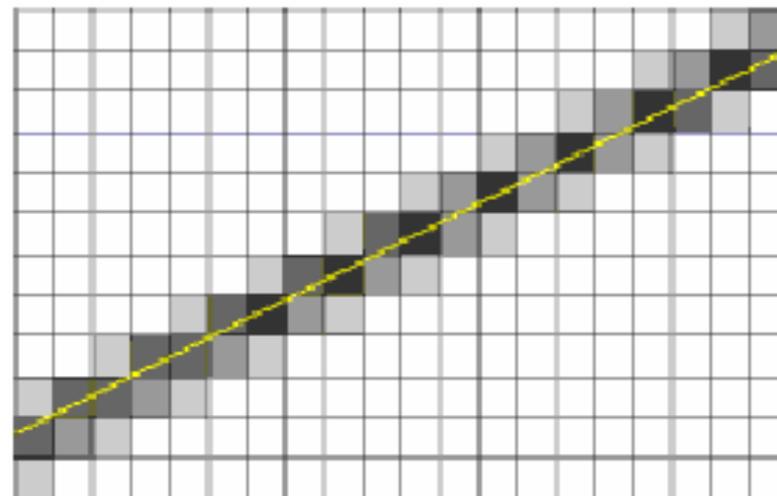


Harry Nyquist (Harry Theodor Nyqvist; pron. [ni:kvist], not [naikwist] as often pronounced), (February 7, 1889 – April 4, 1976) was an important contributor to [information theory](#)

- He worked at [AT&T](#)'s Department of Development and Research from 1917 to 1934, and continued when it became [Bell Telephone Laboratories](#) in that year, until his retirement in 1954.



“Dentes” na representação de retas.



Uma forma de amenizar o problema.

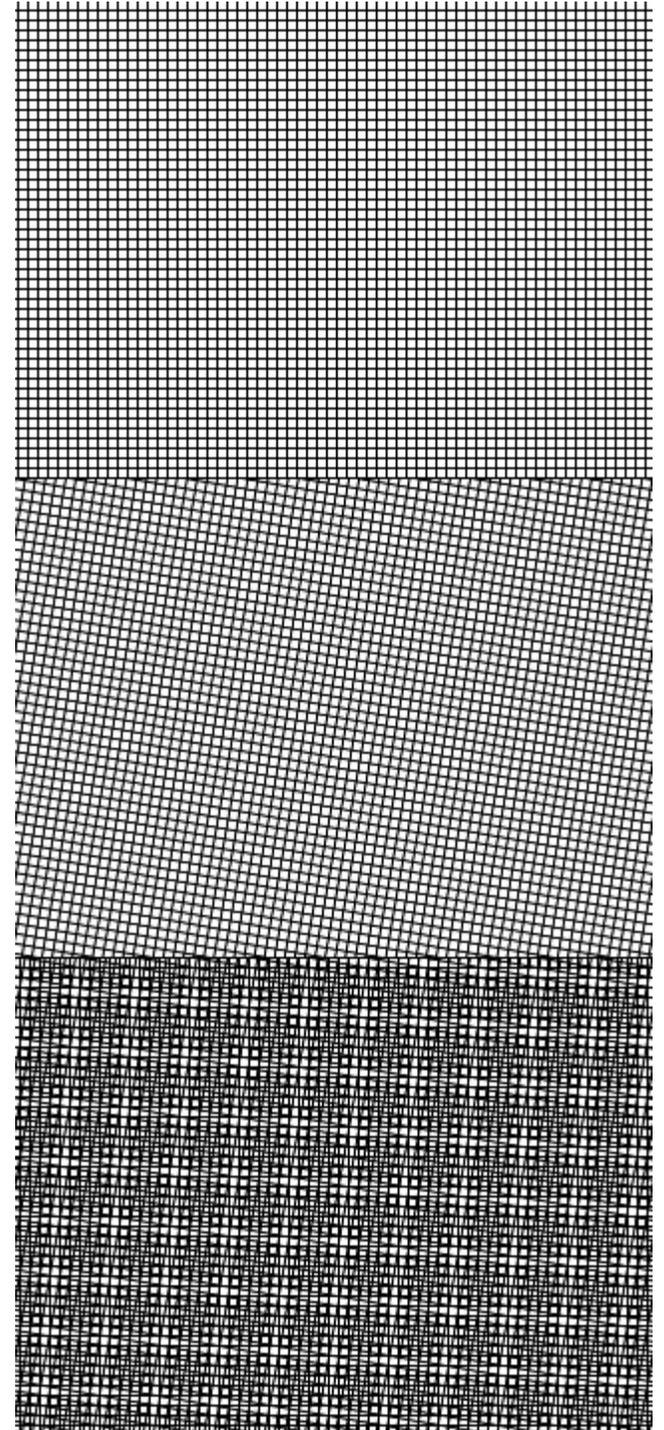
Problema do *aliasing* em descrição de baixa resolução.

Importante não confunda
aliasing com *Moiré*

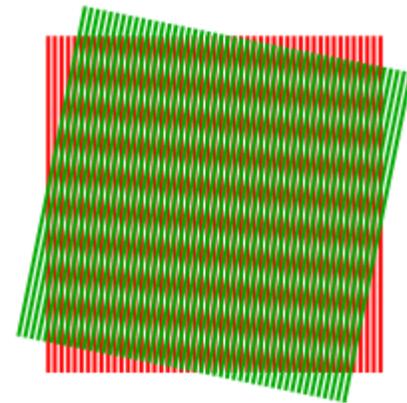
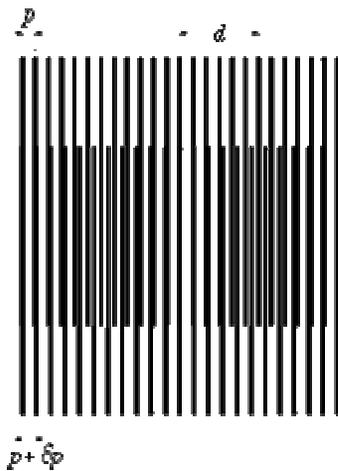
Moiré é um efeito de segunda
ordem:

ocorre quando se
sobreposição **duas resoluções
diferentes** (escaneado em
200dpi e impresso em 300 dpi,
por exemplo); ou há **grids não
alinhados** (rotações ou
aspect ratio)

(site: <http://www.ic.uff.br/~aconci/moire.html>)



Exemplificando a causa dos padrões texturais: *Moirés*



Moiré

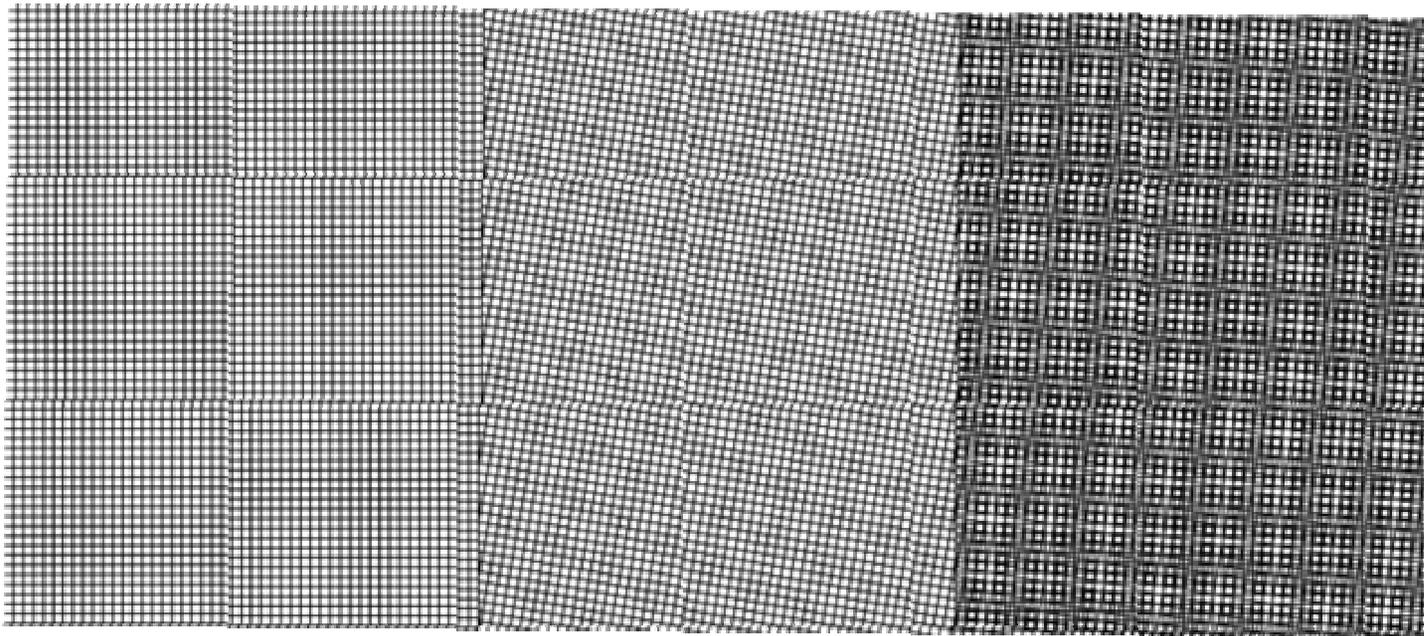
Def.: é um padrão de **interferência** criado quando duas grades são **sobrepostas** em um determinado ângulo, ou quando elas têm pequenas diferenças nos tamanhos da malhas da grade.

http://en.wikipedia.org/wiki/Moire_pattern

- A **moiré pattern** (pronounced [/mwa:'reɪ/](#) in English, [\[mwaze\]](#) in French)
- is an [interference](#) pattern created, for example, when two grids are overlaid at an angle, or when they have slightly different mesh sizes.

The term originates from **moire** (or *moiré* in its French form), a type of [textile](#), traditionally of [silk](#) but now also of [cotton](#) or [synthetic fiber](#), with a rippled or 'watered' appearance.

padrão moiré



Nem sempre uma maior resolução é melhor:

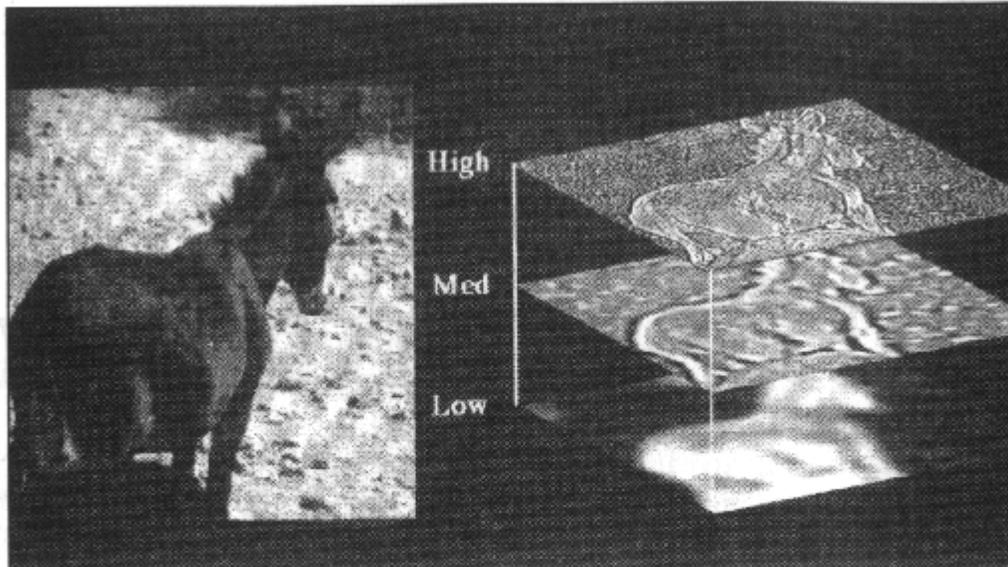


Figure 2. A "natural scene" and its decomposition into high, middle, and low frequencies, using a two-dimensional wavelet transform. The effectiveness of a transform cannot be understood or evaluated in isolation; it depends on the relationship between the transform and the properties of the data to be encoded. Natural scenes have certain statistical properties in common. For example, as shown in the above decomposition, they are redundant: many edges found in low frequencies also exist in middle or high frequencies. Wavelets with a certain narrow bandwidth of frequencies and certain narrow range of orientations can encode natural scenes concisely, with just a few coefficients. (Courtesy of David Field.)

imagem com **140
dpis**

Observe os padrões
na região escura
da imagem.

Nem sempre maior resolução é melhor:

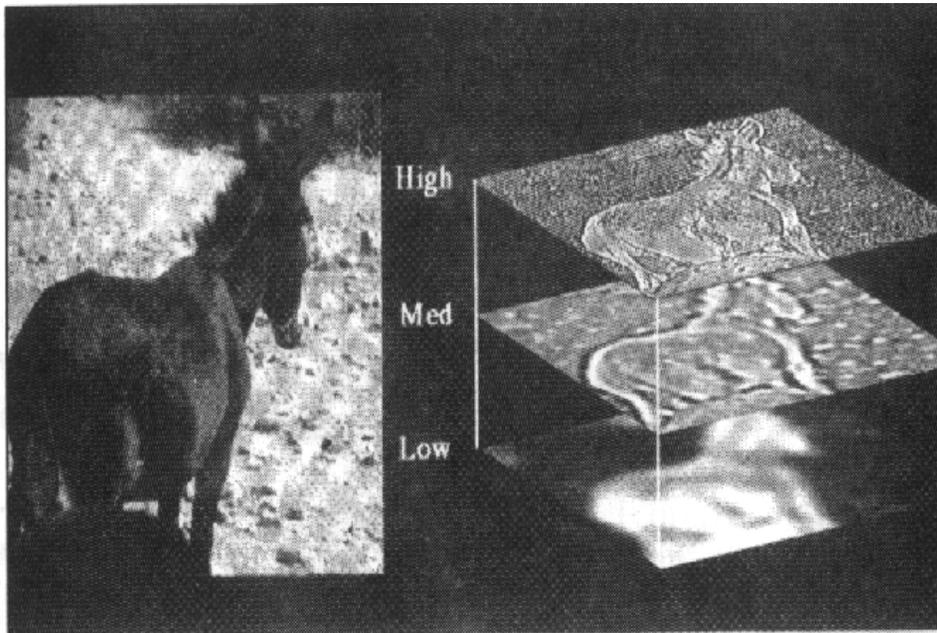


Figure 2. A "natural scene" and its decomposition into high, middle, and low frequencies, using a two-dimensional wavelet transform. The effectiveness of a transform cannot be understood or evaluated in isolation; it depends on the relationship between the transform and the properties of the data to be encoded. Natural scenes have certain statistical properties in common. For example, as shown in the above decomposition, they are redundant: many edges found in low frequencies also exist in middle or high frequencies. Wavelets with a certain narrow bandwidth of frequencies and certain narrow range of orientations can encode natural scenes concisely, with just a few coefficients. (Courtesy of David Field.)

imagem com **180 dpis**

Observe os padrões
Diminuem bem na
imagem.

Nem sempre maior resolução é melhor:

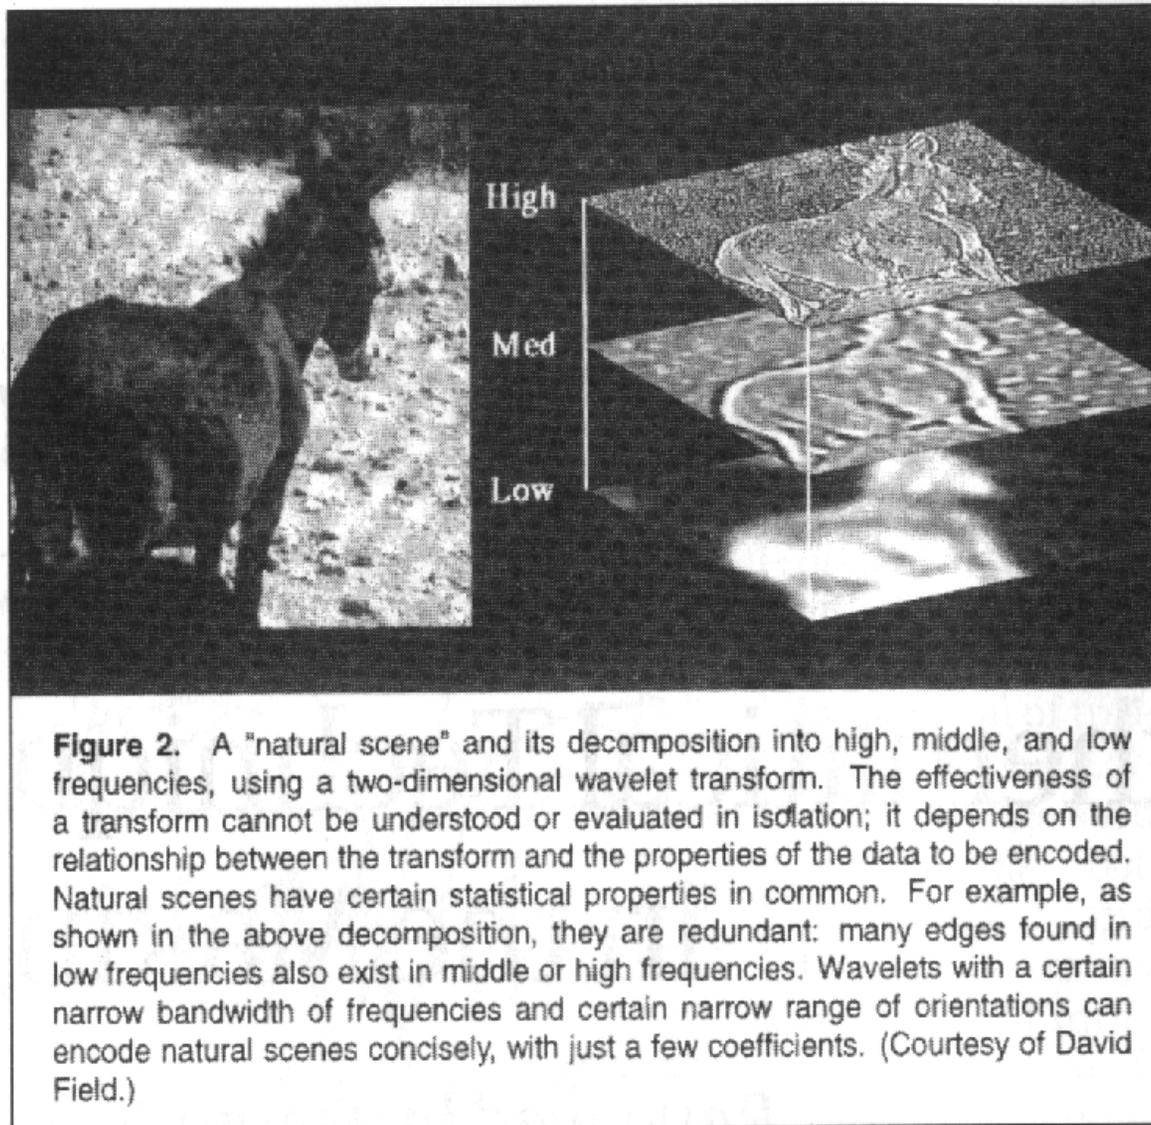


Imagem
200 dpis

Padrões
umentam
tanto na
parte clara
como na
escura
da imagem.

