



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

Mineração de Dados

CAP 349: Bancos de Dados Geográficos 2014

Adeline Marinho
Doutorado – CAP – INPE
adelsud6@gmail.com

8 setembro 2014



Introdução

- Crescimento explosivo das bases de dados
 - Governo, corporações, institutos científicos
 - *Internet*
- Demanda por informações estratégicas
 - Meios convencionais para examinar dados
 - Análise automática e inteligente de grandes BDs
- Disponibilidade de dados
 - Armazenamento eletrônico

Cenário

Hoje, a maioria das organizações produz mais informações em uma semana do que muitas pessoas poderiam ler em toda a vida.

**“MAIS DADOS PODE SIGNIFICAR
MENOS INFORMAÇÕES”**



Cenário

- Dificuldade para analisar dados
 - métodos manuais tradicionais

- A informação não está explicitada

- Necessidade
 - técnicas que facilitem a extração da informação
 - dado operacional não oferece grande valor quando estudado isoladamente.

O que fazer?



Dados ricos, porém pobres em informação

Fonte: (HAN e KAMBER, 2006)

Informação e Conhecimento

- Segundo Han e Kamber (2006)
 - A abundância de dados
 - A necessidade de ferramentas de análise de dados

- É descrita como uma situação de dados ricos, mas pobres em informação.
 - Os dados tornam-se "dados túmulos" arquivos de dados que raramente são visitados.



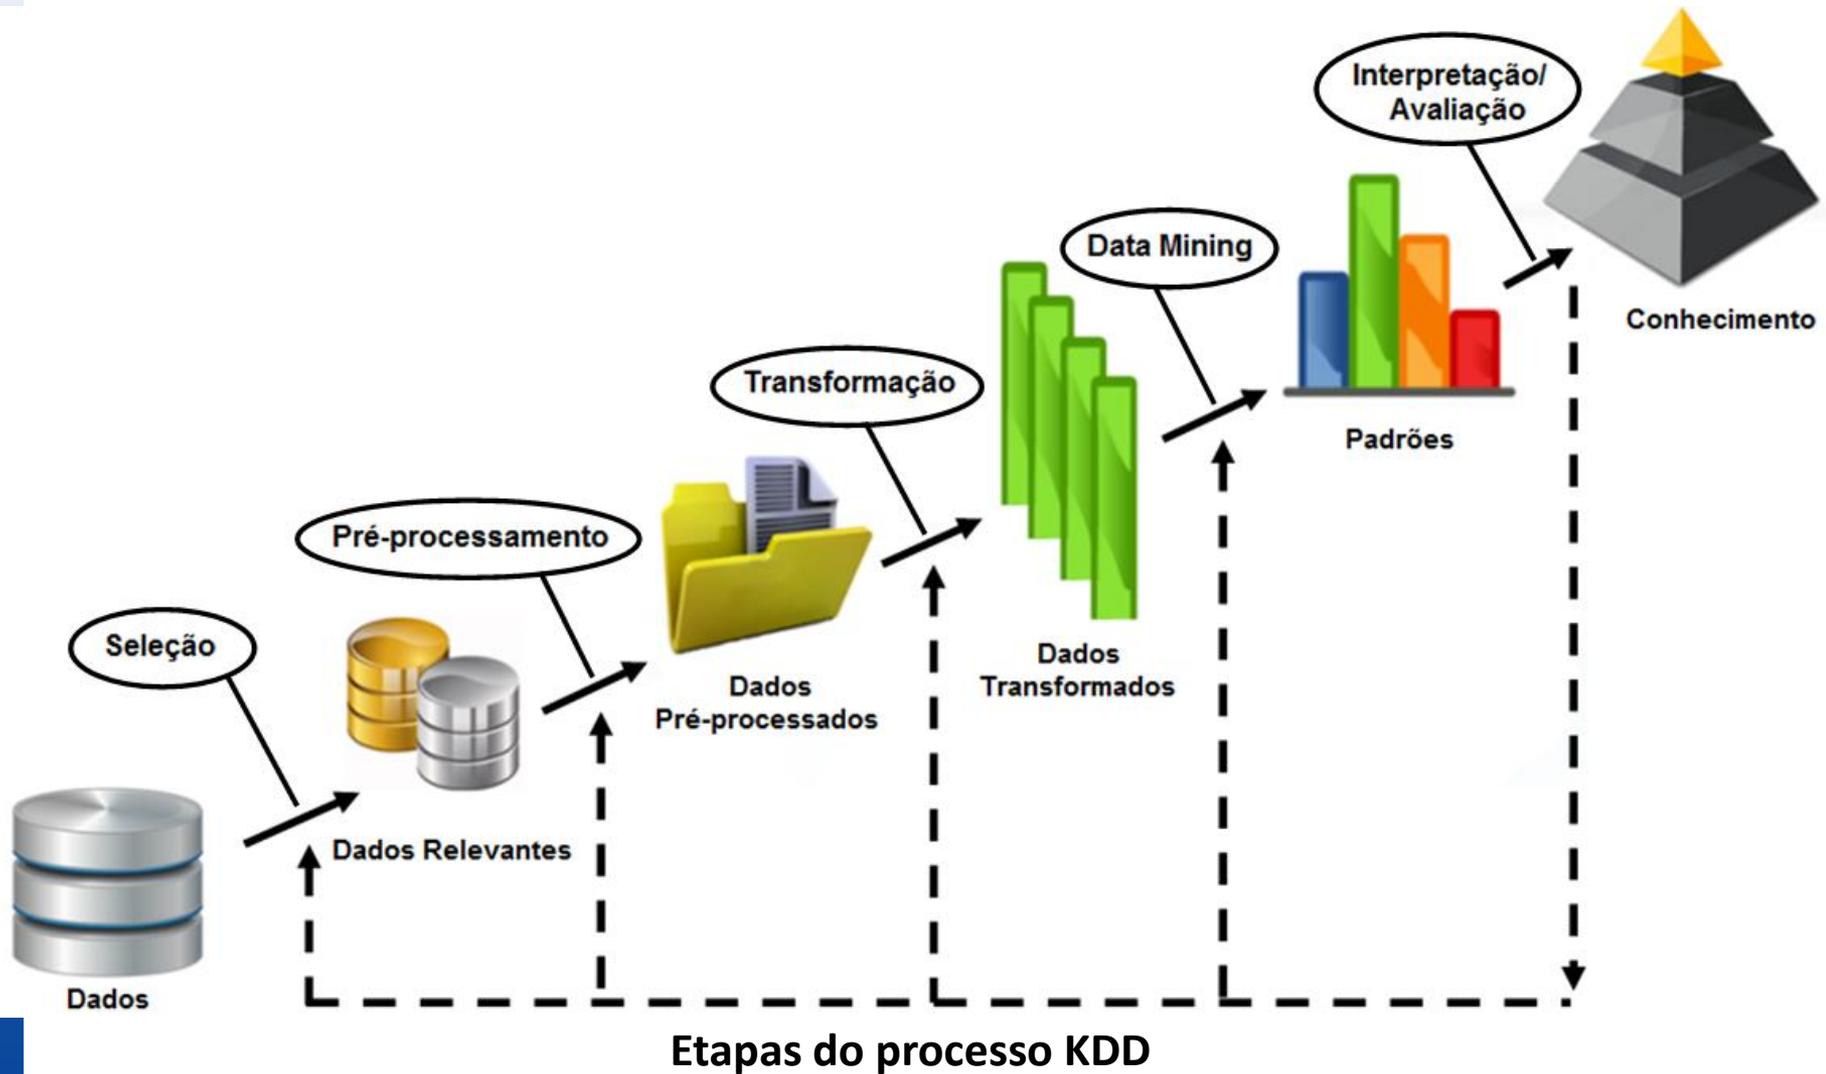
Processo de KDD

- Descoberta de Conhecimento em BDs
 - *Knowledge Discovery in Databases* (KDD) (FAYYAD et al., 1996)
 - Ferramentas e técnicas empregadas para análise automática e inteligente de imensos repositórios

- Processo não trivial de identificar em dados padrões que sejam
 - Válidos
 - Novos (previamente desconhecidos)
 - Potencialmente úteis
 - Compreensíveis

- Visando melhorar o entendimento de um problema ou um procedimento de tomada de decisão.

Etapas do KDD





Etapas do KDD

- Fases/Etapas do KDD
 - Seleção.
 - Pré-processamento.
 - Transformação.
 - Mineração de dados
 - Interpretação e Avaliação.



Etapas do KDD

■ Seleção

- Selecionar ou segmentar dados de acordo com critérios definidos:
 - Ex.: Todas as pessoas que são proprietárias de carros é um subconjunto de dados determinado.

Etapas do KDD

■ Pré-processamento

- Estágio de limpeza dos dados, onde informações julgadas desnecessárias são removidas.
 - Ex. : O sexo de um paciente, gestante

- Reconfiguração dos dados para assegurar formatos consistentes (identificação)
 - Ex. : sexo = "F" ou "M"
 sexo = "M" ou "H"

- Agregar dados externos



Etapas do KDD

■ Transformação

- Transforma-se os dados em formatos utilizáveis.
- Depende da técnica *data mining* usada.
 - converter valor literal em valor numérico
- Normalização de valores
- Agregar semântica ao dado
- Disponibilizar os dados de maneira usável e navegável.



Etapas do KDD

■ Mineração de Dados

- É a verdadeira extração dos padrões de comportamento dos dados
- Utilizando a definição de fatos, medidas de padrões, estados e o relacionamento entre eles.



Etapas do KDD

■ Interpretação e Avaliação

- Identificado os padrões pelo sistema, estes são interpretados em conhecimentos, os quais darão suporte a tomada de decisões humanas
- Ex.: Tarefas de previsões e classificações

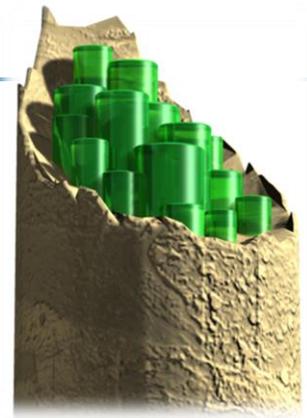
Processo de KDD

- Alguns possíveis resultados são:
 - Confirmação do óbvio
 - Conhecimento novo
 - Nenhum relacionamento encontrado (dados aleatórios)

- Problemas:
 - Identificação dos dados relevantes
 - Representação dos dados
 - Busca por modelos ou padrões válidos



Mineração de Dados

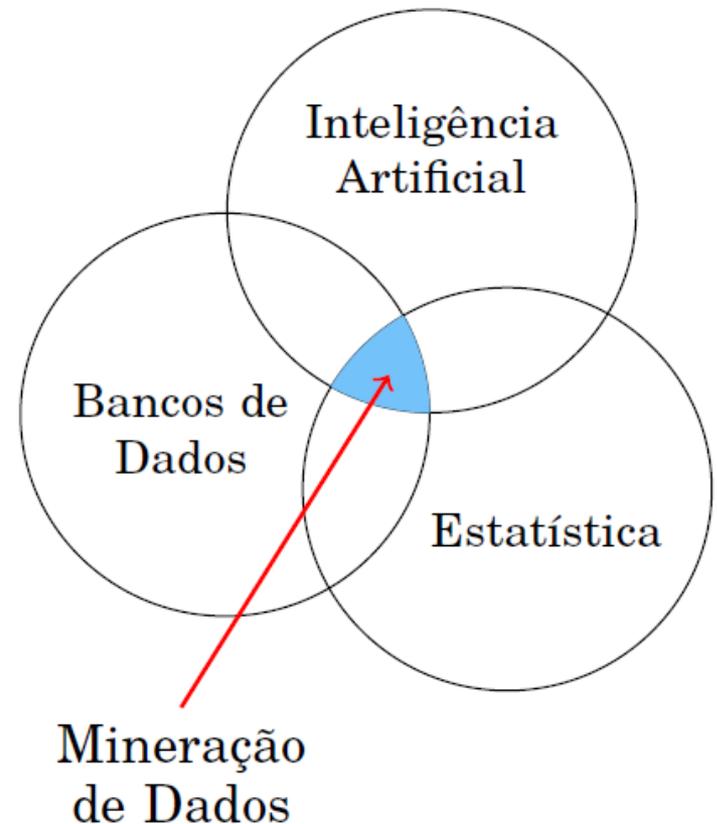


- É uma das etapas no KDD
- A mineração de dados preocupa-se em buscar conhecimento compreensível em grandes conjuntos de dados.

