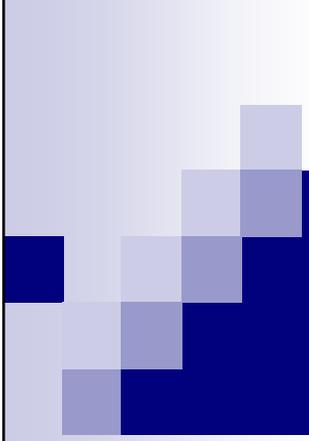


Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005



Sistemas de Apoio à Decisão

Data Mining & Optimização
Victor Lobo

Objectivos gerais

- Abrir horizontes em temas actuais
- Aprender técnicas usadas em “Sistemas de apoio à decisão” ou “Business Intelligence”
- Métodos de DataMining
 - Pesquisa de informação em grandes bases de dados
 - Aprender com experiência passada
- Métodos de Optimização
 - Resolver problemas de pesquisa “complicados”

Sistemas de Apoio à Decisão– Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005

Programa (parte relativa a técnicas)

1. **Introdução a Data Mining**
2. **Redes Neurais – Percepção multicamada (MLP)**
3. **Redes Neurais – Mapas auto-organizados (SOM)**
4. **Árvores de decisão**
5. **Introdução às técnicas de otimização**
6. **Algoritmos Genéticos**

Bibliografia

- **Data Mining Techniques, for sales and customer support**
 - Berry, M., Linoff, G., John Wiley and Sons, 1997
- **Principles of Data Mining**
 - Hand, D., Mannila, H., Smyth, P.; MIT Press, 2001
- **Machine Learning**
 - Mitchell, Tom, McGraw-Hill, 1997
- **Haykin, Bishop, Hertz, Breiman, Salvador, ...**

Sistemas de Apoio à Decisão – Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005

Software

- SAS - Enterprise Miner
- SPSS - Clementine
- IBM - Intelligent Miner
- “open source em Java” - WEKA
- SAP – Módulos de Business Intelligence
- Matlab – Toolboxes de NN, DT, GA, etc
- Outros – “Statistica Neural Networks”, SOM_PAK, C4.5(original), SNNS, plug ins para Excel, etc, etc, etc.

**Nosso patrocinador !
Disponível nas salas**

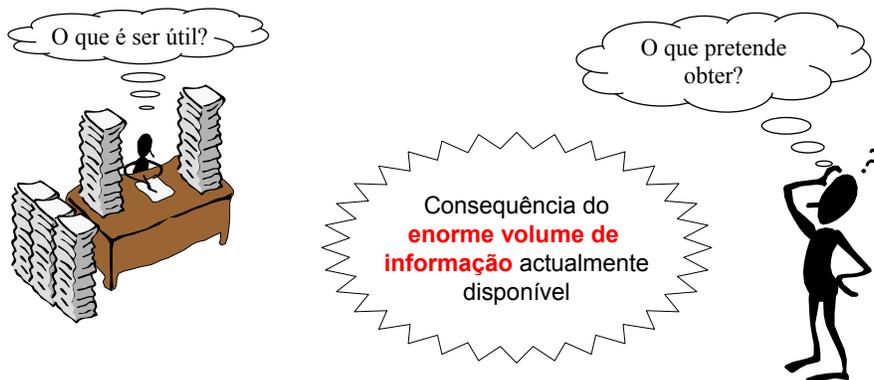
Alguns sites interessantes...

- Machine Learning Network
 - www.mlnet.org
 - Software, dados, conferências, projectos, etc.
- Repositório de Irvine
 - www.ics.uci.edu/~mlearn
 - Dados, software, artigos
- Homepage do WEKA
 - www.mkp.com/datamining
- SOM (H.U.T.)
 - www.cis.hut.fi/research/som-research/
 - Software, bibliografia sobre SOM



O que é “Data Mining”?

- “Data Mining” é a pesquisa de informação útil em grandes quantidades de dados

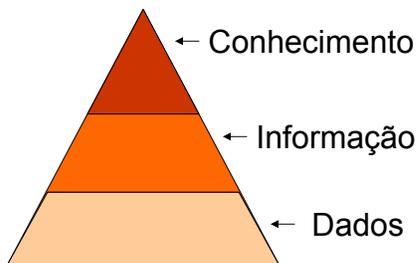


Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005

Informação é poder...

