

**WORKSHOP  
ANÁLISIS  
DE DATOS**

**16 al 18 JUNIO 2020 | 19:00 HORAS**



Clodis Boscarioli  
[boscarioli@gmail.com](mailto:boscarioli@gmail.com)



**Disertante:**  
**Prof. Dr. Clodis Boscarioli**  
Universidade Estadual do Oeste do Paraná

**ORGANIZA:**



**FINANCIADO POR:**



- 16** Minería de datos para toma de decisiones: conceptos principales.  
Prof. Dr. Clodis Boscarioli
- 17** Modelos predictivos de ventas para recomendación de stock.  
Prof. Dr. Clodis Boscarioli  
Rodrigo Pereira Fontes
- 18** Uso de Business Intelligence y Analytics en la gestión de la construcción civil.  
Prof. Dr. Clodis Boscarioli  
Anderson Brunheira Lopes



**unioeste**

Universidade Estadual do Oeste do Paraná



**PPGTGS**



**PPGComp**

# ***Mineração de Dados para Tomada de Decisões: Conceitos Principais***

***Clodis Boscarioli***

# Me apresentando...



**Clodis Boscarioli**





Silva, L. A., Peres, S. M. e Boscarioli, C. Introdução à Mineração de Dados com Aplicações em R. Editora Elsevier, Rio de Janeiro, 2016.

# Agenda

- Conceitos gerais de BI&A
- BIA& KDD
- Mineração de Dados



## **BI – Business Intelligence**

Denomina um conjunto de metodologias e ferramentas que permitem às organizações integrar, acessar e compartilhar grandes volumes de informações, de modo a auxiliar a tomada de decisões (Gartner Group)

## **BA – Business Analytics**

Complementa o termo BI incluindo cenários e modelos preditivos

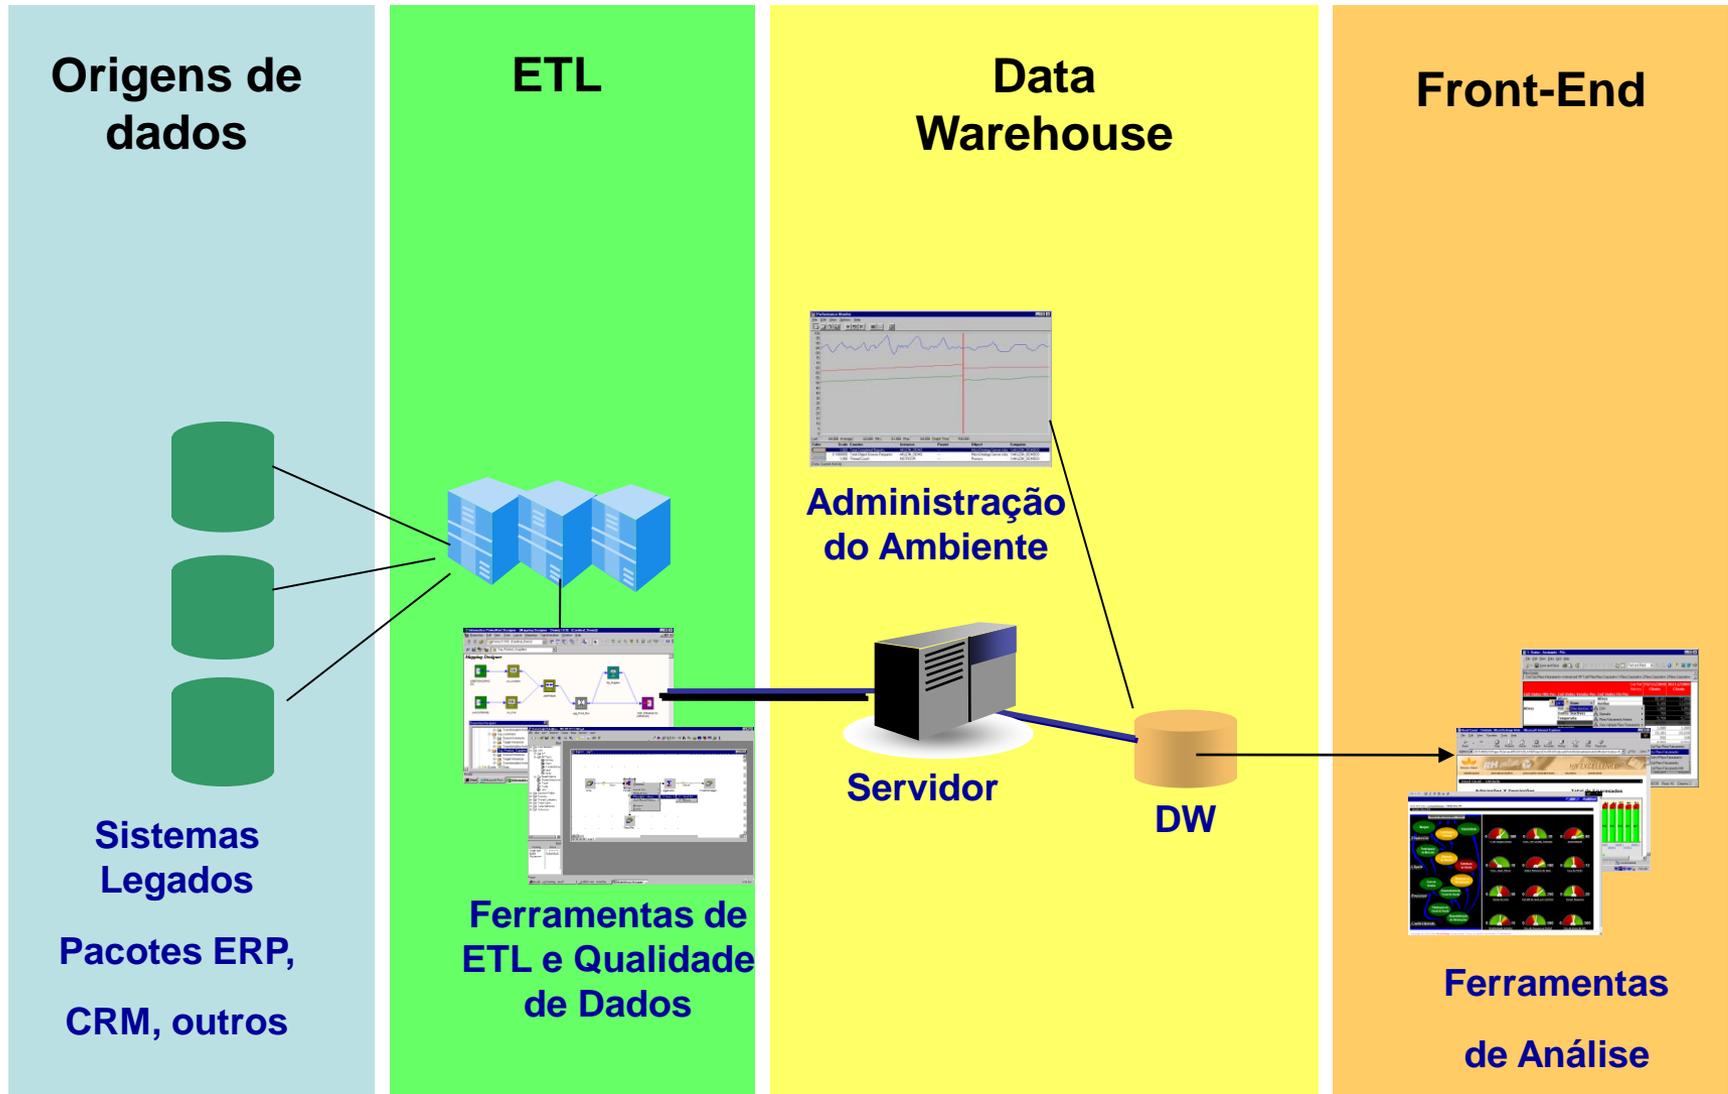
# BI e BA

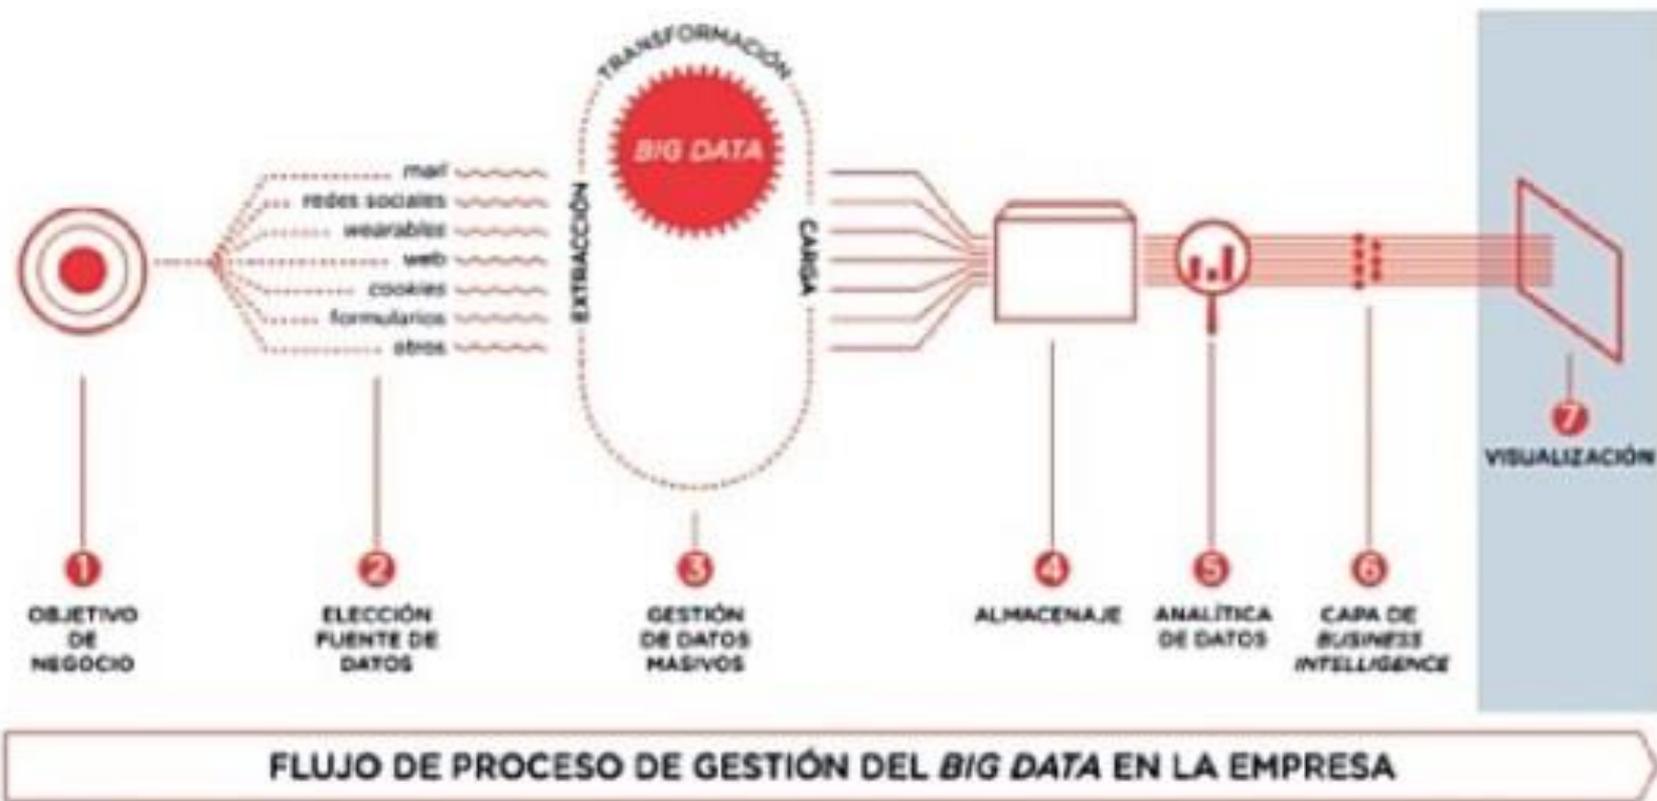
- BI: aborda o que aconteceu no passado e como aconteceu até o momento presente. Identifica tendências e padrões sem investigar ou prever o futuro.
- BA - lida com o “por quê” do que aconteceu no passado. Relação de fatores e causalidades. Fazer previsões do que acontecerá no futuro.

## (BI&A)

- O termo *Business Intelligence and Analytics* (BI&A) trata do desenvolvimento de tecnologias, sistemas, práticas e aplicativos para analisar dados de negócios, a fim de obter novas ideias sobre negócios e mercados, que podem ser usadas para melhorar produtos e serviços, obter melhor eficiência operacional e fomentar o relacionamento com os clientes.

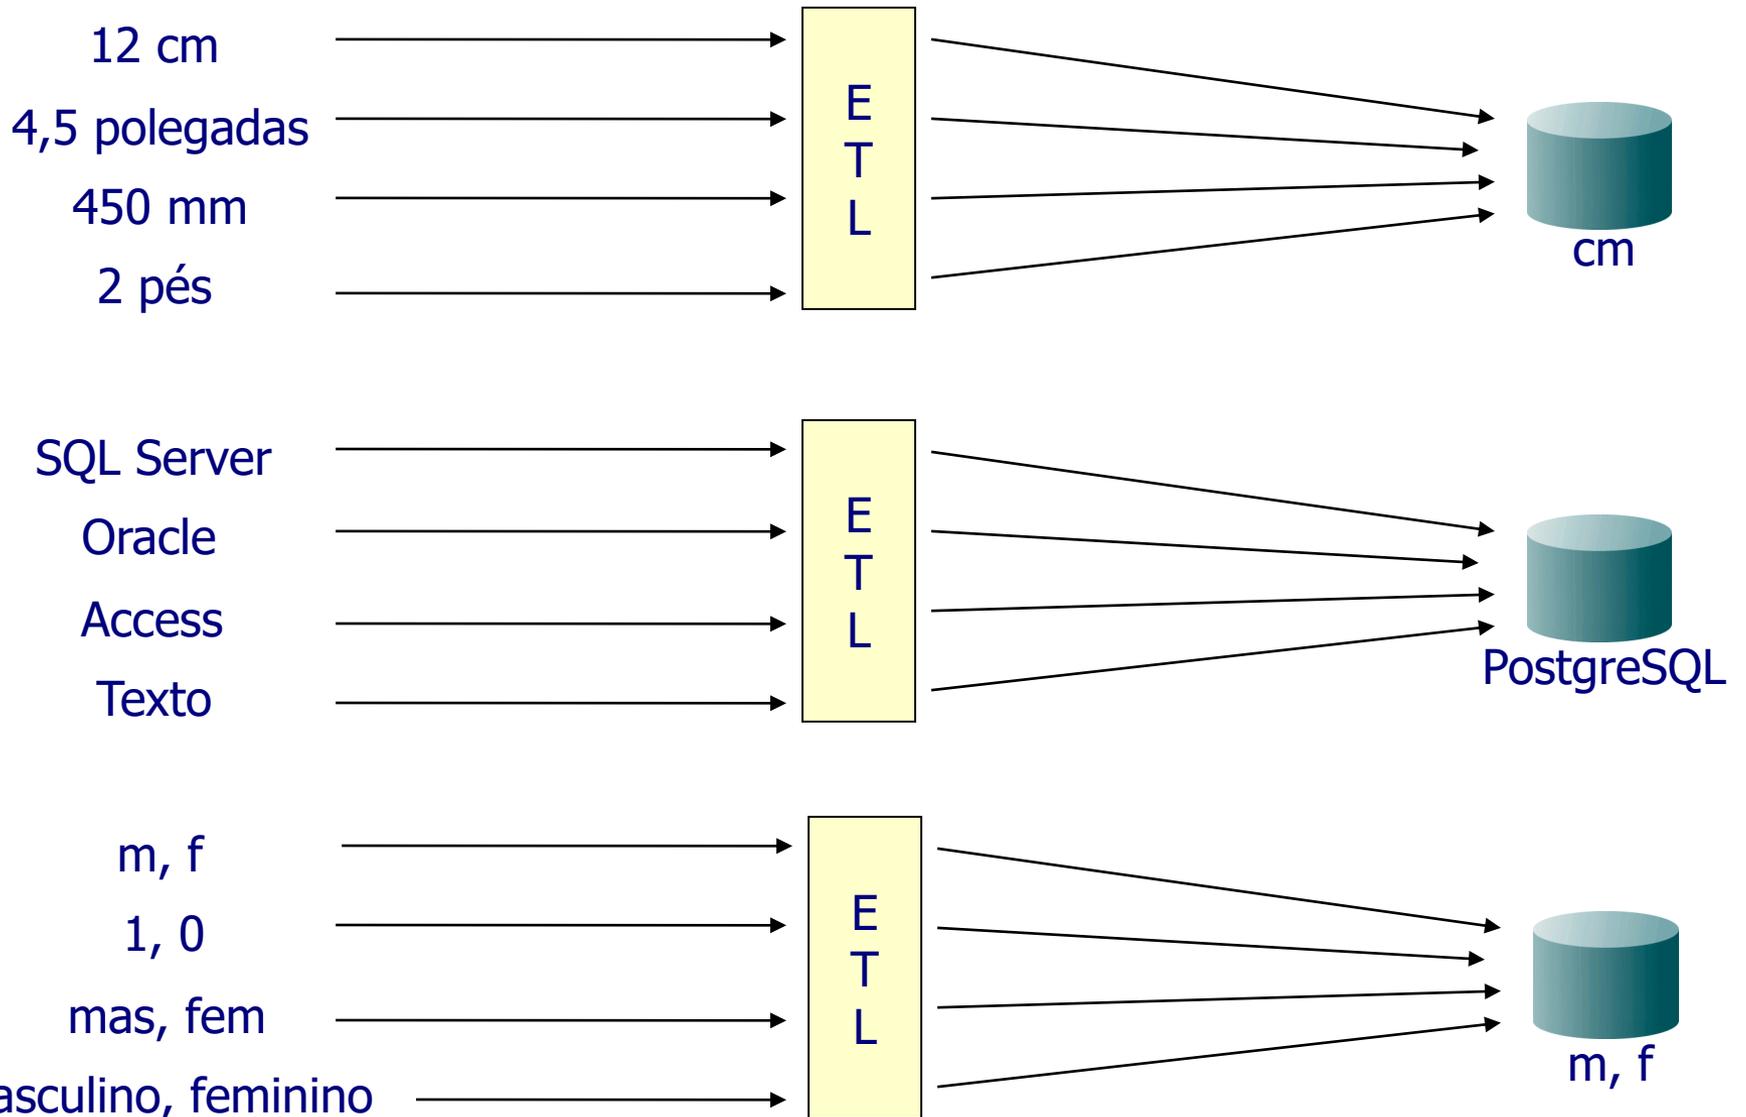
# Arquitetura genérica de um BI&A





Fonte: Manzano et al. (2016)

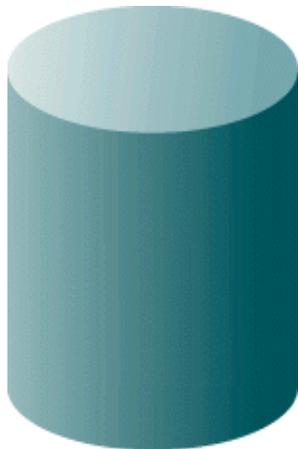
# ETL – Transformação



# DATA WAREHOUSE (DW) - Conceito

## *Armazém de Dados*

É um amplo e flexível repositório de dados, que aglutina dados de fontes heterogêneas, projetado de modo a suportar o processo de tomada de decisão.