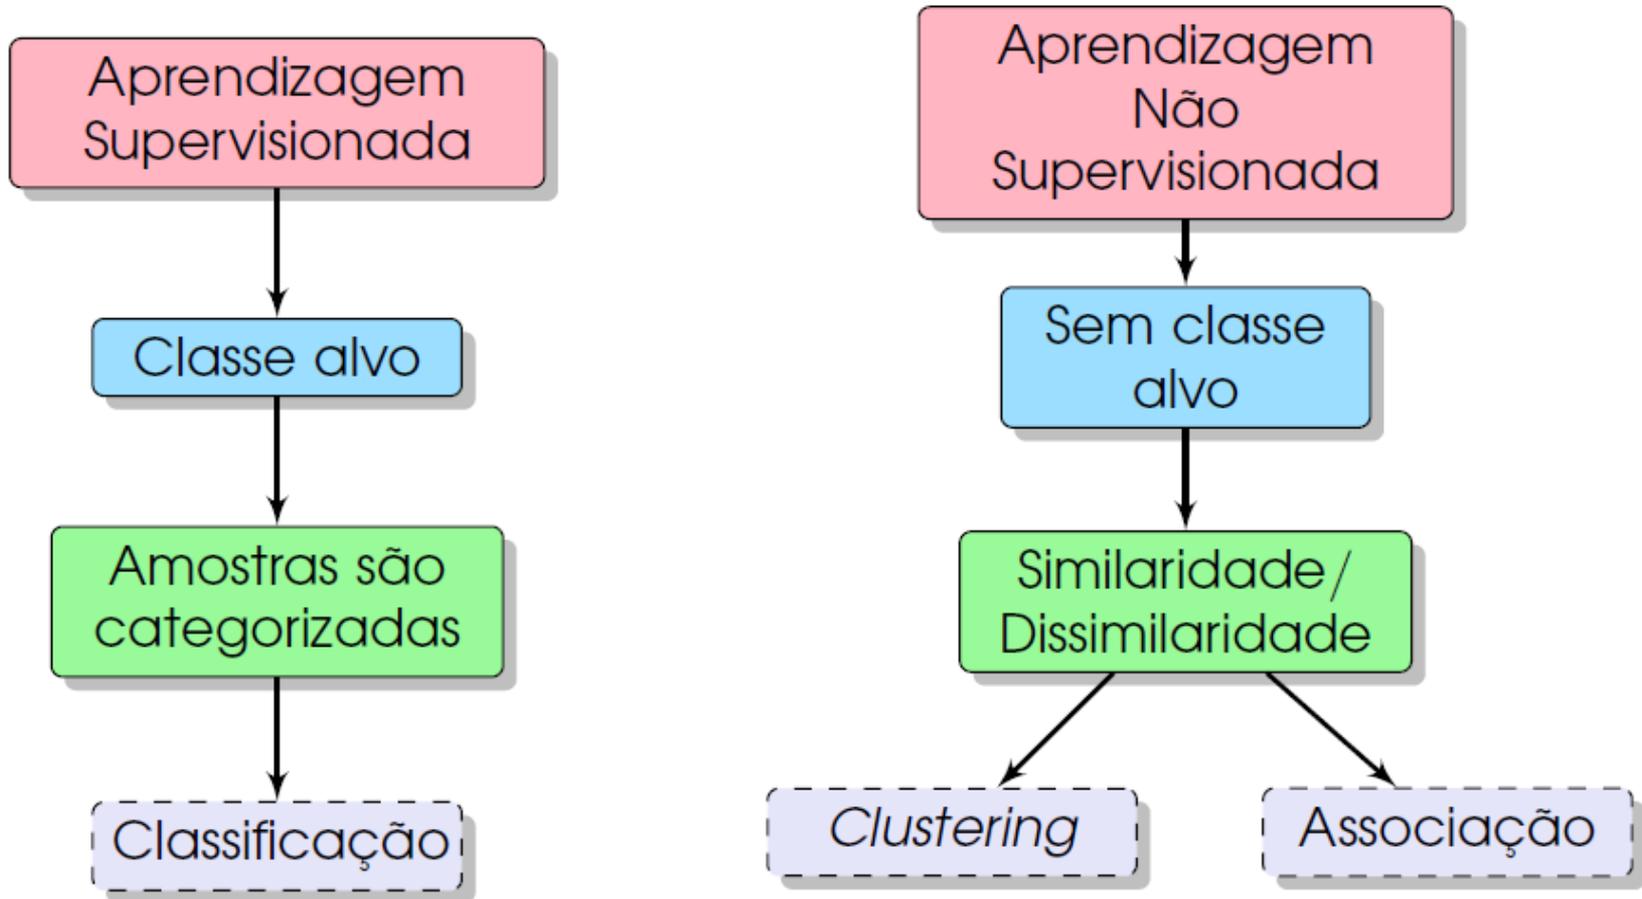


Mineração de Dados

- Utiliza técnicas e algoritmos de diferentes áreas do conhecimento
 - inteligência artificial
 - aprendizagem de máquina
 - banco de dados
 - recursos para manipular grandes bases de dados
 - Estatística
 - avaliação e validação de resultados



Técnicas de Mineração de Dados





Aprendizagem Supervisionada

- Aprendizagem do modelo é supervisionada
 - É fornecida uma classe à qual cada amostra no treinamento pertence

- Algoritmos preditivos
 - suas tarefas de mineração desempenham inferências nos dados;
 - fornecem previsões ou tendências, obtendo informações não disponíveis a partir dos dados disponíveis.



Aprendizagem Supervisionada

■ Classificação

- determina o valor de um atributo (*classe*) através dos valores de um subconjunto dos demais atributos.

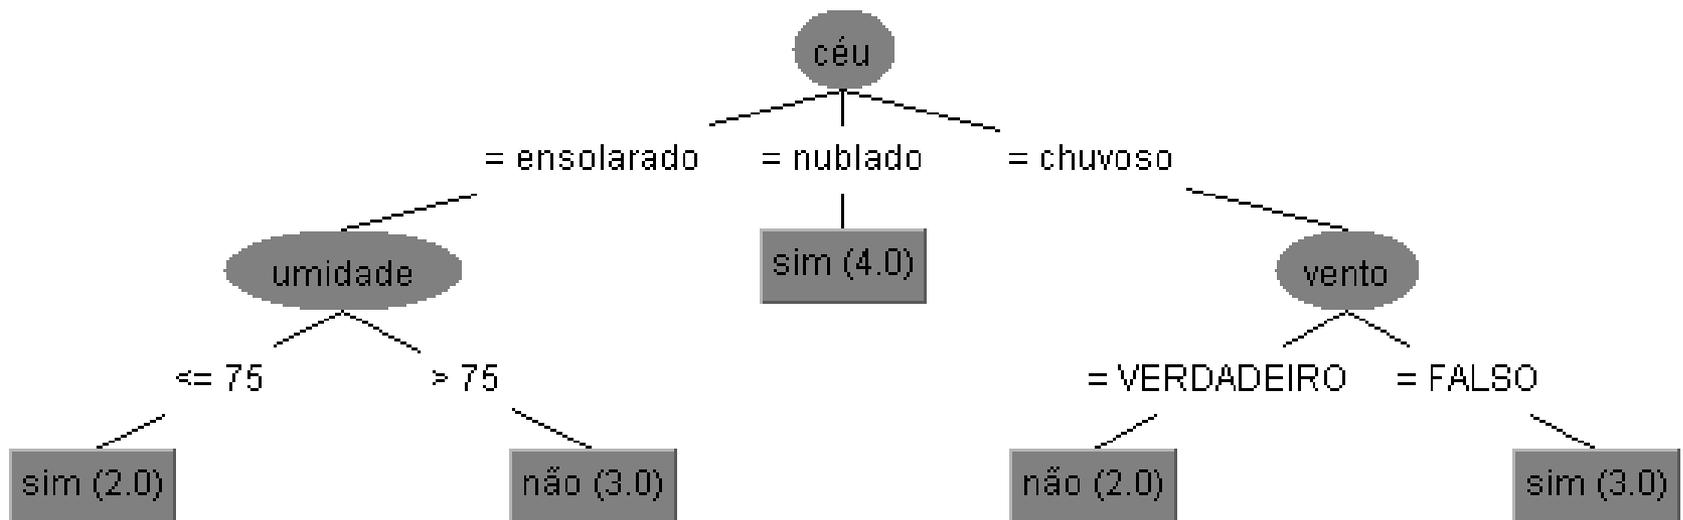
■ Ex. Qual o perfil dos clientes que consomem cosméticos importados?

- Inferir (Prever) - “clientes do sexo feminino, com renda superior a R\$ 1.500,00 e com idade acima de 30 anos compram cosméticos importados ”
- Atributo compra cosmético importado = classe
 - Atributo alvo (Sim ou Não)

Aprendizagem Supervisionada

■ Classificação

- Formas mais comuns de representação: regras e árvores.



Árvore de decisão

Aprendizagem Supervisionada

■ Seleção de atributos

- Alguns atributos têm um peso maior ou até determinante nas tarefas de mineração de dados
 - ex.: o atributo renda é determinante nos hábitos de consumo do cliente

- Com os algoritmos é possível determinar os atributos relevantes para a mineração separando-os dos atributos irrelevantes
 - ex.: nome do cliente caso não influenciem nos hábitos de consumo



Aprendizagem Não-Supervisionada

- O rótulo da classe de cada amostra do treinamento não é conhecida
 - Número ou conjunto de classes a ser treinado pode não ser conhecido a priori

- Descritivos
 - Descreve de forma concisa os dados disponíveis
 - Fornece características das propriedades gerais dos dados minerados.



Aprendizagem Não-Supervisionada

■ Associação

- A classe da tarefa de mineração não é determinada
- Gera regras do tipo:
 - clientes do sexo masculino, casados, com renda superior a R\$ 1.800,00 têm o seguinte hábito de consumo: *roupas de grife, perfumes nacionais, relógios importados*
- Revela associações entre valores dos atributos

Aprendizagem Não-Supervisionada

■ Exemplo de Regras de associação

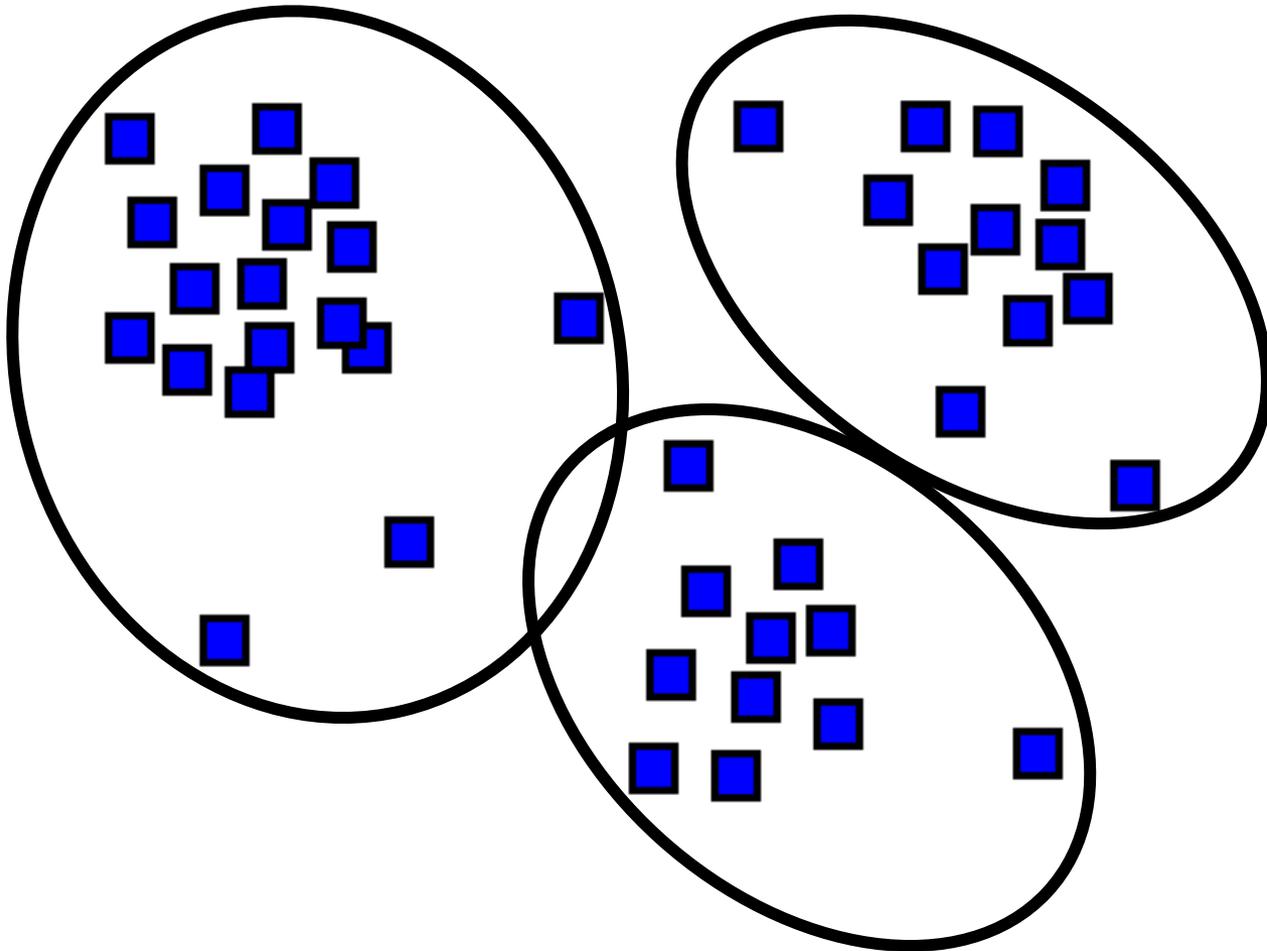
```
1. classe=tripulação 885 ==> idade=adulto 885      conf:(1)
2. classe=tripulação sexo=masculino 862 ==> idade=adulto 862      conf:(1)
3. sexo=masculino sobreviveram=não 1364 ==> idade=adulto 1329      conf:(0.97)
4. classe=tripulação 885 ==> sexo=masculino 862      conf:(0.97)
5. classe=tripulação idade=adulto 885 ==> sexo=masculino 862      conf:(0.97)
6. classe=tripulação 885 ==> idade=adulto sexo=masculino 862      conf:(0.97)
7. sobreviveram=não 1490 ==> idade=adulto 1438      conf:(0.97)
8. sexo=masculino 1731 ==> idade=adulto 1667      conf:(0.96)
9. idade=adulto sobreviveram=não 1438 ==> sexo=masculino 1329      conf:(0.92)
10. sobreviveram=não 1490 ==> sexo=masculino 1364      conf:(0.92)
```

