



Sensoriamento Remoto: Classificação de imagens

Jorge Centeno - UFPR

Classificação: Por que classificar?



Os valores digitais das imagens são o resultado da interação entre a radiação e os objetos. Por isso, objetos similares apresentam valores digitais parecidos.

Se sabemos que esta é a cidade de Paranaguá na imagem... Que outras áreas urbanas aparecem na imagem?

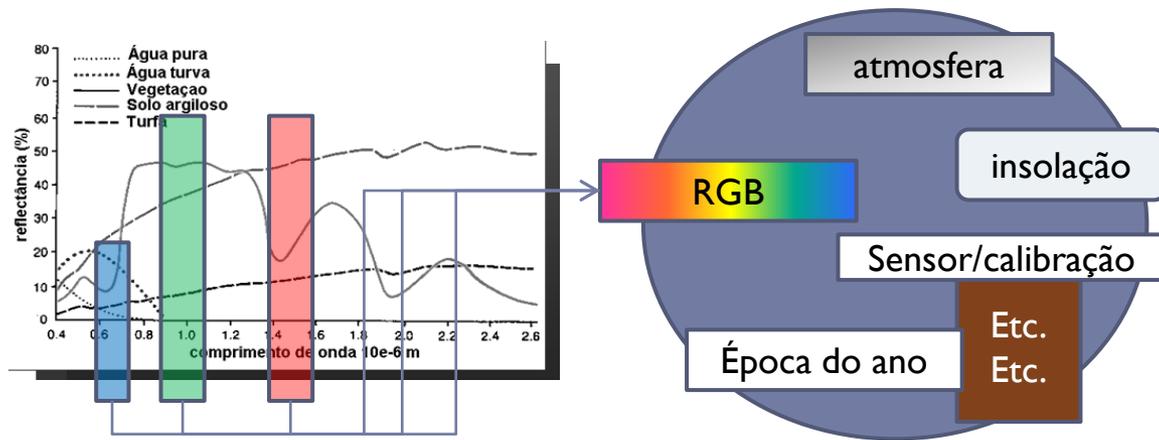
Podemos estimar a área de mangue identificando pixels com características espectrais típicas de mangue?

Para responder tais perguntas, cada pixel deve ser rotulado dentro de uma das prováveis classes. Isto se chama **classificar** os pixels da imagem

classificar

Com base nos conhecimentos do comportamento espectral dos alvos e das características dos sensores usados para a coleta de imagens é esperado que os objetos na superfície da Terra tenham cores (tonalidades) típicas.

Porém, estas cores podem variar em função das condições ambientais.

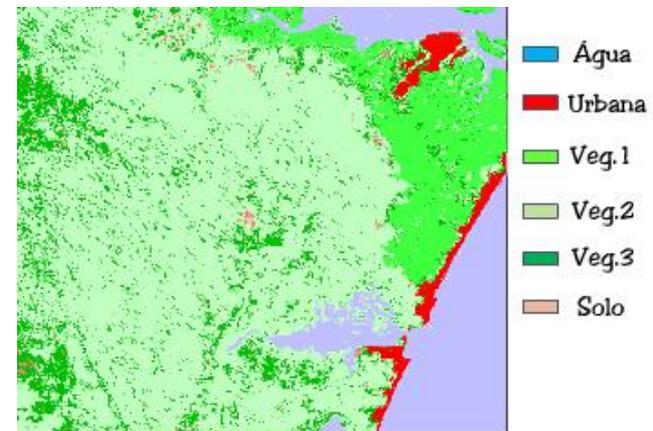


Classificação digital

A partir dos valores do contador digital gerar uma nova imagem, mais simples, onde cada pixel está associado a uma categoria.

Produto final: uma imagem com valores associados às classes. Esta associação é feita através da legenda.

Os produtos são **imagens temáticas**, pois neles a cena é representada por temas ou classes.



Nro.	Nome	Cor no mapa	Nro pixels	Área (km ²)
1	Água	(27, 12, 25)	1.230.500	1107,45
2	Área urbana	(255,100,0,)	456050	410,445
3	Vegetação 1	(64,255,64)	13253	11,9277
4	Vegetação 2	192,255,192)	12455	11,2095
5	Vegetação 3	(8, 195,8)	12445	11,2005
5	Solo nu	(255,128,128)	1124	1,0116

Classificar

Esse problema pode ser resolvido de forma manual, pela análise visual da imagem.

Esta tarefa pode se tediosa e subjetiva. Por isso, a intenção é realizar a tarefa usando programas em computadores, capazes de processar grande quantidade de pixels de forma rápida e sistemática, evitando assim a decisão subjetiva de diferentes operadores humanos.

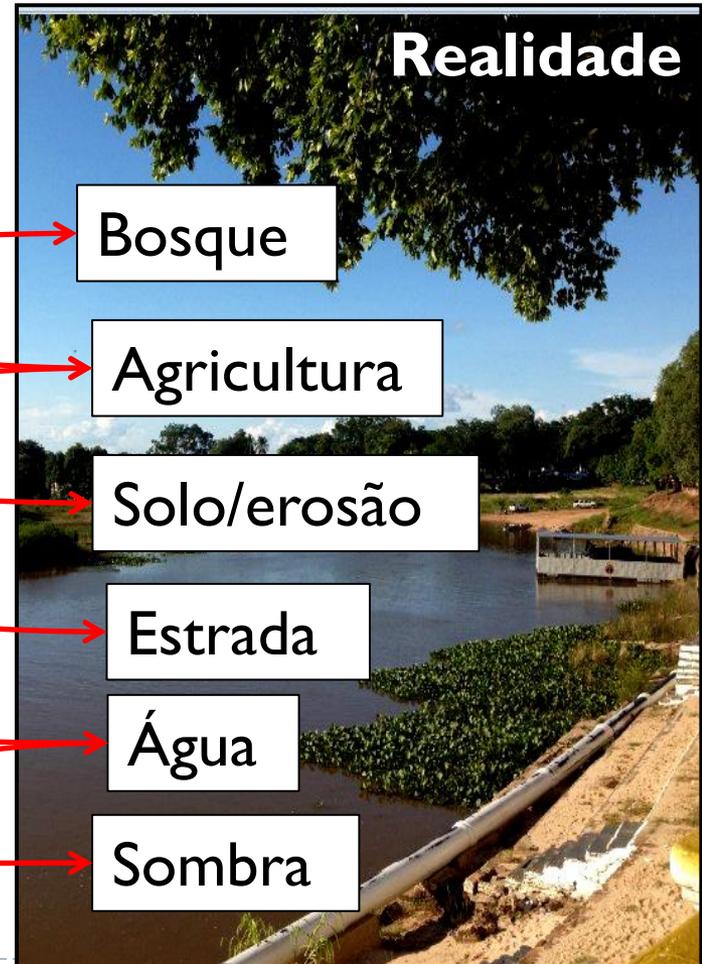
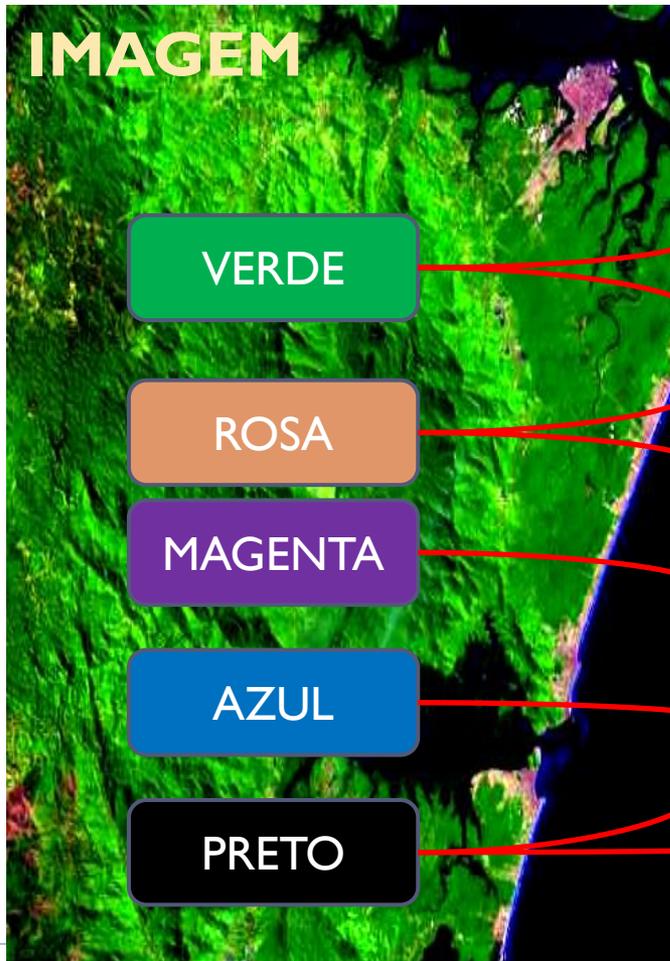




Exemplos de aplicação

- ▶ Cartografia: atualização de mapas;
 - ▶ Hidrologia: estimar cobertura do solo para conhecer potencial de escoamento superficial
 - ▶ Agricultura/Ciências Florestais: Estimar a produção de madeira
 - ▶ Arquitetura/planejamento: monitorar crescimento de cidades
-

Relação Imagem-Realidade



▶ De que cor é a agricultura?



Criar padrões de valores digitais para cada classe e comparar os pixels da imagem com este padrão.

Assim, cada pixel pode ser classificado como membro da classe representada com o padrão mais parecido.



RGB:	R	G	B	
	Agri.1	r1	g1	b1
	Agri.2	r2	g2	b2
	Solo 1	r3	g3	b3
	Solo 2	r4	g4	b4



Este pixel (rgb), com qual classe se parece mais?