- “Água é vida”...
 - Todos os anos morre gente afogada...
- É necessário “trabalhar” a informação
- Hierarquia de compreensão e utilidade

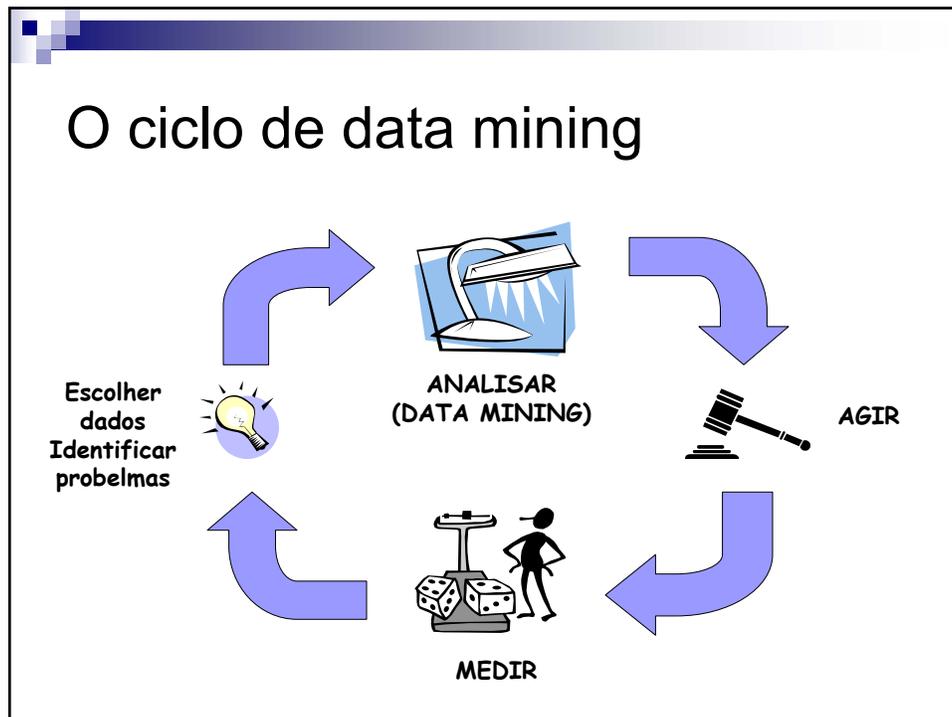


E o que fazer depois de ter os dados organizados ?



Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005



Simplificando, Data Mining é

■ A utilização de três técnicas diferentes:

- Bases de dados
- Estatística
- Aprendizagem máquina.**
(Machine Learning)

■ Para resolver dois tipos de problemas

- Predição
- Descobrir novo conhecimento



Predição e novo conhecimento

■ Predição

- é aprender critérios de decisão para ser capaz de classificar casos desconhecidos

■ Descobrir novo conhecimento

- é encontrar padrões desconhecidos existentes nos dados



Tipos de problemas

■ Predição

- Classificação
- Regressão



■ Descoberta de conhecimento

- Detecção de desvios
- Segmentação de bases de dados
- Clustering
- Regras de associação
- Sumarização
- Visualização
- Pesquisa em texto

Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005

Exemplos

- Detecção de fraudes na utilização de um cartão de crédito
- Deferir, ou não, um pedido de crédito
- Prever perdas com seguros
- Prever os níveis de audiência dos canais de televisão
- Classificar os efeitos hidrofónicos produzidos por diferentes navios
- Analisar as respostas de um inquérito médico
- Escolher clientes a quem direccionar uma campanha de marketing
- Cross-selling, fidelização, etc, etc,

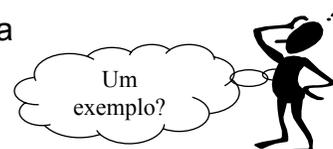


Problemas “a montante” ...

- Recolha de dados
- Representação dos dados
- Armazenagem, organização, e disponibilização dos dados
- Pré-processamento dos dados

Representação dos dados

- Representação mais usada = tabela
 - (Existem muitas outras...)
- Exemplo
 - Empresa de seguros de saúde



Dado, vector, registo ou padrão

Variável, característica, ou atributo

Altura	Peso	Sexo	Idade	Ordenado	Usa ginásio	Encargos para seguradora
1.60	79	M	41	3000	S	N
1.72	82	M	32	4000	S	N
1.66	65	F	28	2500	N	N
1.82	87	M	35	2000	N	S
1.71	66	F	42	3500	N	S

Tipos de atributos

- Booleanos ou binários
 - Só tomam dois valores
- Nominais
 - Tomam um conjunto de valores não ordenados
- Ordinais
 - Tomam um conjunto (finito) de valores ordenados
- Numéricos

Como organizar os dados?