Aprendizagem Não-Supervisionada

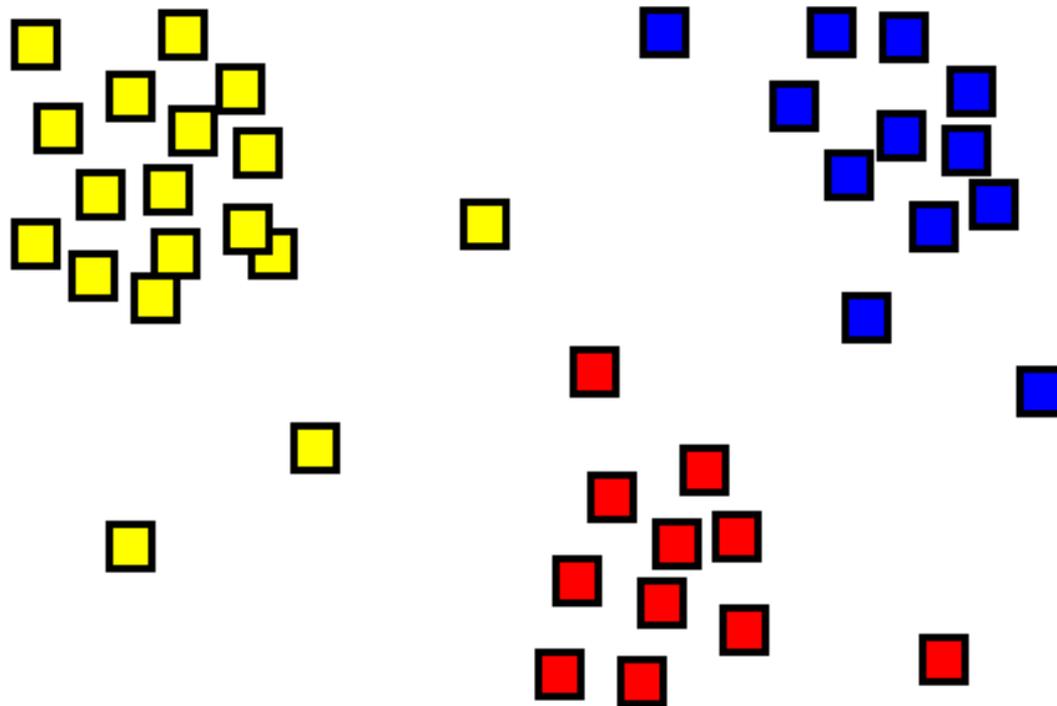
■ *Clustering*

- Verifica como as instâncias de uma determinada base de dados se agrupam
 - considera características intrínsecas de seus atributos, sem que seja definida uma classe para a tarefa
- A partir de uma métrica de similaridade
 - objetos são agrupados com base no princípio da maximização da similaridade intraclasse e da minimização da similaridade interclasse
- ex.: identificar subgrupos homogêneos de clientes

Clustering



Clustering





Validação de Resultados

- É importante que os resultados e modelos possam ser avaliados e comparados
- Teste e validação
 - fornecem parâmetros de validade e confiabilidade nos modelos gerados
 - *cross validation, supplied test set, training set, percentage split*
 - indicadores estatísticos para auxiliar a análise dos resultados
 - matriz de confusão, estatística kappa, erro médio absoluto, precisão...



Medidas de interesse

Artigo (item)	número que o representa
Pão	1
Leite	2
Açúcar	3
Papel Higiênico	4
Manteiga	5
Fralda	6
Cerveja	7
Refrigerante	8
Iogurte	9
Suco	10

Representação numérica de cada artigo do supermercado

Um banco de dados de transações de clientes

TID	Itens comprados
101	{1,3,5}
102	{2,1,3,7,5}
103	{4,9,2,1}
104	{5,2,1,3,9}
105	{1,8,6,4,3,5}
106	{9,2,8}

Medidas de Interesse - Confidência

■ Grau de confiança

- $\text{conf}(A \Rightarrow B)$
- A porcentagem das transações que suportam B dentre todas as transações que suportam A

$$\text{conf}(A \rightarrow B) = \frac{\text{número de transações que suportam } (A \cup B)}{\text{número de transações que suportam } A}$$

- Ex. O grau de confiança da regra
- $\{\text{cerveja}\} \Rightarrow \{\text{manteiga}\}$, isto é $\{7\} \Rightarrow \{5\}$, com relação ao banco de dados é $1\{100\%$

Confidência

Artigo (item)	número que o representa
Pão	1
Leite	2
Açúcar	3
Papel Higiênico	4
Manteiga	5
Fralda	6
Cerveja	7
Refrigerante	8
Iogurte	9
Suco	10

Um banco de dados de transações de clientes

TID	Itens comprados
101	{1,3,5}
102	{2,1,3,7,5}
103	{4,9,2,1}
104	{5,2,1,3,9}
105	{1,8,6,4,3,5}
106	{9,2,8}

Representação numérica de cada artigo do supermercado

$$Conf\{7\} \rightarrow \{5\} = 1/1 = 1$$

Confidência

- Seja uma regra "A => B".
- A confidência da regra é dada por:

$$\text{Confidência (A => B)} = \frac{\# \text{ Tuplas Contendo Tanto A Como B}}{\# \text{ Tuplas Contendo A}}$$

□ Exemplo:

- Uma confidência de 85% (0,85) da regra:
compra(mulher, computadores) => compra(mulher, software)
- Significa que 85% das mulheres que compram computadores também compram software.



Medidas de Interesse - Suporte

■ Função do suporte

- determinar a frequência que ocorre um *itemset* dentre todas as transações da base de dados
 - é a porcentagem de transações onde este *itemset* aparece
- Um *itemset* será frequente se seu suporte for maior ou igual a um suporte mínimo estabelecido previamente.

■ Forma:

- $X \Rightarrow Y$ (lê-se X implica em Y)
 - onde X é o antecessor e Y o conseqüente
 - X e Y são dois *itemsets* distintos na Base de Dados

Suporte

- O suporte da regra " $A \Rightarrow B$ " é dado por:

$$\text{Suporte } (A \Rightarrow B) = \frac{\# \text{ Tuplas Contendo Tanto } A \text{ Como } B}{\# \text{ Total_De_Tuplas}}$$

$$\text{Sup } (X U Y) = \frac{\text{N}^\circ \text{ de registros com } (X U Y)}{\text{N}^\circ \text{ total de transações do BD}}$$

- Um suporte de 5% significa que de todas as transações comerciais realizadas, 5% são efetuadas por *mulheres que comprando computador também compram softwares*.

Suporte

Um banco de dados de transações de clientes

TID	Itens comprados
101	{1,3,5}
102	{2,1,3,7,5}
103	{4,9,2,1}
104	{5,2,1,3,9}
105	{1,8,6,4,3,5}
106	{9,2,8}

Artigo (item)	número que o representa
Pão	1
Leite	2
Açúcar	3
Papel Higiênico	4
Manteiga	5
Fralda	6
Cerveja	7
Refrigerante	8
Iogurte	9
Suco	10

Itemset	Suporte
{1,3}	0,6666
{2,3}	0,3333
{1,2,7}	0,16666
{2,9}	0,5

Representação numérica de cada artigo do supermercado

$$Sup \{7\} \rightarrow \{5\} = 1/6 = 0.16...$$

Suporte de alguns *itemsets*



Critérios de Comparação

- Critérios para comparar métodos e resultados de mineração de dados permitem avaliar e optar pelo melhor custo/benefício
 - Precisão avaliativa ou preditiva
 - habilidade do modelo para avaliar ou prever corretamente classes, agrupamentos, regras.
 - Velocidade
 - custo computacional da geração e utilização do modelo



Critérios de Comparação

- Robustez
 - habilidade do modelo para avaliar ou prever corretamente utilizando dados ruidosos ou com valores ausentes
- Escalabilidade
 - capacidade de construir modelos eficientemente a partir de grandes volumes de dados
- Interpretabilidade
 - nível de compreensão fornecido pelo modelo



Softwares

KDnuggets Polls

May 20 - Jun 2, 2014

What Analytics, Big Data, Data mining, Data Science software you used in the past 12 months for a real project? [3285 voters]	
Legend: Red: Free/Open Source tools Green: Commercial tools	% users in 2014 % users in 2013
RapidMiner (1453), 35.1% alone	44.2% 39.2%
R (1264), 2.1% alone	38.5% 37.4%
Excel (847), 0.1% alone	25.8% 28.0%
SQL (832), 0.1% alone	25.3% na
Python (639), 0.9% alone	19.5% 13.3%
Weka (558), 0.4% alone	17.0% 14.3%
KNIME (492), 10.6% alone	15.0% 5.9%
Hadoop (416), 0% alone	12.7% 9.3%
SAS base (357), 0% alone	10.9% 10.7%
Microsoft SQL Server (344), 0% alone	10.5% 7.0%
Revolution Analytics R (300), 13.3% alone	9.1% 4.5%
Tableau (298), 1.3% alone	9.1% 6.3%
MATLAB (277), 0% alone	8.4% 9.9%

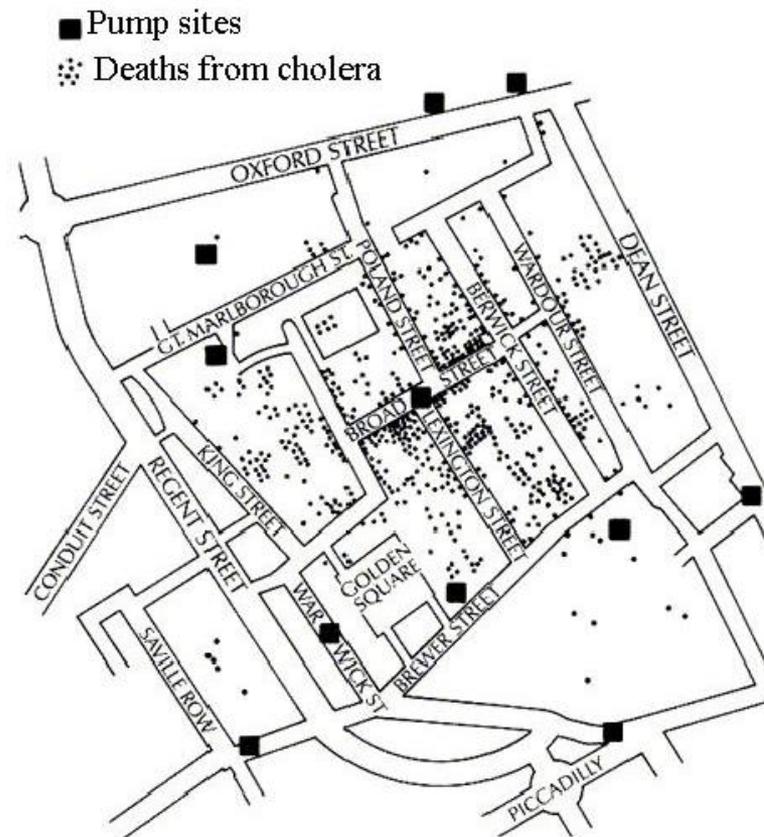


MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

Mineração de Dados Espaciais

Exemplo Histórico

- Cólera Asiática em Londres (1855): um poço identificado como a fonte do problema





