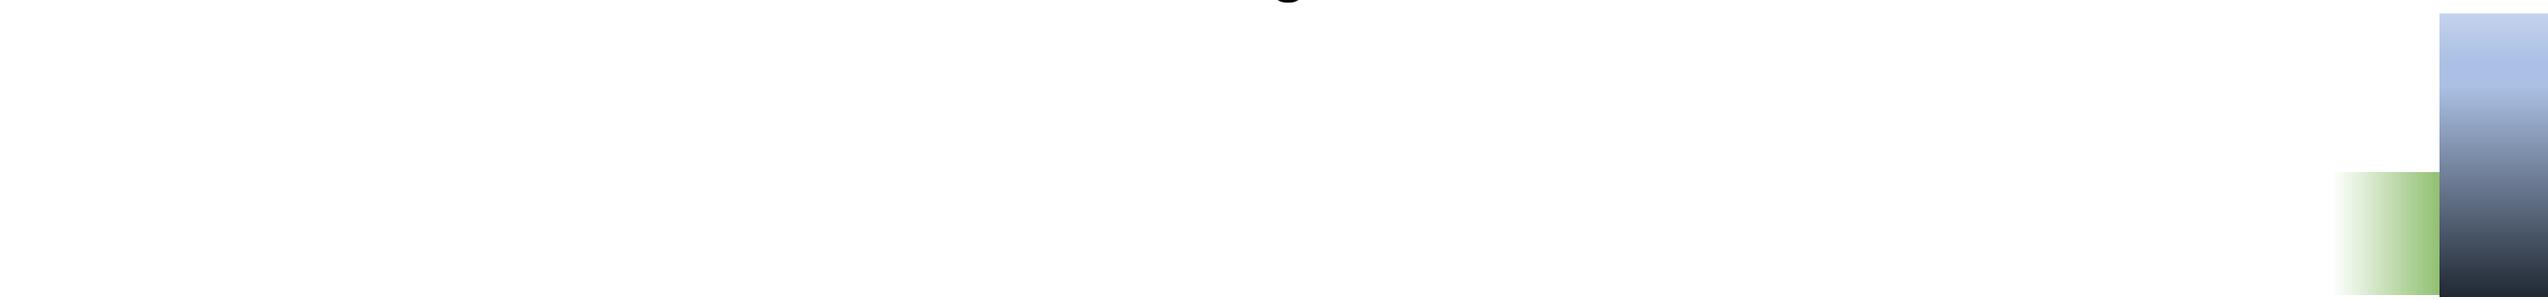


# Processamento Digital de Imagens

## **LIMIARIZAÇÃO**

CPGCG/UFPR

Prof. Dr. Jorge Centeno



# Problema

Dada uma imagem onde dois grandes grupos de pixels são visíveis (claro e escuros), achar o melhor limiar para separar estes dois grupos e binarizar a imagem

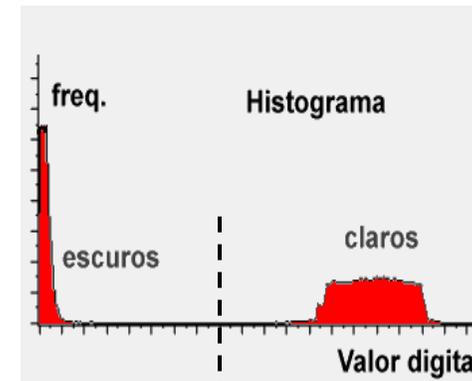
Parte-se da hipótese de que existem dois grupos de pixels na imagem:

claros e escuros

FUNDO e OBJETO

Para separar estes grupos é analisado o histograma da imagem. É assumido que o histograma é bimodal.

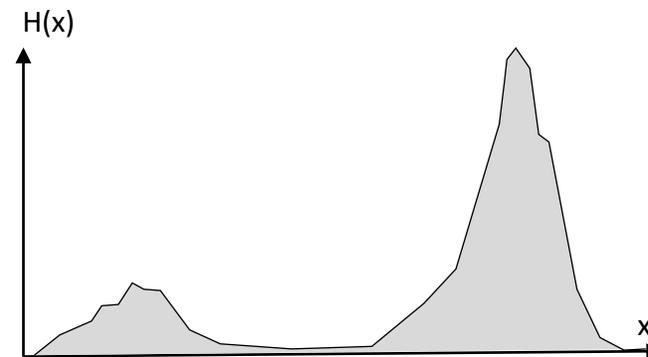
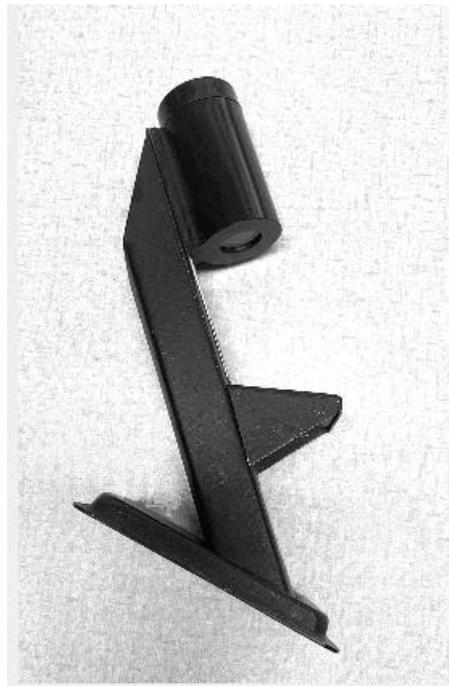
O problema é identificar automaticamente o valor ótimo para separar estes dois grupos.



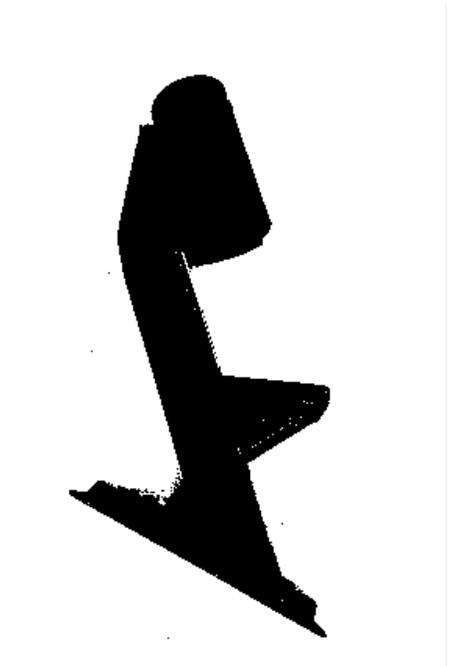
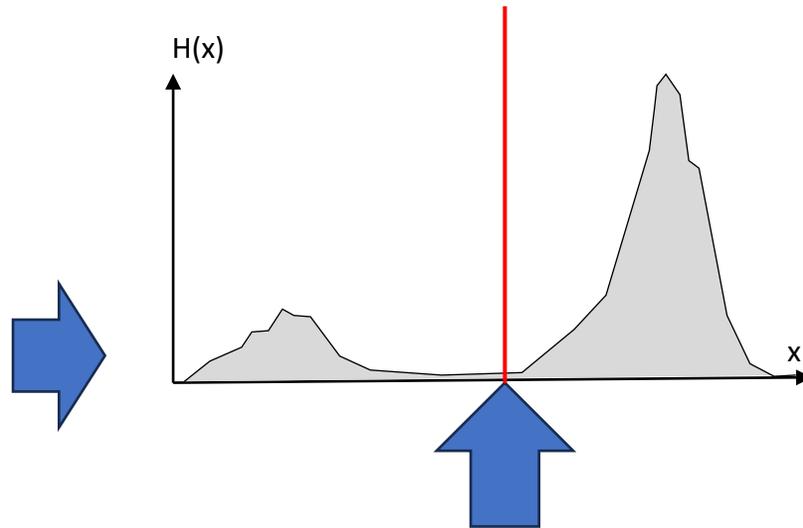
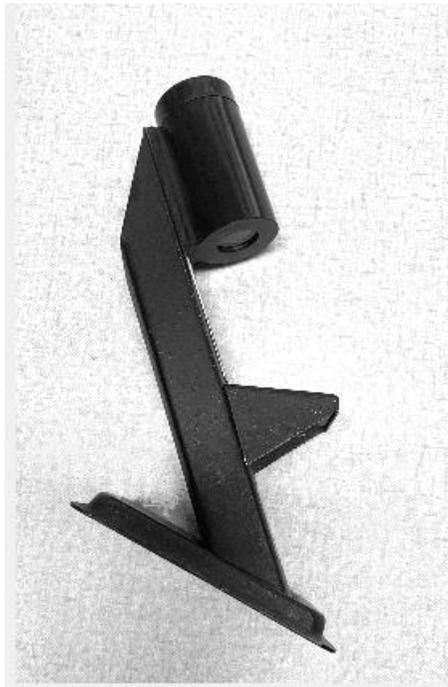
# Detectar limiar no Histograma

O Histograma  $H(x)$  representa a variação dos valores digitais na imagem. Se na imagem ocorrem apenas dois tipos de superfícies, claros e escuros, o histograma será bimodal.

O histograma é uma função positiva definida em um domínio finito.