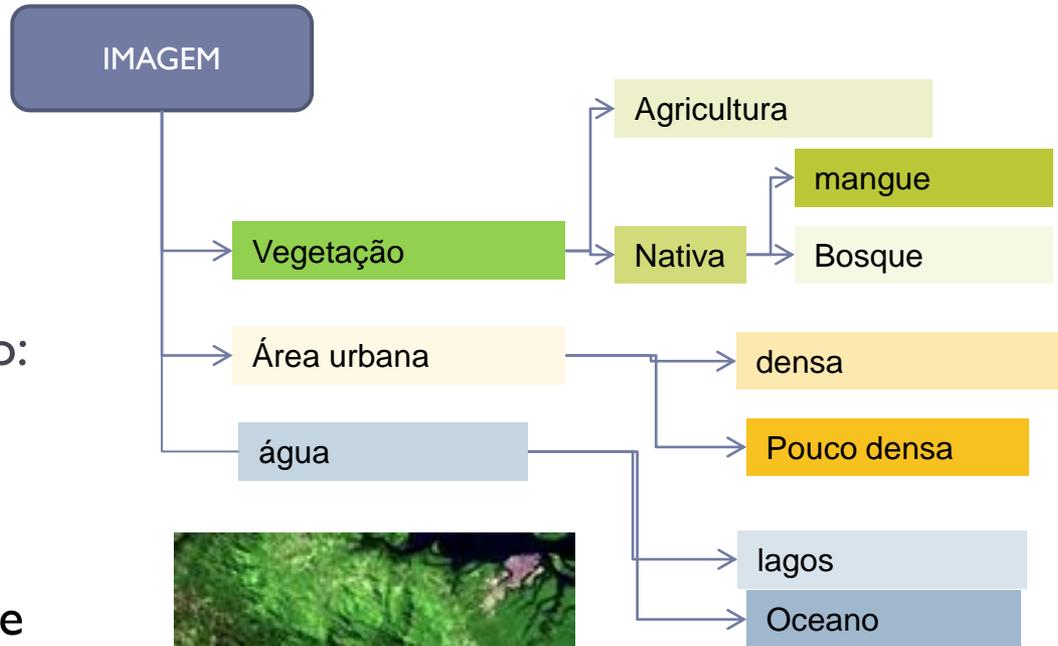
Passos

1. Definir classes de interesse
 2. Definir padrões de valores digitais para cada classe
 1. Calcular parâmetros de cada classe por amostragem
 2. Amostragem manual? Automática?
 3. Avaliar qualidade de amostras
 3. Classificar todos os pixels da imagem
 4. Verificar a qualidade do produto
-

Definição das classes

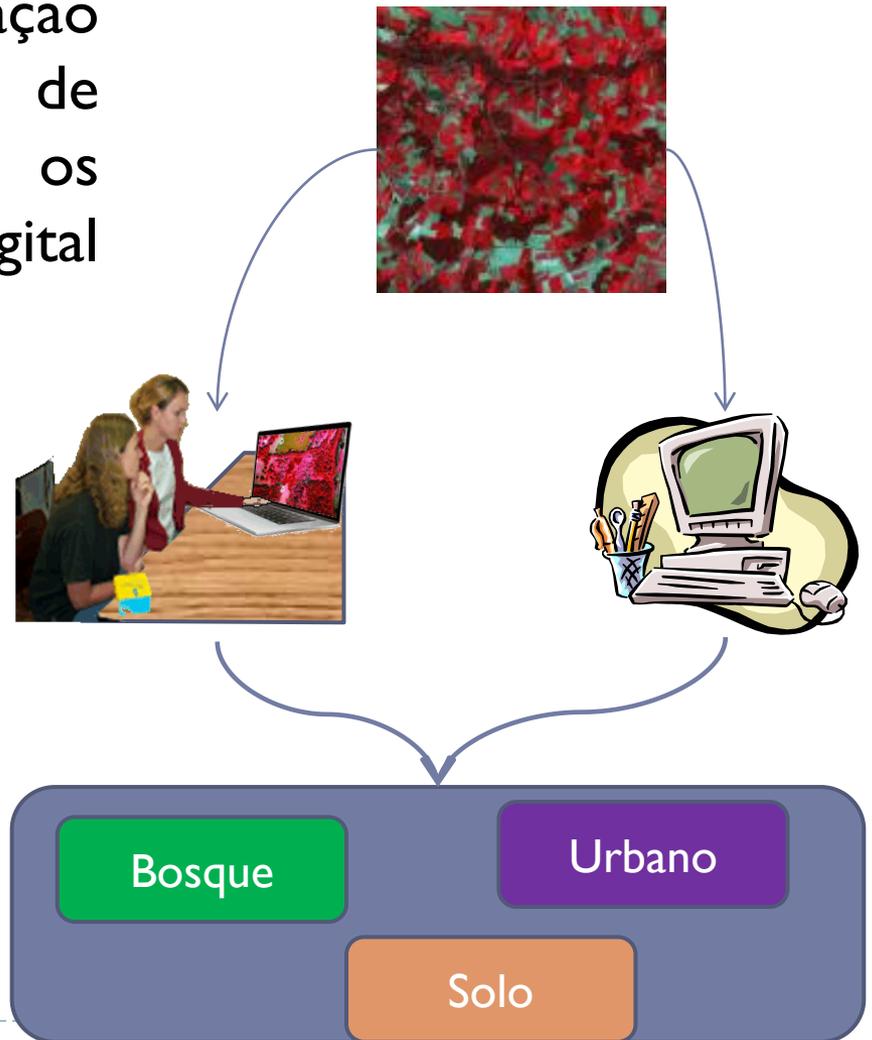
O primeiro passo é dividir os pixels em categorias (classes) de interesse como: floresta, agricultura, água, área urbana

A estrutura e o grau de detalhe das classes depende nas necessidades do usuário e das resoluções da imagem. Além disso, pode ser diferente para cada aplicação



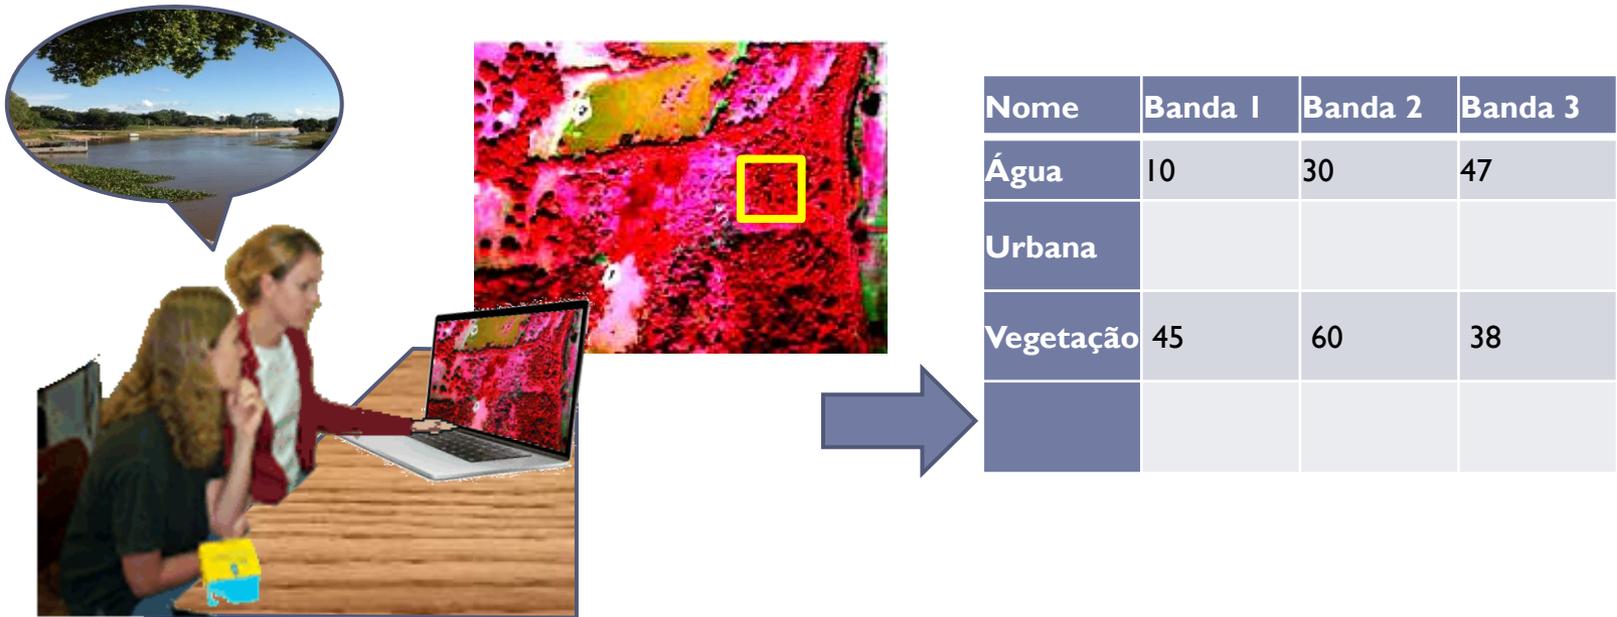
Método Supervisionado ou não

- ▶ Segundo o grau de participação do analista no processo de descrição das classes, os métodos de classificação digital podem ser:
 - ▶ supervisionado e
 - ▶ não supervisionado.



Supervisionado

O usuário contribui com seu conhecimento a respeito da área para definir as classes de interesse. Assim, ele identifica na imagem áreas onde as classes aparecem puras e informa isto ao computador, que, a partir dos valores correspondentes a estas regiões, calcula parâmetros estatísticos para cada classe.



Amostragem manual

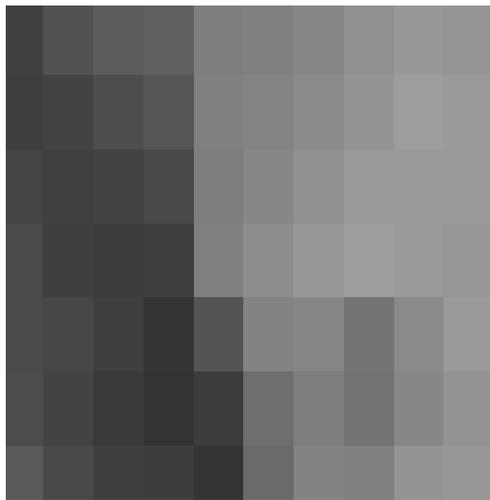
Na amostragem as características das classes são definidas através de amostras (aprendizado).

A amostragem é feita identificando áreas de cobertura conhecida na imagem e demarcando estas regiões com o cursor na tela para que o sistema identifique os pixels que ocupam esta região.

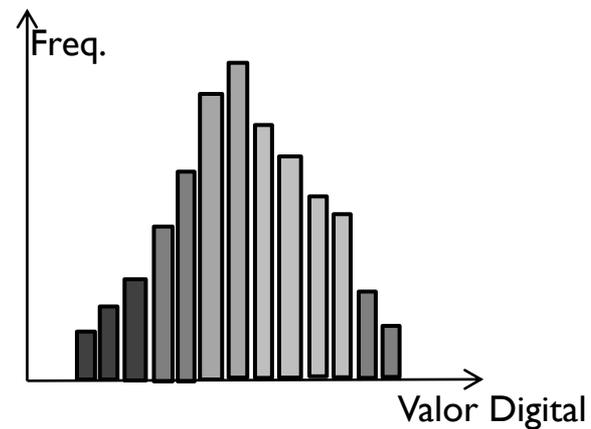
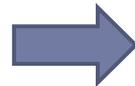


variabilidade

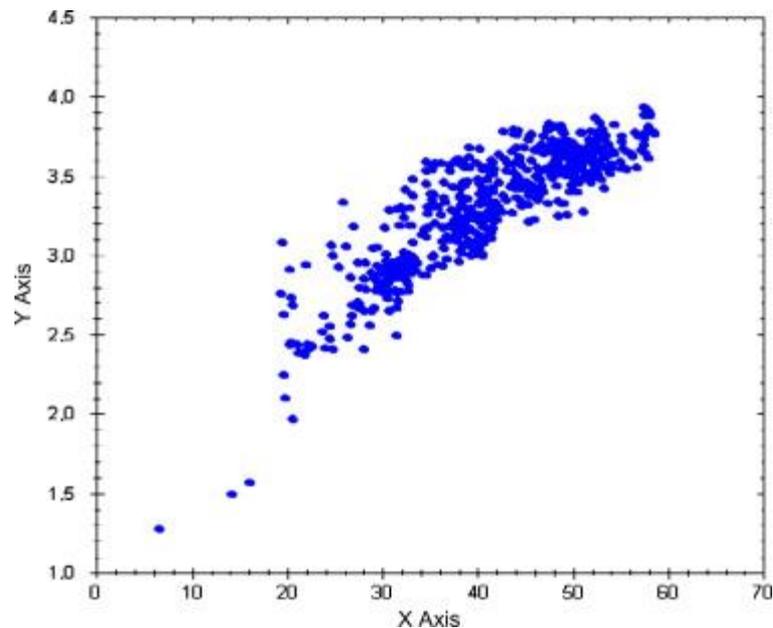
- ▶ Devido à variação dos valores digitais, é esperado que exista uma dispersão dos mesmos dentro da classe.