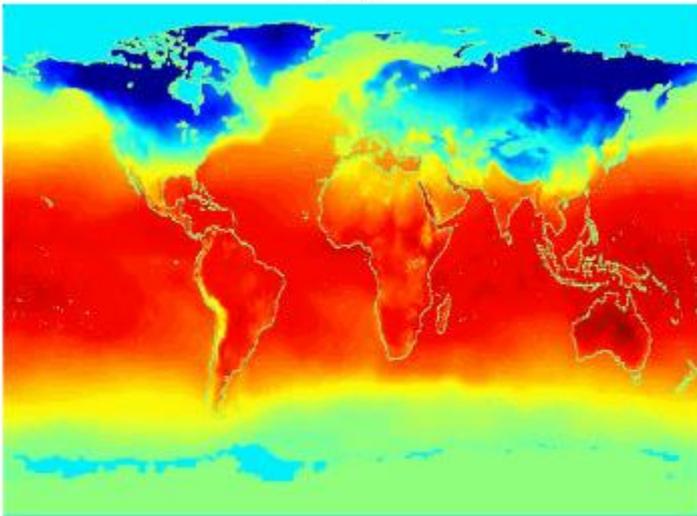
Exemplos Modernos

- *Clusters* de pessoas com cancer para investigar a influência do ambiente
- Locais de concentração de crimes para planejar as rotas de patrulha da polícia
- Identificação de características onde certos tipos de águias fazem os ninhos

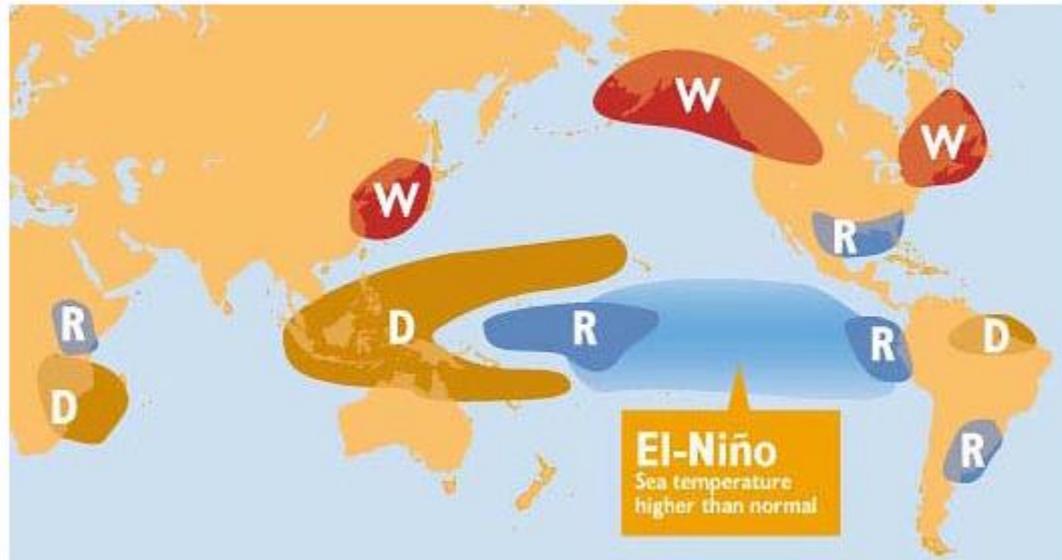
Exemplos Modernos

- Aquecimento anormal de região do oceano Pacífico (El Niño) afeta o clima

Jan



Average Monthly Temperature
(Courtsey: NASA, Prof. V. Kumar)



Global Influence of El Niño during
the Northern Hemisphere Winter
(D: Dry, W: Warm, R: Rainfall)



O que é um padrão espacial?

- O que não é um padrão?
 - Aleatório, ao acaso, acidental
 - Casual

- O que é um padrão (*pattern*)?
 - Um arranjo frequente, configuração, regularidade
 - Uma regra, lei, método
 - Uma direção ou tendência importante
 - Uma irregularidade espacial importante



O que é descoberta de conhecimento em dados espaciais?

- Definindo *Data Mining* Espacial
 - Procura por padrões espaciais
 - Procura não-trivial tão automática quanto possível
 - reduzindo o esforço humano
 - Padrões espaciais interessantes, úteis e inesperados
 - Desconhecidos
 - Auxílio especialista do domínio

O que é *data mining* espacial?

- Busca não trivial por padrões espaciais **interessantes e desconhecidos**
- Busca não trivial
 - Grande (ex. exponencial) espaço de busca de hipóteses plausíveis
 - Ex. Cólera Asiática - causas plausíveis: água, alimento, ar, insetos, ...;
- Interessante
 - Útil em algum domínio de aplicação
 - Ex. Desativando o poço identificado => salvar vidas humanas
- Inesperado
 - O padrão não é conhecimento comum
 - Pode levar a um novo entendimento do mundo
 - Ex. A conexão Poço - Colera levou a teoria do “germe”



O que NÃO é *data mining* espacial?

- Consultas simples a dados espaciais
 - Encontre os vizinhos de Porto Alegre dados os nomes e limites de todas as cidades
 - Encontre o menor caminho do RS a SP na malha de rodovias
 - O espaço de busca não é grande (não é exponencial)

- Testar uma hipótese através de uma análise simples de dados
 - Ex. O território das chimpanzes femeas é menor do que o dos machos
 - O espaço de busca não é grande!

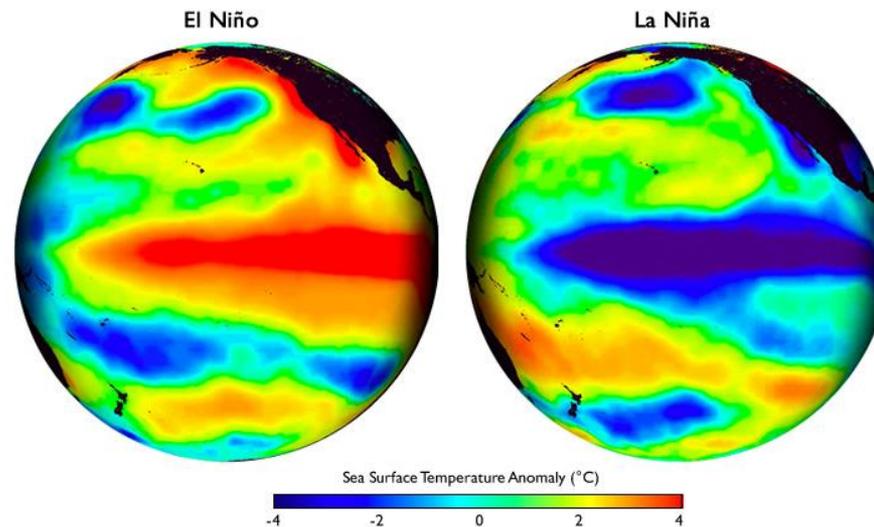
O que NÃO é *data mining* espacial?

- Padrões espaciais não interessantes ou óbvios
 - Muita chuva em Porto Alegre está correlacionada com muita chuva em Canoas, dado que as duas cidades são vizinhas.
 - Conhecimento comum: lugares próximos tem precipitações similares

- Mineração de dados não espaciais
 - As vendas de fraldas e cervejas são correlacionadas nas sextas-feiras

Porque estudar mineração de dados espaciais?

- Novo conhecimento dos processos geográficos para questões críticas
 - Ex. Como está a saúde do planeta Terra?
 - Ex. Caracterizar os efeitos da atividade humana para o ambiente e a ecologia
 - Ex. Predizer o efeito do El Niño no clima e na economia





Porque estudar mineração de dados espaciais?

- Abordagem tradicional: gerar e testar hipóteses manualmente
 - Mas os dados espaciais estão crescendo rápido demais para uma análise manual
 - Imagens de satélite, trajetórias geradas por GPS, sensores em rodovias, ...
 - Número de hipóteses geográficas possíveis é grande demais para uma análise manual
 - Grande número de objetos geográficos
 - O número de relacionamentos entre os objetos cresce exponencialmente
 - Ex. Encontre correlação entre eventos climáticos oceânicos e em terra firme
- *Data Mining* Espacial pode reduzir o conjunto de hipóteses plausíveis

Escolha dos métodos

- Duas abordagens:
 - Uso de técnicas específicas para mineração de dados espaciais
 - Obtenção dos dados ou relacionamentos espaciais de interesse para uso com métodos de DM clássicos

- Abordagem possível:
 - Defina o problema: obtenha as necessidades particulares
 - Analise os dados usando mapas e outras técnicas de visualização
 - Tentar usar métodos clássicos de *data mining*
 - Se não obtiver resultados satisfatórios, tente novos métodos
 - Avalie os métodos escolhidos rigorosamente

Famílias de padrões espaciais

- Famílias comuns de padrões espaciais
 - Classificação
 - *Clustering*
 - Detecção de *Outliers*
 - Co-location
 - Trajetórias
 -

- Outras famílias podem ser definidas

Classificação

- Dado um conjunto de instâncias, a função da classificação é descobrir as classes das instâncias

- Objetos podem ser caracterizados, classificados, por diferentes tipos de informações
 - Atributos não espaciais (população)
 - Atributos espacialmente relacionados com valores não-espaciais (população total que vive a menos de 100 metros das antenas celulares);

Remote Sensing Data Mining (Silva et al. 2008)

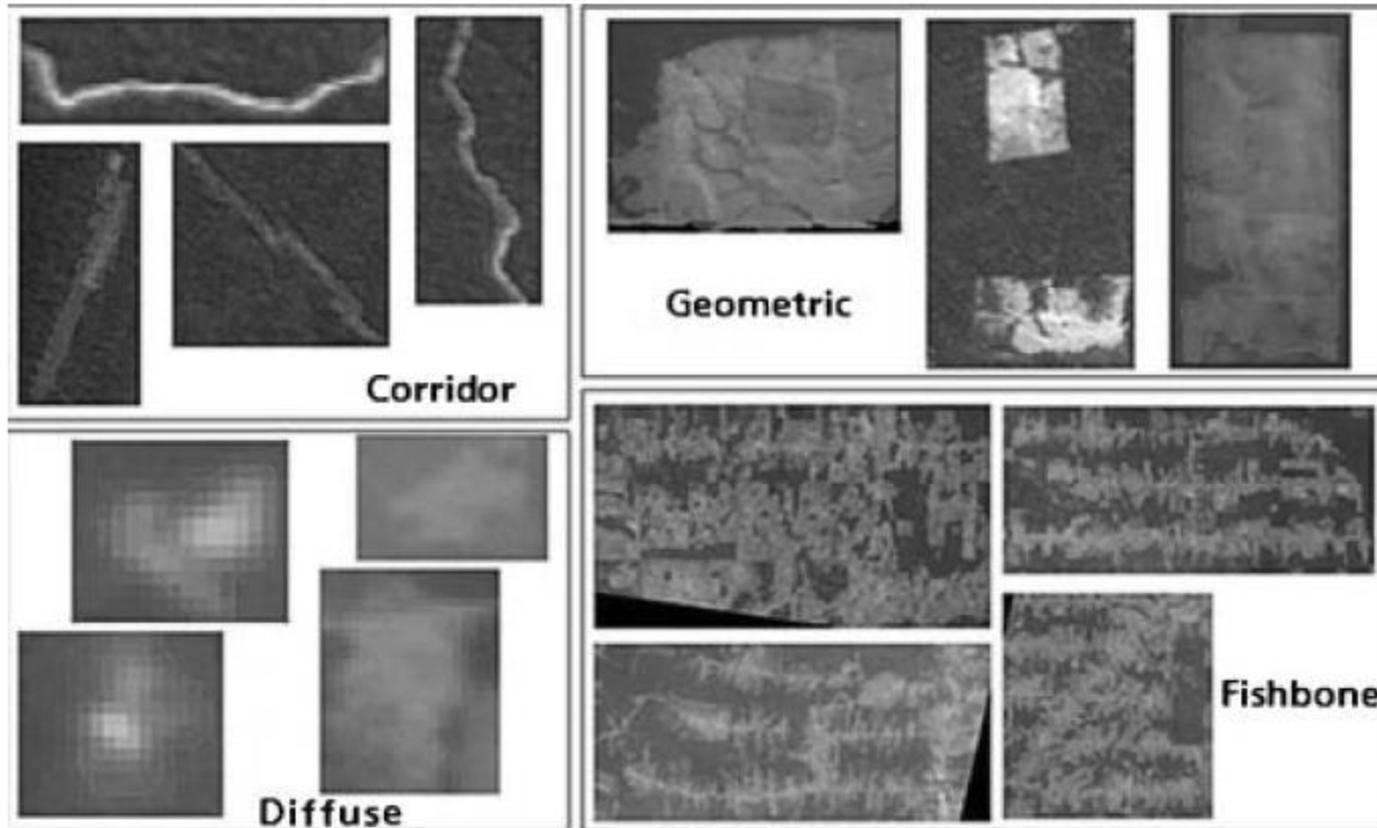


Figure 2. Examples of patterns of tropical deforestation proposed by Mertens and Lambin (1997) in the Brazilian Amazonia: corridor, diffuse, fishbone, and geometric.