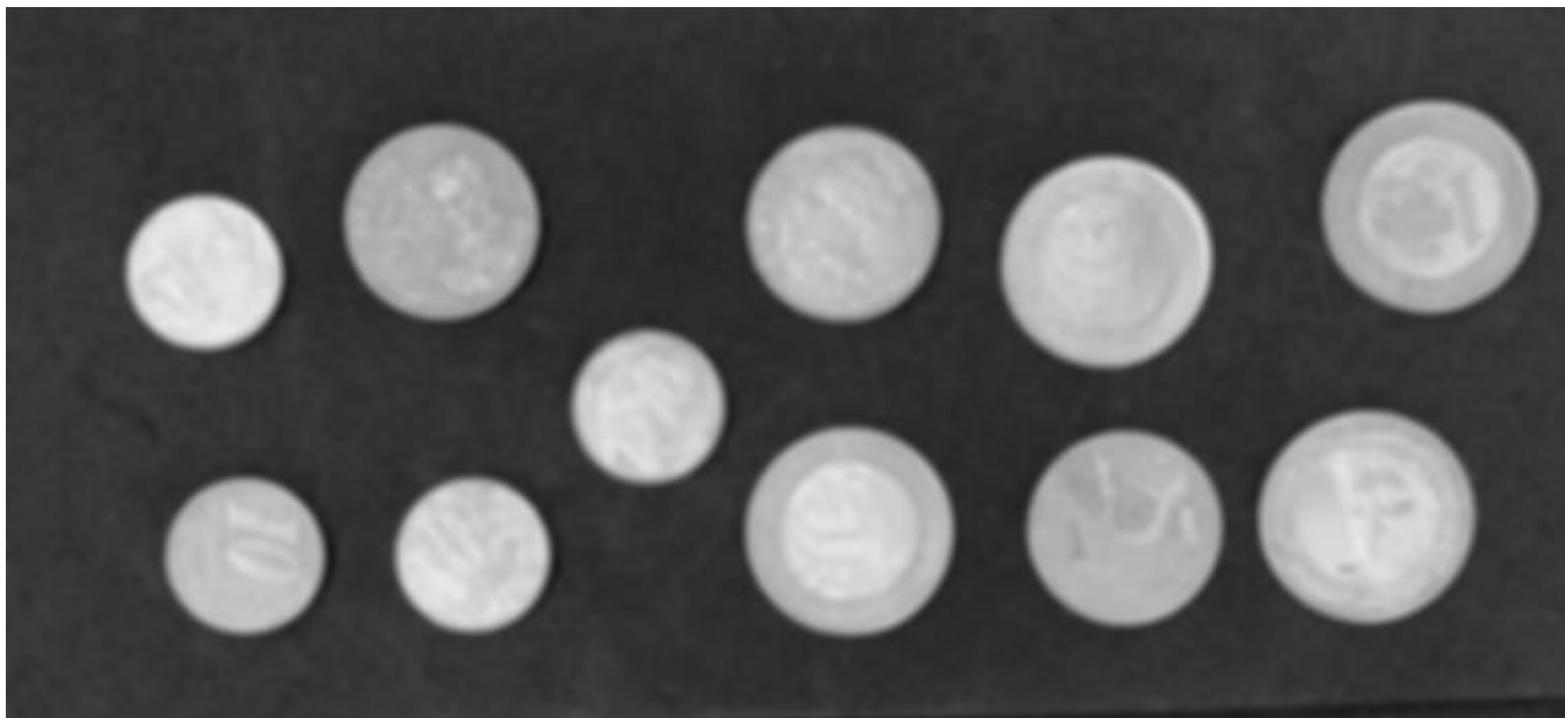


- Problema: determinar o limiar ótimo para qualquer imagem contendo claros e escuros



# exemplo

- Dada a imagem com diferentes objetos, separe os objetos do fundo escuro. Vale a pena analisar o histograma para identificar a fronteira entre grupos (escuro e claro)



# Thresholding (limiarização)

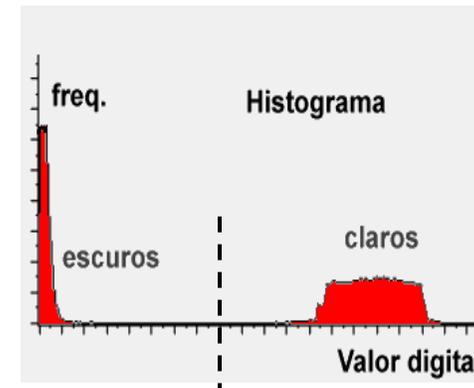
Parte-se da hipótese de que existem dois grupos de pixels na imagem:

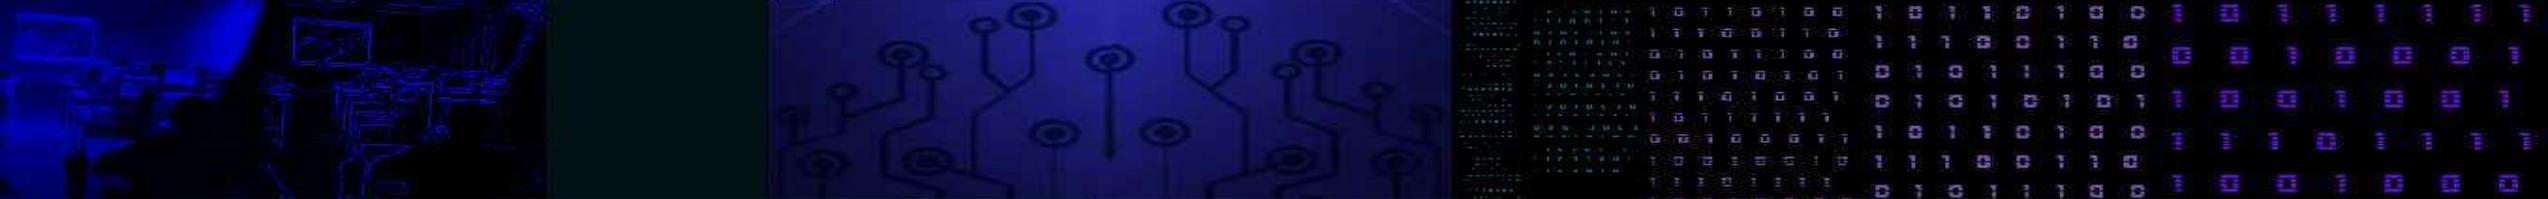
claros e escuros

FUNDO e OBJETO

Para separar estes grupos é analisado o histograma da imagem. É assumido que o histograma é bimodal.

O problema é identificar automaticamente o valor ótimo para separar estes dois grupos.





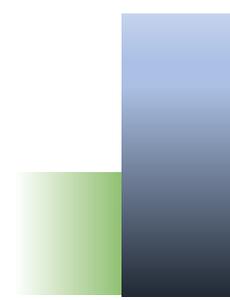
MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO PARANÁ  
SETOR DE CIÊNCIAS DA TERRA  
**Departamento de Geomática**

Disciplina: PROCESSAMENTO DIGITAL DE IMAGENS II  
Código: GA144

**CH Total:45 h**

**CH Semanal 03 h**

# Método do envoltório



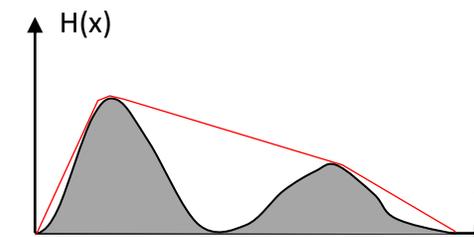
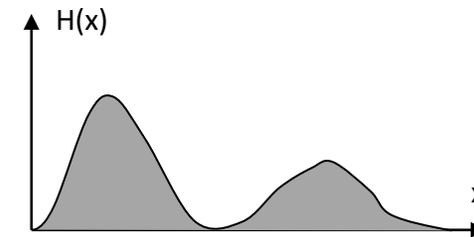
# Método do envoltório

Hipótese: Sendo  $H(x)$  o histograma bimodal, então o limiar deve estar localizado no vale central.

O histograma é uma função positiva definida em um domínio finito  $H(x)$ .

O envoltório convexo de  $H(x)$  é a menor função que:

- é maior ou igual a  $H(x)$
- e é convexa.



# Diferença Convexa

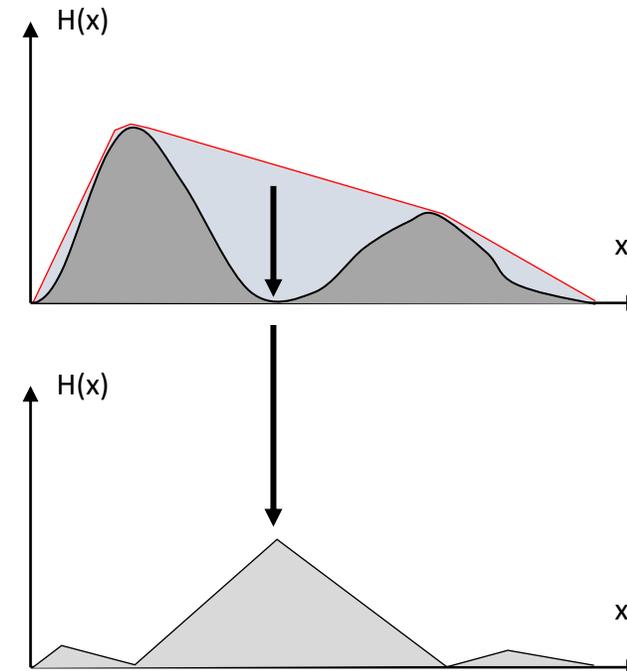
A diferença entre o envoltório e o histograma é chamada de deficiência convexa

$$D(x) = G(x) - H(x)$$

E informa quanto o histograma se afasta da forma convexa.

