



PDI

Limiarização de imagens

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

Segmentação Global

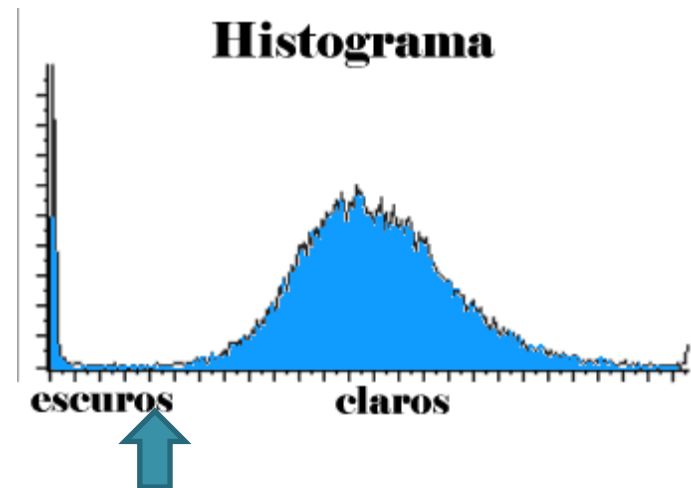

- Os métodos de segmentação global analisam a variação dos valores digitais presentes em toda a imagem e tentam formar grupos, partindo da hipótese de que os objetos na imagem aparecem de forma uniforme em termos de cor.
- São exemplos os métodos de
 - Limiarização
 - Agrupamento

Problema

Em imagens de satélite, objetos podem ser mapeados e delimitados por processos de classificação. Porém nem sempre é necessário usar várias bandas espectrais ou usar amostras para classificar certos objetos.

Considere a imagem do infravermelho ao lado, onde os lagos aparecem bem escuros contrastando com outros objetos.

É possível escolher um limiar que permita separar lagos (escuros) de outros objetos (claros), com base na análise do histograma?



Limiar = Por aqui




Limiarização

Escolher um limiar “a mão” pode ser subjetivo e ainda seria necessário analisar cada imagem que se deseje processar.

O resultado é uma imagem binária, pixels claros vs pixels escuros (0 ou 1)

Objeto vs fundo (0 ou 1)





```
If NC < LIMIAR  
    pixel=1;  
Else  
    pixel=0;  
end
```



Limiarização

Este limiar pode ser selecionado automaticamente.

A vantagem é que o limiar é calculado com base no histograma e um valor pode ser selecionado para cada imagem, o que permite considerar problemas de contraste.



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.



Análise do histograma

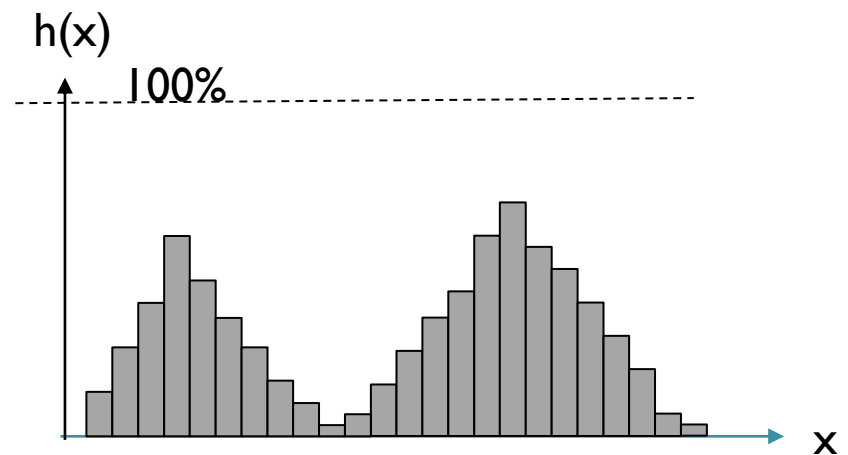

O histograma representa a frequência dos valores digitais na imagem. Para isto pode-se contar quantas vezes cada valor digital ocorre na imagem.

