

**CLASSIFICAÇÃO**

**EM IMAGENS**

**MULTIESPECTRAIS**

# Classificação em imagens multiespectrais

- Imagens multiespectrais
- Espaço de atributos
- Classificação
- Seleção de atributos
- Regras de decisão
- Segmentação
- Avaliação da classificação

# Classificação em imagens multiespectrais

- Alta resolução espacial ou Hiperespectral
- Multitemporais
- Fusão de imagens
- Áreas urbanas
  - Mudanças => no tempo e no espaço (“change detection”)
- Classificação
  - SVM – Support Vector Machine
  - Regras de decisão
  - Segmentação
  - Avaliação da classificação

# Classificação em imagens multiespectrais

- Imagens multiespectrais
  - Definição
  - Exemplos

# Classificação em imagens multiespectrais

- Espaço de atributos
  - Definição
  - Exemplos

# Classificação em imagens multiespectrais

- Classificação
  - Definição
  - Tipos
    - Pixel a pixel
      - Supervisionada
      - Não supervisionada
    - Baseada em objetos
  - Exemplos

# Classificação em imagens multiespectrais

- Seleção de atributos
  - Definição
  - Tipos
  - Exemplos

# Classificação em imagens multiespectrais

- Regras de decisão
  - Definição
  - Tipos
    - Regra de decisão de Bayes
  - Exemplos

# Classificação em imagens multiespectrais

- Segmentação
  - Definição
  - Tipos
    - Crescimento de regiões
    - Detecção de bacias
  - Exemplos

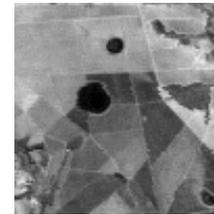
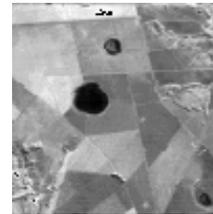
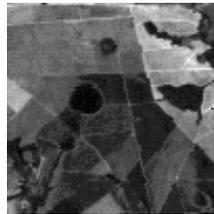
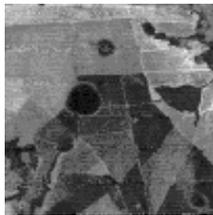
# Classificação em imagens multiespectrais

- Avaliação da classificação
  - Definição
  - Tipos
  - Exemplos

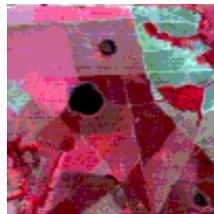
# Imagem multiespectral

## Composição colorida

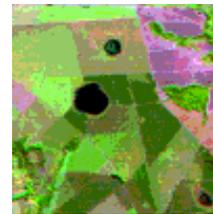
- Banda 2    Banda 3    Banda 4    Banda 5



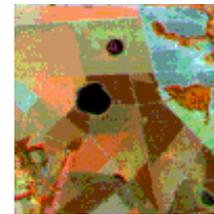
Exemplos de  
Composições  
coloridas



4R3G2B



3R4G5B



4R5G3B

## **Classificação em imagens multiespectrais: Etapas da classificação - Seleção de atributos**

- Espaço de atributos (ou de feições):  
  
“O gráfico contendo as frequências de distribuição de intensidades de duas ou mais bandas de uma imagem multiespectral, define o chamado espaço de atributos (feature space).” (Crósta 1989)

# Classificação em imagens multiespectrais

- Objetivos da classificação:
  - definir classes de objetos semelhantes, segundo algum critério de parecença ou homogeneidade
  - incluir novos elementos (alocar de maneira ótima) nas classes pré-definidas, segundo alguma regra de decisão

# Classificação em imagens multiespectrais

- Objetivos da classificação:
  - no caso específico de geoprocessamento:
    - agrupar e atribuir pixels em classes ou categorias
    - gerar de mapas/imagens temáticas
    - servir como fonte de dados para SIG

# Classificação em imagens multiespectrais: Objetivos da classificação

- Critérios de homogeneidade:
  - estatísticos  $\Rightarrow$  classes espectrais  
( $\Rightarrow$  classificação não supervisionada)
  - da aplicação  $\Rightarrow$  classes informais  
( $\Rightarrow$  classificação supervisionada)

# **Classificação em imagens multiespectrais: Objetivos da classificação**

- Regras de decisão :  
(aplicadas sobre o espaço de atributos)
  - paramétricas (estatísticas)
  - não paramétricas (geométricas)

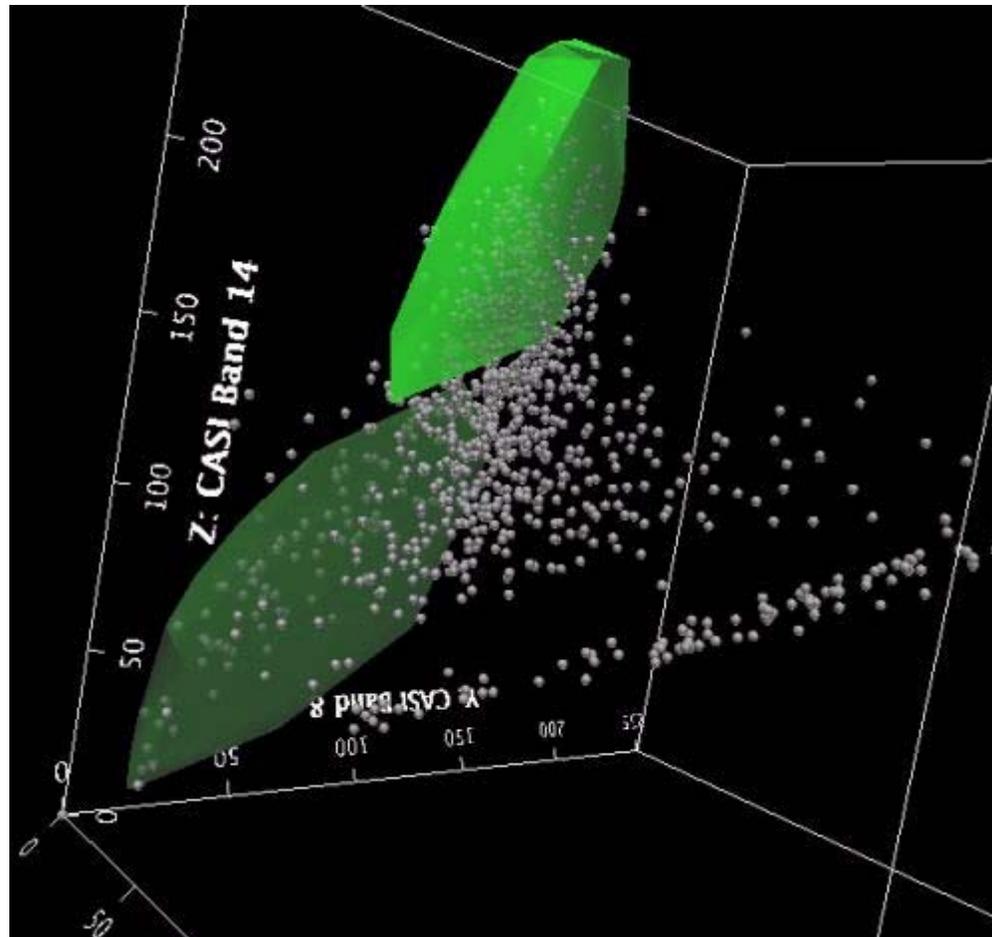
# Classificação em imagens multiespectrais

- Etapas da classificação:
  - Seleção de atributos
  - Classificação:
    - supervisionada
    - não supervisionada
    - “híbrida”
  - Rotulação/Legenda/”Labeling”

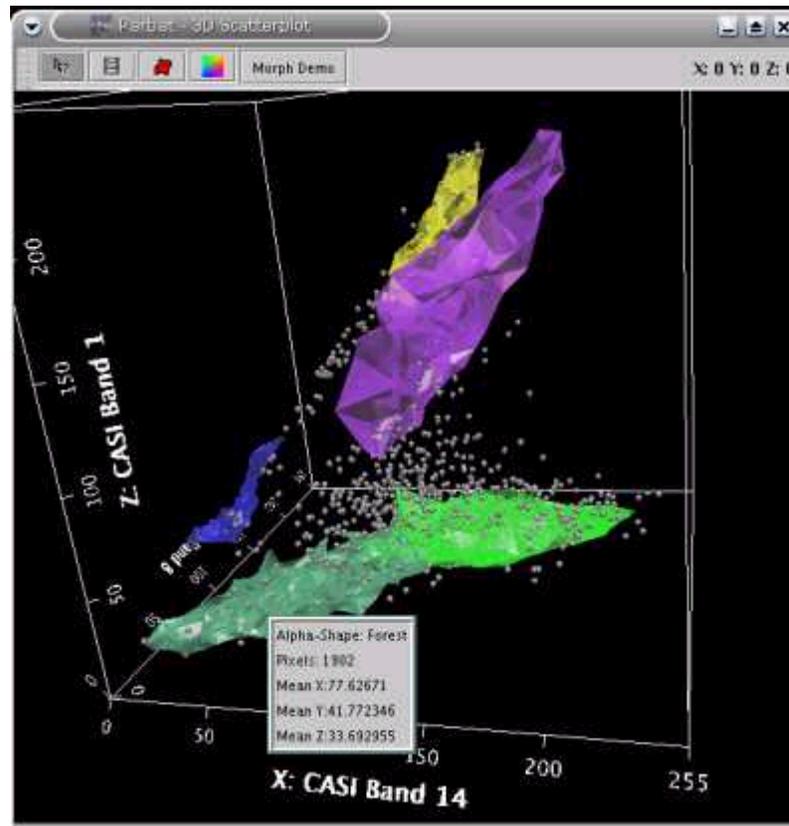
# **Classificação em imagens multiespectrais: Etapas da classificação**

- Seleção de atributos:
  - necessita ao menos uma composição colorida
  - conceito de espaço de atributos

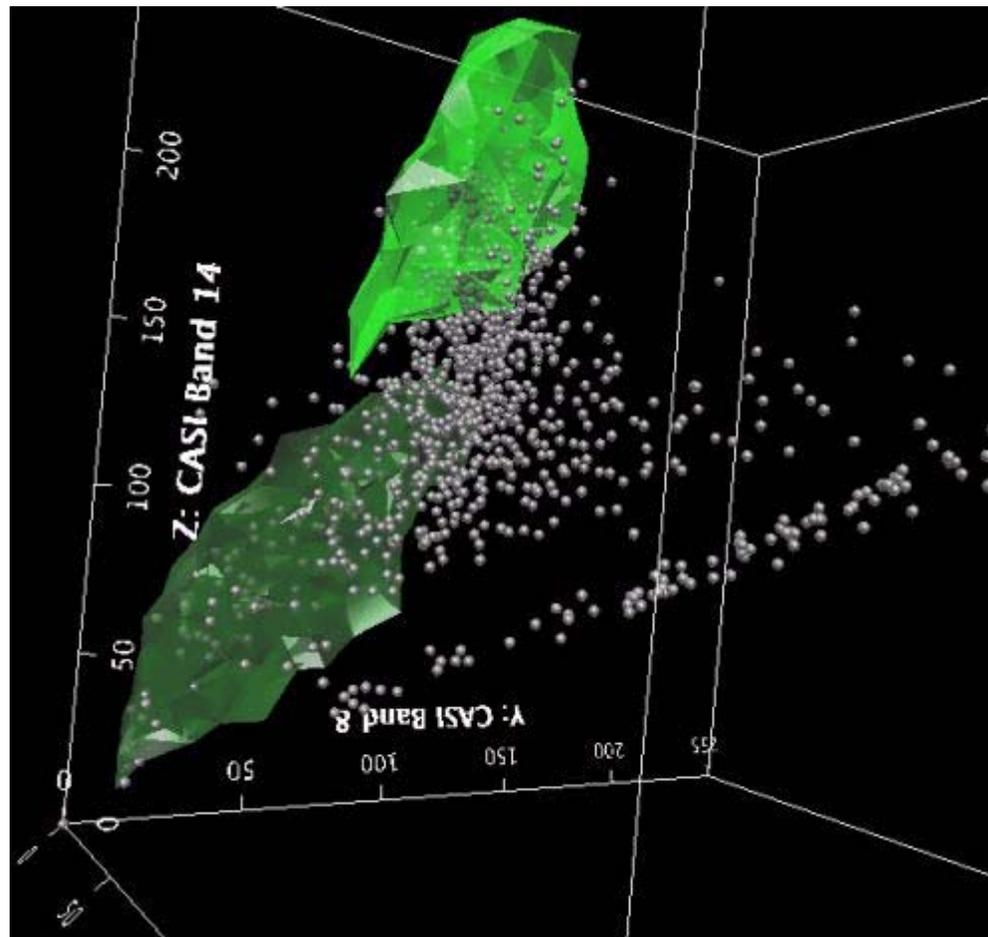
# Classificação em imagens multiespectrais: Etapas da classificação - Espaço de atributos



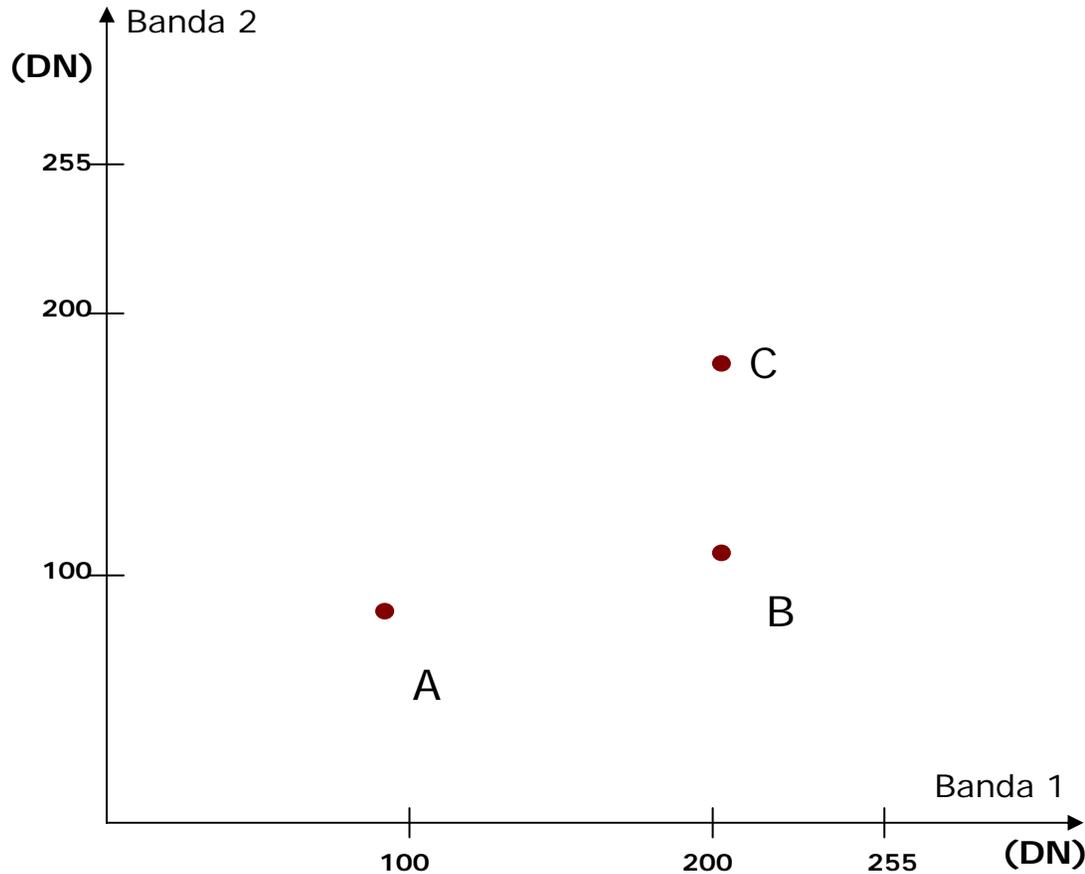
# Classificação em imagens multiespectrais: Etapas da classificação - Espaço de atributos



# Classificação em imagens multiespectrais: Etapas da classificação - Espaço de atributos



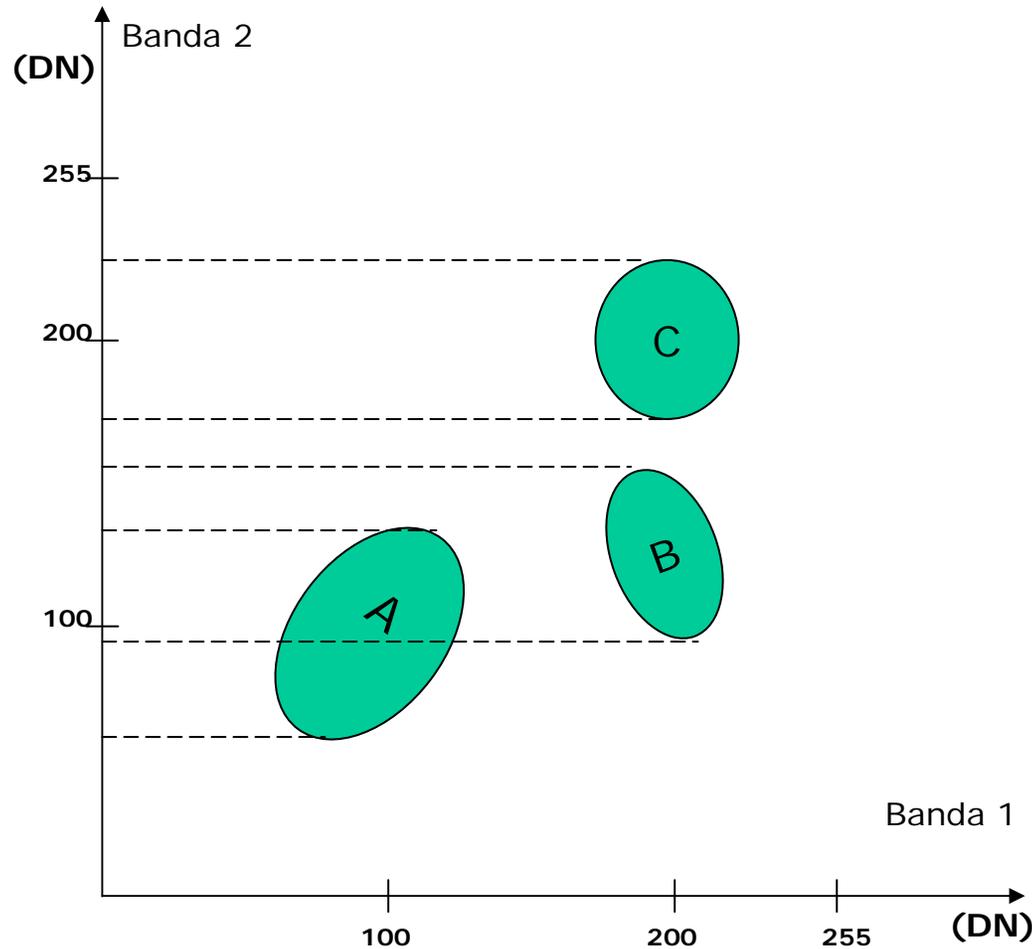
# Classificação em imagens multiespectrais: Etapas da classificação - Seleção de atributos



Duas bandas espectrais plotada uma contra a outra, contendo as características espectrais de pixels de três classes distintas.

Fonte: Crósta, 1989

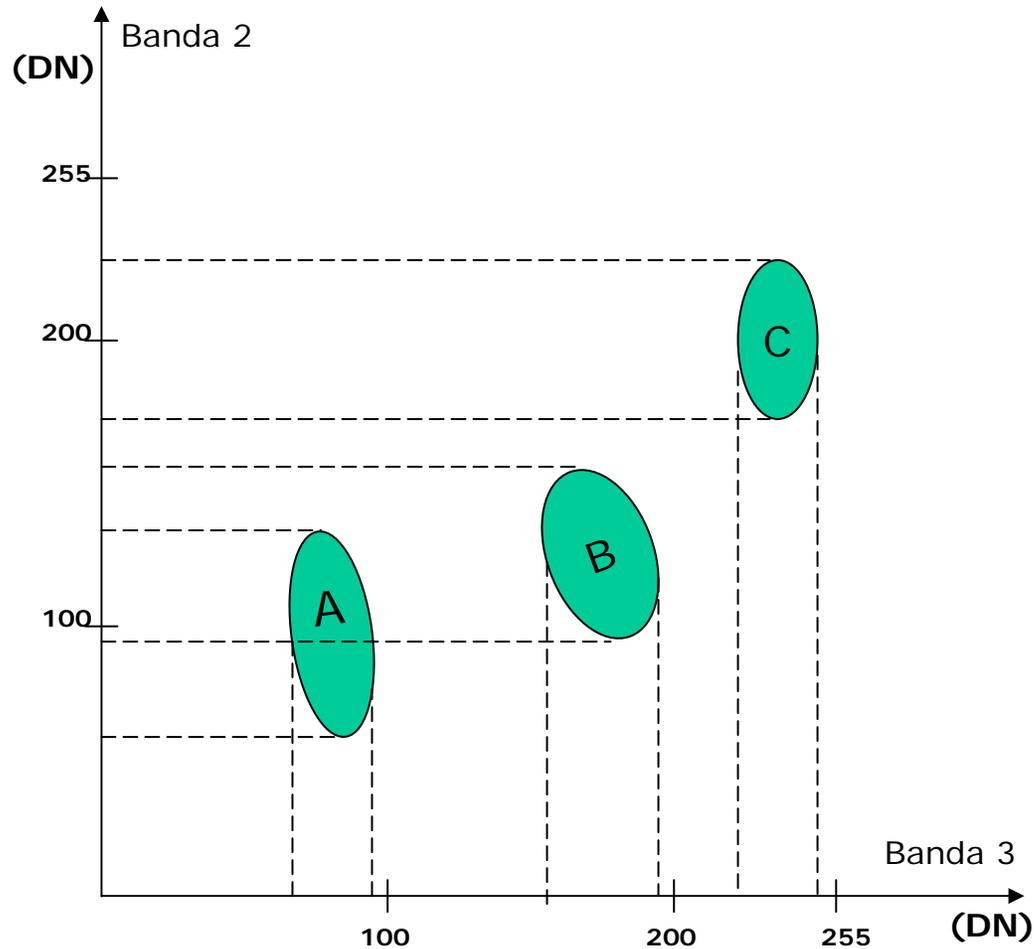
# Classificação em imagens multiespectrais: Etapas da classificação - Seleção de atributos



As classes estão representadas pelas áreas de distribuição dos pixels.