Ocorre que, esta deficiência é maior no fundo do vale entre dois picos. Ou seja, no local ideal para um limiar.

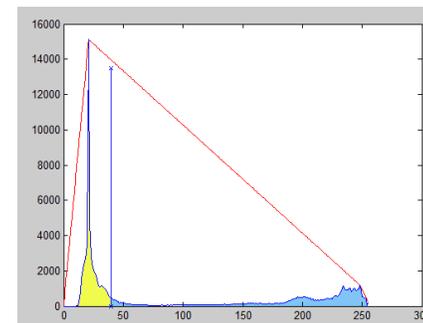
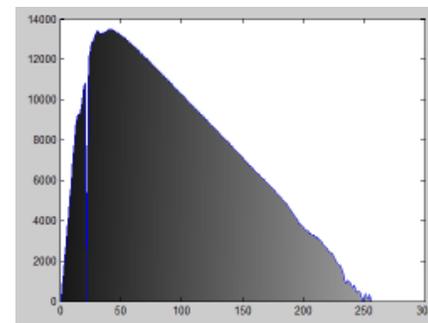
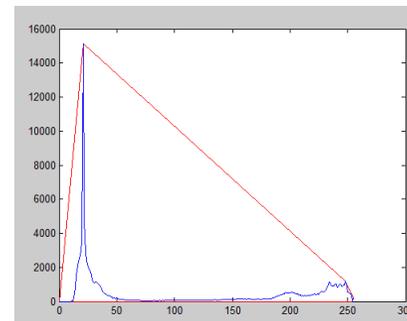
O máximo desta diferença indica o fim do primeiro agrupamento (LIMIAR)





## LOGARITMO

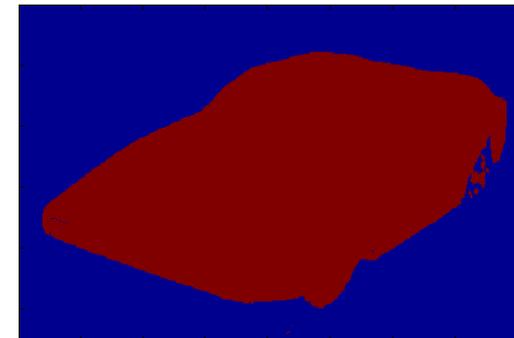
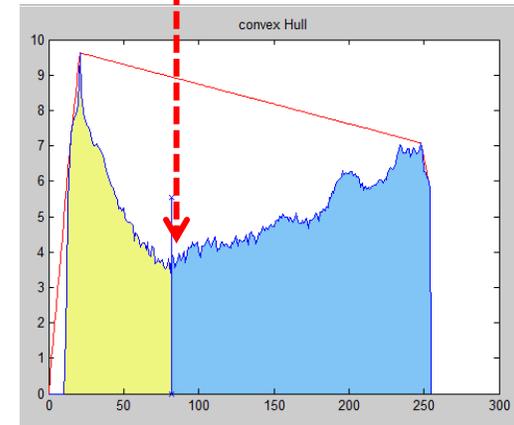
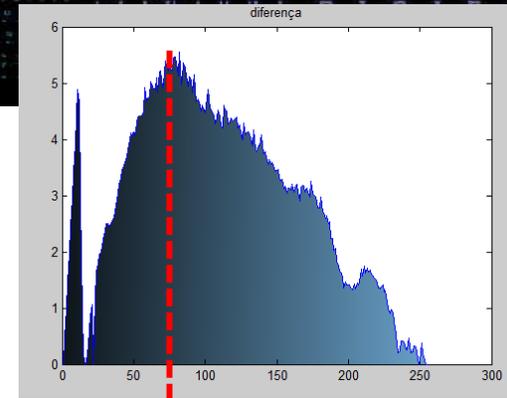
Na prática, o Histograma pode ter picos muito diferentes em altura, o que pode prejudicar a detecção do Limiar.

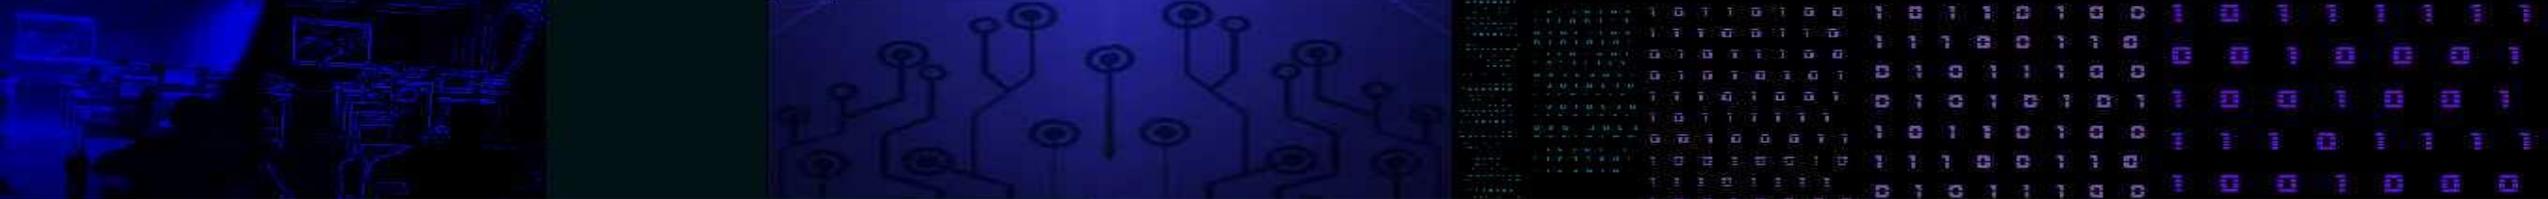


# Exponential Convex Hull

A diferença entre os valores é menor se em lugar dos valores originais se usa o logaritmo:

$$h1(x) = \log(h(x))$$





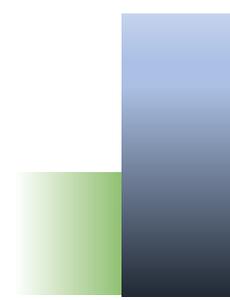
MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO PARANÁ  
SETOR DE CIÊNCIAS DA TERRA  
**Departamento de Geomática**

Disciplina: PROCESSAMENTO DIGITAL DE IMAGENS II  
Código: GA144

**CH Total:45 h**

**CH Semanal 03 h**

# **Método de OTSU**



# OTSU

## Método de OTSU

Trata o Histograma da imagem como uma Função Densidade de Probabilidade Discreta:

$$p(x) = H(x) / N$$

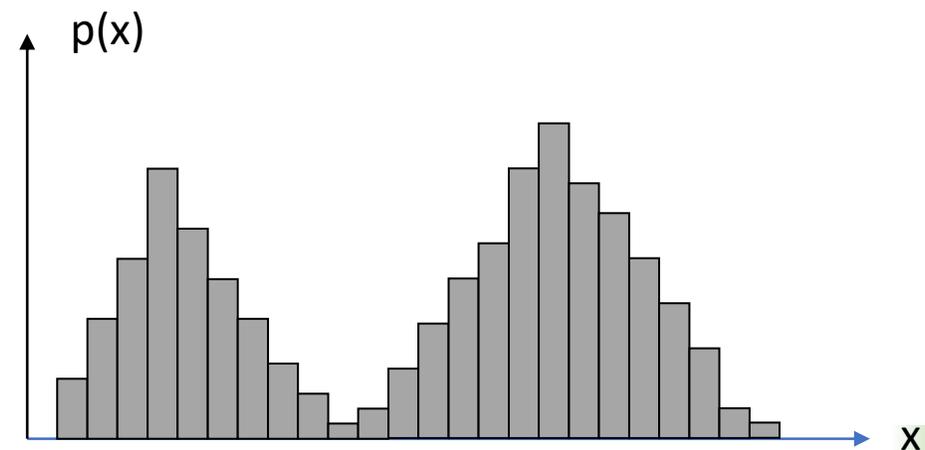
Onde:

$x$  = valor digital, com  $q = 0, 1, 2, \dots, 255$  (\*pode ser outro valor máximo)