Uma banda: dimensão=1



▶ Considerando duas (Bandas) dimensões...



▶ E com 7 bandas?

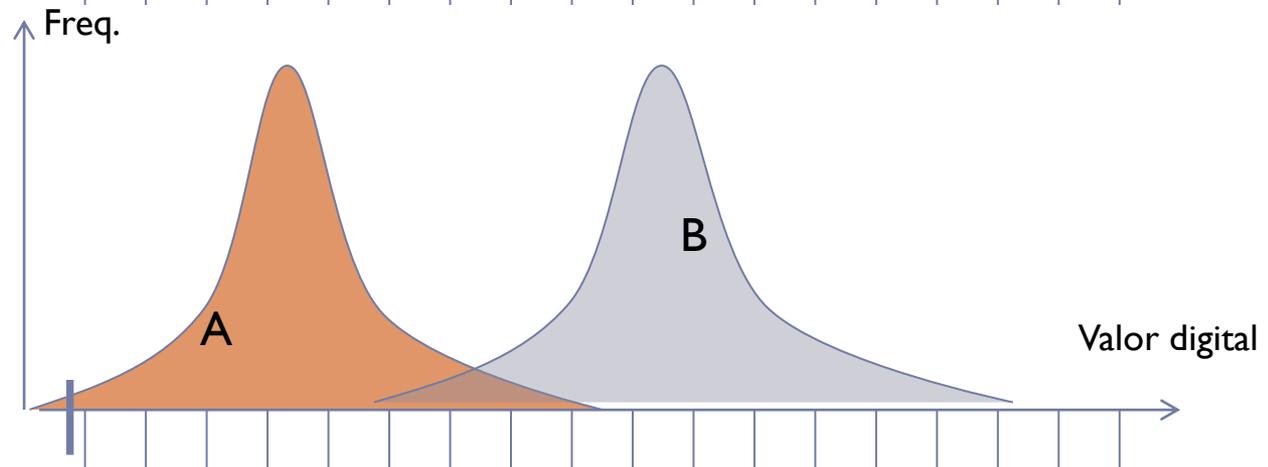
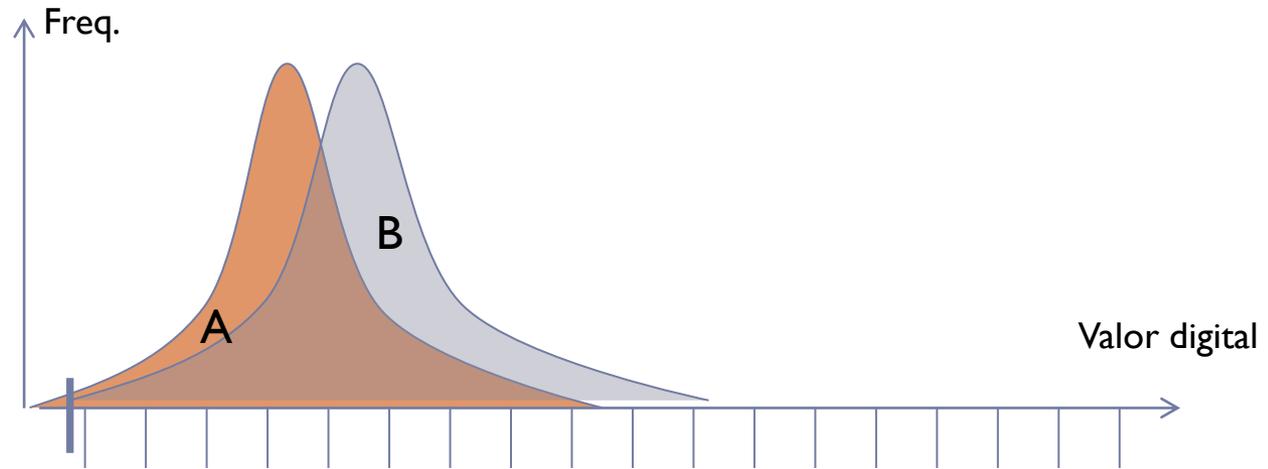
Cuidados

- Regiões em locais onde as classes apareçam puras.
 - Evitar áreas de transição, onde a interpretação é duvidosa.
 - Se for necessário, subclasses podem ser definidas.
 - Usar áreas de treinamento distribuídas ao longo de toda a região pesquisada, procurando cobrir todas as diferentes situações nas quais a classe aparece.
 - O tamanho da amostra deve ser suficientemente grande para descrever adequadamente a classe.
- ▶ Após a seleção das amostras verificar a qualidade da amostragem



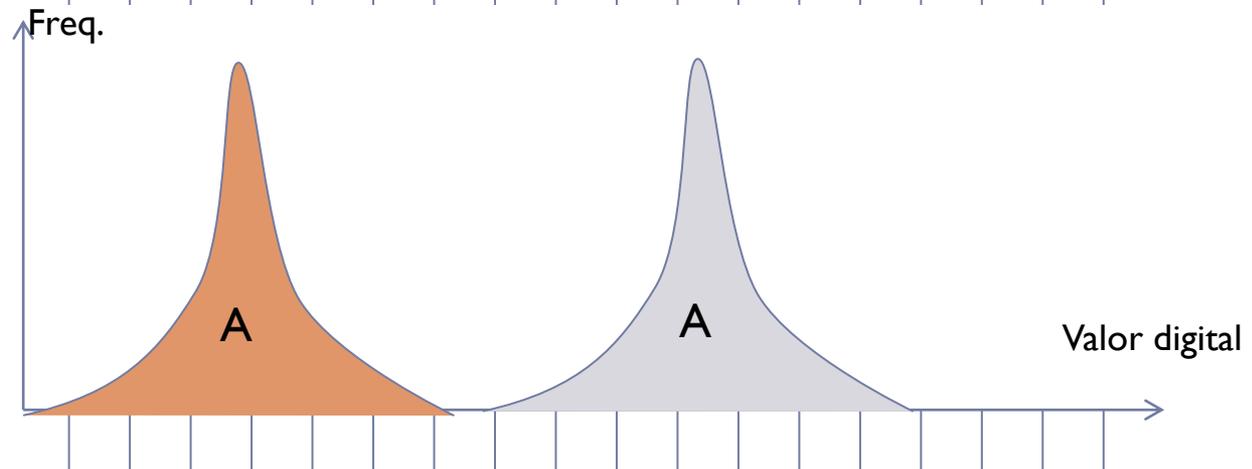
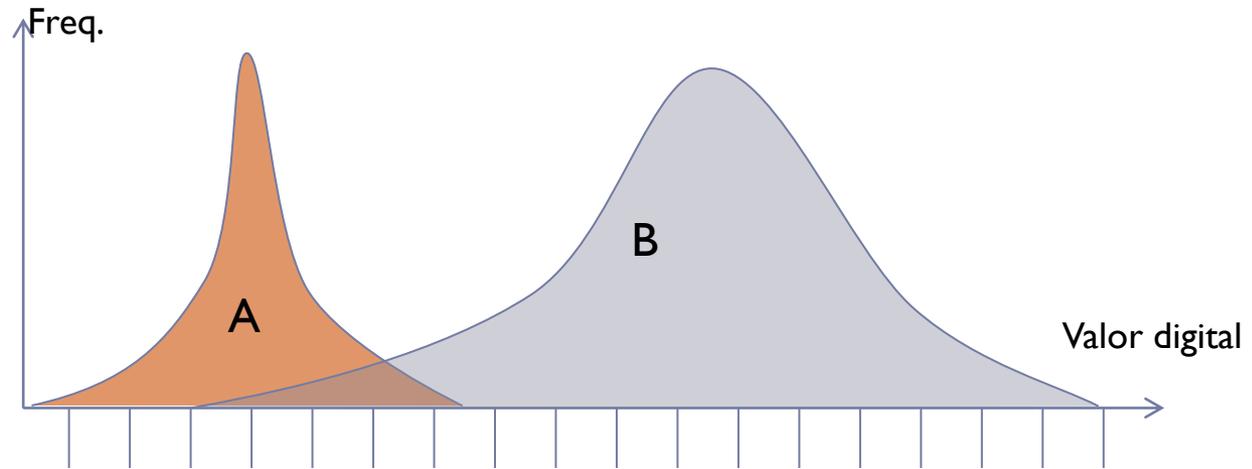
As Classes são separáveis?

- ▶ A médias são próximas?



As Classes são separáveis?

► E as variâncias?



Divergência

- ▶ Utiliza os vetores de médias (m), bem como as matrizes variância-covariância (V) de cada classe, estimadas a partir das amostras. A divergência pode ser entendida como a soma de duas medidas.
 - ▶ $Div(A, B) = \frac{1}{2} \{ P1 + P2 \}$
 - ▶ A primeira, $P1$, é a diferença normalizada entre as matrizes variância-covariância (V).
 - ▶ $P1 = Tr \{ (V_A - V_B) (V_B^{-1} - V_A^{-1}) \}$
 - ▶ A segunda parte, $P2$, leva em consideração a diferença entre os vetores de médias.
 - ▶ $P2 = Tr \{ (V_B^{-1} - V_A^{-1}) (m_A - m_B)(m_A - m_B)^t \}$
 - ▶ Quanto maior o valor da divergência, maior a separabilidade entre classes.
-

Divergência Transformada:

- ▶ Para fins de comparação, a divergência pode ser normalizada a uma faixa de variação determinada.
 - ▶ $DT(A, B) = 2000 [1 - \exp(Div(A, B)/8)]$
 - ▶ Alguns autores consideram que uma separabilidade aceitável é atingida quando os valores da divergência se aproximam de 2000 (Chuvieco [1990]).
-