Método

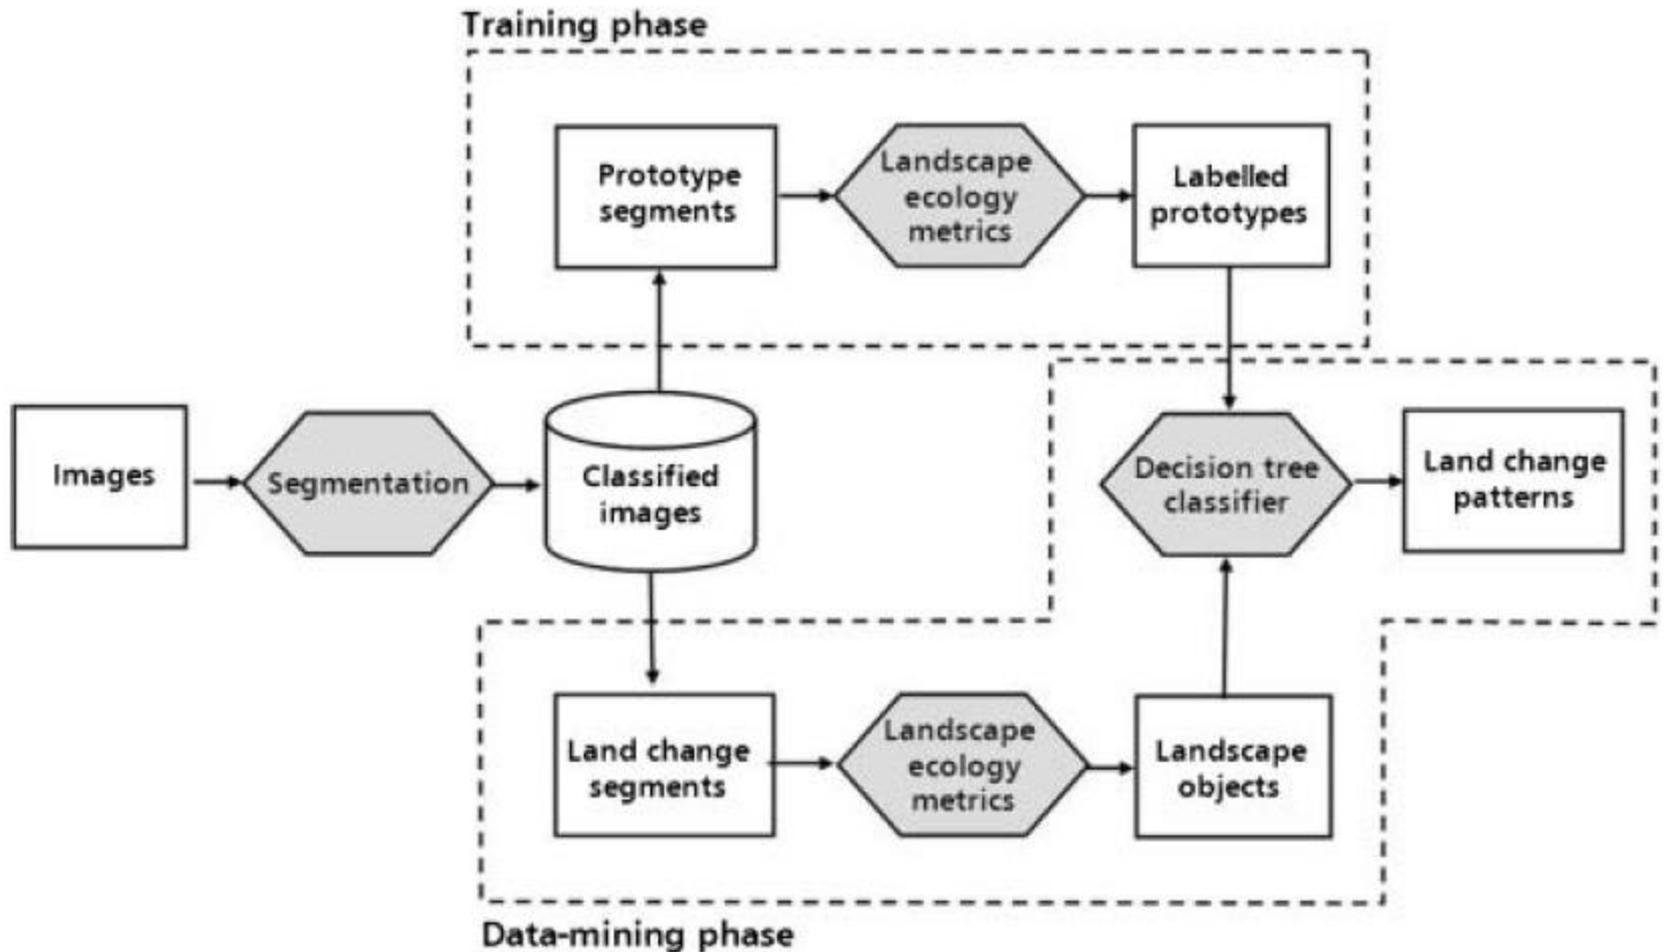


Figure 1. Proposed method for remote sensing image mining.



Métricas de Ecologia da Paisagem

- Perimeter (m):

$$\text{PERIM} = p_{ij}. \quad (1)$$

- Area (ha):

$$\text{AREA} = (a_{ij}/10\,000). \quad (2)$$

- PARA, perimeter–area ratio, a measure of shape complexity:

$$\text{PARA} = \frac{p_{ij}}{a_{ij}}. \quad (3)$$

- Shape, shape compactness index, calculated by the patch perimeter p_{ij} divided by $p_{ij \text{ min}}$, which is the minimum perimeter possible for a maximally compact patch of the matching patch area. It is equal to 1 when the region is a square and grows according to the region's irregularity.

$$\text{SHAPE} = \frac{p_{ij}}{p_{ij \text{ min}}}. \quad (4)$$

Árvore de Decisão

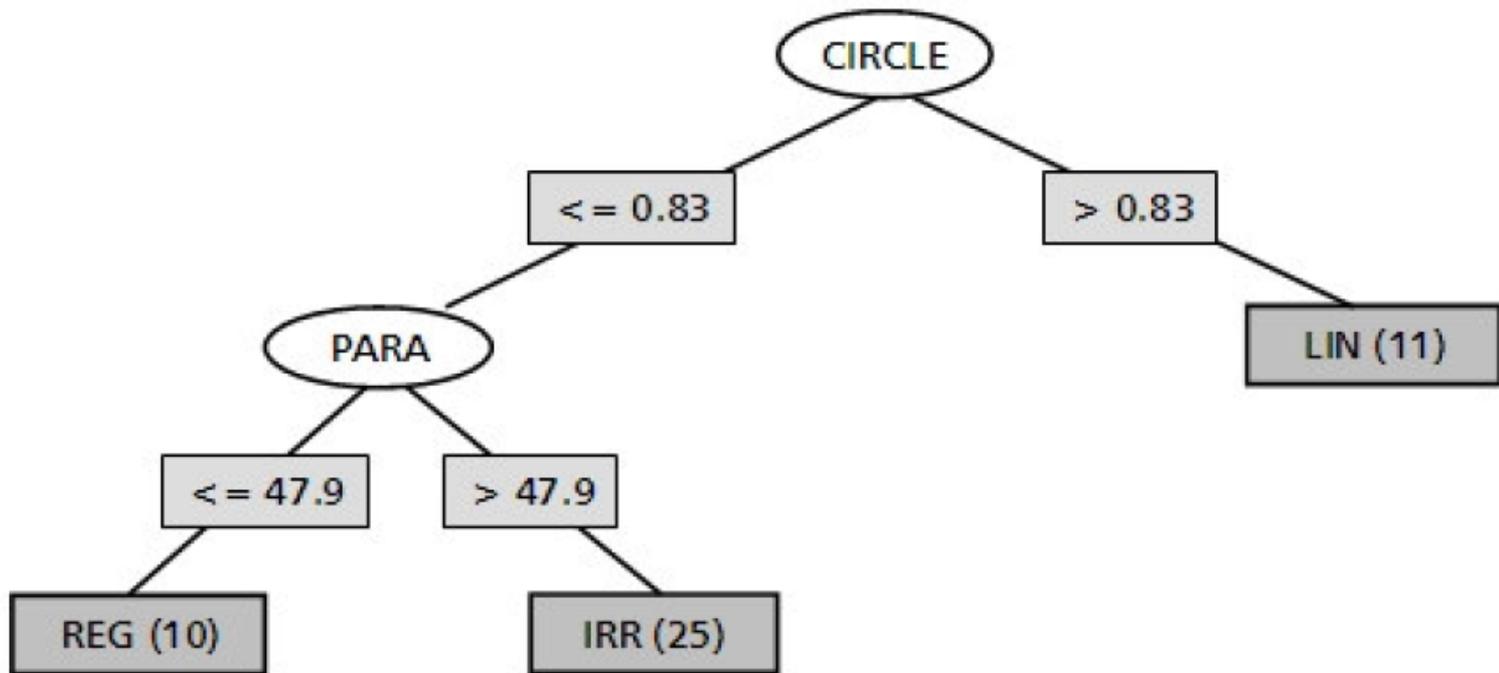
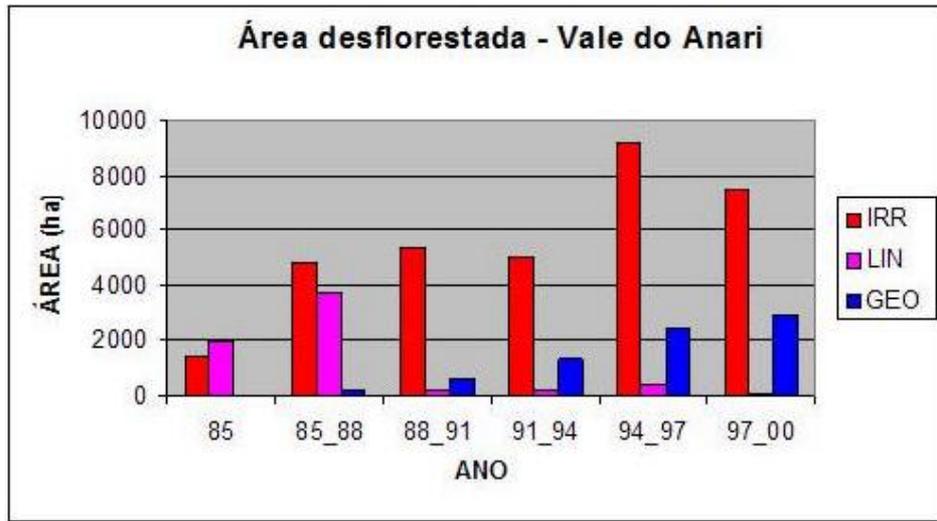
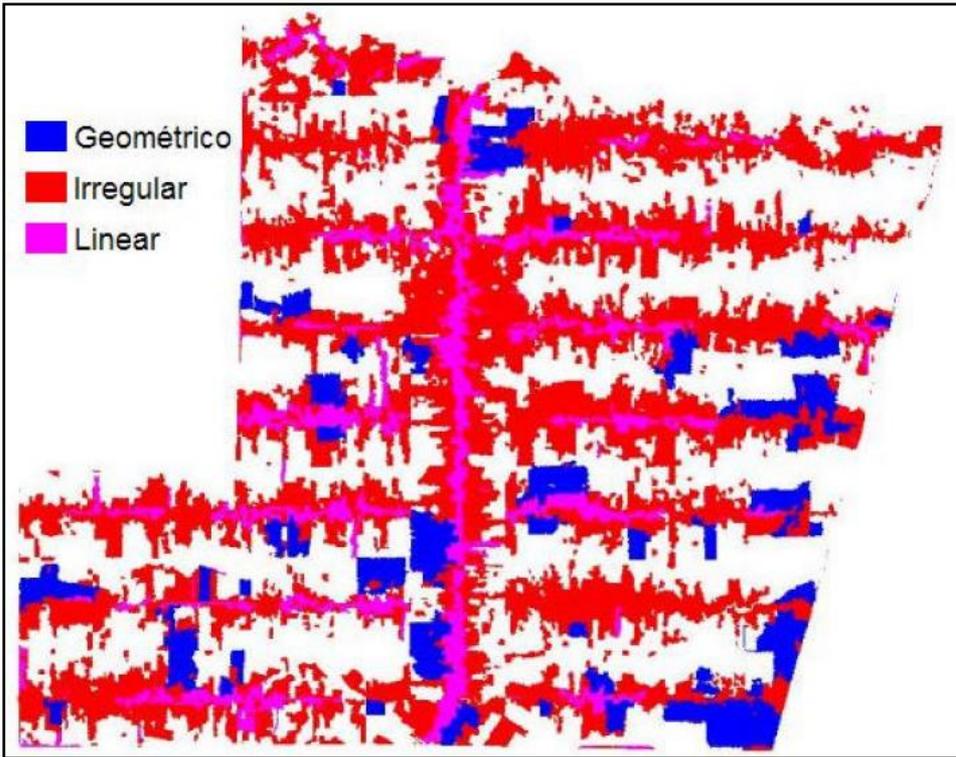


Figure 11. Decision tree for Vale do Anari spatial patterns. The metrics are: perimeter/area ratio (PARA) and circumscribing circle (CIRCLE).