$H(x)$  = número de pixels com valor digital  $x$

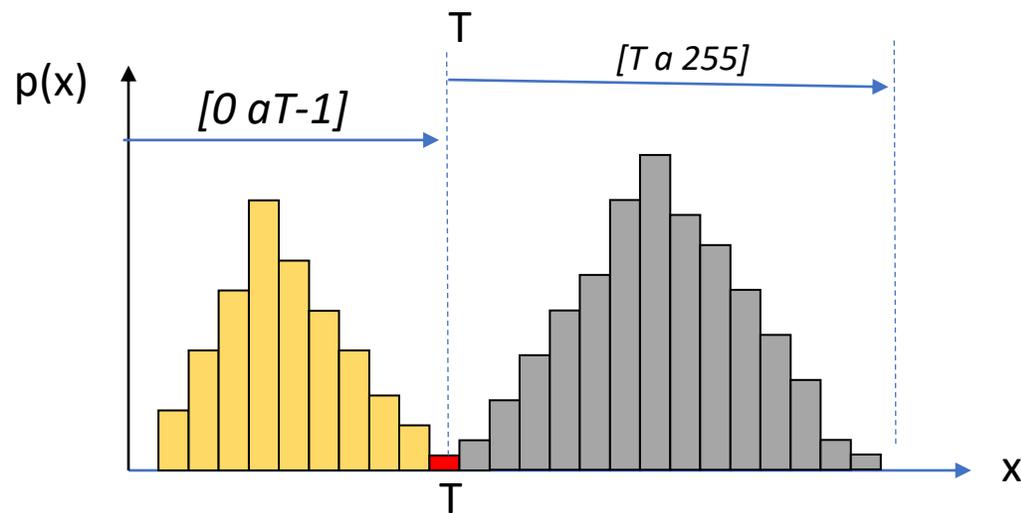
$N$  = número total de pixels na imagem

Qual valor é mais provável?  
quele mais frequentemente!



Usando o Limiar (T) pode-se separar a imagem em duas classes, dois grupos:

- A = pixels com valores entre  $[0, T-1]$  e
- B = pixels com valores entre  $[T, 255]$



```
Limiar=100
if I[x,y] < Limiar:
    J[x,y] = 0
else:
    J[x,y] = 255
```

Cada grupo é descrito por:  
soma das probabilidades das classes ,  
a área de cada grupo (w)

- valor x médio (m)
- variância (S)

$$w_1 = \sum_0^{T-1} p(x)$$

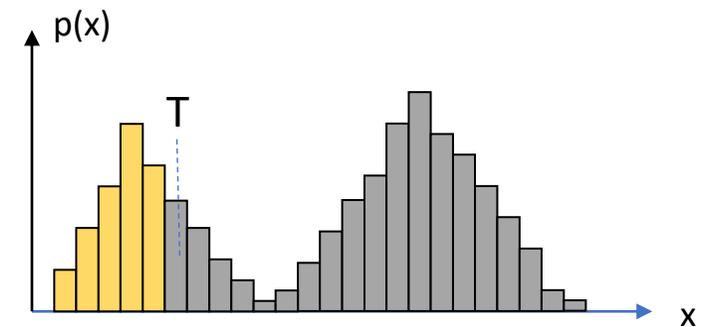
$$m_1 = \sum_0^{T-1} x * p(x) / w_1$$

$$S_1 = \sum_0^{T-1} (x - m_1)^2 * p(x) / w_1$$

$$w_2 = \sum_T^{255} p(x)$$

$$m_2 = \sum_T^{255} x * p(x) / w_2$$

$$S_2 = \sum_T^{255} (x - m_2)^2 * p(x) / w_2$$



# Variância (S) mínima

O Limiar ótimo separa os pixels em dois grupos uniformes.

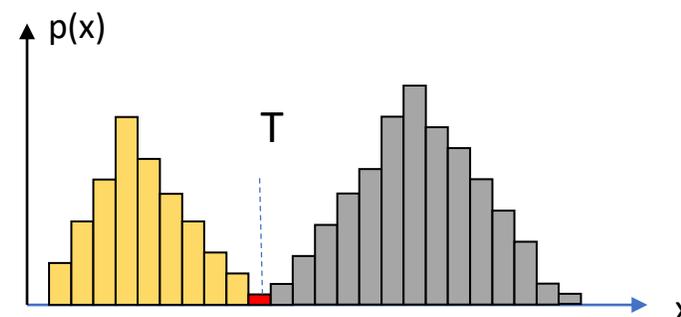
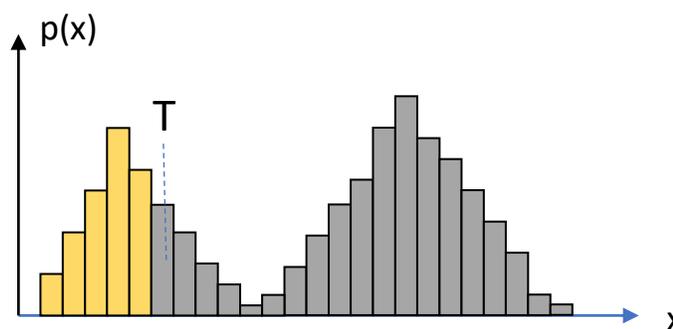
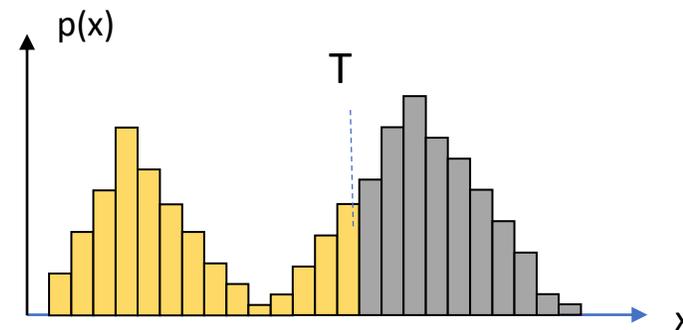
Grupos uniformes tem variância baixa.

Logo, a variância combinada dos dois grupos deve ser baixa

A variância combinada é dada pela soma (ponderada) das variâncias

$$S^2(T) = a_1(T) S_1^2(T) + a_2(T) S_2^2(T)$$

a = fator de ponderação



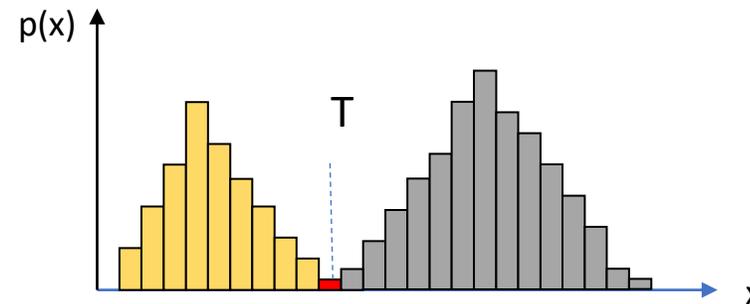
# Variância (S) mínima

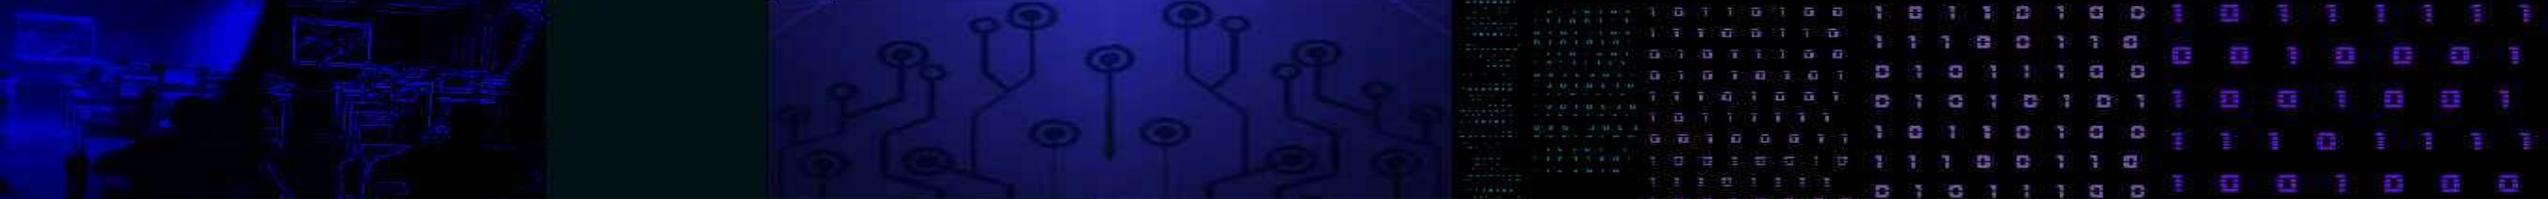
Busca-se o Limiar “T” que minimiza a variância combinada (dentro dos grupos).  
Como “peso”, usa-se a soma das probabilidades das classes (a área).  
Classe mais frequente “pesa” mais.