■ “Data warehouse”

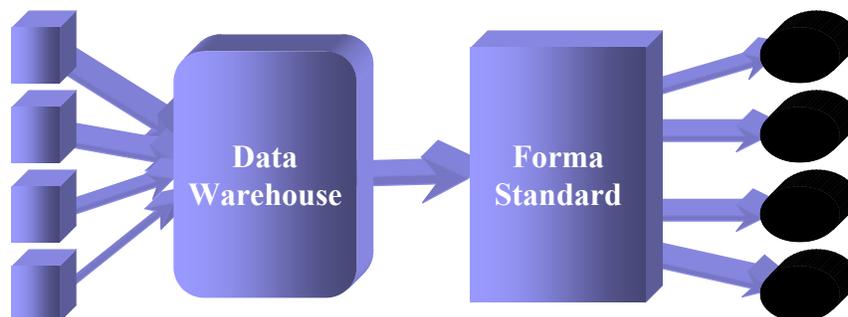
- É o suporte centralizado de informação importante para a decisão.



O modelo de “data warehouse”

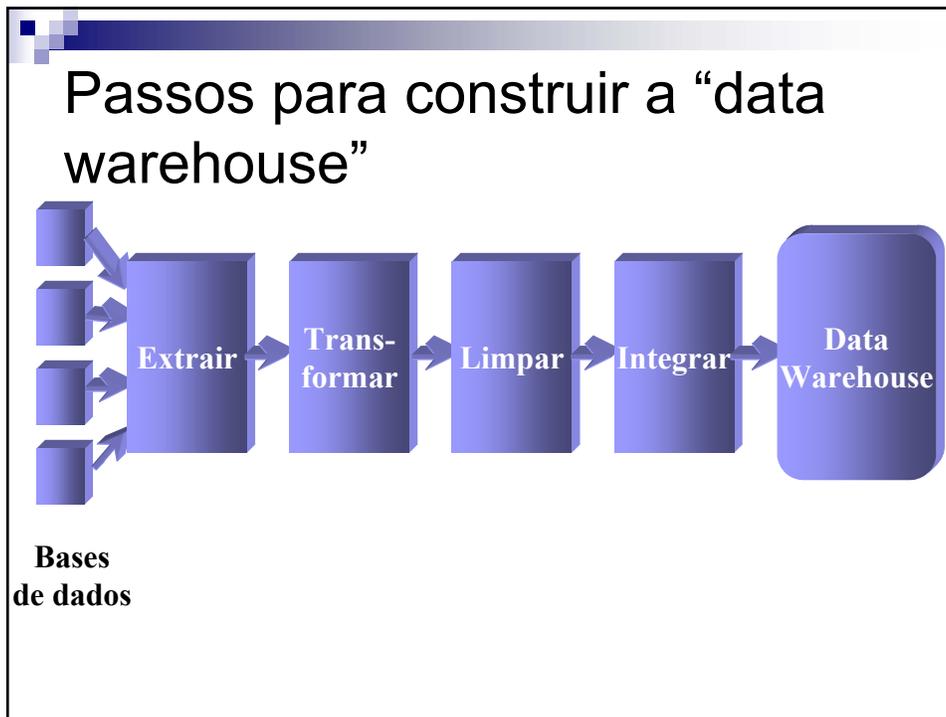
Bases de dados

Métodos preditivos



Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005



Pré-processamento dos dados

- “Tratar” dos missing values
 - Eliminá-los, substituí-los, etc
- Corrigir factores de escala entre atributos
 - Normalização linear por min/max
 - Normalizar média e desvio padrão
 - Outras
- Transformações de variáveis...
- *Vidé “Data preparation for Data Mining”, Dorian Pyle, Morgan Kaufmann, 1999*

Alguns problemas importantes que NÃO vamos tratar...