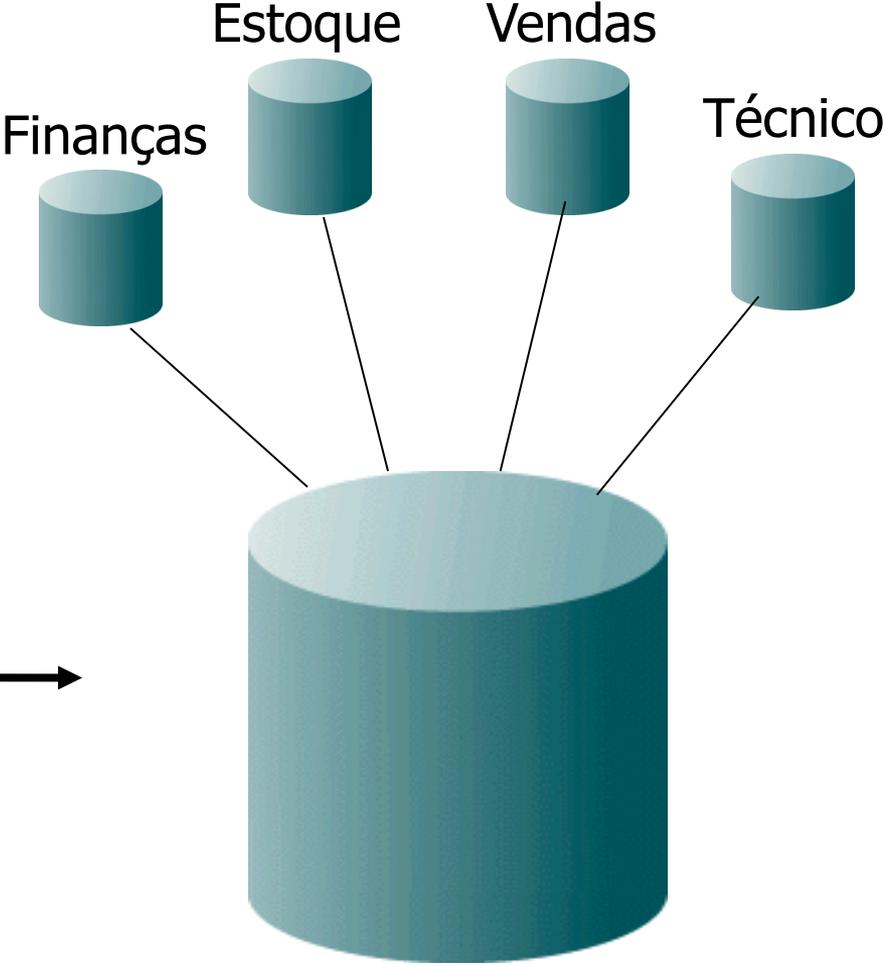
- **Ambiente separado**
- **Disponibilidade**
- **Integrado**
- **Retrato no tempo**
- **Orientado por assunto**
- **Fácil acesso**

# DW - Organização

**DATA MART**  
DW Departamental

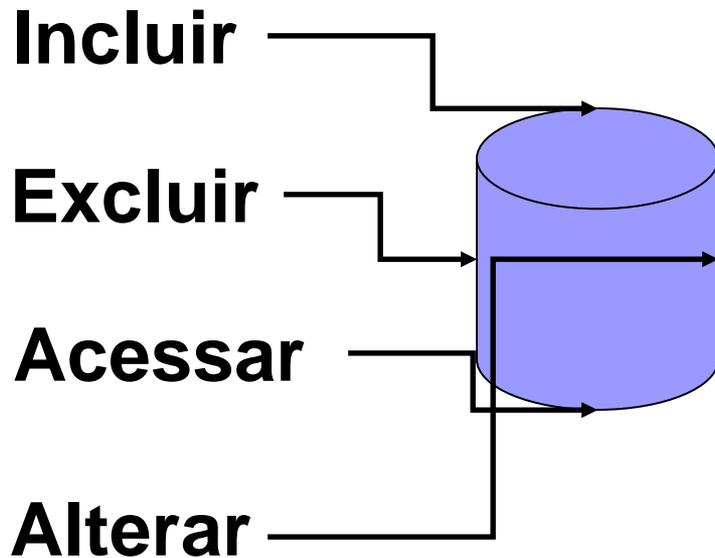


**DATA WAREHOUSE**  
Corporativo

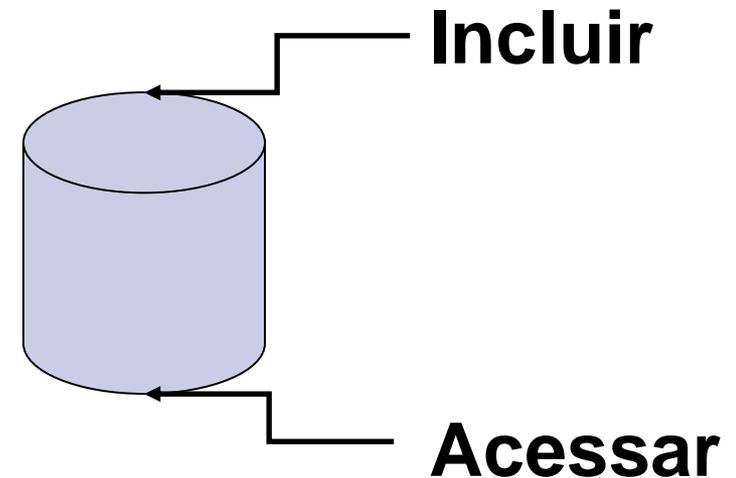


# Conceitos Principais

## Banco de dados Transacional

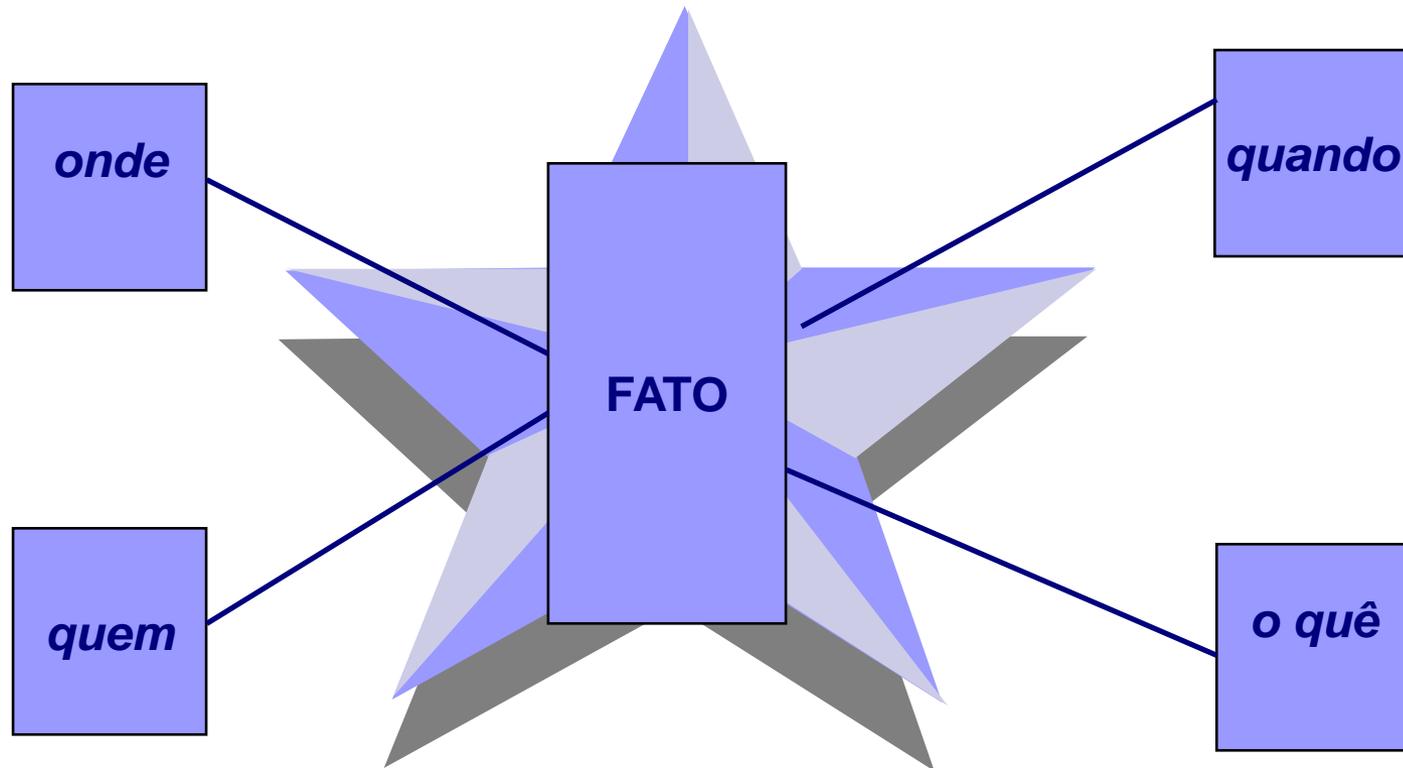


## Data Warehouse



# Modelo Dimensional → Esquema Estrela

- Uma tabela de fatos cercada de tabelas de dimensões



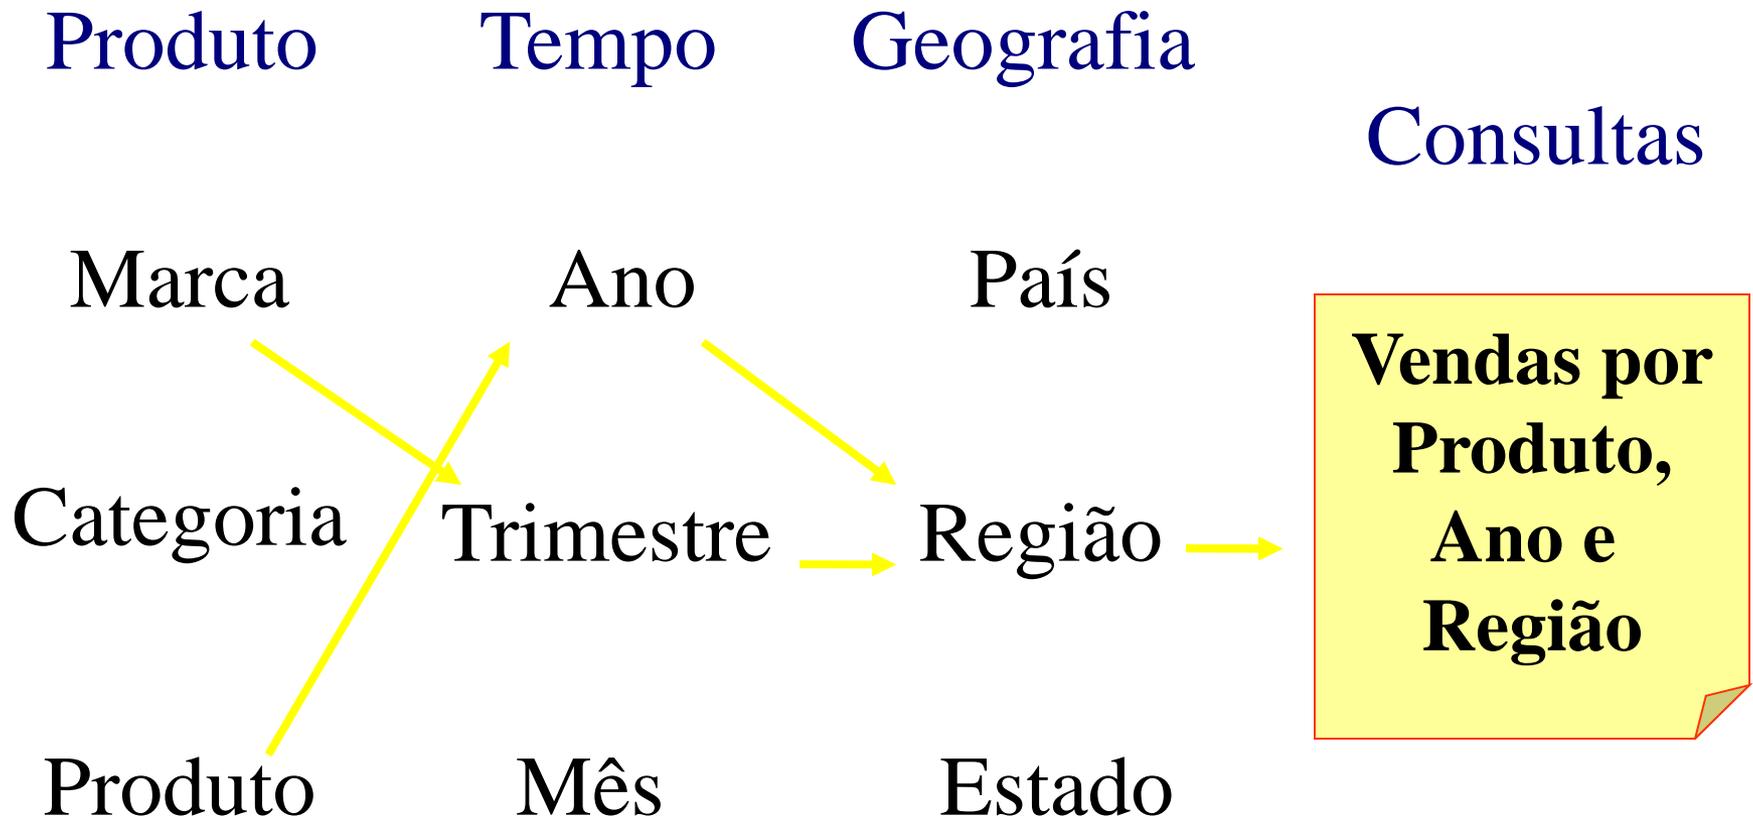
# O componente *Front-End*

- É o que permite ao usuário final acessar os dados do DW
- Também disponibilizado em ambiente web
- Disponibiliza relatórios e um diversificada forma de análises

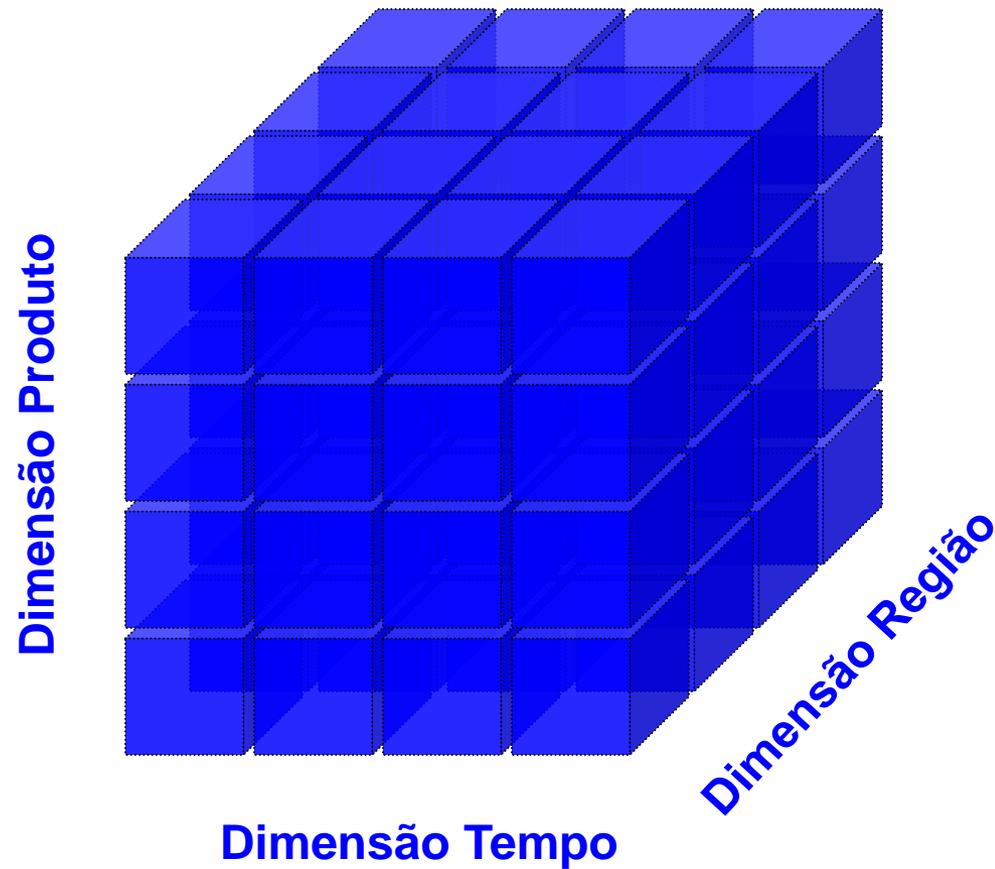
# OLAP (*Online Analytical Processing*)

- Conjunto de processos para criação, gerência e manipulação de dados multidimensionais para análise e visualização, visando maior compreensão dos dados pelos usuários finais.
- Facilidade para fazer análises, definir agregações e cruzamentos, permitindo visualizar os dados em múltiplos níveis de hierarquias e diferentes perspectivas.

