PDI

Segmentação

UFPR – Departamento de Geomática
Prof. Jorge Centeno
2021

Segmentação

Uma das maneiras de extrair informação de uma imagem é analisando agrupamentos de pixels com características similares (uma região uniforme) em lugar do pixel isolado. O primeiro passo nesta análise é a delimitação de regiões uniformes na imagem, o que pode ser atingido aplicando métodos de segmentação.

segmentar: Separar ou dividir uma coisa em suas diferentes partes”

Algoritmos de segmentação

- Podem ser Globais ou Locais
- Global: busca pixels com cores similares ao longo de toda a imagem
- Local: busca pixels similares dentro de uma região limitada

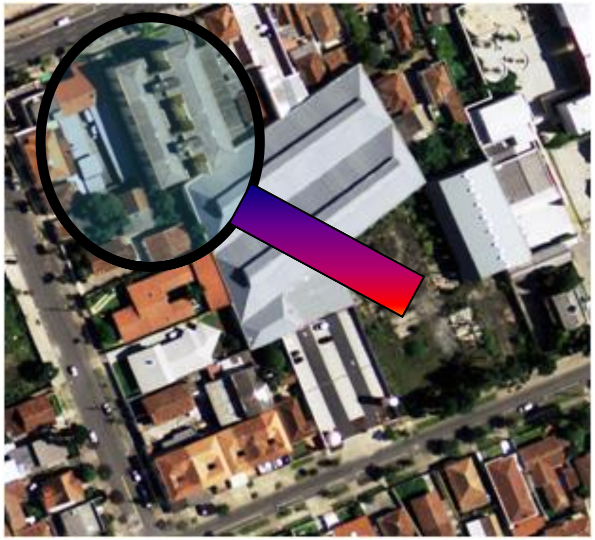

Segmentação Global

- Os métodos de segmentação global analisam a variação dos valores digitais presentes em toda a imagem e tentam formar grupos, partindo da hipótese de que os objetos na imagem aparecem de forma uniforme em termos de cor.
- São exemplos os métodos de
  - **Limiarização**
  - Agrupamento

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.