Imagens Monocromáticas

Imagens monocromáticas são imagens digitais onde cada *pixel* possui apenas uma **banda espectral**.



Exemplos de imagens monocromáticas

O número de tons entre os valores limites, **branco e preto**, que se pode representar em tons, depende de quantos **bits** são alocados na matriz de imagem para armazenar o tom de cada *pixel*.

Número de elementos na Escala de cinza	Tons de cinza limites	Números de Bits necessários para representação do <i>pixels</i>
2^1 2 valores	0,1	1
2^3 8 valores	0 a 7	3
2^4 16 valores	0 a 15	4
2^8 256 valores	0 a 255	8

Uma imagem **monocromática** pode ser representada geometricamente também por **valores reais** quanto à posição dos *pixels* como no gráfico $G(f)$ da função f :

$$G(f) = \{ (x,y,z); (x,y) \in R^2 ; z = f(x,y) \} \quad (3.4)$$

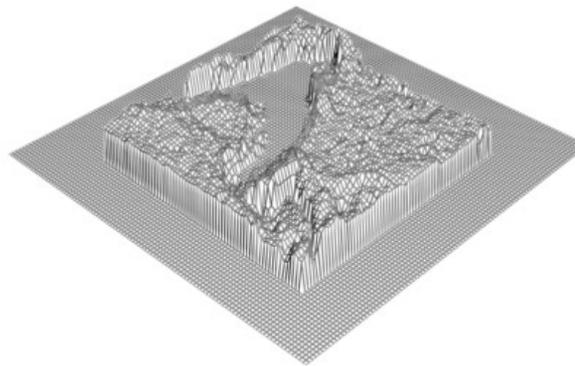


Imagem Monocromática de uma represa e seu gráfico 3D ns forma de sua função $G(f)$ no R^3 .

Imagens Coloridas

Imagens multibandas são imagens digitais onde cada *pixel* possui n **bandas espectrais** ($n > 1$).

Quando uma imagem é representada pela composição de **três bandas visíveis** (como as **RGB**) tem-se uma **imagem colorida aos olhos humanos**.



(a) Imagem Colorida



(b) Banda Vermelha (Red)



(c) Banda Verde (Green)

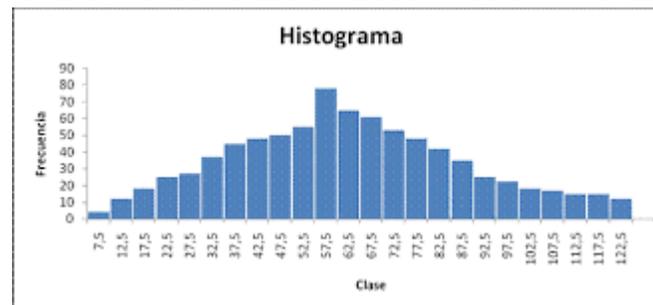


(d) Banda Azul (Blue)

Imagem colorida e cada uma de suas bandas RGB.

histograma,

também conhecido como distribuição de frequências ou diagrama das frequências, é a representação gráfica, em colunas (retângulos), de um conjunto de dados previamente tabulado e dividido em classes uniformes.



Momentos do histograma

Seja l o brilho de uma imagem (ou objeto) e $h(l)$, $l = 0, 1, \dots, L - 1$, o seu histograma normalizado. O n -ésimo momento central é dado por:

$$\mu_n = \sum_{l=0}^{L-1} (l - \mu)^n h(l)$$

$$\mu = \sum_{l=0}^{L-1} lh(l)$$

onde μ é o brilho médio.

Momentos do histograma

- Cont.

Quando $n = 2$, nós temos a variância (contraste) $\mu_2 = \sigma^2$.

Os momentos μ_3 e μ_4 medem *skewness* (assimetria em relação ao centro) e *kurtosis* (concentração em torno da média). Podemos usar, por exemplo, $R = 1 - \frac{1}{1+\sigma^2}$ como medida de contraste. Momentos de mais alta ordem não estão relacionados com a forma do histograma.

Textura: Momentos do Histograma

- Uma das abordagens mais simples para a descrição da textura é através dos momentos do histograma de níveis de cinza de uma região.
- Seja Z uma variável aleatória denotando a intensidade discreta de uma imagem
- Seja $p(z_i)$, $i = 1, 2, \dots, L$, a distribuição de probabilidade associada a esta variável, na qual L é o número de níveis de cinza.

Textura: Momentos do Histograma

- O n-ésimo momento de z em torno da média é dado por

$$\mu_n(z) = \sum_{i=1}^L (z_i - m)^n p(z_i)$$

- na qual m é valor médio de z

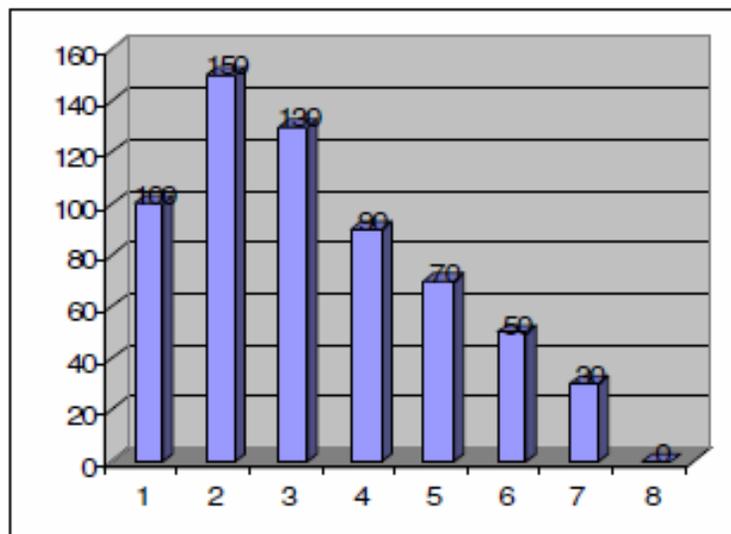
$$m = \sum_{i=1}^L z_i \times p(z_i)$$

Textura: Momentos do Histograma

- O segundo momento possui uma importância particular para a descrição da textura
 - Medida de contraste do nível de cinza
 - Pode ser usada no estabelecimento de descritores de suavidade relativa.
- O terceiro momento é uma medida de anti-simetria do histograma.
- Quatro momento fornece uma medida de achatamento.

Textura: Momentos do Histograma

- Exercício: Considere o seguinte histograma em 8 níveis de cinza.



Calcule o segundo e o terceiro momentos.

Z	P(z)
1	0.16
2	0.24
3	0.20
4	0.14
5	0.11
6	0.08
7	0.05
8	0

$$M=102, M2 = 1274$$

Histograma de imagem digital

O histograma de uma imagem indica o **número** ou o **percentual** de *pixels* que a imagem tem em determinado nível de cinza ou cor.

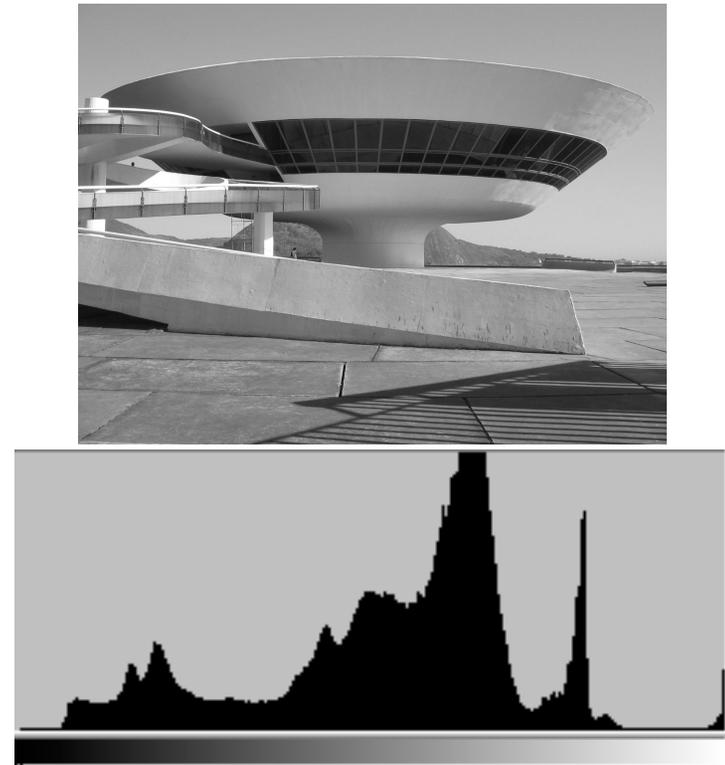
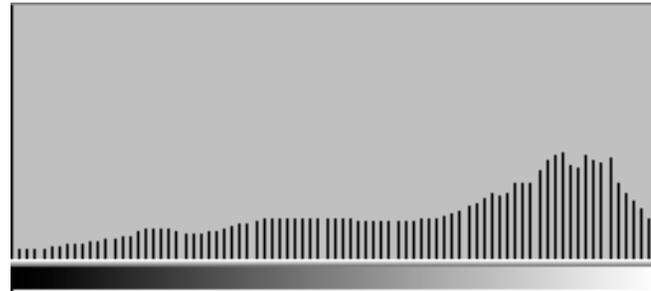
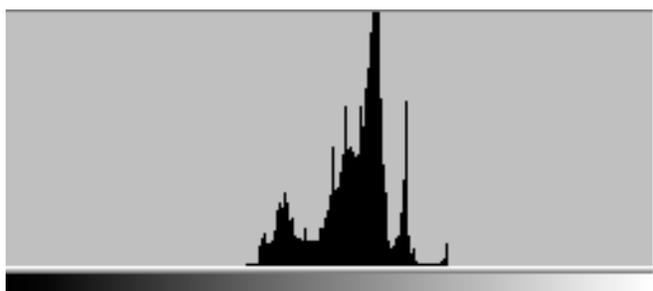
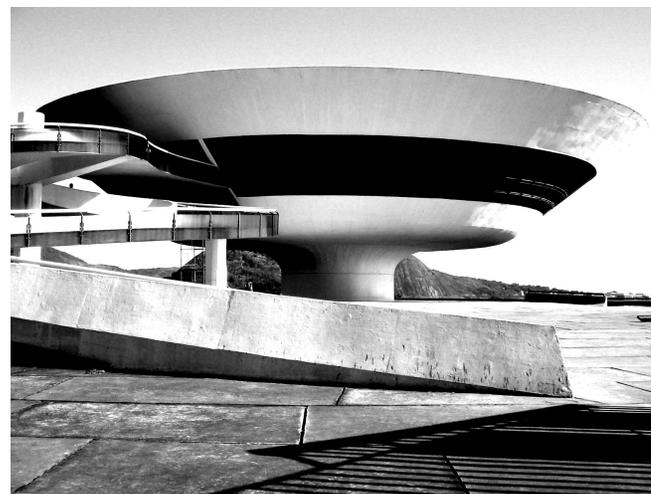
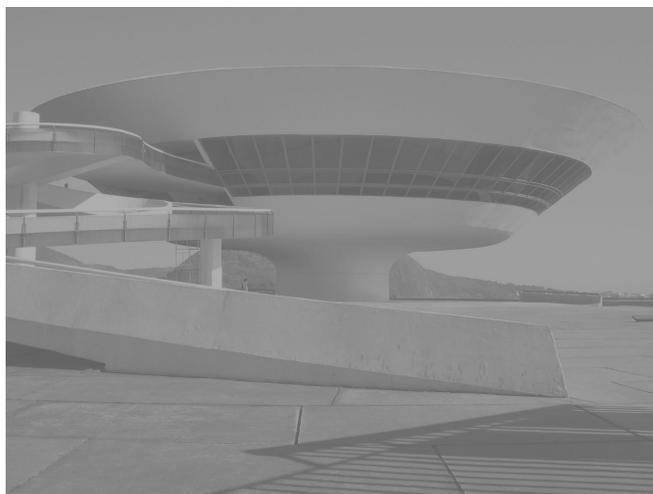
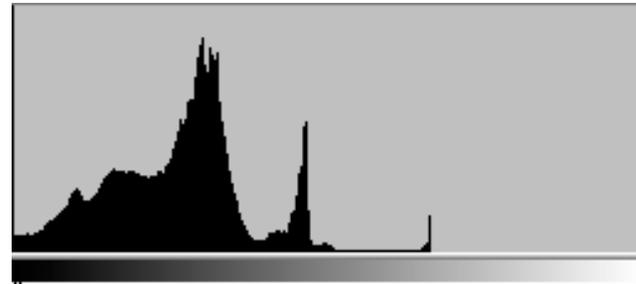
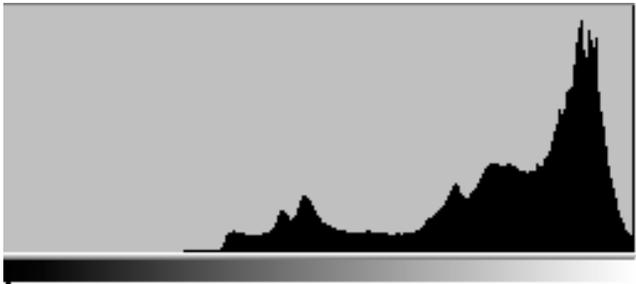


Imagem em tons de cinza e o seu histograma.

O histograma fornece uma indicação da **qualidade da imagem** quanto ao contraste e intensidade luminosa.

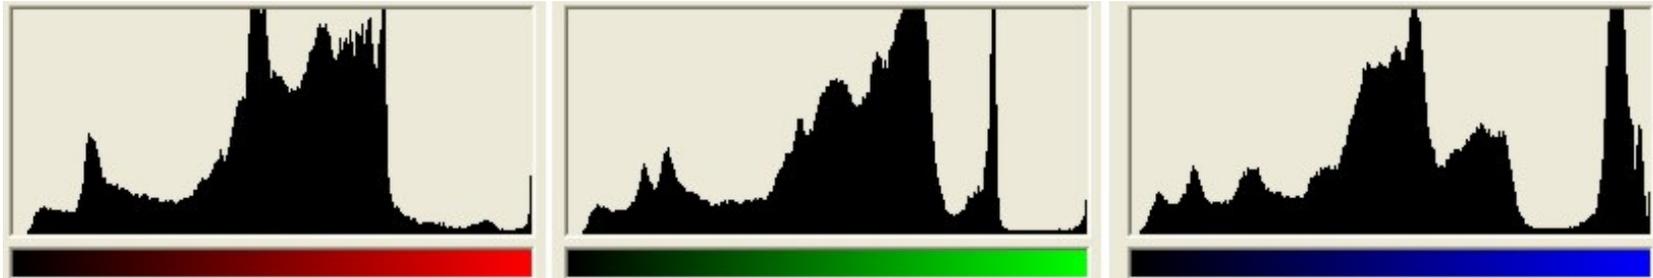
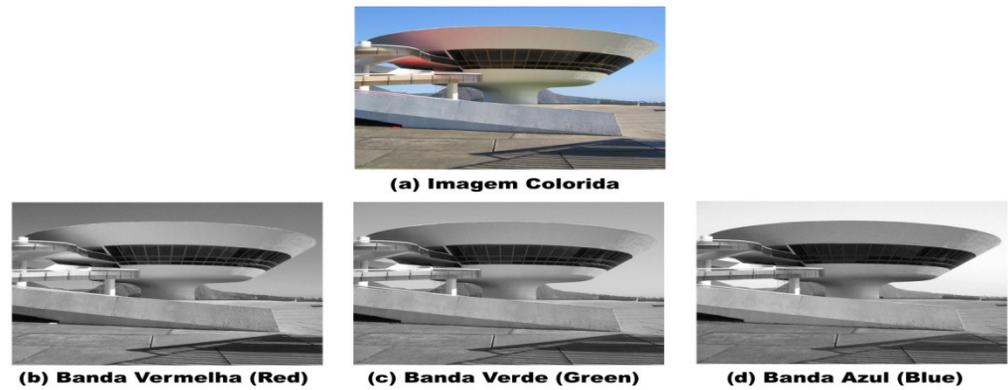


Imagens em tons de cinza e seus respectivos histogramas: com pouco (direita) e bom **contraste** (esquerda).



Imagens em tons de cinza e seus respectivos histogramas: com **alta luminosidade** (clara) e com **baixa luminosidade** (escura).

Histogramas das **bandas** de uma imagem colorida



Histogramas da Imagem colorida separado por canal R,G B.

