




Sensoriamento Remoto: Classificação de imagens

Jorge Centeno - UFPR

Classificação: Por que classificar?

É possível, com base na imagem de satélite, saber:
O tamanho da área urbana?
A área dos manguezais? E onde eles estão?




Classificação: Por que classificar?



Imagem Landsat

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



- Água
- Urbana
- Veg.1
- Veg.2
- Veg.3
- Solo





Imagem temática

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 de uma 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	(192, 192, 255)	1.230.500	1107,45
2	Área urbana	(255,0,0.)	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 pela análise visual da imagem, delimitando as áreas com o “mouse”.

Esta tarefa pode se tediosa e demorada.

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.



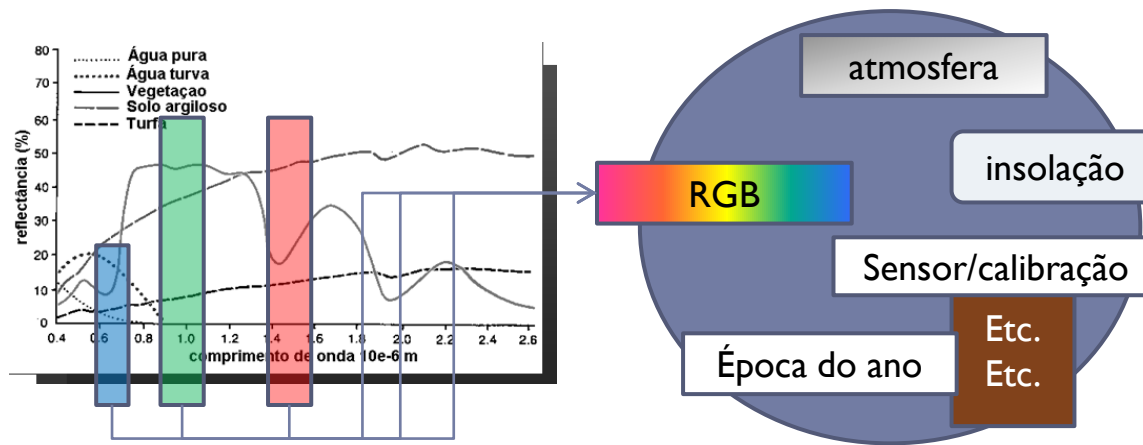


Exemplos de aplicação

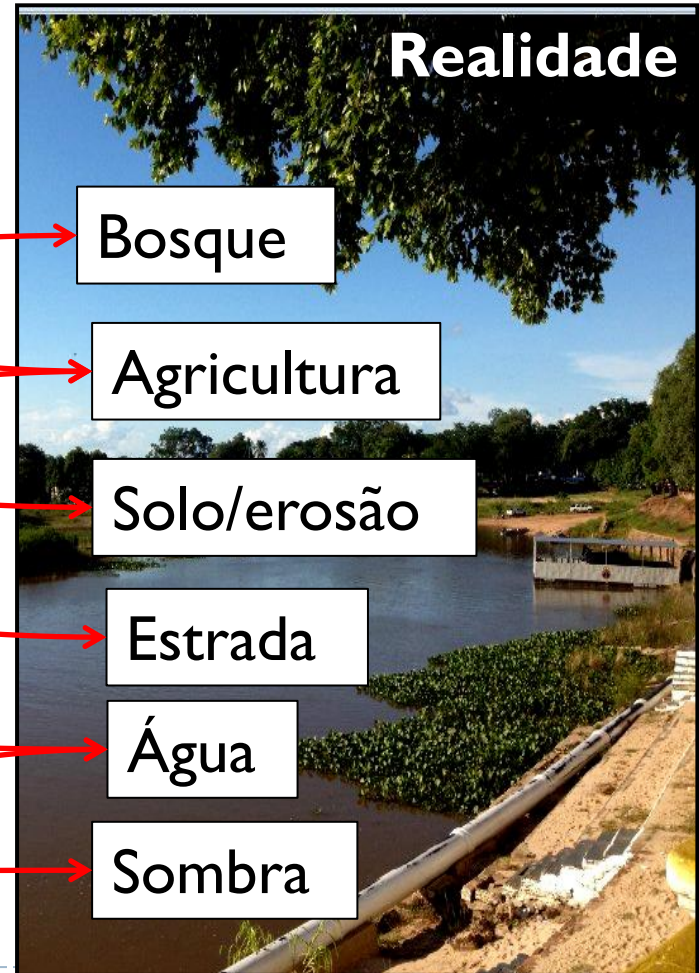
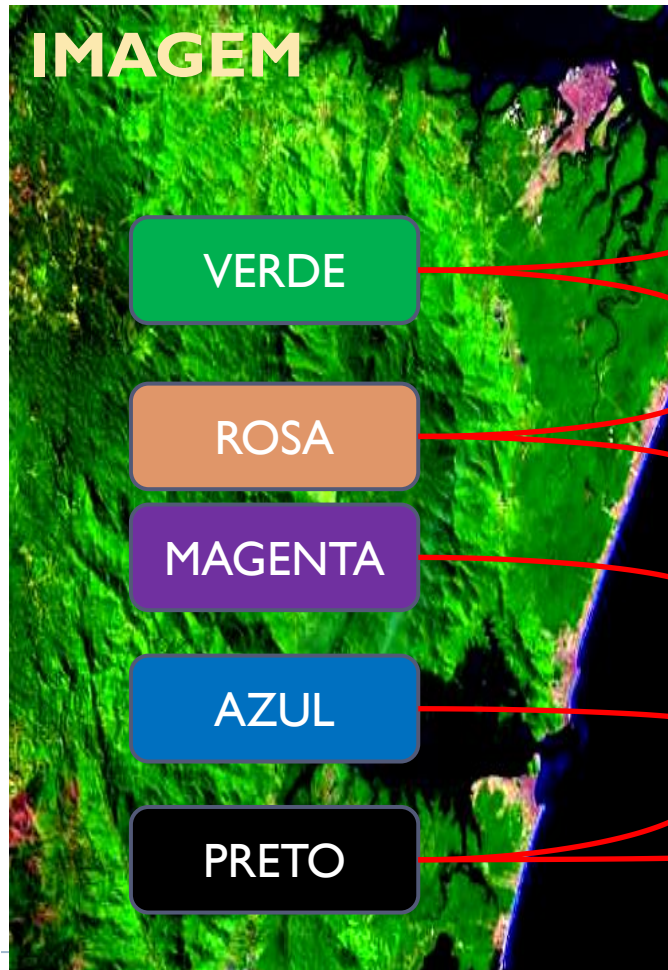
- ▶ Cartografia: atualização de mapas;
 - ▶ Hidrologia: estimar cobertura do solo para conhecer potencial de escoamento superficial
 - ▶ Agricultura/Ciências Florestais: Estimar a produção de culturas
 - ▶ Arquitetura/planejamento: monitorar crescimento de cidades
-

classificação

- ▶ 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.