Resultados



Clustering (cluster analysis)

- *Clustering* é um processo de particionamento de um conjunto de dados em um conjunto de grupos chamados *clusters*

- Um cluster é um conjunto de dados (objetos) com características similares
 - que podem ser tratadas coletivamente como um grupo

- *Clustering* é um método não supervisionado
 - não há classes pré-definidas

Clustering Analysis (Kumar 2005)

- Diferentes formas de agrupamento para o mesmo conjunto de pontos



How many clusters?



Six Clusters



Two Clusters



Four Clusters



Principais categorias de *clustering*

- Métodos de Particionamento
 - A divisão de dados em subconjuntos (*clusters*)
 - Dados n objetos, o método constrói k partições, onde cada partição representa um grupo, e $k \leq n$.

- Métodos Hierárquicos
 - Um conjunto de clusters aninhados organizado como uma árvore hierárquica

- Métodos Baseados em Densidade
 - Encontra grupos com base na densidade das regiões

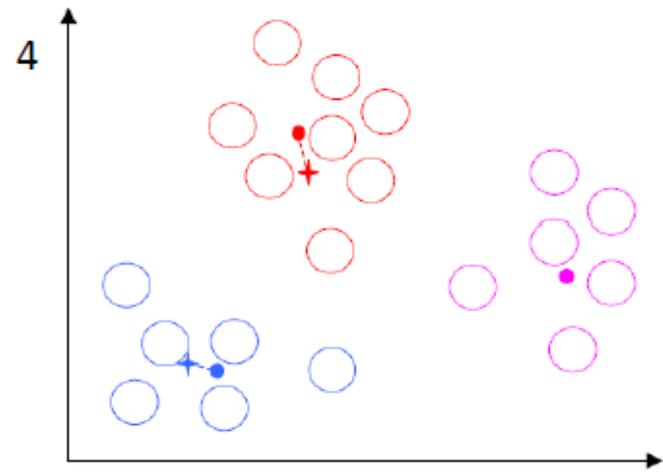
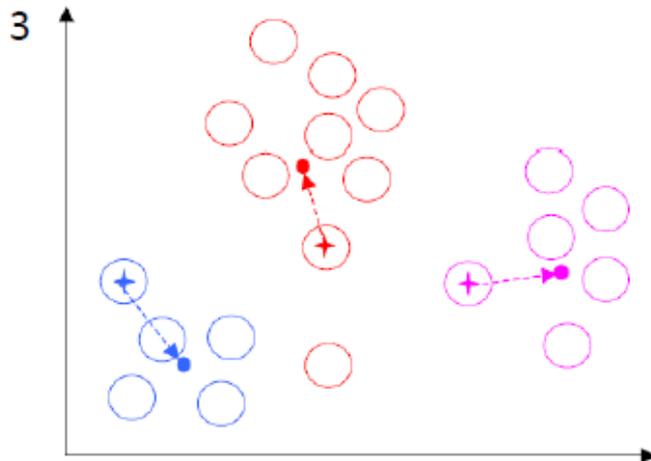
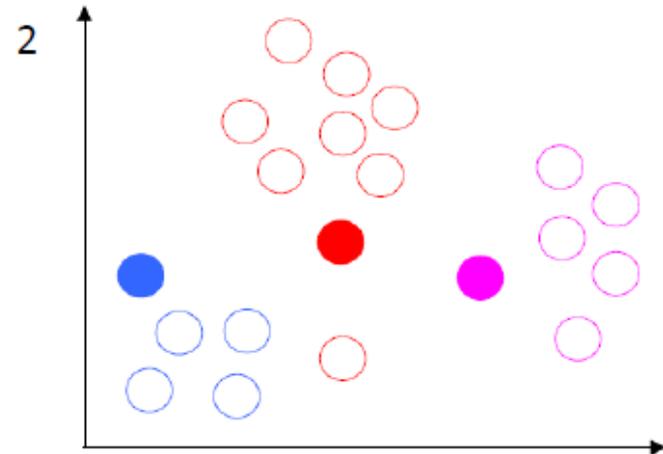
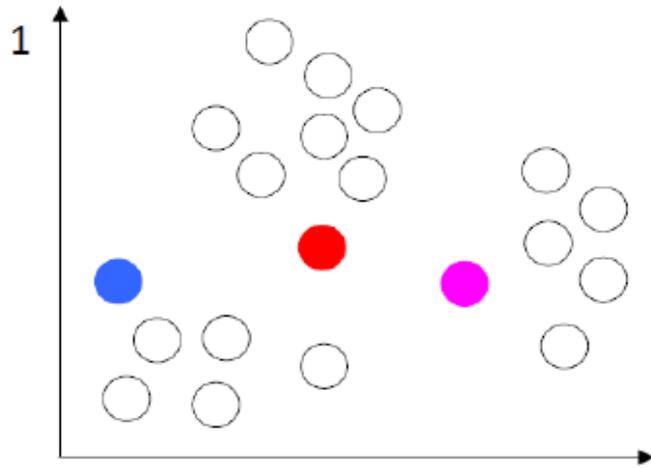
- Baseado em Grades
 - Encontrar grupos com base no número de pontos em cada célula



K-Means

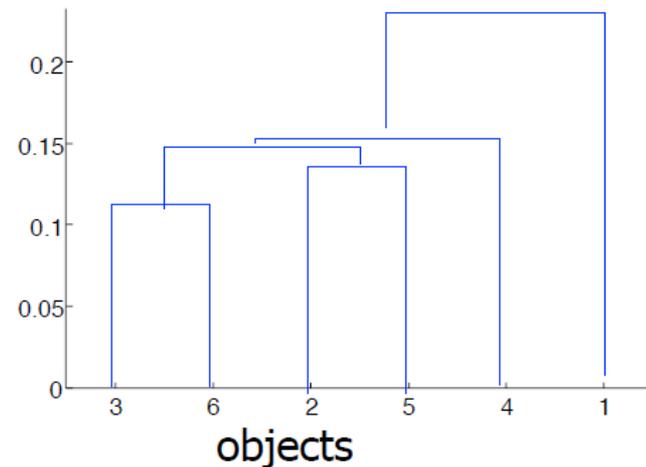
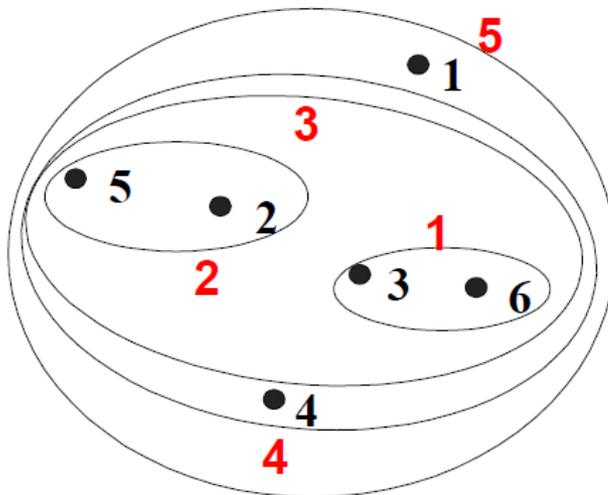
- Métodos de Particionamento
- Cada conjunto está associado com um centroide
- Cada ponto é atribuído ao grupo com o centroide mais próximo
- A desvantagem das k-means é que o número de *clusters* K é um parâmetro de entrada

K-Means



Hierarchical Clustering

- Existem dois tipos principais: Divisivo e Aglomerativo
- Aglomerativo
 - Começa com todos os objetos como aglomerados individuais
 - A cada passo, uni os dois *clusters* mais semelhantes
 - Até restar um *cluster* (ou *k clusters*)