Sistemas de visão binária

Limiarização (Thresholding):

Manual (baseada no histograma)

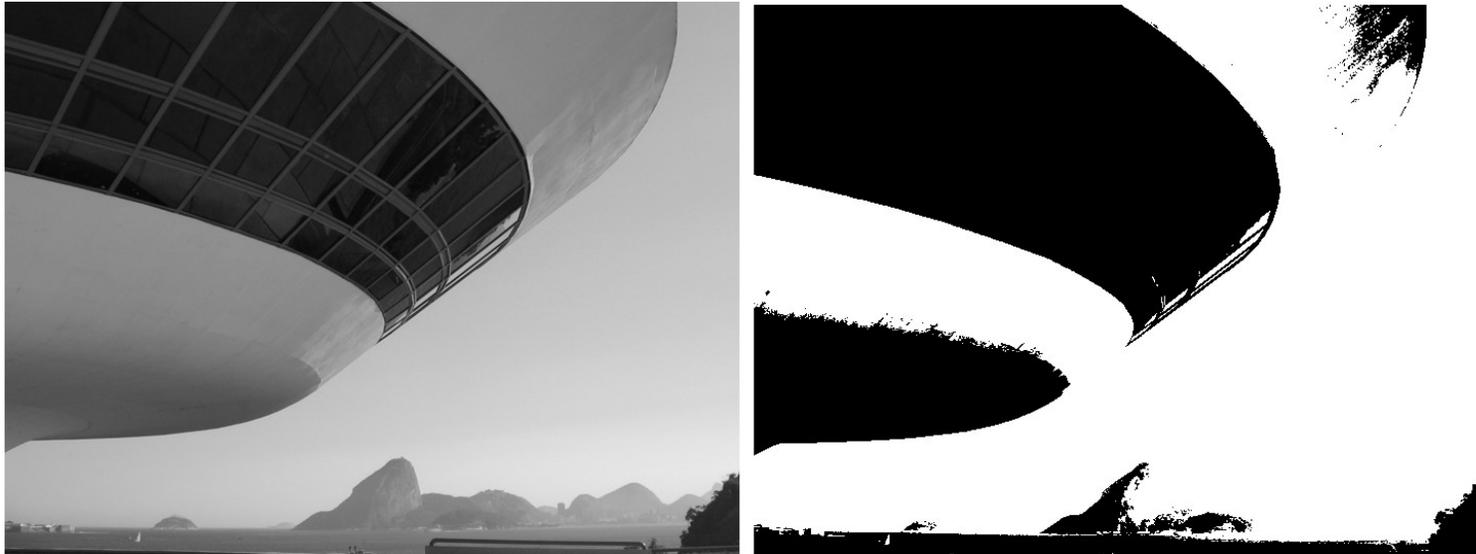
Automática:

Método de Otsu (*Thresholding* Global)

Método Iterativo

outros (ver site do curso)

Agrupamento por limiar (Thresholding):



Exemplo de binarização:

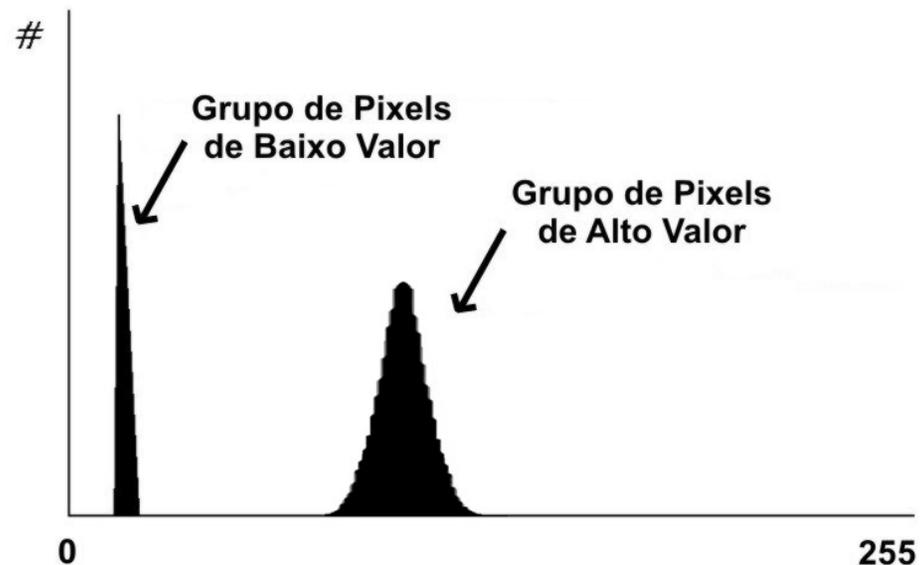
(a) Imagem em tons de cinza,

(b) Imagem binária

Agrupamento por limiar (limiarização)

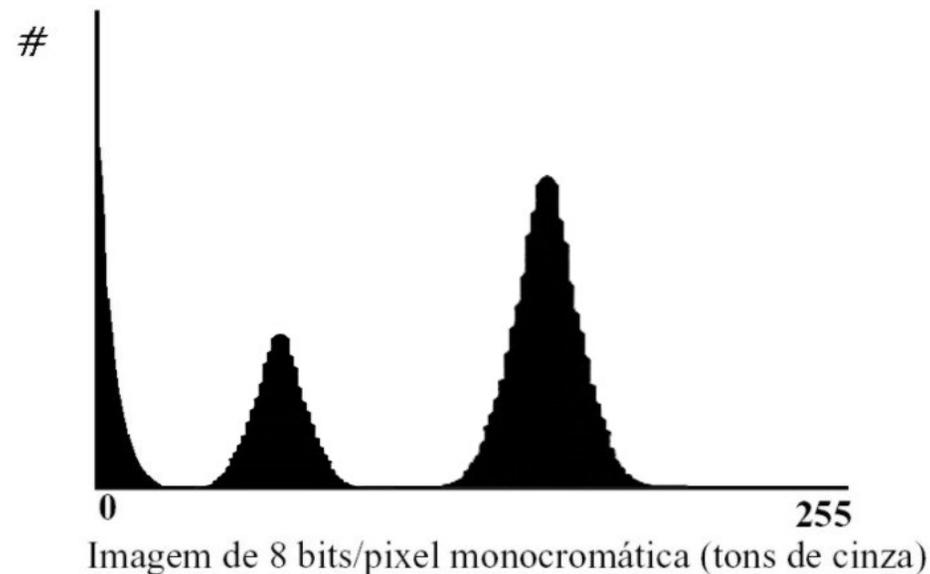
Uso: segmentação em imagens em que o objeto a ser segmentado apresenta uma tonalidade **bem diferente** do fundo da imagem.

Em um **histograma bimodal**, é possível estabelecer um limiar entre as duas tonalidades.



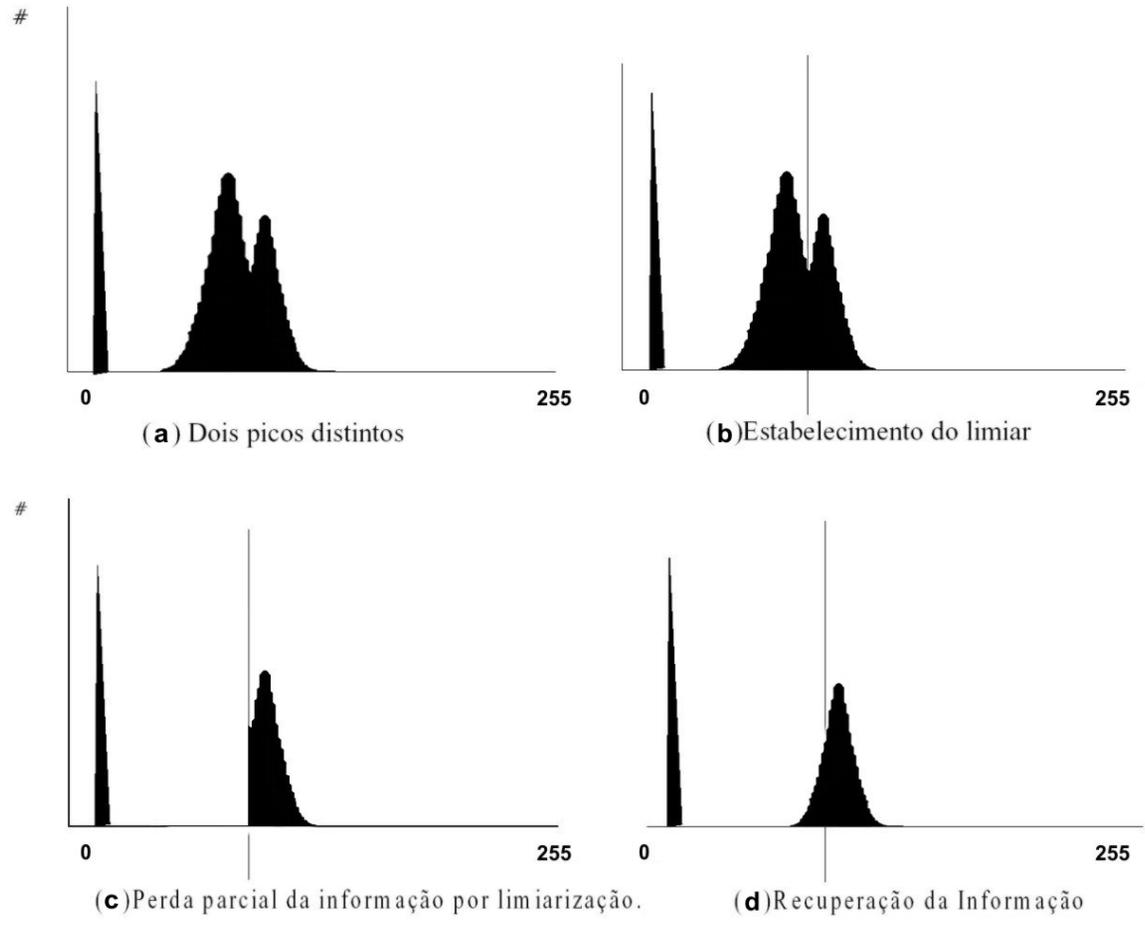
Exemplo de histograma bem-divisível.

Quando a imagem tem mais de dois objetos com cinzas diferentes em um fundo mais escuro, pode ser usada a técnica de **limiarização multinível** (*multilevel thresholding*).



Exemplo de um histograma trimodal.

Há casos em que torna-se necessário o uso de técnicas mais complexas



Limiarização por interpolação (Chow e Kaneko, 1972).

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:

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

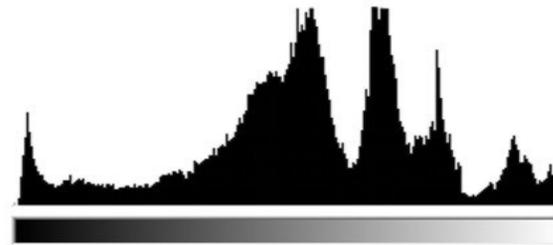
De uma maneira mais genérica, a definição de T é a função de **várias variáveis** na forma:

$$T = T [x, y, p(x,y), f(x,y)]$$

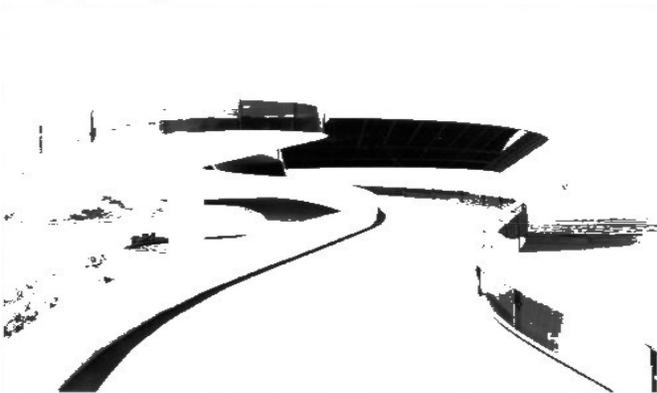
onde $p(x,y)$ é uma propriedade local , isto é função de x,y .



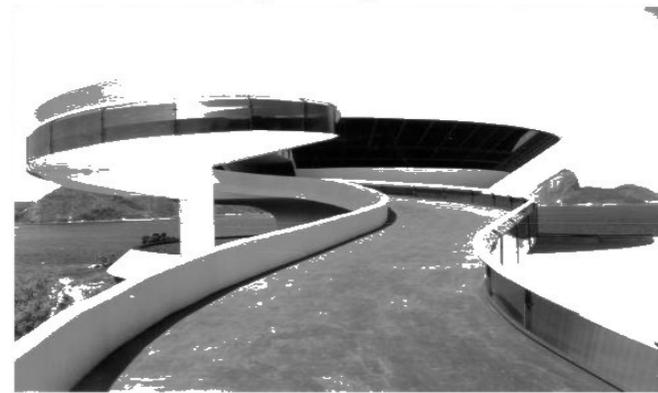
(a) Imagem com 256 tons de cinza



(b) Histograma



(c) Limiarização com valor 80



(d) Limiarização com valor 150

Influência do valor do limiar sobre a qualidade da limiarização.

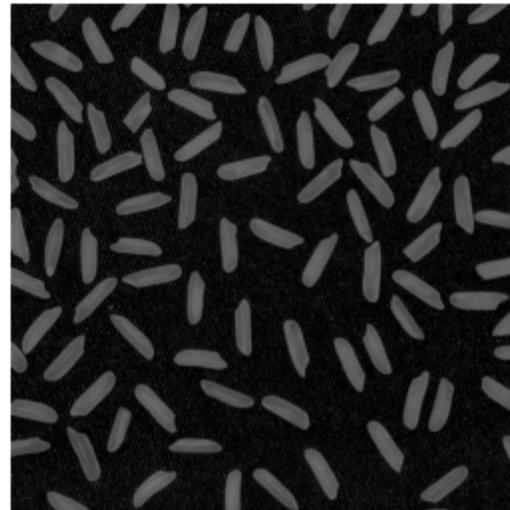
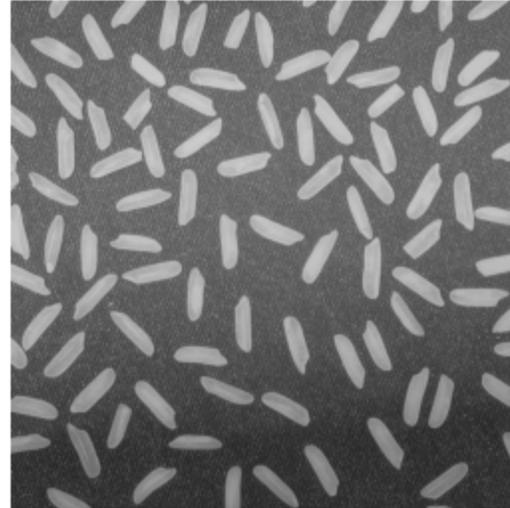
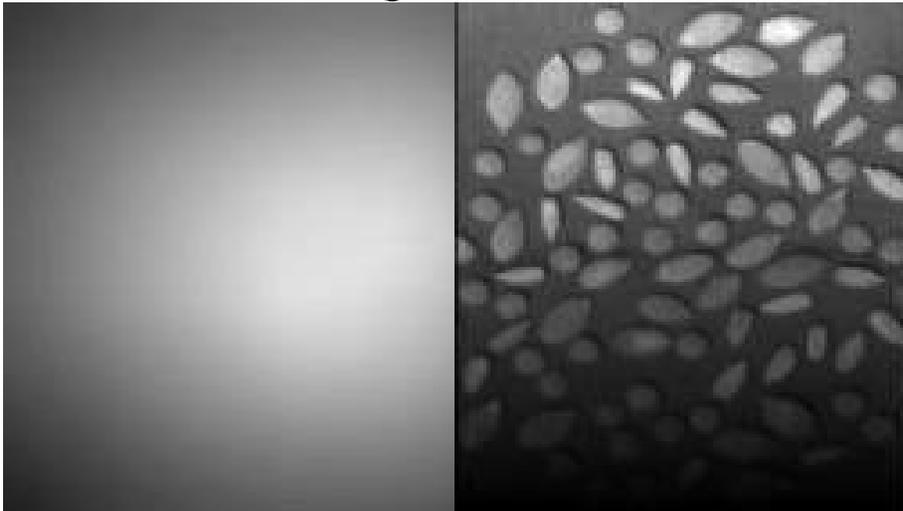
(A imagem (d) está posterizada nesta representação).

É uma técnica muito boa para separar elementos de uma imagem

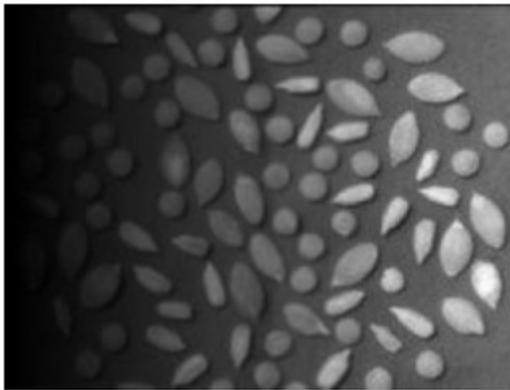
- Desde que a iluminação seja adequada
- E
- Os elementos sejam diferenciados por tons

Uneven illumination

- Subtração do fundo



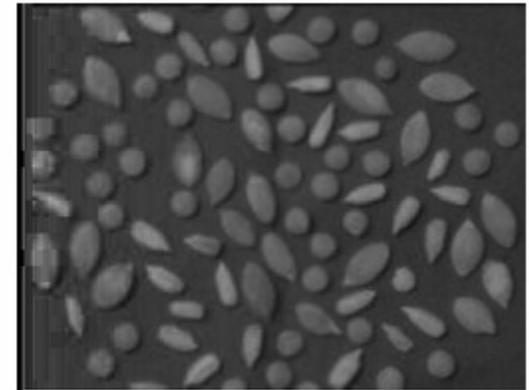
Subtração fundo



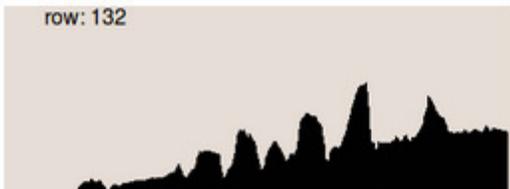
Input image.



Background image.



Output image.



Profile of the row 132.

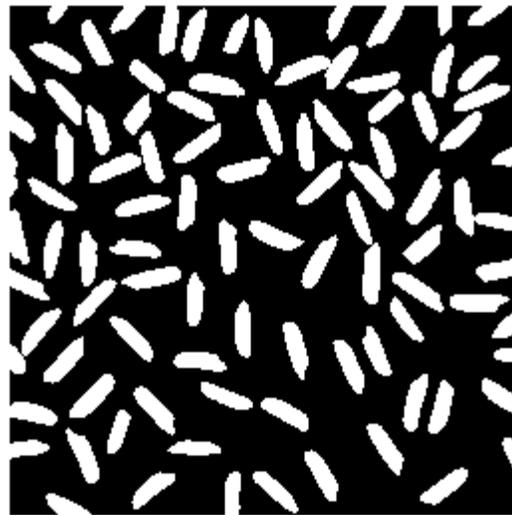
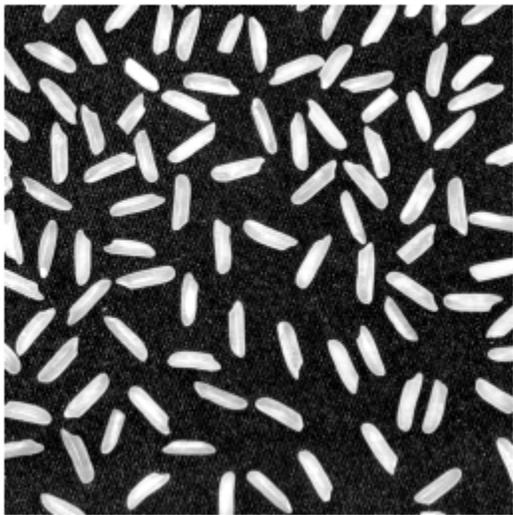


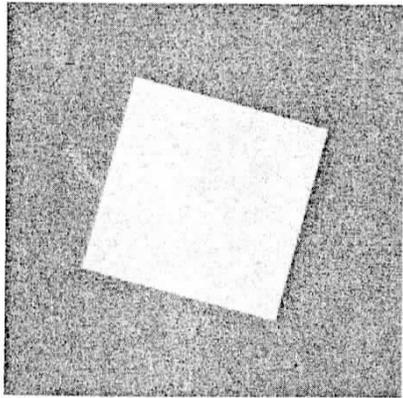
Profile of the row 132.