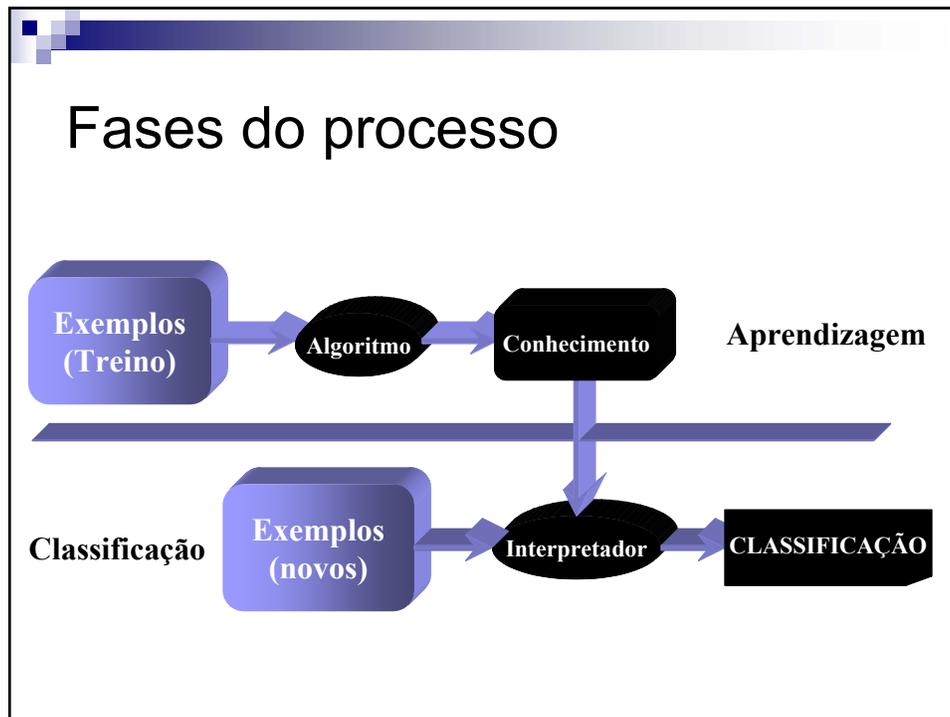
- Escolha dos atributos
- Visualização
 - Dados multidimensionais
 - Problema central em datamining
- OLAP e outras técnicas de “reporting”
 - On-line Analytical Processing
- Regras de Associação e “Market Basket Analysis”

Introdução à aprendizagem

Aprender a partir dos dados conhecidos

Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005



Exemplo de aprendizagem

(1)

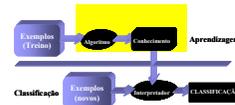
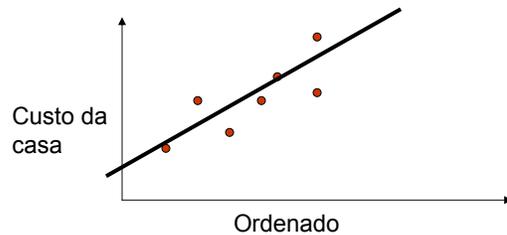
- Agência imobiliária pretende estimar qual a gama de preços para cada cliente
- Exemplos de treino:
 - Dados históricos
 - Ordenado vs custos de casas compradas

A scatter plot showing the relationship between the floor number of a house (Ordenado) on the x-axis and the house cost (Custo da casa) on the y-axis. The data points show a positive correlation, indicating that houses on higher floors tend to have higher costs.

Exemplo de aprendizagem

(2)

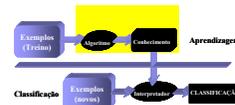
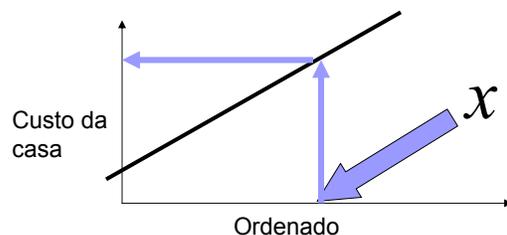
- Algoritmo
 - Regressão linear
- Representação do conhecimento
 - Recta (declive e ordenada na origem)



Exemplo de aprendizagem

(3)

- Exemplos novos
 - Um novo cliente, com ordenado x
- Interpretação
 - Usar a recta (método de previsão usado) para obter uma PREVISÃO



Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005

Outro problema de predição

- Exemplo da seguradora
- Existem um conjunto de dados conhecidos
 - Conjunto de treino
- Queremos prever o que vai ocorrer noutros casos
 - Empresa de seguros de saúde quer estimar custos com um novo cliente

Conjunto de treino (dados históricos)

Altura	Peso	Sexo	Idade	Ordenado	Usa ginásio	Encargos para seguradora
1.60	79	M	41	3000	S	N
1.72	82	M	32	4000	S	N
1.66	65	F	28	2500	N	N
1.82	87	M	35	2000	N	S
1.71	66	F	42	3500	N	S

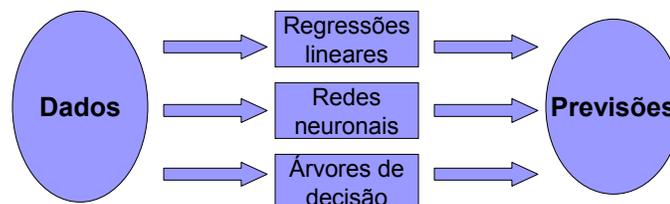
E o Manel ?

Altura=1.73
Peso=85
Idade=31
Ordenado=2800
Ginásio=N

Terá encargos para a seguradora ?