Classificação

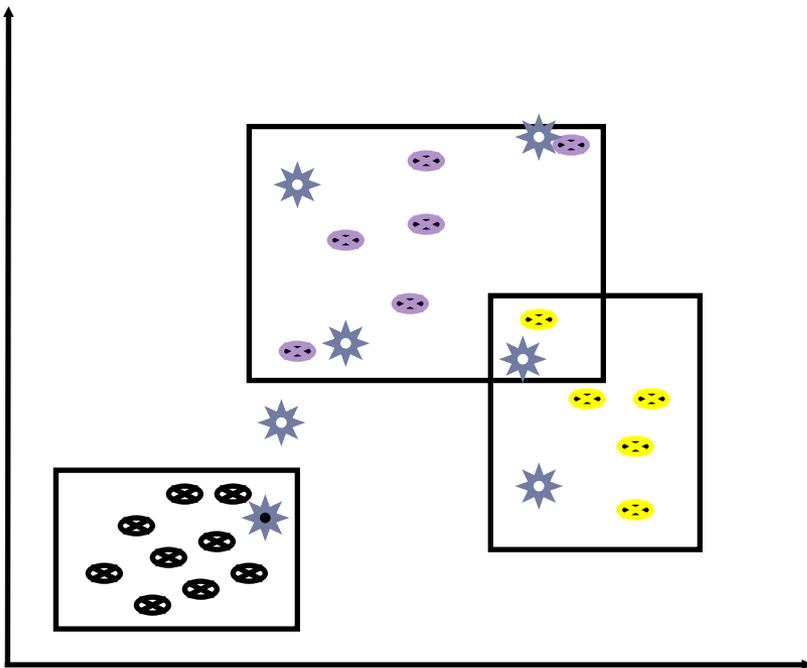
- ▶ Atribuir a cada pixel um rótulo que o identifique como membro de uma das classes, em função de seus valores do contador digital.
 - ▶ A estratégia consiste em classificar o pixel como pertencendo à classe à qual ele mais se aproxime.
 - ▶ Como medir o grau de similaridade entre o pixel e as classes?
 - ▶ Devemos levar em consideração a dispersão?
-



Métodos

- ▶ Hipercubos
 - ▶ Distância Mínima (Euclidiana)
 - ▶ Máxima Verossimilhança Gaussiana
-

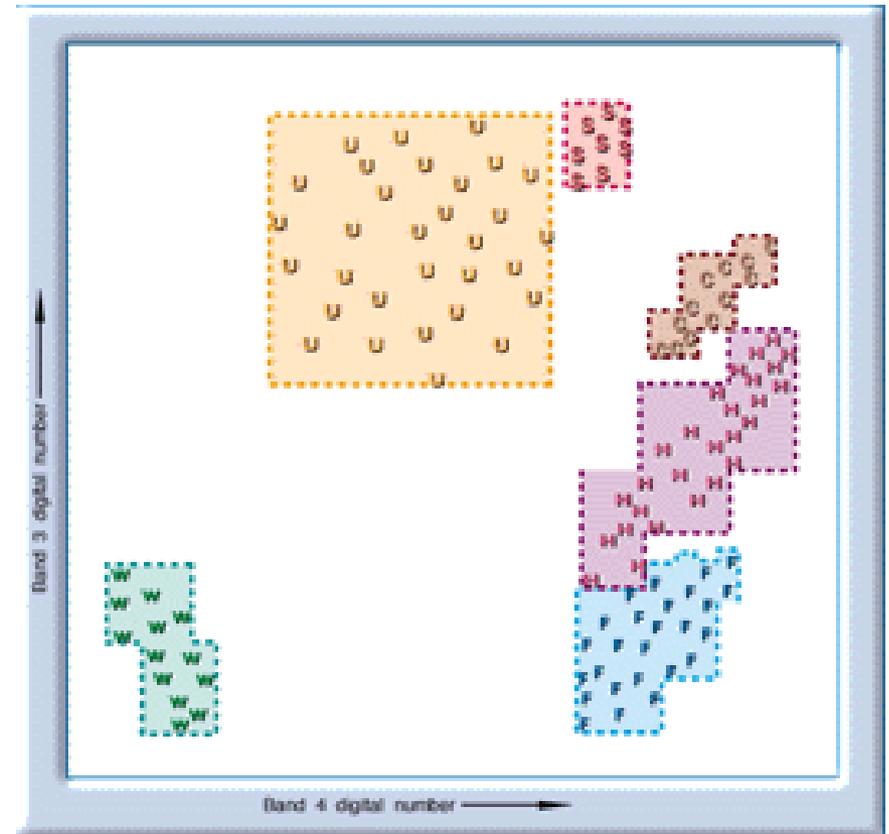
Hipercubos



O espaço multiespectral é dividido demarcando regiões em torno das amostras. Por ex. em função dos valores mínimos e máximos de cada banda dos pixels que formam a amostra.

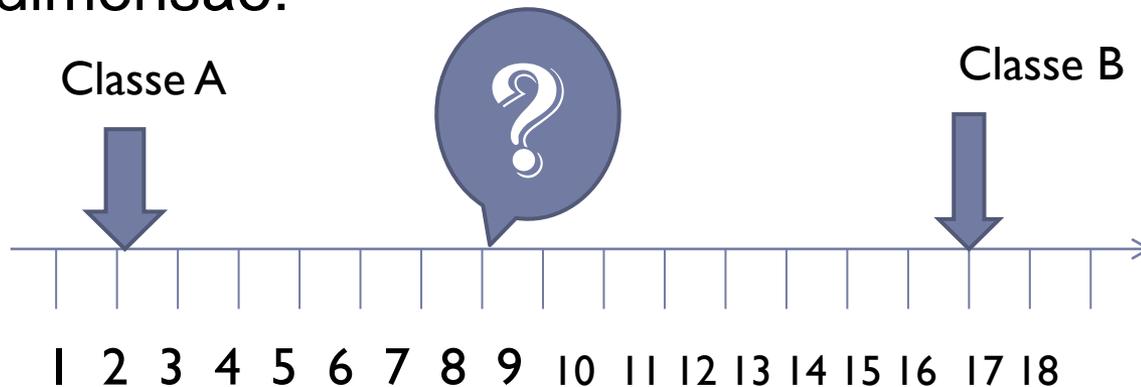
A similaridade, neste caso, é medida em função da posição do pixel em relação aos limites fixados pelo usuário

- ▶ A delimitação das classes, na realidade, é efetuada em várias dimensões, do que deriva o nome hipercubos, paralelepípedos.
- ▶ Mais de um retângulo pode ser usado para uma classe.
- ▶ O operador deve seleccionar os limites entre bandas de acordo com as classes e seu conhecimento da região.



Distância Mínima Euclidiana

- ▶ A Similaridade pode ser medida em função do afastamento (diferença) entre os valores digitais do pixel e de cada classe.
- ▶ Ex: 1 dimensão:

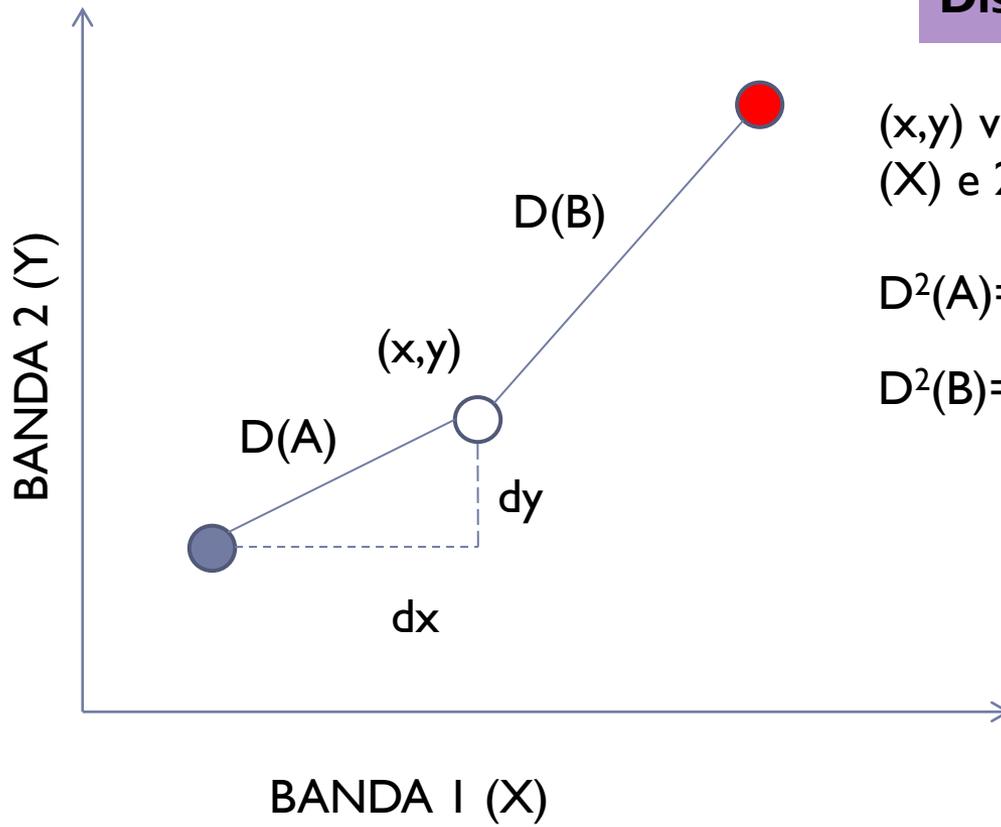


$$D(A) = |8 - 2| = 6$$

$$D(B) = |16 - 8| = 8$$

Classe mais próxima = A, logo, o pixel deve ser da classe A!

Distância para duas bandas



Distância espectral

(x,y) valores do pixel nas bandas 1 (X) e 2 (Y)

$$D^2(A) = (x - m_x(A))^2 + (y - m_y(A))^2$$

$$D^2(B) = (x - m_x(B))^2 + (y - m_y(B))^2$$

Método da distância mínima

Matematicamente, o grau de semelhança entre um pixel “x” e uma classe pode ser expresso usando o conceito de distância Euclidiana. A distância entre o pixel “x” e o vetor de médias da classe “w_i” (m_i) é dada por:



$$D^2(x_j, w_i) = \sum (x_j - m_{ij})^2$$

▶ Onde m_{ij} representa a média da classe “i” na banda “j”

▶ O pixel “x” pertence à classe w_i se:

$$D^2(x_j, w_i) < D^2(x_j, w_j)$$

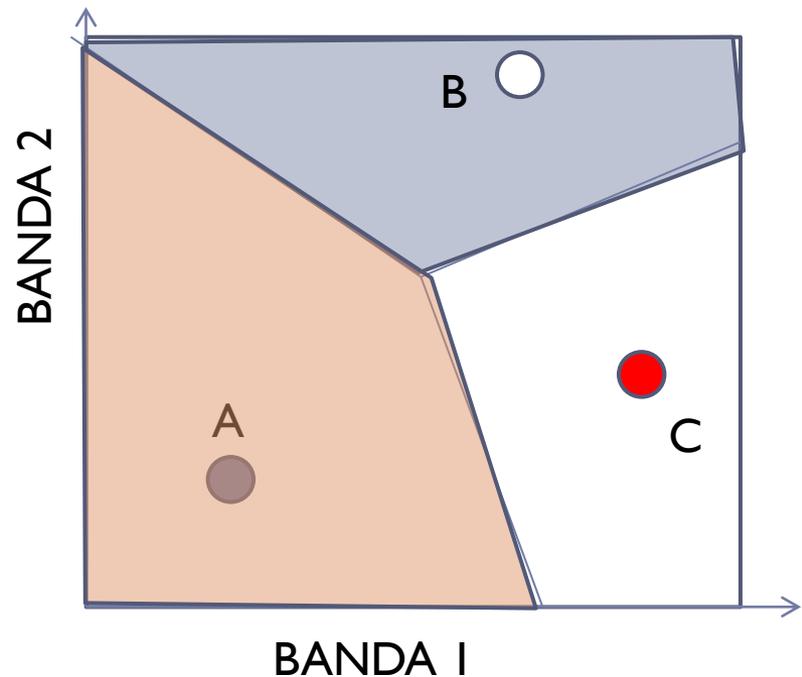
Distância Mínima

▶ Pros

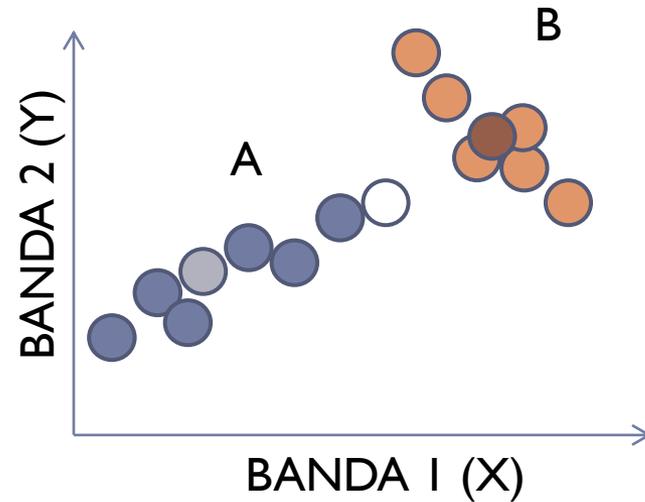
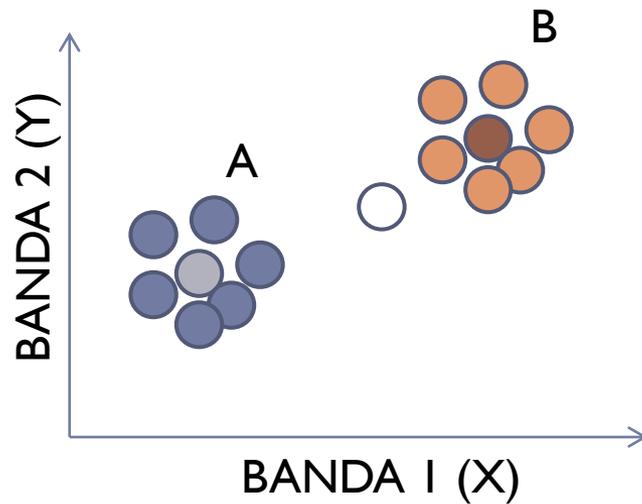
- ▶ Todos os valores possíveis dentro do espaço n-dimensional são classificados
- ▶ Não ocorre superposição de classes
- ▶

Contra

Assume que a variação dos valores digitais é igual em todas as direções, o que nem sempre é verdade



Considere os 2 casos



Qual é a decisão mais correta para classificar o pixel (Ponto Branco) ?



▶ **Máxima Verossimilhança**

Máxima Verossimilhança

Objetivo: Dado um pixel “x” (ou seja, lemos um pixel na imagem e conhecemos seus valores digitais) definir a classe mais provável w_i , dentre um conjunto de classes possíveis:

$$[W = w_1, w_2, \dots, w_n].$$

X pertence à classe W_i se a probabilidade dele pertencer a esta classe é maior que a probabilidade dele pertencer a outra classe qualquer.

Ou seja, atribuir o pixel “x” à classe w_i , se:

$$P(x \in w_i) > P(x \in w_k)$$

Dados os valores do pixel, o pixel pertence à classe “i” cuja probabilidade for maior que qualquer outra probabilidade.



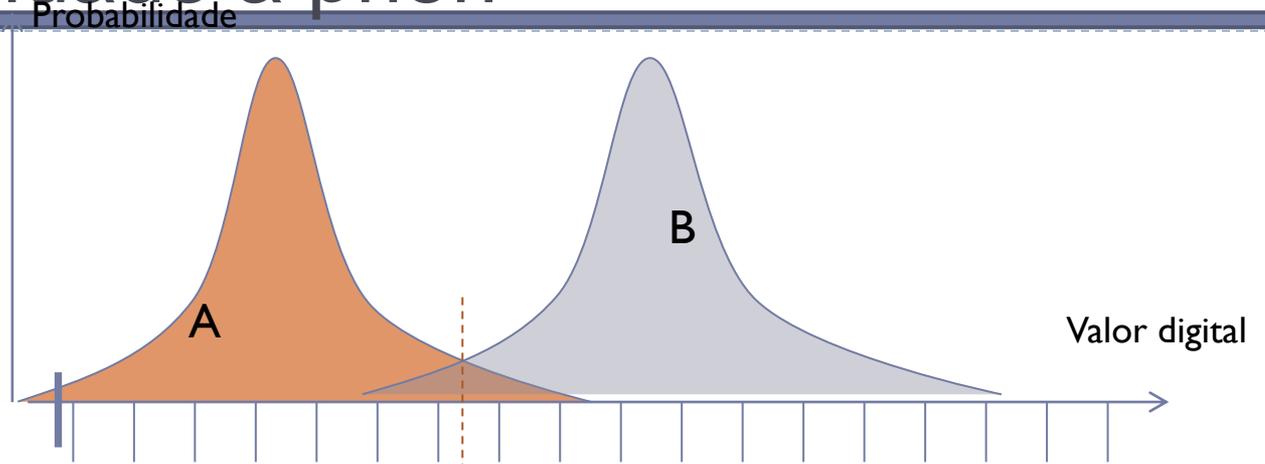
A probabilidade é calculada como:

$$\blacktriangleright P(w/x) = p(x/w) * p(w) / p(x)$$

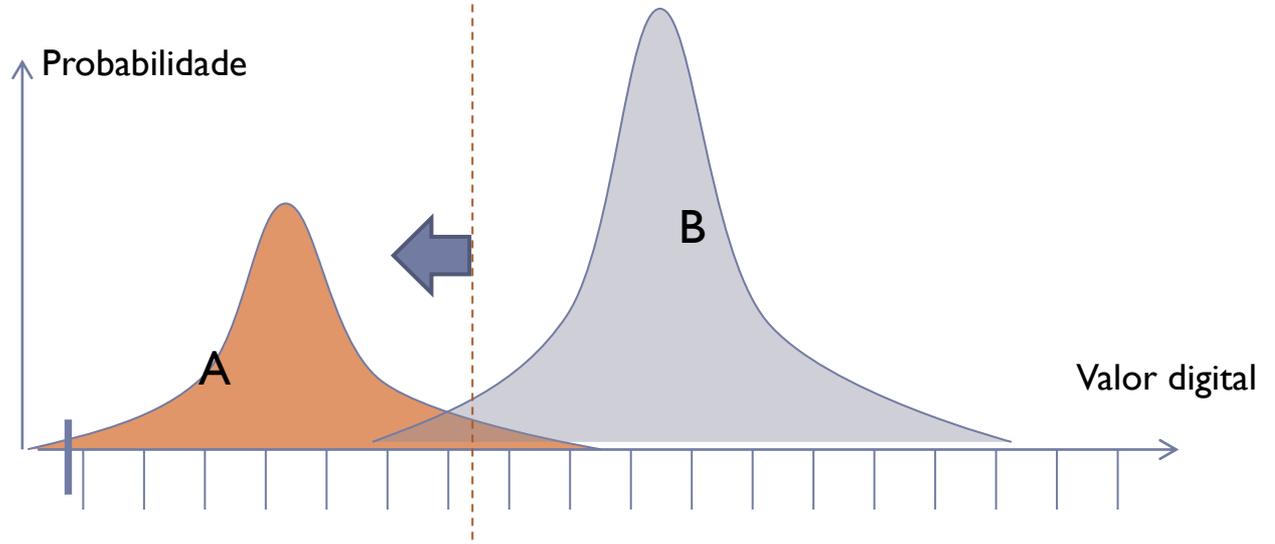
- ▶ $P(x)$: Prob. do pixel “x” ocorrer na imagem. Este valor pode ser negligenciado, porque nas comparações se trata do mesmo pixel.
 - ▶ $P(x/w)$: função densidade de probabilidade da classe “w”. Descreve a variação dos valores digitais dentro de cada classe
 - ▶ $P(w)$: Probabilidade “a priori” da classe. Descreve a frequência relativa das classes. Como a princípio não sabemos quantos pixels de cada classe tem na imagem, pois queremos exatamente classificar a imagem, este valor é mantido constante. Na prática, para não favorecer nenhuma classe, o valor de $p(x)$ é igual para todas as classes.
-

Probabilidade a priori

$P(A)=P(B)$



$P(A) < P(B)$



- 
-
- ▶ Se não vamos considerar a “**probabilidade a priori**” ($p(w_j) = p(w_k) = 1$) e ainda ao comparar as probabilidades do mesmo pixel em relação a duas classes $p(x)$ é igual, a regra de decisão pode ser escrita como:

- ▶ Ou seja, Atribuir o pixel “ x ” à classe w_j , se:

- ▶ $P(x \in w_j) > P(x \in w_k)$

- ▶ $\frac{p(x|w_j)*p(w_j)}{p(x)} > \frac{p(x|w_k)*p(w_k)}{p(x)}$

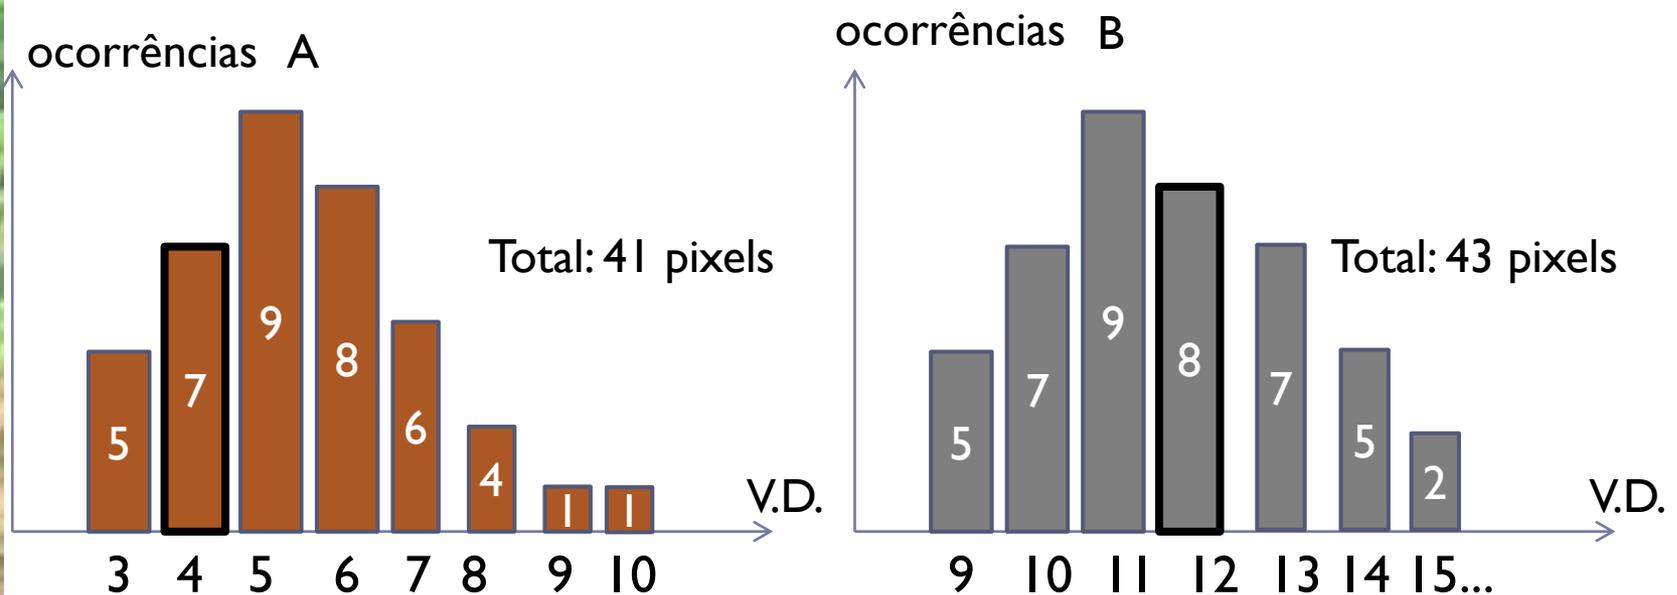
- ▶ Ou seja, Atribuir o pixel “ x ” à classe w_j , se:

- ▶ $p(x|w_i) > p(x|w_k)$

- ▶ Ou seja, apenas a distribuição dos pixels dentro da classe é analisada. Neste caso, não se calcula o verdadeiro valor da probabilidade, mas sim um valor que permite discriminar as classes, por isso se fala em função discriminante.
-

$p(x/w)$ dada uma classe, qual a $prob(x)$?