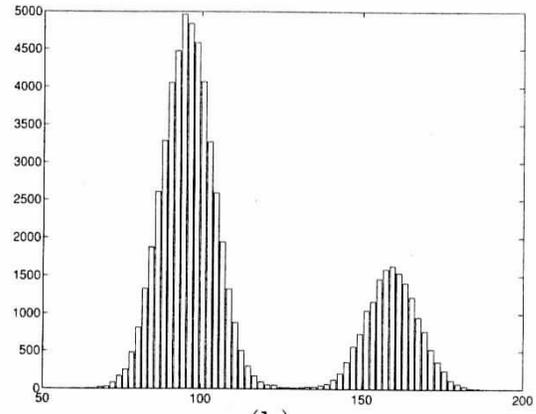
Profile of the row 132.

Aumento do contraste x limiarização

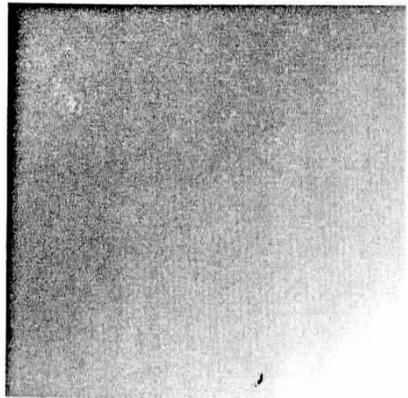




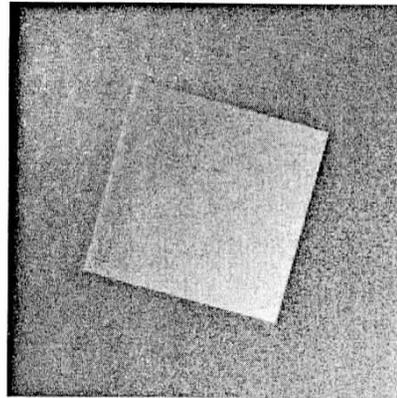
(a)



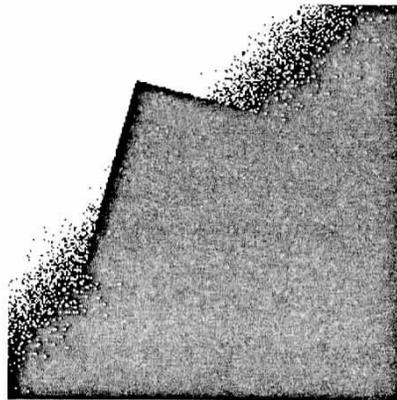
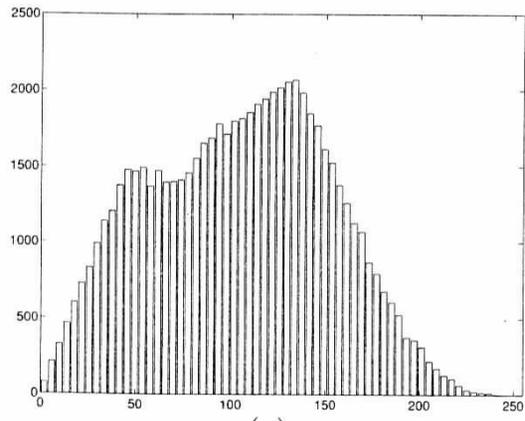
(b)

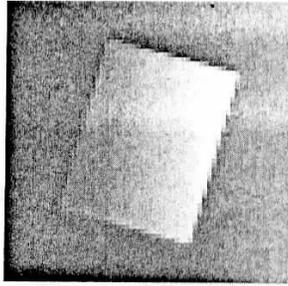


(c)

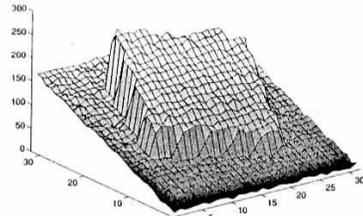


(d)

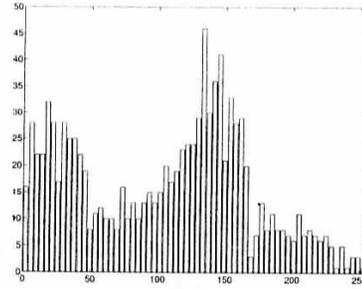




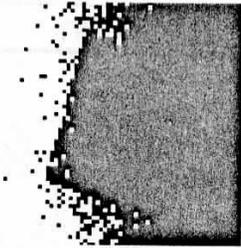
(a)



(b)



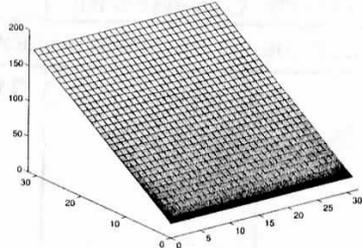
(c)



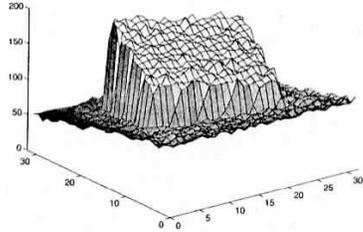
(d)



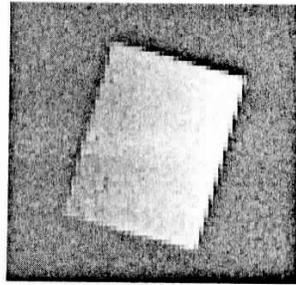
(e)



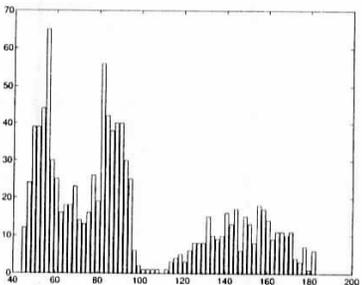
(f)



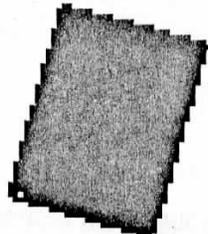
(g)

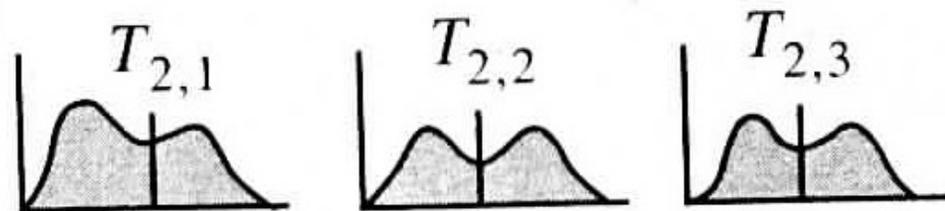
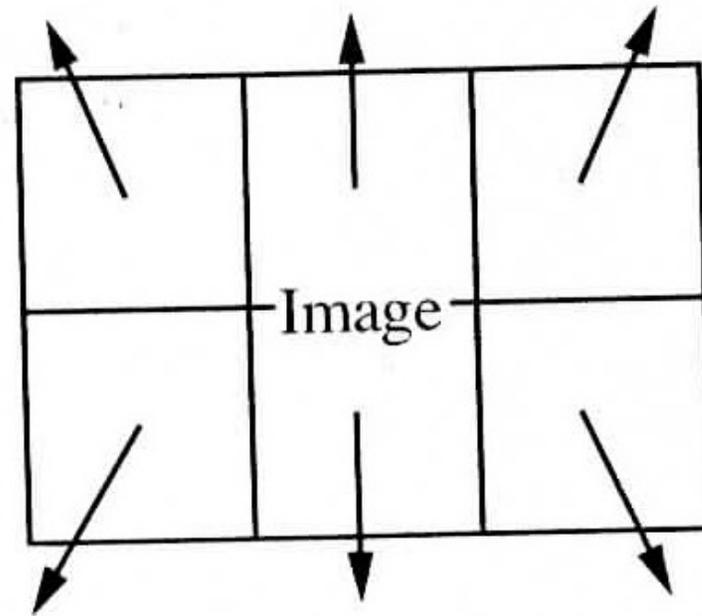
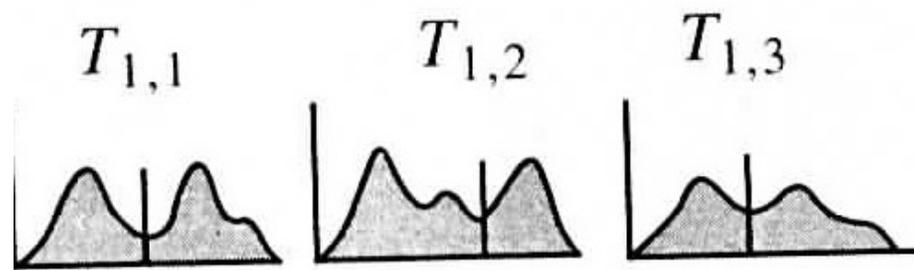


(h)



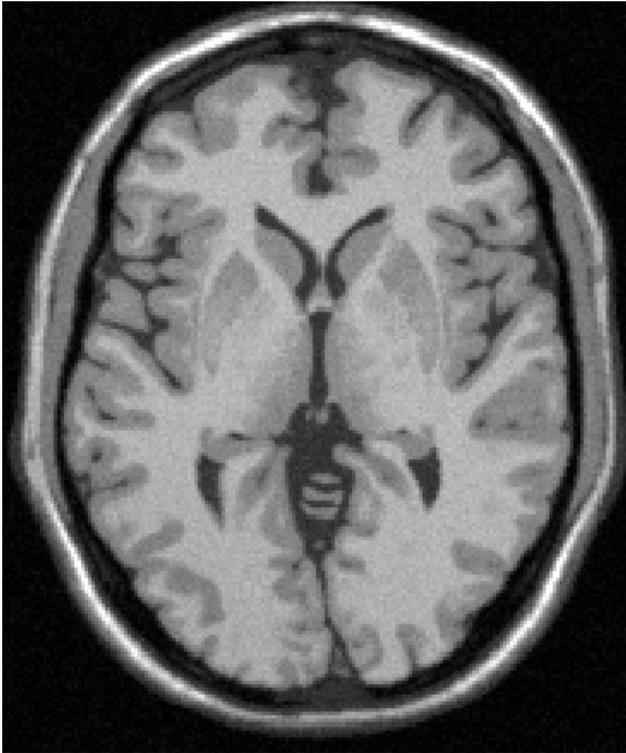
(i)



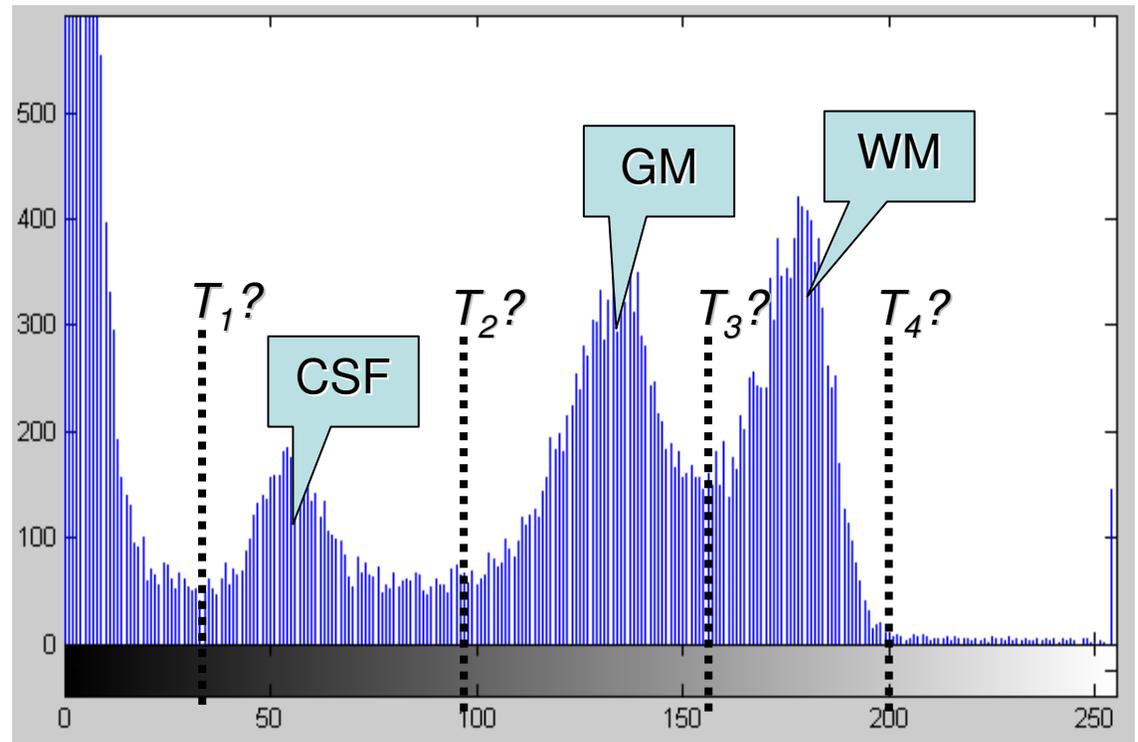


Experimentação

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*

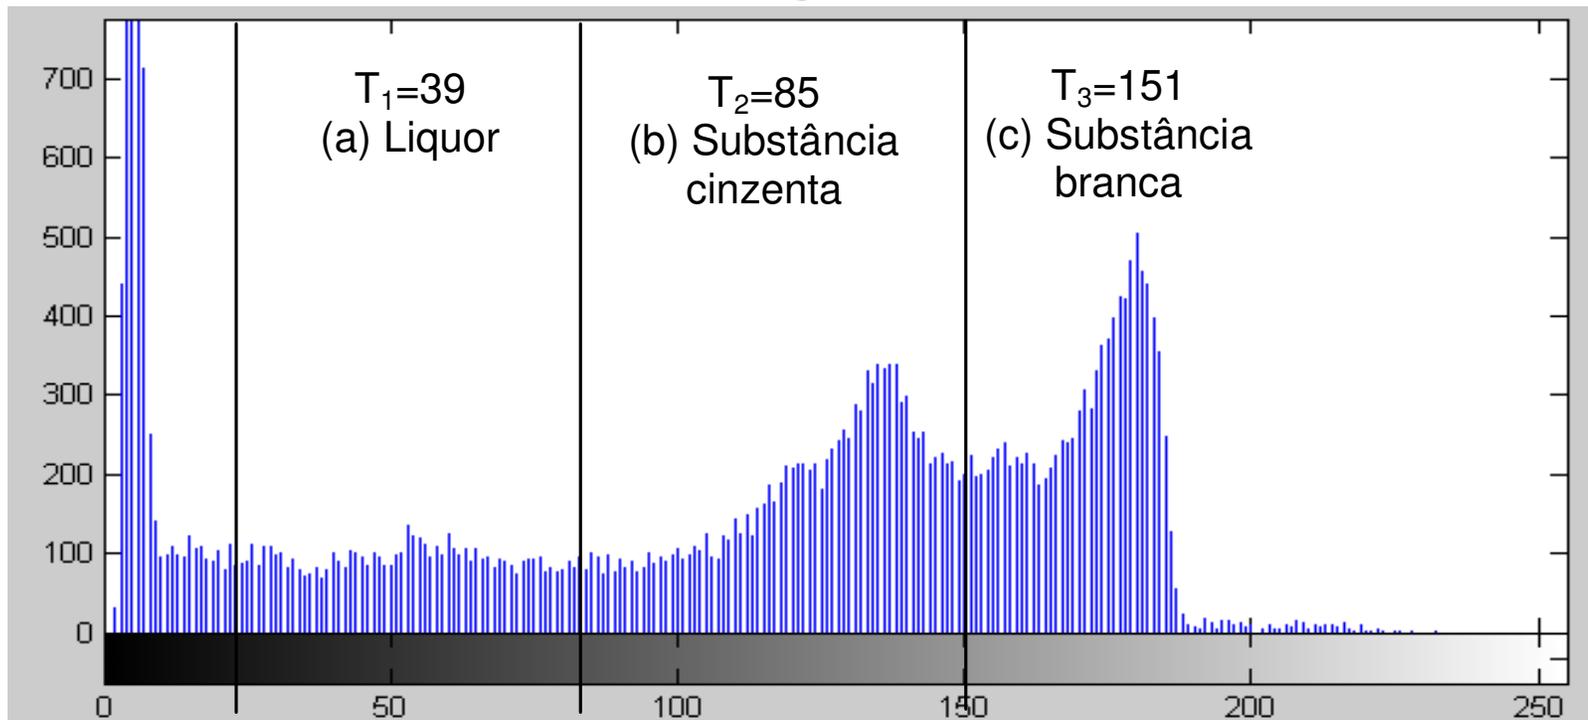
<http://brainweb.bic.mni.mcgill.ca/brainweb/>

Segmentação utilizando método de Otsu:

Considerações:

Três níveis de limiarização T_1 , T_2 e T_3

Histograma



comparação dos Resultados

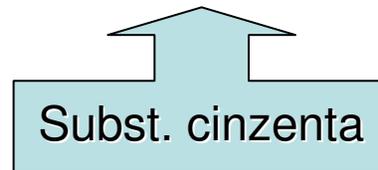
Imagens binárias geradas pela segmentação por limiarização, utilizando os níveis encontrados pelo método de Otsu:



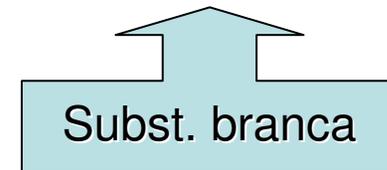
(a)



(b)

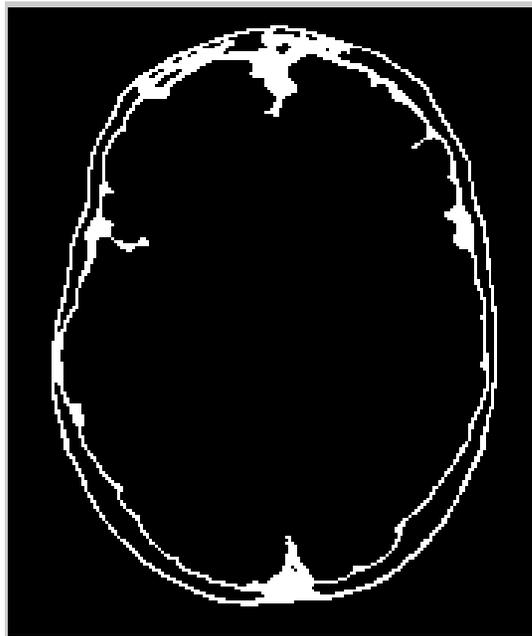


(c)



Unir as áreas para calcular volumes

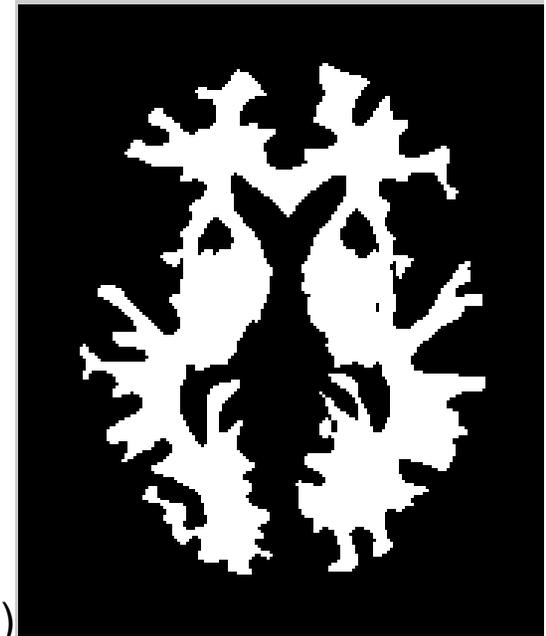
Considerando a conectividade das regiões:



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

Limiarização Automática (*Thresholding*) baseada no histograma

O método mais simples (e mais caro computacionalmente) de calcular automaticamente o *threshold* é o **método iterativo**.