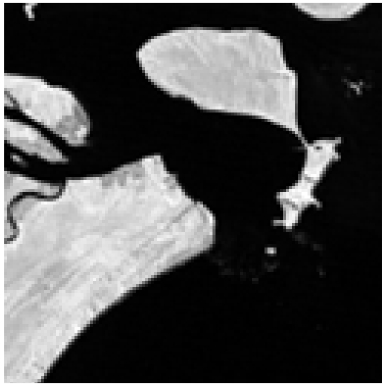

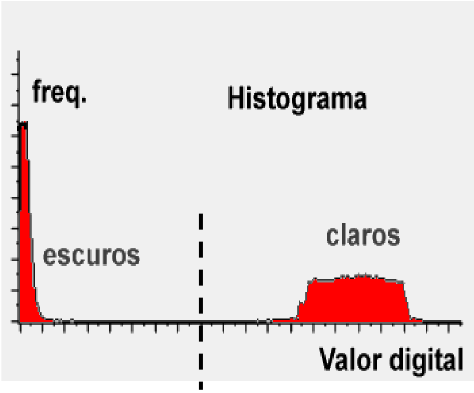

Detectar limiar no Histograma

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

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

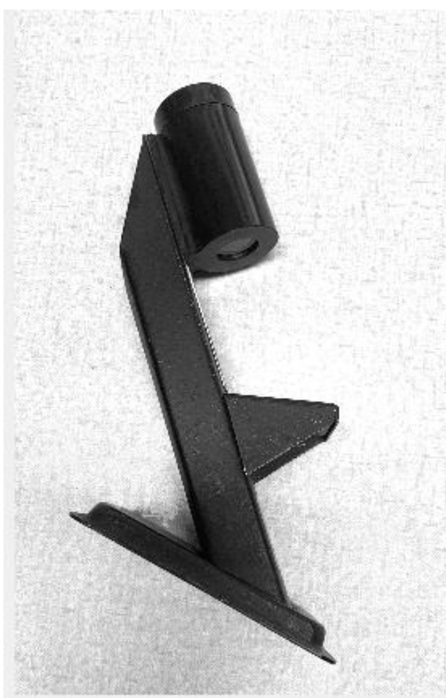

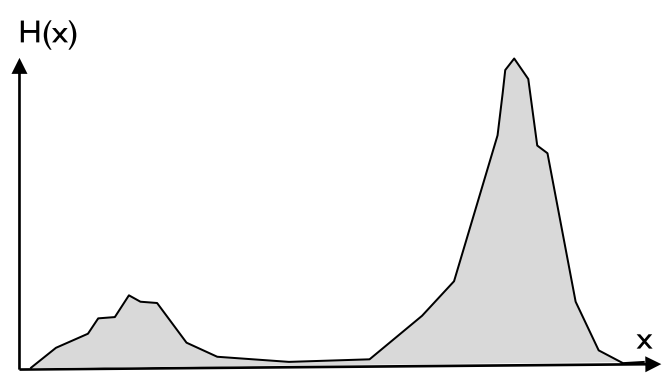

Método do envoltório

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

Este vale pode ser detectado com ajuda do envoltório convexo de H(x)

Que é a menor função que:

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

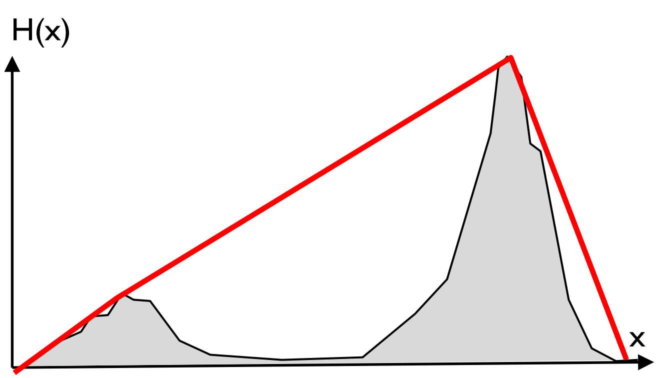

Diferença Convexa

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.

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)

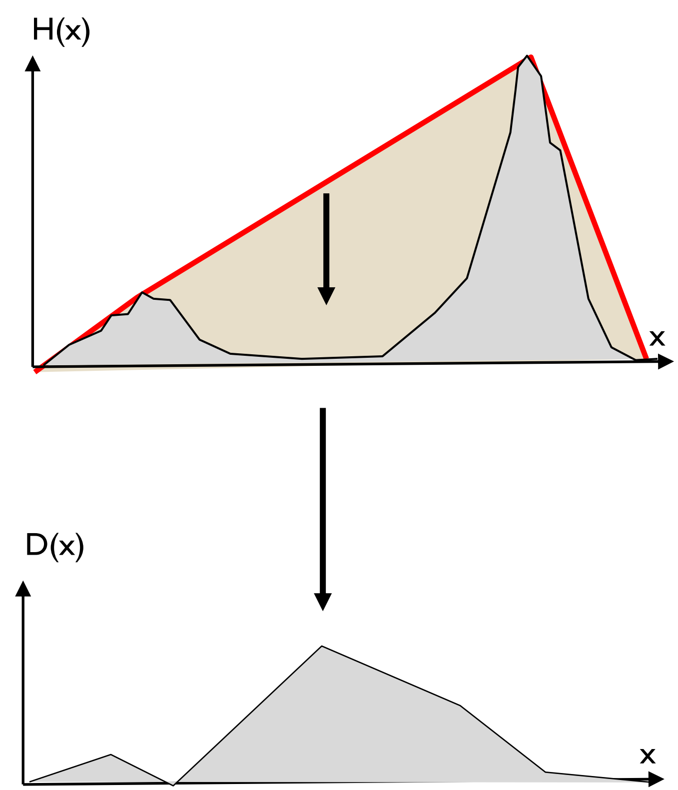

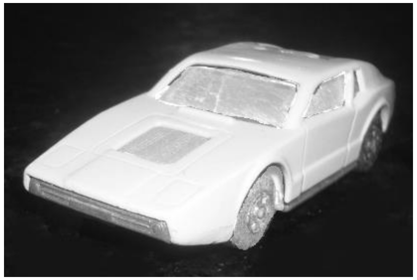

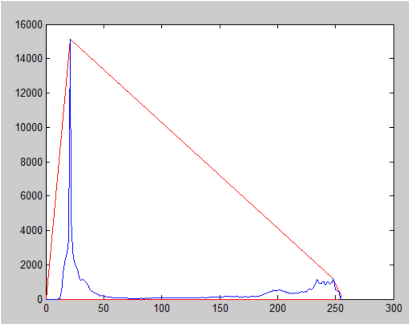

Na prática, o Histograma pode ter picos muito diferentes em altura, o que pode prejudicar a detecção do Limiar.