# Hierarquias e Agregados

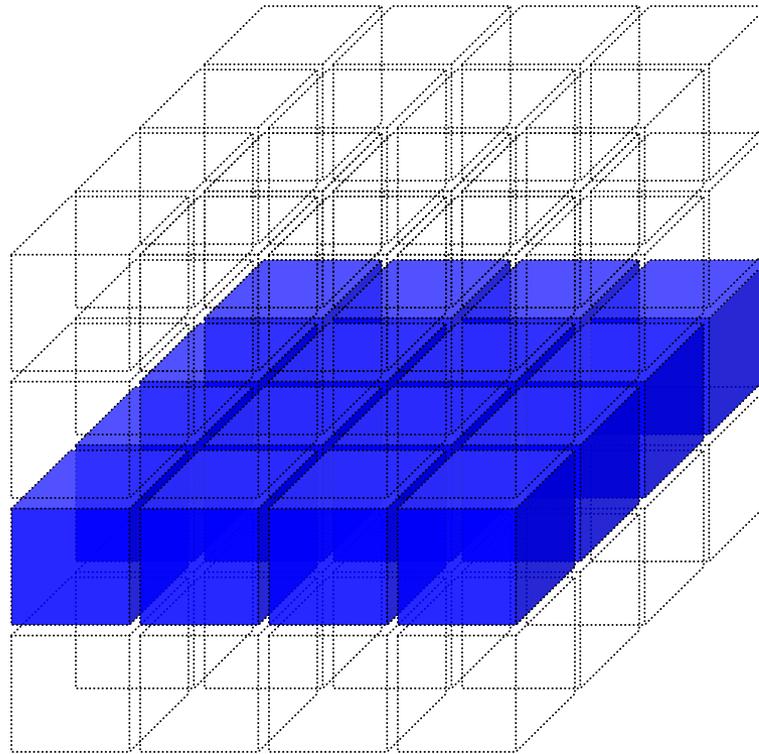


# Exemplos no Cubo de Dados

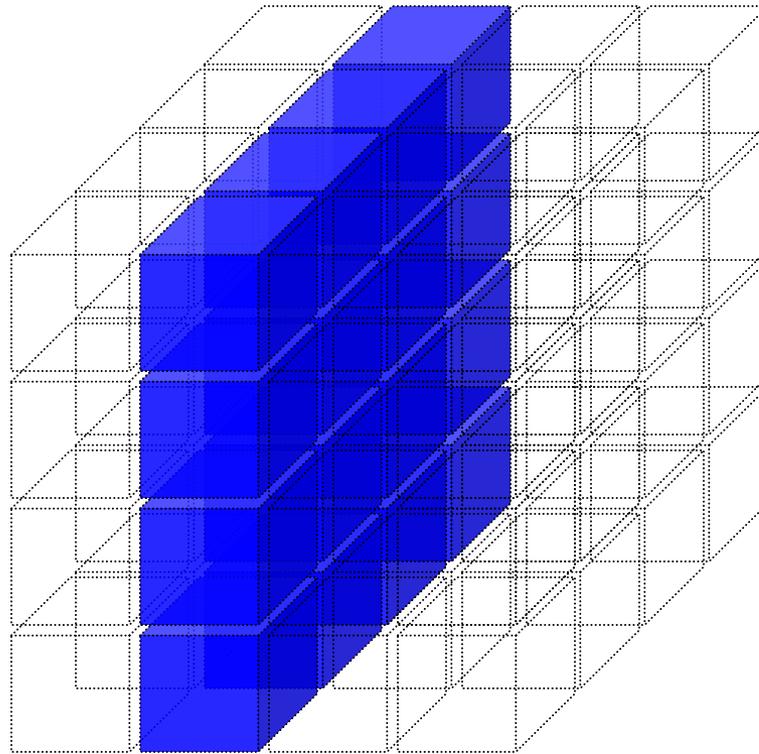


# Slice and Dice

Visão Produto

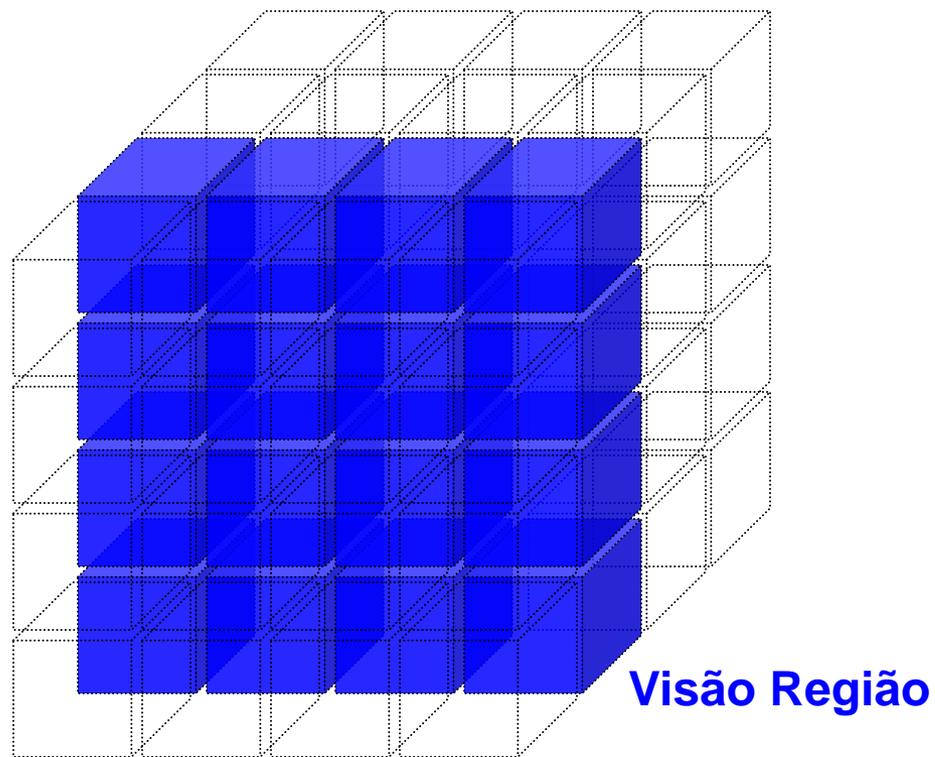


# Slice and Dice



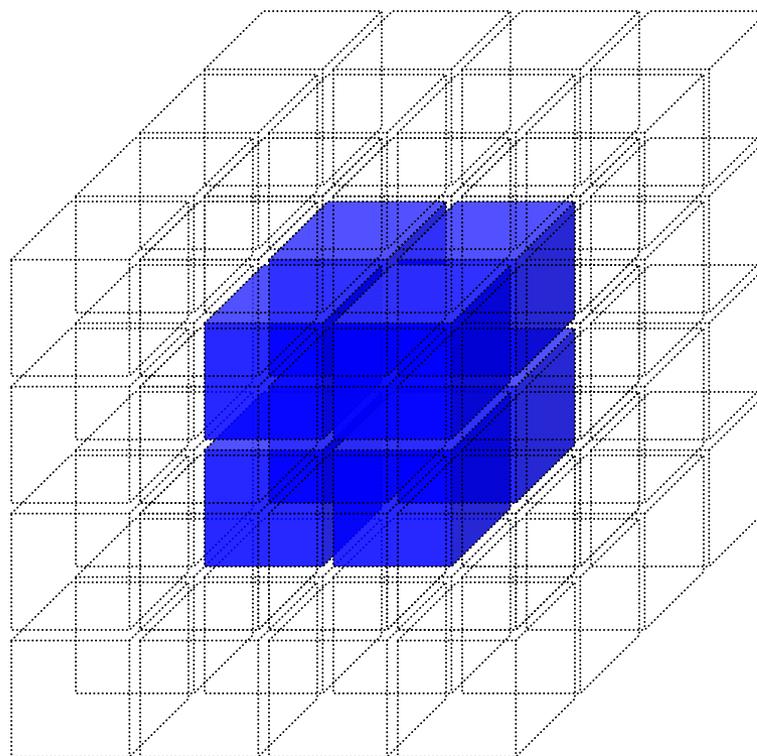
Visão Tempo

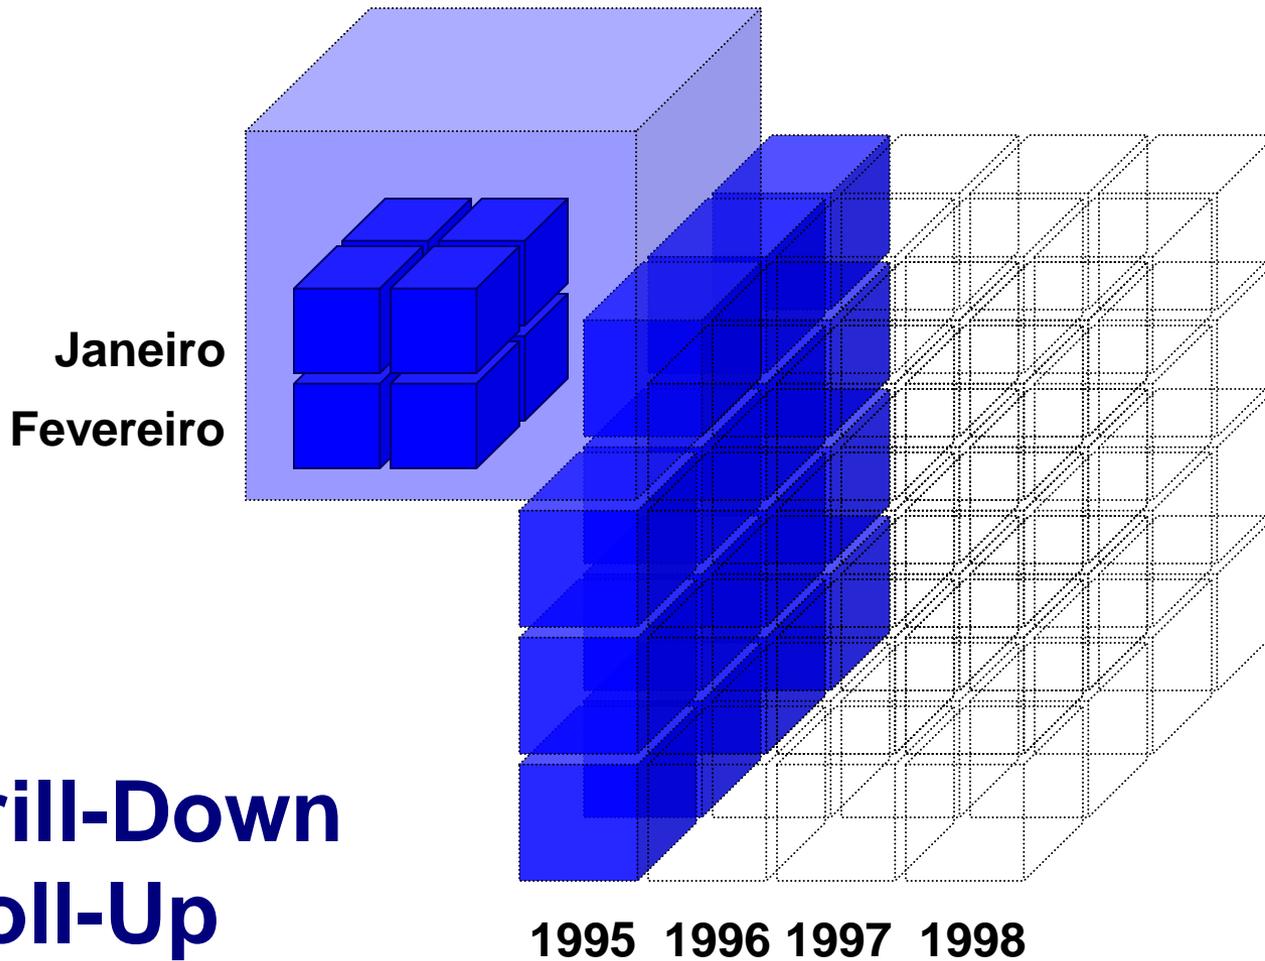
# Slice and Dice



# Slice and Dice

Visão ad-hoc





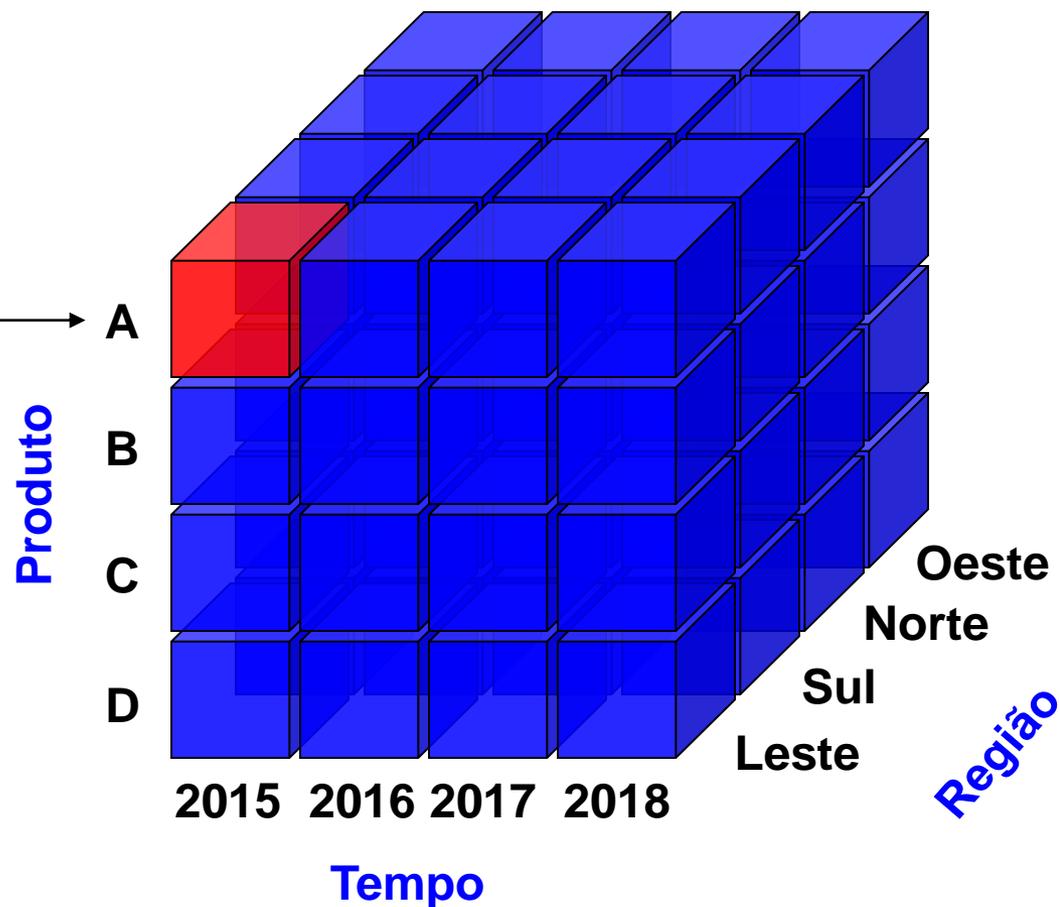
**Drill-Down**  
**Roll-Up**

1995 1996 1997 1998

**Visão Tempo**

# Analizando o Cubo

## Volume de Vendas (Fato)

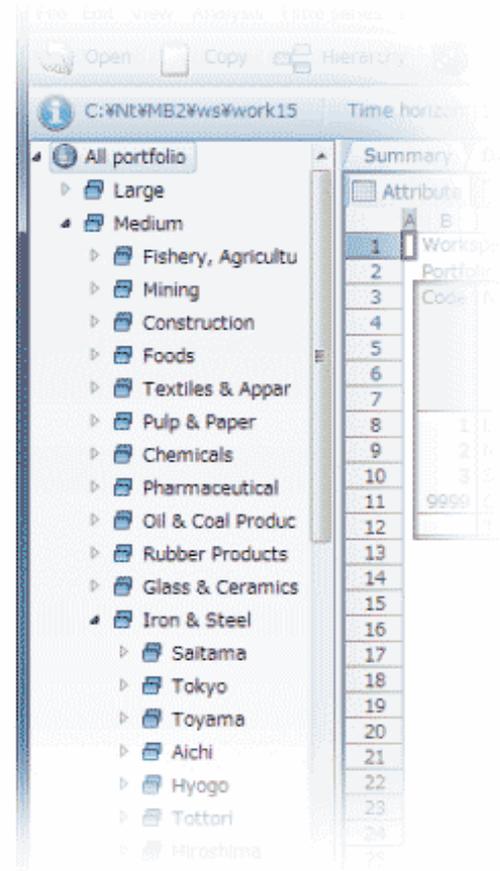
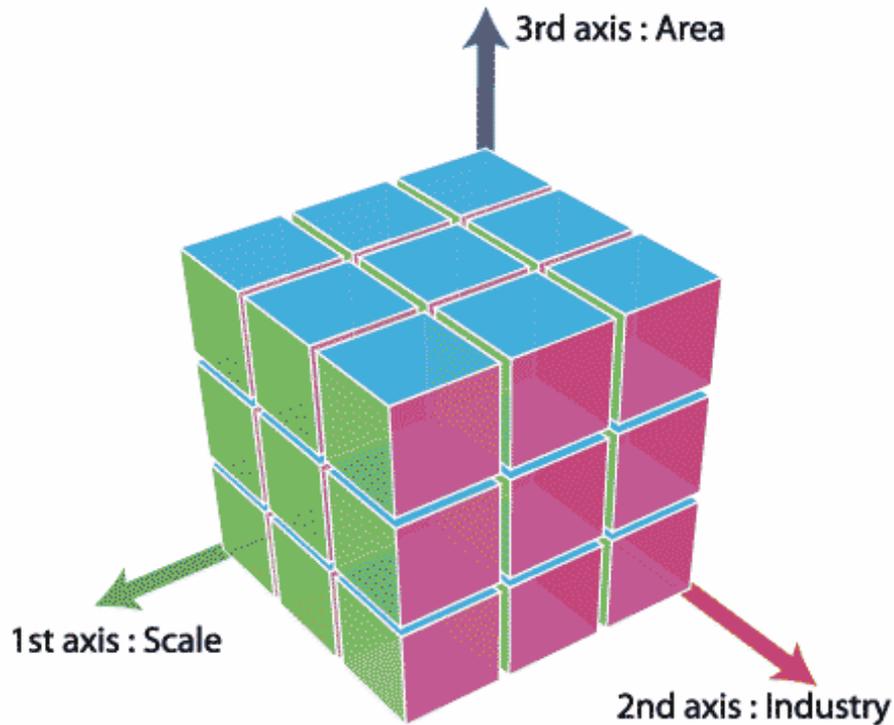


Número de vendas do produto A na região Leste em 2015.