Fonte: Crósta, 1989

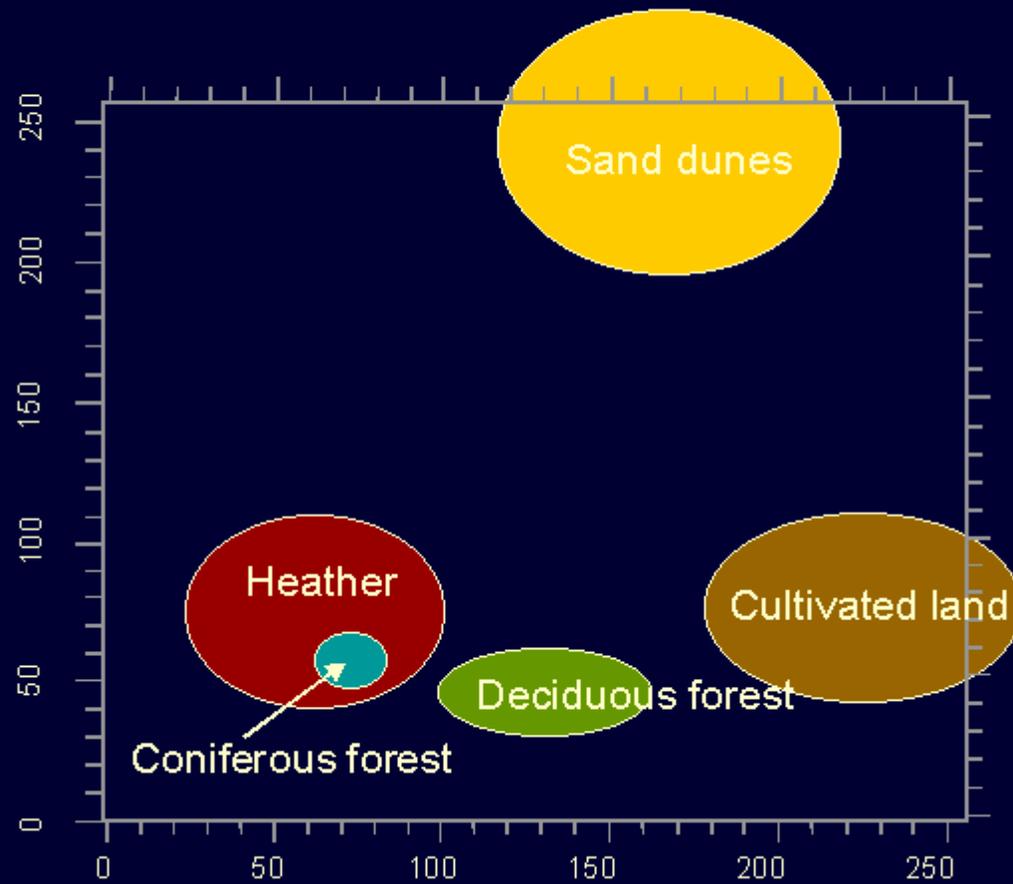
# Classificação em imagens multiespectrais: Etapas da classificação - Seleção de atributos



Espaço de atributos para a mesma porém com uma terceira banda diferente no eixo horizontal. Mostrando a separabilidade das classes.

Fonte: Crósta, 1989

# Feature Space Plot



# Classificação em imagens multiespectrais

- Classificação:
  - supervisionada
  - não supervisionada
  - “híbrida”
- Suposições/condições desta abordagem:
  - pixels de uma mesma classe são semelhantes
  - diferentes alvos tem diferentes comportamentos espectrais

# Classificação em imagens multiespectrais

- Classificação supervisionada
  - definição das classes
  - treinamento ou supervisão
  - escolha do algoritmo de classificação
  - alocação de novos pixels/indivíduos
  - avaliação da classificação

# Classificação em imagens multiespectrais: Classificação Supervisionada - Padrões espectrais

## Conhecidas:

- as classes  $w_i$
- o vetor de observações no espaço de atributos:  
$$\underline{X} = (x_1, x_2, \dots, x_p)'$$
 por pixel
- as probabilidades *a priori* de ocorrência de cada classe:  
 $P(w_i)$
- as funções densidade de probabilidade de cada classe  
(ou suas estimativas):  $p(\underline{X} \mid w_i)$
- o vetor de médias das classes:  $(\underline{m}_w)_i$
- a matriz de variância-covariância  $\Sigma_i$  de cada classe

## Classificação em imagens multiespectrais: Class. Supervisionada - Probabilidade condicional

- Probabilidade condicional  
classificar é atribuir um grupo de pixels a  
uma classe  $w_i$  baseada na probabilidade  
condicional:

$$p(\underline{X} \setminus w_i) = \frac{P(\underline{X} \text{ e } w_i)}{P(w_i)}$$

$\underline{X}$  pertence a classe  $w_i$  se a probabilidade  
 $P(\underline{X} \setminus w_i)$  for a maior para qualquer outra  
classe  $w_j \neq w_i$

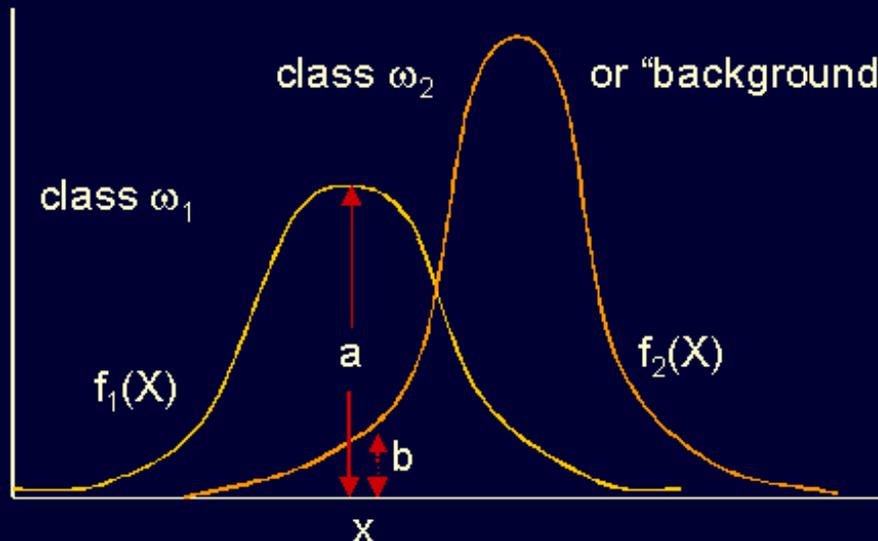
# Classificação em imagens multiespectrais: Classificação Supervisionada - Distribuição normal

## Gaussian Distribution

Example: 2 classes with a  
Gaussian (Normal) distribution

$$f(x) = \frac{1}{\sigma \sqrt{2\pi}} \cdot e^{-\frac{1}{2}[(x-\mu)/\sigma]^2}$$

$f(X)$  (probability density)



$X$  (radiation intensity in  
one spectral band)

$$P(\underline{X} | \omega_1) = a$$

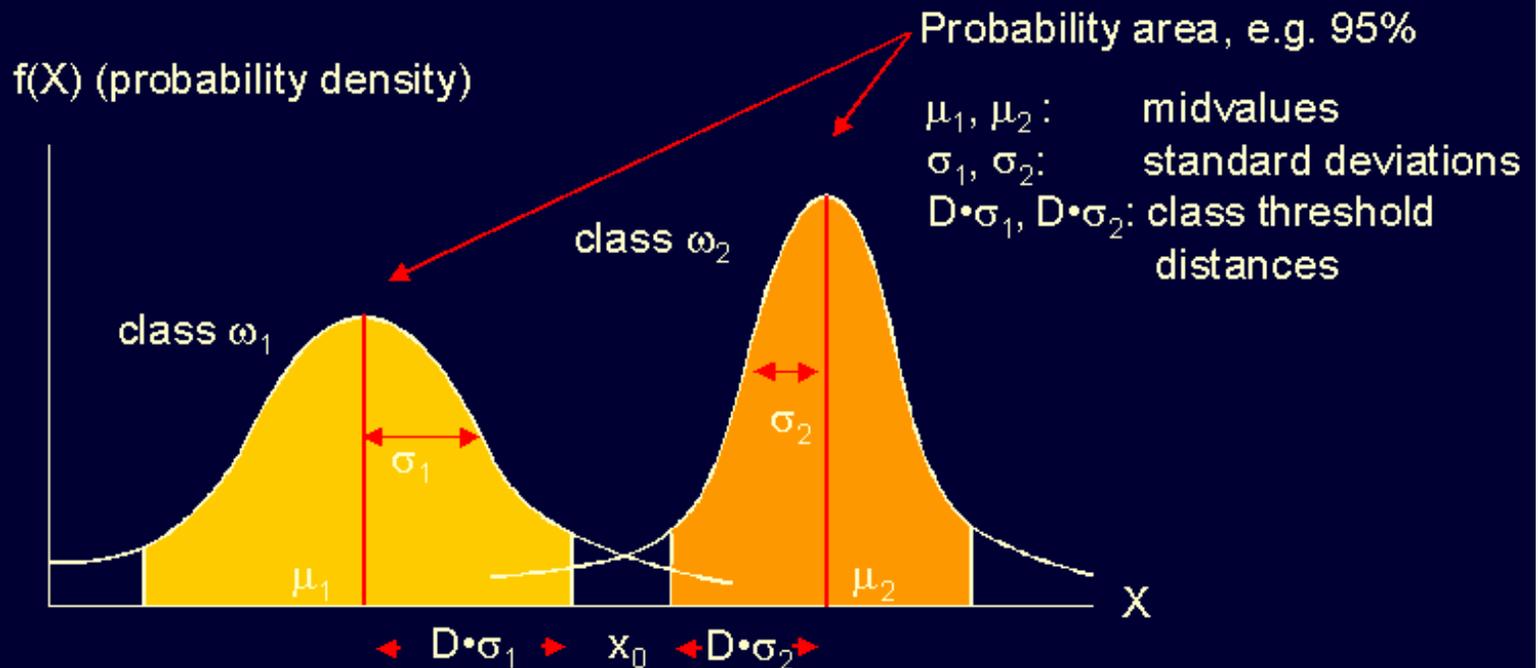
$$P(\underline{X} | \omega_2) = b$$

decision rule:  $a > b \rightarrow x$  belongs to class  $\omega_1$   
 $a < b \rightarrow x$  belongs to class  $\omega_2$

# Classificação em imagens multiespectrais: Classificação Supervisionada - Classe de rejeitados

## Rejection Class

When the distances from a pixel to each class centre become too large (larger than a threshold  $D$ ), in other words:  $a$  and  $b$  both very small, then one often wants the pixel to be called "unclassified" → **rejection class**.



## **Classificação em imagens multiespectrais: Classificação Supervisionada - Treinamento**

- Objetivo do treinamento: definir um padrão de resposta espectral para cada classe a ser classificada na imagem, a partir de estatísticas
- A qualidade do processo de treinamento determina o sucesso do processo de classificação

## **Classificação em imagens multiespectrais: Supervisionada - Definição das classes**

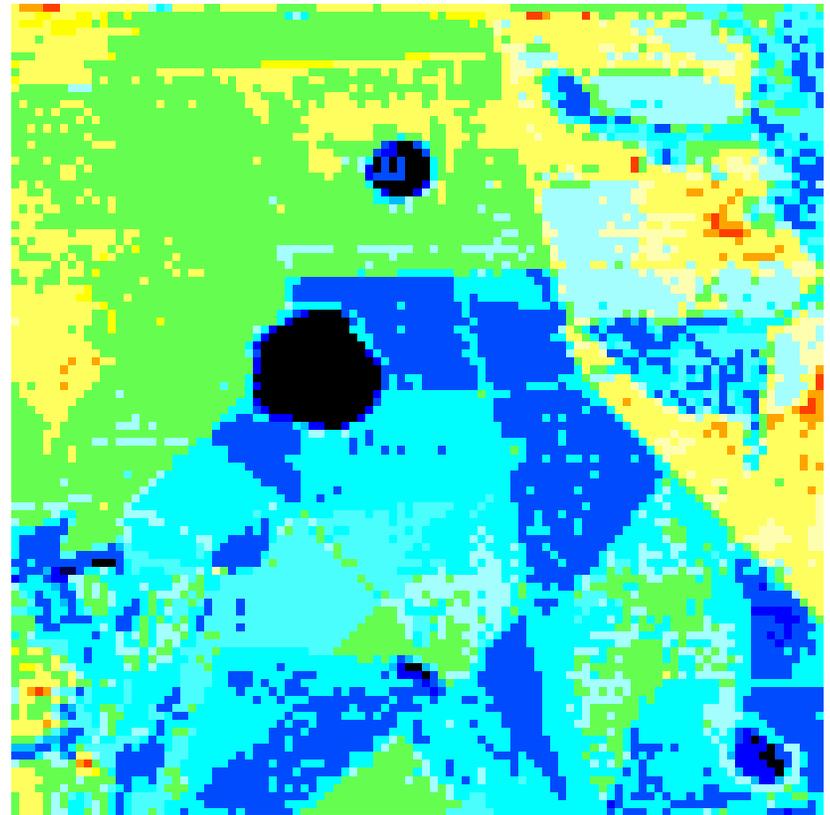
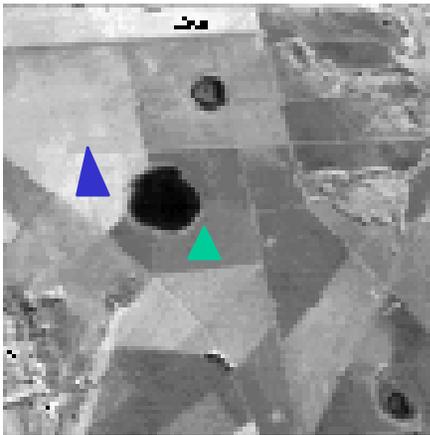
- Definição das classes:
  - pelas necessidades do usuário
  - impostas pela região/aplicação

## **Classificação em imagens multiespectrais: Classificação Supervisionada - Treinamento**

- **Treinamento ou supervisão:**  
a partir de amostras das classes conhecidas e identificadas na imagem, escolhidas com base no conhecimento (teórico do comportamento espectral dos alvos ou prático adquiridos de trabalhos de campo, análise de foto- aérea, etc.) que se tem da área.

# Classificação em imagens multiespectrais: Classificação Supervisionada - Treinamento

- Treinamento



# **Classificação em imagens multiespectrais: Classificação Supervisionada - Regras de decisão**

- Regras (superfícies) de decisão:
  - Objetivos (em função das imagens disponíveis):
    - garantir a separabilidade das classes
    - permitir a classificação de novos pixels

# **Classificação em imagens multiespectrais: Classificação Supervisionada - Regras de decisão**

- Regras (superfícies) de decisão:
  - Necessidades:
    - algoritmo de classificação
    - medida de distância entre as classes
    - valores limites (“threshold values”)

## **Classificação em imagens multiespectrais: Supervisionada - Escolha do algoritmo**

- Escolha do algoritmo de classificação  $\leq$  regras de decisão
  - Paramétricas: conhecidas as propriedades estatísticas das classes (vetores de média, matriz de covariância, etc.)
  - Não paramétricas: funções não lineares ou subdivisão geométrica/matemática do espaço de feições

## Classificação em imagens multiespectrais: Supervisionada - Escolha do algoritmo

- Escolha do algoritmo (regras de decisão) de classificação:
  - paramétricas: máxima verossimilhança, Bayes, Ward
  - não paramétricas: paralelepípedo, centróide (MNM), vizinho mais distante, vizinho mais próximo (k-NN)

## **Classificação em imagens multiespectrais: Supervisionada - Escolha da medida de distância**

- Escolha da medida de separação (distância) entre as classes (no espaço de atributos):
  - Euclidianas: angular, city block
  - Estatísticas: Mahalanobis, divergência, Bhattacharya, Jeffreys - Matusita

## **Classificação em imagens multiespectrais: Supervisionada - Escolha dos valores limites**

- Escolha dos valores limites (“threshold values”):
  - máxima distância admissível para classificar um pixel numa determinada classe
    - distância geométrica
    - número de desvios padrões referentes àquela classe

## Classificação em imagens multiespectrais: Supervisionada - Exemplos regras de decisão

- Exemplos de regras de decisão:

- máxima verosimilhança:

$$\underline{X} \in w_i \text{ se } p(\underline{X} \mid w_i) P(w_i) > p(\underline{X} \mid w_k) P(w_k), i \neq k$$

- vizinho mais próximo: :

$$\underline{X} \in w_i \text{ se } \text{dist} \mid \underline{X} - (\underline{m}_w)_i \mid \text{ é mínima}$$

# Classificação em imagens multiespectrais: Superv. - Algoritmo Máxima Verossimilhança

## MLHD Classification

- Distance definition: statistical (Mahalanobis distance)
- MLHD decision rule (classification criterion)
- Threshold value:  $\chi^2_{N,(1-\alpha)}$ 
  - acceptable probability range
  - number of features

**Condition:**

Gaussian distribution

**Advantage:**

accounts for shape of cluster

**Disadvantage:**

computing intensive

# Classificação em imagens multiespectrais: Superv. - Algoritmo Máxima Verossimilhança

## MLHD Classification -2-

### Point no. 2:

geometrical  
distance:

$$I_u < I_c$$

$$I_u > I_s$$

class "S"

statistical  
distance:

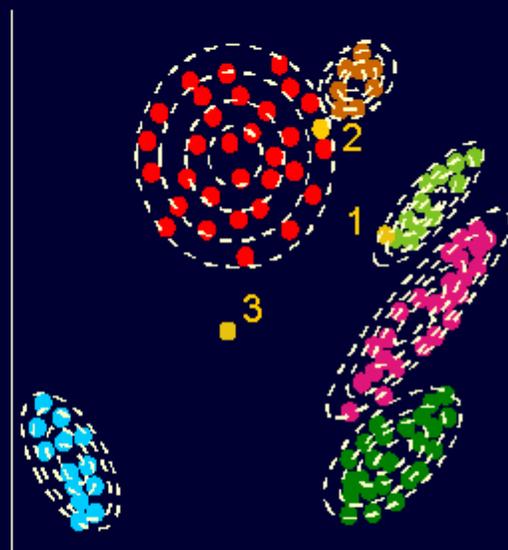
$$d_u^2 \ll d_c^2$$

$$d_u^2 < d_s^2$$

class "U"