Tipos de sistemas de previsão

- “Clássicos”
 - Regressões lineares, logísticas, etc...
- Redes Neurais
- Árvores de decisão



Tipos de Aprendizagem

SUPERVISIONADA vs NÃO SUPERVISIONADA
INCREMENTAL vs BATCH
PROBLEMAS

Professor/Aluno

- Todo o processo de aprendizagem pode ser caracterizado por um protocolo entre o professor e o aluno.
- O professor pode variar entre o tipo dialogante e o não cooperante.



Protocolos Professor/Aluno

- Professor nada cooperante
 - Só dá os exemplos => **não supervisionada**
- Professor cooperante
 - Dá exemplos classificados => **supervisionada**
- Professor pouco cooperante
 - Só diz se os resultados estão certos ou errados
=> **aprendizagem por reforço**
- Professor dialogante - ORÁCULO

Formas de adquirir o conhecimento

- Incremental
 - Os exemplos são apresentados um de cada vez e a estrutura de representação vai-se alterando
- Não incremental (batch)
 - Os exemplos são apresentados todos ao mesmo tempo e são considerados em conjunto.

Acesso aos exemplos

- Aprendizagem “offline”
 - Todos os exemplos estão disponíveis ao mesmo tempo
- Aprendizagem “online”
 - Os exemplos são apresentados um de cada vez
- Aprendizagem mista
 - Uma mistura dos dois casos anteriores

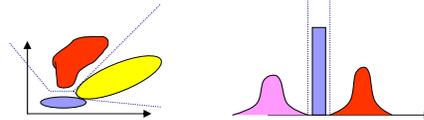
Problema do n° de atributos

- Poucos atributos
 - Não conseguimos distinguir classes
- Muitos atributos
 - Caso mais vulgar em Datamining
 - Praga da dimensionalidade
 - Visualização difícil e efeitos “estranhos”
- Atributos importantes vs redundantes
 - Quais os atributos importantes para a tarefa?

Problema da separabilidade

■ Separáveis

- Erro \emptyset possível

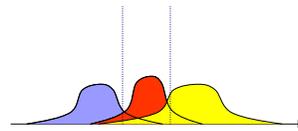


■ Não separáveis

- Erro sempre $> \emptyset$

- Erro de Bayes

- Erro mínimo possível para um classificador



Problema do “melhor” tipo de modelo

- A representação de conhecimento mais simples.
 - Mais fácil de entender
 - Árvores de decisão vs redes neuronais
- A representação de conhecimento com menor probabilidade de erro.
- A representação de conhecimento mais provável
 - Navalha de Occam ...

Problemas ...

- Adequabilidade da representação do conhecimento à tarefa que se quer aprender
- Ruído
 - Ruído na classificação dos exemplos ou nos valores dos atributos.
 - Má informação é pior que nenhuma informação
- Enormes quantidades de dados
 - Quais são importantes? Tempo de processamento
- Aprender “demais”
 - Decorar os dados. Vamos ver isso agora...

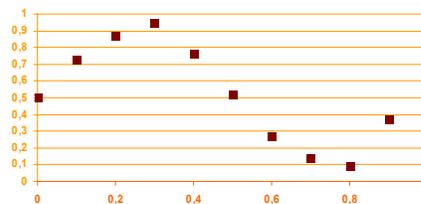
Generalização e
“overfitting”

Os dados



Exemplo de overfitting

- Seja um conjunto de 11 pontos.
- Encontrar um polinómio de grau M que represente esses 11 pontos.