Internal expression of multi-dimensional database  
(Hyper-cube structure)



User interface  
(Tree structure)



C1Olap: Conditional Formatting

Grid Chart Report

Choose fields to add to table:

- Address
- City
- Country
- CustomerID
- Customers.CompanyName
- Discount
- ExtendedPrice
- Freight
- OrderDate

Drag fields between areas below:

Filter:  Column Fields: Country

Row Fields: ProductName Values: ExtendedPrice (Co), Freight (Count)

Defer Updates

Olap Grid Olap Chart Raw Data

	Argentina		Austria	
ProductName	ExtendedPrice	Freight	ExtendedPrice	Freight
Sir Rodney's Marn	2	2	1	1
Sir Rodney's Scon	2	2	3	3
Sirop d'érable	1	1	3	3
Spegesild	1	1	1	1
Steeleye Stout	1	1	3	3
Tarte au sucre	0	0	1	1
Teatime Chocolate	0	0	0	0
Thüringer Rostbra	0	0	2	2
Tofu	1	1	2	2
Tourtière	0	0	1	1
Tunnbröd	0	0	1	1
Uncle Bob's Orgar	1	1	1	1
Valkoinen suklaa	0	0	1	1
Vegie-spread	0	0	3	3
Wimmers gute Ser	0	0	5	5
Zaanse koeken	0	0	0	0
<b>Total</b>	<b>34</b>	<b>34</b>	<b>125</b>	<b>125</b>

OlapChart OlapGrid

Normal

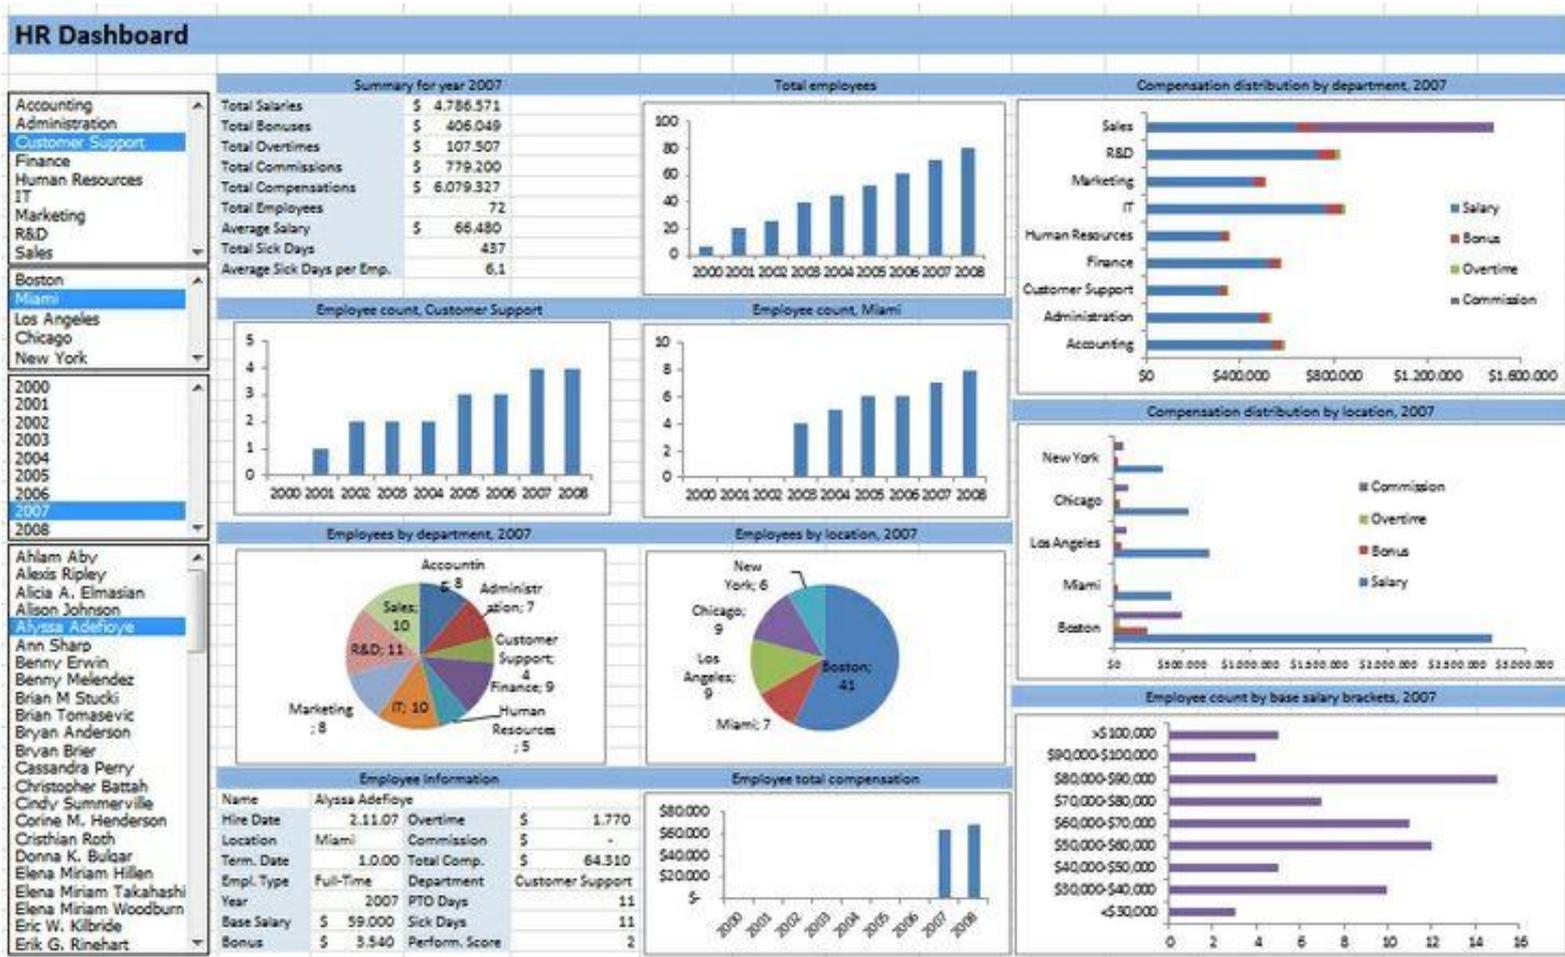
	Internet Sales Amount				Total
	FY 2002	FY 2003	FY 2004	FY 2005	
Australia	\$2,568,701.39	\$2,099,585.43	\$4,383,479.54	\$9,234.23	\$9,061,000.58
Canada	\$573,100.97	\$305,010.69	\$1,088,879.50	\$10,853.70	\$1,977,844.86
France	\$414,245.32	\$633,399.70	\$1,592,880.75	\$3,491.95	\$2,644,017.71
Germany	\$513,353.17	\$593,247.24	\$1,784,107.09	\$3,604.83	\$2,894,312.34
United Kingdom	\$550,507.33	\$696,594.97	\$2,140,388.50	\$4,221.41	\$3,391,712.21
United States	\$2,452,176.07	\$1,434,296.26	\$5,483,882.67	\$19,434.51	\$9,389,789.51
<b>Total</b>	<b>\$7,072,084.24</b>	<b>\$5,762,134.30</b>	<b>\$16,473,618.05</b>	<b>\$50,840.63</b>	<b>\$29,358,677.22</b>



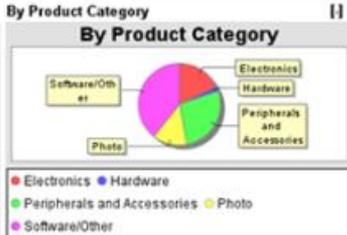
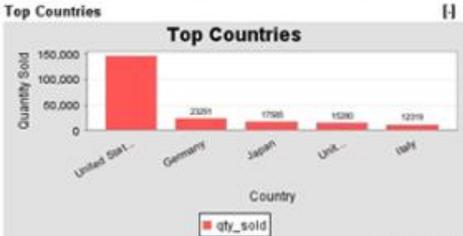
## *Dashboard*

- São relatórios de alto nível
- Extrema importância
- Abrange vários níveis do negócio

# Dashboard - Exemplos



Year: 2001  
 Region: ALL Values



#### By Region

Country	Qty Sold	Amnt Sold
Americas	154,378	15,892,073.53
Europe	69,002	7,061,183.14
Asia	24,680	3,000,604

#### By Product Category

Prod Category	Qty Sold	Amnt Sold
Peripherals and Accessories	70,842	7,835,162.01
Photo	34,787	6,333,629.91
Hardware	4,740	5,684,370.01
Electronics	46,117	4,686,999.18

#### By Channel

Channel Class	Qty Sold	Amnt Sold
Direct	122,063	13,355,240.8
Others	73,724	8,026,028.25
Indirect	62,825	6,698,125.94

AdminLTE
Hello, Jane ● Online

### Dashboard

**150**  
New Orders

**53%**  
Bounce Rate

**44**  
User Registrations

**65**  
Unique Visitors

#### Server Load

**90**  
CPU

**50**  
Disk

**30**  
RAM

#### Visitors

Country	Visitors	Online	Page Views
USA	209	239	
India	131	958	
Britain	15	417	
Brazil	109	476	
China	192	437	

#### Sales

# BI&A → KDD

- A disponibilização dos dados não basta, sendo vital a interpretação, análise e relacionamento destes dados para que se possa desenvolver estratégias de ação.
- Para atender este novo contexto, há a Descoberta de Conhecimento em Bases de Dados - KDD – *Knowledge Discovery in Databases*

# KDD - Conceito

- KDD – *Knowledge Discovery in Databases* [Fayyad]: “É um processo, de várias etapas, não trivial, interativo e iterativo, para identificação de padrões compreensíveis, válidos, novos e potencialmente úteis a partir de conjuntos de dados”.

## ▶ Etapas do Processo de KDD (forma resumida)

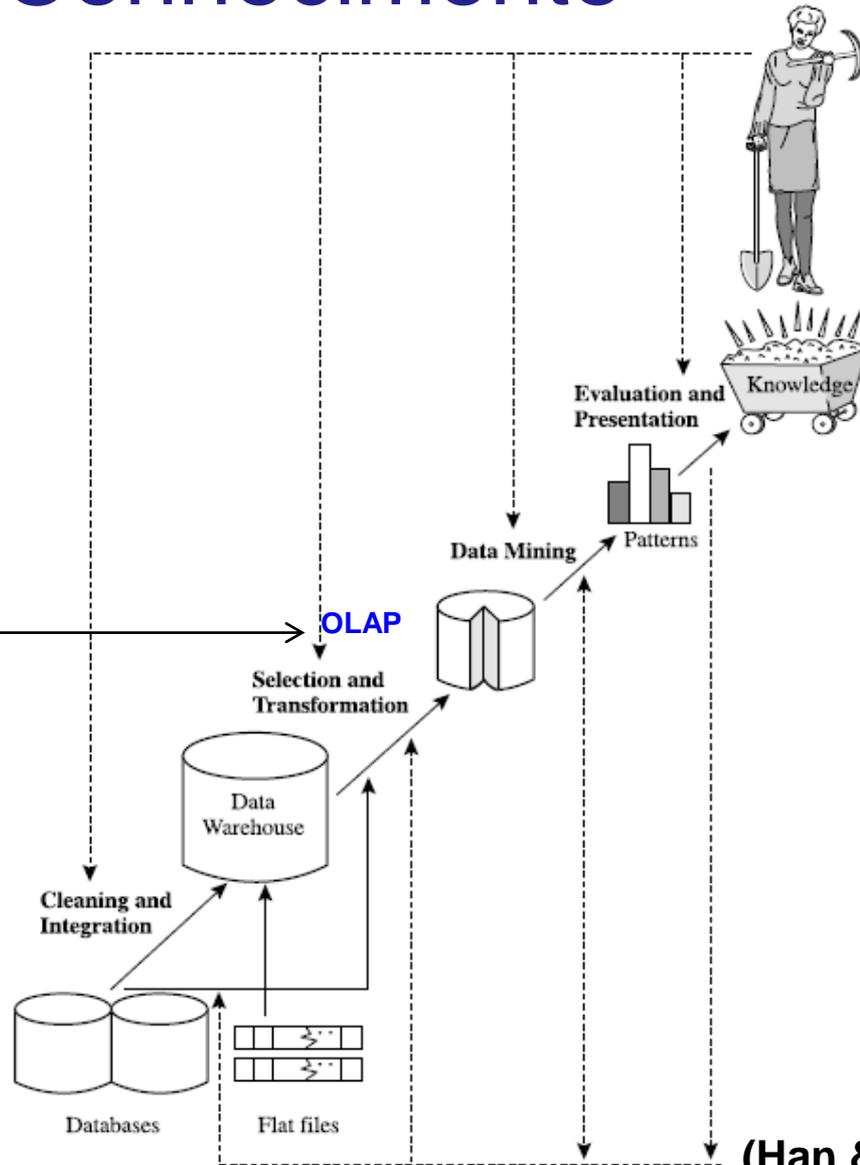


**Analista humano: orienta a execução do processo**



# Descoberta de Conhecimento

Uma opção!



(Han & Kamber, 2006)

# Tarefas de Mineração de Dados

- Mineração de Dados: Principal etapa do KDD: envolve a aplicação de algoritmos sobre os dados em busca de conhecimentos.

## □ Tarefas Preditivas

- Classificação → incluindo Descoberta de Desvios e Previsão de Séries
- Regressão

## □ Tarefas Descritivas

- Regras de Associação → incluindo Associações Temporais
- Agrupamentos
- Sumarização

# Aprendizagem supervisionada e não supervisionada

- **Aprendizagem supervisionada (classificação)**
  - **Supervisão: O conjunto de treinamento (observações, medições, etc.) é acompanhado dos rótulos indicativos das classes das observações;**
  - **Novos dados são classificados com base na estrutura gerada a partir do conjunto de treinamento;**

# Aprendizagem supervisionada e não supervisionada

- **Aprendizagem não supervisionada (agrupamento = *clustering*)**
  - Os rótulos das classes no conjunto de treinamento são desconhecidos;
  - Dado um conjunto de medidas, observações, etc. o objetivo é estabelecer a existência de classes ou grupos nos dados.

# Preparação da Entrada

- **Problema:** fontes diferentes de dados  
(ex.: departamento de vendas, departamento de cobrança, ...)
  - Diferenças: estilos de manter os registros, convenções, períodos de tempo, agregação dos dados, chaves primárias, erros;
  - Os dados precisam ser **integrados** e **limpos**;
  - Data warehouse.
- **Denormalização** não é o único problema
- Dados externos podem ser necessários
- Crítico: tipo e nível de agregação dos dados

O que é necessário fazer?  
Corrigir / selecionar / transformar / limpar ...



# A Tarefa de Associação

# Regras de Associação

(Han & Kamber, 2006)

- Representação: considere seu universo como sendo o conjunto de produtos (itens) vendidos.
  - A existência ou ausência de cada um desses itens pode ser representada por uma variável booleana.
  - Cada compra pode ser representada por um vetor de variáveis booleanas, sendo que, de fato, nesta compra (transação) foram comprados apenas os itens valorados com *verdadeiro*.
  - Analisando esses vetores, é possível descobrir itens que frequentemente aparecem juntos (estão associados), constituindo um padrão de comportamento.
  - Esse “padrão” pode ser representado por meio de uma **regra de associação**.

antecedente → consequente

# Regras de Associação

(Han & Kamber, 2006)

- Medidas de “*interessabilidade*”

**computador → antivírus [ suporte = 2%, confiança = 60%]**

Suporte = utilidade da regra

Confiança = certeza sobre a regra

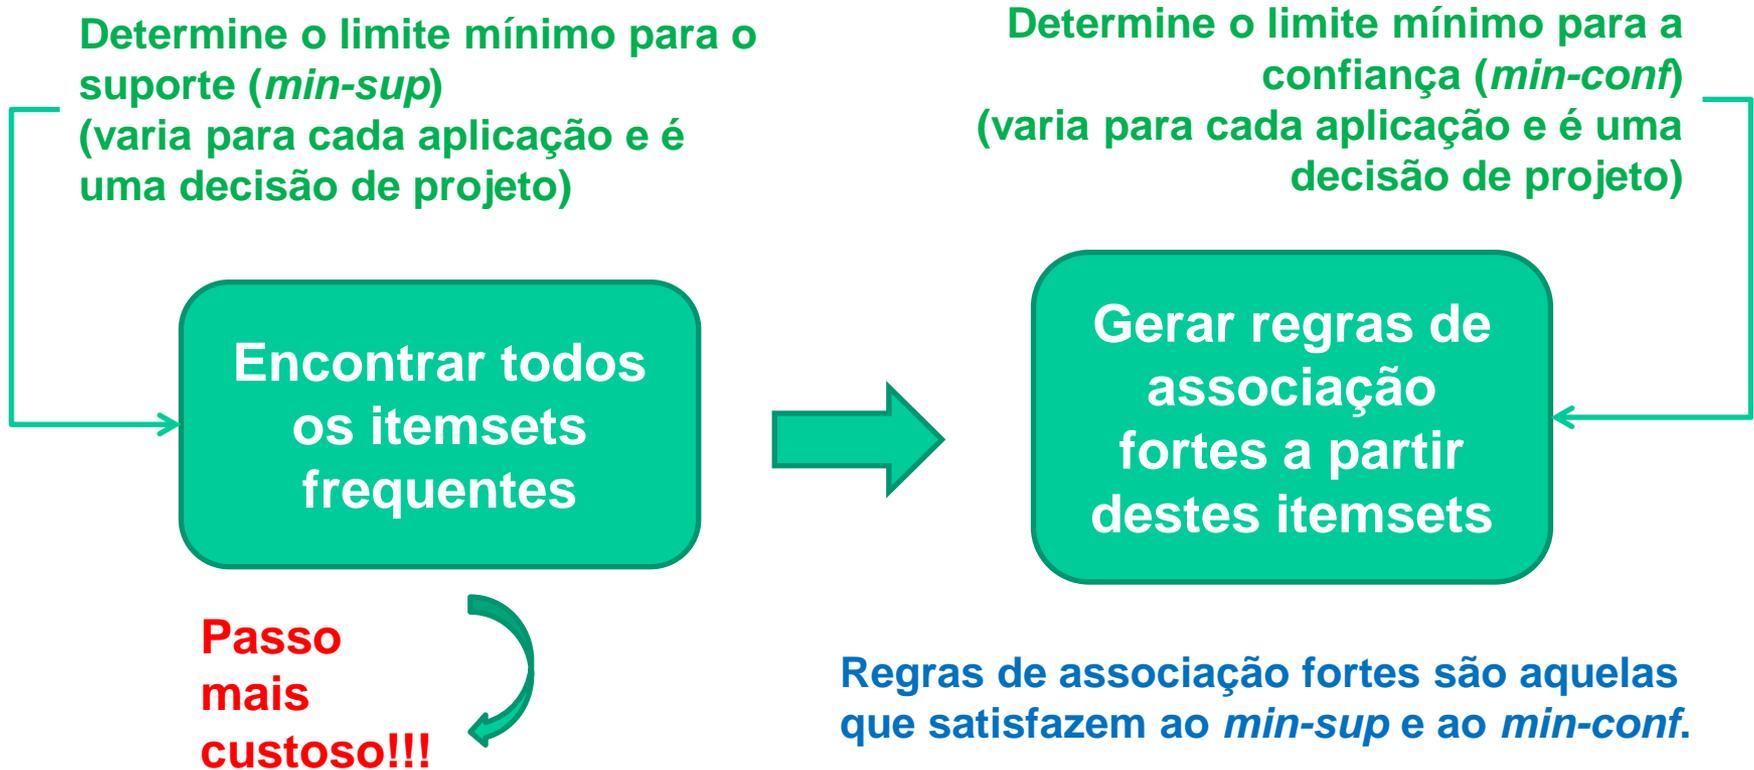
O **suporte** de 2% para a regra acima significa que 2% de todas as transações analisadas mostram que computadores e antivírus são comprados juntos.

A **confiança** de 60% da regra acima significa que 60% dos fregueses que compram um computador também compram um antivírus.