$$\text{with } \ln[P(\underline{X}_2 | u)] > \ln[P(\underline{X}_2 | s)]$$

Digital number band 3



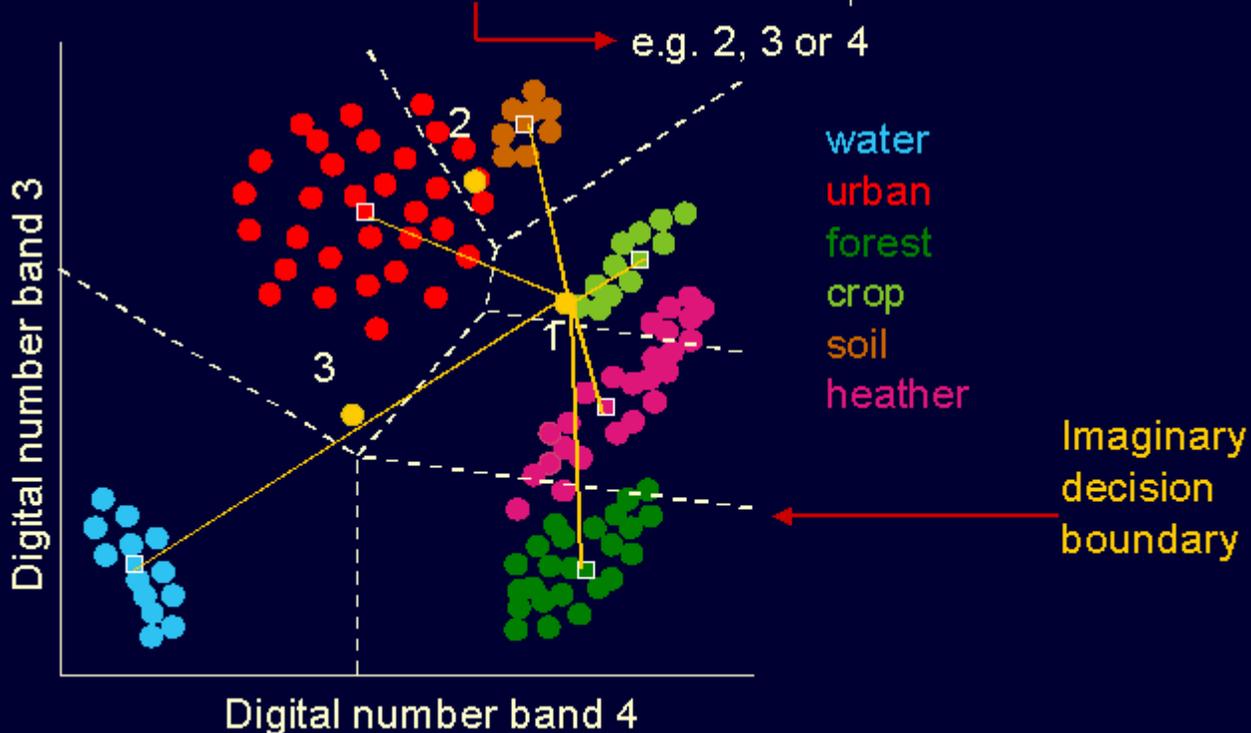
Digital number band 4

water  
urban  
forest  
crop  
soil  
heather

# Classificação em imagens multiespectrais: Superv. - Algoritmo Mínima Distância

## MDM Classification

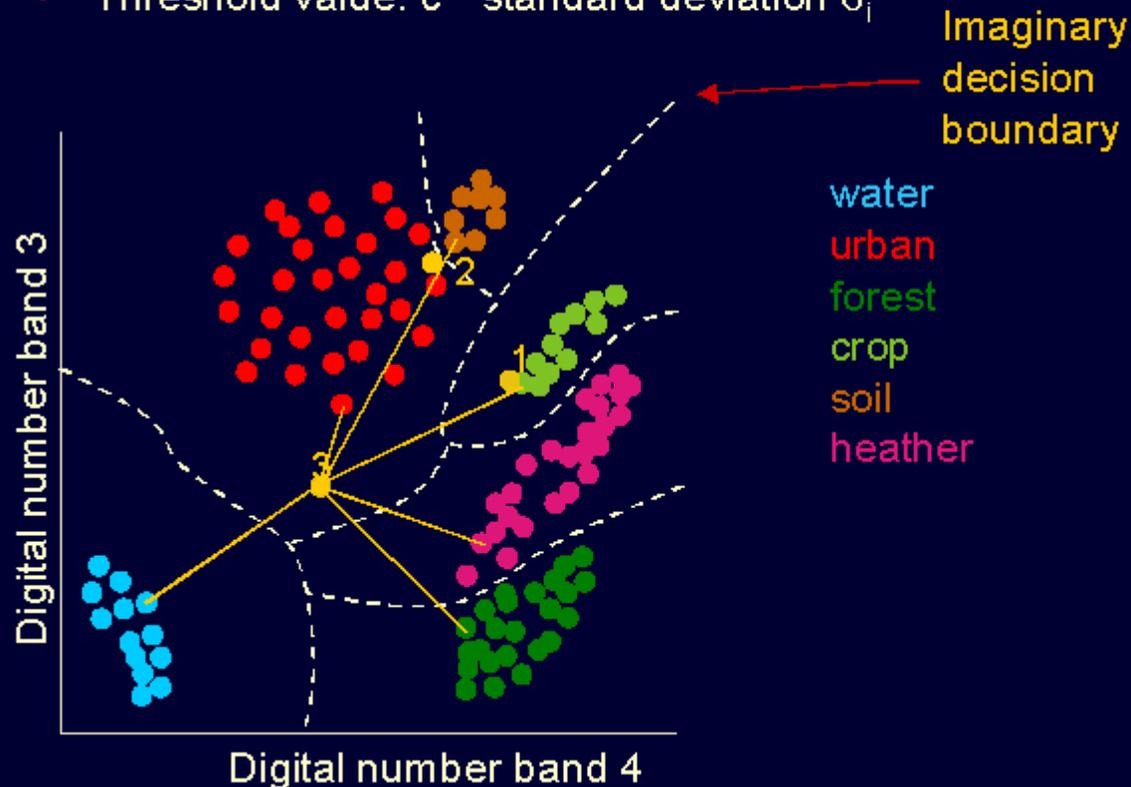
- Distance definition: geometrical (Euclidean distance)
- MDM decision rule (classification criterion)
- Threshold value:  $c * \text{standard deviation } \sigma_i$



# Classificação em imagens multiespectrais: Superv. - Algoritmo Vizinho Mais Próximo

## NN Classification

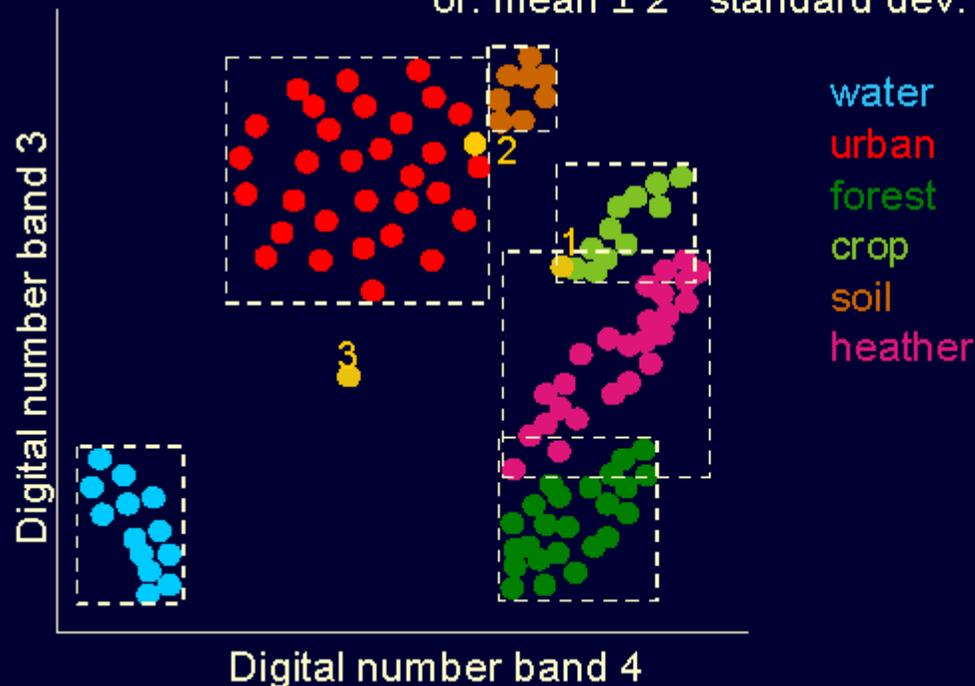
- Distance definition: geometrical (Euclidean)
- 1-NN classification criterion
- Threshold value:  $c * \text{standard deviation } \sigma_i$



# Classificação em imagens multiespectrais: Superv. - Algoritmo Paralelepípedo

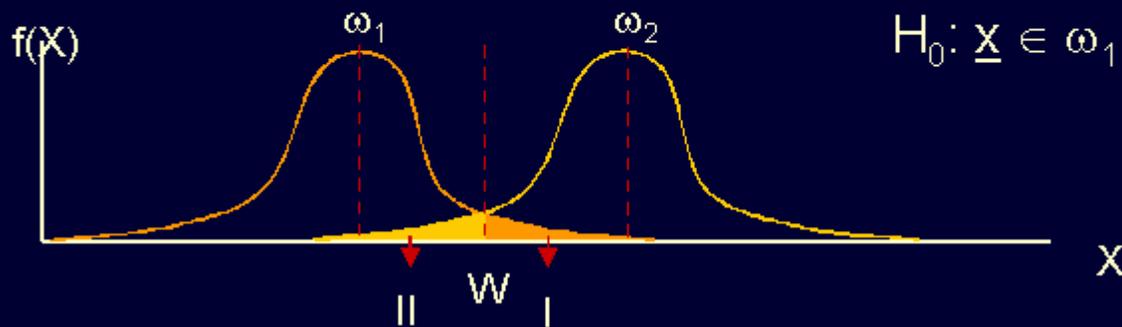
## Box Classification

- Distance definition: point coordinates in the feature space
- Parallelepiped (box) classification criterion
- Threshold value: min-max per class  
lower-upper boundary  
or: mean  $\pm 2$  \* standard dev.  $\sigma_i$



# Classificação em imagens multiespectrais: Supervisionada - Avaliação da classificação

## Classification Accuracy



Assume we are concerned with class  $\omega_1$ .

$I =$  probability called size of a type I error,  
meaning that the null hypothesis is rejected when it is true.

$II =$  probability called size of a type II error,  
meaning that the null hypothesis is accepted when it is false.

$I =$  error of omission

$1-I =$  accuracy

$II =$  error of commission

$1-II =$  reliability

# Classificação em imagens multiespectrais: Superv. - Avaliação da classificação

## Confusion Matrix

unknown ← **Classification result "LABELLING"**

Ground truth "TRUE"	$\omega_0$	$\omega_1$	$\omega_2$	$\omega_3$	$\omega_4$	$\omega_5$	$\omega_6$	Total
$\omega_1$	117	<b>897</b>	308	75	65	17	33	1512
$\omega_2$	72	65	<b>347</b>	141	105	0	26	756
$\omega_3$	56	0	7	<b>110</b>	131	3	71	378
$\omega_4$	36	0	0	18	<b>117</b>	32	49	252
$\omega_5$	105	2	0	101	127	<b>294</b>	127	756
$\omega_6$	38	0	0	3	12	0	<b>325</b>	378
Total	424	964	662	448	557	346	631	4032

Accuracy  $\omega_1 =$   
 $897/1512 * 100\% = 59.3\%$

Error of omission =  
 $1 - \text{accuracy: } \omega_1 \rightarrow 40.7\%$

Error of commission  $\omega_1 =$   
 $67/964 * 100\% = 7.0\%$

Total classification accuracy:  
 $100\% * (897+347+110+117+294+325)/4032 = \mathbf{51.8\%}$

"TRUE"	Accuracy (%)	Omission (%)	Commission (%)
$\omega_1$	59.3	40.7	7.0
$\omega_2$	45.9	54.1	47.6
$\omega_3$	29.1	70.9	75.4
$\omega_4$	46.4	53.6	79.0
$\omega_5$	38.9	61.1	15.0
$\omega_6$	86.0	14.0	48.5

## **Classificação em imagens multiespectrais: Supervisionada - Avaliação da classificação**

- Avaliação da classificação:
  - homogeneidade da amostra de treinamento
  - concordância entre o que é conhecido e o resultado da classificação (Qui-quadrado, Kappa)

# Classificação em imagens multiespectrais: Supervisionada - Avaliação da classificação

## Summary

Rows → size of a type I error  
error of omission

Columns → size of a type II error  
error of commission

1 - I: accuracy ("nauwkeurigheid")  
% of a class, which is classified correctly

1 - II: reliability ("betrouwbaarheid")  
% of the pixels assigned to a class,  
which really belong to that class

**Example:**

$\omega_1$ : the classification accuracy of class  $\omega_1$  is only moderate (59.3%), but the reliability of the classification result is large (93.0%).

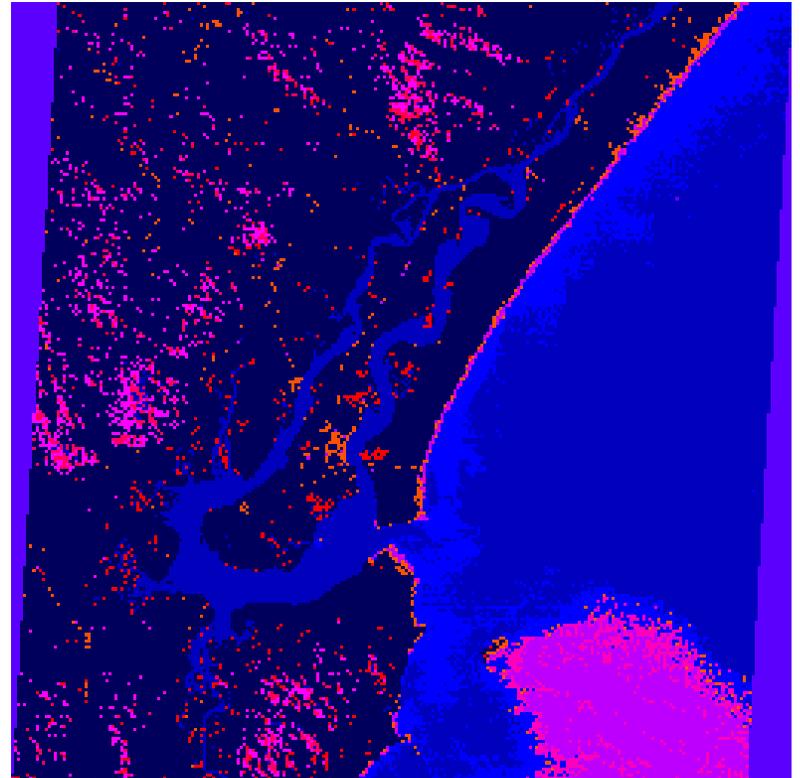
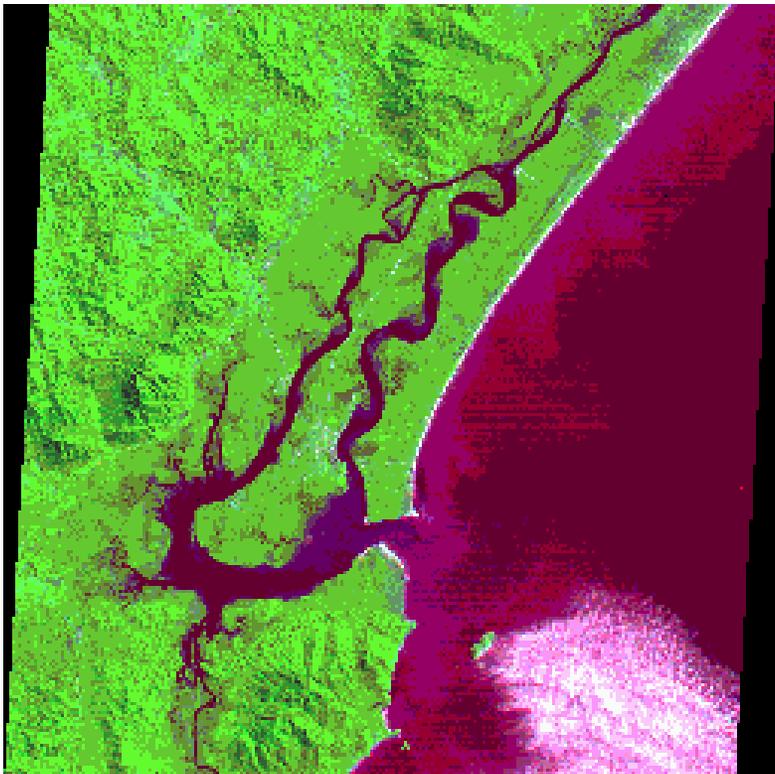
$\omega_6$ : the classification accuracy of class  $\omega_6$  is large (86.0%), but the reliability of the result is moderate (51.5%).

# Classificação em imagens multiespectrais

- Classificação não supervisionada
  - classes espectrais
  - algoritmo de classificação (agrupamento)
    - medidas de similaridade
    - número de classes e de iterações é fornecido pelo usuário
  - interpretação das classes geradas
  - normalmente precede a supervisionada

# Classificação em imagens multiespectrais

- Classificação não-supervisionada



# Classificação em imagens multiespectrais

- Classificação não supervisionada
  - segmentação
    - definição do número de classes
  - escolha do algoritmo de classificação
    - definição do número de iterações
  - interpretação das classes geradas
  - avaliação da classificação e possível reprocessamento

# **Classificação em imagens multiespectrais: Classificação não supervisionada - Segmentação**

- Segmentação em imagens:

“Identificação das características relevantes existentes na imagem.”

## **Classificação em imagens multiespectrais: Classificação não supervisionada - Segmentação**

- Segmentação em imagens:
  - Divide-se a imagem em regiões, que devem corresponder às áreas de interesse da aplicação (“mosaico”)
  - Regiões: conjunto de pixels contíguos, cujas características de atributos (nível de cinza) são uniformes (semelhantes) e se espalham bidirecionalmente

## **Classificação em imagens multiespectrais: Classificação não supervisionada - Segmentação**

- Segmentação em imagens - alguns dos possíveis processos de segmentação são:
  - crescimento de regiões
  - detecção de bordas
  - detecção de bacias

## **Classificação em imagens multiespectrais: Não superv. - Segmentação/Crescimento de regiões**

- Crescimento de regiões: condições
  - as regiões devem ser espacialmente adjacentes
  - serão unidas se:
    - tem o vetores médios semelhantes (dentro de um limiar estabelecido)
    - são mutuamente próximas

## **Classificação em imagens multiespectrais: Não superv. - Segmentação/Crescimento de regiões**

- **Crescimento de regiões:**

Critério para a união de duas regiões vizinhas A e B:

- A e B são similares (teste das médias);
- a similaridade satisfaz o limiar estabelecido;
- A e B são mutuamente próximas (dentre os vizinhos de A, B é a mais próxima, e dentre os vizinhos de B, A é a mais próxima).
- Se A e B satisfazem os critérios acima, estas regiões são agregadas, caso contrário, o sistema reinicia o processo de teste de agregação

## **Classificação em imagens multiespectrais: Não superv. - Segmentação/Deteção de bacias**

- Deteção de bacias:
  - é feita a partir de uma imagem resultante da extração de bordas
  - Ex.: filtro de Sobel. Este algoritmo considera os gradientes de nível de cinza da imagem original, para gerar uma imagem gradiente ou imagem de intensidade de borda

## **Classificação em imagens multiespectrais: Não superv. - Segmentação/Detecção de bacias**

- Detecção de bordas:
  - determina o que é borda a partir de um limiar a partir do qual começa a perseguição de bordas
  - observa na vizinhança, o próximo "pixel" de maior valor de nível digital e segue-se nesta direção, até que se encontre outra borda

## **Classificação em imagens multiespectrais: Não superv. - Segmentação/Detecção de bordas**

- Detecção de bordas:
  - deste processo gera-se uma imagem binária com os valores de 1 referentes às bordas e 0 para as regiões de não-bordas.
  - a imagem binária será rotulada de modo que as porções da imagem com valores 0 constituam regiões limitadas pelos valores 1 da imagem, formando a imagem rotulada

# K-MÉDIAS

## (Algoritmo de Agrupamento k-média)

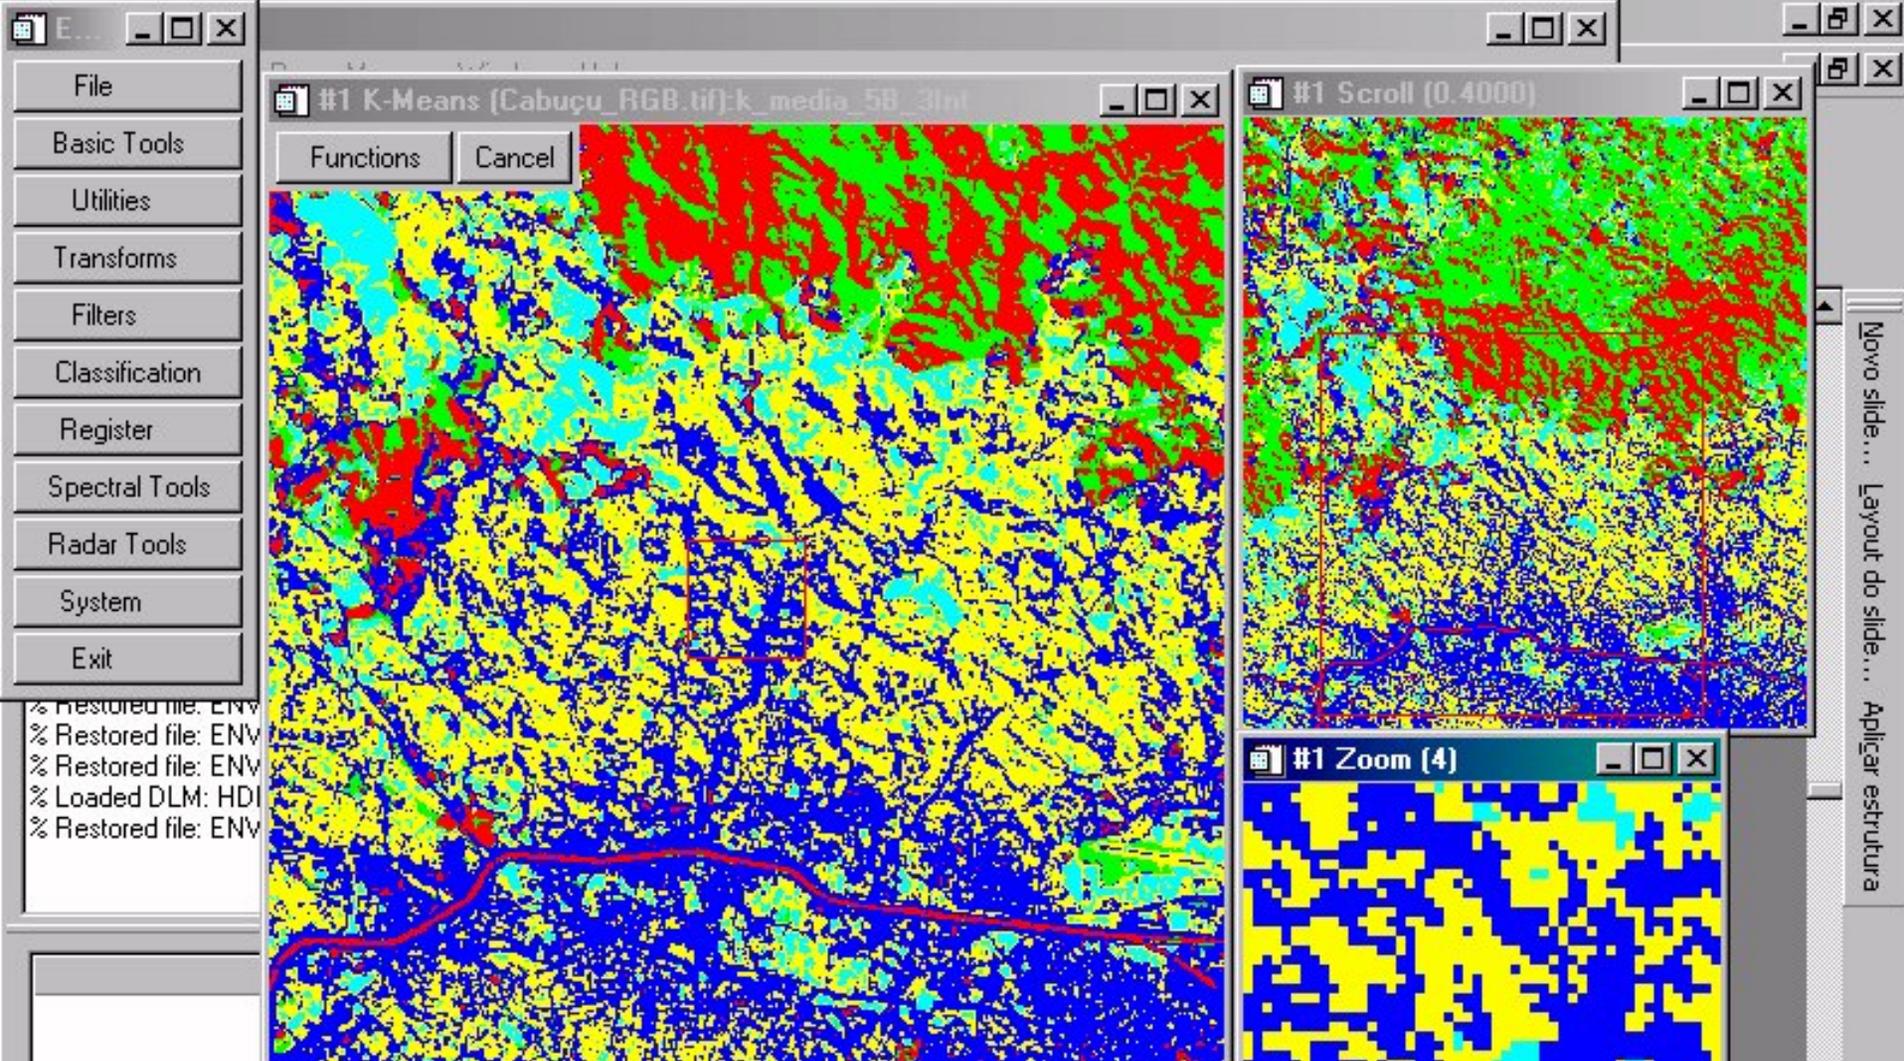
Método não hierárquico de agrupamento que considera o número de componentes da população inicial igual ao número exigido no final dos agrupamentos. Nesta etapa o número final de agrupamentos é escolhido tal que os pontos estejam separadas o máximo possível. Cada componente da população é avaliado e enquadrado num dos agrupamentos, levando em conta a distância mínima. A posição do centróide é continuamente recalculada e deslocada (média móvel) até que todos os elementos estejam agrupados segundo o número pré-definido de classes.