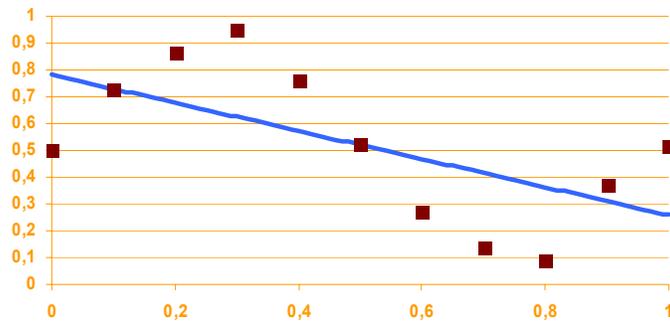
$$y(x) = \sum_{i=0}^M w_i x^i$$

Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005

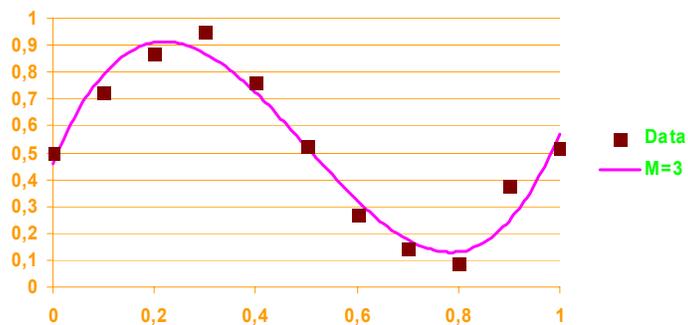
Aproximação M = 1

$$y(x) = w_0 + w_1x$$



Aproximação M = 3

$$y(x) = w_0 + w_1x + w_2x^2 + w_3x^3$$

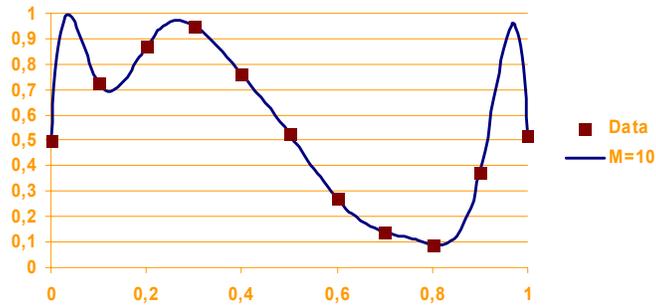


Sistemas de Apoio à Decisão— Introdução ao DataMining

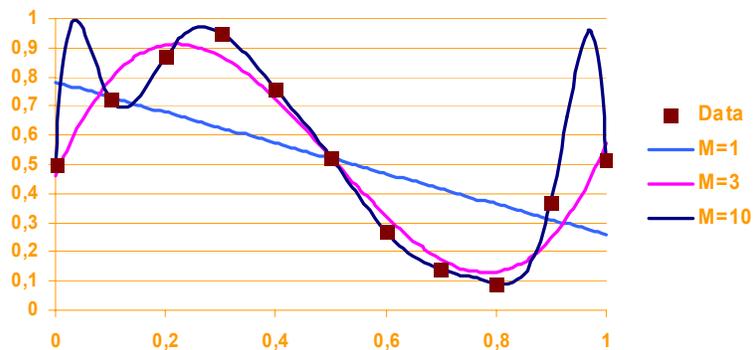
V 1.0, V.Lobo, EN/ISEGI, 2005

Aproximação M = 10

$$y(x) = w_0 + w_1x + w_2x^2 + w_3x^3 + w_4x^5 + w_6x^6 + w_7x^7 + w_8x^8 + w_9x^9 + w_{10}x^{10}$$



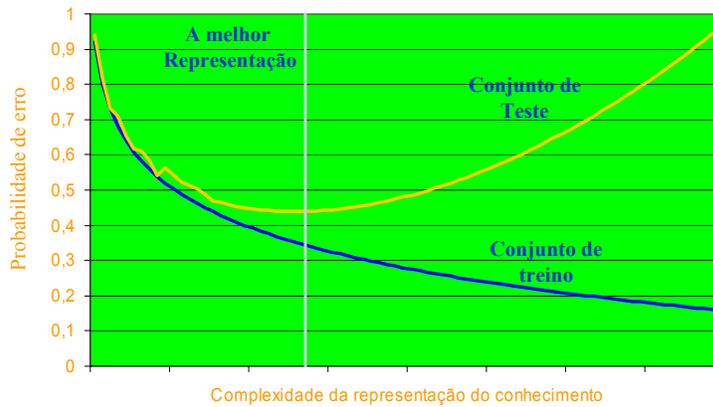
Overfitting



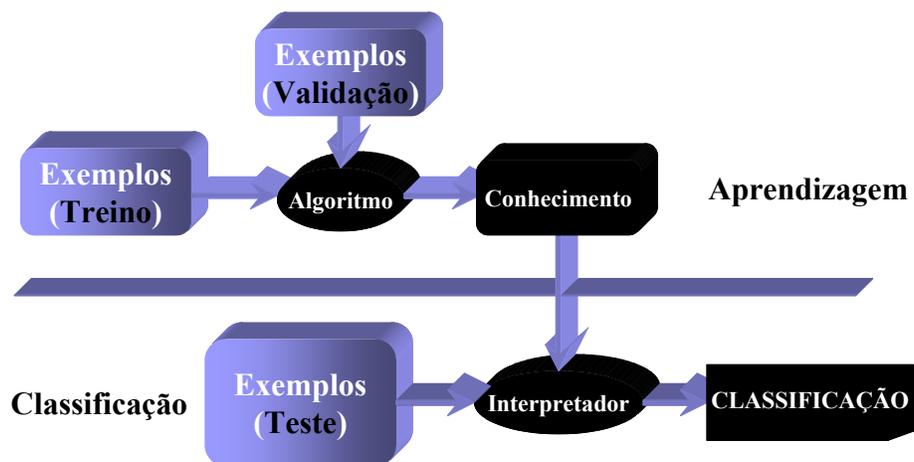
Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005