$$S^2(T) = w_1(T) S_1^2(T) + w_2(T) S_2^2(T)$$

$$w_1(T) = \sum_0^{T-1} p(x)$$

$$w_2(T) = \sum_T^{255} p(x)$$





Minimizar a variância dentro das classes equivale a  
Maximizar a variância entre classes:

$$S_{entre}^2(T) = S^2 - S_{dentro}^2(T)$$

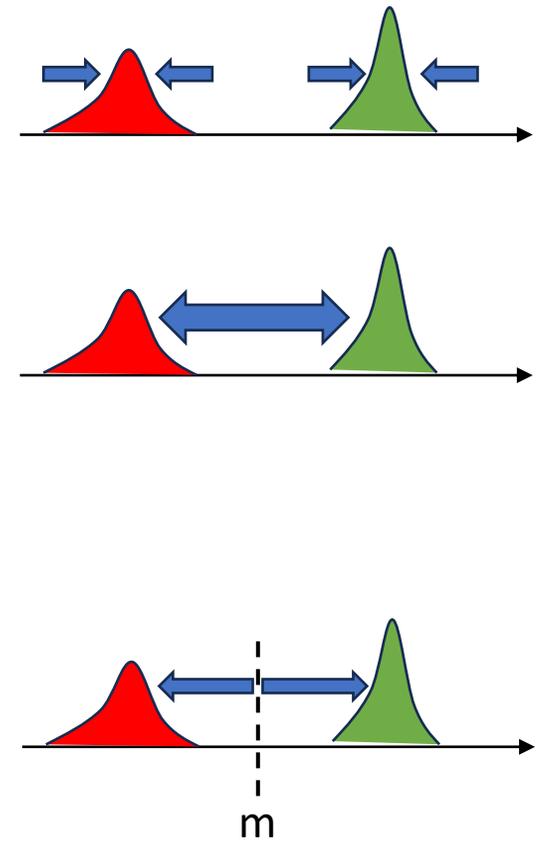
A variância entre classes pode ser calculada com ajuda da  
distância das médias dos grupos à média de toda a imagem  
média da imagem

$$m = w_1 m_1 + w_2 m_2$$

$$S_{entre}^2 = w_1 (m_1 - m)^2 + w_2 (m_2 - m)^2$$

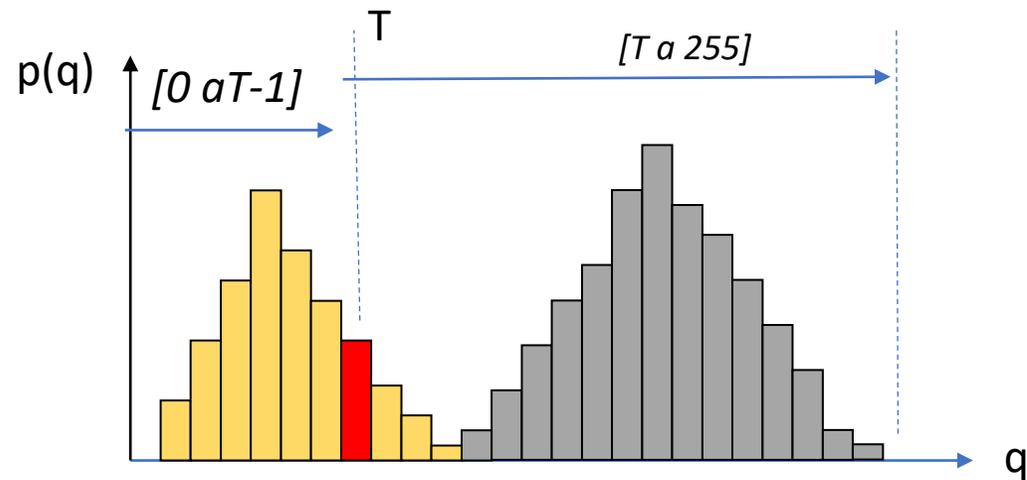
Ou, desenvolvendo e agrupando...

$$S_{entre}^2 = w_1 w_2 (m_1 - m_2)^2$$

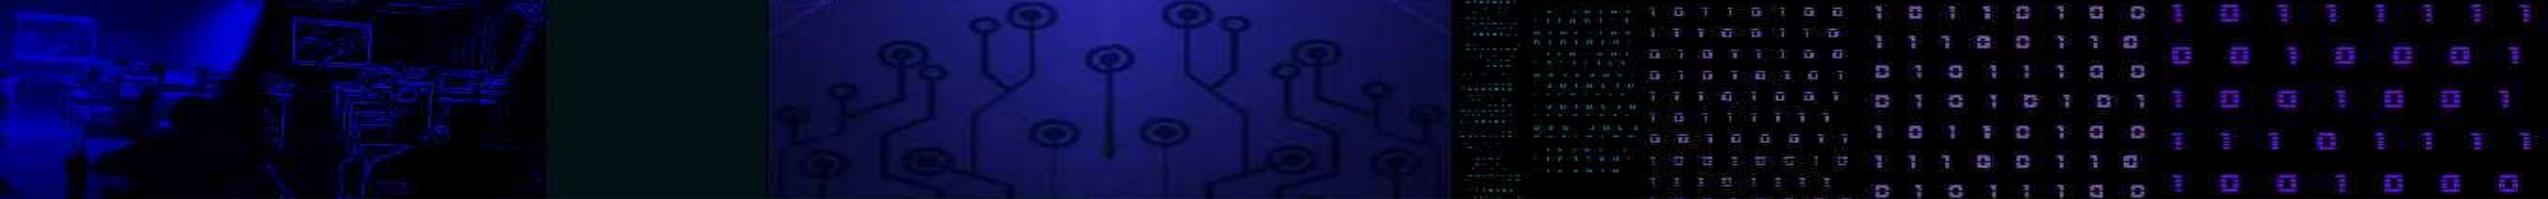


Como fazer?

Varrer todos os possíveis valores e calcular a variância para achar o máximo

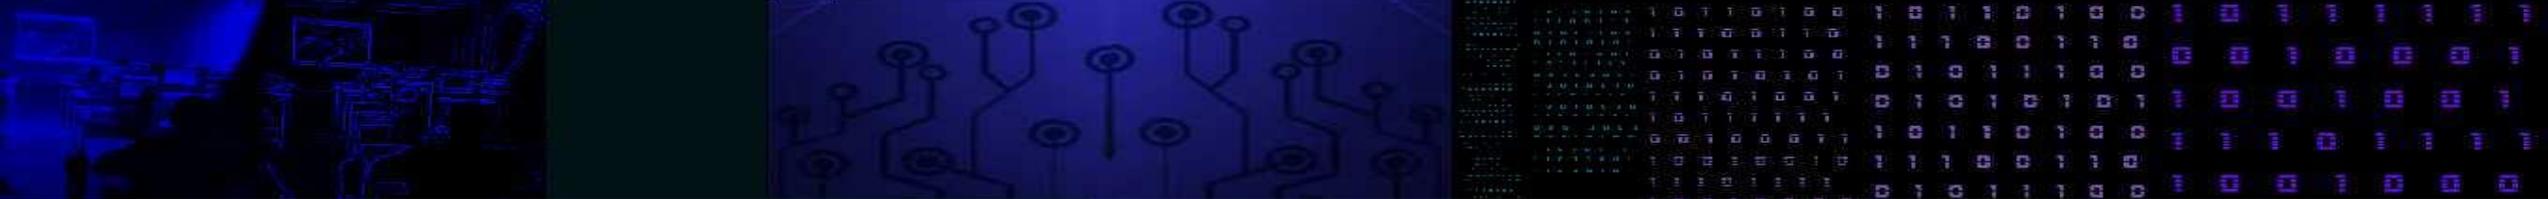


Consulte: Otsu N., "A Threshold Selection Method from Gray-level Histograms", IEEE Transactions on Systems, Man and Cybernetics, v. SMC 9, no 1, pp.62-66, 1979.



## **cv.calcHist(imagem, banda, mask, histSize, faixa)**

- image : entrada uint8 ou float32. Deve ser escrito em colchetes, "[I]".
- banda : No caso de imagens coloridas, especifica qual banda será processada. Em imagens em nível de cinza, deve-se usar [0], sempre entre colchetes.
- mask : opção de processor apenas uma parte da imagem (mascara). Por default se processa toda a imagem com a opção "None".
- histSize : número de elementos do histograma. Em imagens de 8 bits o correto é usar [256].
- faixa : a faixa a ser representada, em colchetes. Geralmente [0,256]



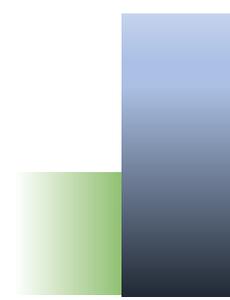
```
hist = cv2.calcHist([I],[0],None,[256],[0,256])
```

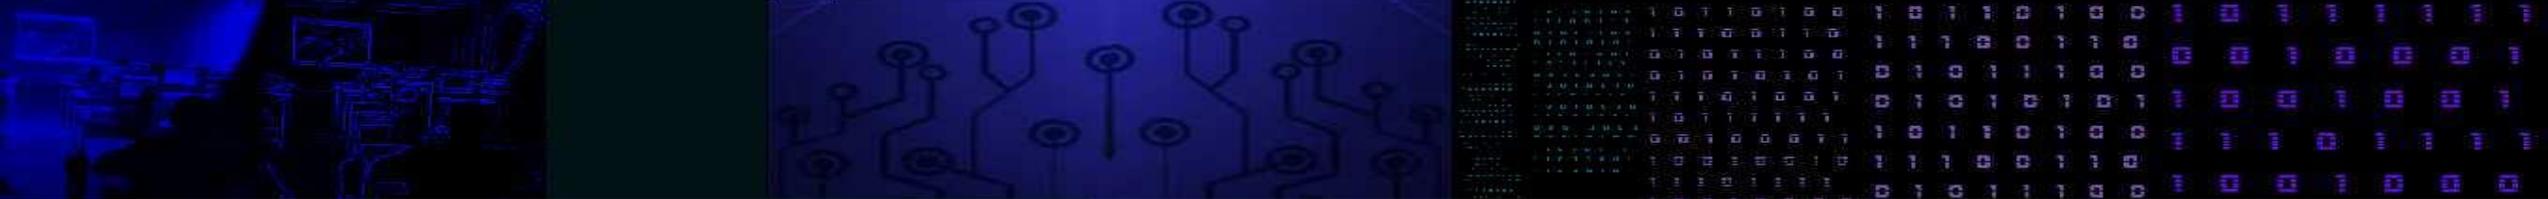
```
from matplotlib import pyplot as plt
```

```
plt.plot(hist,color = 'red')
```