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

Ou podemos normalizar o histograma para levar em consideração o tamanho da imagem:

Total de pixels na imagem: $N = N_{lin} * N_{col}$

$$h(q) = n(x) / N$$




Método de OTSU

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

$$p(x) = \frac{n(x)}{N}$$

Esta função descreve a probabilidade de encontrar um determinado valor digital na imagem.



OTSU

Para separar duas classes, o Limiar ideal (T) deve separar os pixels em dois conjuntos:

- A = pixels com valores abaixo do Limiar, entre [0, T-1] e
- B = pixels com valores acima do limiar, entre [T, 255]

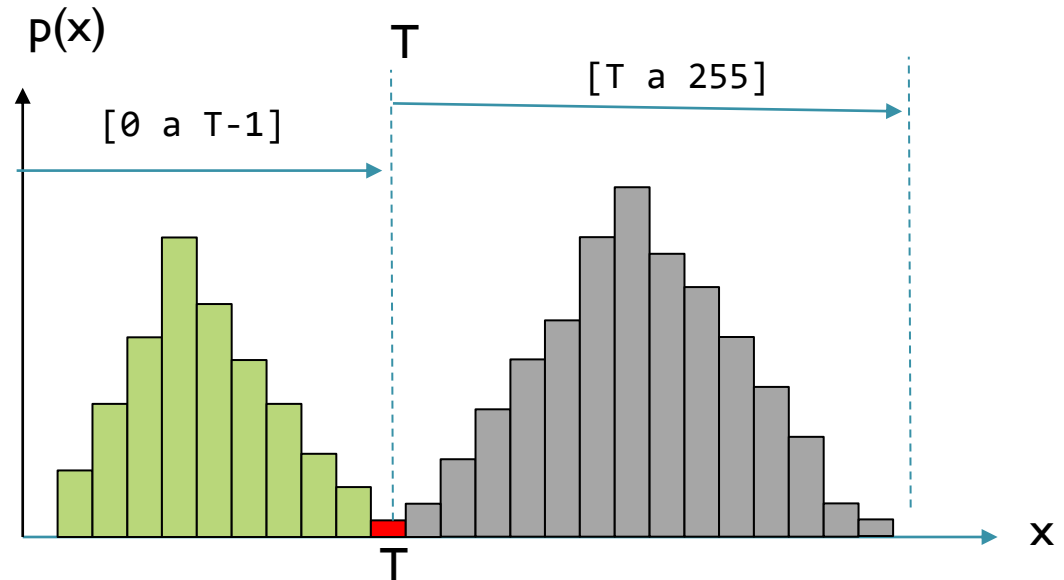
A média destes grupos depende de T e é:

$$m_1 = \frac{\sum_0^{T-1} x p(x)}{\sum_0^{T-1} p(x)}$$

$$m_2 = \frac{\sum_T^{255} x p(x)}{\sum_T^{255} p(x)}$$

Ou

$$m_1 = \frac{\sum_0^{T-1} x p(x)}{w_1}$$
$$m_2 = \frac{\sum_T^{255} x p(x)}{w_2}$$




Descrição dos grupos

Supondo que existam dois grupos de pixels: claros e escuros, cada grupo pode ser descrito por

- sua média “ m_1 e m_2 ”
- e sua variância “ S_1^2 S_2^2 ”.

$$S^2 = \frac{\sum_x (x - m)^2}{n}$$

O limiar ideal separa os pixels em os dois grupos uniformes, ou seja, a variância dos dois grupos será baixa.