Relação Imagem-Realidade

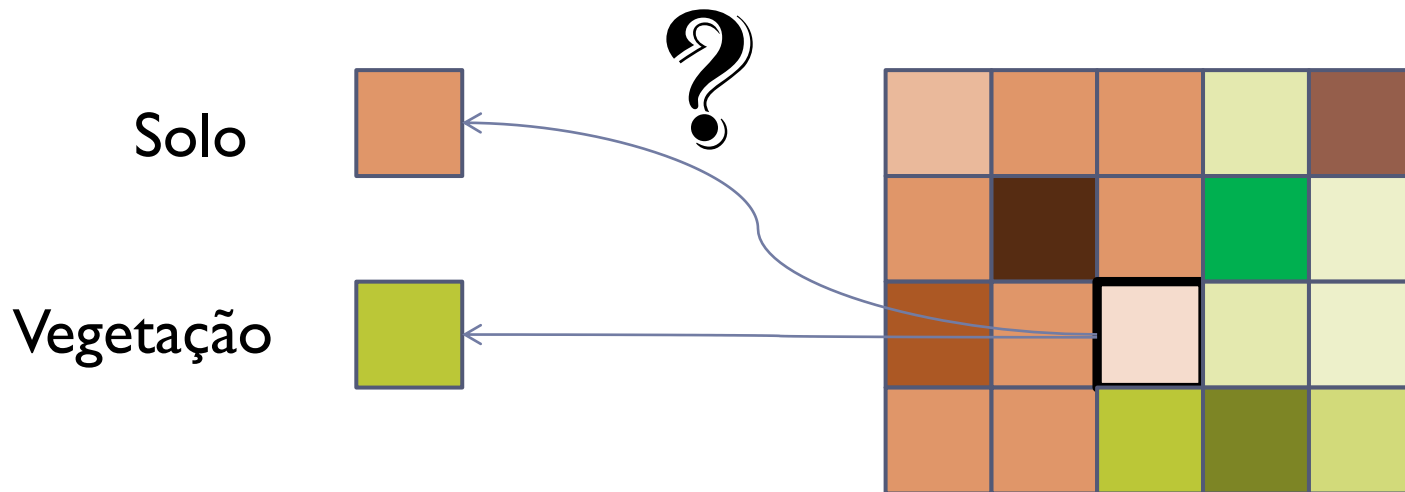


▶ De que cor é a agricultura?



Estratégia

- ▶ 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.





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
-

Método Supervisionado ou não

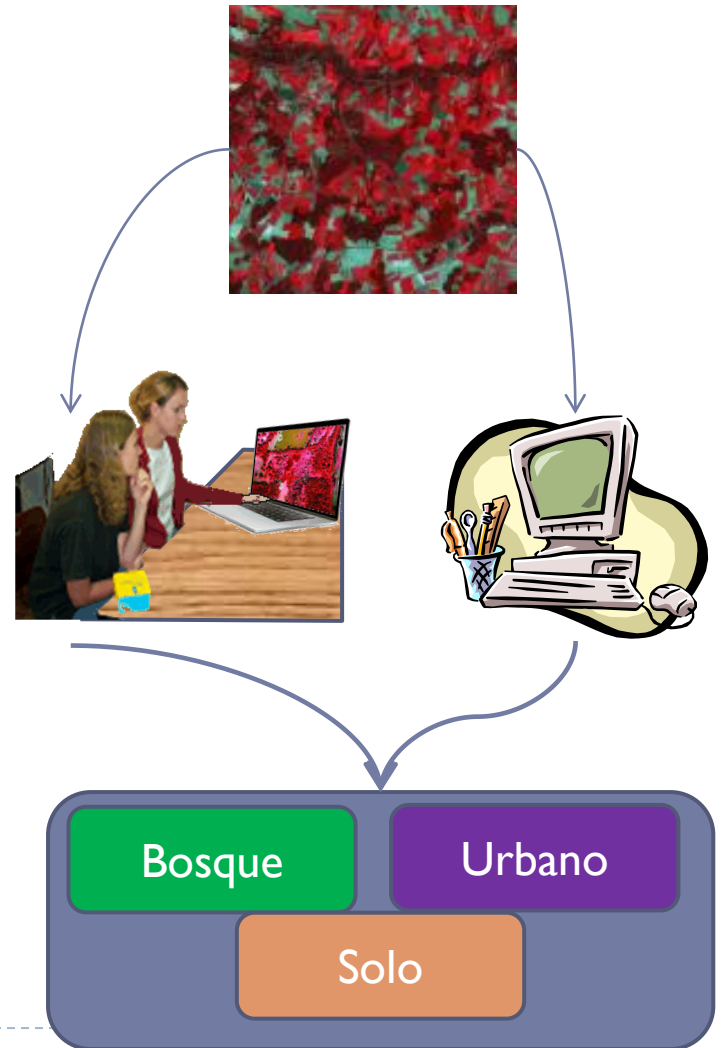
- ▶ Segundo o grau de participação do analista no processo de descrição das classes, os métodos de classificação digital podem ser:

- ▶ supervisionado

O analista coleta amostras representativas, visualmente, para criar os padrões de valor digital das classes,


- ▶ não supervisionado

As classes mais frequentes na imagem são identificadas por meio de algoritmos.



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.




amostragem

- ▶ Uma opção é obter um valor típico da imagem em questão.
- ▶ Mas... Qual?