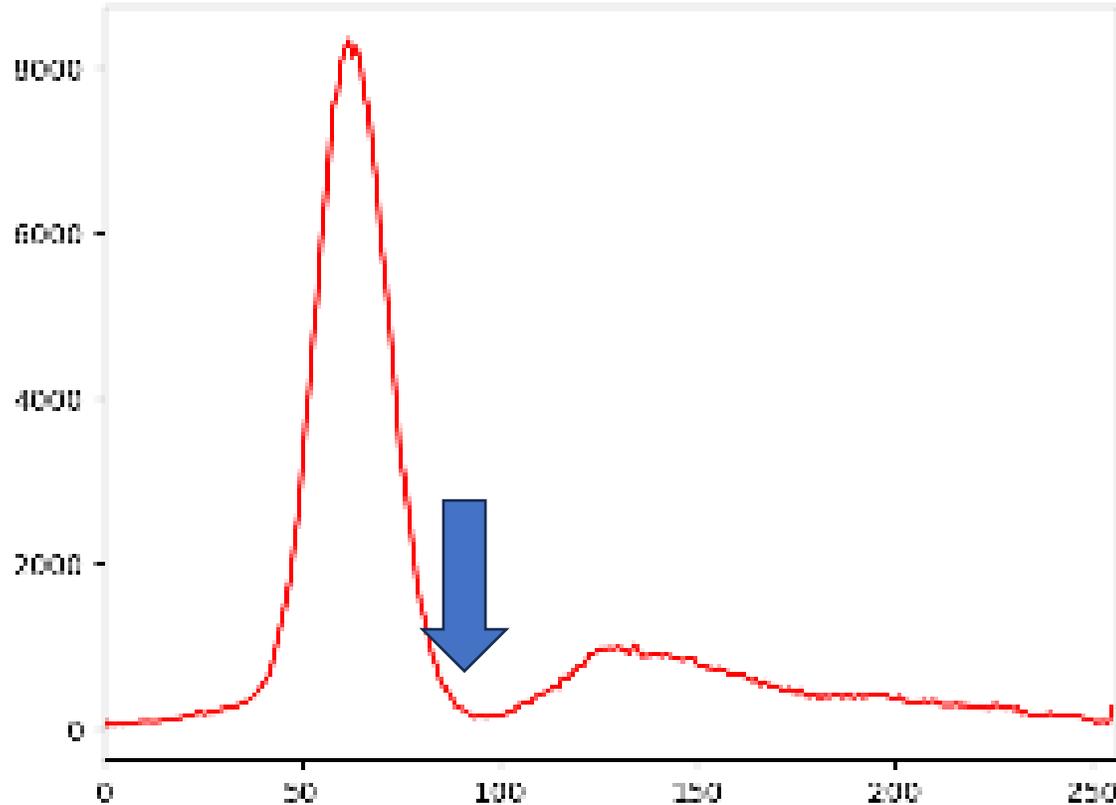
```
plt.xlim([0,256])
```

```
plt.show()
```





- Analisar o histograma e detectar o melhor valor LIMAR

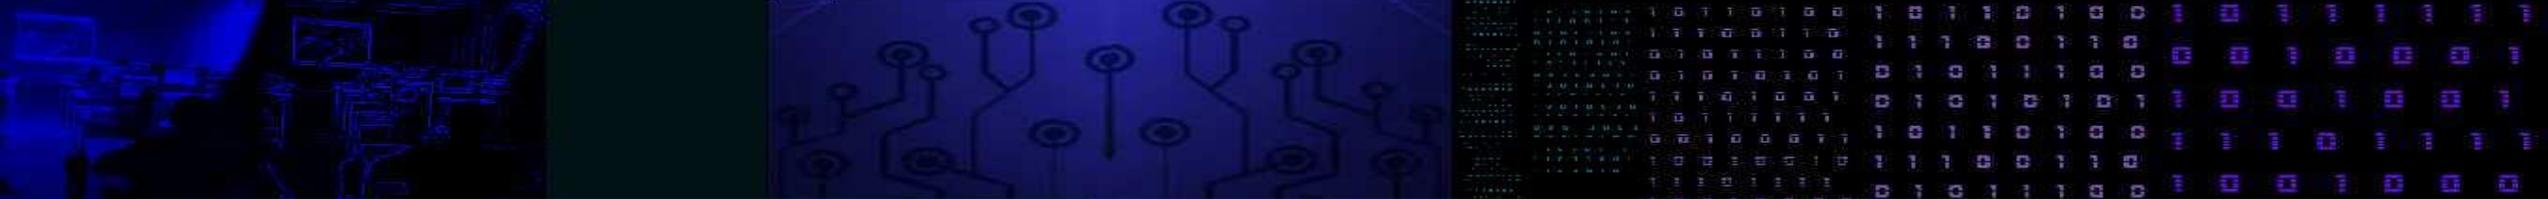


Limiar =90, ou 100?

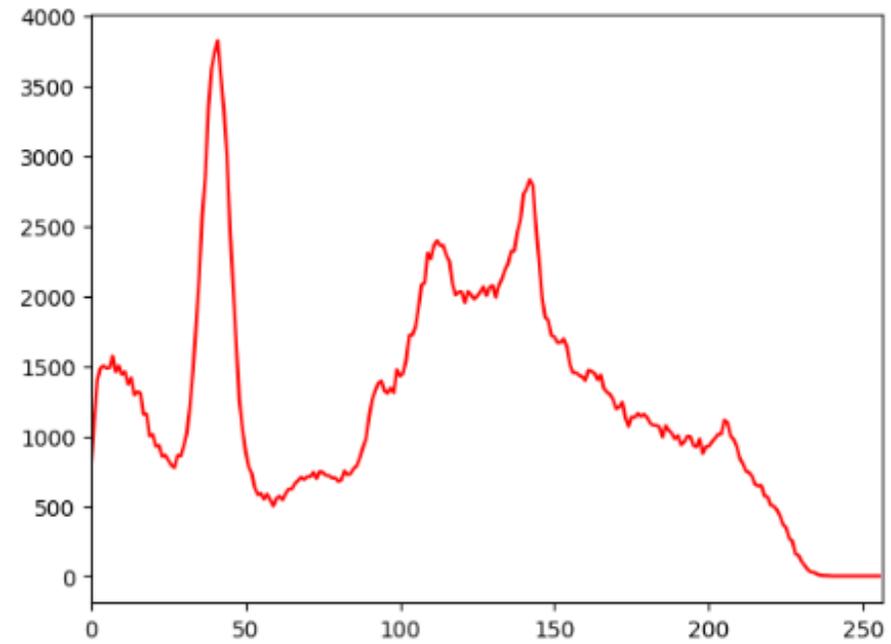
# `PROGRAMA SIMPLES MANUAL

```
Limiar=100
for i in range(nlin):
    for j in range(ncol):
        if I[i,j] > Limiar:
            J[i,j] = 255
        else:
            J[I,j] = 0
```

- Binarização em OpenCV selecionando limiar MANUALmente



- histograma



opções

th, K = cv2.threshold(IMA, limiar, maximo, MODO)

- th: limiar (redundante)
- K: imagem de saída
- **IMA**: imagem de entrada
- **Limiar**: Limiar especificado pelo usuário. Deve estar dentro da faixa de valores da imagem. Vale a pena visualizar o histograma para escolher um valor
- **Maximo**: o valor que será atribuído aos pixels que superem o limiar
- **MODO**: opção de binarização, pode ser simples ou preservando valores originais. veja a lista ...