## O que é um agrupamento de k-média

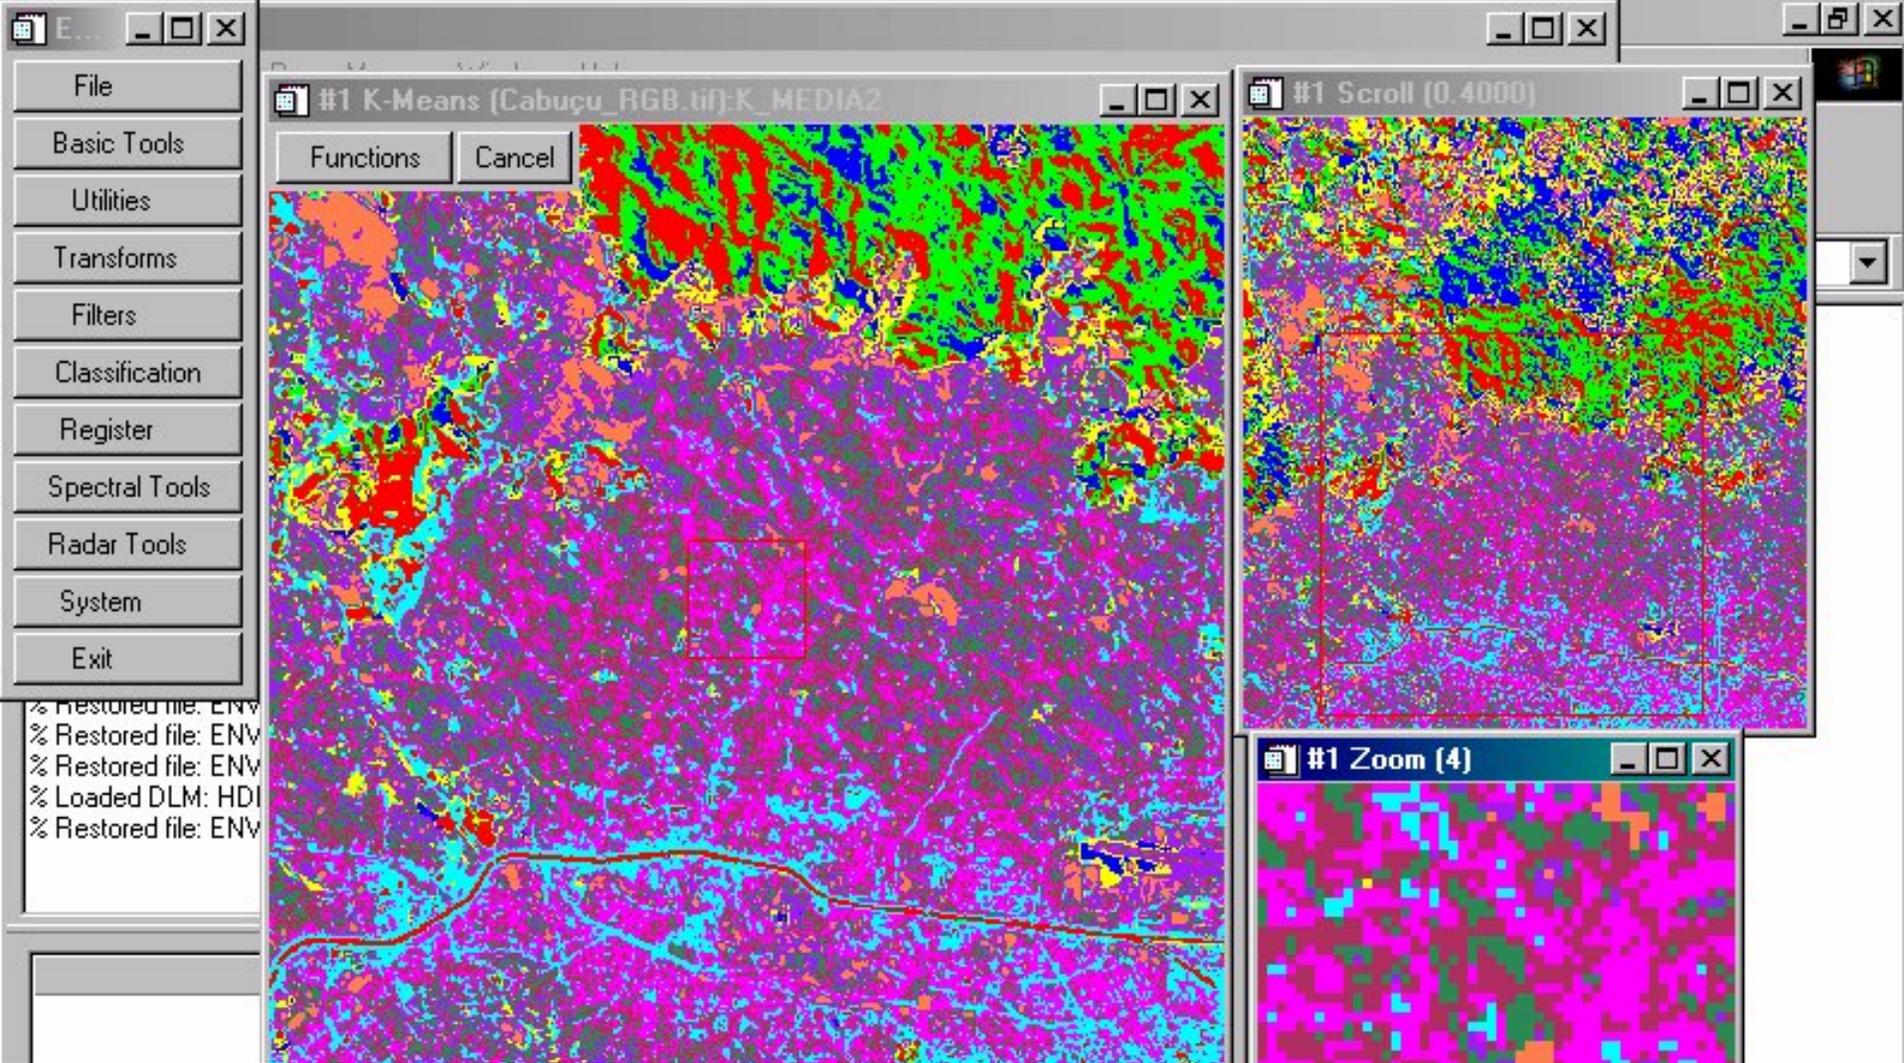
- São diversas as variantes do algoritmo de agrupamento pelo k-medias, mas a maior parte deles envolve um esquema iterativo que opera sobre um número fixo de agrupamentos, que atendam satisfatoriamente as seguintes propriedades:
  - - Cada classe tem um centro que é a posição média de todas as amostras da classe;
  - - Cada amostra está em uma classe cujo centro está mais próximo a ele.

## Parâmetros e opções para o algoritmo k-media

- Número de classes
- Inicialização
- Medida de distância
- Terminação
- Qualidade
- Paralelismo
- Distância
- Condições de finalização do processo



**Resultado do Algoritmo k-media  
5 classes - 3 interações**



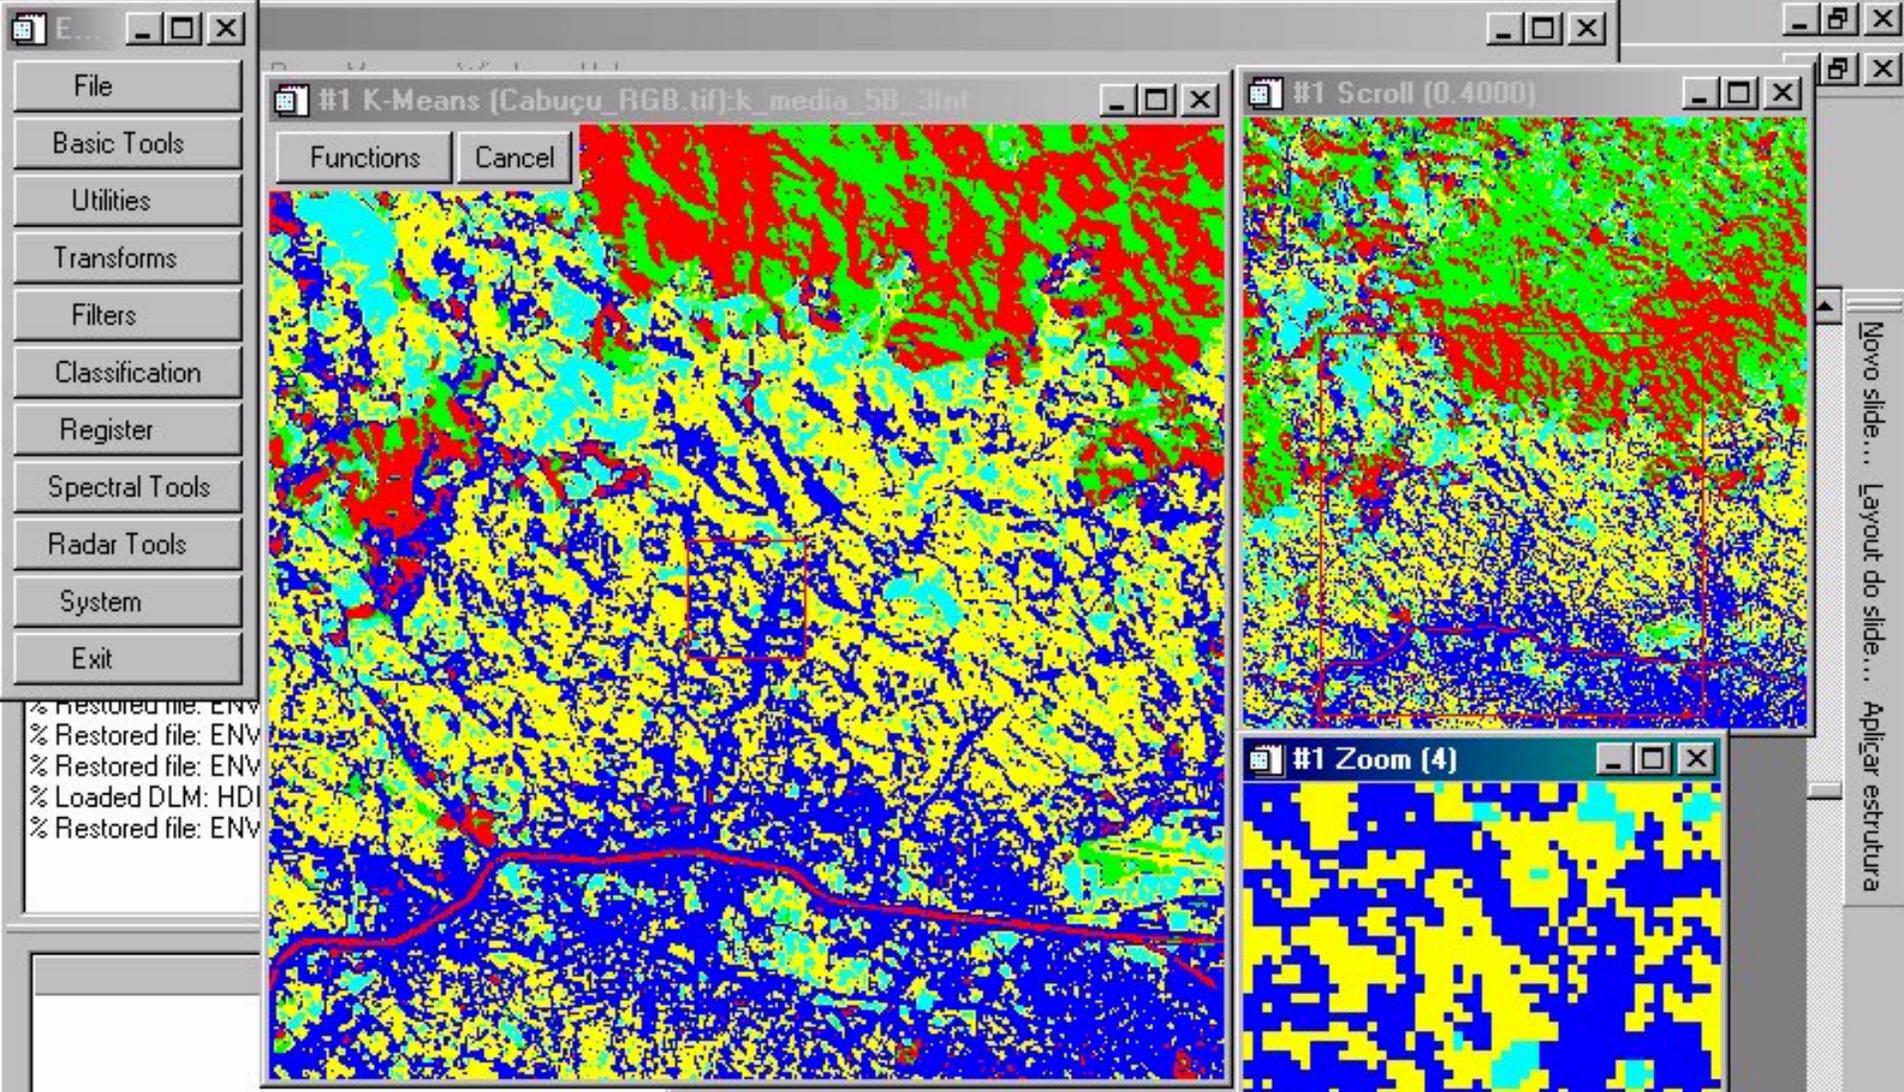
**Resultado do Algoritmo k-media  
10 classes - 3 interações**

# ISODATA

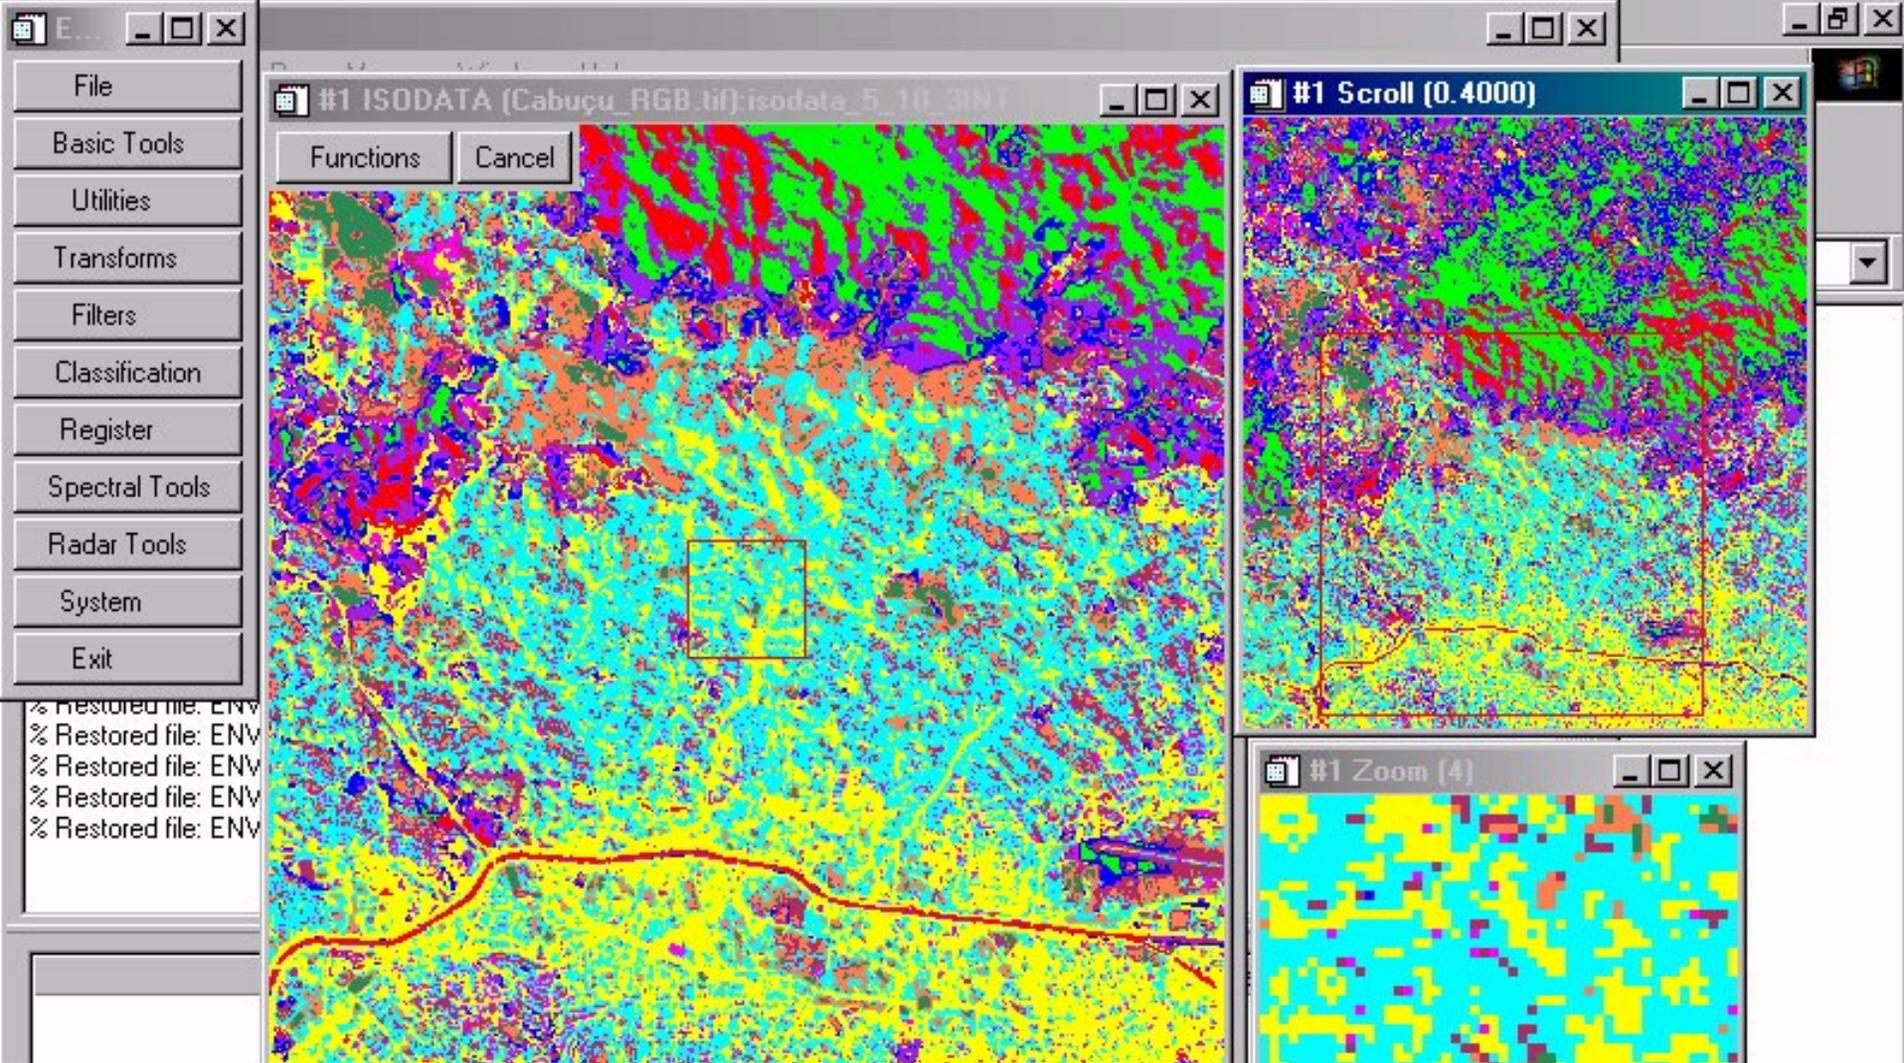
O isodata padrão é um algoritmo que começa selecionando agrupamentos a partir de centros introduzidos no espaço multidimensional dos dados. Cada pixel se agrupa em um dos agrupamento criados, baseando-se na minimização de uma função de distância entre o pixel e os centros de cada agrupamento. Depois de cada repetição, são atualizadas as médias dos agrupamentos, e estes podem se separar ou se mesclar, dependendo do tamanho e do espalhamento dos dados em relação aos agrupamentos.