Regras de associação interessantes são aquelas que possuem um suporte e uma confiança **mínimos** (de acordo com um limite inferior pré-estabelecido).

# Regras de Associação (Han & Kamber, 2006)

## Processo de mineração de regras de associação:



# Representações de Dados Transacionais

*Base de dados transacional  $T_{ID}$*

$T_1 = \{i_1, i_3\}$   
 $T_2 = \{i_1, i_2, i_3\}$   
 $T_3 = \{i_1\}$   
 $T_4 = \{i_1, i_3, i_4\}$   
 $T_5 = \{i_3\}$   
 $T_6 = \{i_1, i_2\}$   
 $T_7 = \{i_1, i_2, i_3, i_4\}$

$T_{ID}$	$i_1$	$i_2$	$i_3$	$i_4$
$T_1$	1	0	1	0
$T_2$	1	1	1	0
$T_3$	1	0	0	0
$T_4$	1	0	1	1
$T_5$	0	0	1	0
$T_6$	1	1	0	0
$T_7$	1	1	1	1

(a)

(b)

Exemplo de base transacional genérica: (a) representação por conjuntos;  
(b) representação matricial

## Base de dados transacional TID

$$T_1 = \{i_1, i_3\}$$

$$T_2 = \{i_1, i_2, i_3\}$$

$$T_3 = \{i_1\}$$

$$T_4 = \{i_1, i_3, i_4\}$$

$$T_5 = \{i_3\}$$

$$T_6 = \{i_1, i_2\}$$

$$T_7 = \{i_1, i_2, i_3, i_4\}$$

$$T_8 = \{i_1, i_2, i_3, i_4\}$$

4-itemset	Suporte
$\{i_1, i_2, i_3, i_4\}$	25%

3-itemset	Suporte
$\{i_1, i_2, i_3\}$	37%
$\{i_1, i_3, i_4\}$	37%
$\{i_1, i_2, i_4\}$	25%
$\{i_2, i_3, i_4\}$	25%

2-itemset	Suporte
$\{i_1, i_2\}$	50%
$\{i_1, i_3\}$	62%
$\{i_1, i_4\}$	37%
$\{i_2, i_3\}$	37%
$\{i_2, i_4\}$	25%
$\{i_3, i_4\}$	37%

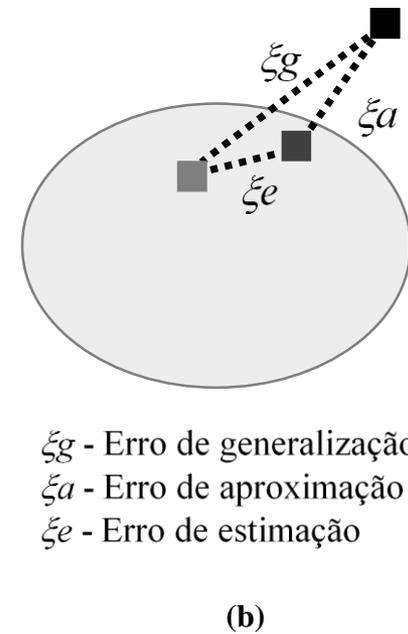
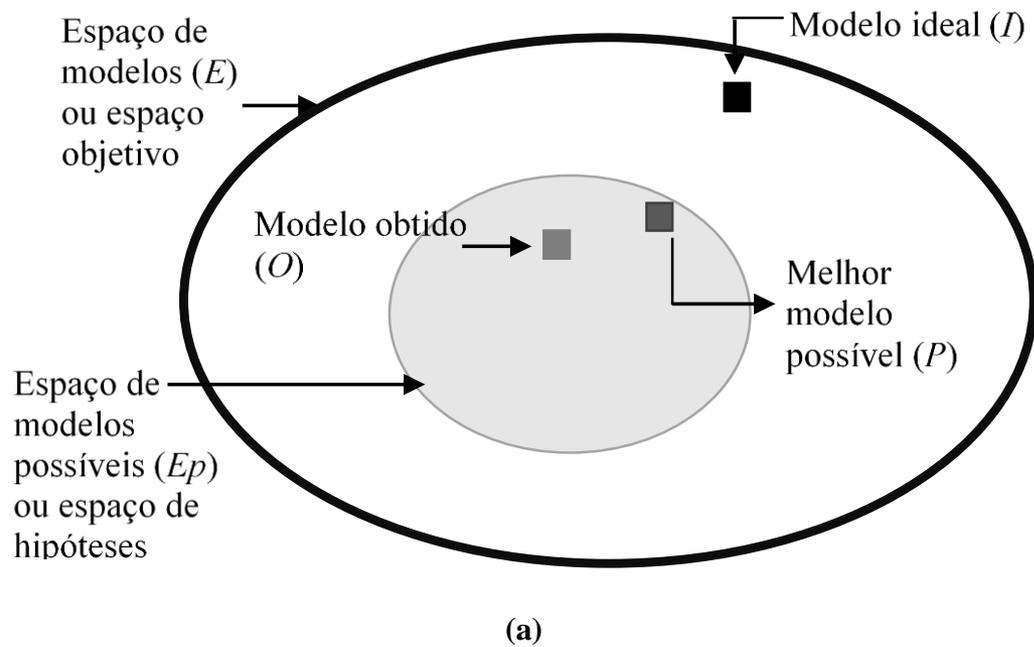
1-itemset	Suporte
$\{i_1\}$	87%
$\{i_2\}$	50%
$\{i_3\}$	75%
$\{i_4\}$	37%

Novo contexto para a base de dados transacional; os *itemsets* e seus respectivos suportes. Note que transações diferentes podem envolver o mesmo subconjunto de itens



# A tarefa de Classificação/Predição

# Introdução



Espaço de modelos (a); erros de predição (b); baseado em Lima (2004)

# Coleção de dados

Podemos armazenar *características* em bases de dados

O problema de classificação agora pode ser expresso da seguinte forma:

- Dada uma base de treinamento (**Minha\_Coleção**), prediga o rótulo da **classe dos exemplos ainda não vistos**

**Minha\_Coleção**

ID do inseto	Comp. do abdômen	Comp. das antenas	Classe do inseto
1	2.7	5.5	Gafanhoto
2	8.0	9.1	Esperança
3	0.9	4.7	Gafanhoto
4	1.1	3.1	Gafanhoto
5	5.4	8.5	Esperança
6	2.9	1.9	Gafanhoto
7	6.1	6.6	Esperança
8	0.5	1.0	Gafanhoto
9	8.3	6.6	Esperança
10	8.1	4.7	Esperança

Exemplo não visto =

11

5.1

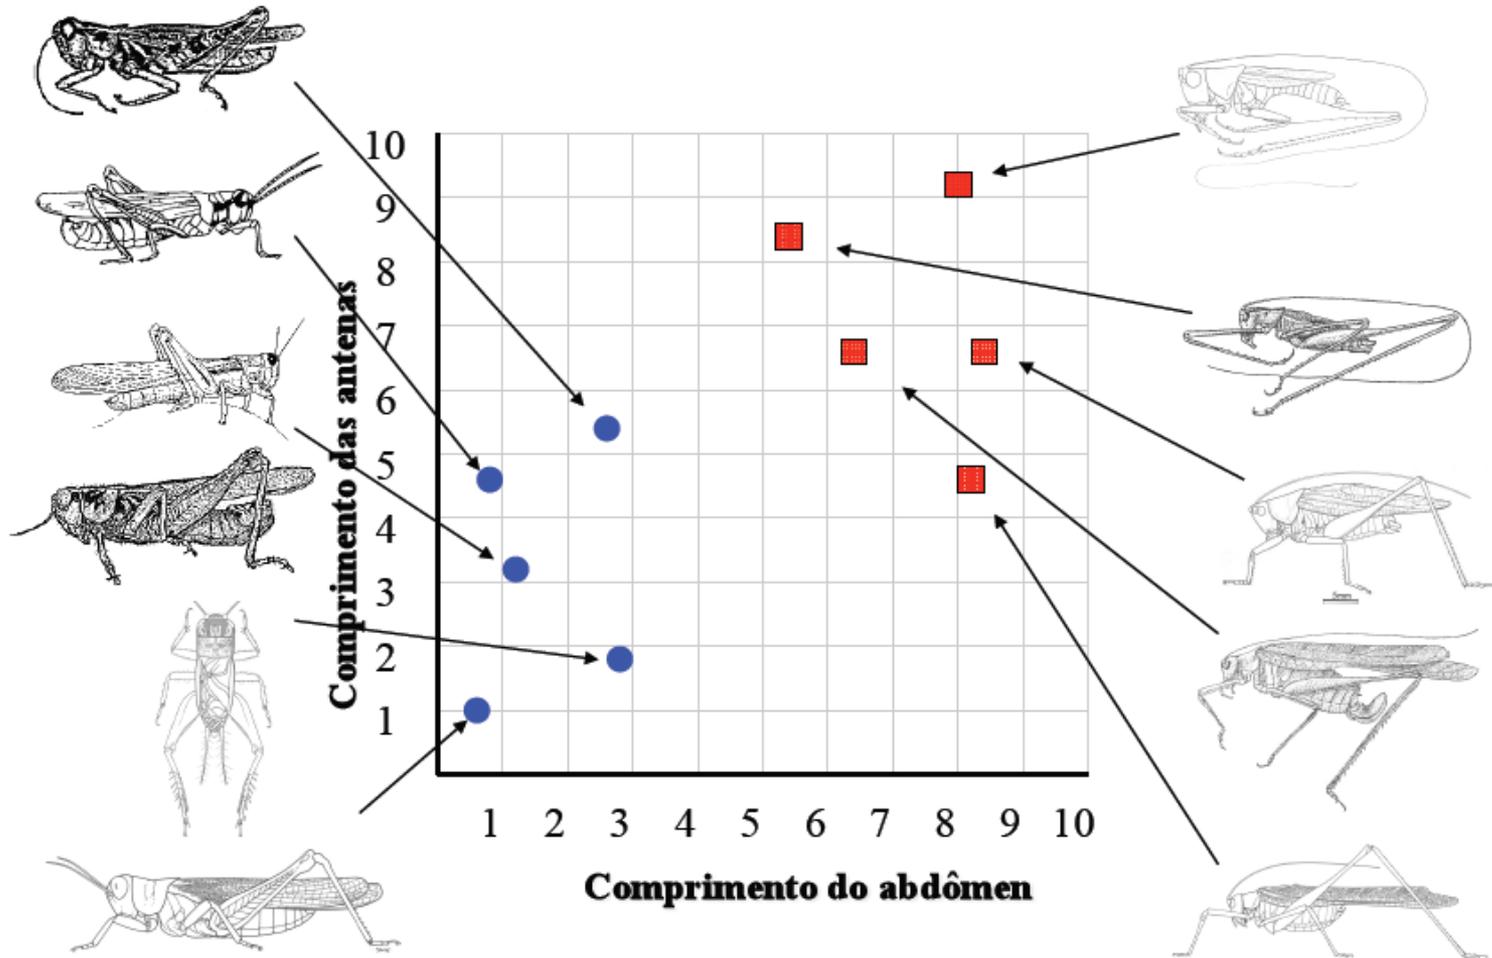
7.0

???????

# Visualização gráfica

**Gafanhoto**

**Esperança**

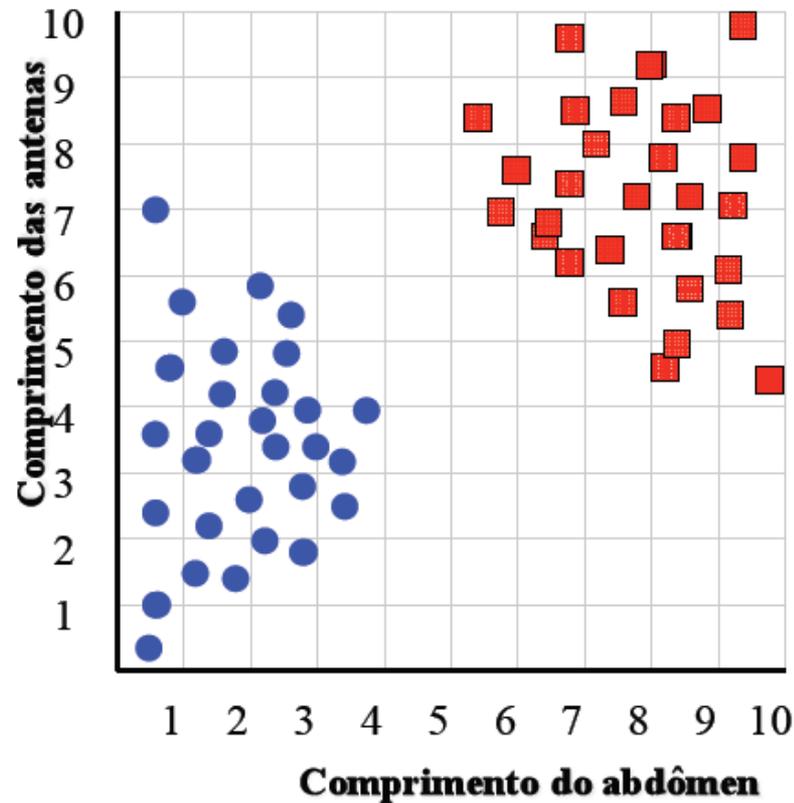


# Visualização Gráfica

## Gafanhoto



Também utilizaremos esta base de dados maior para motivação ...



## Esperança

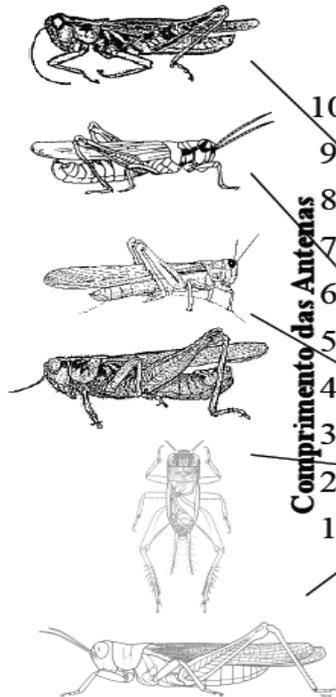


Cada um destes objetos de dados é chamado de...

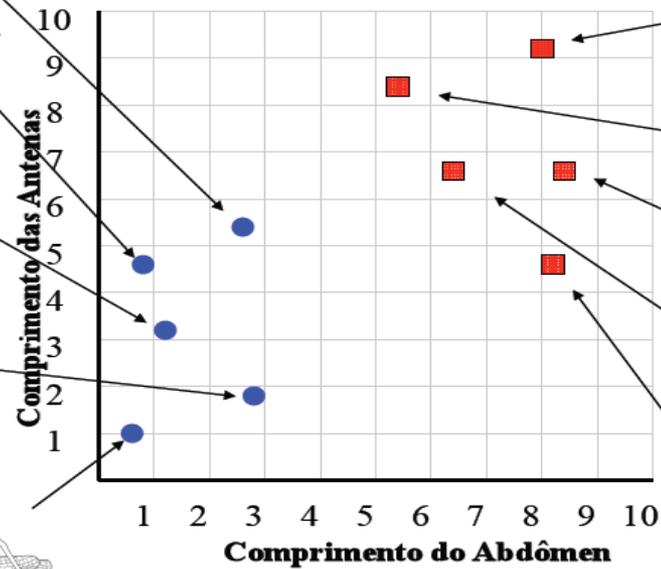
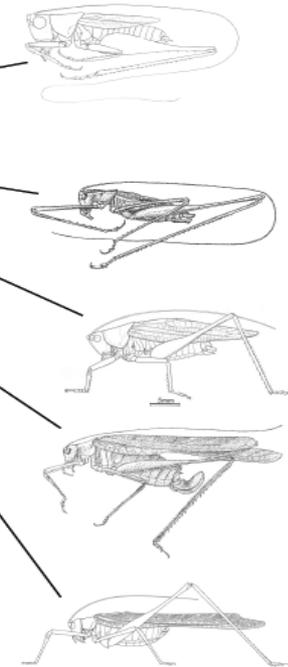
- exemplar
- exemplo (de treinamento)
- instância
- tupla

# Problema Inicial

**Gafanhoto**



**Esperança**



# Gafanhoto ou Esperança

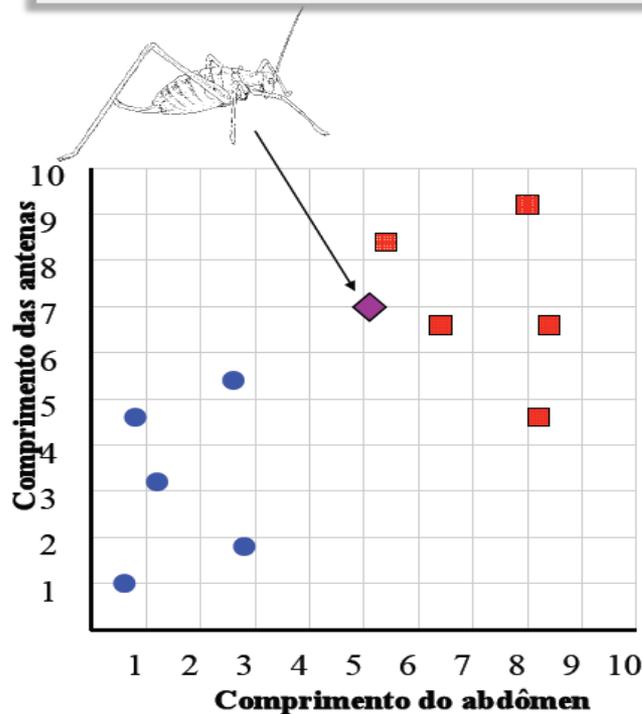
Exemplo não visto antes =

11

5.1

7.0

???????



- Podemos “projetar” o **exemplo não visto antes** dentro do mesmo espaço que a base de dados.
- Acabamos de abstrair os detalhes do nosso problema particular. Será muito mais fácil conversar sobre pontos no espaço.

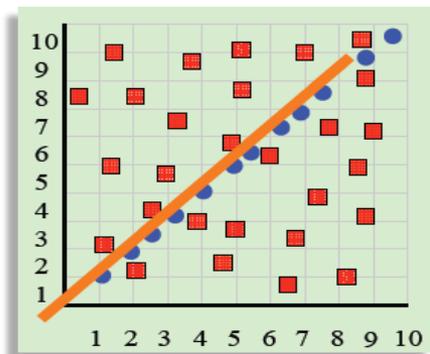
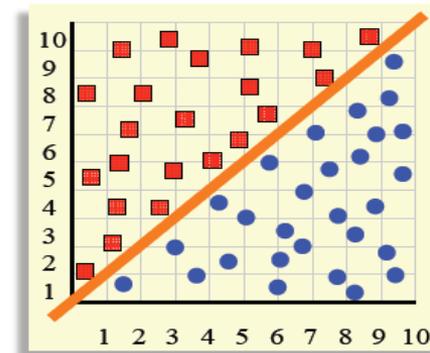
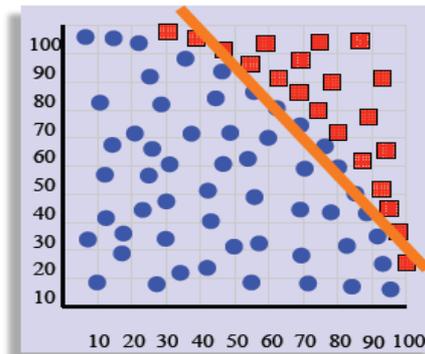
■ **Esperança**

● **Gafanhoto**

# Classificadores Lineares

- 1) Perfeito
- 2) Inútil
- 3) Muito bom

Problemas que podem ser resolvido por um classificador linear são chamados de **linearmente separáveis**.