Este método é 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 $T_{i+1} - T_i < (\text{parâmetro pré-definido})$

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

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

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

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

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

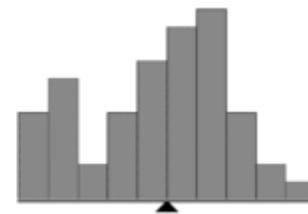
Métodos de Limiarização

• <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:

- 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; }
```

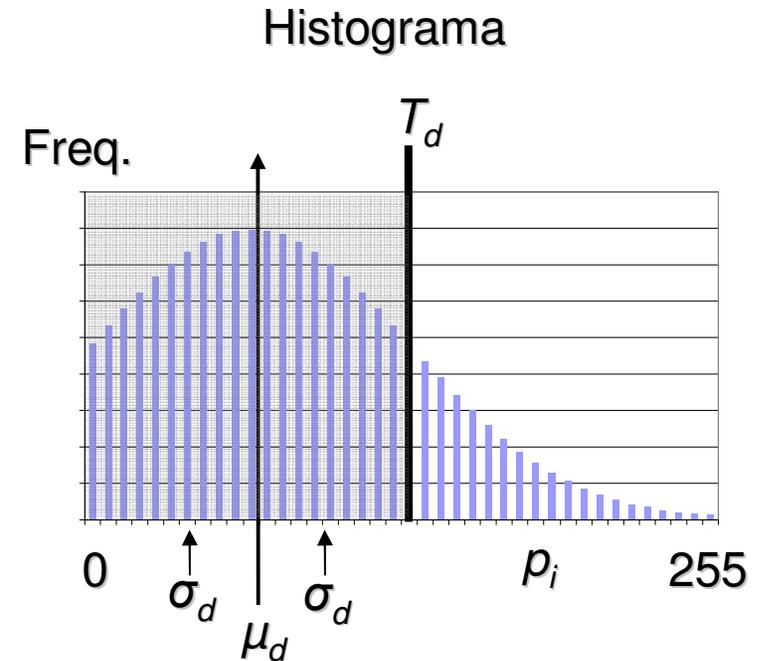
Métodos de Otsu:

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

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

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

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



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

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).

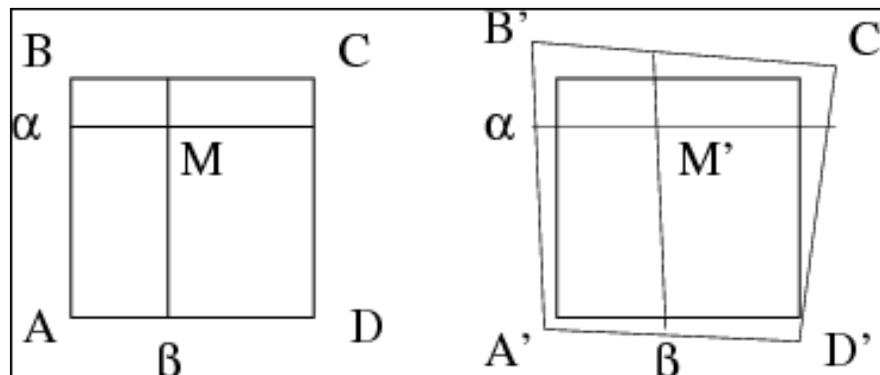
Limiarização em Multiníveis de Niblack

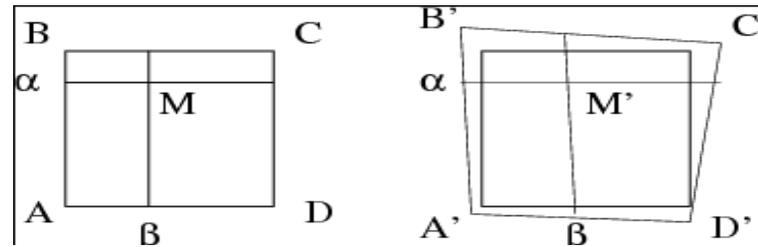
- Desvantagens:
 - produz uma grande quantidade de ruídos em imagens com muitos tons de cinza.
 - processamento posterior intenso computacionalmente para redução ou remoção de ruídos.
 - Definição do tamanho da vizinhança → deve ser pequeno suficiente para preservar detalhes locais mas grande o suficiente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

Manipulações básicas de Re-amostragem e Re- escalamento

- São geralmente feitas por *interpolação bilinear*.
- Essa transformação é encontrada nos softwares de imagem existentes
- É uma técnica de *transformação e registro de imagens elementar*.

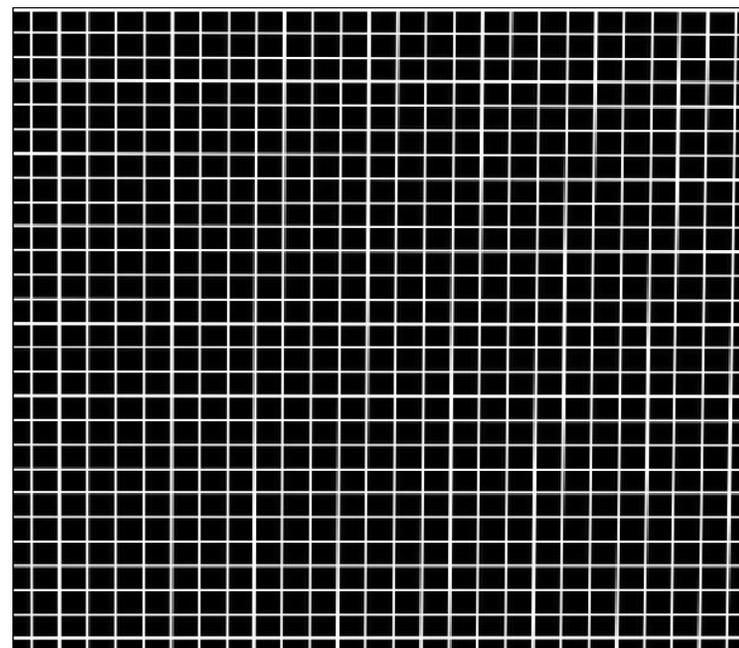
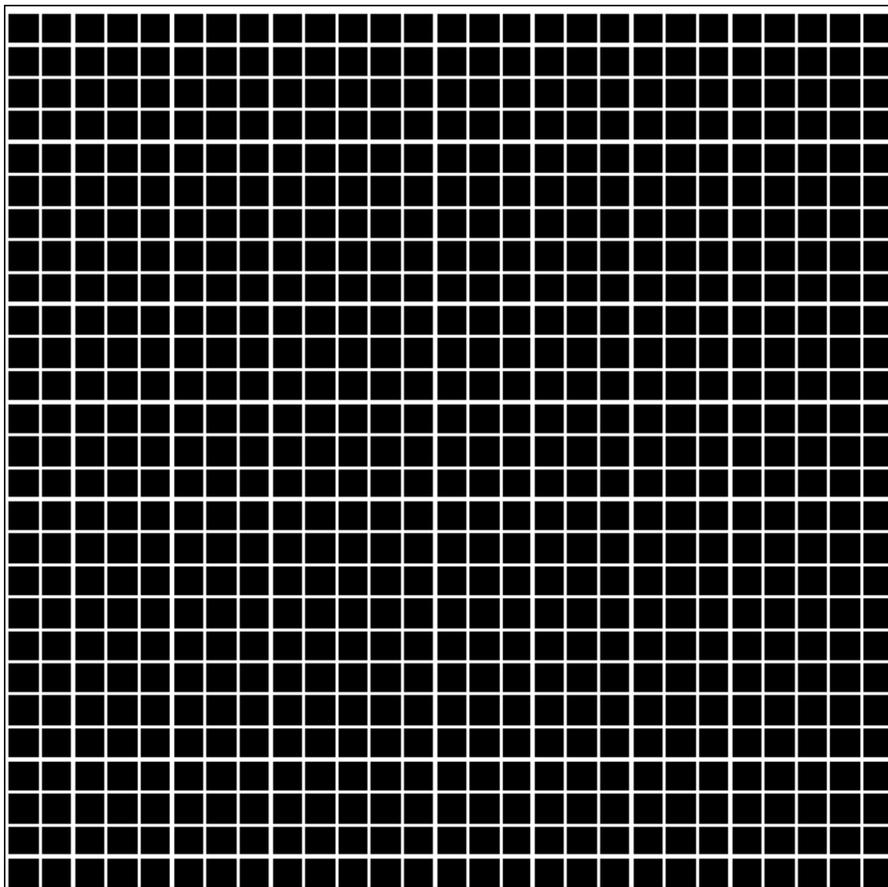
- Se **A**, **B**, **C**, e **D** são vértices de uma imagem, ou parte dela, então
- um ponto **M** da imagem pode ser expresso por
 - $M = \alpha (\beta A + (1 - \beta) D) + (1 - \alpha) (\beta B + (1 - \beta) C)$,
- onde $0 \leq \alpha, \beta \leq 1$ são coordenadas de **M** (ou distância normalizada) relativas ao vértice **B** e **D** respectivamente.





- A distorção é inserida movendo-se os vértices por uma quantidade aleatória pequena em ambas as direções.
- As novas coordenadas de M , M' , são dadas pela fórmula prévia, mantendo-se (α e β) constantes mas utilizando os novos vértices: A' , B' , C' , e D'
- Note que se esta transformação for *inversível*, conseqüentemente ela não eliminará dados.

(a) Imagem original



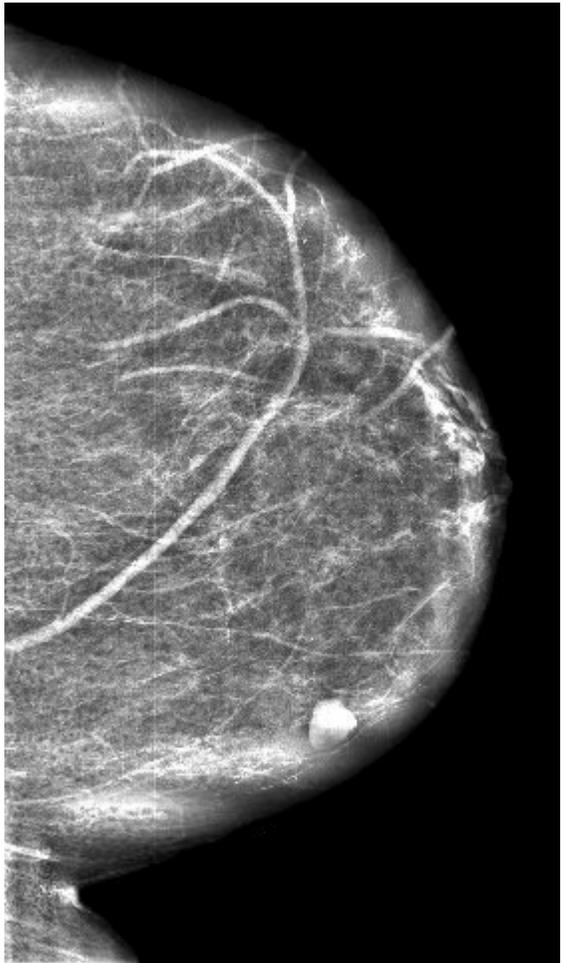
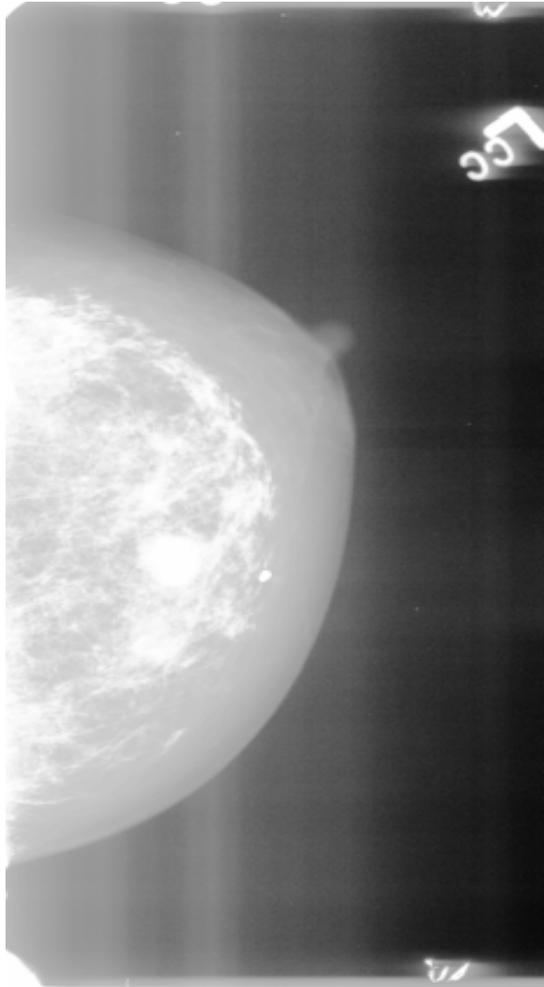
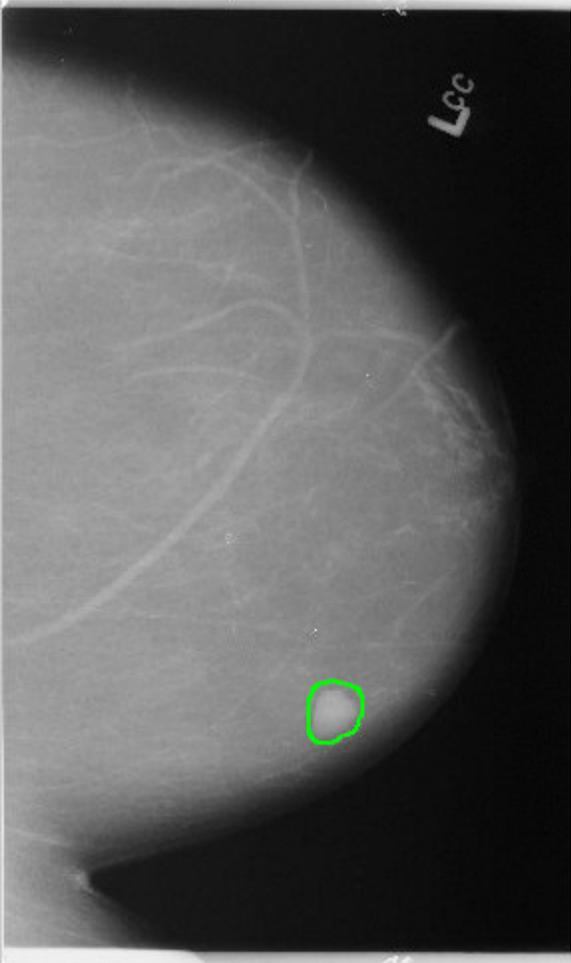
(b) Imagem após transformação

Exercicio

Faça e visualize as alterações (respostas no site do curso:)

- Implementar , na aplicação escolhida pelo seu grupo, uma forma que permite uma comparação visual entre como fica uma imagem típica, que você vai usar, nas formas:
- 1- original
- 2- depois de processada por Equalização do Histograma
- 3- depois de uma equalização adaptativa do histograma (AHE - Adaptive Histogram Equalization)
- 4- depois de usar a técnica de equalização adaptativa de histograma com limitação de contraste (CLAHE - Contrast Limited Adaptive Histogram Equalization)

Exemplos:



Importante no trabalho

- Deve-se mostrar o histograma e a imagens e cada etapa;