# ISODATA

- O algoritmo ISODATA é um método iterativo que usa a distância euclidiana como a medida de semelhança para agrupar elementos de dados em classes diferentes



Resultado do Algoritmo Isodata  
5 classes - 3 interações



**Resultado do Algoritmo Isodata  
5 - 10 classes - 3 interações**

1 objeto(s) selecionado(s)

28,0KB

Meu computador



# Outros Classificadores

- Ioseg (Mahalanobis)
- Ecognition (Segmentação textural)

# Classificação em imagens multiespectrais

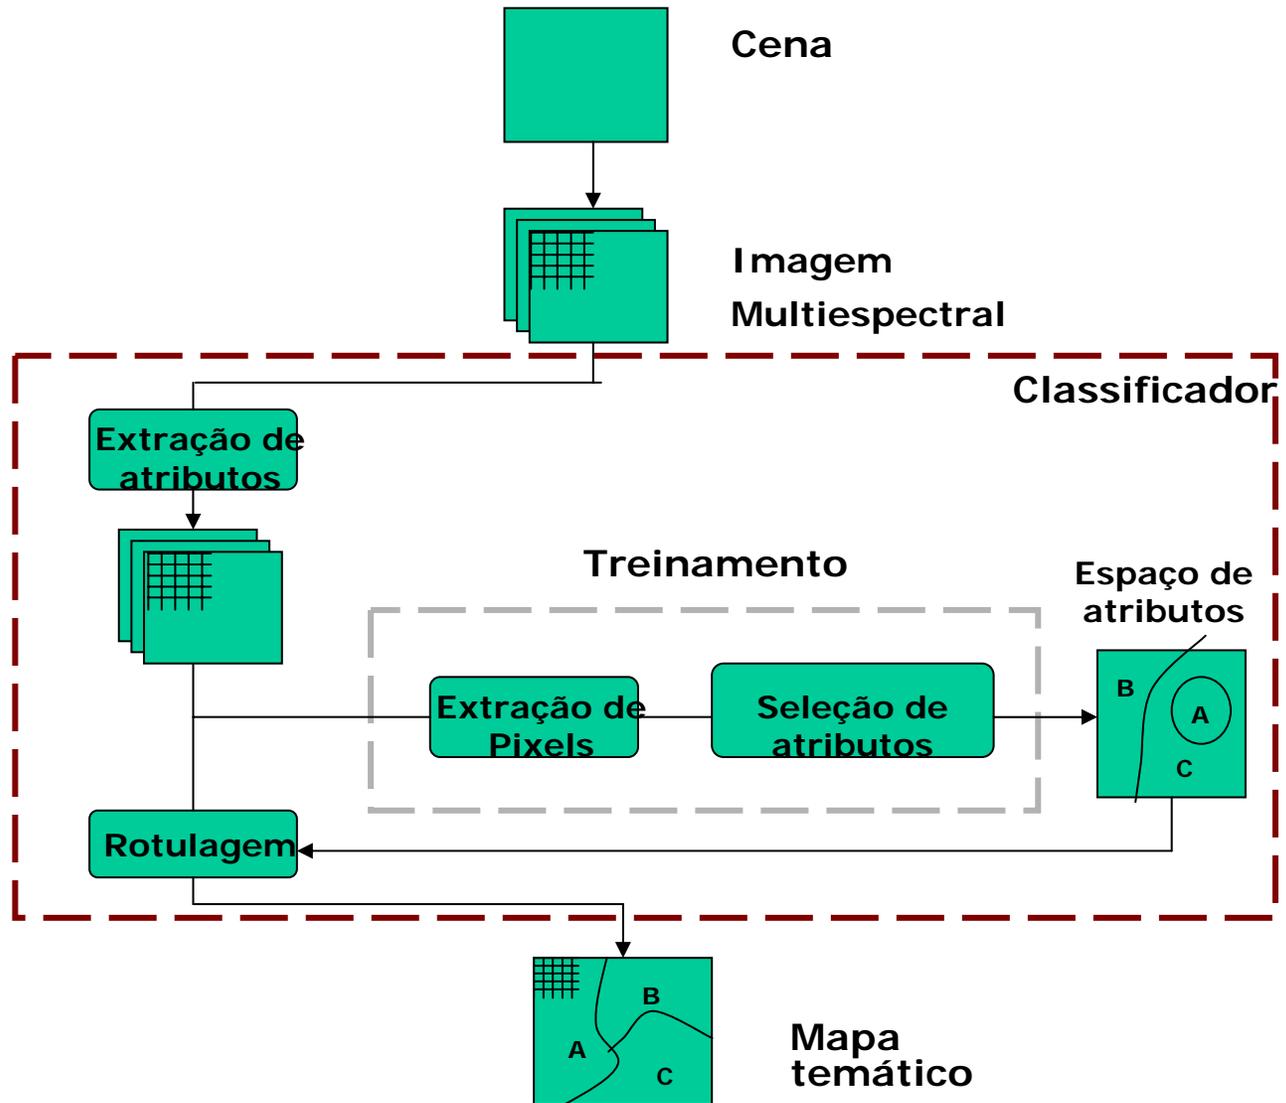
- Supervisionada: uso de amostras de campo e/ou áreas de treinamento
- Não supervisionada: sem informação de campo

# Classificação em imagens multiespectrais

Passos para a classificação:

- escolha das regras de decisão
- subdivisão do espaço de feições
- atribuição de um nome a todos os pixels da imagem de acordo com a sua posição no espaço de feições
- avaliação da classificação resultante através da análise dos padrões espaciais no espaço de imagem
- se necessário, ajustar o resultado da classificação

# Classificação em imagens multiespectrais: Processo de classificação



# Classificação em imagens multiespectrais

- Etapas da classificação:
  - Classificação (baseada em) por objetos: exige segmentação
    - abstração
    - encapsulamento
    - polimorfismo
    - hierarquia ou herança

# Classificação em imagens multiespectrais

- Etapas da classificação:
  - Classificação por objetos:
    - Abstração: consiste na concentração nos aspectos essenciais, próprios, de uma entidade e em ignorar suas propriedades acidentais.

# Classificação em imagens multiespectrais

- Etapas da classificação:
  - Classificação por objetos:
    - Encapsulamento: também chamado de ocultamento de informações, consiste na separação dos aspectos externos de um objeto, acessíveis por outros objetos, dos detalhes internos da implementação daquele objeto, que ficam ocultos dos demais objetos.

# Classificação em imagens multiespectrais

- Etapas da classificação:
  - Classificação por objetos:
    - Polimorfismo: significa que a mesma operação pode atuar de modos diversos em classes diferentes. As operações podem atuar de forma diferente em classes diferentes.

# Classificação em imagens multiespectrais

- Etapas da classificação:
  - Classificação por objetos:
    - Hierarquia ou herança: a herança da estrutura de dados e do seu comportamento permite que a estrutura comum seja compartilhada por diversas subclasses semelhantes sem redundâncias

# Reconhecimento de Padrões

- A habilidade do ser humano em *reconhecer e classificar objetos* sempre impressionou e continua a impressionar os cientistas... Desde os primórdios da computação, a tarefa de implementar algoritmos emulando essa capacidade humana, tem-se apresentado como a mais intrigante



# Reconhecimento de Padrões

- **Algumas definições:**

***“Reconhecimento de padrões é a área de pesquisa***

***que tem por objetivo a classificação de objetos (padrões) em um número de categorias ou classes.”***

*(Sergios Theodoridis. Pattern Recognition. Academic Press, USA, 1st edition, 1999)*

*“É a designação de um um objeto físico ou evento para uma de várias categorias pré-especificadas” (Richard O. Duda and Peter E. Hart.*

*Pattern Classification and Scene Analysis. Wiley-Interscience, USA, 1st edition, 1972.)*

# Reconhecimento de Padrões

- Resumindo:

O *Reconhecimento de Padrões (RP)* é a ciência que trata da *classificação e descrição de objetos*.

# Reconhecimento de Padrões

- **Algumas Aplicações:** (Por Anil K. Jain, Robert P. W. Duin, e Jianchang Mao.)
  - bio-informática, análise de seqüências de proteínas ou DNA;
  - mineração de dados (data mining), procurando por padrões significativos em espaços multi-dimensionais;
  - classificação de documentos de Internet;
  - análise de imagens de documentos para reconhecimento de caracteres (Optical Character Recognition - OCR);
  - inspeção visual para automação industrial;
  - busca e classificação em base de dados multimídia;
  - reconhecimento biométrico, incluindo faces, íris ou impressões digitais;
  - reconhecimento de fala.

# Reconhecimento de Padrões

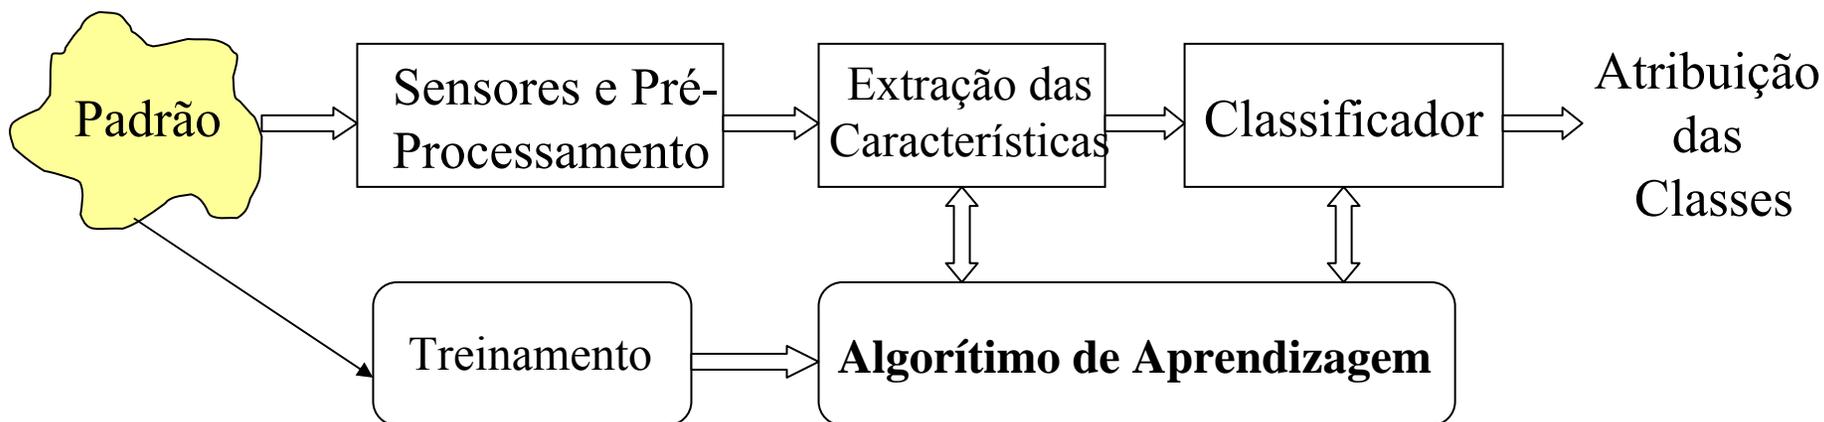
- Um ponto em comum entre essas aplicações é que usualmente as características disponíveis nos padrões de entrada, que tipicamente são milhares, não são diretamente utilizadas. Normalmente são utilizadas características extraídas dos padrões de entrada otimizadas usando-se procedimentos guiados pelos dados, como ACP (Análise de Componente Principal).  
*(Shapiro & Stockman, Duda & Hart)*

# Reconhecimento de Padrões

- Fluxo padrão para selecionar as características:



## Componentes de um Sistema de RP

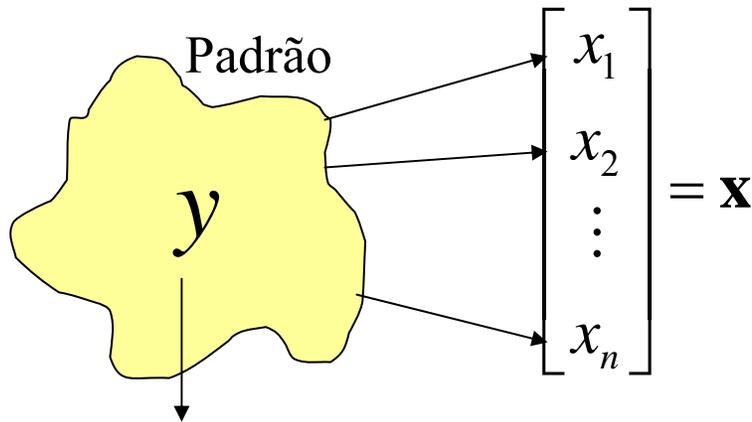


- **Sensores e Pré-Processamento**
- **Extração das Características** aponta para criar características discriminativas boas para classificação..
- **Classificador**
- **Treinamento** provê informações sobre o estado escondido - aprendizado supervisionado
- **O algoritmo de Aprendizagem** Estabelece exemplos de aprendizagem para RP.

# Reconhecimento de Padrões

- **Métodos**: Conforme o tipo de objetos a classificar (ou descrever) seguem os principais métodos ou abordagens (Por Anil K. Jain):
  - **Abordagem estatística**
    - Abordagem clássica, mais antiga, denominada por "Teoria da Decisão". Assume que as características das classes se regem por **modelos probabilísticos**.
  - **Abordagem sintática**
    - Procura descrever a **estrutura** dos padrões usando inter-relações de características descritoras básicas denominadas primitivas.
  - **Abordagem neural**
    - Abordagem tipo "caixa negra" que procura determinar um **mapeamento ótimo** entre entradas e saídas inspirando-se em modelos de neurônios do cérebro.
  - **Abordagem difusa**
    - Abordagem que leva em conta o grau de **incerteza** por vezes inerente as características e as classificações, usando a Teoria dos conjuntos difusos para modelar esse grau de incerteza.

# Conceitos Básicos



Vetor Característico  $\mathbf{x} \in X$

- $X$  é um vetor das observações (medidas).
- $\mathbf{x}$  é um ponto no espaço característico  $X$ .

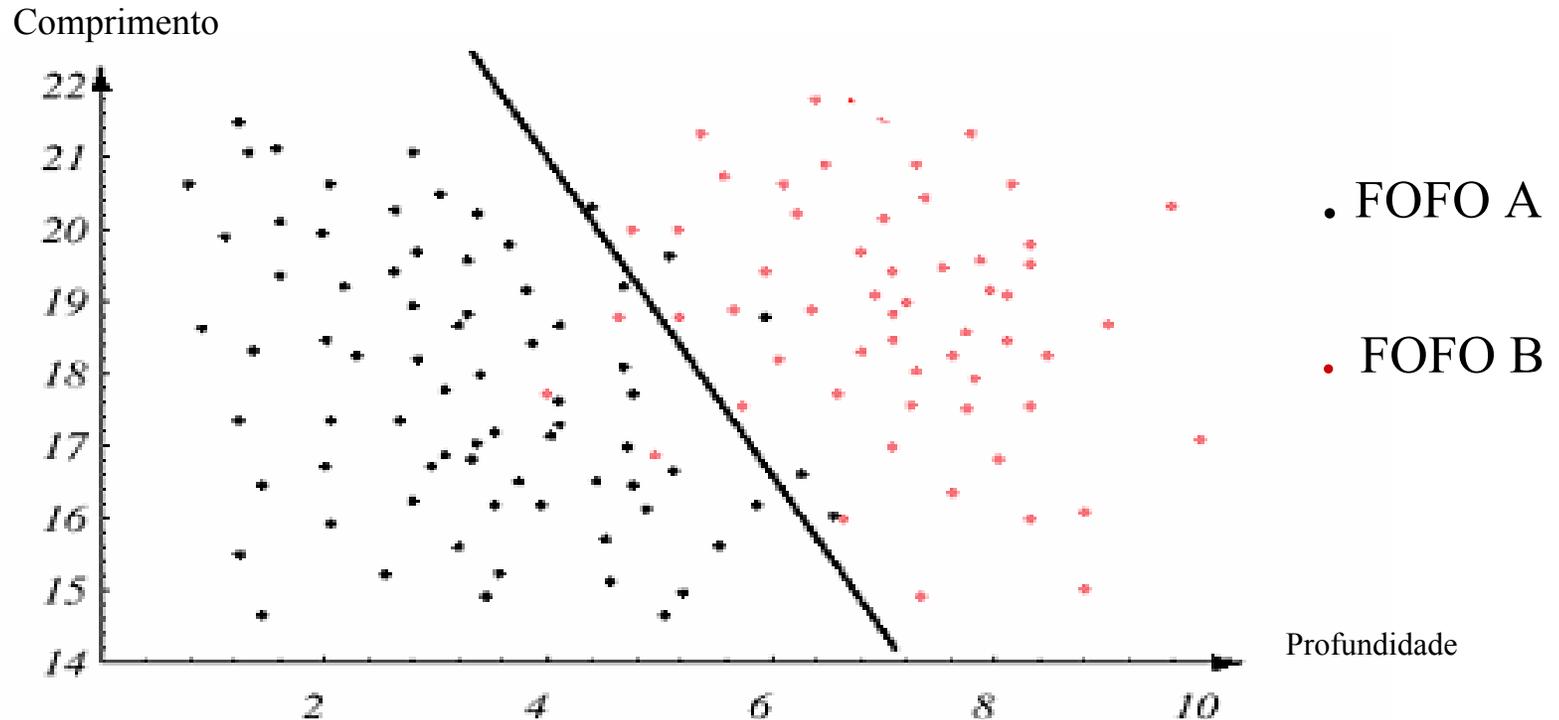
## Estado Escondido

- Não pode ser medido diretamente.
- Padrões com estado escondido iguais pertencem à mesma classe.  $y \in Y$

## Tarefa

- Definir um classificador (Regra de decisão) o qual irá decidir sobre os estados escondidos baseados em observações.

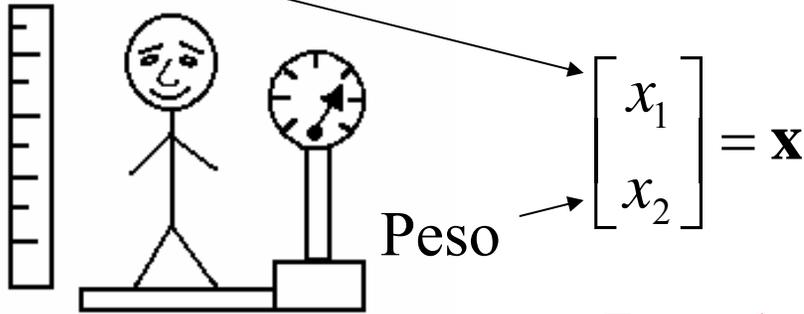
# Exemplo 1 Peças com defeito



Identificadas duas características do defeito, a Profundidade e o Comprimento. A linha escura poderia servir como um limite de decisão de nosso classificador. O erro de classificação global nos dados mostrados é mais baixo do que se usarmos só uma característica, mas ainda haverá alguns erros.

# Exemplo 2 seleção de Jóqueis

Altura



Tarefa: Reconhecimento dos Jóqueis ideais

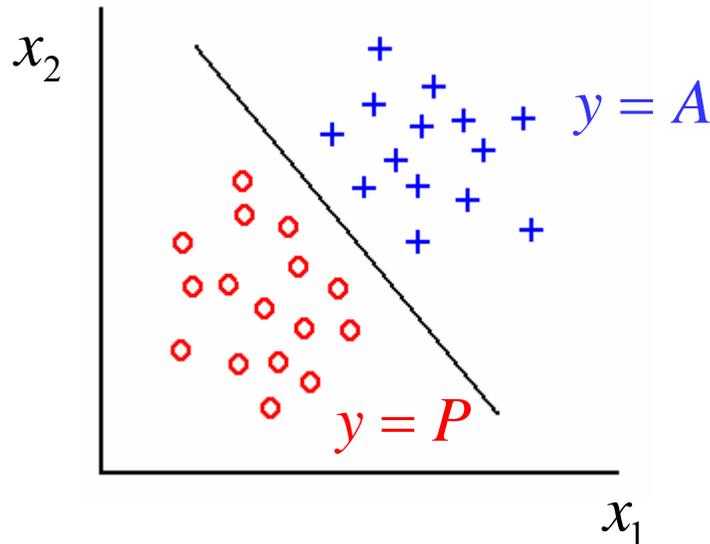
-Um grupo de Estado Escondido é  $Y=\{A,P\}$

-O Espaço característico é  $X$

Exemplo já Definido  $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\}$

+ Alemão

o Japonês

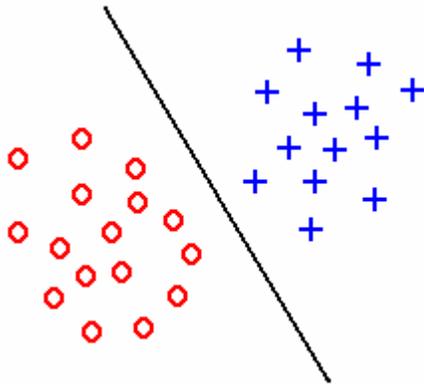


# Extração de Características

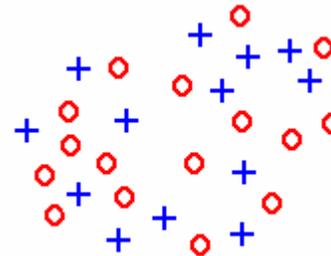
Tarefa: extrair características que são boas para classificação.