## Exemplo

cv2.THRESH\_BINARY: opção de binarização simples

```
limiar=100
```

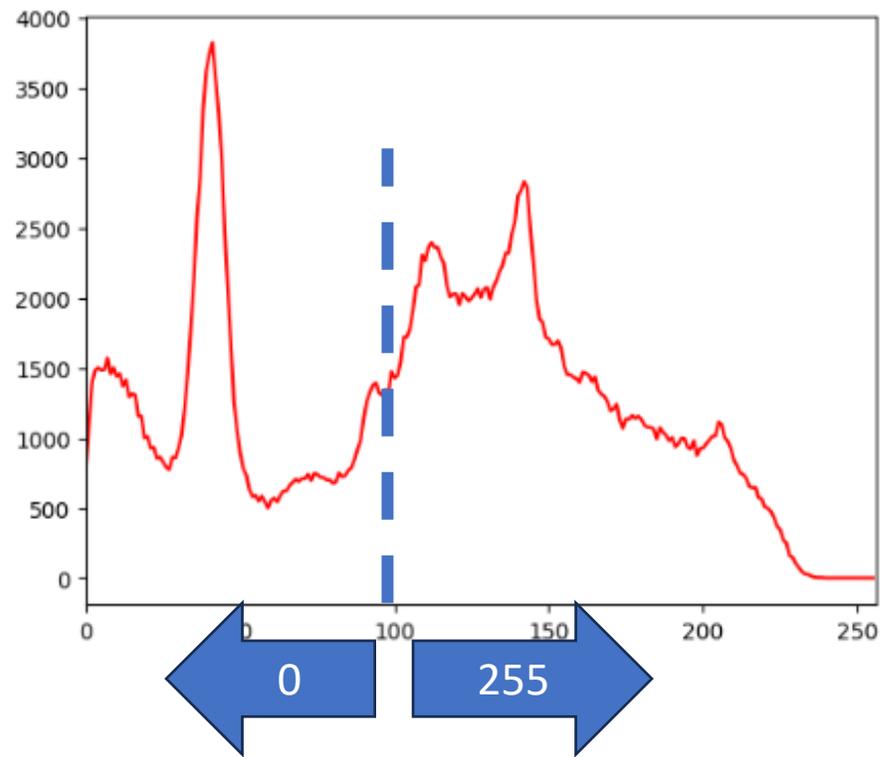
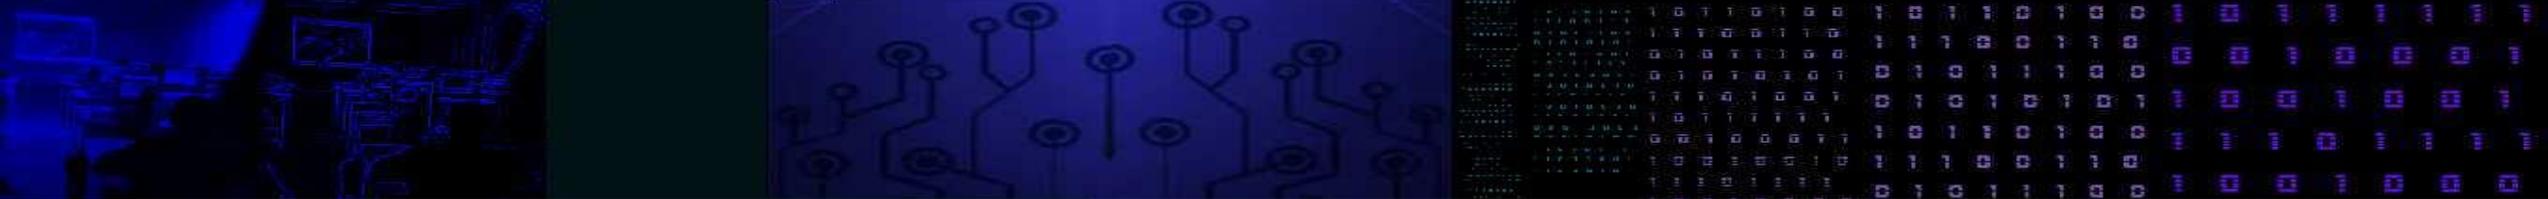
```
maximo=255
```

```
th, K = cv2.threshold(I, limiar, maximo, cv2.THRESH_BINARY)
```

```
cv2.imshow(K)
```

```
print(th)
```

```
maximo=255
Limiar=100
if I[x,y] > Limiar:
    J[x,y] = maximo
else:
    J[x,y] = 0
```



Limiar=100

Qual o melhor Limiar para separar as áreas escuras desta imagem?

- MODO: THRESH\_BINARY\_INV

Neste caso, o resultado é o negativo do anterior. Ou seja, os valores que superam o limiar são marcados como zero.



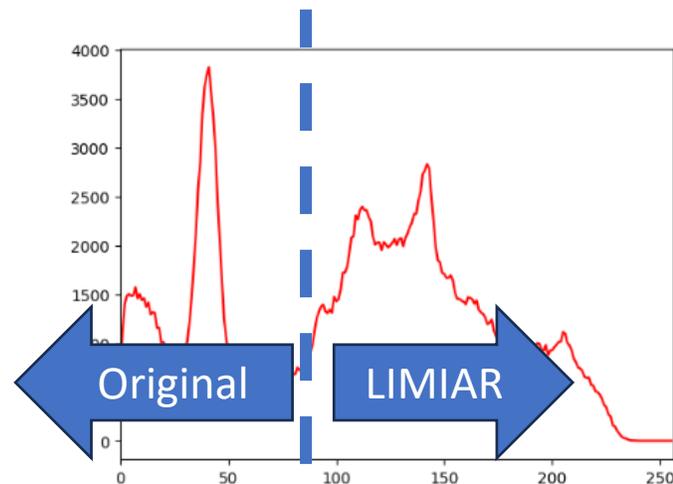
```
maximo=255  
Limiar=100  
if I[x,y] > Limiar:  
    J[x,y] =0  
else:  
    J[x,y] = maximo
```

- MODO THRESH\_TRUNC

É usado para salientar os valores acima do limiar e preservar aqueles abaixo do limiar. Neste caso, os valores que seriam anulados (abaixo do limiar) preservam seu valor original e aqueles acima do limiar assumem o valor do limiar. Equivale a truncar a imagem com o limiar.

```
th, K = cv2.threshold(I, limiar, maximo, cv2.THRESH_TRUNC)
```

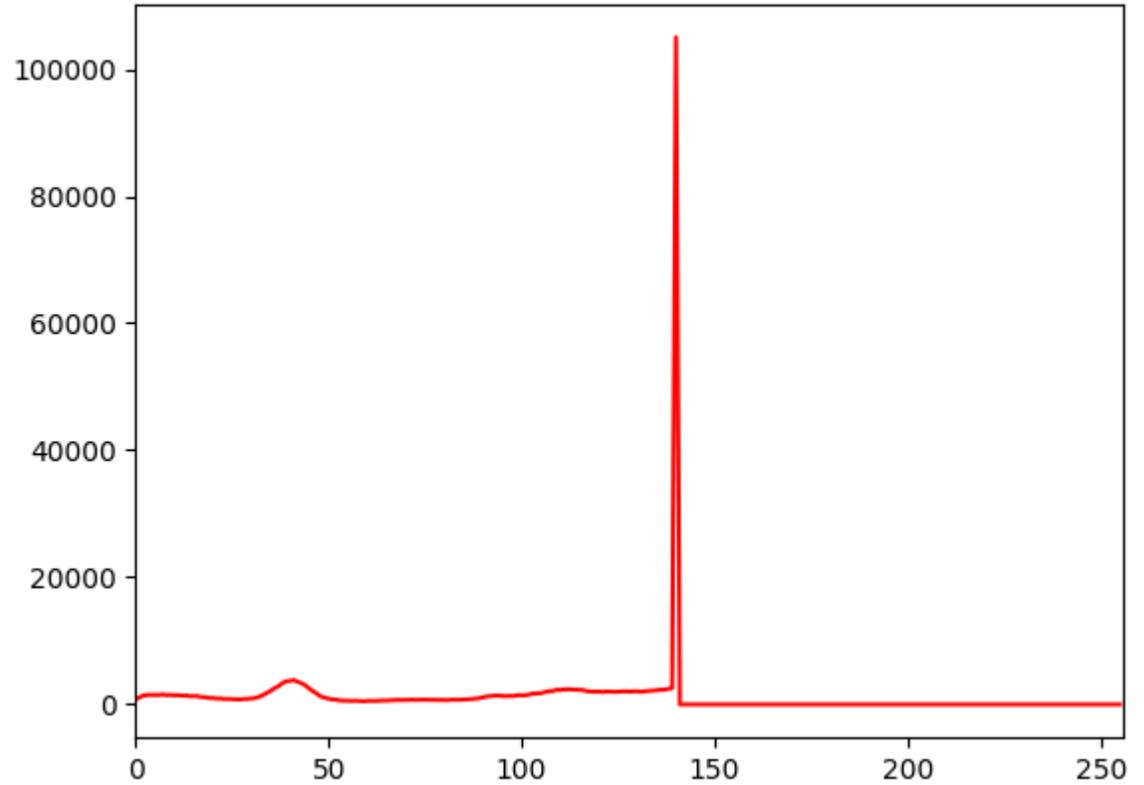
Ignora-se máximo



```
maximo=255  
Limiar=100  
if I[x,y] > Limiar:  
    J[x,y] = maximo  
else:  
    J[x,y] = I[i,j]
```

```
limiar=140
```

```
th, K = cv2.threshold(I, limiar, maximo, cv2.THRESH_TRUNC)  
cv2_imshow(K)
```