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

$$S^2 = peso_1 S_1^2 + peso_2 S_2^2$$

Onde $peso_1$ e $peso_2$ são fatores de ponderação que dependem do limiar “ T ”


Escolha do Limiar

Como “peso”, usa-se a soma das probabilidades das classes (ou o total de pixels em cada classe n_1 n_2):

$$w_1 = \sum_0^{T-1} p(x) \qquad w_2 = \sum_T^{255} p(x)$$

Com isso, a variância total dos dois grupos é:

$$S^2 = w_1 S_1^2 + w_2 S_2^2$$


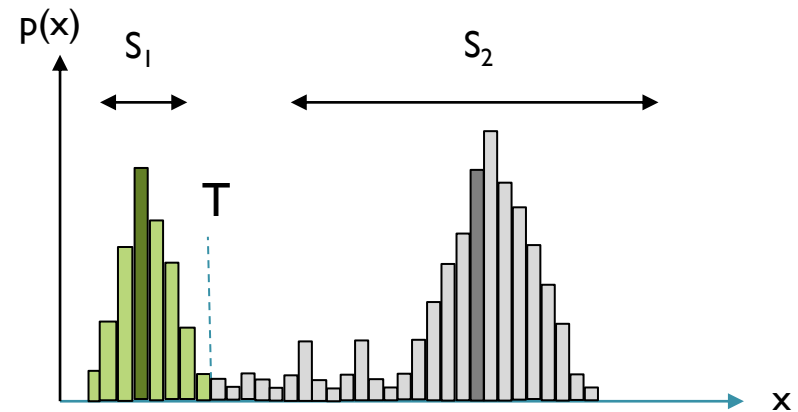


Escolha do Limiar

Se o limiar não for o ideal, um dos grupos pode crescer demais, incluindo pixels do outro grupo.

Como esses pixels estão distantes da média, a variância desse grupo cresce.

Por isso, busca-se o Limiar “T” que minimiza a variância combinada (dentro dos grupos).



Minimizar ou maximizar?

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

$$S_{entre}^2 = S^2 - S_{dentro}^2$$

Que pode ser calculado como:

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

Escolha do Limiar




Para determinar o melhor limiar, varrer todos os valores possíveis de “T” e calcular a variância “entre” grupos

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

E escolher o valor associado ao maior valor desta variância.

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.



Exemplos:


Original Image



Binary



<https://gis.stackexchange.com/>



Kel N. Markert et al (2020)



George E. Meyer & Joao Camargo Neto (2008)



Agrupamento (Clustering)


Agrupamento

- O método consiste em identificar nos dados grupos de pixels similares.
- Cada grupo é descrito por seu vetor de médias. Estas médias são a princípio desconhecidas e devem ser achadas.
- As médias devem ser tais que:
 - Os pixels de um mesmo grupos sejam similares entre si;
 - Pixels de grupos diferentes sejam diferentes;
- Geralmente não se conhece *a priori* o número de grupos que existem na imagem.




Pergunta:

Quantos grupos de pixels similares podem ser encontrados nesta imagem?







- Cluster1
- Cluster2
- Cluster3



- Cluster1
- Cluster2
- Cluster3
- Cluster4
- Cluster5
- Cluster6



- Cluster1
- Cluster2
- Cluster3
- Cluster4
- Cluster5
- Cluster6
- Cluster7
- Cluster8
- Cluster9




Similaridade

Como medida de similaridade pode ser usada a distância Euclidiana. Ela é calculada a partir da diferença entre a média da classe " $m_{k,b}$ " e o valor do pixel (x), em cada banda.

$$D(x, C_K) = \sqrt{\sum_{b=1}^{nBandas} (x_b - m_{k,b})^2}$$




Onde $m_{k,b}$ é a média do grupo "k" na banda "b".

So os valores do pixel forem muito parecidos aos valores da média de um grupo, podemos dizer que este pixel se parece com o grupo.



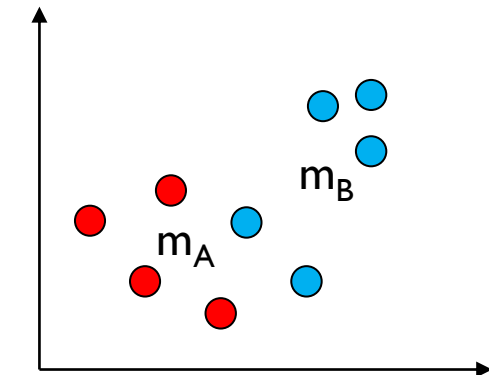
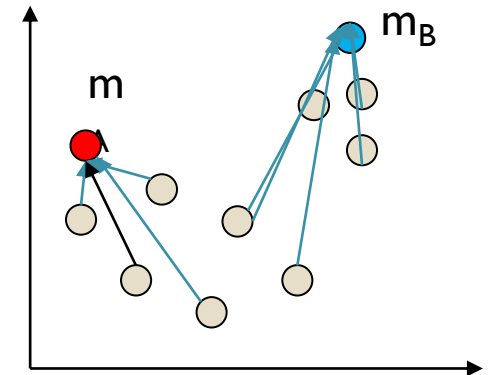