- Deve-se possibilitar experiências com diversas janelas, de preferência não deixar de usar de tamanhos indo de:
- 5×5 , 7×7 , 9×9 , 11×11 , 15×15 etc... até $N \times N$ (i.e. imagem inteira)
- Se sua imagem típica for colorida, usar o melhor espaço de cor e verificar se deve fazer em cada banda ou como trata-las!

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:

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

Operações pontuais em imagens

Operações pontuais baseadas na curva de tom

Operações baseadas em histograma

Técnicas Baseadas no Histograma de Imagens Coloridas

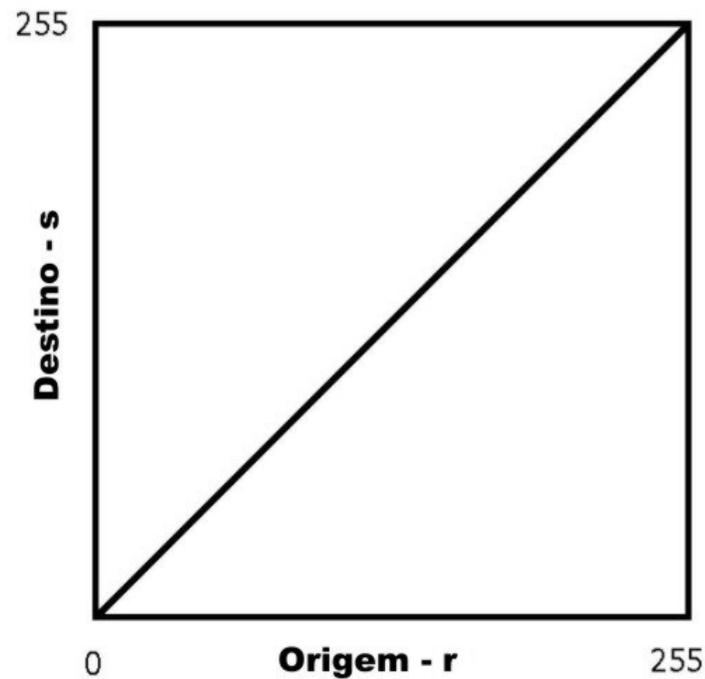
Operações pontuais em imagens

Global x local

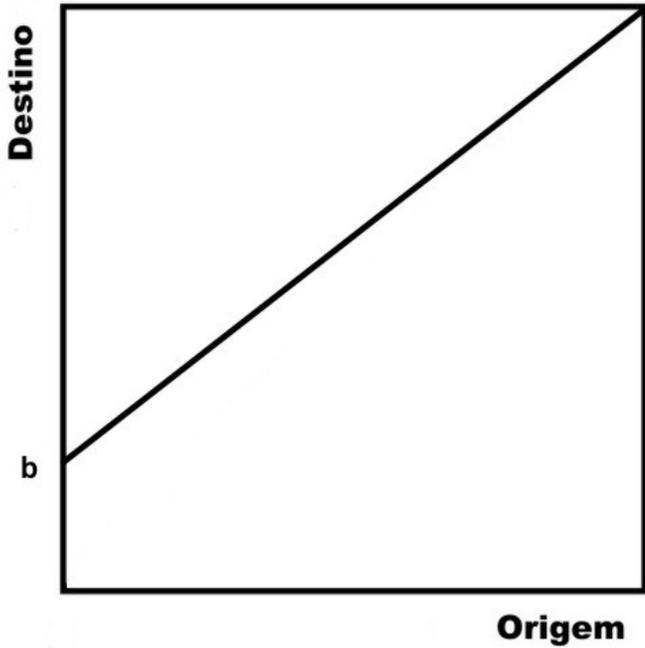
Uma operação pontual **global** m uma imagem digital r é a função $f(r)$ aplicada a **todo** *pixel* da imagem:

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

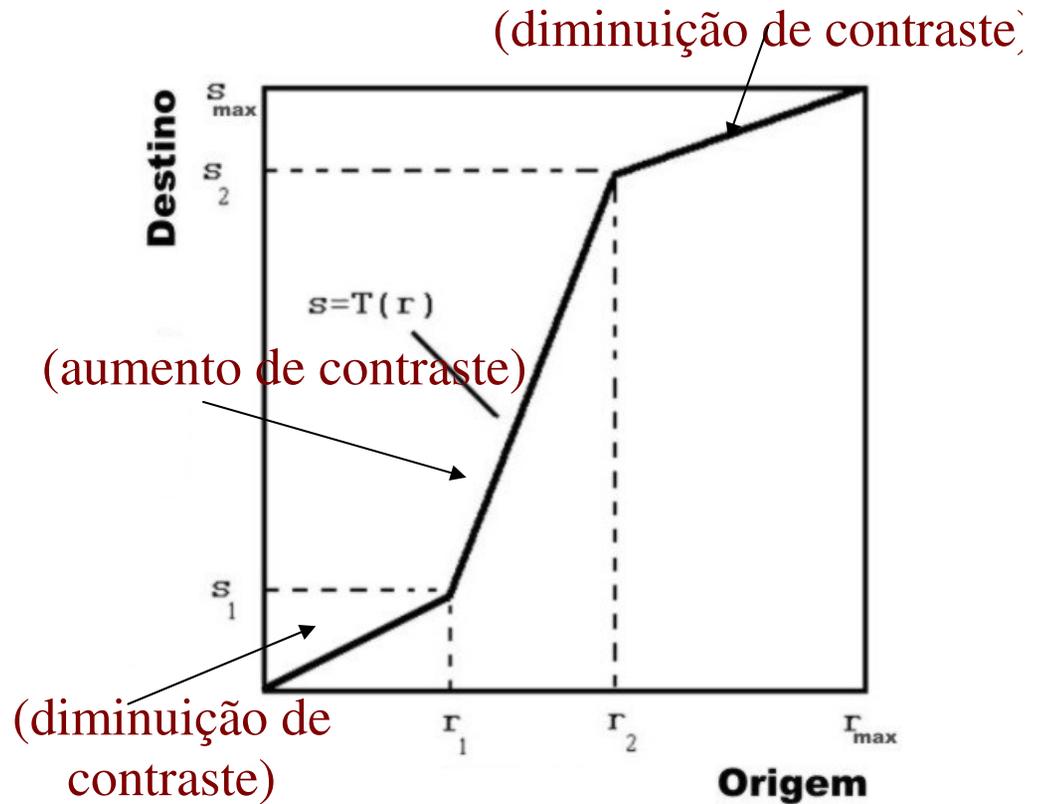
Operações pontuais globais baseadas na curva de tom



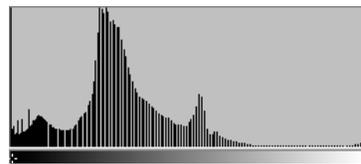
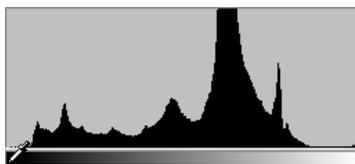
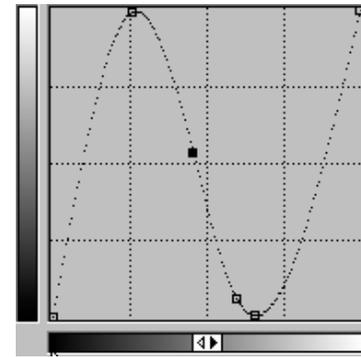
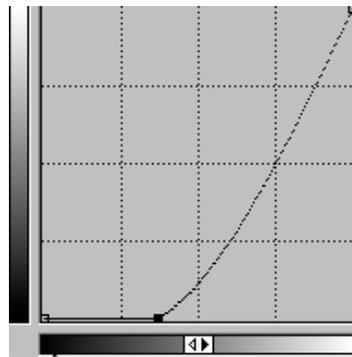
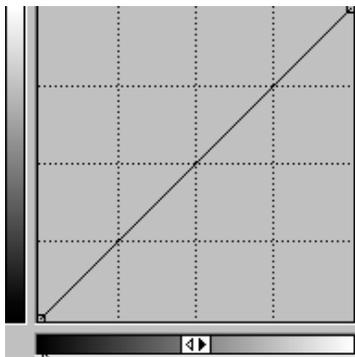
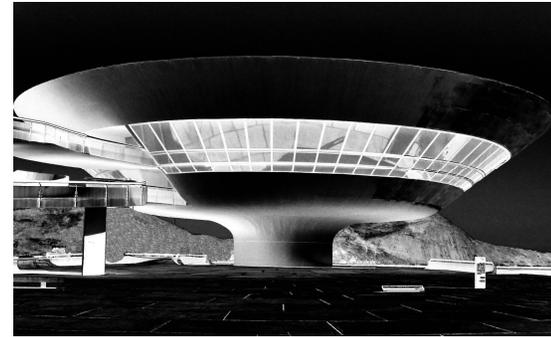
Relação entre imagem origem e destino.



Representação na forma linear

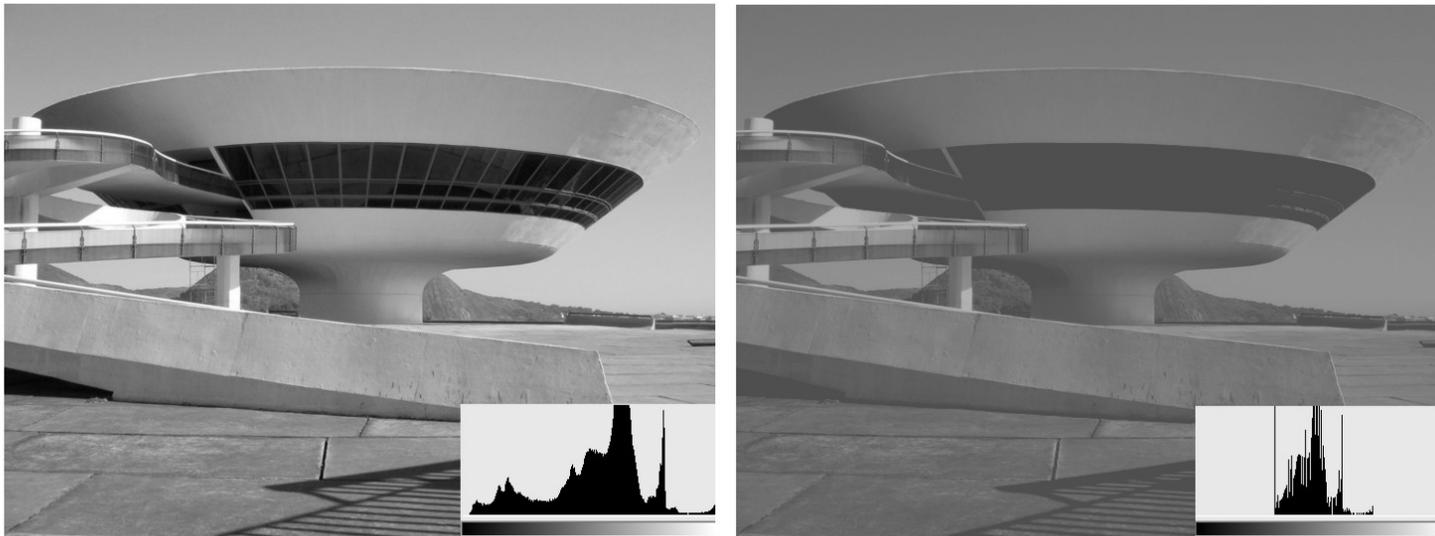


Alteração da imagem destino a partir de uma função genérica.



Curva de tom original e alteradas, com suas respectivas curvas de tom e histogramas.

Compressão do histograma (diminuição do range)



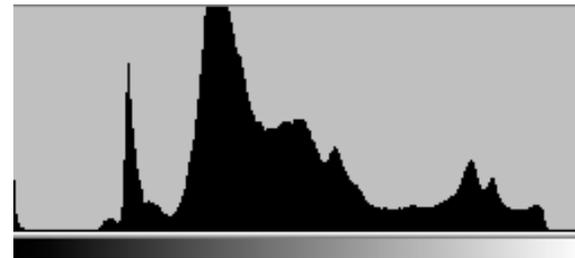
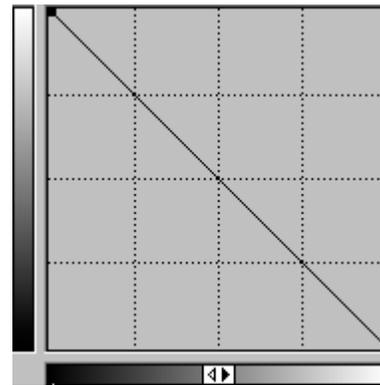
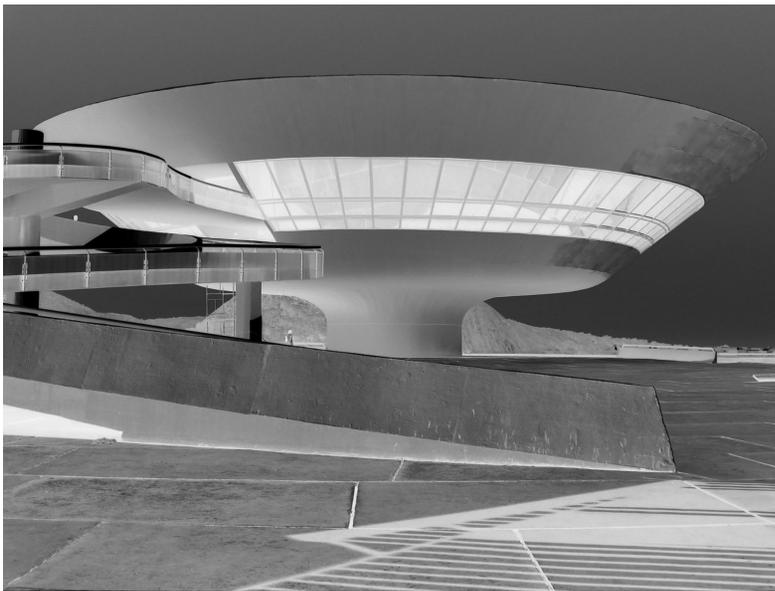
Efeito da Compressão de Histogramas

Expansão de histograma (ampliação do range)



Efeito da Expansão de Histogramas.

Imagem negativa (ou com os tons invertidos)



Efeito da imagem negativa.

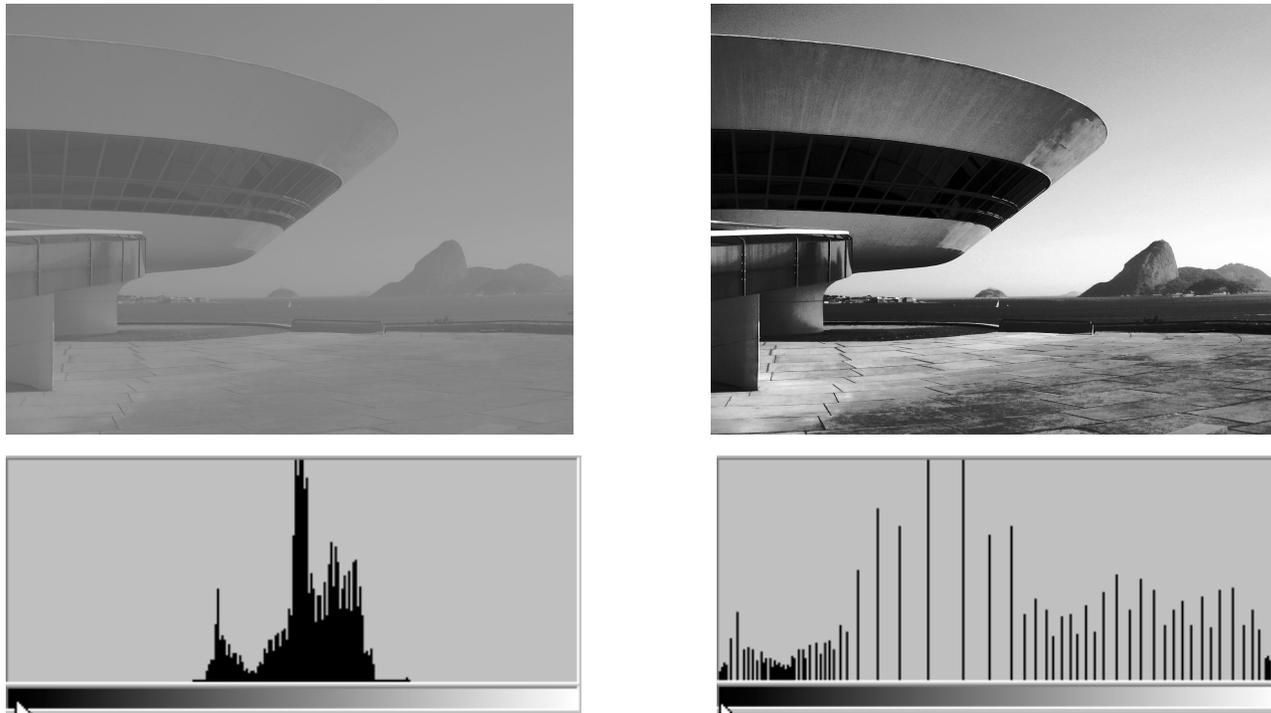
Outras operações globais baseadas em histograma

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.

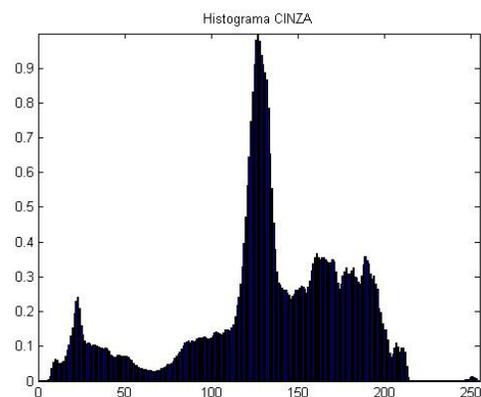


Imagem original e seu histograma normalizado

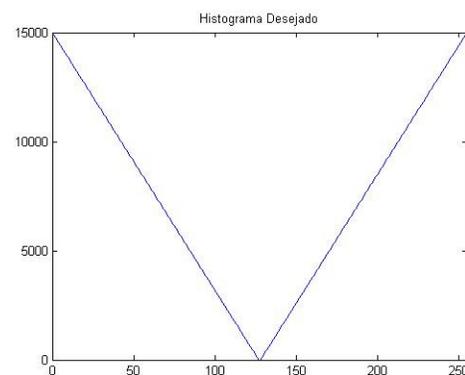


Imagem obtida (a) após a especificação do histograma (b).

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.

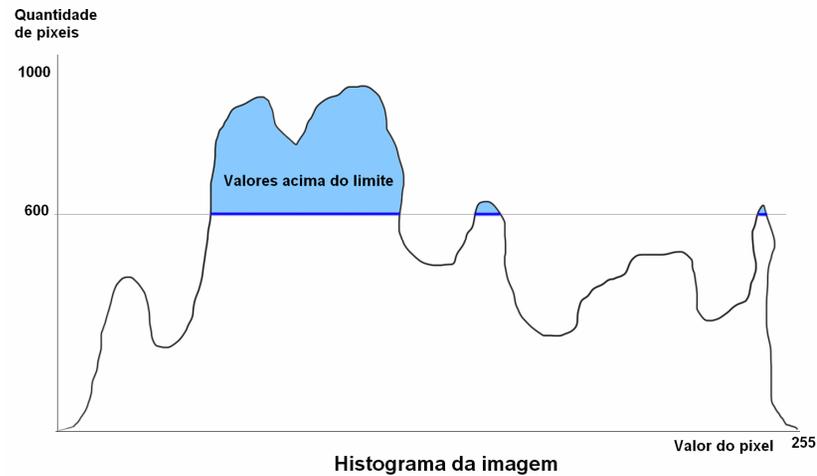
Características da Equalização

- 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.

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

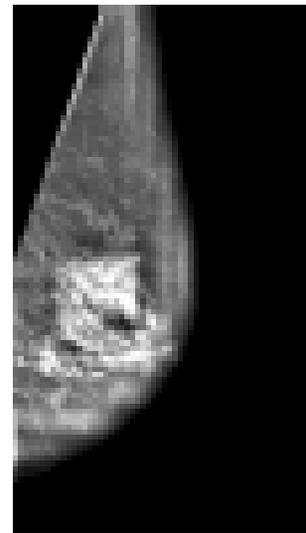
Exemplo de como fica para cada janela:



(a) Sem realce



(b) Equalização global de histograma



(c) CLAHE

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.

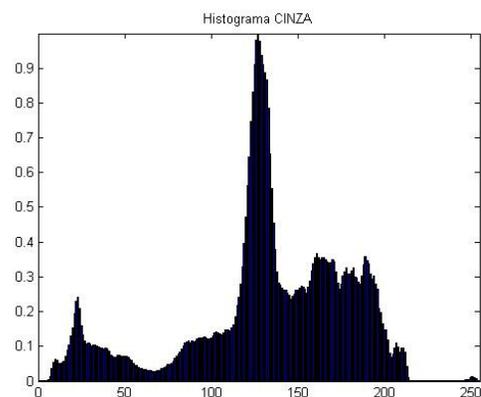


Imagem original e seu histograma normalizado

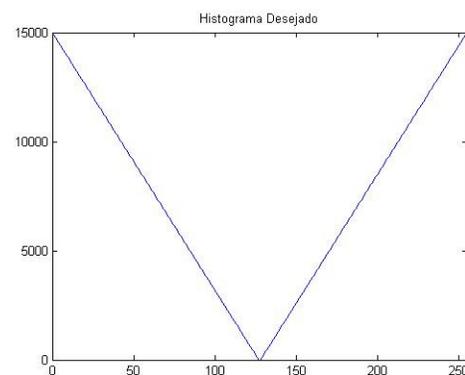


Imagem obtida (a) após a especificação do histograma (b).

Técnicas Baseadas no Histograma de Imagens Coloridas

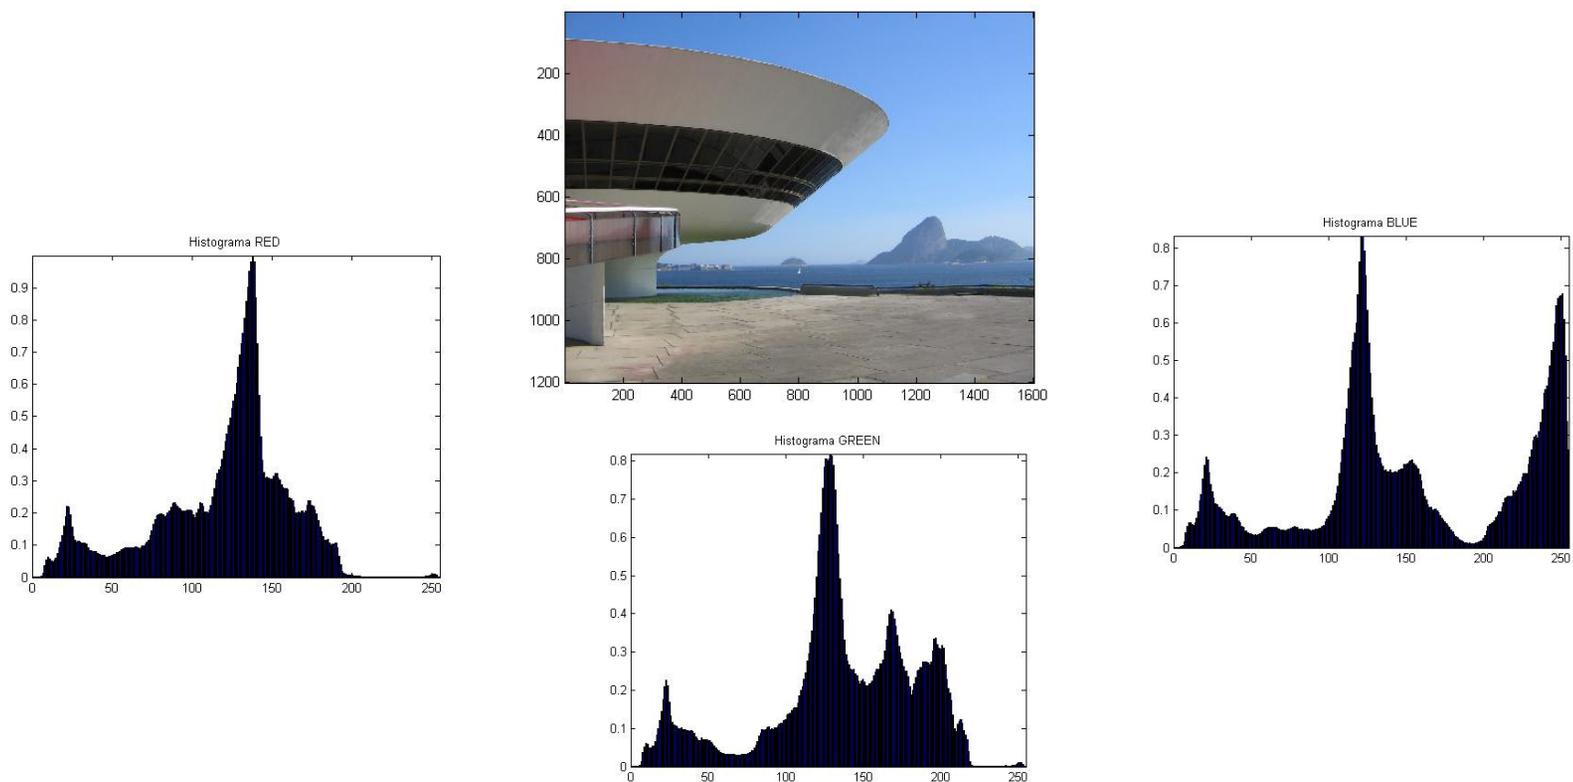


Imagem original e seus histogramas normalizados

Problema:

Quando as técnicas de mudança de histograma para imagens em **tons de cinza** são simplesmente **triplicadas** para cada um dos canais (**RGB**) independentemente, o resultado será o surgimento de **cores não presentes** na imagem original.

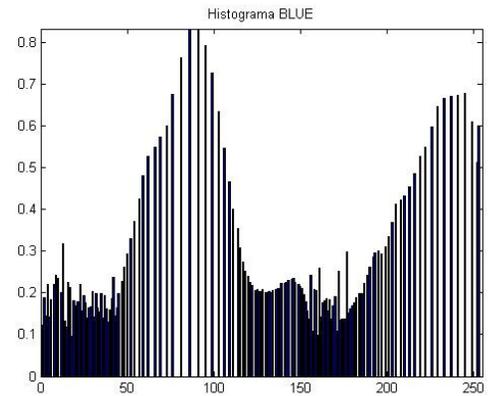
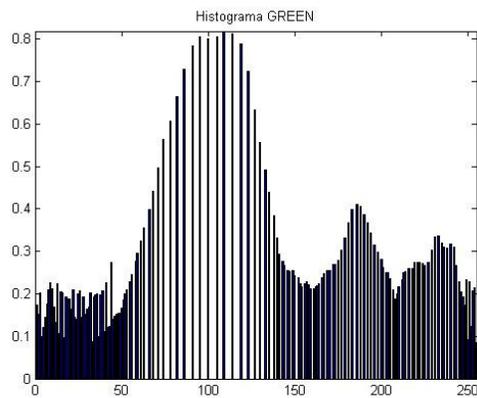
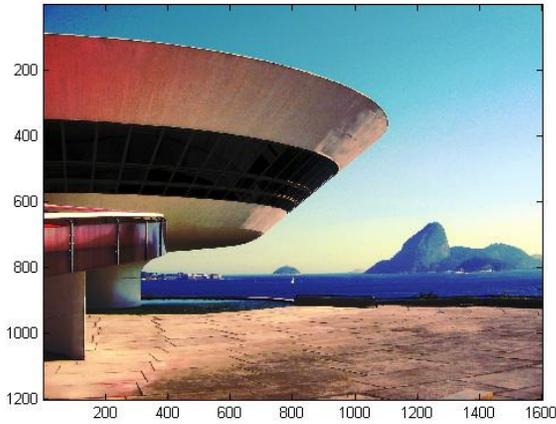
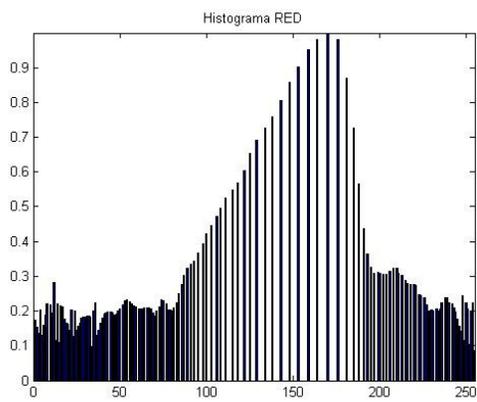