Curva de Overfitting



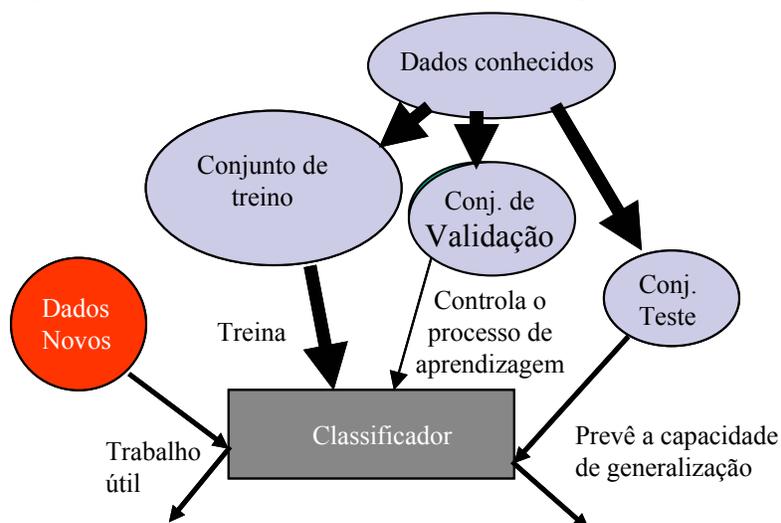
Fases do processo



Generalização

- O objectivo não é aprender a agir no conjunto de treino mas sim no universo “desconhecido” !
 - Como preparar para o desconhecido ?
- Manter um conjunto de teste “de reserva”

Conjunto de treino/validação/teste



Divisão dos dados

- Conjunto de treino
 - Quanto maior, melhor o classificador obtido
- Conjunto de validação
 - Quanto maior, melhor a estimação do treino óptimo
- Conjunto de teste
 - Quanto maior, melhor a estimação do desempenho do classificador

Processo de aprendizagem

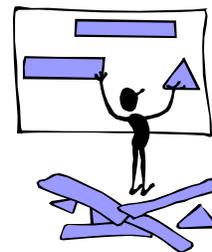
- A aprendizagem é um processo de optimização (Minimização do erro)
- Algoritmo de optimização
 - Método do gradiente
 - Subir a encosta
 - Guloso
 - Algoritmos genéticos
 - “Simulated annealing”
- Formas de adquirir o conhecimento



Projecto do sistema de aprendizagem

Tarefas do projecto

- Preparação dos dados.
- Redução dos dados.
- Modelação e predição dos dados.
- Casos e análise das soluções