K-Means Clustering

- Como não se conhece os centros dos grupos, a busca da solução é iterativa.
- Para começar, escolhe-se k centros (de maneira aleatória), um para cada grupo (clusters).
- Com base na distância Euclidiana, verifica-se qual centro está mais próximo de cada pixel e assim se classificam os pixels. Isto associa cada pixel ao grupo mais próximo.
- Como isto definiu os grupos, recalcula-se os verdadeiros centroides, pois já é conhecido quais pixels pertencem a cada grupo.
- Se houver diferença entre o centro (*chute*) inicial e o centro calculado, deve-se repetir o processo até atingir o centro verdadeiro. Mas desta vez, usando os novos centros calculados.




Algoritmo *k*-Means

1. Determinar os centróides (aleatoriamente? De forma sistemática?)
2. Atribuir a cada objeto do grupo o centróide mais próximo.
3. Após atribuir um centróide a cada objeto, recalcular os centróides.
4. Repetir os passos 2 e 3 até que os centróides não sejam modificados.



k-Means – Exemplo



Como iniciar

Poderíamos iniciar escolhendo centros de forma aleatória.

Ou ao longo da diagonal principal.




Ou usando a direção do primeiro autovetor

Uma escolha aleatória seria...

$$C1 = [150 \quad 50]$$

$$C2 = [100 \quad 10]$$

$$C3 = [150 \quad 150]$$



$$T = I$$

Inicie escolhendo centros arbitrários...

$C1 = [150 \ 50]$

$C2 = [100 \ 10]$


$C3 = [150 \ 150]$

Classifique a imagem, ou seja, veja com qual centro cada pixel se parece. Isto formará os grupos.

Calcule os novos centros e

Verifique se os centros mudaram de posição

Ex: medindo a distancia total entre os centros.



Iteração	distância
1	110.4


$t=2$

Se os centros dos grupos são diferentes dos anteriores, adote estes novos centros.

Note como os centros já são uma boa estimativa.


Classifique a imagem, Isto mudará os grupos.

Calcule os novos centros e
Verifique se os centros mudaram de posição



T=3


Repita o processo...
Até que os centros
não mudem, ou
mudem "muito pouco"