- ▶ Dado que temos definida a classe, qual a prob. De encontrar um pixel com determinado valor?

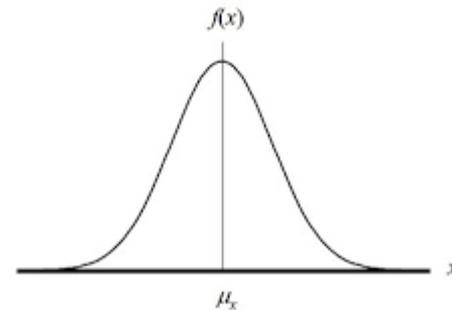


Qual a probabilidade de encontrar um pixel com valor=9 na classe A?
E na B?

$p(x|w)$ = distribuição dos pixels considerando apenas os membros de uma classe "w"

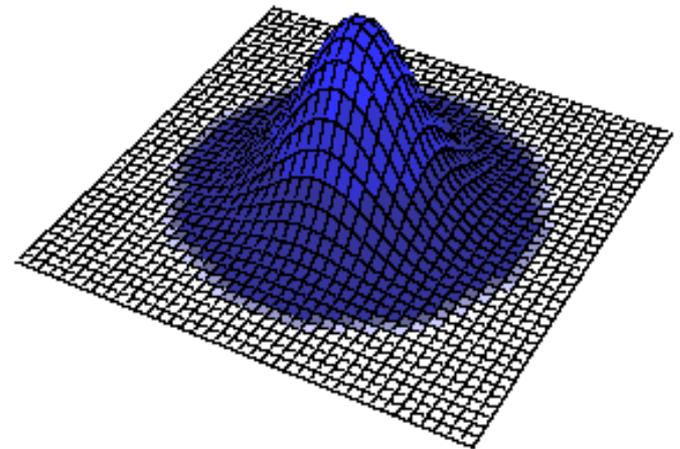
Com base nas amostras de treinamento, uma função pode ser usada para modelar a distribuição dos pixels em cada classe. Na maioria dos casos, as classes seguem uma distribuição Gaussiana, ou Normal, que pode ser descrita, no caso unidimensional, com a média μ e a variância σ (ou desvio padrão).

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-0.5\left(\frac{x-\mu}{\sigma}\right)^2}$$

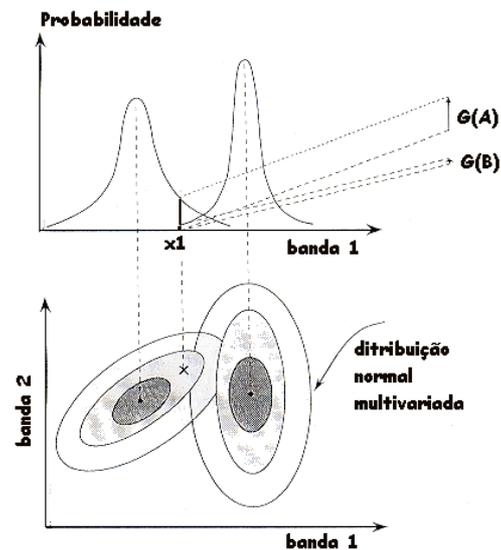


- ▶ No caso multidimensional, o que se encontra geralmente na classificação de várias bandas espectrais em sensoriamento remoto, a expressão muda, substituindo-se a média pelo vetor de médias (m) e a variância pela matriz variância-covariância (C), para considerar a dispersão dos dados em torno da média em todas as bandas. Assim:

$$p(x|w) = \frac{1}{|C|^{1/2}\sqrt{2\pi}} e^{-0.5(x-m)^T C^{-1}(x-m)}$$



- ▶ A inclusão da matriz variância covariância é fundamental para levar em consideração a dispersão dos dados em torno das médias, que pode ser paralela aos eixos, com intensidades diferentes, e apresentar correlação entre bandas.



Regra de decisão

- ▶ Atribuir o pixel “x” à classe w_j , se:

$$P(x \in w_j) > P(x \in w_k)$$

- ▶ onde a probabilidade é calculada como:

$$P(w|x) = p(x|w) * p(w) / p(x)$$

- ▶ $P(x)$: Prob. do pixel “x” ocorrer na imagem;
 - ▶ $P(x|w)$: função densidade de probabilidade da classe “w”
 - ▶ $P(w)$: Probabilidade “a priori” da classe.

 - ▶ Na prática, o valor de $p(x)$ é igual para todas as classes
 - ▶ E como não se conhece a probabilidade “a priori” $p(w)$ um valor igual para todas as classes é usado.
-

processo

Ler um pixel da imagem:
Calcular a classe mais provável para esta
leitura.



$$x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$$

$$p(x \in CA)$$

$$p(x \in CB)$$

$$MA = \begin{bmatrix} m_{A1} \\ m_{A2} \\ m_{A3} \end{bmatrix}$$

$$MB = \begin{bmatrix} m_{B1} \\ m_{B2} \\ m_{B3} \end{bmatrix}$$

Probabilidade

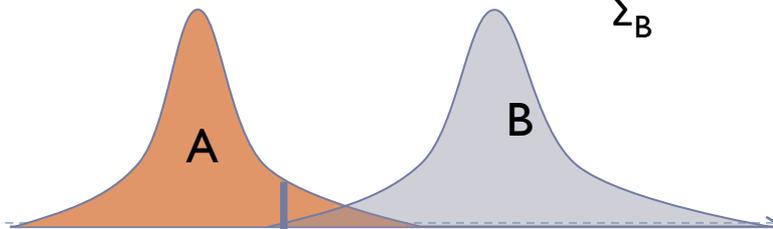
Σ_A

Σ_B

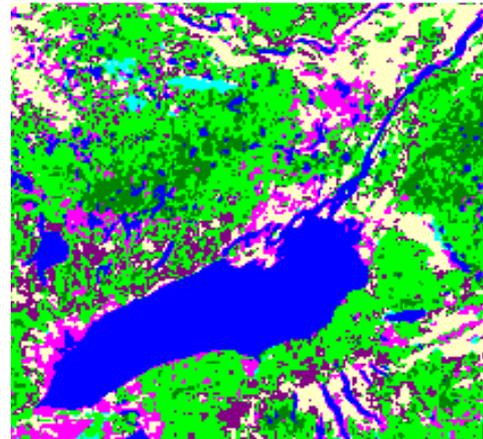
A

B

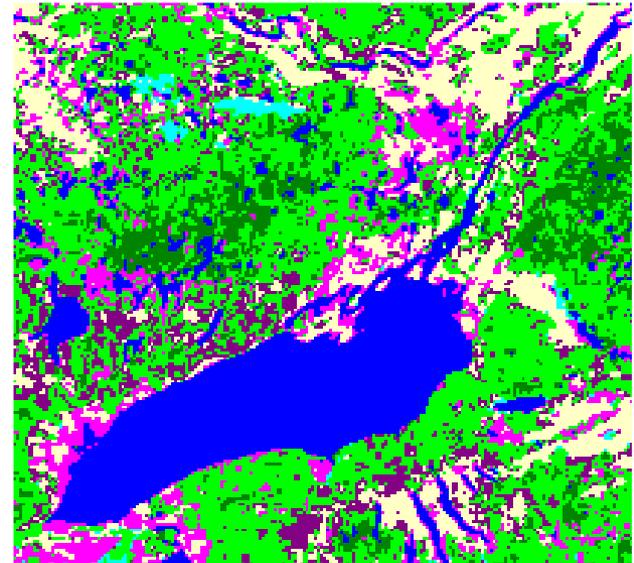
Valor digital



- ▶ Após a classificação se dispõe de um mapa temático, todos os pixels são rotulados como membros de uma classe, mas... como saber se todos os pixels estão corretamente classificados, ou pelo menos a percentagem de pixels errados e em qual classe estes erros são mais frequentes?



- ▶ Uma opção é comparar o resultado com um mapa com a verdadeira classificação, mas isto é impraticável. Outra opção é fazer uma avaliação amostral, ou seja, avaliar a classificação apenas em algumas regiões da imagem e derivar um valor que descreva a qualidade.





A matriz de confusão

- ▶ É uma forma de representar as coincidências e contradições entre a verdade de campo e o resultado da classificação.
 - ▶ São confrontadas duas situações: as linhas correspondem à classe correta e as colunas à classe estimada no processo de classificação.
 - ▶ Cada célula armazena o valor de pixels que deveriam ser classificados como a classe especificada na linha e que foram classificados segundo a classe especificada na coluna.
 - ▶ Numa situação ideal a matriz será diagonal.
-

Exemplo de matriz de confusão

Classe	solo	Bosque	Agricult.	área urbana	soma parcial
solo	60	0	0	0	60
bosque	0	40	5	15	60
Agricultura	0	0	55	5	60
Área urbana	8	16	4	32	60
Soma parcial	68	56	64	52	240

- ▶ A estimativa global da qualidade pode ser calculada como a soma da diagonal principal dividida pelo total de pixels nas amostras, ou seja a soma de todas as células.

Produtor/Usuário

- ▶ exatidão do *ponto de vista do produtor*:
- ▶ Os erros de omissão são pixels pertencentes a uma determinada classe que foram erroneamente classificados como sendo de outra, foram omitidos da classe. A taxa de acerto pode ser calculada dividindo o número de pixels corretamente classificados da classe pela soma parcial da linha da mesma classe.

▶ Classe solo	Bosque	agricult	urbana		
▶ solo	60	0	0	10	
▶ bosque	0	40	5	15	
▶ Agricultura	0	0	55	5	
▶ Urbana	8	6	4	32	total Urbana=60

- ▶ Exemplo para a classe URBANA: $Ac(Prod) = 32/60 = 53\%$

Produtor/Usuário

- ▶ exatidão do *ponto de vista do usuário*:

Os erros de inclusão correspondem aos pixels que, sendo na realidade de outra classe, foram incluídos na classe considerada. A taxa de acerto pode ser calculada dividindo o número de pixels corretamente classificados da classe pela soma parcial da coluna da mesma classe.