Características boas:

- Objetos da mesma classe têm valores de característica semelhantes.
- Objetos de classes diferentes têm valores diferentes.



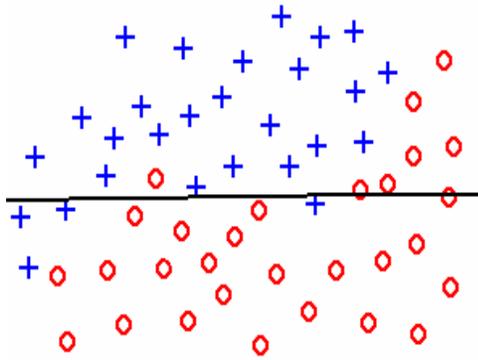
Características “BOAS”



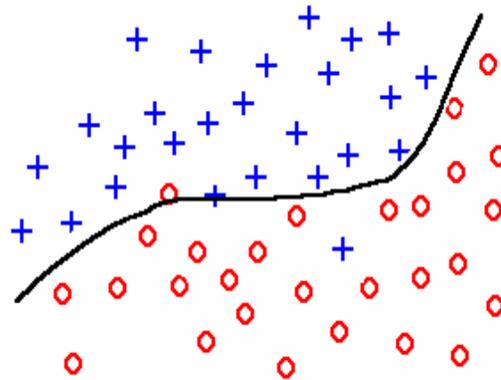
Características “RUINS”

# Extração de Características

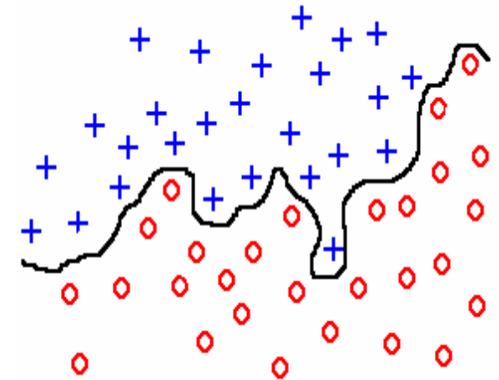
- Qual classificação usar?



Ajuste Baixo



Ajuste Bom

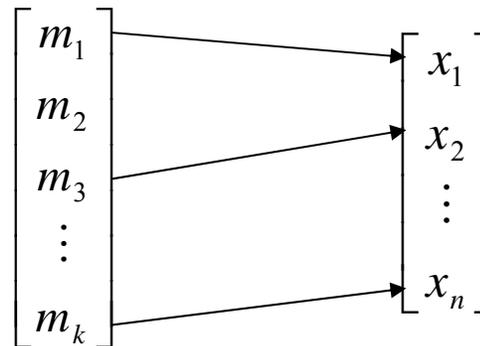
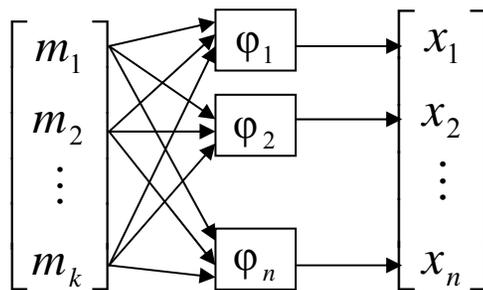


Ajuste Alto

É preciso encontrar o *tradeoff* entre desempenho e simplicidade

# Métodos de Extração de Características

## Extração de Características



## Seleção das Características

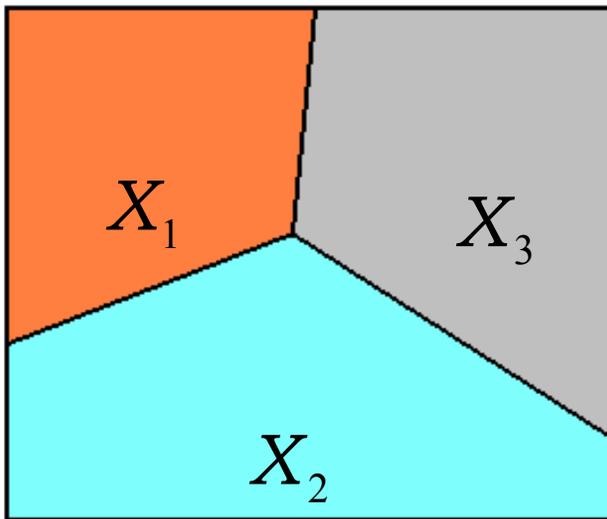
O Problema pode ser expresso como otimizador de parâmetros do extrator de características  $\varphi(\theta)$

**Método Supervisionado:** Padrão de entrada é identificado como um membro de uma classe pré-definida pelos padrões de treinamento, que são rotulados com suas classes. Ou seja, é um padrão já definido.

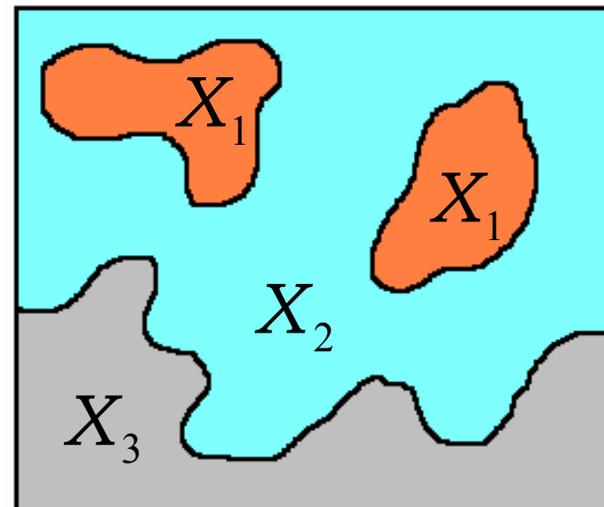
**Método não Supervisionado:** Em que o padrão é associado a uma classe que é aprendida com base na similaridade entre os padrões de treinamento (Ex.: ACP)

# Classificador

Um classificador divide o Espaço Característico  $X$  em regiões de classe “etiquetadas” tal que:



e



A classificação consiste em determinar para qual região um vetor característico  $x$  pertence. São chamadas regiões de decisão as bordas entre os limites de decisão.

# Resumindo

- ❖ **Reconhecimento de Padrões:** *Através de dados não trabalhados, procurar uma categoria de padrões;*
- ❖ O principal objetivo da classificação de padrões é generalizar ou sugerir uma classe de objetos ainda não identificados ou desconhecidos;
- ❖ É preciso encontrar o *tradeoff* entre desempenho e simplicidade;
- ❖ **Componentes do Sistema:** *sensibilidade, segmentação e agrupamento, extração de características, classificação e processamento posterior;*
- ❖ **Aplicando o sistema de reconhecimento de padrões é necessário seguir os seguintes passos:** *Coletar os dados, escolher as características, escolher o modelo, treinamento e avaliação.*

# **Classificação Digital de Imagens**

Alessandra M. Knopik Beltrame

Claudia M. Soares Machado

José Alberto Quintanilha

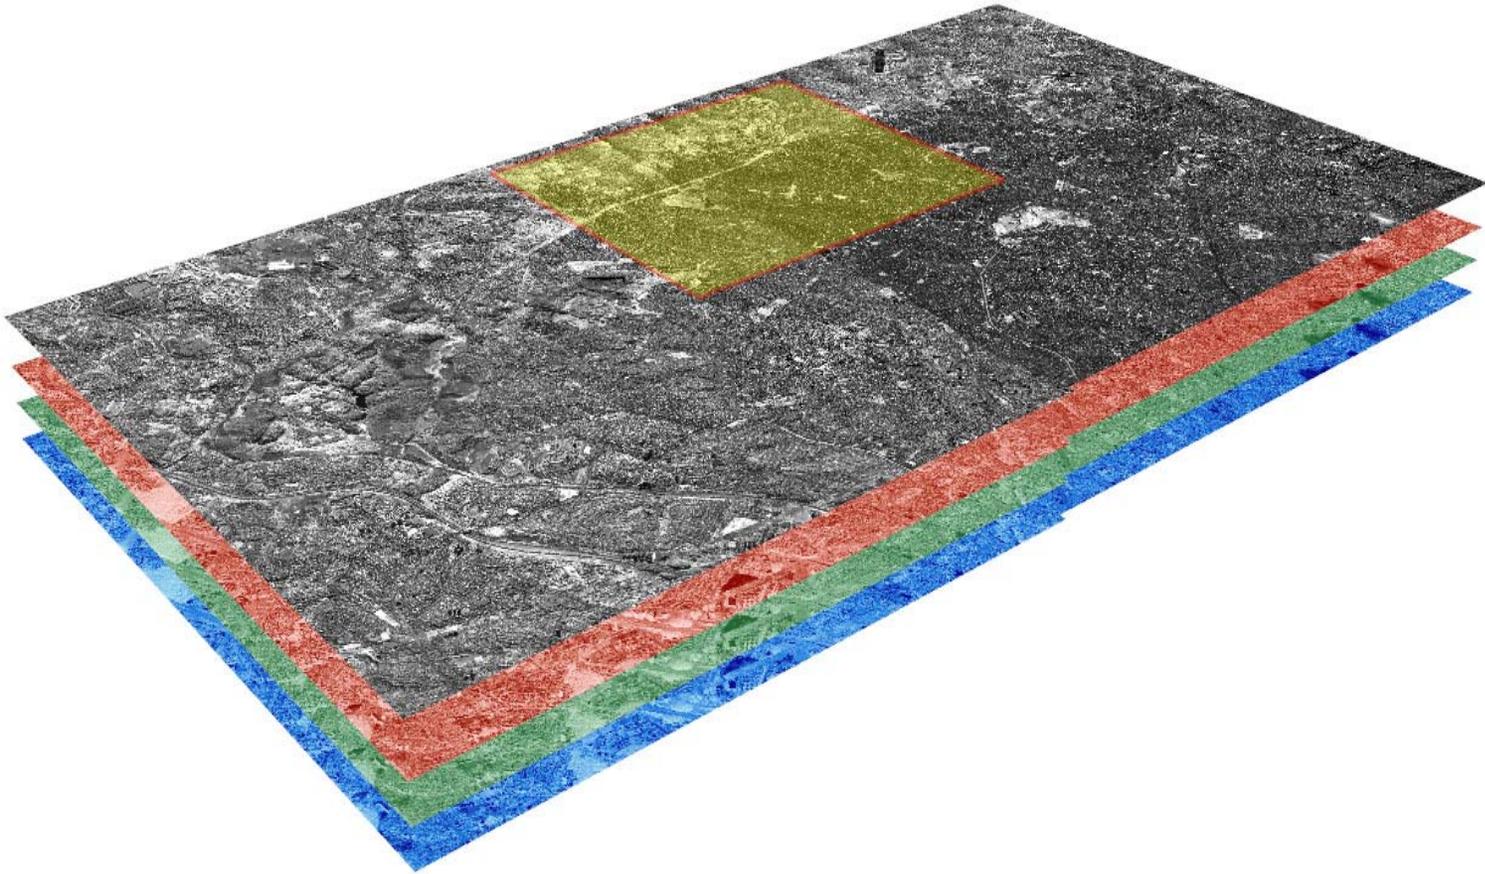
Laboratório de Geoprocessamento – EPUSP

ANPET 2008

# Programa

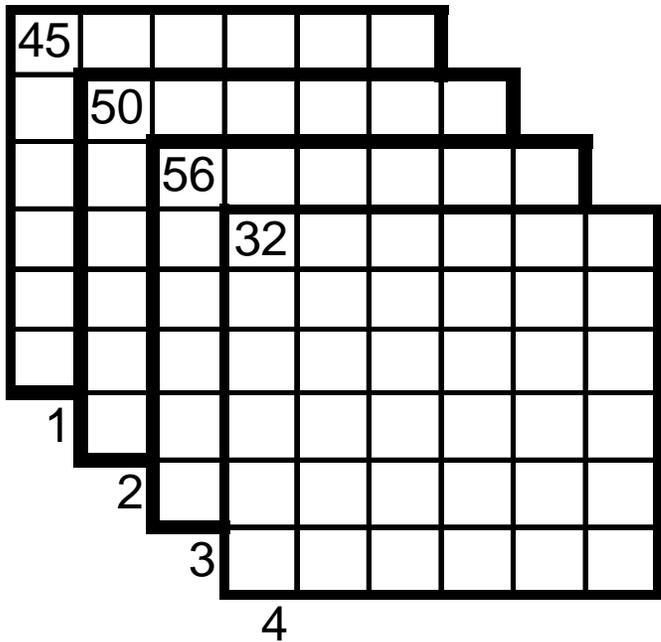
- Conceito básicos
- Classificação Tradicional
  - Classificação Supervisionada
  - Classificação Não-Supervisionada
- Avaliação de Desempenho

# Conceitos



Fonte: Nóbrega, 2007.

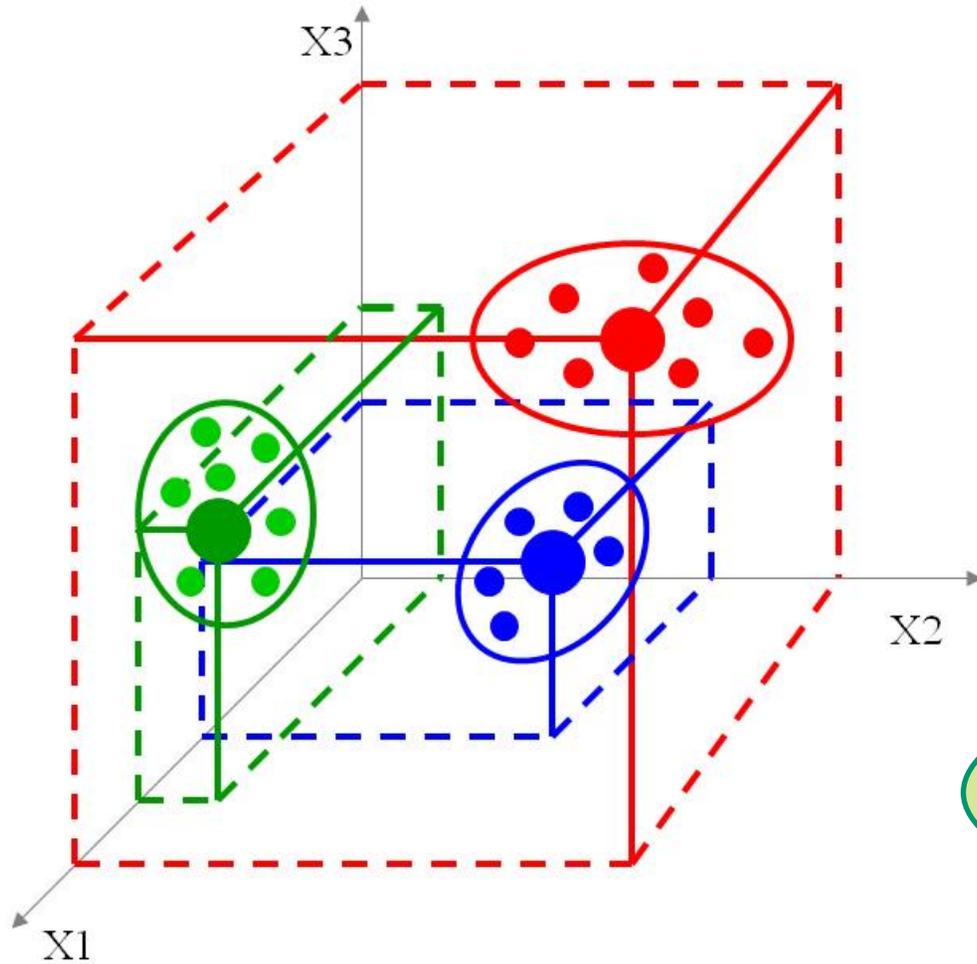
# Conceitos



Vetor padrão do pixel (1,1)

$$\begin{bmatrix} 45 \\ 50 \\ 56 \\ 32 \end{bmatrix}$$

# Conceitos



Vegetação

Água

Área impermeável

Espaço de Atributos

# Classificação

Designação de cada elemento constituinte da imagem a uma determinada classe.