# Distribuição espacial de atributos

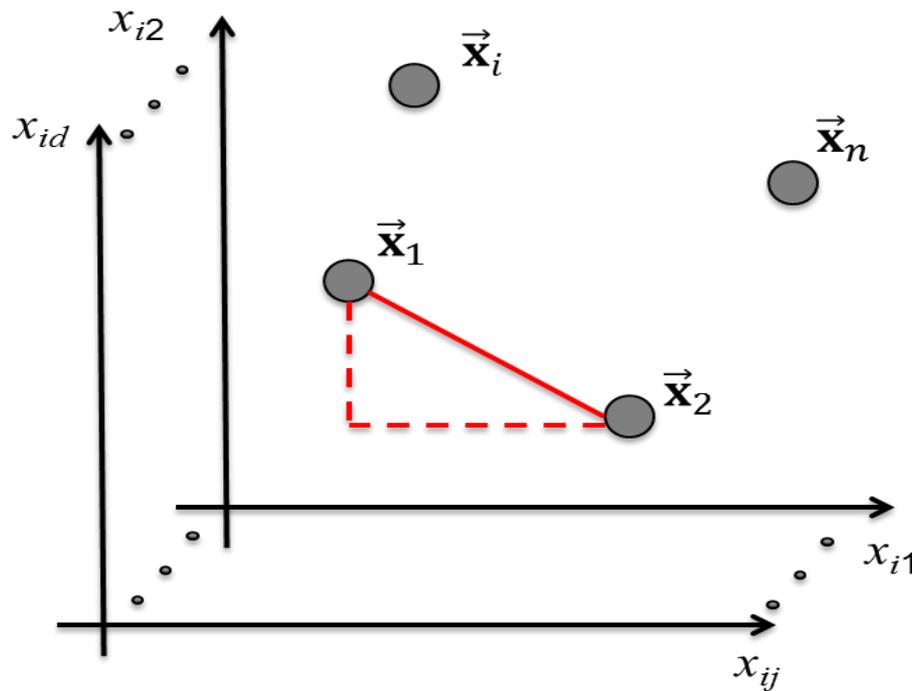
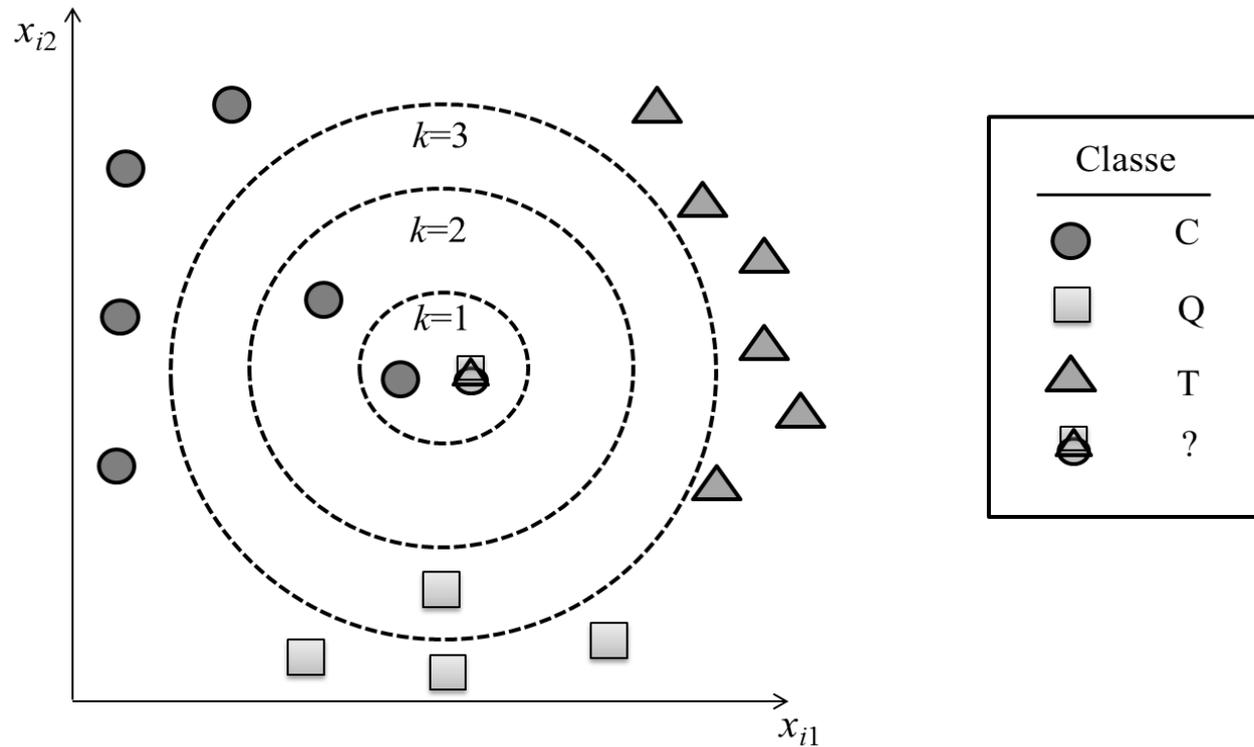


Gráfico de dispersão como uma abstração dos exemplares distribuídos no espaço dos atributos

# Exemplo algoritmo kNN



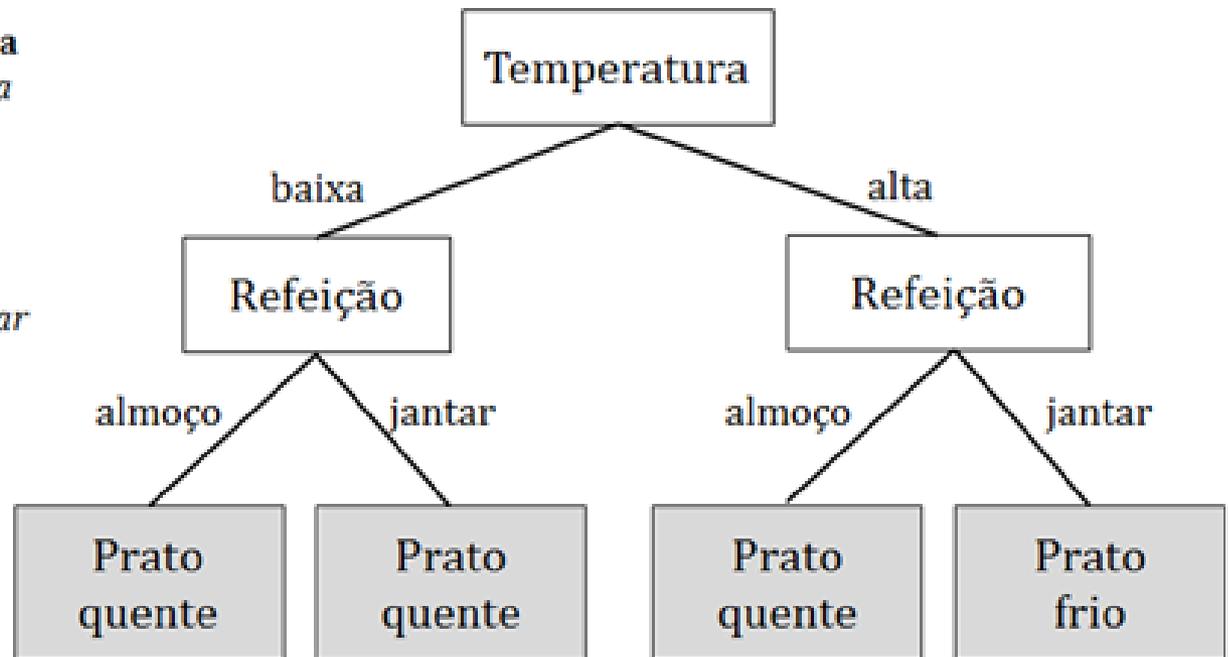
Exemplo ilustrativo para o  $k$ -NN

# Árvore de Decisão

Atributo descritivo = **temperatura**  
Valores de temperatura: *alta, baixa*

Atributo descritivo = **refeição**  
Valores de refeição: *almoço, jantar*

Atributo de rótulo: **tipo de prato**  
Valores de rótulo:  
*Prato quente, prato frio*



Exemplo de um classificador hipotético, na forma de uma árvore de decisão

# Treinamento e Teste

- O desempenho de um classificador pode ser medido por meio da **taxa de erro**:
  - A taxa de erro é a proporção de erros obtidos sobre um conjunto completo de instâncias.

**O classificador prediz a classe de cada instância; se ela é correta, é contada como um “sucesso”; se não, é contada como um “erro”.**

- O que interessa é o desempenho do classificador mediante “novos” dados, e não sobre os dados velhos (usados no processo de treinamento).

# Treinamento, validação e teste

- Frequentemente é útil dividir o conjunto de dados disponíveis em três partes, para três diferentes propósitos:
  - **Conjunto de treinamento**: usado por um ou mais métodos de aprendizado para construir o classificador.
  - **Conjunto de validação**: usado para otimizar os parâmetros do classificador, ou para selecionar um em particular.
  - **Conjunto de teste**: usado para calcular a taxa de erro final do modelo já otimizado.

Uma vez que a taxa de erro foi determinada, os dados de testes podem se juntar aos dados de treinamento para produzir um novo classificador para o uso real. Não há problema nisso quando usado apenas como uma forma de maximizar o classificador que será usado na prática. O que é importante é que a taxa de erro não seja calculada com base nesse último classificador gerado. Além disso, o mesmo pode ser feito com os dados de validação. (Witten & Frank, 2005)

# Análise de desempenho

Meu classificador apresentou 25% de taxa de erro (75% de taxa de acerto). Mas o que isso realmente significa? Quanto posso confiar nesta medida?

É útil determinar a taxa de sucesso com relação a um intervalo de confiança.

Seja  $S$  a contagem de respostas corretas obtidas nos testes do classificador e  $N$  o número de testes realizados, então:

- Se  $S = 750$  e  $N = 1000$ , a taxa de sucesso é **por volta** de 75%. Se considerarmos 80% de confiança na medida, a taxa de sucesso fica entre 73.2% e 76.7%.
- Se  $S = 75$  e  $N = 100$ , a taxa de sucesso é **por volta** de 75%. Se considerarmos 80% de confiança na medida, a taxa de sucesso fica entre 69.1% e 80.1%.

# Matriz de Confusão

- Oferece uma medida da eficácia do modelo de classificação, mostrando o número de classificações corretas *versus* o número de classificação prevista para cada classe.

Classe	C <sub>1</sub> Prevista	C <sub>2</sub> Prevista	...	C <sub>k</sub> Prevista
C <sub>1</sub> Real	M(C <sub>1</sub> ,C <sub>1</sub> )	M(C <sub>1</sub> ,C <sub>2</sub> )	...	M(C <sub>1</sub> ,C <sub>k</sub> )
C <sub>2</sub> Real	M(C <sub>2</sub> ,C <sub>1</sub> )	M(C <sub>2</sub> ,C <sub>2</sub> )	...	M(C <sub>2</sub> ,C <sub>k</sub> )
⋮	⋮	⋮	...	⋮
C <sub>k</sub> Real	M(C <sub>k</sub> ,C <sub>1</sub> )	M(C <sub>k</sub> ,C <sub>2</sub> )	...	M(C <sub>k</sub> ,C <sub>k</sub> )

$$M(C_i, C_j) = \sum_{\{ \forall (x, y) \in T : y = C_i \}} \|h(x) = C_j\|$$

# Matriz de Confusão para duas classes

Classe	prevista $C_+$	prevista $C_-$	Taxa de erro da classe	Taxa de erro total
real $C_+$	$T_p$	$F_n$	$F_n / (T_p + F_n)$	$(F_p + F_n) / n$
real $C_-$	$F_p$	$T_n$	$F_p / (F_p + T_n)$	

**TP = True Positive (verdadeiro positivo)**

**FN = False Negative (falso negativo)**

**FP = False Positive (falso positivo)**

**TN = True Negative (verdadeiro negativo)**

**$n = (TP+FN+FP+TN)$**

# Matriz de Confusão para duas classes

- Outras métricas derivadas da tabela anterior:

$$C_+ \text{ Predictive Value} = T_p / (T_p + F_p)$$

$$C_- \text{ Predictive Value} = T_n / (T_n + F_n)$$

$$\text{True } C_+ \text{ Rate ou Sensitivity y ou Recall} = T_p / (T_p + F_n)$$

$$\text{True } C_- \text{ Rate ou Specificity} = T_n / (F_p + T_n)$$

$$\text{Precision} = (T_p + T_n) / n$$

# Avaliação do classificador

- Para estimar o erro verdadeiro de um classificador, a amostra para teste deve ser aleatoriamente escolhida
- Amostras não devem ser pré-selecionadas de nenhuma maneira
- Para problemas reais, tem-se uma amostra de uma única população, de tamanho  $n$ , e a tarefa é estimar o erro verdadeiro para essa população



# Métodos para estimar o erro verdadeiro de um classificador

- Resubstitution
- Random
- Holdout
- r-fold cross-validation
- r-fold stratified cross-validation
- Leave-one-out
- Bootstrap

# Holdout

(Witten & Frank, 2005)

- Estratégia para teste de classificador que reserva um certo montante de dados para treino e o restante para teste (podendo ainda usar parte para validação).
- Comumente esta estratégia usa  $1/3$  dos dados para teste e o restante para treinamento, escolhido randomicamente.
- É interessante assegurar que a amostragem randômica seja feita de tal maneira que garanta que cada classe é apropriadamente representada tanto no conjunto de treinamento quanto no conjunto de teste. Este procedimento é chamado de *estratificação (holdout estratificado)*.
- Também é útil, para amenizar tendências, repetir todo o processo de treino e teste várias vezes com diferentes amostragens randômicas (*holdout repetitivo/iterativo*).

# Cross Validation

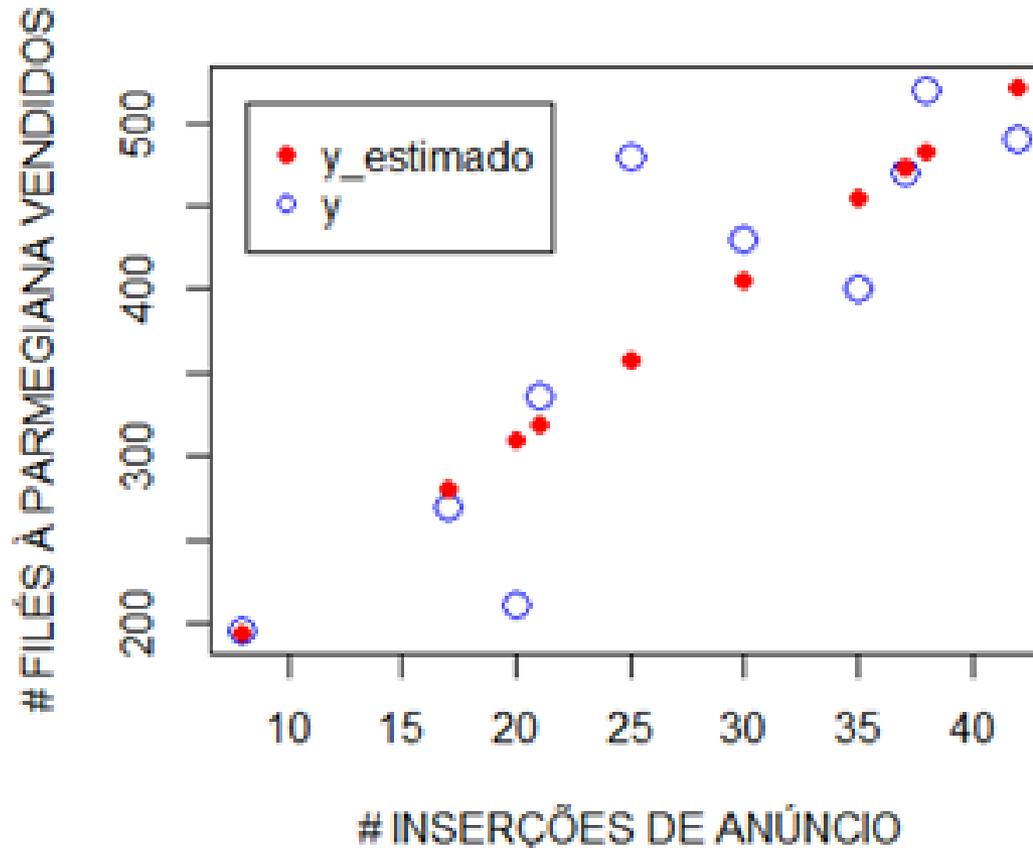
(Witten & Frank, 2005)

- Trata-se de uma estratégia para lidar com um montante de dados limitado.
- Nesta estratégia decide-se um numero fixos de folds, ou partições dos dados. Supondo que sejam usados três folds (**3-fold cross validation**):
  - o conjunto de dado é dividido em três partições de tamanhos aproximadamente iguais e, de maneira rotativa, cada uma delas é usada para teste enquanto as duas restantes são usadas para treinamento.
  - ou seja: use **2/3** para treinamento e **1/3** para teste e repita o processo três vezes, tal que, no fim, cada instância tenha sido usadas exatamente uma vez para teste.
  - se a estratificação é adotada, então o procedimento se chama **3-fold cross validation estratificado** (aconselhável).
  - o padrão é executar o **10-fold cross validation**, 10 vezes.
  - o erro final do classificador é a média dos erros obtidos em cada iteração da estratégia cross-validation

# Leave-one-out (Witten & Frank, 2005)

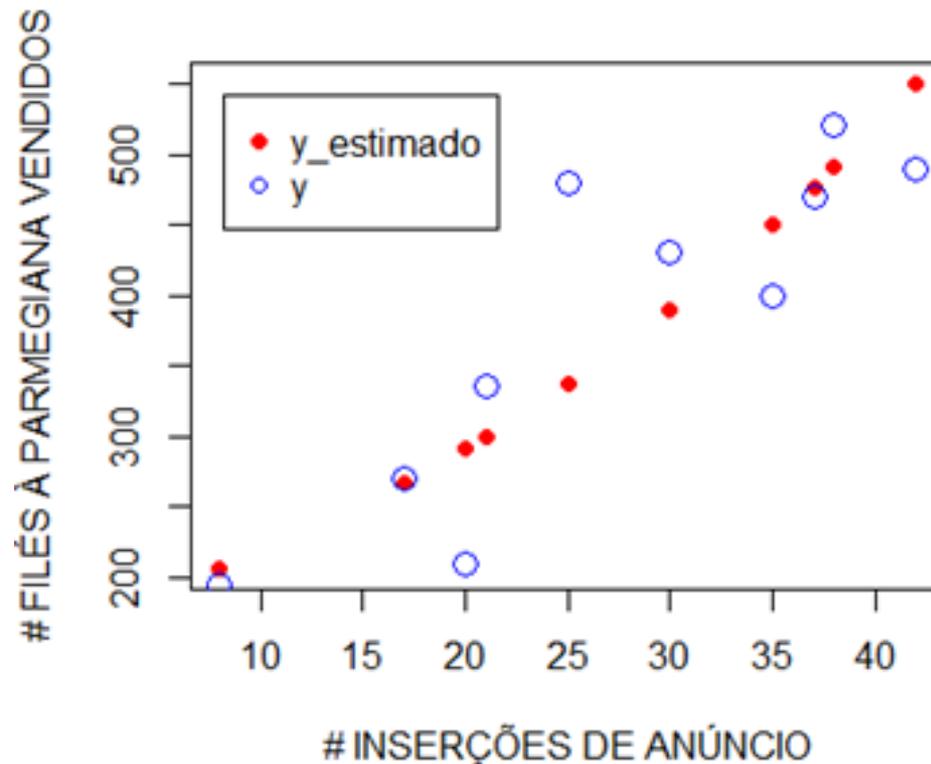
- Leave-one-out cross-validation é um **n-fold cross-validation**, onde **n** é o número de instâncias no conjunto de dados.
- A avaliação é sobre a corretude de classificação da instância em teste – um ou zero para sucesso ou falha, respectivamente.
- Os resultados de todas as **n** avaliações, uma para cada instância do conjunto de dados, são analisados via média, e tal média representa o erro final estimado.
- **Motivações:**
  - o maior número possível de dados é usado para treinamento em cada caso, o que aumenta as chance do classificador alcançar acuidade.
  - o procedimento é determinístico.
- Indicado para conjunto de dados pequenos.
- Não é possível aplicar qualquer procedimento de estratificação.