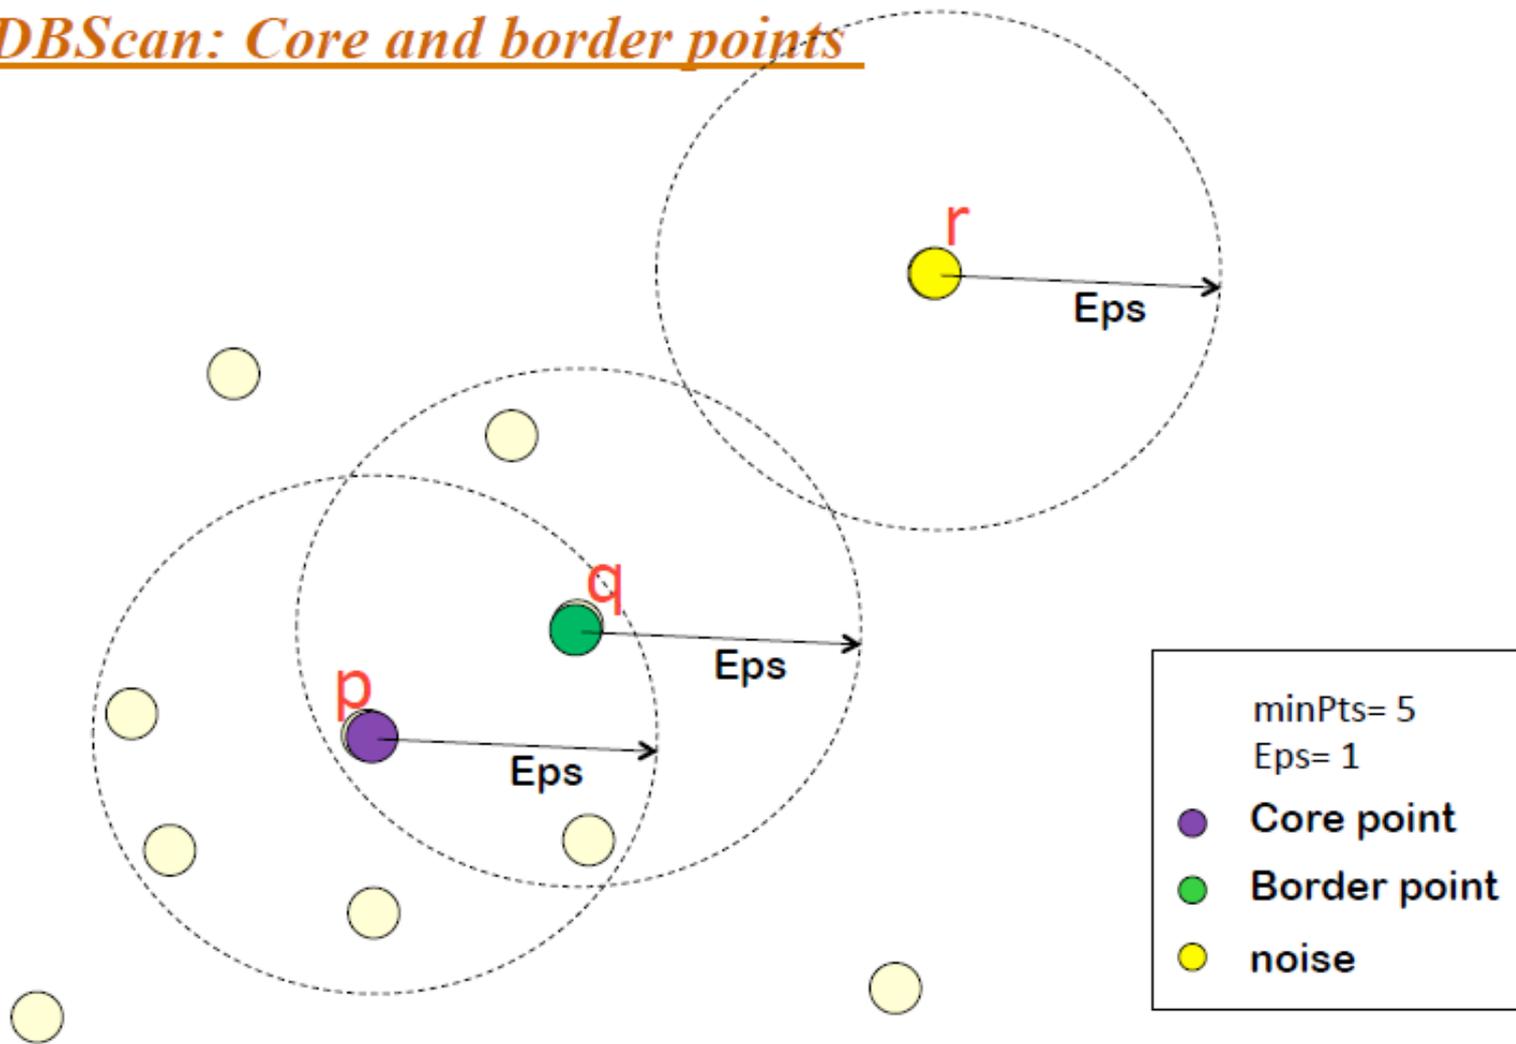




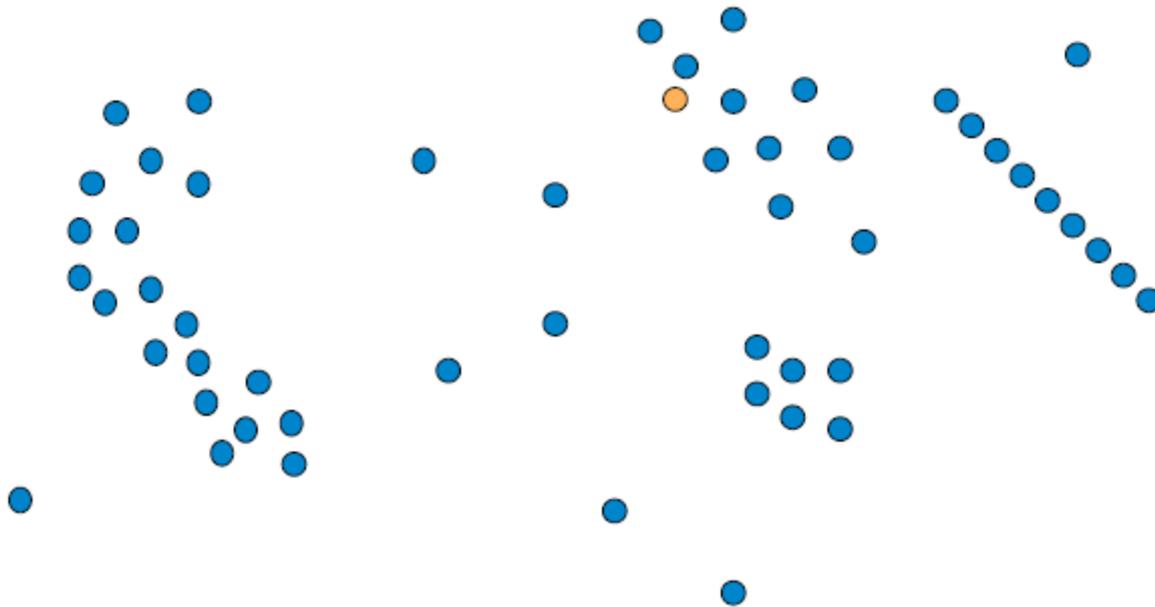
DBSCAN (Ester 1996)

- DBSCAN é um algoritmo baseado em densidade
- Densidade = número de pontos dentro de um raio específico (EPS)
- Um ponto é um ponto central
 - se tem mais do que um determinado número de pontos (MinPts) dentro Eps
- Um ponto de fronteira
 - tem menos que MinPts dentro Eps, mas está na vizinhança de um ponto central
- Um ponto de ruído é qualquer ponto que não é um ponto central ou um ponto de fronteira.

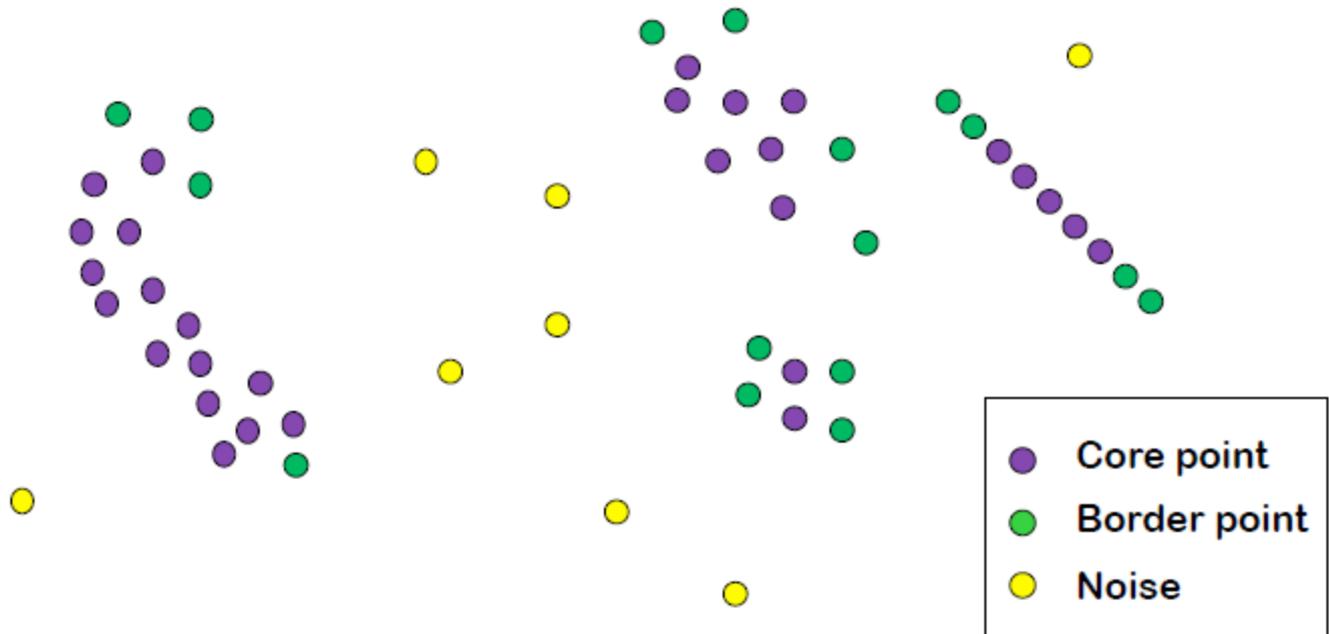
DBScan: Core and border points



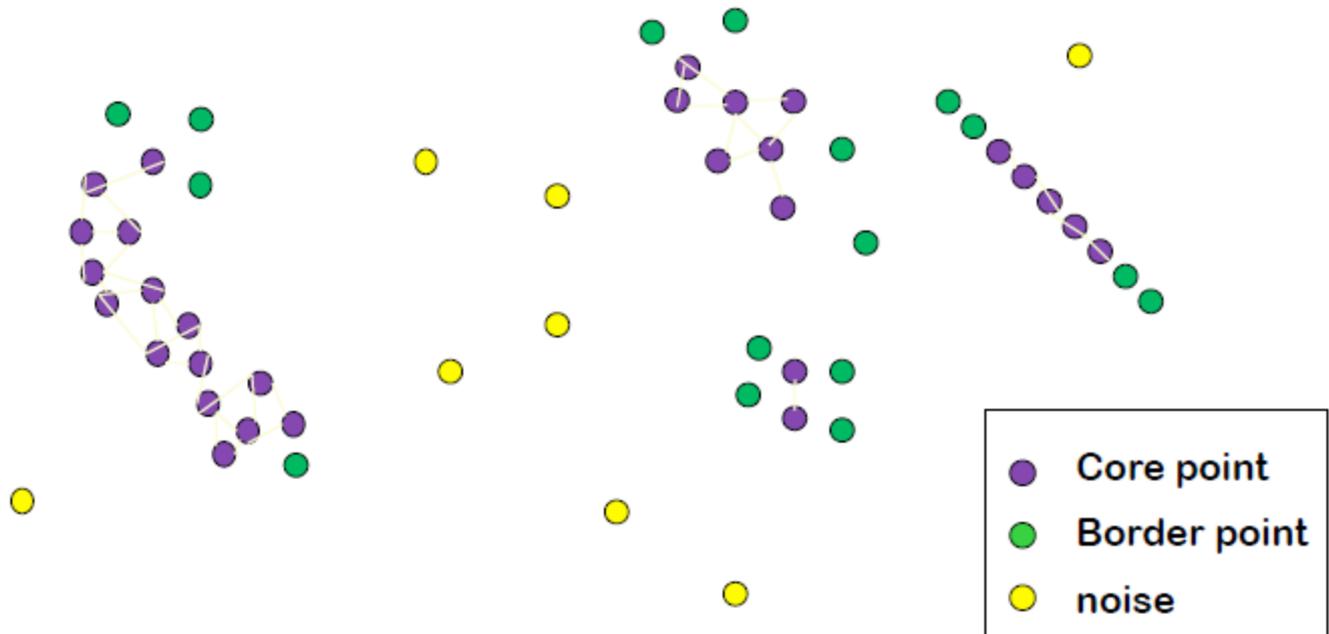
DBSCAN example



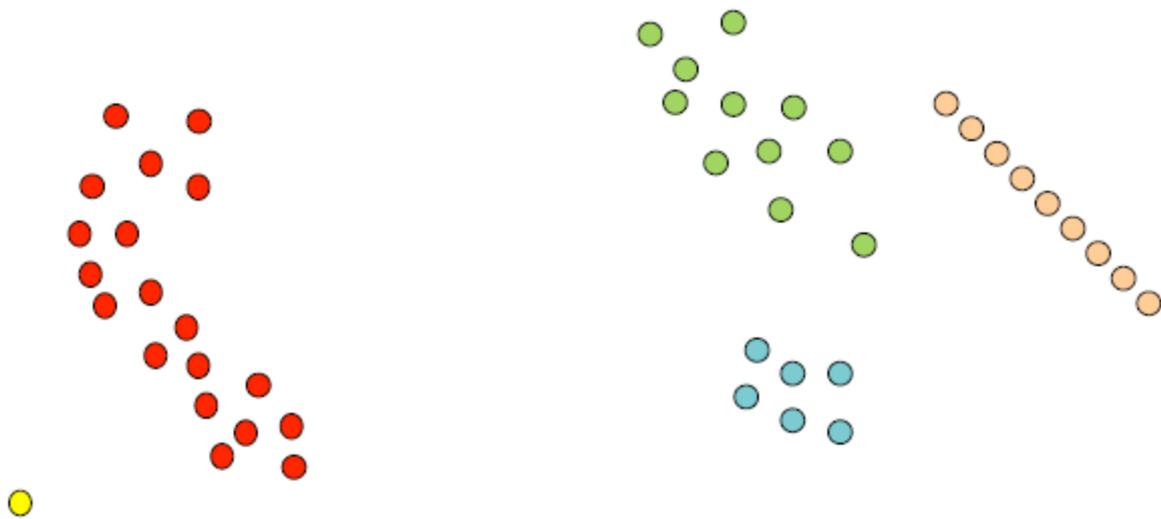
Identifying core, border and noise points



Computing distance



Final Clusters



Detecção de *Outliers*

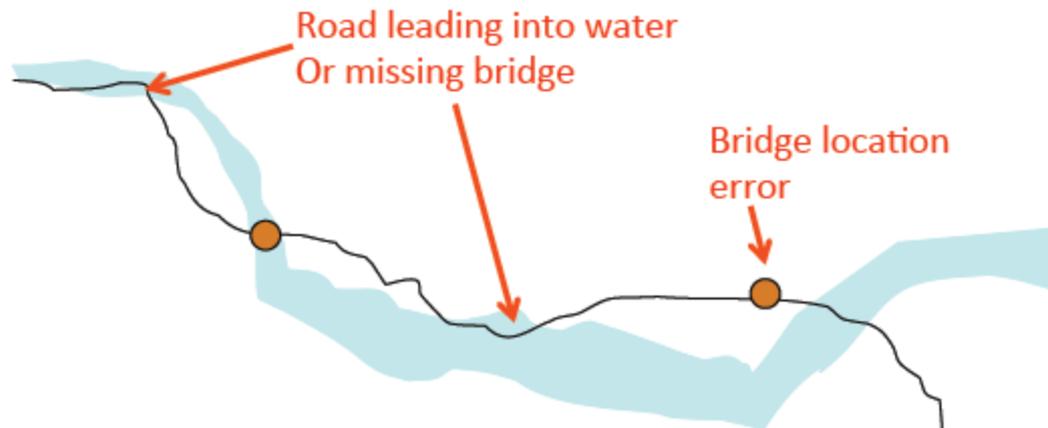
- O que é um *outlier*?
 - Observações inconsistentes com o resto do conjunto de dados

- O que é um *outlier* espacial?
 - Observações inconsistentes com sua vizinhança
 - Uma instabilidade ou descontinuidade locais

Outliers – Examples (Shekhar 2003)