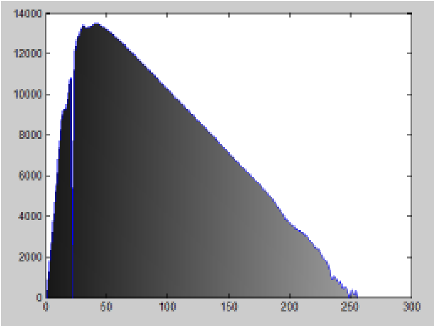

Por isso, usa-se a transformação logarítmica do histograma.

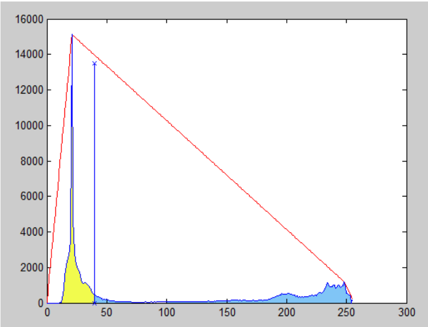

Exponential Convex Hull

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

h1(x)=*log*(h(x))

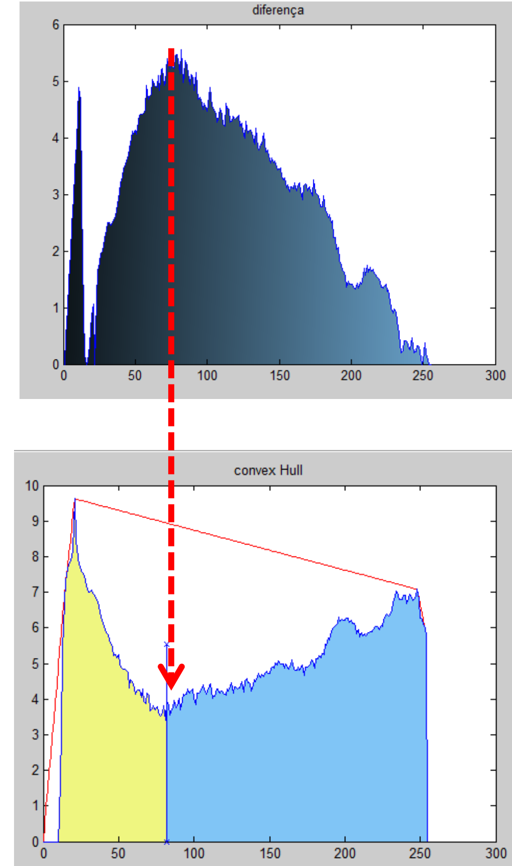

limiar

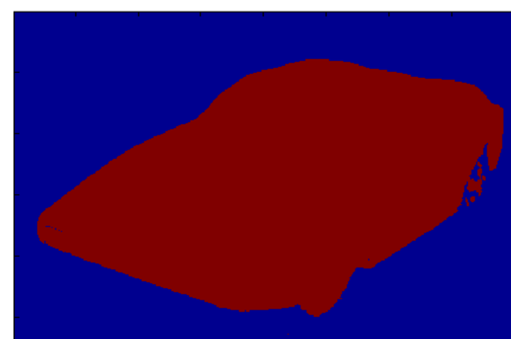

OTSU

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,……255 (*pode ser outro valor máximo)

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

N = número total de pixels na imagem

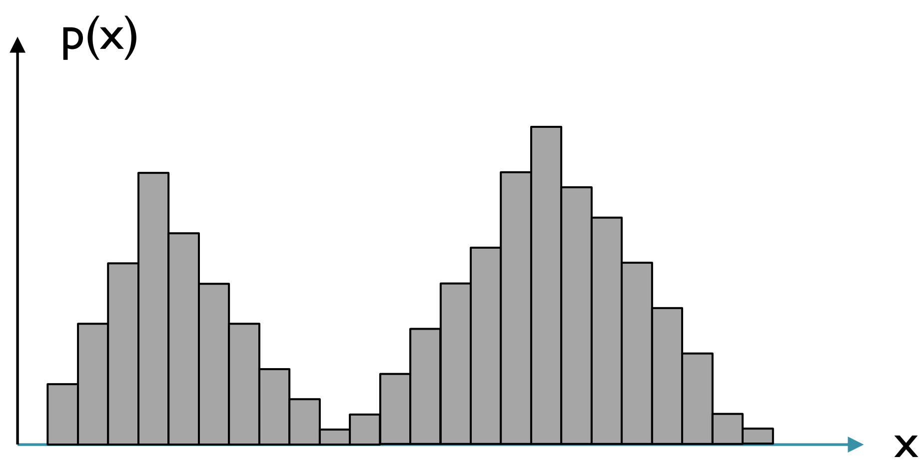

OTSU

O valor ideal para separar duas classes, o Limiar (T) deve ser tal que se formem dois conjuntos:

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

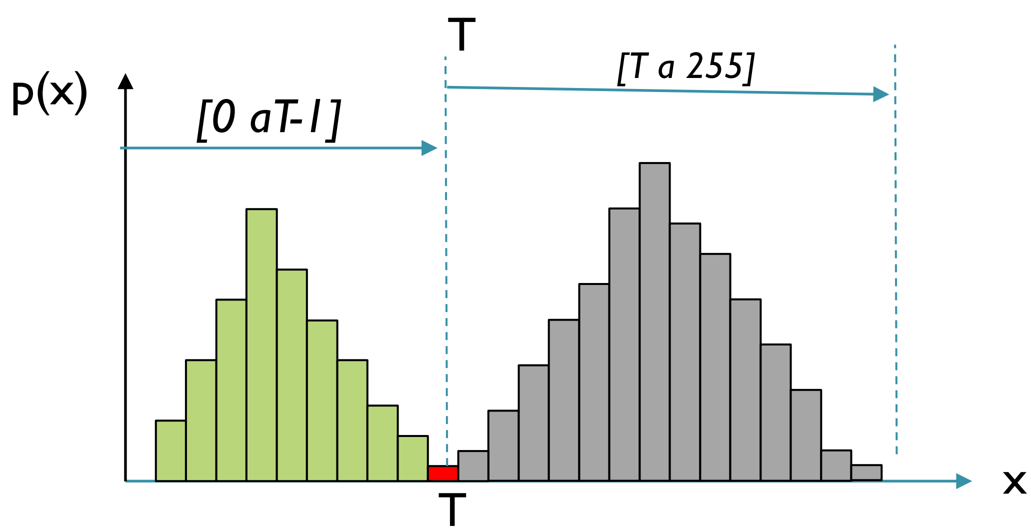

Cada grupo é descrito por:

soma das probabilidades das classes , a área de cada grupo (w)

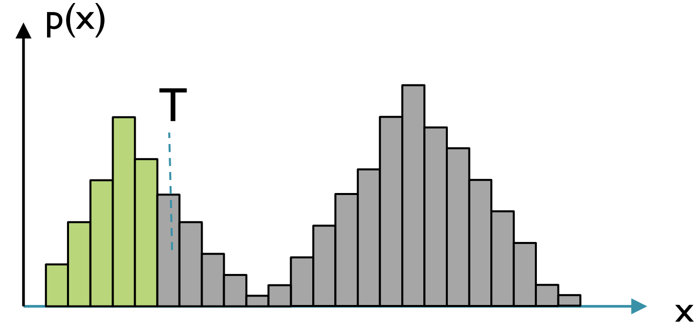

- valor x médio (m)
- Sua variância (S)