# Exemplo de predição linear



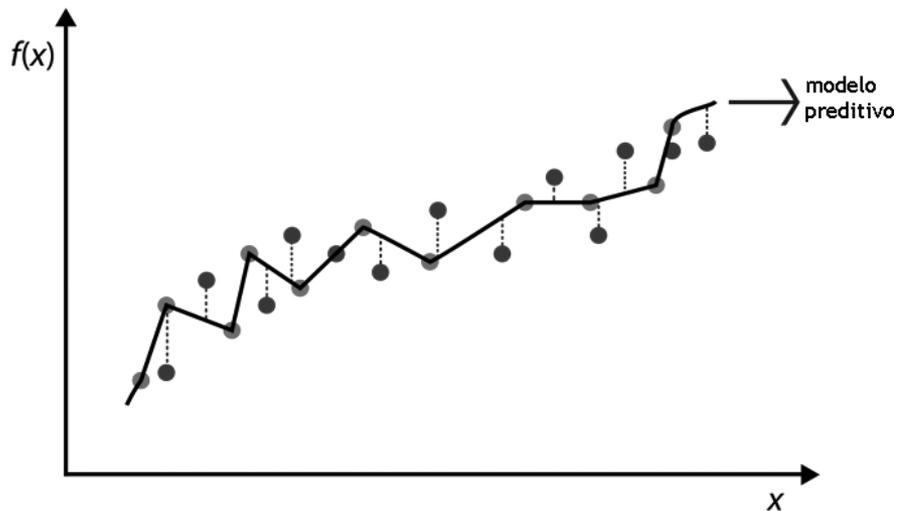
Representação gráfica para o modelo de regressão linear obtido para o conjunto PLANEJAMENTO DE PROPAGANDA

# Exemplo de predição não linear



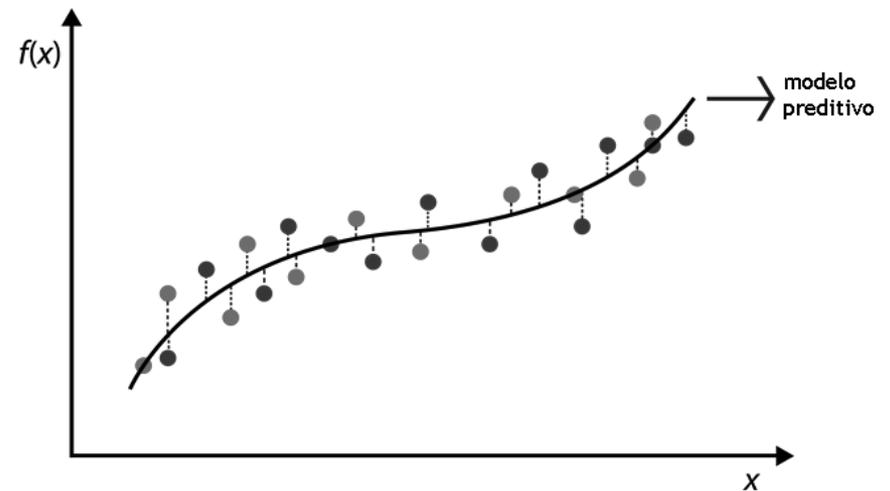
Representação gráfica para o modelo de regressão não linear obtido para o conjunto PLANEJAMENTO DE PROPAGANDA

# Avaliação de modelos preditivos



- dados de treinamento
- dados de teste
- | erro de generalização

(a)



- dados de treinamento
- dados de teste
- | erro de generalização

(b)

Exemplos de modelo preditivo: (a) com sobreajuste; (b) sem sobreajuste



# A tarefa de Agrupamento

# Agrupamento (clustering)

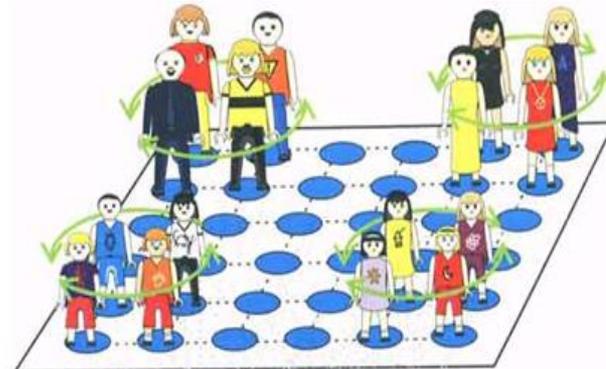
Tarefa descritiva que agrupa exemplos (objetos) de acordo com suas características

- Objetivo: agrupar objetos em clusters (agrupamentos) de modo que objetos pertencentes a um mesmo cluster são mais similares entre si de acordo com alguma medida de similaridade pré-definida, enquanto que objetos pertencentes a clusters diferentes têm uma similaridade menor
- Consumo de um carro em função de suas características
- Valor de um imóvel em função de suas características e do bairro

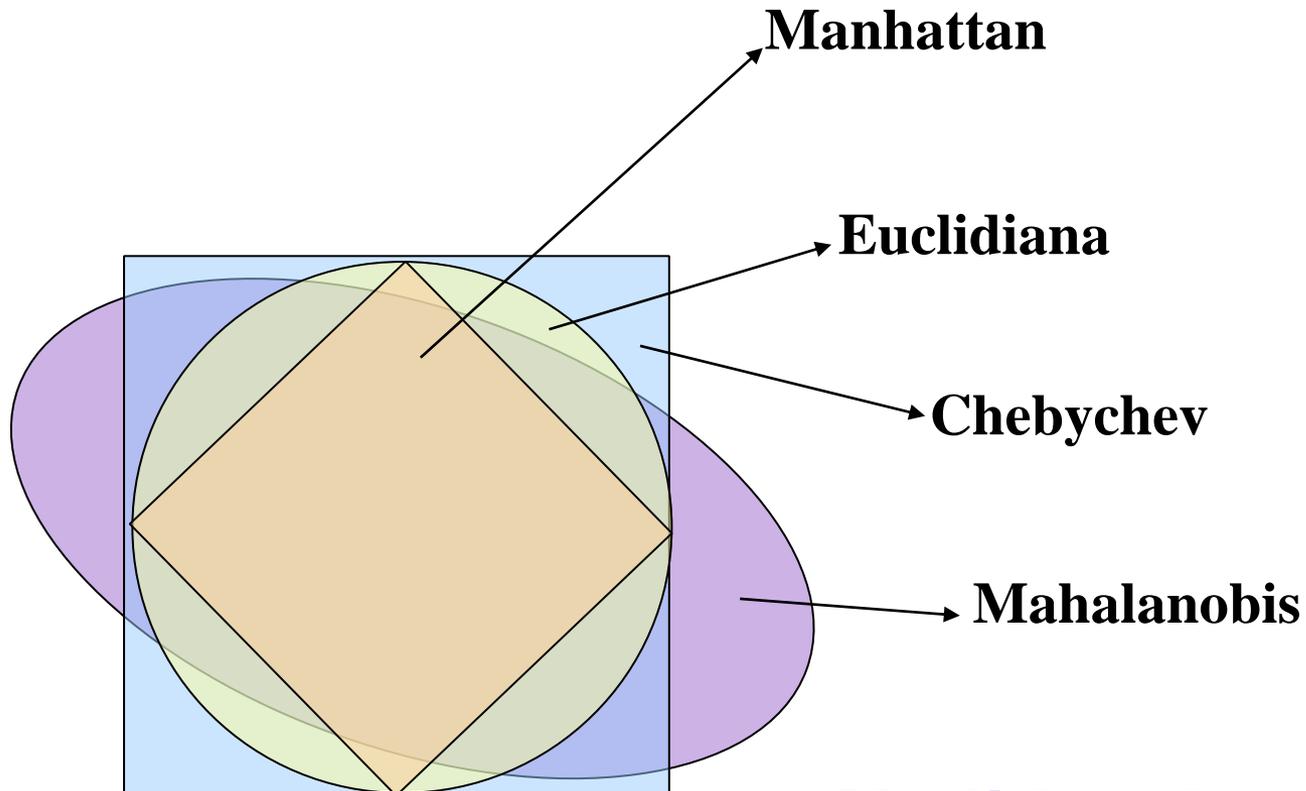
# Agrupamento (clustering)

(Han & Kamber, 2006)

- A tarefa de agrupamento consiste em agrupar um conjunto de objetos físicos ou abstratos em grupos de objetos similares.
- Um grupo é uma coleção de objetos que são similares uns aos outros, dentro de um grupo, e dissimilares aos objetos de outros grupos.
  - pode ser considerada uma forma de compressão
- O modelo de agrupamento não é construído com base em dados rotulados. Apenas a informação de similaridade entre os dados é usada.
  - após o modelo de agrupamento ser construídos, um processo de rotulação dos grupos formados pode ser útil.

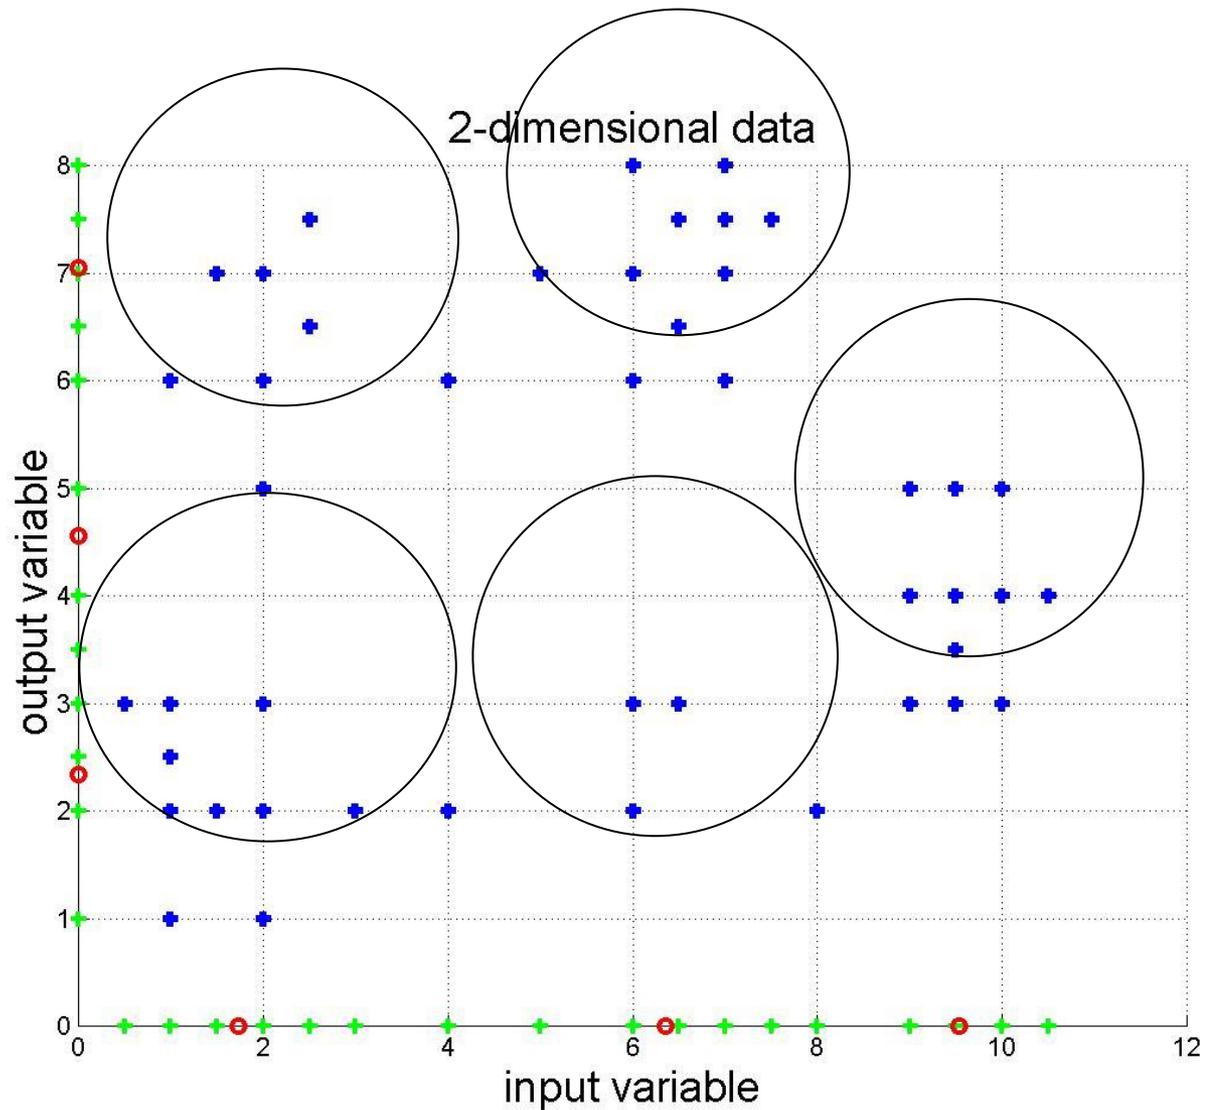


# Formatos de clusters



**Medidas de similaridade**

# Formatos de clusters

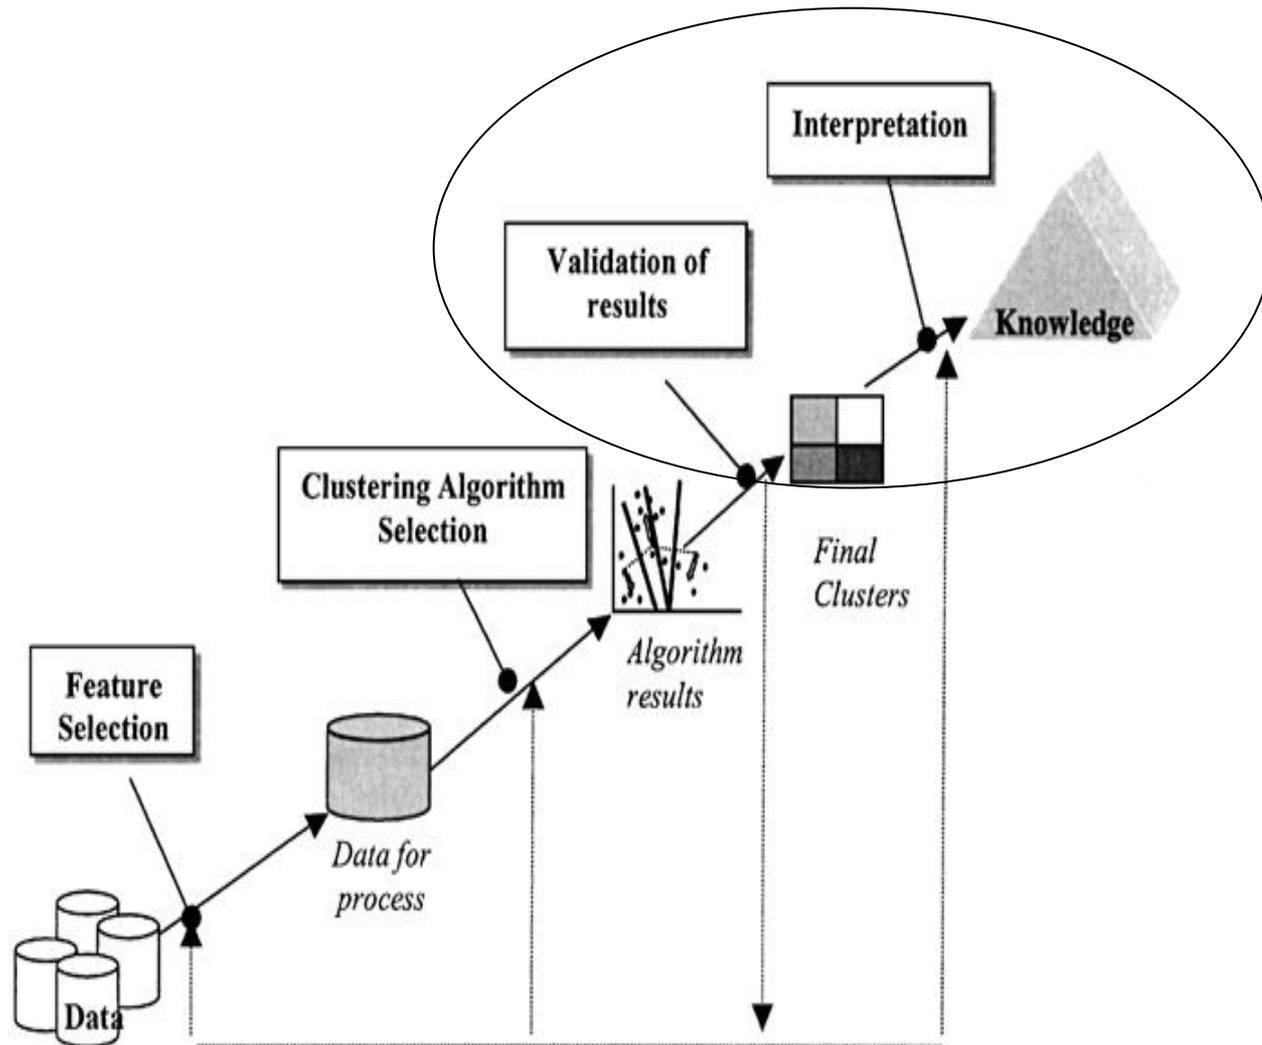




# Processo de Agrupamento

1. seleção de exemplos e seleção ou construção de atributos:
  - Selecciona atributos relevantes, ou
  - Constrói atributos representativos
2. Similaridade entre exemplos
  - Selecciona a medida de similaridade a ser utilizada, que deve ser adequada ao domínio
3. Agrupamento
  - Aplicação do algoritmo de agrupamento

# Processo de Agrupamento



# Categorização dos Métodos de agrupamento

(Han & Kamber, 2006)

- Métodos de particionamento
- Métodos hierárquicos
- Métodos baseados em densidade
- Métodos baseados em gride
- Métodos baseados em modelos
- Agrupamento de dados de alta-dimensão
- Agrupamento baseado em restrições

# Métodos de Particionamento

(Han & Kamber, 2006)

- Os clusters são encontrados por meio da otimização de critérios tais como a função de dissimilaridade baseada em distância.
- Para alcançar a otimalidade global, é necessário enumerar, exaustivamente, todas as possíveis partições.
- Porém, dado o custo de tal procedimento, métodos heurísticos são usados:
  - algoritmo **k-means**: onde cada cluster é representado pelo valor médio dos objetos no cluster
  - algoritmo **k-medóides**: onde cada cluster é representado por um dos objetos localizado próximo ao centro do cluster.