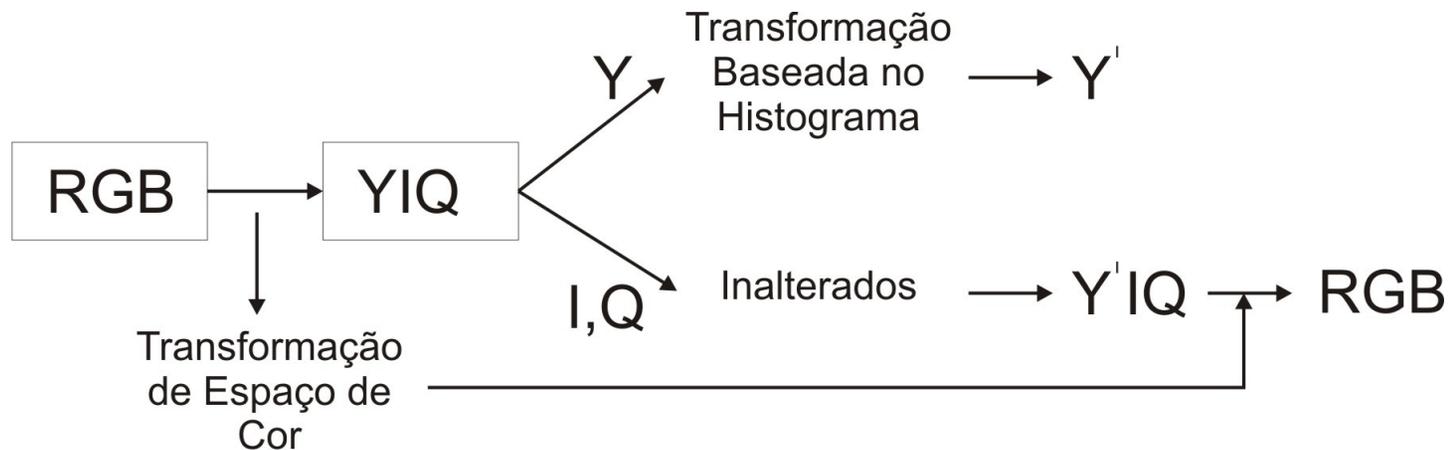


Imagem modificada por equalização e seus histogramas equalizados normalizados .

Soluções:

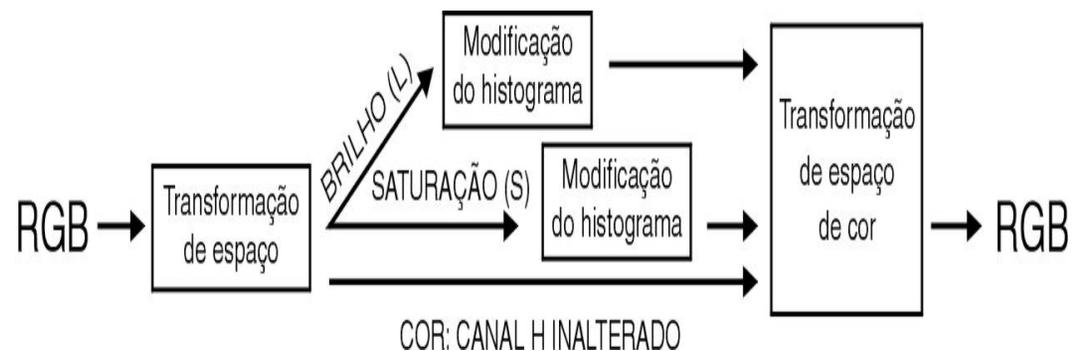
1- Usar **apenas** um canal em um **espaço de cores como o YIQ**



Esquema de modificações baseadas no histograma para imagens coloridas.

Soluções:

2- **Deixar inalterado** o canal que representa cores em um espaço de cores como o **HSV**



Esquema de modificação para espaços HSV e HLS

Exemplos de Trabalhos deste capítulo:

- 1-Amplificar 2x (dar zoom) as imagens dos mamogramas usando interpolação bilinear
- 2-Fazer limiarizações nas imagens de por algum método (iterativo, Otsu, Chow Kaneko, buscarem idéias na internet)
- 3-Fazer alterações pontuais nos tons para interativamente melhorar a visibilidade da região de texturas
- 4-Fazer a equalização destas imagens
- 5-Mudar a intensidade baseada em um histograma desejado que seja um triangulo

Bibliografia Complementar:

*

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

Limiarização de Pun e Kapur: .../[/~aconci/curso/binari~3.htm](http://www.ic.uff.br/~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

Flávio L. Seixas, Anita Martins, Arthur R. Stilben, Daniel Madeira, Rafael Assumpção, Saulo Mansur, Silvia M. Victer, Vilson B. Mendes e Aura 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>

Cont.

Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ter Haar Romeny, B., Zimmerman, J. B., and Zuiderveld, K. (1987). Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3):355 – 368.

Etapas reais de uma pesquisa em Analise de Imagens

[IEEE VCIP 2015](#)

IEEE International Conference on Visual Communications and Image Processing 2015

Dec. 13-16, 2015, Singapore, Singapore

Reviews For Paper

Paper ID 109

Title On the importance of genetic optimization in breast disease detection by using IR images

Masked Reviewer ID: Assigned_Reviewer_3

Review:

Question	
Relevance: How relevant is the topic of this paper to VCIP?	Relevant
Novelty: How Novel is the paper's approach?	Minor Tweak of Prior Scheme
Technical Strength: Is the paper technically sound and correct?	Minor flaws but conclusions still believable
Experimental validation	Limited but convincing
Presentation	Could benefit from revision
Detailed Comments	This paper studied the feature selection and classification for diagnosis of breast cancer using infrad images. The main concern is the technical novelty, mainly testing(experimental) several classification methods.
Overall Rating	Reject

Masked Reviewer ID: Assigned_Reviewer_7

Review:

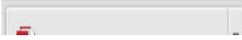
Question	
Relevance: How relevant is the topic of this paper to VCIP?	Very Relevant
Novelty: How Novel is the paper's approach?	Novel
Technical Strength: Is the paper technically sound and correct?	Technically Solid
Experimental validation	Sufficient validation
Presentation	Well written. Small errors that are correctable
Detailed Comments	This paper gives detailed expound of the method. I did not find error in it. Besides, the experiment gives a good data table to compare this method with others in different conditions. What I suggest is that the paper may give a more thorough description of the data result. For example, I see that the accuracy is around 60%, and it may be better to explain whether this number is enough for using. That is to say, it may be better to tell readers the value of your number.