▶ Classe solo	Bosque	agricult	urbana	
▶ solo	60	0	0	10
▶ bosque	0	40	5	15
▶ Agricultura	0	0	55	5
▶ Urbana	8	16	4	32
				▶ total Urbana = 62

- ▶ Exemplo para a classe URBANA: $Ac(Prod) = 32/62 = 52\%$

Não supervisionado!

Deixa
comigo!



Não Supervisionada

- ▶ Na classificação não supervisionada, o analista não participa da definição dos parâmetros das classes (médias, variância, etc). E tarefa é deixada ao computador.
- ▶ Os algoritmos analisam o conjunto de dados disponíveis e nele identificam as classes mais frequentes. Cabe então ao usuário apenas determinar o número de classes que ele deseja obter.

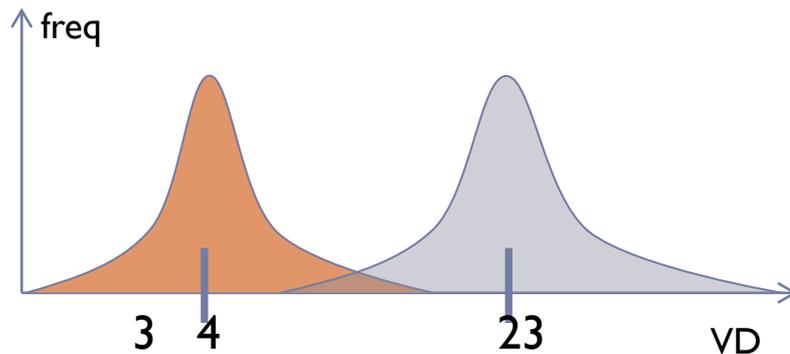
1	2	1	4	12
2	1	2	3	15
1	3	3	5	10
1	1	3	6	12
1	2	3	9	16
21	21	20	21	26
22	22	24	23	27
23	29	29	30	29

Um grupo perto de 4
e outro perto de 23 ?

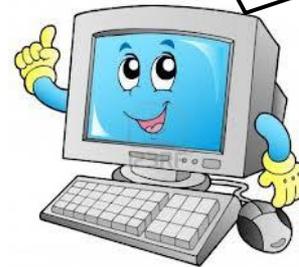


Analizando os valores...

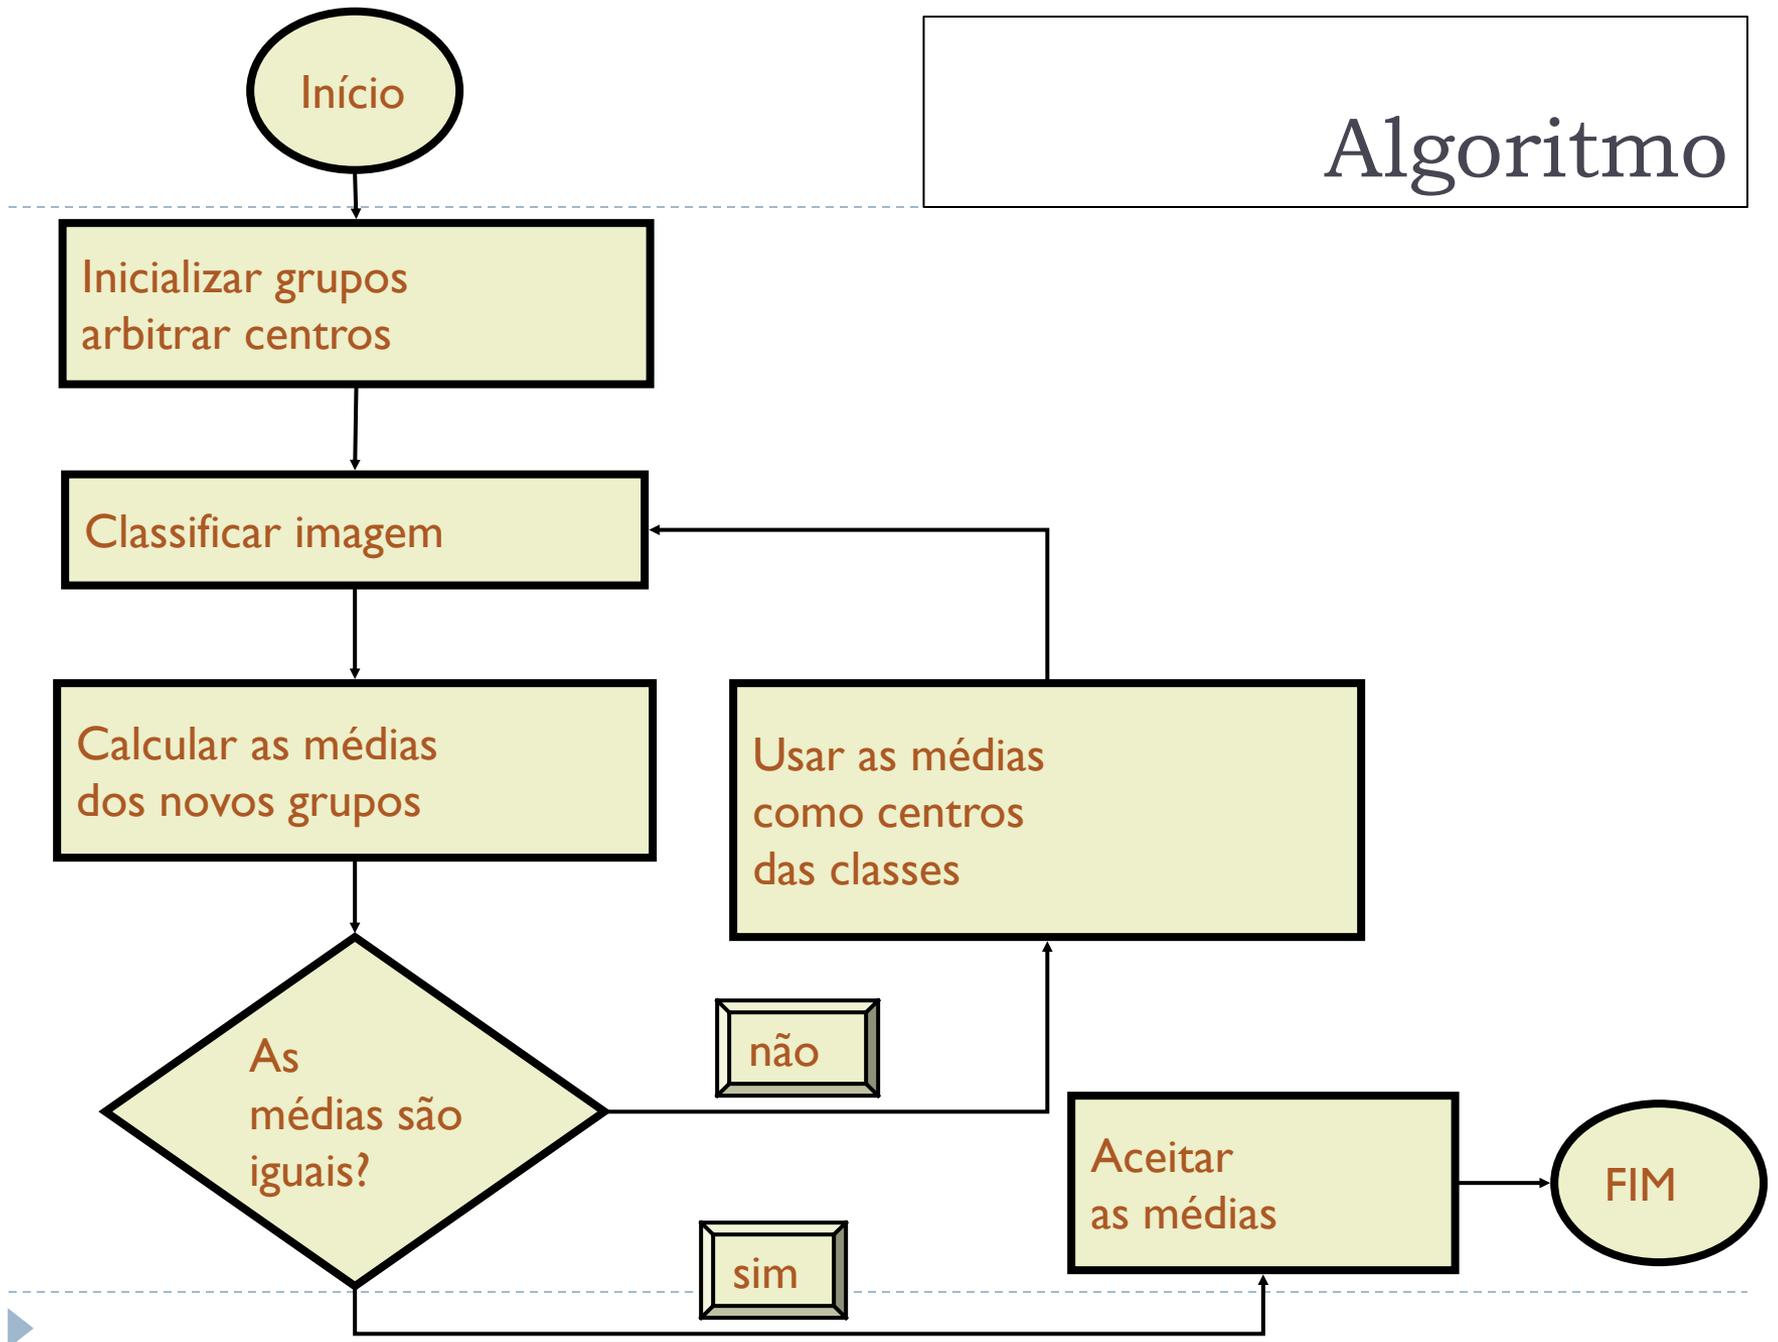
1	2	1	4	12
2	1	2	3	15
1	3	3	5	10
1	1	3	6	12
1	2	3	9	16
21	21	20	21	26
22	22	24	23	27
23	29	29	30	29



Um grupo perto de 4
e outro perto de 23 !



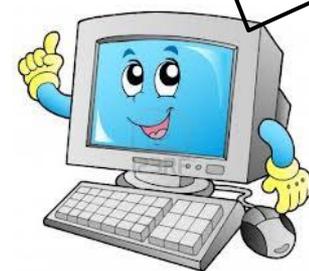
Algoritmo



Inicializar grupos atribuindo centros

1	2	1	4	12
2	1	2	3	15
1	3	3	5	10
1	1	3	6	12
1	2	3	9	16
21	21	20	21	26
22	22	24	23	27
23	29	29	30	29

*Não sei...
Digamos um grupo
perto 10 e outro
perto de 20 ?*



Classif.

				2
2	2	2	2	2
2	2	2	2	2
2	2	2	2	2

medias = 4.2917 23.9375

Sinto muito, errou no chute!

Use as novas médias

Tente de novo!