- Enfoque

- Tradicional: pixel a pixel
- Baseada em objeto



Supervisionada

Não – supervisionada

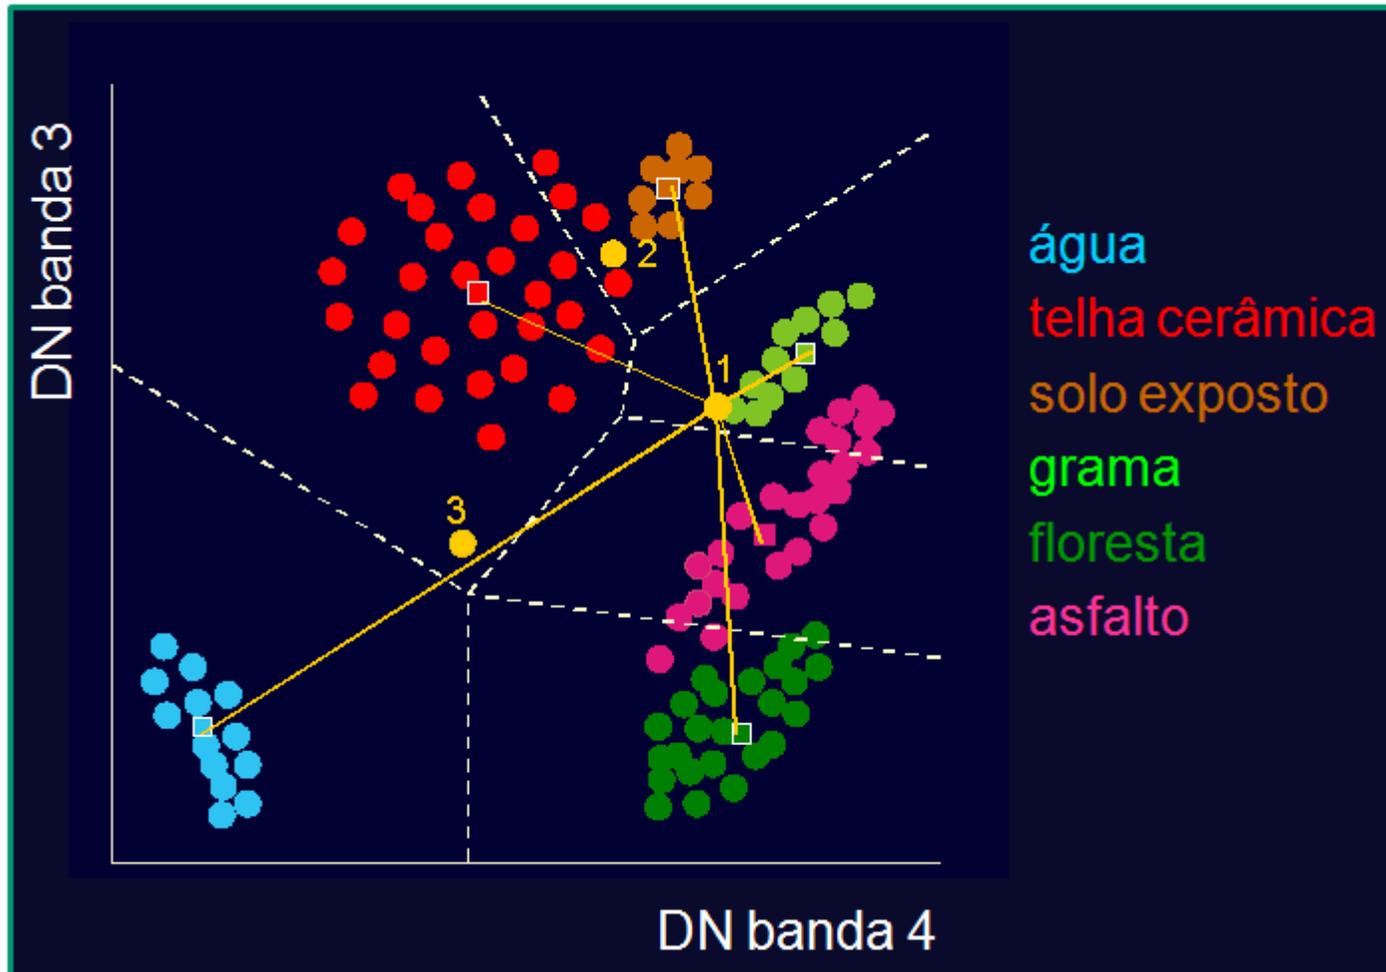
# Classificação

## Supervisionada

- Baseada no conhecimento prévio da área em análise
- Amostras de treinamento

# Classificação

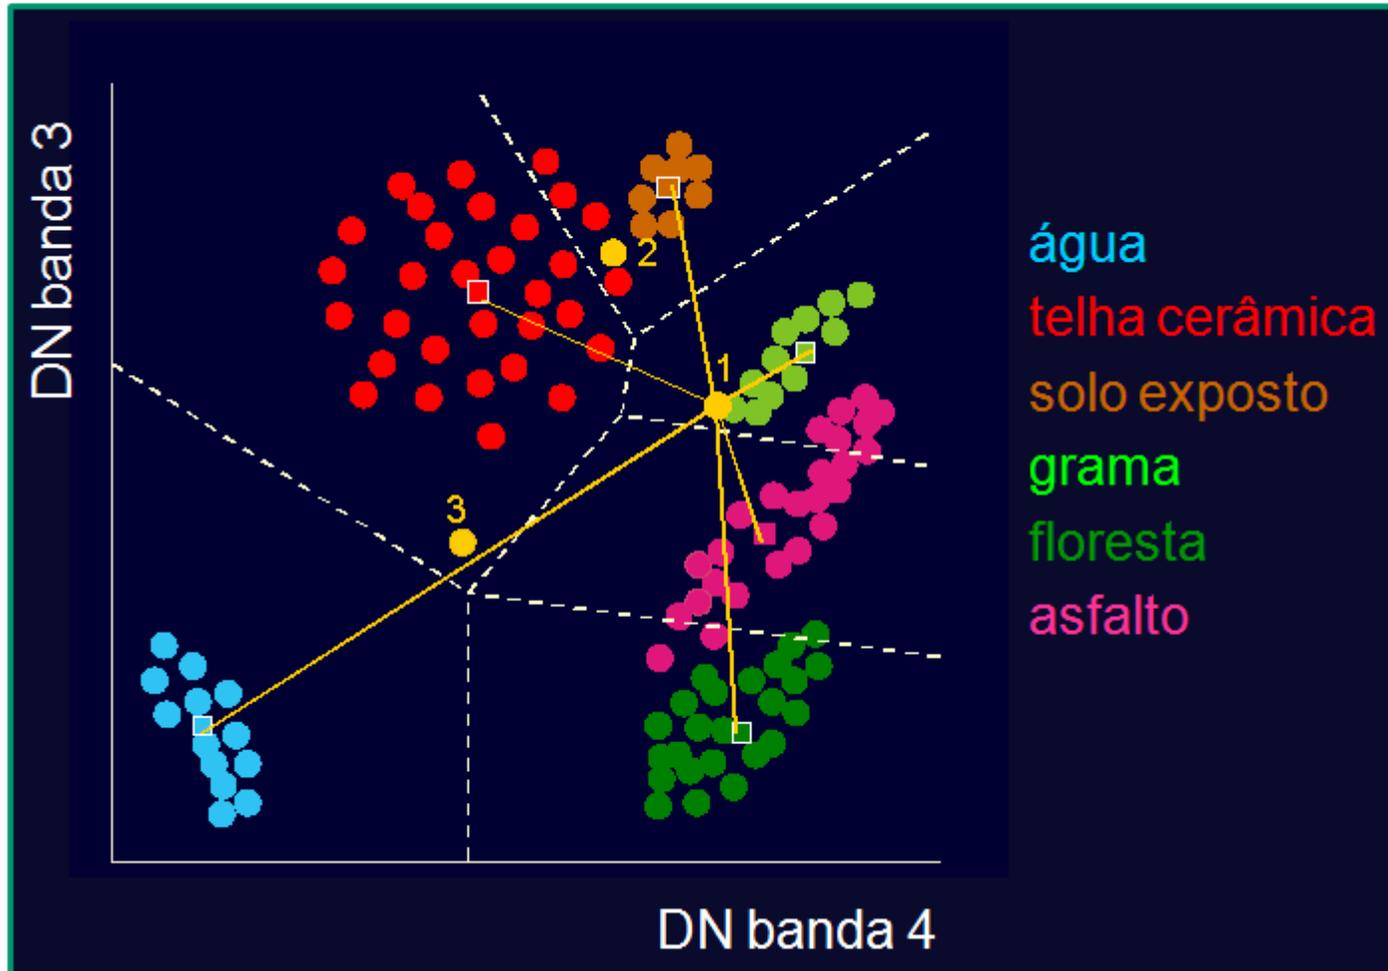
Supervisionada - Mínima distância



Adaptado de Clevers, 1999

# Classificação

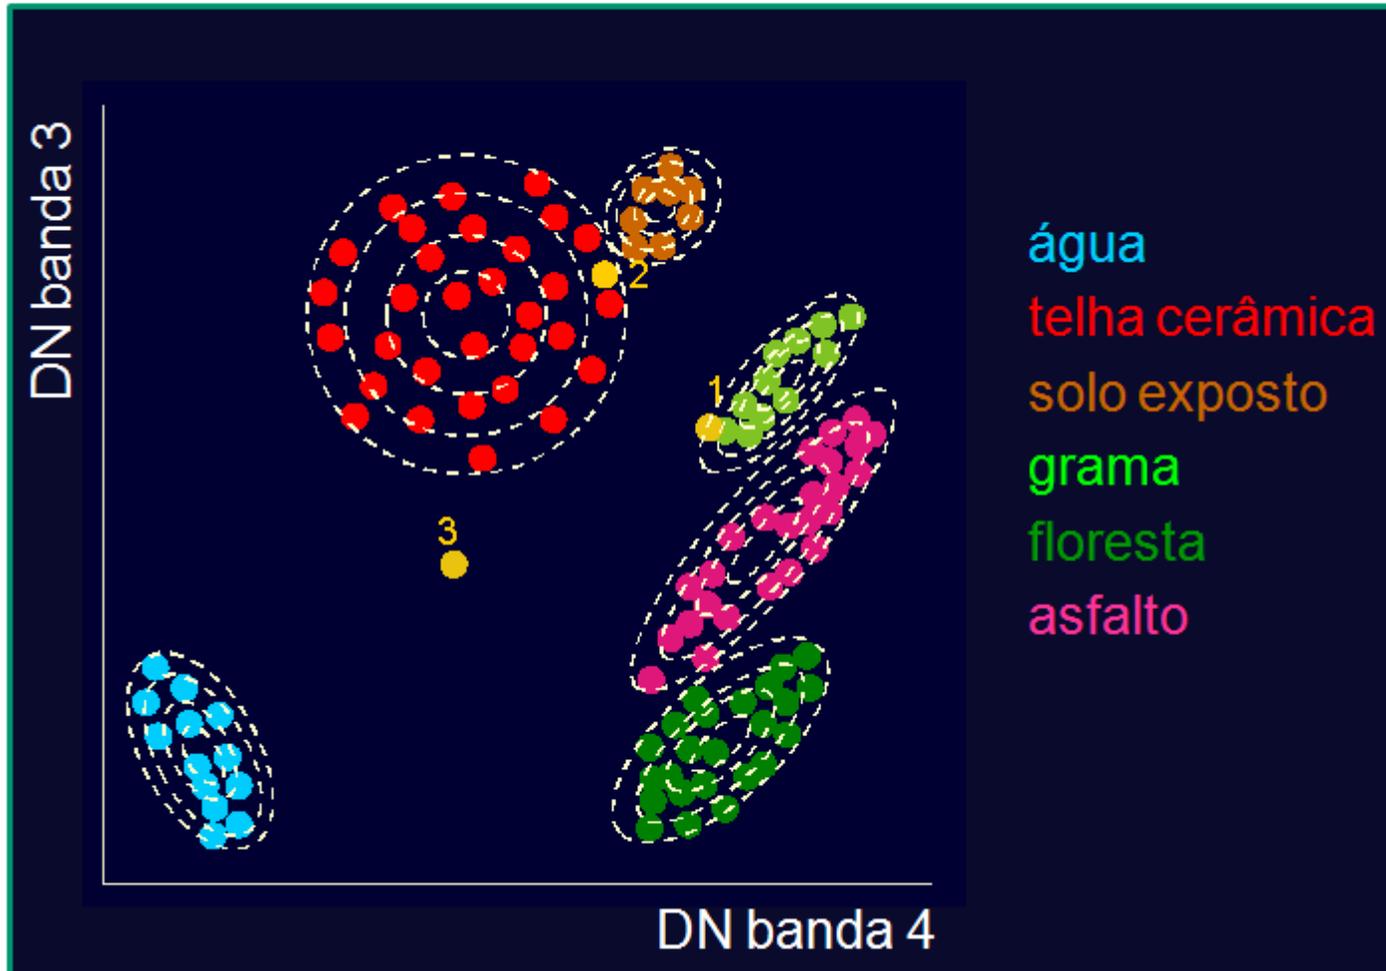
Supervisionada – Vizinho mais próximo



Adaptado de Clevers, 1999

# Classificação

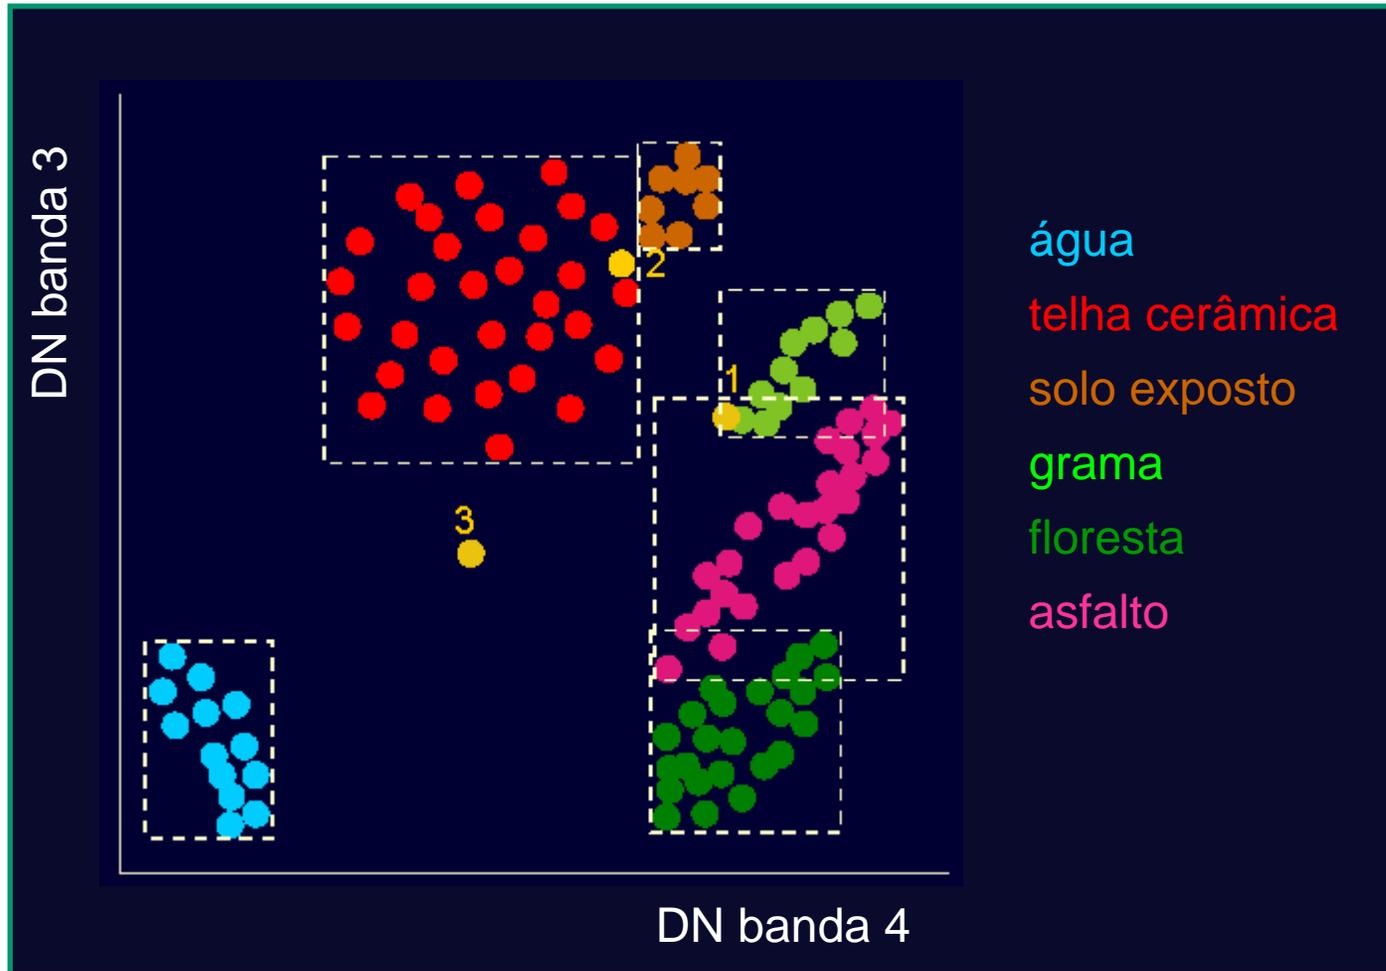
Supervisionada – Máxima verossimilhança



Adaptado de Clevers, 1999

# Classificação

## Supervisionada – Método do paralelepípedo



Adaptado de Clevers, 1999

# Classificação

## Treinamento

- “Treinar” o algoritmo
- Coleta de amostras para cada classe
- Quanto maior a exatidão das amostras, melhor serão os resultados



Nome: Agua

Cor...

Temas

- Agua
- Vegetação
- Urbano

- Criar
- Alterar
- Remover
- Visualizar
- Importar...

Modo:  Normal  Agrupar  Desagrupar

Tipo:  Aquisição  Teste

Contorno:  Poligonal  Retangular  Região

Amostras

- Adquirir
- Alterar
- Remover
- Visualizar

Exportar Arquivo de Redes Neurais (SRN)

Edição Poligonal

- Criar LF
- Adicionar P
- Mover P
- Remover P

Exportar Temas

Categoria...

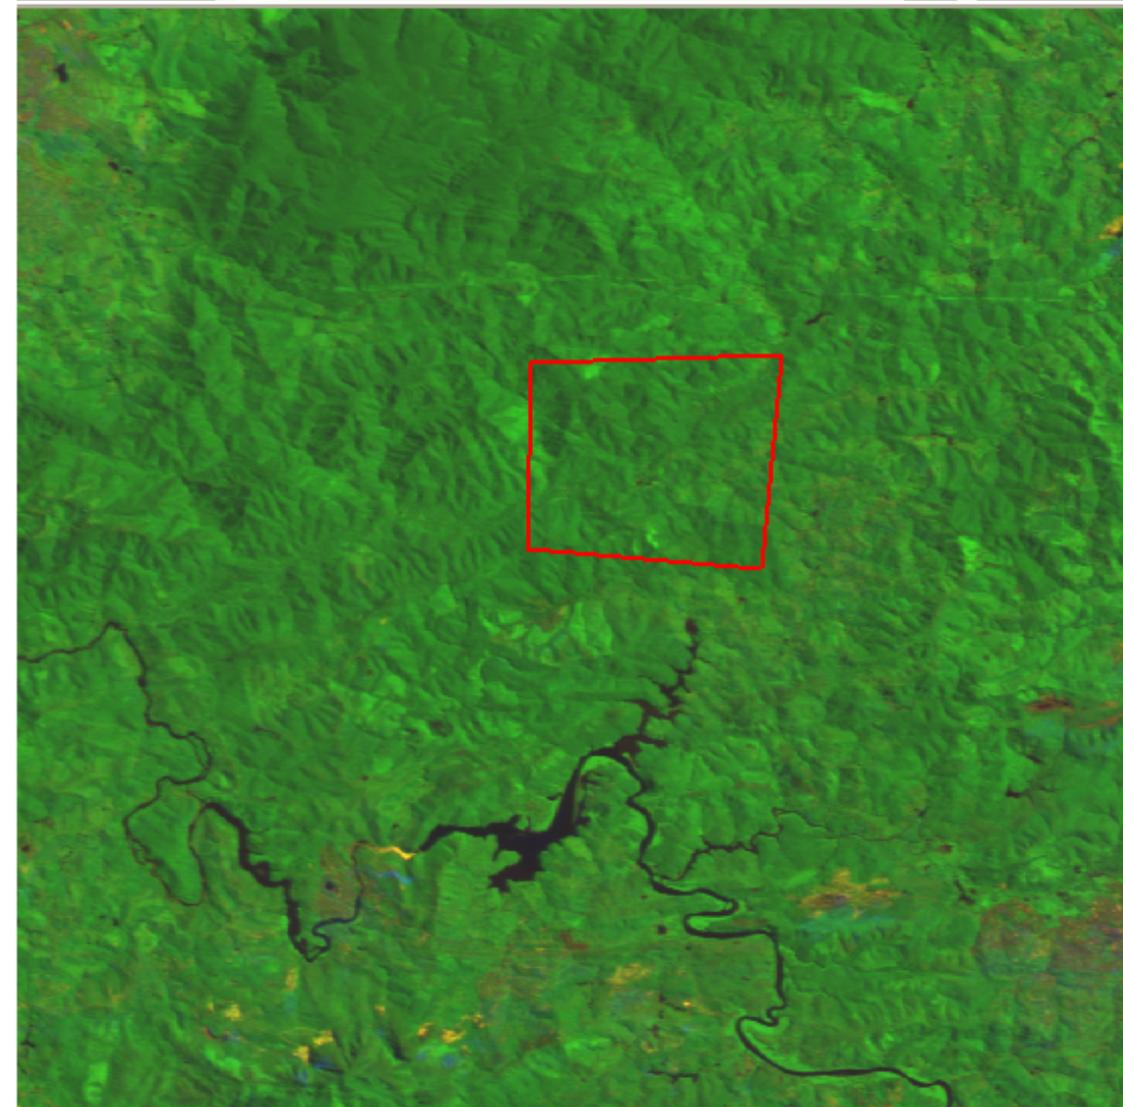
PI:

Aquisição  Exportar

SPRING-4.3.3 - [LinhaF][LinhaF]

Arquivo Editar Exibir Imagem Temático MNT Cadastral Rede Análise Executar Ferramentas Ajuda

Auto 1/ 133926 Inativa



### Treinamento

Nome:   

Temas

- Água
- Vegetação
- Urbano

Modo:  Normal  Agrupar  Desagrupar

Tipo:  Aquisição  Teste

Contorno:  Poligonal  Retangular  Região

Amostras

- 4 Aquisição.

Exportar Arquivo de Redes Neurais (SRN)

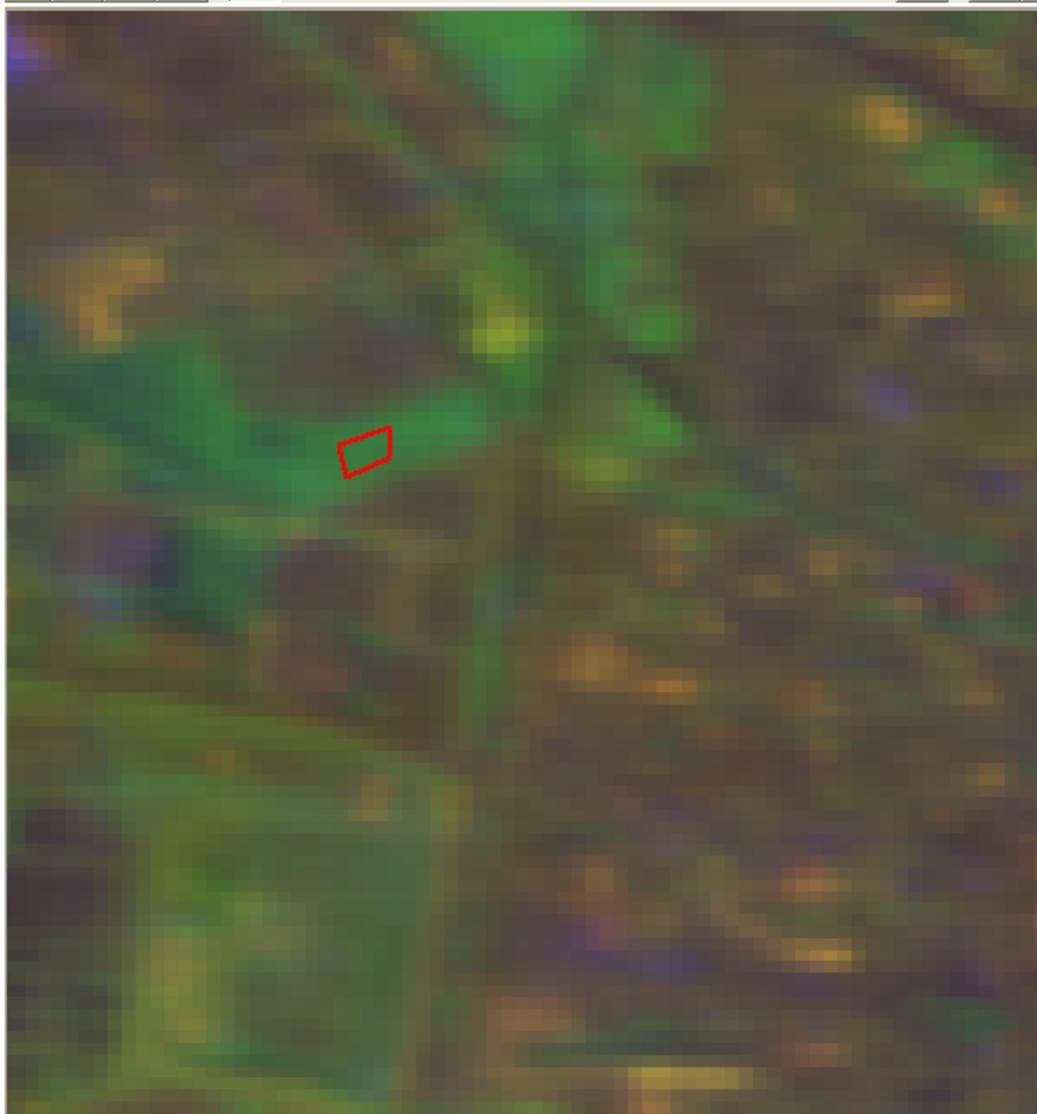
Edição Poligonal

- Criar LF
- Adicionar P
- Mover P
- Remover P

Exportar Temas

Categoria...

PI:



**Treinamento**

Nome:   

Temas

- Água
- Vegetação
- Urbano

Modo:  Normal  Agrupar  Desagrupar

Tipo:  Aquisição  Teste

Contorno:  Poligonal  Retangular  Região

Amostras

- 4 (Aquisição)
- 5 (Aquisição)
- 9 Aquisição.
- 10 Aquisição.

Exportar Arquivo de Redes Neurais (SRN)

Edição Poligonal

- Criar LF
- Adicionar P
- Mover P

Exportar Temas

PI:



Nome: Urbano

Cor...