Overall Rating	Accept

Overall Rating	Accept
----------------	--------

Masked Reviewer ID: Assigned_Reviewer_8

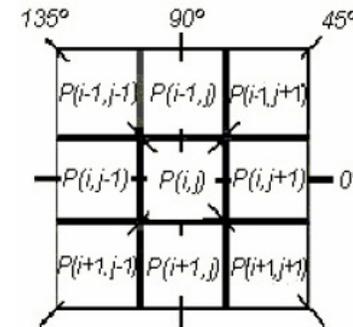
Review:

Question	
Relevance: How relevant is the topic of this paper to VCIP?	Relevant
Novelty: How Novel is the paper's approach?	Minor Tweak of Prior Scheme
Technical Strength: Is the paper technically sound and correct?	Minor flaws but conclusions still believable
Experimental validation	Limited but convincing
Presentation	Could benefit from revision
Detailed Comments	the paper is to verify the importance of parameter selection in the classification for breast cancer. Many methods have been tested and compared. However, I think the novelty of the paper is incremental although the paper said GA is needed to improve the accuracy.
Overall Rating	Neutral

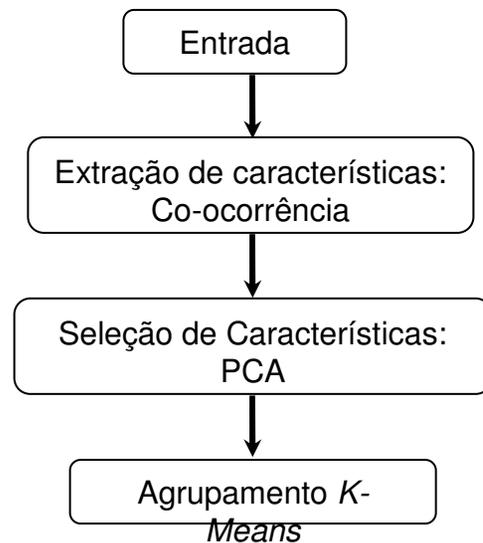


Automatic detection by texture only:

- Used approaches:
- *K_Means cluster decision*
- *Based on Haralick features*
 - **8 features used:**
 - **2nd angular moment (SMA),**
 - **contrast (Cont), entropy (Ent),**
 - **Inverse diferent moment (MDI),**
 - **correlation (Cor), variance (Var),**
 - **dissimilarity (Dis) and**
 - **average of the Co-occurrence matrices.**
- *PCA analysis of main features*
- *From Co-occurrence matrices on 256 levels*
 $G^y : Z^2 \rightarrow [0, \dots, 255]$
- *Windows of different sizes from 2x2 to 10x10*



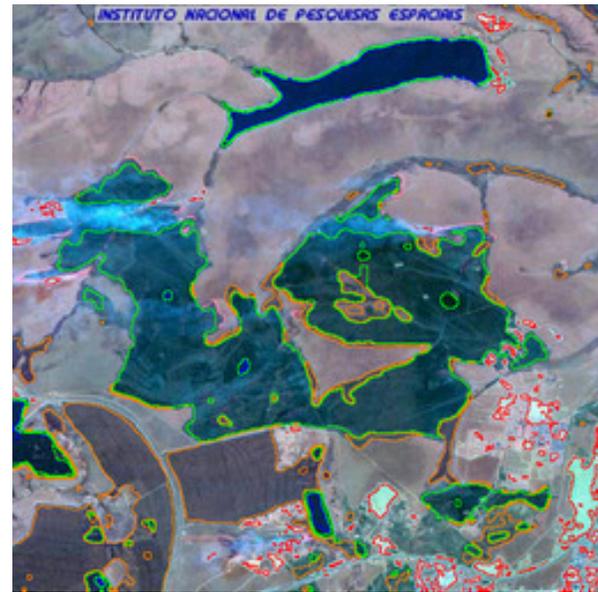
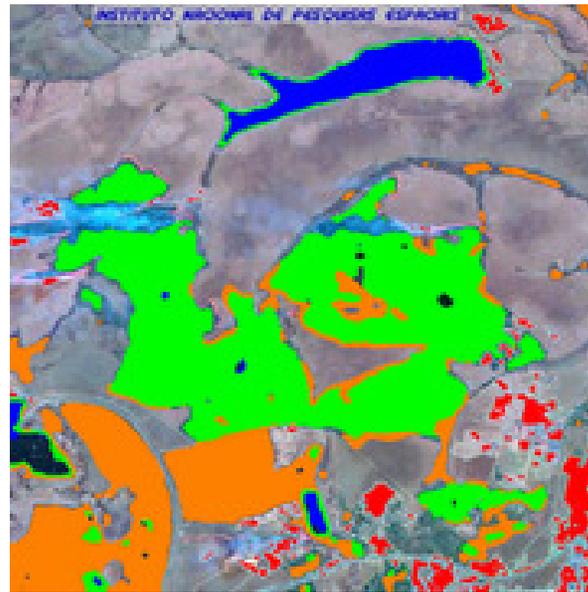
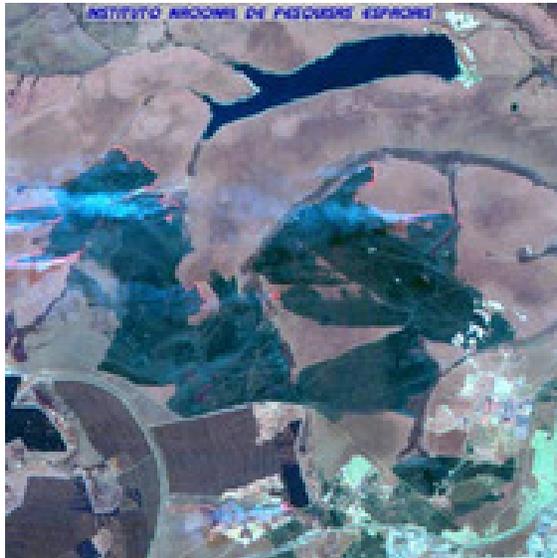
Exemplo típico de uma aplicação de AI:



Para segmentação foram utilizados centróides

Aerial or Landsat satellite images

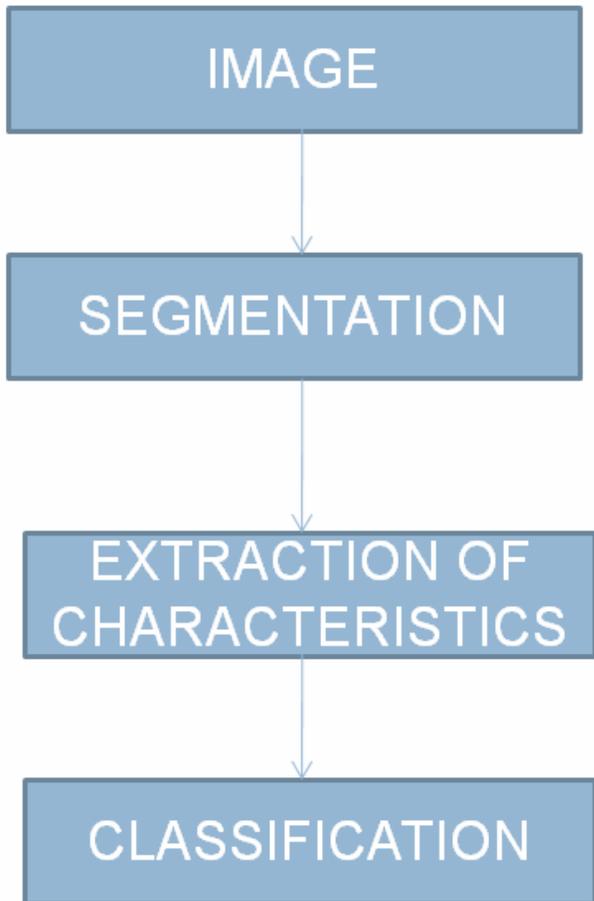
- » Original,
- » interior segmentation and only boundaries segmentation



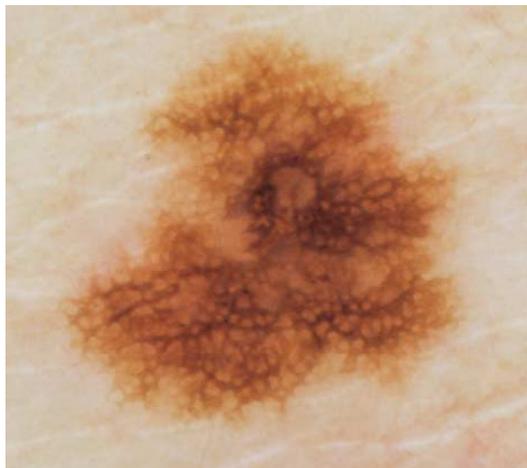
trabalhos em desenvolvimento

- Segmentação por cor e textura de imagens de mais complexas como:
 - Multibandas
 - Satélites
 - Térmicas
 - Médicas
 - Ultrassom - US;
 - Ressonância - RM
 - Tomografia – CT
 - Outras(PECT, SPECT, EEG, EMG, Termicas – IR)

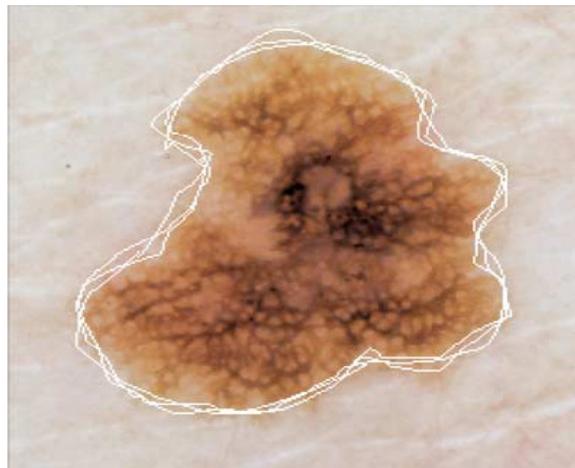
Introduction - Pipeline



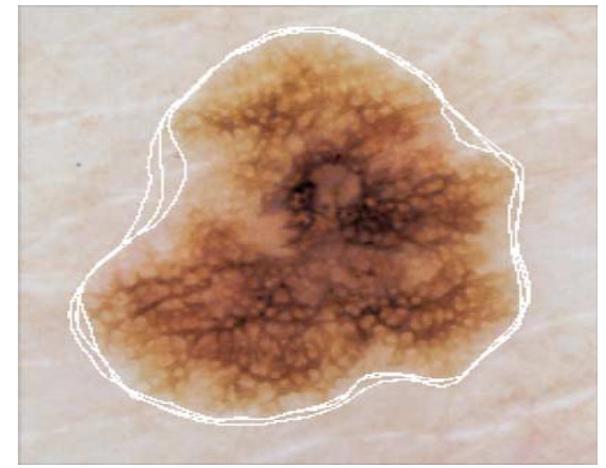
exemplo:
Segmentação de Lesões de Pele



Lesão Maligna



Dermatologista A

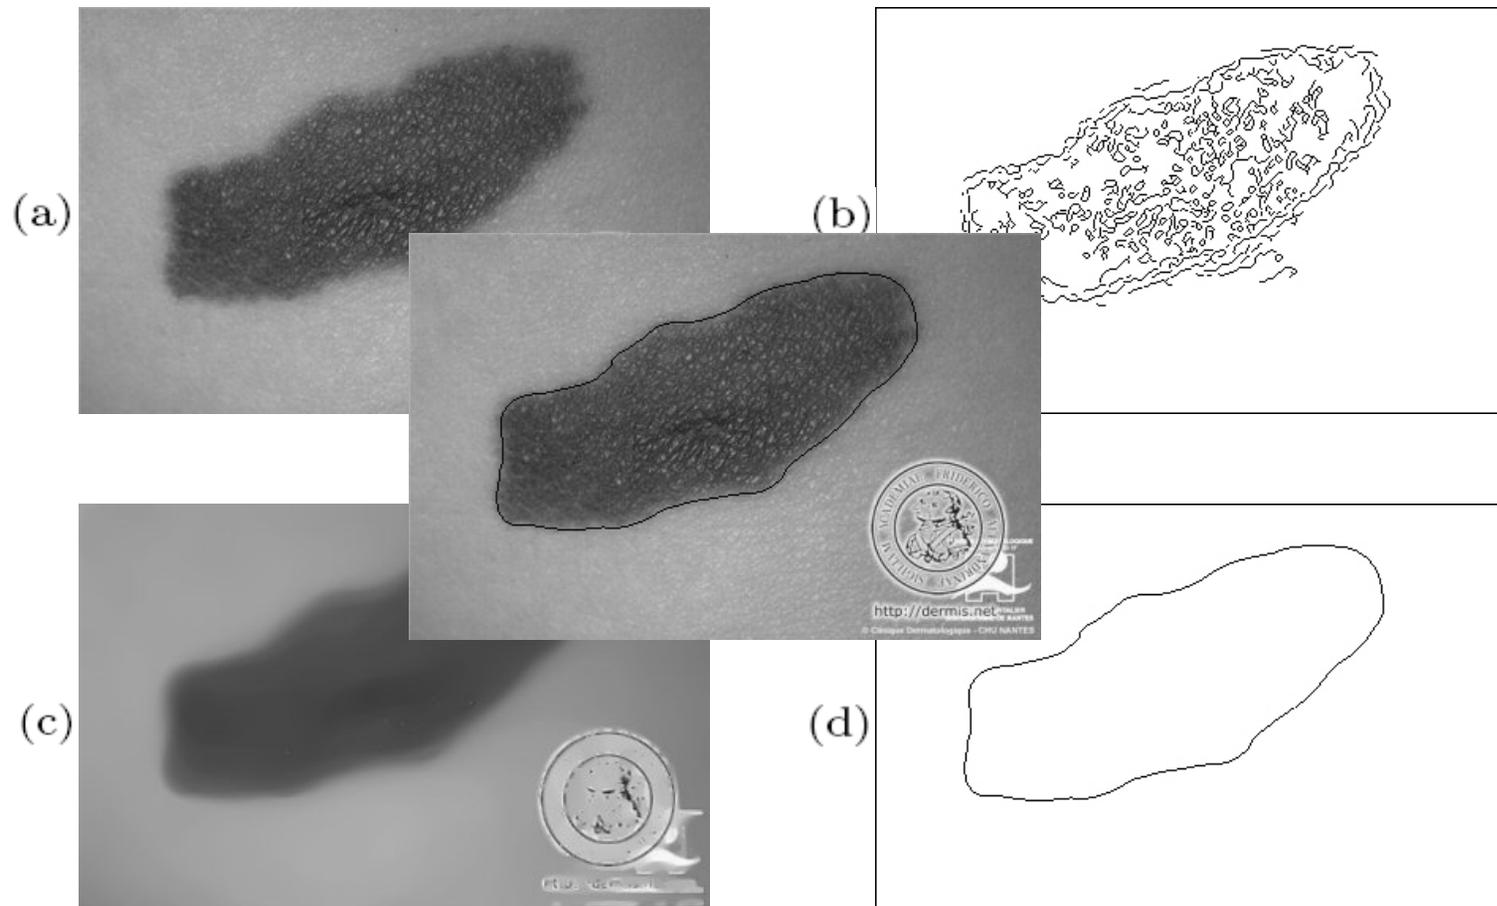


Dermatologista B

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 abaixo mostra desenhos manuais de 2 dermatologistas.

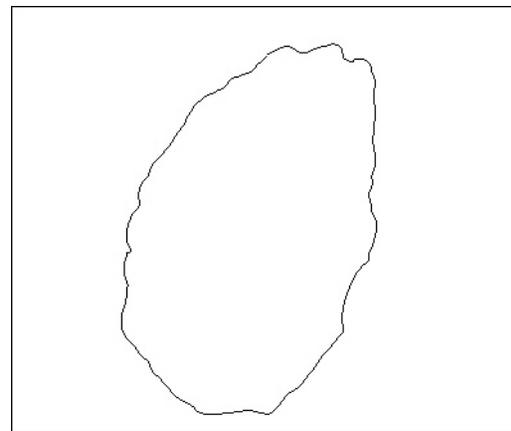
Resultados (Lesão Benigna)



Resultados (Lesão Benigna)



(a)



(b)

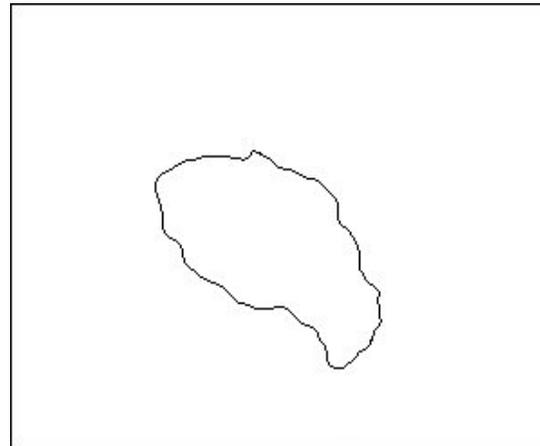


(c)

Resultados (Lesão Maligna)



(a)

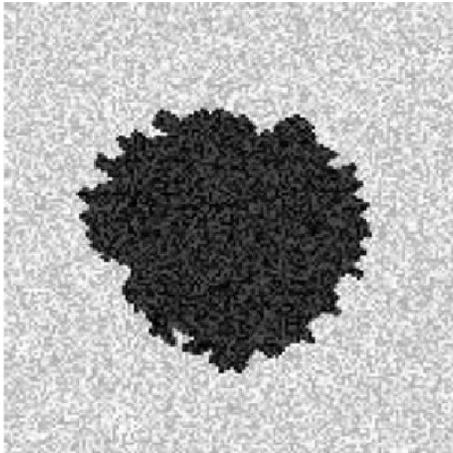


(b)

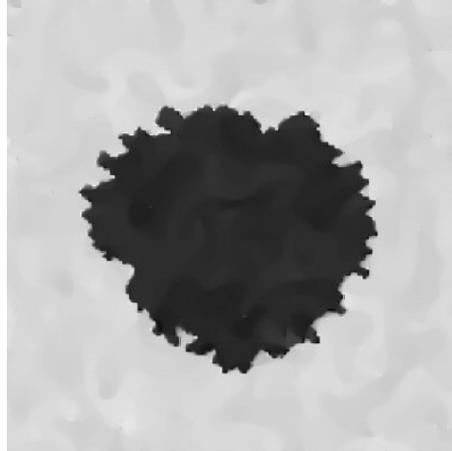


(c)

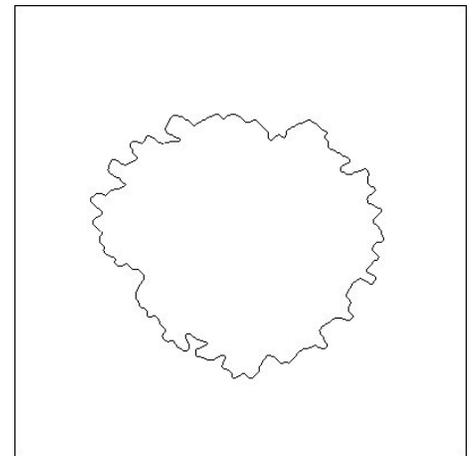
Resultados (Lesão contaminada com ruídos)



(a)



(b)



(c)

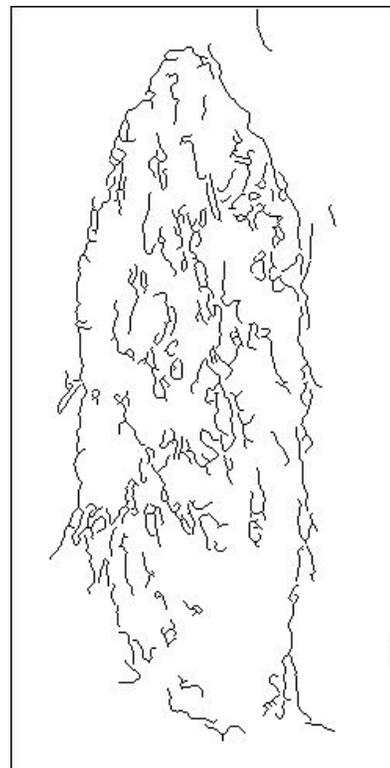
Resultados (Lesão com pelos)



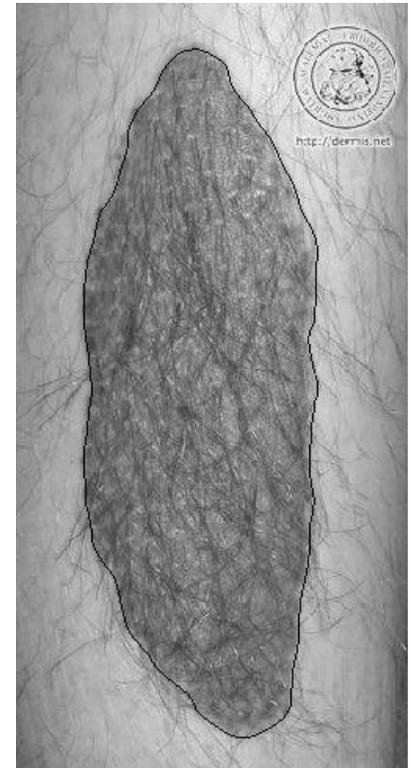
(a)



(b)



(c)



(d)

Conclusões

- Os resultados experimentais mostraram que a técnica de segmentação de lesões de pele proposta é muito promissora.
- Resultados experimentais mostraram que a técnica proposta pode ser aplicada tanto em imagens em níveis de cinza como em imagens coloridas.
- Além disso, podemos obter automaticamente o contorno da lesão de imagens com pelos e com ruídos.