**K-means e K-medóides são os mais comuns dentro da categoria de particionamento.**

**Trabalham bem em bases de dados pequenas e médias e encontram clusters de formas esféricas.**

# K-means

(Han & Kamber, 2006)

- Técnica baseada em centróide.

**Objetivo: maximizar a similaridade intracluster e minimizar a similaridade intercluster.**

- A similaridade do cluster é medida em relação ao valor médio dos objetos no cluster (centróide ou centro de gravidade).

- Critério do erro quadrado:
- $$E = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2$$

**onde E é a soma do erro quadrado (distância) para todos os objetos no conjunto de dados; p é o ponto em um espaço de representação do objeto; m<sub>i</sub> é a média do clusters C<sub>i</sub> (tanto p quanto m são multidimensionais).**

# K-means - Algoritmo

(Han & Kamber, 2006)

**Input:**

k: o número de clusters;  
D: o conjunto de dados com n objetos;

**Output:**

um conjunto de k clusters (os vetores protótipos de cada clusters);

**Method:**

- (1) escolha k objetos de D, arbitrariamente, para representar os centros dos clusters (partições) iniciais;
- (2) repeat
- (3) (re)associe cada objeto para o cluster que tem seu centro mais similar ao objeto;
- (4) atualize as médias dos clusters, i.e., calcule o valor médio dos objetos para cada cluster;
- (5) until "nenhuma mudança ocorrer" (ou outro critério de parada);

# K-means: Executando...

- Dado um conjunto de pontos numéricos no espaço D-dimensional e um inteiro K;
- O algoritmo gera K (ou menos) clusters da seguinte maneira:

Escolha K clusters aleatoriamente

Ex.:  $K = 3$

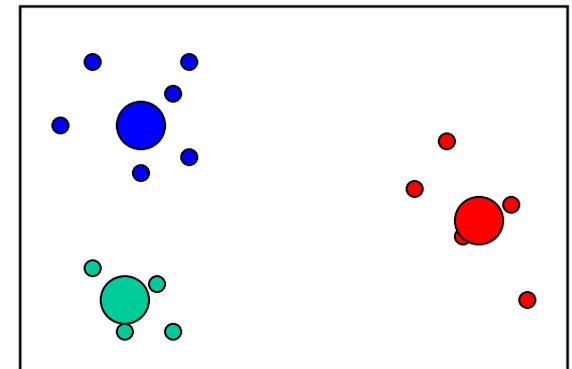
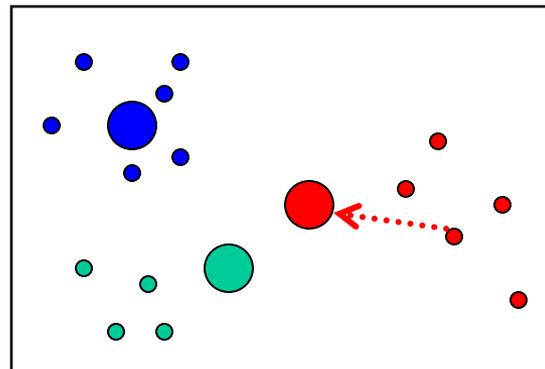
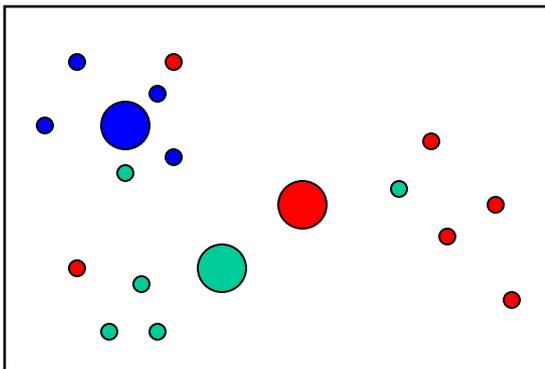
Calcule o centróide para cada cluster

Repita

Atribua cada ponto ao centróide mais próximo

Recalcule o centróide para cada cluster

Até estabilidade



# K-means: Problemas

- Os clusters finais não representam uma otimização global mas apenas local e clusters diferentes podem surgir a partir da diferença na escolha inicial aleatória dos centróides (1ª Figura);
- O parâmetro K deve ser escolhido antecipadamente, ou vários valores devem ser tentados, até encontrar o “melhor”;

Os dados devem ser numéricos e devem ser comparados através da distância Euclideana.

# K-means: Problemas

- O algoritmo trabalha melhor com dados que contêm clusters esféricos; clusters com outra geometria podem não ser encontrados;
- O algoritmo é sensível a *outliers* (pontos que não pertencem a nenhum cluster). Esses pontos podem distorcer a posição do centróide e deteriorar o cluster;

# Métodos Hierárquicos

(Han & Kamber, 2006)

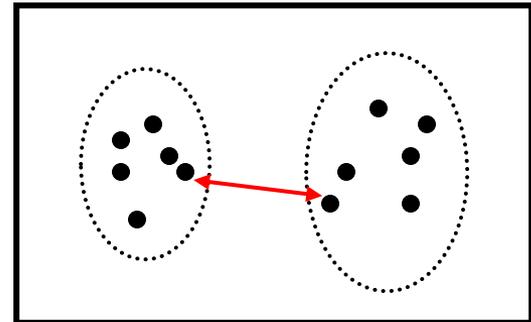
- Um método hierárquico cria uma decomposição hierárquica de um conjunto de dados. São classificados em:
  - **aglomerativos (*bottom-up*)**: inicia com cada objeto formando um grupo separado e sucessivamente junta os objetos ou grupos que estão mais próximos um do outro, até que apenas um grupo seja formado ou alguma condição de parada seja alcançada.
  - **divisivos (*top-down*)**: inicia com todos os objetos no mesmo grupo e a cada iteração, os divide em grupos menores, até que cada objeto esteja em um grupo ou alguma condição de parada seja alcançada.

# Clustering Hierárquico: Algoritmo

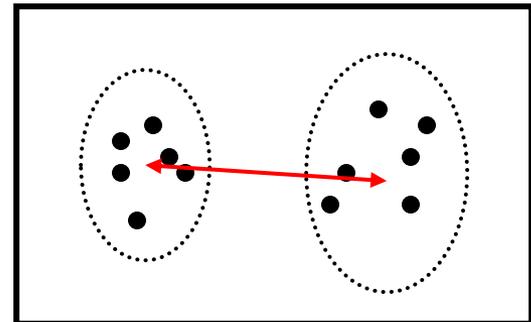
- Cria uma árvore na qual os objetos são as folhas e os nós internos revelam a estrutura de similaridade dos pontos
  - A árvore é freqüentemente chamada de “dendograma”
- O algoritmo pode ser resumido da seguinte maneira:  
Coloque todos os pontos em seus próprios clusters  
Enquanto há mais de um cluster Faça  
    Agrupe o par de clusters mais próximos
- O comportamento do algoritmo depende de como o “par de clusters mais próximo” é definido.

# Clustering Hierárquico: Agrupando Clusters

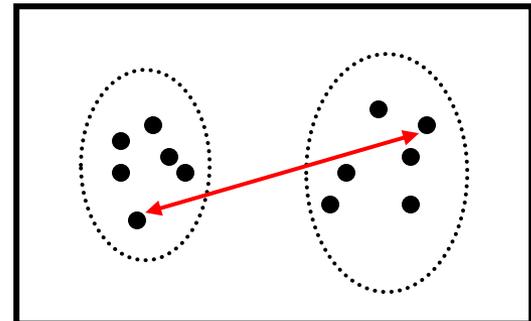
**Single Link:** Distância entre dois clusters é a distância entre os pontos mais próximos. Também chamado “agrupamento de vizinhos”.



**Average Link:** Distância entre clusters é a distância entre os centróides.



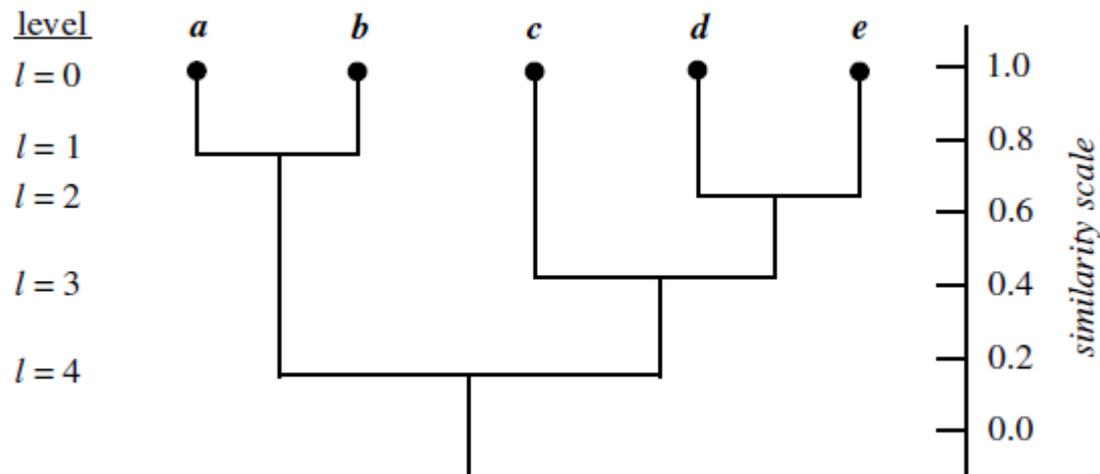
**Complete Link:** Distância entre clusters é a distância entre os pontos mais distantes.



# Métodos Hierárquicos

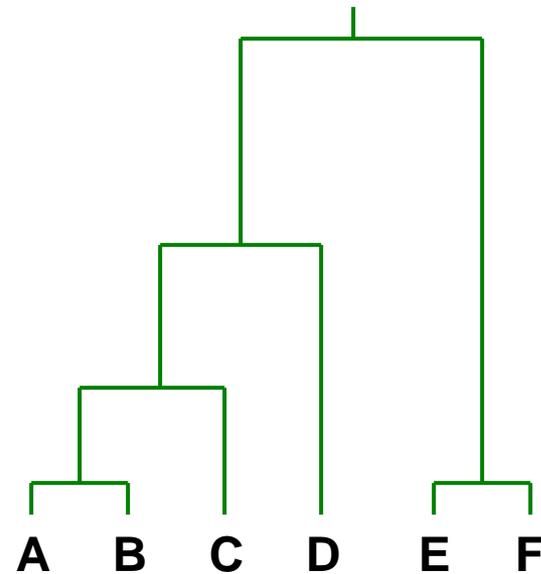
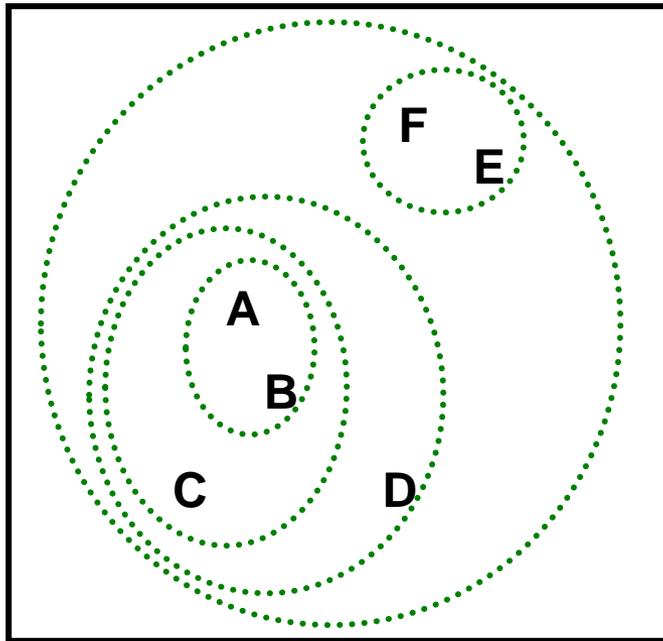
(Han & Kamber, 2006)

- Um dendograma é frequentemente usado para representar um agrupamento hierárquico.



# Clustering Hierárquico: Exemplo

Este exemplo ilustra single-link clustering no espaço Euclideano com 6 pontos



# Soluções (Há muitas)

- Pacotes em R, MatLab, Python,...
- Ferramentas livres como Weka, RapidMiner,...
- Ferramentas proprietárias como Clementine, Microsoft Power BI, Tableau,...



# Pra fechar...

- Objetivei dar uma visão geral (introdutória) de Análises de dados
- Um campo aberto para pesquisas, estudos de casos e desenvolvimento de soluções
- Não há como falar em Sistemas de Informação para tomada de decisões sem falar de Análise de Dados (diferencial)

# Referências

- Introdução a Banco de Dados (Apostila, Cap. 10). Prof. João Eduardo Ferreira (IME/USP)
- Notas de aula da Prof. Maria Luiza M.Campos (DCC/IM/UFRJ)
- Notas de aula do Prof. Edgard Jamhour (PPGIA/PUCPR)
- Eric Thomsen. OLAP – Construindo Sistemas de Informações Mutidimensionais. Editora Campus. Rio de Janeiro, 2002.
- Ralph Kimball. Data Warehouse Toolkit. Editora Makron Books. São Paulo, 1998.
- Laudon & Laudon. Gerenciamento de Sistemas de Informação. 3ª Edição. Editora LTC. Rio de Janeiro, 2001.
- Sistemas de Banco de Dados. (Cap. 28) Ramez Elmarsri e Sham Navathe. 4ª Edição. Ed. Pearson, 2005.
- REMENYL, D. MONEY, A. SHERWOOD-SMITH, M. The effective measurement and management of IT costs and benefits. Oxford: Butterworth-Heinemann, 2000.

# Referências

- Tecnologia da Informação para Gestão. Turban, E; McLean, E.; Wetherbe, J.; Bookman; 2002.
- Corporate Information Systems Management : Text and Cases. Fourth Edition By Applegate, Lynda M. / McFarlan, F. Warren / McKenney, James L.; 1996.
- Information Systems Management in Practice. Fourth Edition; Sprague, Ralph H. / McNurlin, Barbara; Prentice-Hall; 1999.
- Management Information Systems: Organization and Technology in the Networked Enterprise. Laudon, K., Laudon, J.; Prentice Hall; 2000.
- Enterprise Architecture Planning: Developing a Blueprint for Data, Applications and Technology By Spewak, Steven; 1993.
- Software Assessment, Benchmarks, and Best Practices;. Capers Jones; Addison Wesley; 2000.
- Redes de Valor. David Bovet; Joseph Martha; Negócios Editora; 2000.
- Big Data. Eje estratégico en la industria audiovisual. Eva Patricia Fernández Manzano (Organizador). Editorial UDC; 2016.

# Referências

- Mariano, V. L.; Boscarioli, C. Utilização de BI na Análise de Desempenho em uma Empresa do Agronegócio. In: Anais do SBSI 2012, São Paulo, SP, 2012.
- Zanardi, F.; Oyamada, M. S.; Boscarioli, C. Geração de Painéis Gerenciais a partir de Data Marts: Um Relato de Experiência . In: Anais do CONTECSI 2012, São Paulo, SP, 2012.
- Voltolini, R.; Boscarioli, C. Projeto, Implantação e Avaliação de uma Solução OLAP para Empresas de Venda de Telefonia Móvel Empresarial. Artigo de Conclusão de Curso. Pós-graduação em Tecnologias de Business Intelligence, Unioeste, Campus de Cascavel, 2011.
- HEHN, Herman F. e SILVA, Eloah C. A. M. P. Managerware: como extrair valor dos investimentos em Sistemas de Informação. São Paulo: Atlas, 2006.
- LAGO, S. M. S. Notas de aula. Unioeste, campus de Cascavel, 2011.
- LAUDON, Kenneth C. e LAUDON, Jane P. Sistemas de informação gerenciais. 9ª edição, São Paulo: Pearson, 2011.
- Gartner Group. 2014 - Magic Quadrant for Business Intelligence and Analytics Platforms. <https://www.gartner.com/doc/2668318>

**Venha pesquisar comigo...**



**unioeste  
Cascavel**



**PPGECM**

[www.unioeste.br/ppgecem](http://www.unioeste.br/ppgecem)

**Programa de Pós-graduação em Educação  
em Ciências e Educação Matemática**

**Mestrado e Doutorado**



**PPGComp**

[www.inf.unioeste.br/pos](http://www.inf.unioeste.br/pos)

**Programa de Pós-graduação em  
Ciência da Computação**

**Mestrado**

# Na continuação...



**Rodrigo Pereira Fontes**

**17/06 - Palestra 2: Modelos Preditivos de Vendas para Recomendação de Estoque**



**Anderson Brunheira Lopes**

**18/06 - Palestra 3: Business Intelligence and Analytics na Gestão da Construção Civil**

# Obrigado!



*Clodis Boscarioli*

 [boscarioli@gmail.com](mailto:boscarioli@gmail.com)  [clodisboscarioli](https://www.instagram.com/clodisboscarioli)