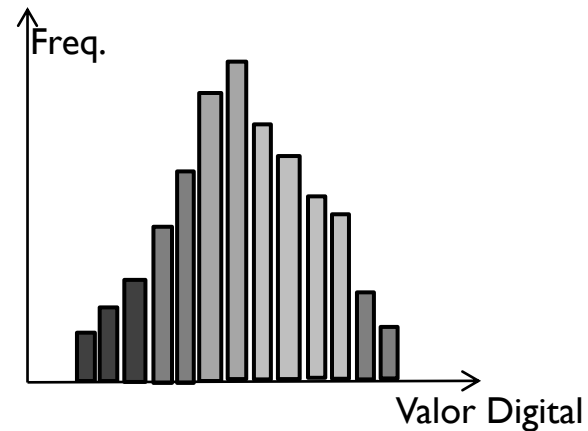



variabilidade


- ▶ 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?

amostras

Regiões em locais onde as classes apareçam puras.

Evitar áreas de transição, onde a interpretação é duvidosa.


Se for necessário,
podem ser definidas.

subclasses





Amostragem: Cuidados

- 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.

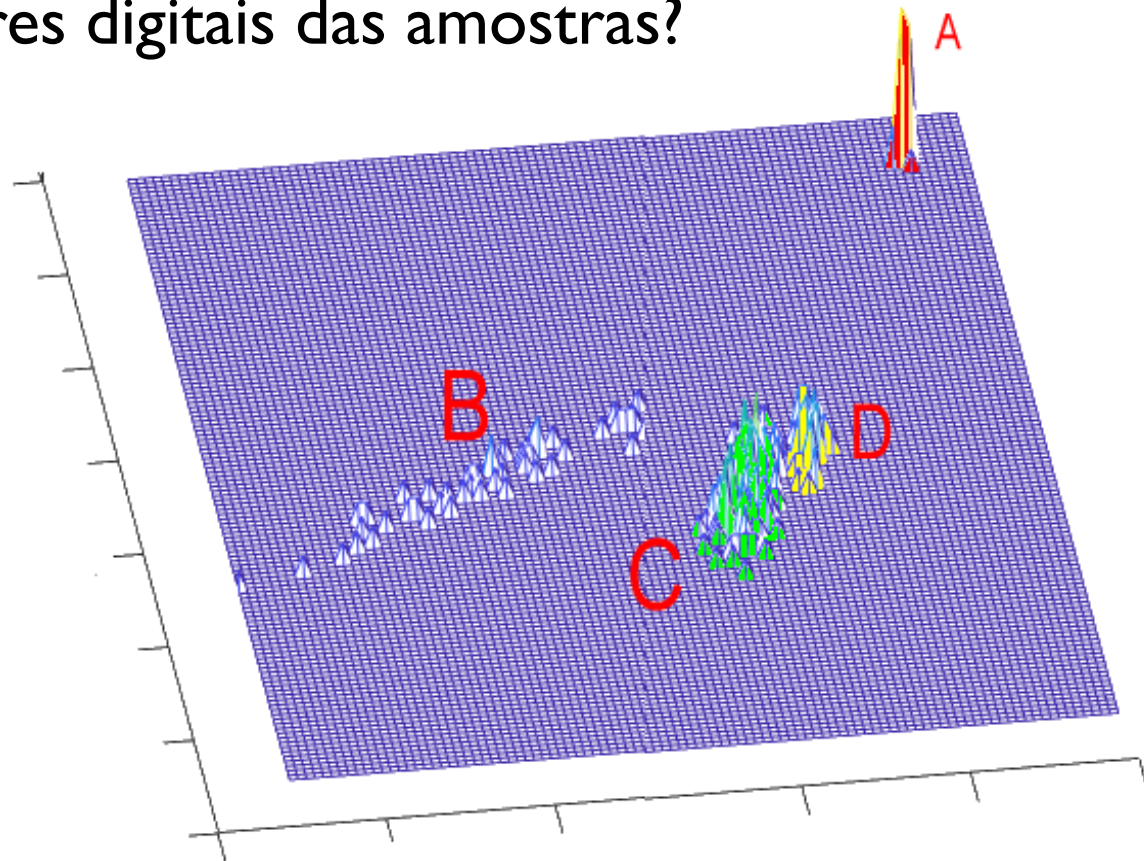


Descrição das classes

- ▶ Com os pixels de uma (ou várias) amostra(s) é possível descrever cada classe em termos de parâmetros estatísticos como
 1. A) valores médios em cada banda
 2. B) variância em cada banda
 3. C) covariância entre diferentes bandas





- ▶ É possível avaliar se haverá confusão entre algumas classes? Ou se elas são facilmente separáveis com base nos valores digitais das amostras?