1	2	1	4	12
2	1	2	3	15
1	3	3	5	10
1	1	3	6	12
1	2	3	9	16
21	21	20	21	26
22	22	24	23	27
23	29	29	30	29

Classif.

				2
				2
2	2	2	2	2
2	2	2	2	2
2	2	2	2	2



medias = 3.8261 23.4118

Sinto muito, errou no chute!

Use as novas médias

De novo...

1	2	1	4	12
2	1	2	3	15
1	3	3	5	10
1	1	3	6	12
1	2	3	9	16
21	21	20	21	26
22	22	24	23	27
23	29	29	30	29

Classif.

				2
				2
2	2	2	2	2
2	2	2	2	2
2	2	2	2	2

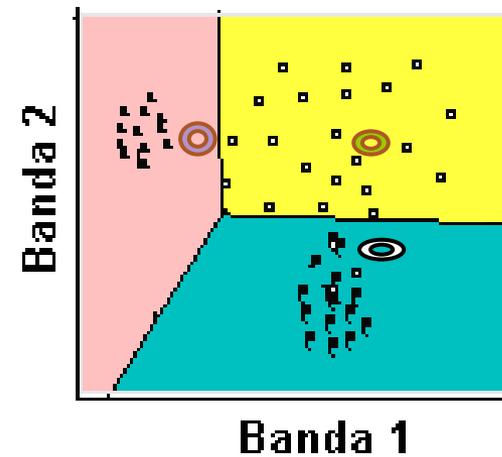
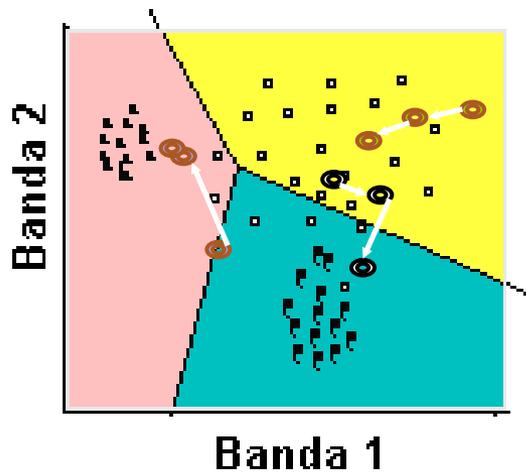
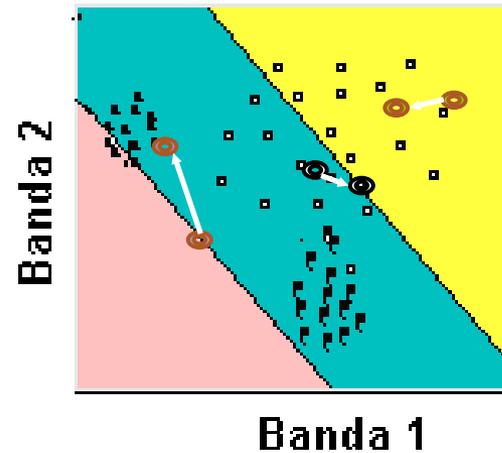
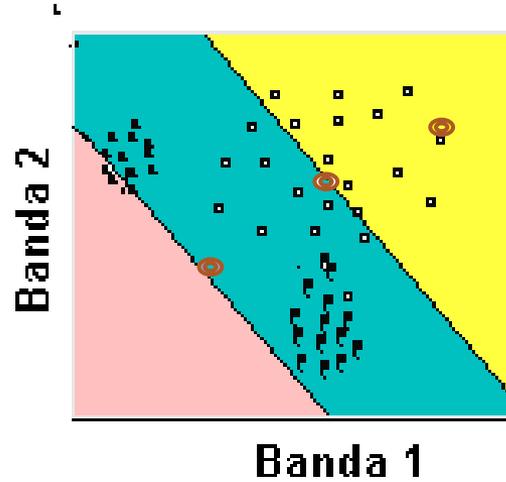


medias = 3.8261 23.4118

Acertou!

Tu é bão,ne compu!

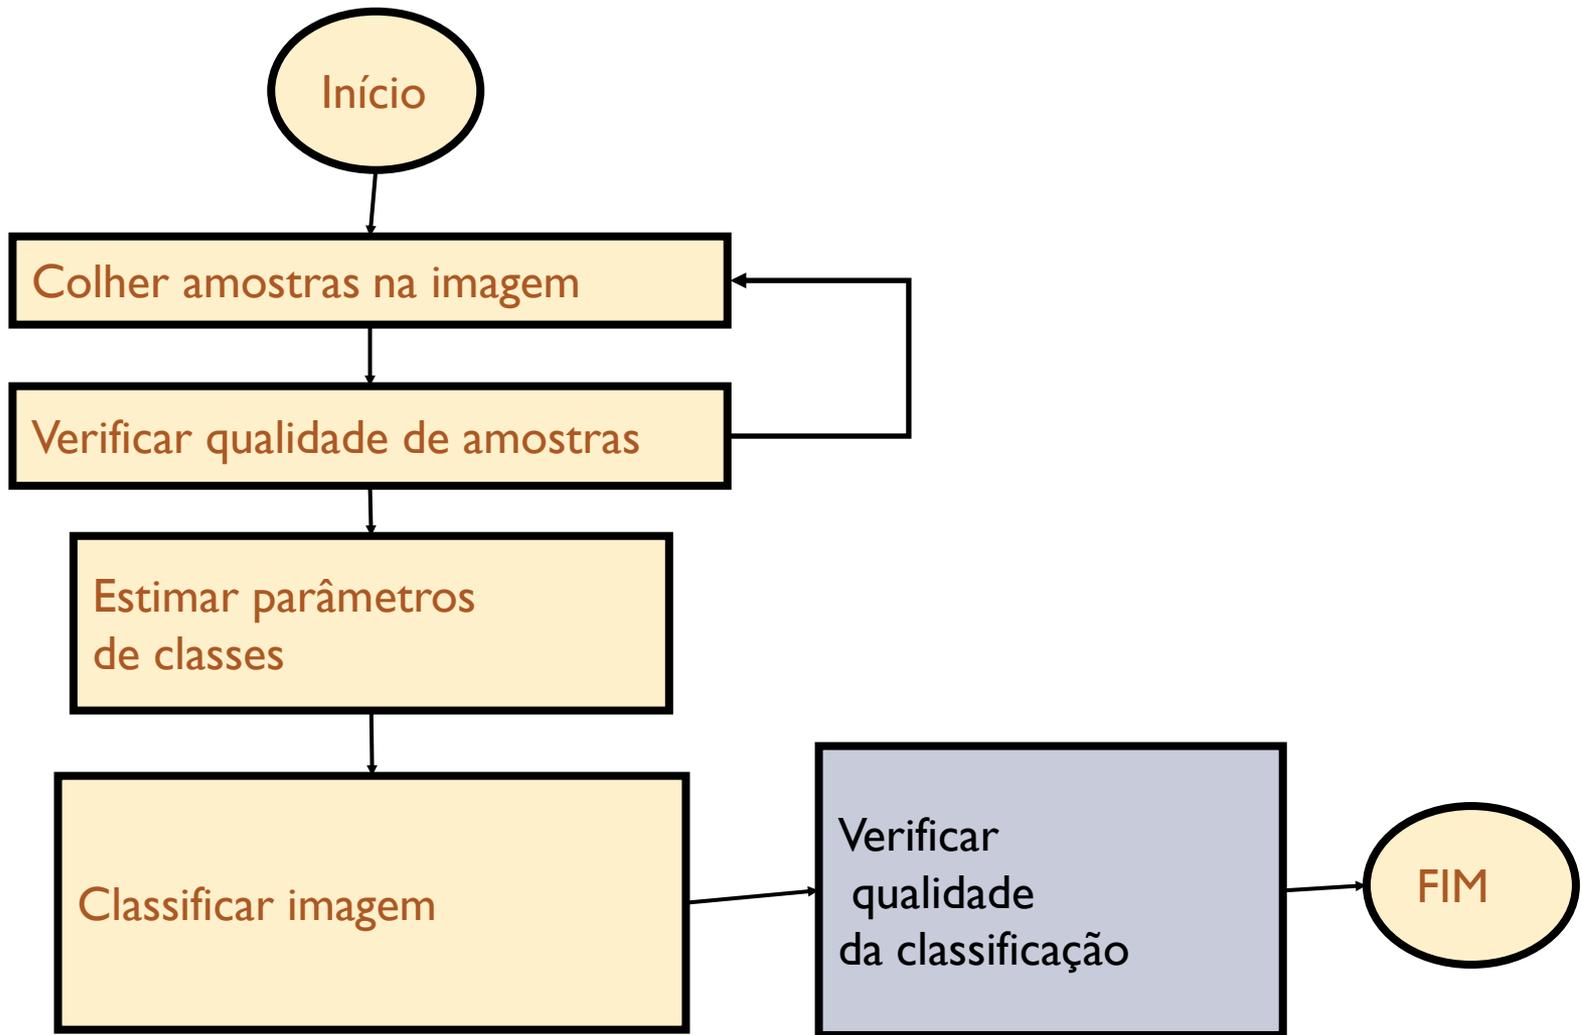
No caso de duas bandas



Não supervisionada

- ▶ Na classificação não supervisionada, os dados espectrais se superpõem à interpretação ou conhecimento prévio do usuário.
 - ▶ As classes não são modeladas de acordo à especificação do usuário, mas em vez disso usa-se abordagens estatísticas para dividir o espaço n-dimensional em grupos com a melhor separação possível.
 - ▶ Depois, pode-se atribuir significado a estes grupos, caso façam sentido no contexto da classificação
-

Algoritmo



Interpolação bilinear

Interpolação por
Condições cúbicas
Uma função cúbica

...porta como uma partícula?

Energia
...do no libe
...das feixes, fótons,
...ortada por um

Energia em J
...stante de P
...com compr
...ar quantidade

Discretiz

As posições p
...imgens são discretizadas em linhas e colunas
...na de tempo dada pelo tamanho da grade
...N_{col}

...y_{col} = 0, 25, 50, 75, 100, 125

Linhas,
colunas,
valor (R, G, B)

O Sensoriamento Remoto permite utilizar regiões do espectro e explorar as diferenças espectrais entre os objetos.

Ex: bandas TM3, TM4 e TM5 da Landsat

Quando a umidade diminui, os picos de absorção também diminuem e a folha passa a refletir maior quantidade da energia incidente.

Este fenômeno também afeta o IVP e VIS.

Características espectrais da água

- absorvência
- refletância entre 0,38 e 0,7
- do 0,7 a água absorve toda a energia solar incidente
- refletividade abaixo de 0,6 é muito baixa.
- a transmitância ocorre em 0,48.

Obrigado!

...da discretização digital podem ser classificadas supervisionada e não supervisionada

Interpolação

$y = ax + b$

...valor digital antigo
...valor digital
...parâmetro

Interpolação

ângulo baixo
Distância baixa

ângulo grande
Distância grande

Interferência entre imagens da mesma área (para latitudes de +A -40°).

2,5 dias no modo Polarimétrico

7,5 dias no modo Multiespectral

Imagem em formato, para mentes e para treinar

...de pontos soltados