❖ Map Production

- ❑ Error identification
- ❑ E.g., spatial object violation

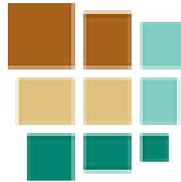




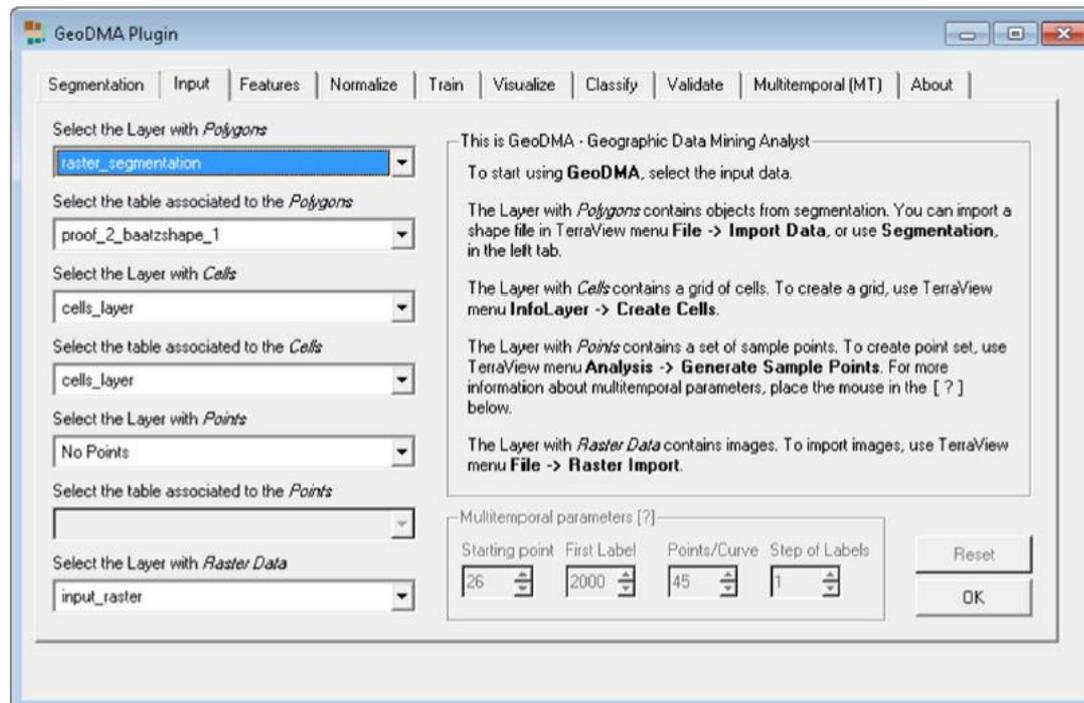
Ferramentas

- GeoMiner (Han 1997)
- INGENS (Malerba 2001)
- Weka-GDPM (Bogorny 2006)
 - <http://www.inf.ufsc.br/~vania/software.html>
- GeoDMA (Korting 2013)
 - <http://www.dpi.inpe.br/menu/Projetos/geodma.php>
- Spatial Data Mining and Visual Analytics Lab
 - <http://www.spatialdatamining.org>
- GeoImageRMP - Rapid Miner extension (Guyet 2013)
 - <http://geoimagermp.gforge.inria.fr>
- Lista com outros *softwares*
 - http://www.spatial.cs.umn.edu/sdm_software.htm
 - <http://www.rdatamining.com/resources/tools>

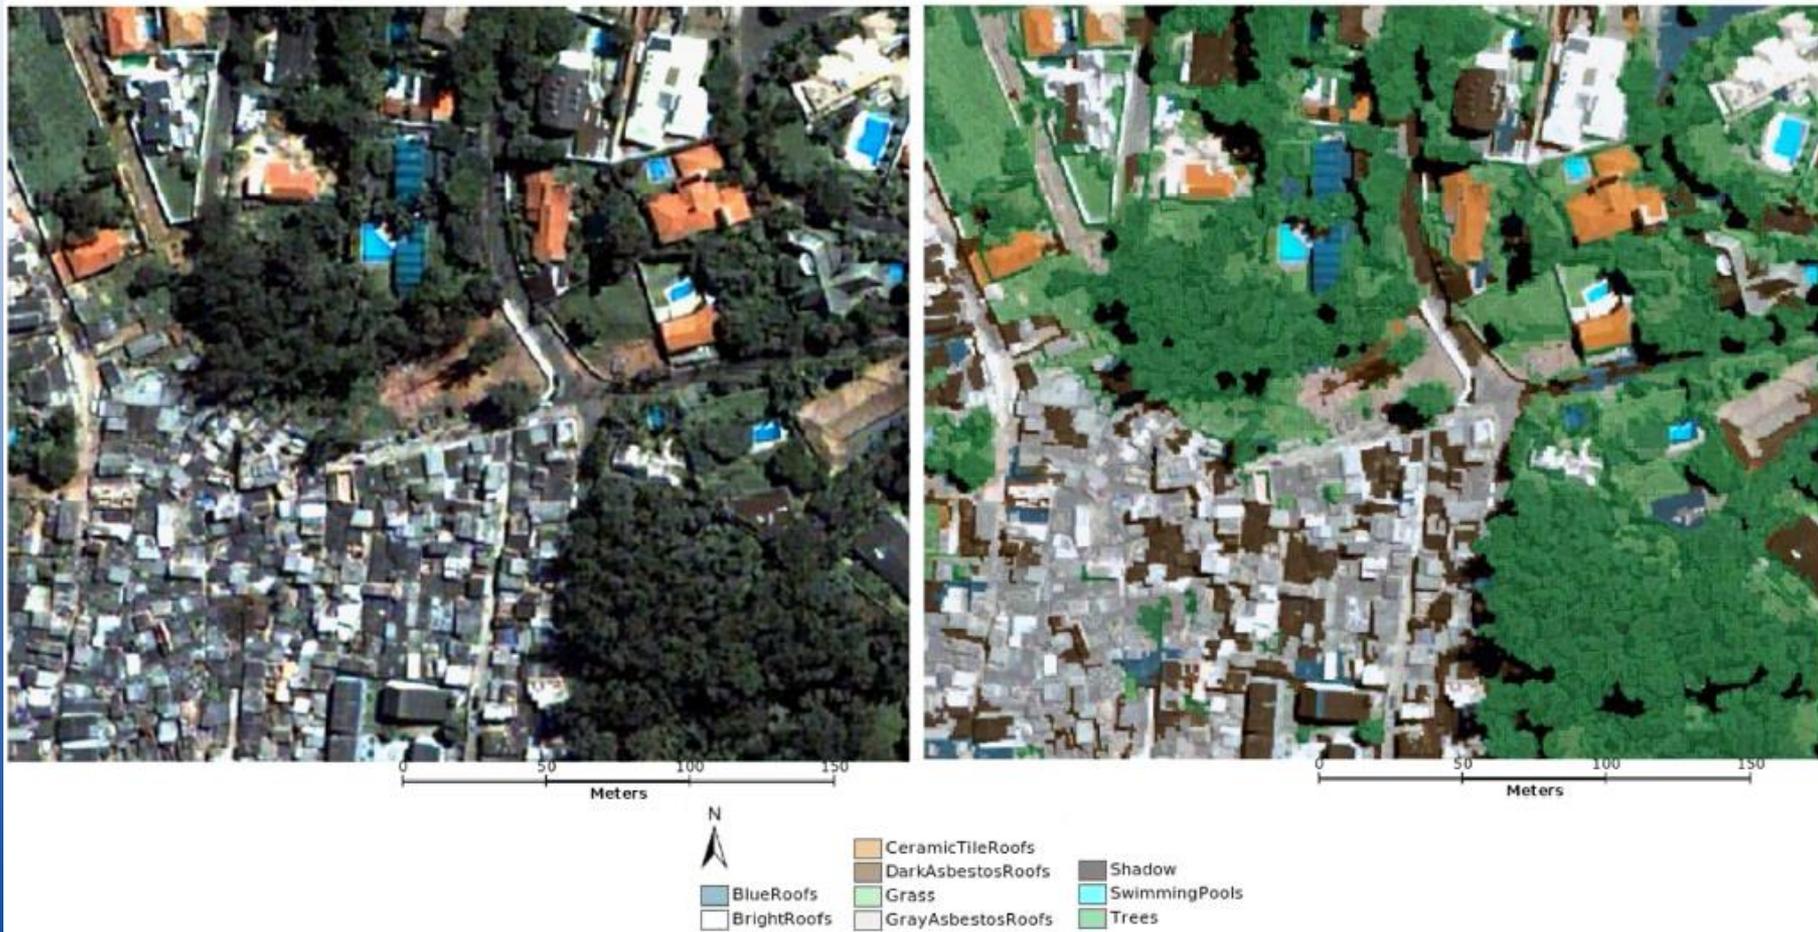
Geographic Data Mining Analyst (GeoDMA)



- Sistema que permite a aplicação de técnicas de mineração de dados espaciais sobre unidades de paisagem definidas por processos de segmentação

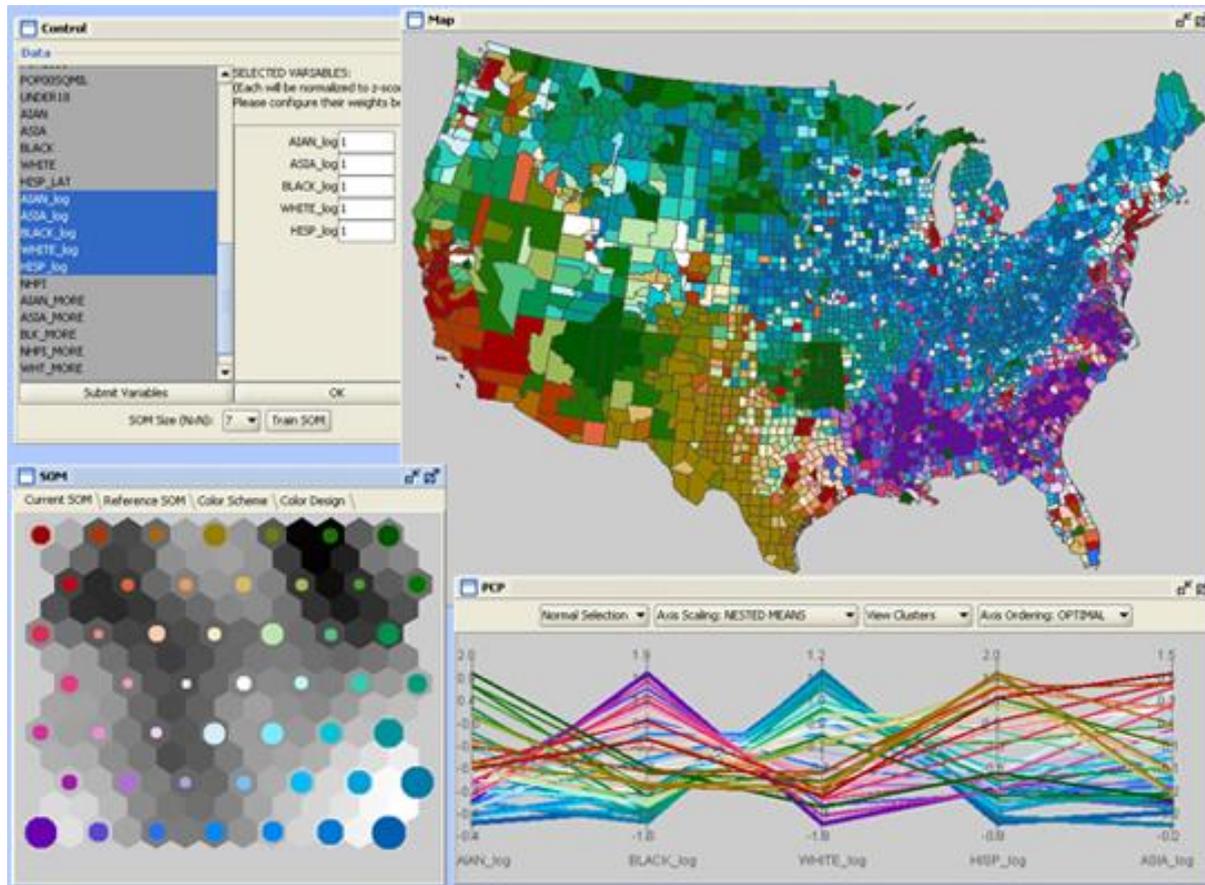


GeoDMA



Fonte: Korting et al. (2013)

SOMVIS: Multivariate Mapping and Visualization





Referências

- Adaptado de material elaborado pelo Prof. Shashi Shekhar, University of Minnesota www.cs.umn.edu/~shekhar
- SHEKHAR, S., CHAWLA, S. **Spatial databases: a tour**. Upper Saddle River, NJ: Prentice Hall, 2003.
- Bogorny, V. and Shekhar S. **Tutorial on Spatial and Spatio-Temporal Data Mining In: SBBD 2008**. (<http://www.inf.ufsc.br/~vania/tutorial.zip>).
- FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI Magazine**, AAAI Press, v. 17, p. 37–54, 1996. Disponível em: <http://www.aaai.org/aitopics/assets/PDF/AIMag17-03-2-article.pdf>.
- HAN, J.; KAMBER, M.; PEI, J. **Data Mining: Concepts and Techniques**. 3rd ed.. ed. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2011.