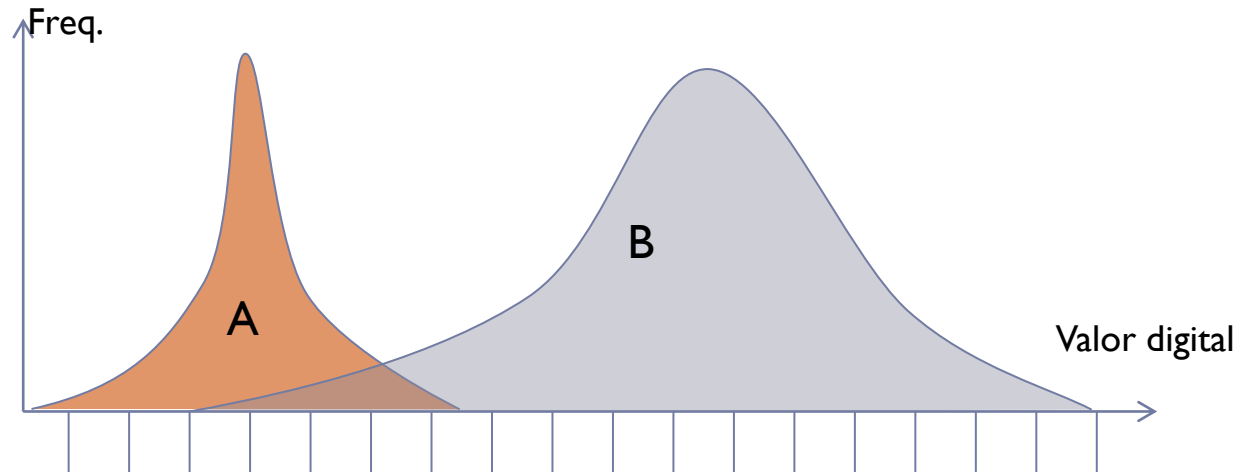
As Classes são separáveis?

- ▶ A médias são próximas?




As Classes são separáveis?

► E as variâncias?



► classificacao





Classificação

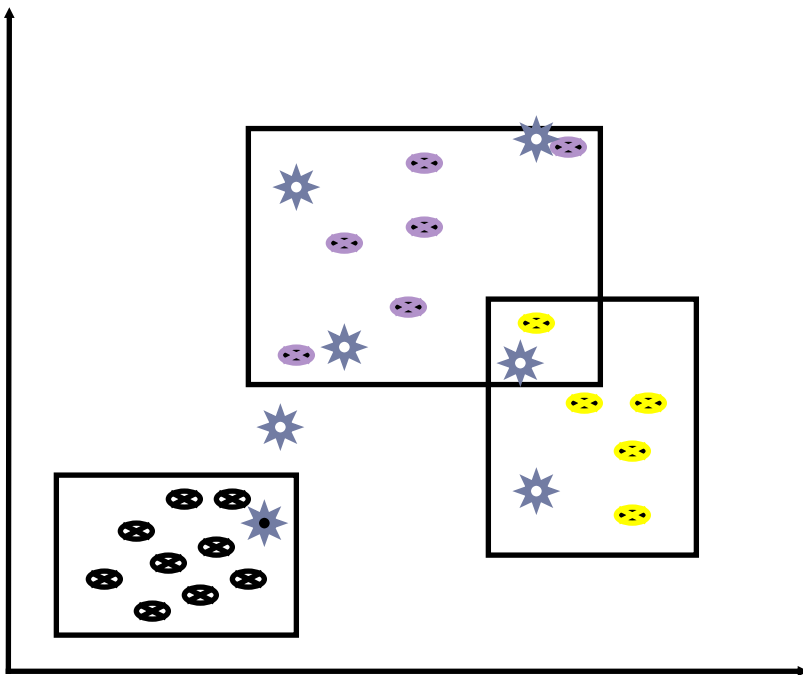
- ▶ Atribuir a cada pixel um rótulo que o identifique como membro de uma das classes, em função de seus valores do contador digital.
 - ▶ Para isto, temos os parâmetros estatísticos de cada calculados a partir das amostras.
 - ▶ A estratégia consiste em classificar o pixel como pertencendo à classe “mais parecida”.
 - ▶ Com quem se parece mais cada pixel, considerando as classes disponíveis?
 - ▶ Como medir o grau de similaridade entre o pixel e as classes?
-