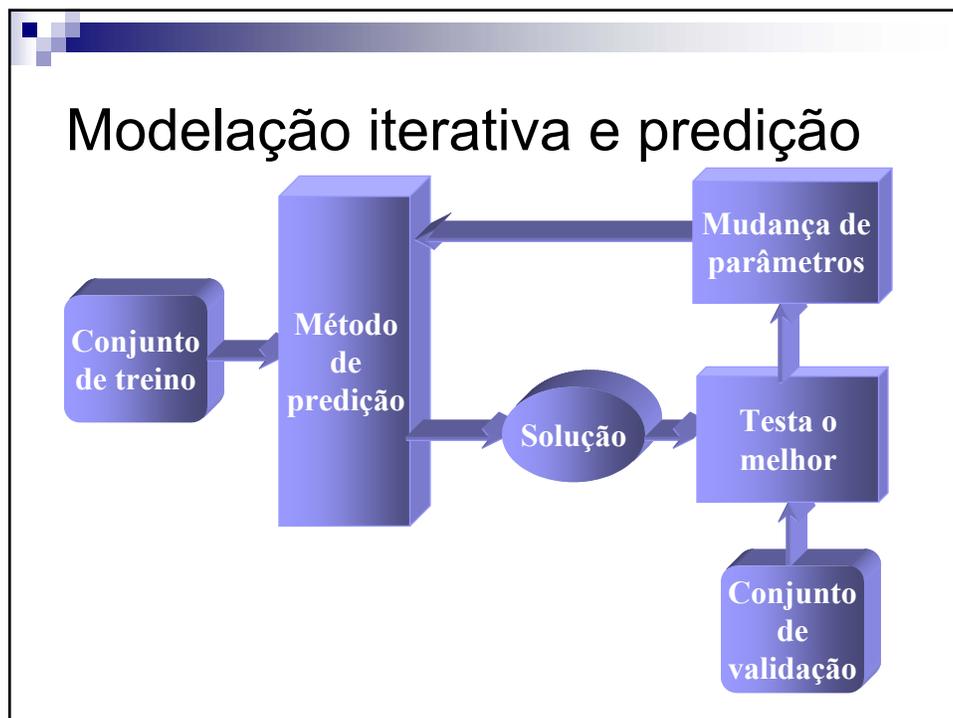
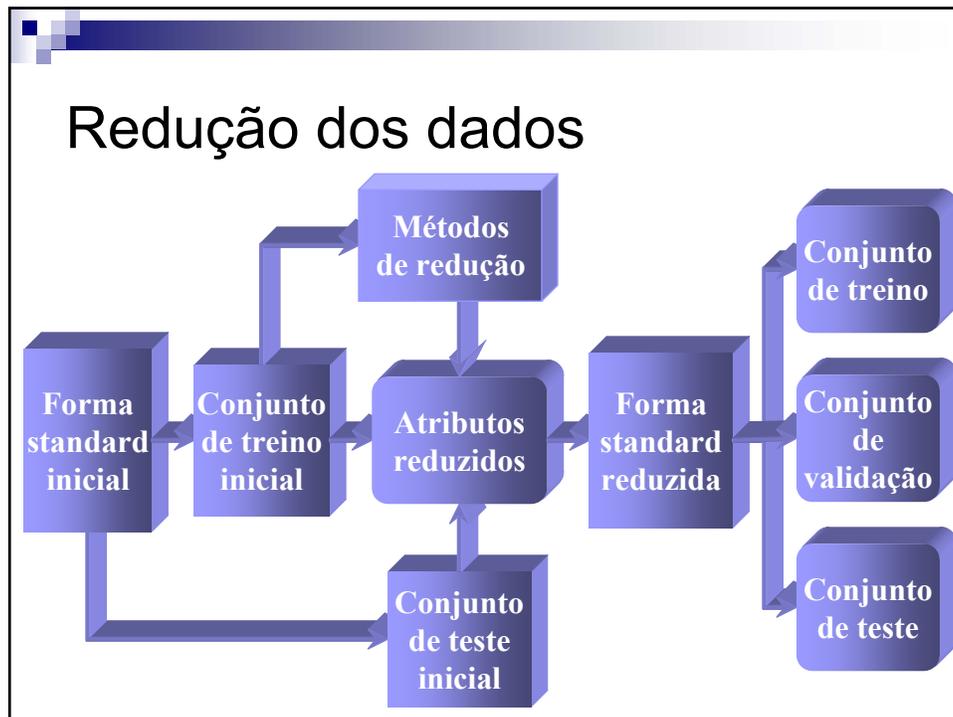
Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005



Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005



Sistemas de Apoio à Decisão— Introdução ao DataMining

V 1.0, V.Lobo, EN/ISEGI, 2005



Considerações finais

Os principais paradigmas

- Redes Neurais
- Baseados em instâncias
- Algoritmos genéticos
- Indução de regras
- Aprendizagem analítica

Alguns pontos para meditar(1)

- Que modelos são mais adequados para um caso específico?
- Que algoritmos de treino são mais adequados para um caso específico?
- Quantos exemplos são necessários? Qual a confiança que podemos ter na medida de desempenho?
- Como pode o conhecimento a priori ajudar o processo de indução?

Alguns pontos para meditar(2)

- Qual a melhor estratégia para escolher o processo exemplo? Em que medida a estratégia altera o processo de aprendizagem?
- Quais as funções objectivo que se devem escolher para aprender? Poderá esta escolha ser automatizada?
- Como pode o sistema alterar automaticamente a sua representação para melhorar a capacidade de representar e aprender a função objectivo?

Exemplos de
problemas

Exemplos (1)

- Um banco quer estudar as características dos seus clientes. Para isso precisa de encontrar grupos de clientes para os caracterizar.
- Quais as variáveis do problema? Como descrever os diferentes clientes.
- Que problema de aprendizagem se está a tratar?

Exemplo (2)

- Uma empresa de ramo automóvel resolveu desenvolver um sistema automático de condução de automóveis.
- Quais as variáveis do problema? Como descrever os diferentes ambientes.
- Que problema de aprendizagem se está a tratar?

Exemplo (3)

- Quer estudar-se a relação entre o custo das casas e os bairros de Lisboa.
- Quais as variáveis do problema? Como descrever os diferentes bairros.
- É um problema problema de predição, mas será de classificação ou de regressão?

Exemplo (4)

- Uma empresa de seguros do ramo automóvel quer detectar as fraudes das declarações de acidentes.
- Quais as variáveis do problema? Como descrever os clientes e os acidentes?
- É um problema problema de predição, mas será de classificação ou de regressão?