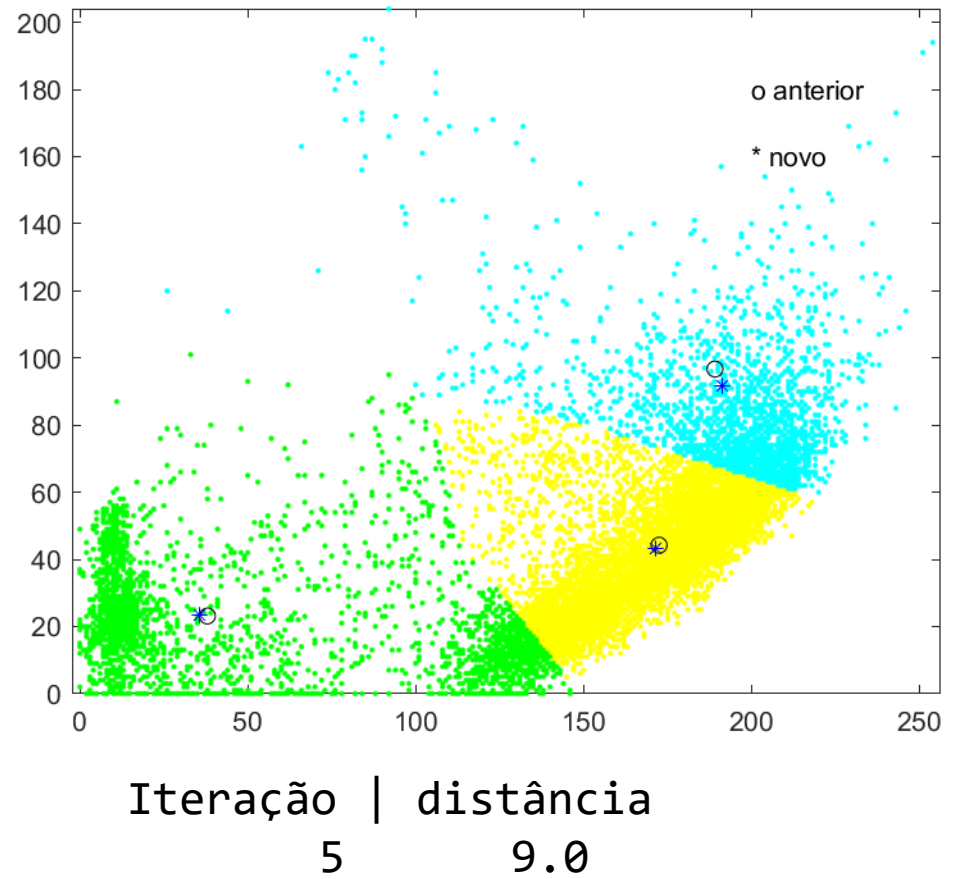
Iteração | distância
3 | 15.2

T=4

Fazer isto até que os novos centros sejam próximos dos anteriores. Cada vez as correções são menores



T=5


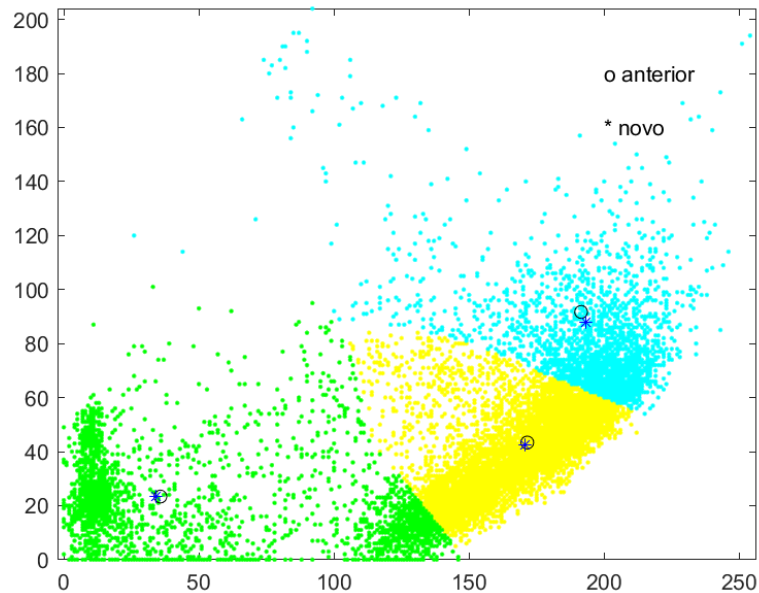


Resumo

soma de distâncias entre centros usados e calculados

Iteração | distância

1	110.4
2	25.6
3	15.2
4	11.3
5	9.0
6	7.1



Resultado
Classificação


Resultado



Banda 1




Banda 2



Resultado (3 grupos)

Para entender os grupos...


- Após o agrupamento, se pode tentar dar significado aos grupos formados.
- Ex: Água
- Se for necessário, se deve repetir o processo com mais grupos, para encontrar os grupos desejados
- Depois... grupos podem ser fundidos



ISODATA

Uma variação do método K-means inclui um último passo, no que grupos muito pequenos são eliminados. Por isso, é necessário estipular qual o menor tamanho de grupo aceitável.

Os grupos muito pequenos são reclassificados em um dos outros grupos maiores.



Faz sentido manter o grupo G3 ?

Ao trabalho!