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.
- ▶ Dada as médias no vermelho e no IVP das classes vegetação (V) e solos (S), e o pixel X... Qual classe é mais parecida (próxima) do pixel X?:

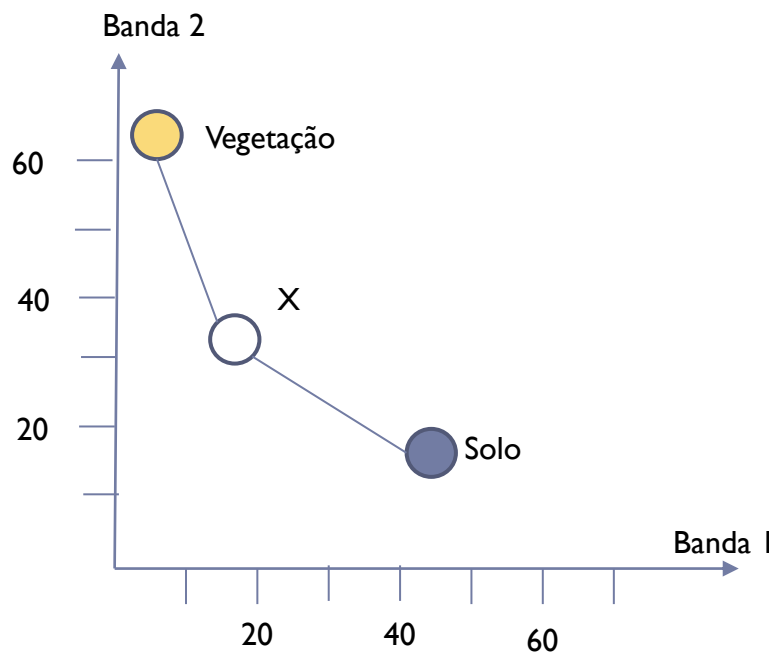
- ▶ $média_V = \begin{bmatrix} 7,90 \\ 65,1 \end{bmatrix}$

- ▶ $média_S = \begin{bmatrix} 42,2 \\ 18,5 \end{bmatrix}$

$$X = \begin{bmatrix} 18,5 \\ 30,3 \end{bmatrix}$$

Distância Mínima Euclidiana

- ▶ Podemos resolver graficamente, plotando os pontos e medindo a distância, ou usando o conceito de distância Euclidiana



$$d^2(x, V) = \sum_{i=1}^2 [(média(V)_i - X_i)^2]$$

$$d^2(x, S) = \sum_{i=1}^2 [(média(S)_i - X_i)^2]$$

Se $d^2(x, V) > d^2(x, S)$,
X é mais próximo de Solos (S) ... Ou
seja, se parece mais com solos.
Seria lógico, classificar o pixel como
“solos”

Distância Mínima Euclidiana

- ▶ O conceito de distância Euclidiana pode ser estendido a “n” bandas

$$d^2(x, A) = \sum_{i=1}^n [(média(A)_i - X_i)^2]$$

Considerando “Nc” classes, deve-se calcular a distância Euclidiana entre o pixel e todas as classes e encontrar a classe associada à menor distância;

X pertence à classe “A” se:
Se $d^2(x, A) < d^2(x, B)$,

Onde “B” denota todas as outras classes.