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

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

$$m_1 = \sum_{0}^{T-1} x * p\,(x)/w_1$$

$$m_2 = \sum_{T}^{255} x * p\,(x)/w_1$$

$$S_1 = \sum_{0}^{T-1} (x - m_1)^2 * p\,(x)/w_1$$

$$S_2 = \sum_{T}^{255} (x - m_1)^2 * p\,(x)/w_2$$

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

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

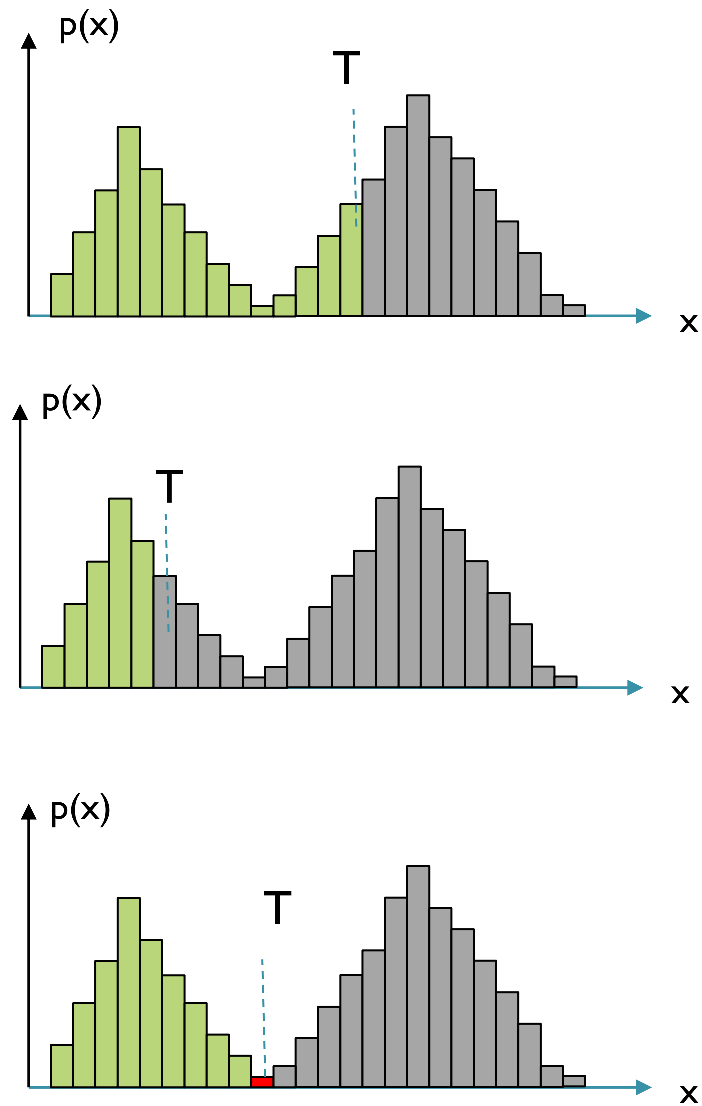

Variância (S) mínima

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):

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

$$w_1(T) = \sum_{0}^{T-1} p(x)$$

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

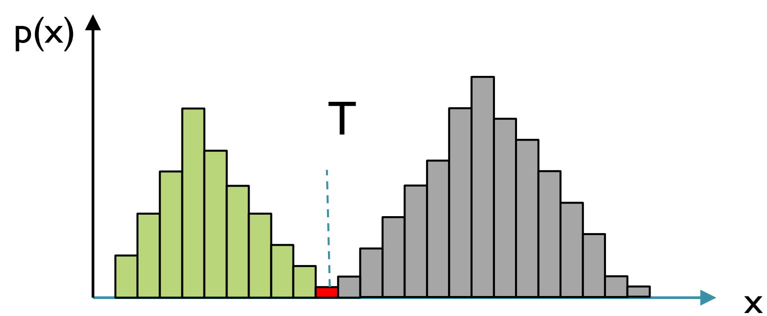

Minimizar a variância dentro das classes equivale a

Maximizar a variância entre classes:

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

Que pode ser calculada com ajuda da distância das médias dos grupos em relação à media 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...

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

OTSU

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

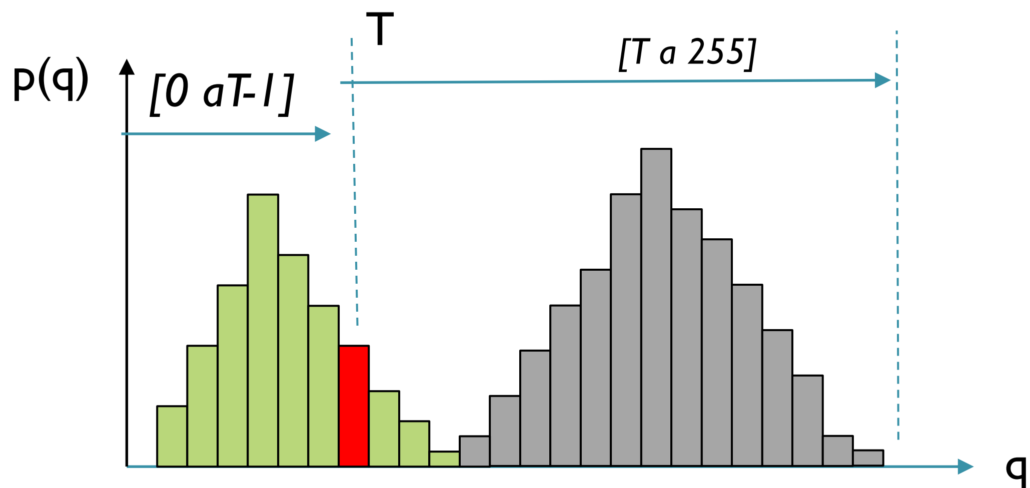

Consulte:Otsu N.,"*A Threshold Selection Method from Gray-level Histograms*", IEEE Transactions on Systems, Man and Cybernetics, v. SMC 9, no 1, pp.62-66, 1979.