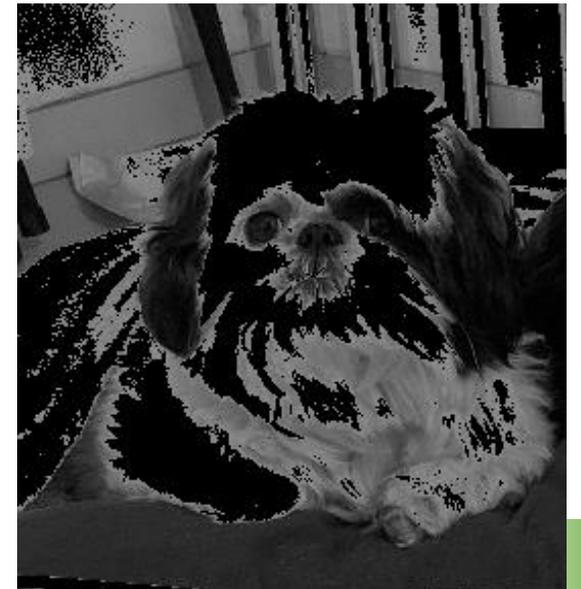
## THRESH\_TOZERO

- Similar ao anterior, mas neste caso o valor original é representado se o limiar for superado. Os pixels abaixo do limiar são anulados (zero)

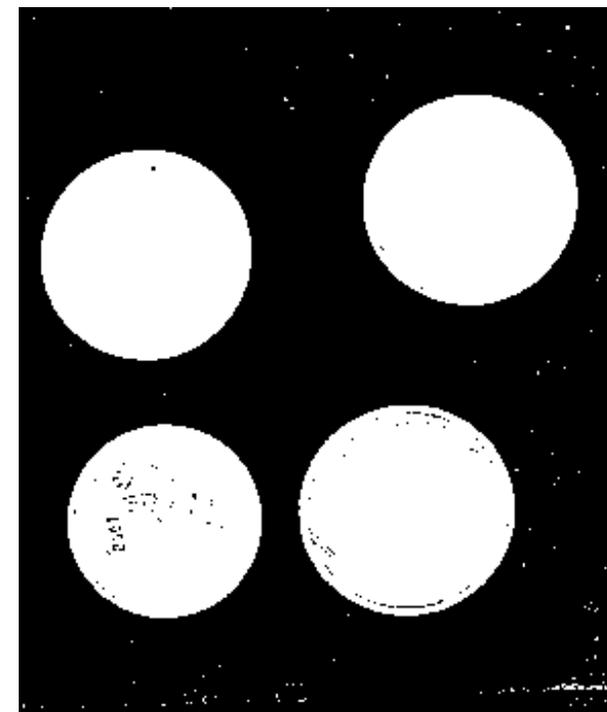


## THRESH\_TOZERO\_INV

- Inverted Threshold to Zero,
- Se o valor do limiar for superado, o pixel recebe zero. Caso contrário o valor original é preservado.



- Cuidado! Devido às sombras, as regiões podem conter “buracos”, e pontos claros podem ocorrer no “fundo”. Como contornar este problema?



Aplicar suavização para uniformizar as regiões

E depois, binarizar

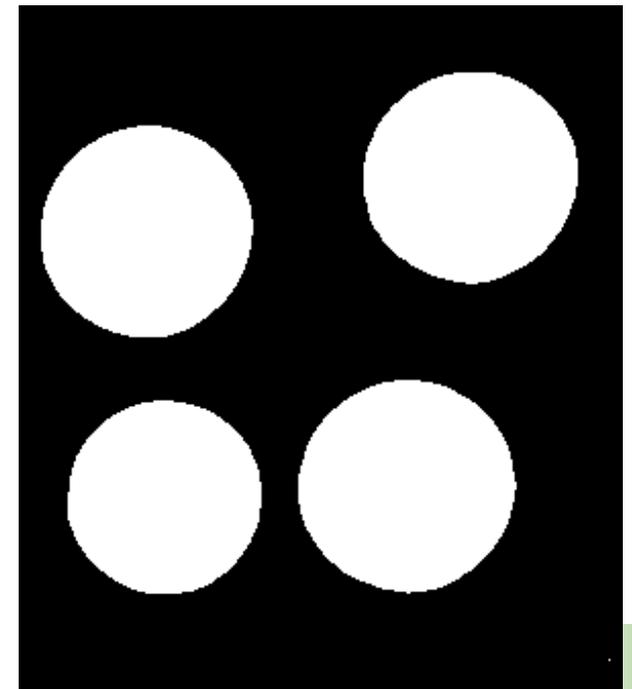
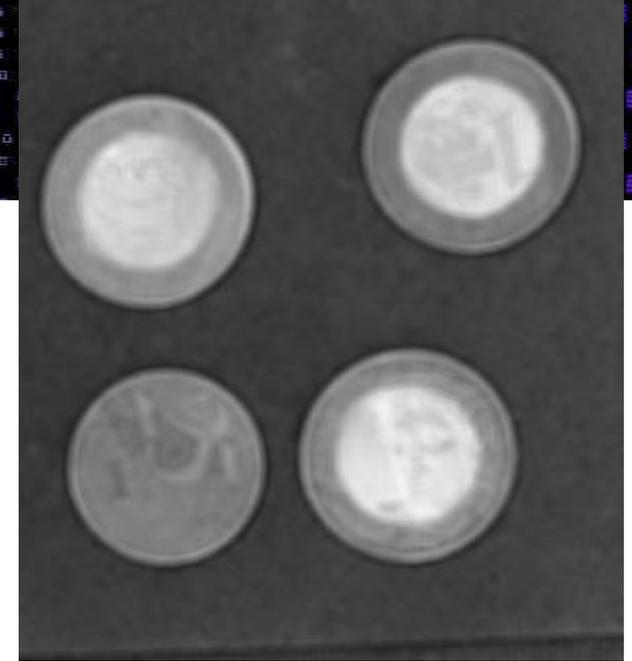
```
im = cv2.blur(src=I, ksize=(5,5))  
cv2_imshow(im)
```

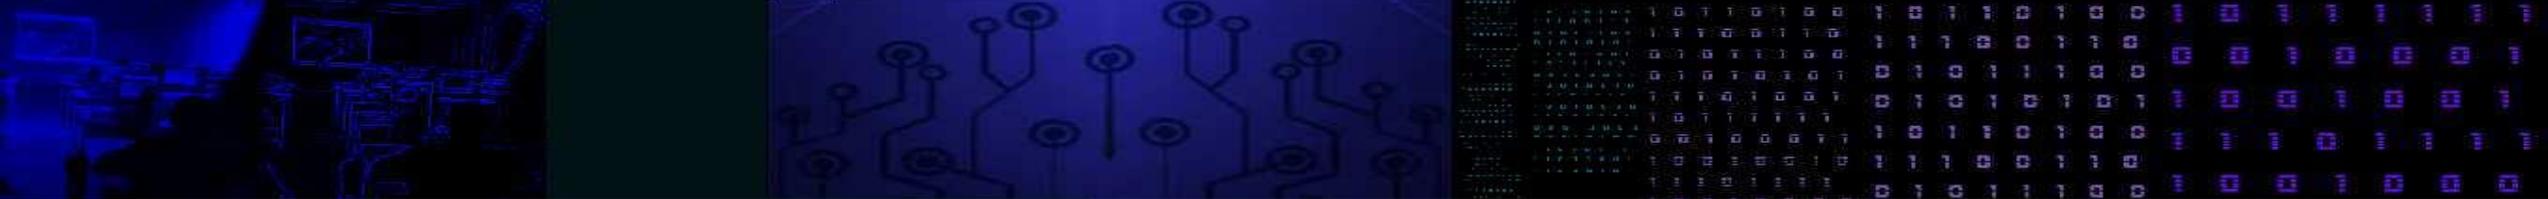
```
limiar=90
```

```
maximo=255
```

```
th, K = cv2.threshold(im, limiar,  
maximo, cv2.THRESH_BINARY)
```

```
cv2_imshow(K)
```

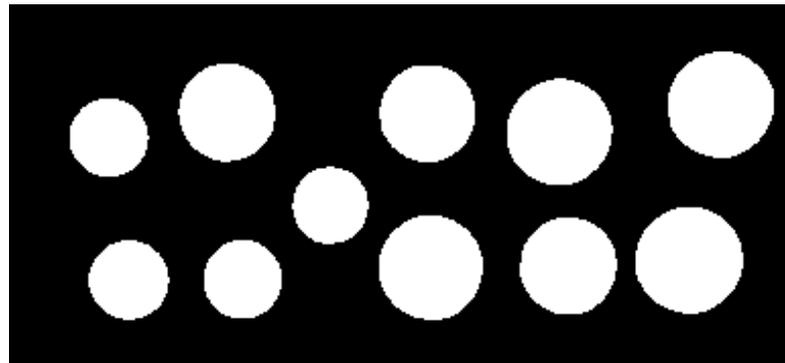




- Seleção automática de LIMIAR por OTSU

```
# Gaussian Blur (7x7)
im = cv2.GaussianBlur(I, (7, 7), 0)

# threshold com OTSU
th, K = cv2.threshold(im, 0, 255, cv2.THRESH_BINARY | cv2.THRESH_OTSU)
cv2.imshow(K)
print(th) # veja o valor do limiar que foi calculado automaticamente
```





- Problema
- Separe as moedas e conte quantas tem de cada valor
- Quantos dedos são mostrados em cada mão?