Problema

- ▶ Se uma classe tem medias $M1=[30,22,113]$
- ▶ e uma segunda $M2=[29, 50,83]$

- ▶ A qual classe atribuiria os pixels com valores:

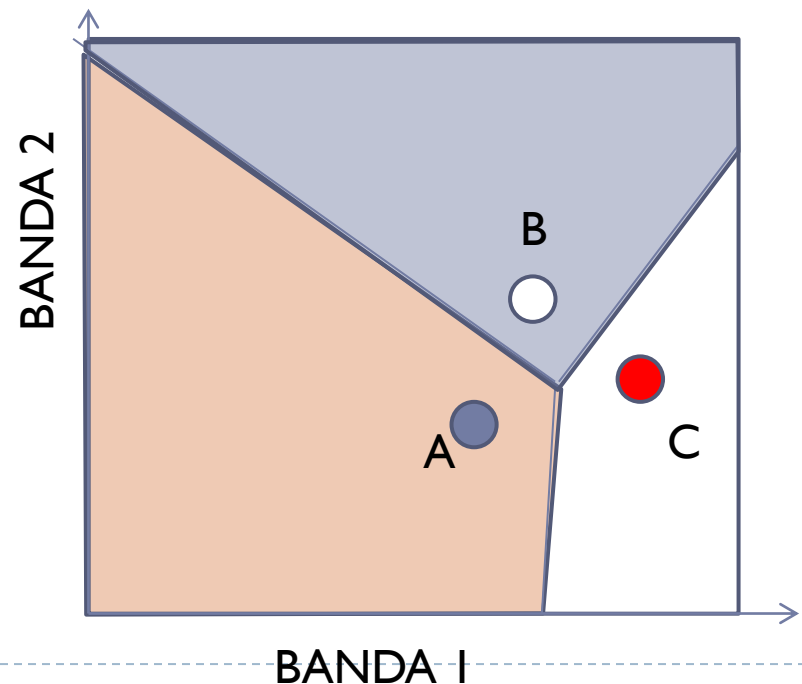
- ▶ 145 39 18 -
 - ▶ 75 68 123 -
 - ▶ 116 187 2 -
 - ▶ 23 78 115 -
 - ▶ 12 55 158 -
 - ▶ 196 30 47 -
 - ▶ 57 79 90 -
 - ▶ 119 75 114 -
 - ▶ 192 26 12 -
 - ▶ 37 87 99 -
-

Distância Mínima

▶ Pros

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

Uma classe sempre será mais próxima de cada pixel, mesmo que a distância seja grande. | Procura-se a “menor” distância. O “mais parecido”



Exercício


- ▶ Colete amostras de várias classes e classifique a imagem usando o método da distância mínima Euclidiana.



Ex:
Água
Mata Atlântica
Áreas urbanas
Areia
Restinga
Solo úmido
Solo seco.... Etc etc

Avaliação da qualidade

Como posso afirmar que esta imagem temática está correta?
Que a informação é verdadeira?




Verificação da qualidade

Após a classificação se dispõe de um mapa temático, todos os pixels são rotulados como membros de uma classe, mas o processo pode ter erros.


Como saber quantos pixels (%) estão corretamente classificados?

Se ocorrem erros, em qual classe estes erros são mais frequentes?




Avaliação por amostragem

- ▶ Uma opção é comparar o resultado com um mapa com a verdadeira classificação, isto permitiria calcular a taxa de pixels errados.




correto



Avaliação por amostragem


Comparando as duas imagens podemos calcular:









- ▶ quantos pixels realmente são de uma classe e foram classificados dentro dessa classe (OK)?
- ▶ quantos pixels realmente são de uma classe e foram classificados dentro de OUTRA classe (x)?



Na verdade é ...



Foi classificado como...



	A 	B 	C 	D 
A 	OK	x	x	x
B 	x	OK	x	x
C 	x	x	OK	x
D 	x	x	x	OK


Avaliação por amostragem

- ▶ 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.



Na verdade é ...

Foi classificado como...



	A 	B 	C 	D 
A 	OK	x	x	x
B 	x	OK	x	x
C 	x	x	OK	x
D 	x	x	x	OK

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.

exercício

- ▶ A) Calcule a acurácia global
- ▶ B) Calcule a acurácia do usuário e do produtor da classe `_3_`
- ▶ Discuta as diferenças

Class	1	2	3	4	5	6	Sum
1	61	20	19	0	0	0	100
2	7	55	35	3	0	0	100
3	2	15	83	0	0	0	100
4	1	25	36	38	0	0	100
5	0	4	4	2	90	0	100
6	0	0	3	0	0	97	100
Sum	71	119	180	43	90	97	600

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: $Ac(Prod) = 32/62 = 52\%$