



PDI

Segmentação

UFPR – Departamento de Geomática
Prof. Jorge Centeno
2021
copyright@centenet

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 escuros, o histograma será bimodal.

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



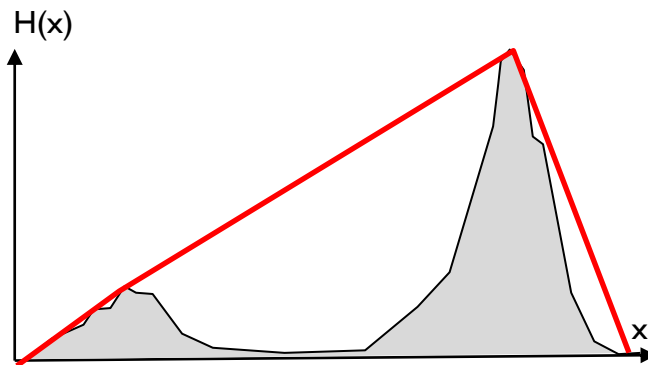
Método do envoltório

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.



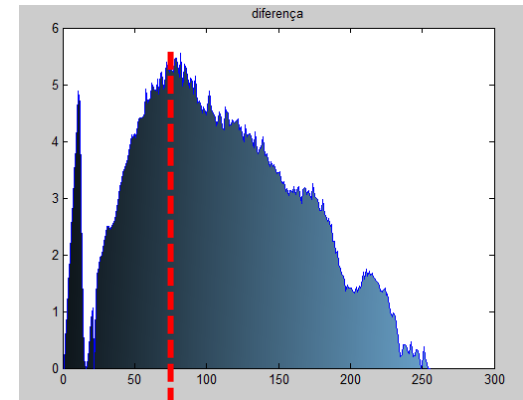
Por isso, usa-se a transformação logarítmica do histograma.



Exponential Convex Hull

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

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





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



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)



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

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

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

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

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

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

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

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



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:

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

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.