Temas

Água  
Vegetação  
Urbano

Criar

Alterar

Remover

Visualizar

Importar...

Modo:  Normal  Agrupar  Desagrupar

Tipo:  Aquisição  Teste

Contorno:  Poligonal  Retangular  Região

Amostras

Adquirir

Alterar

Remover

Visualizar

Exportar Arquivo de Redes Neurais (SRN)

Edição Poligonal

- Criar LF
- Adicionar P
- Mover P
- Remover P

Exportar Temas

Categoria...

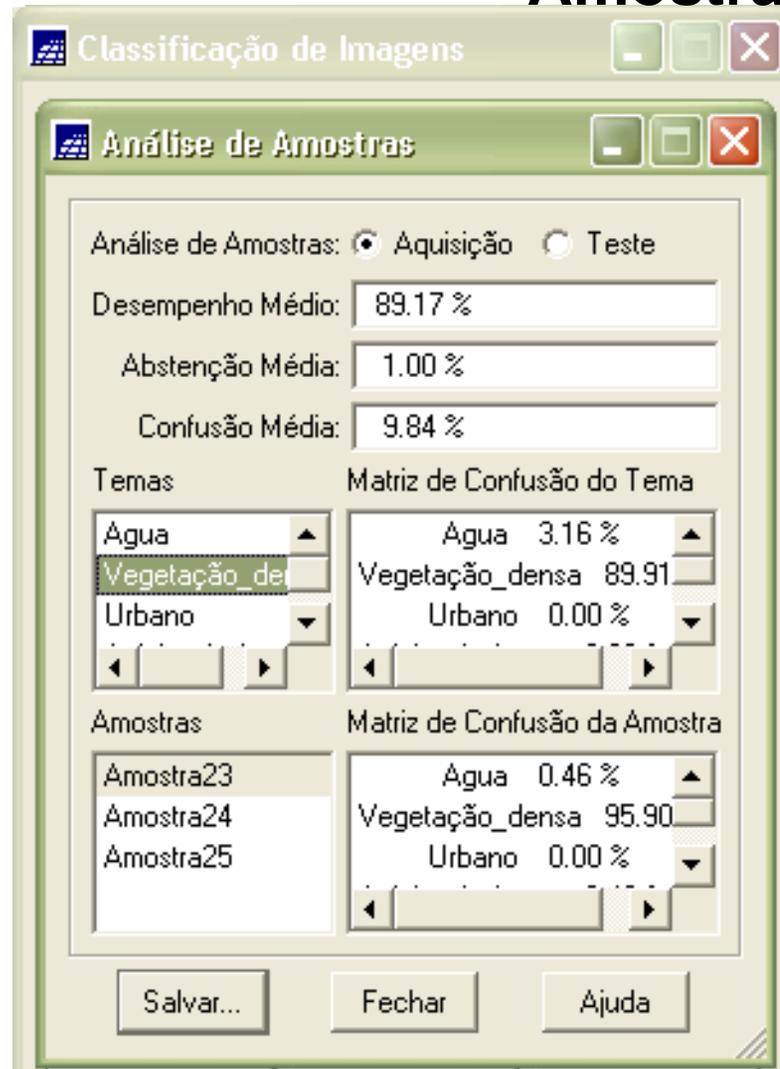
PI:

Aquisição

Exportar

# Classificação

## Amostras de Treinamento



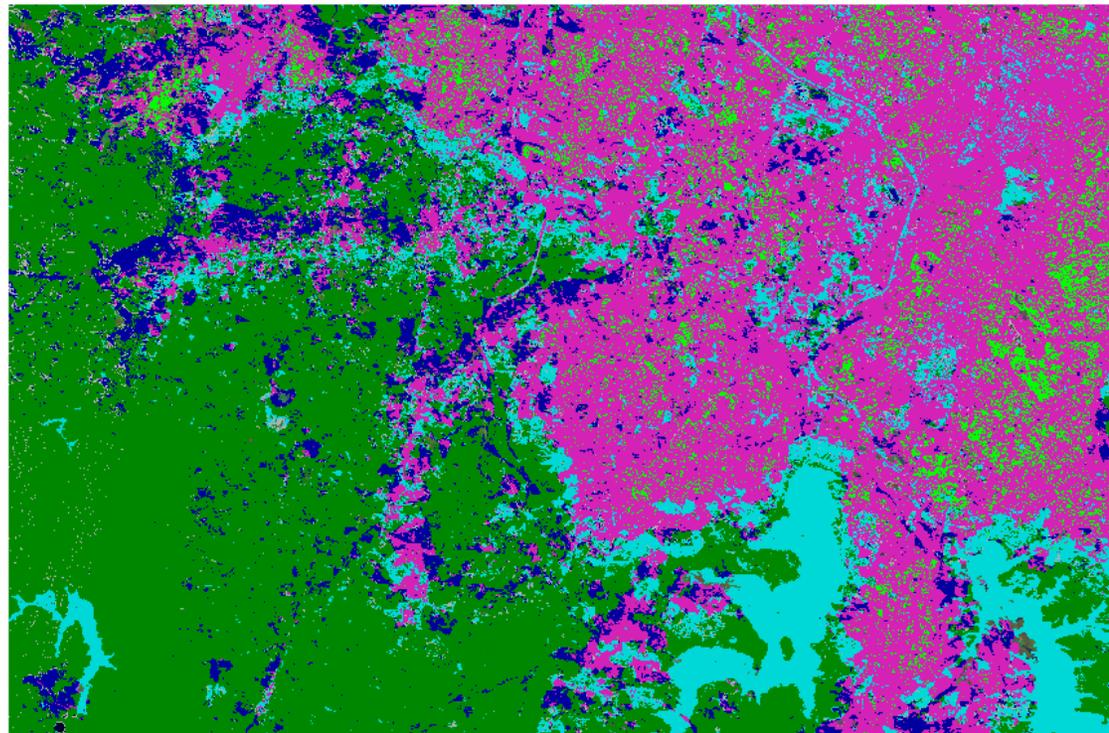
# Classificação Supervisionada



Classificação Maxver

Imagem CBERS, São Paulo, 2008

-  Vegetação densa
-  Vegetação rasteira
-  Água
-  Área urbana
-  Asfalto, amianto

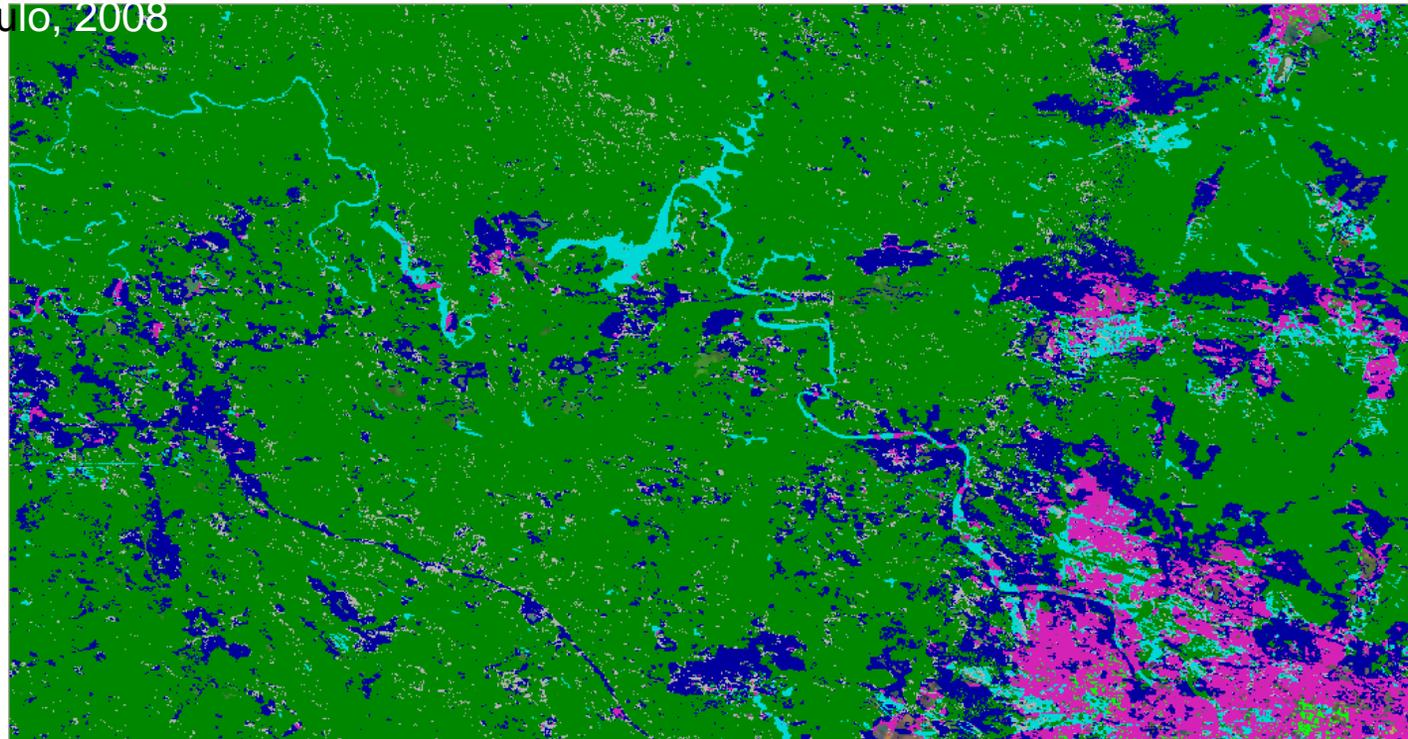


# Classificação Supervisionada



Classificação Maxver

Imagem CBERS, São Paulo, 2008



- Vegetação densa
- Vegetação rasteira
- Água
- Área urbana
- Asfalto, amianto

# Classificação Não-Supervisionada

- O próprio algoritmo identifica agrupamentos no espaço de atributos
- Número de classes pode ser definida pelo analista ou pelo algoritmo
- Conhecimento do analista é aplicado após a classificação
- Melhor opção quando se desconhece a área

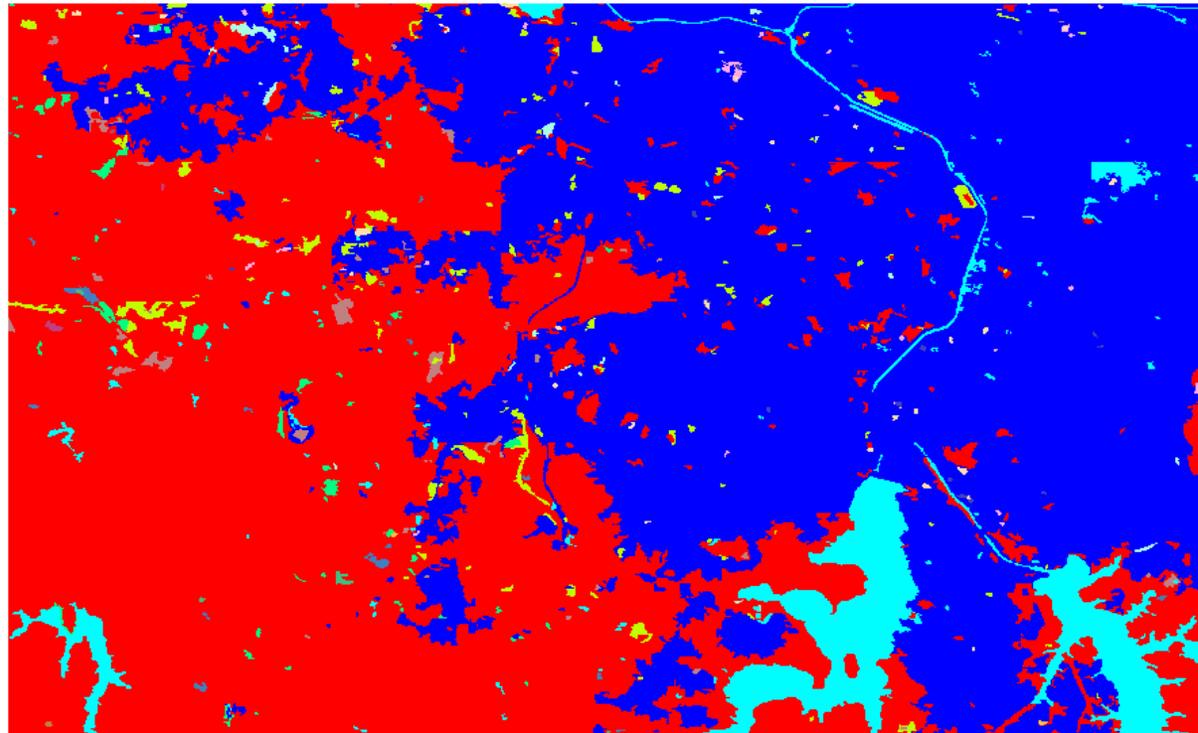
# Classificação Não-Supervisionada



Classificação Isoseg

Imagem CBERS, São Paulo, 2008

-  Vegetação densa
-  Vegetação rasteira
-  Água
-  Área urbana



# Classificação Segmentação

- Divisão da imagem em regiões, ou objetos, com base nas propriedades radiométricas dos pixels.
  - Crescimento de regiões
  - Detecção de bacias
- Identificação de objetos, interpretação visual, amostragem de treinamento e classificação.

# Classificação Segmentação



Imagem CBERS, São Paulo, 2008.

# **Aplicação**

## **Análise da cobertura do solo**

- Mapeamento da cobertura do solo ao longo da faixa de domínio de trem;
- Identificação de áreas invadidas e tendências
- Local: linha F (CPTM) em São Paulo

# Aplicação

## Análise da cobertura do solo



Imagem IKONOS II, São Paulo, 2002.

# Aplicação

## Análise da cobertura do solo



Imagem IKONOS II, São Paulo, 2002.

# Aplicação

## Análise da cobertura do solo



Imagem IKONOS II, 2002.



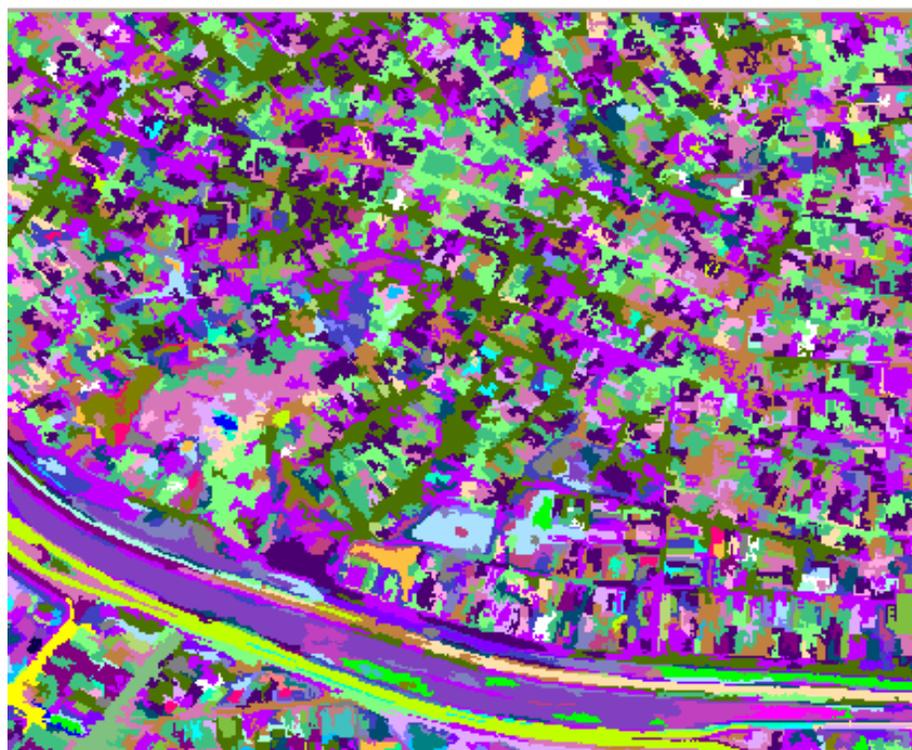
Classificação Supervisionada Maxver.

# Aplicação

## Análise da cobertura do solo



Imagem IKONOS II, 2002.



Classificação Não Supervisionada ISOSEG.

# Aplicação

## Análise da cobertura do solo



Imagem IKONOS II, 2002.



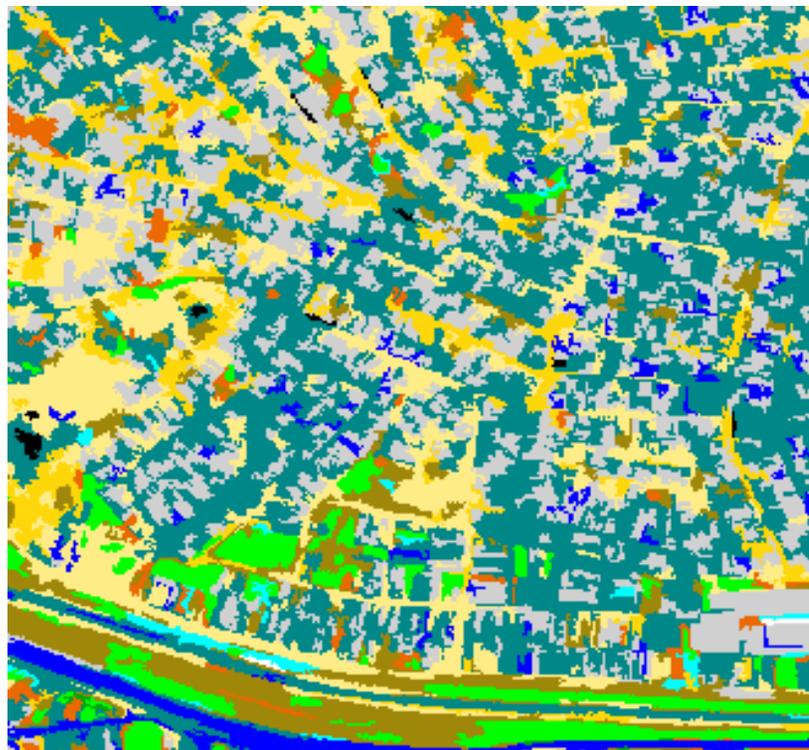
Segmentação

# Aplicação

## Análise da cobertura do solo



Imagem IKONOS II, 2002.



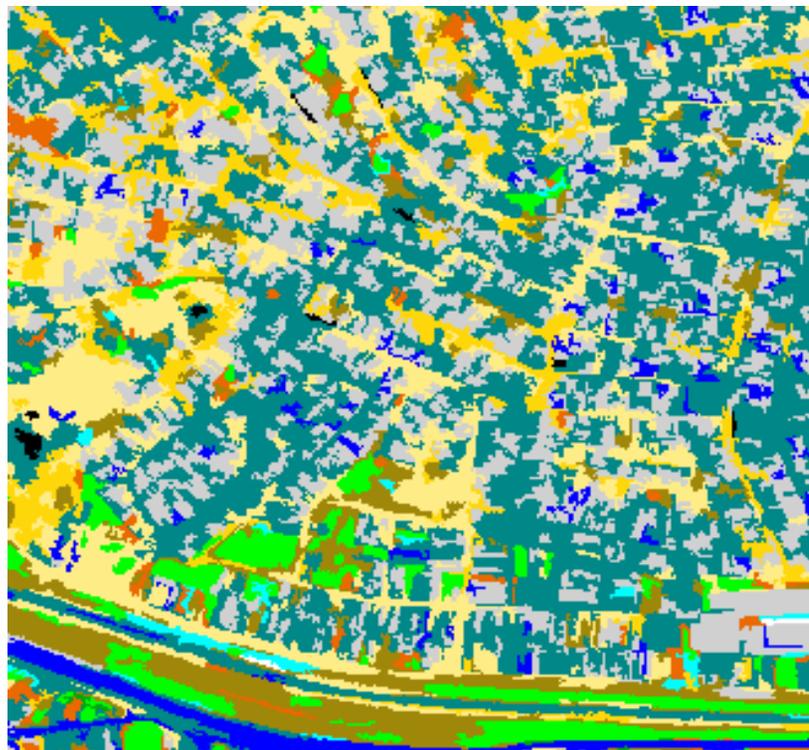
Classificação por regiões - Bhattacharrya

# Aplicação

## Análise da cobertura do solo



Classificação Supervisionada Maxver.



Classificação por regiões - Bhattacharyya

# Classificação

## Avaliação

- Matriz de erro ou confusão:
  - Verdade de campo x classificação
  - Índices de desempenho geral e por classe
    - Erro de omissão
    - Erro de comissão
  - Coeficiente Kappa

# Classificação

## Avaliação

Verdade	C1	C2	C3	C4	C5	C6	Total
C1	897	308	75	65	17	33	1395
C2	65	347	141	105	0	26	684
C3	0	7	110	131	3	71	322
C4	0	0	18	117	32	49	216
C5	2	0	101	127	294	127	651
C6	0	0	3	12	0	325	340
Total	964	662	448	557	346	631	3608

Verdade	Acurácia %	Omissão %	Comissão %
C1	64.3	35.7	6.9
C2	50.7	49.2	47.5
C3	34.1	65.8	75.4
C4	54.1	45.8	78.9
C5	45.8	54.8	15
C6	95.5	4.4	48.4

Acurácia total da classificação =  
 $(\text{Total de acertos} / \text{Total}) * 100\% = 57,9\%$

Erro de omissão =  $1 - \text{Acurácia Cx}$

Erro de comissão =  $(65/964) * 100\% = 6.9\%$

# Referência Bibliográfica

- CLEVERS, J. **Lectures Remote Sensing**. Centre of Geo-Information, Environmental Sciences, Wageningen University na Research Center, Wageningen, UR.
- NÓBREGA, R. A. A. **Detecção da malha viária na periferia da cidade de São Paulo utilizando imagens de alta resolução espacial e classificação orientada a objetos**. 2007. 157p. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo, São Paulo.
- Imagens CBERS: <http://www.cbears.inpe.br/>