

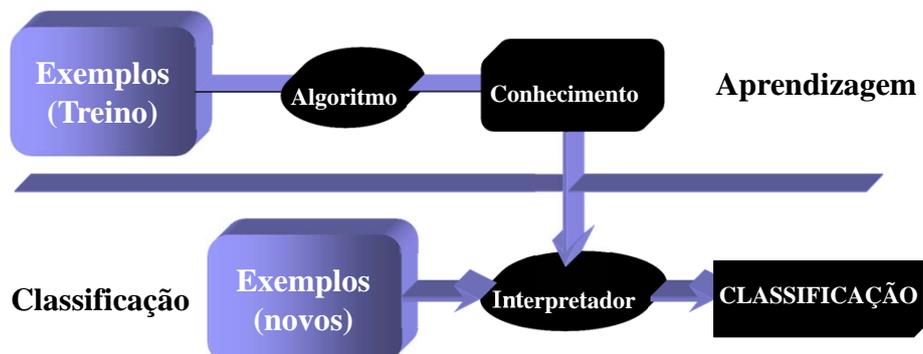
# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Introdução à aprendizagem

Aprender a partir dos dados conhecidos

## Fases do processo

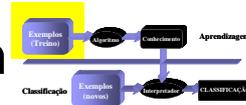


# Introdução ao Datamining

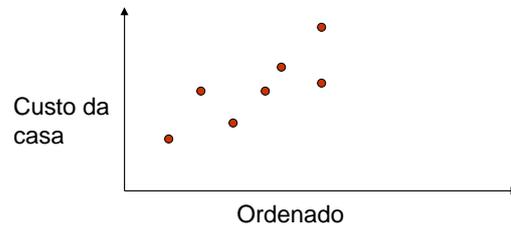
V 1.4, V.Lobo, EN/ISEGI, 2012

## Exemplo de aprendizagem

(1)

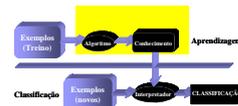


- Agência imobiliária pretende estimar qual a gama de preços para cada cliente
- Exemplos de treino:
  - Dados históricos
  - Ordenado vs custos de casas compradas

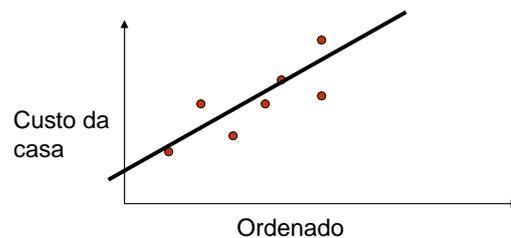


## Exemplo de aprendizagem

(2)



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

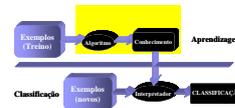


# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Exemplo de aprendizagem

(3)

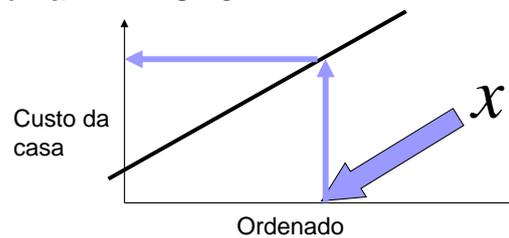


- Exemplos novos

- Um novo cliente, com ordenado  $x$

- Interpretação

- Usar a recta (método de previsão usado) para obter uma PREVISÃO



## Outro problema de predição

- Exemplo da seguradora (seguros de saúde)

- Existe 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

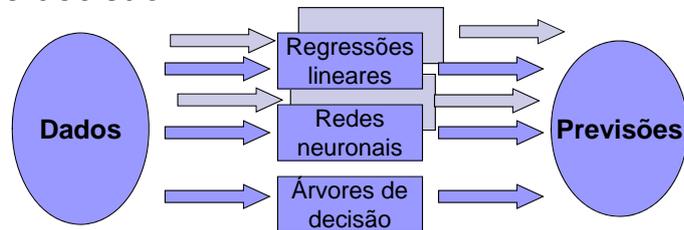
Terá encargos para a seguradora ?

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Tipos de sistemas de previsão

- “Clássicos”
  - Regressões lineares, logísticas, etc...
- Vizinhos mais próximos
- Redes Neurais
- Árvores de decisão
- Regras
- “ensembles”



## Tipos de Aprendizagem

SUPERVISIONADA vs NÃO SUPERVISIONADA

INCREMENTAL vs BATCH

PROBLEMAS

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## 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

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## 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

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

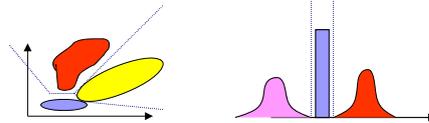
## Problema do nº de atributos

- 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

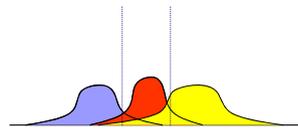
### ■ Separáveis

- Erro  $\emptyset$  possível



### ■ Não separáveis

- Erro sempre  $> \emptyset$
- Erro de Bayes
  - Erro mínimo possível para um classificador



# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Problema do “melhor” tipo de modelo

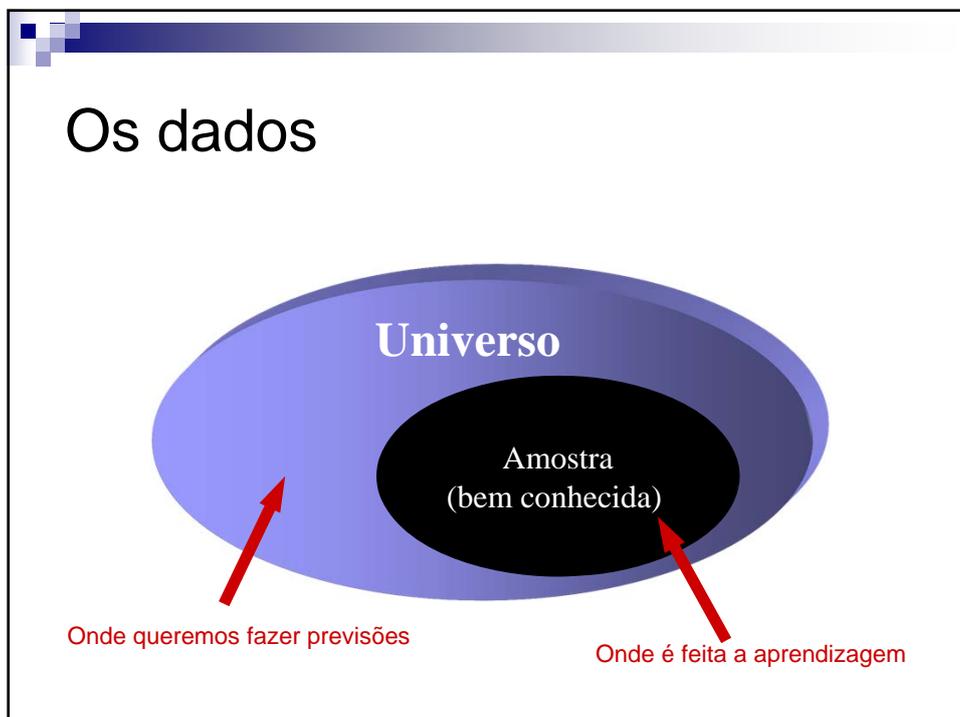
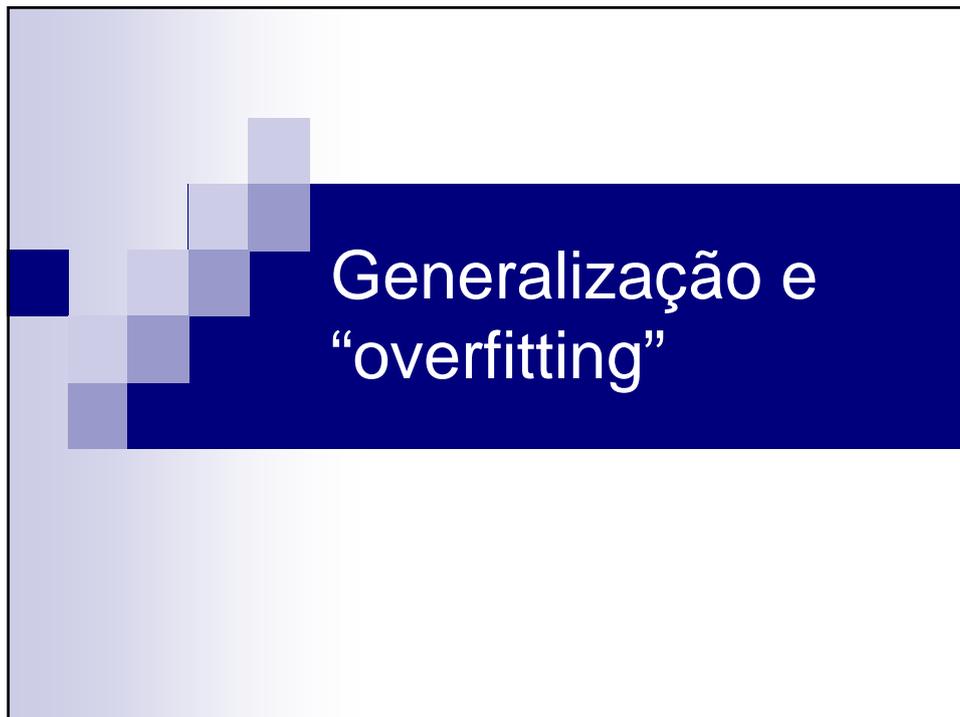
- A representação de conhecimento mais simples.
  - Mais fácil de entender
  - Árvores de decisão vs redes neuronais
- A representação de conhecimento com menor probabilidade de erro.
- A representação de conhecimento mais provável
  - Navalha de Occam ...

## 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...

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012



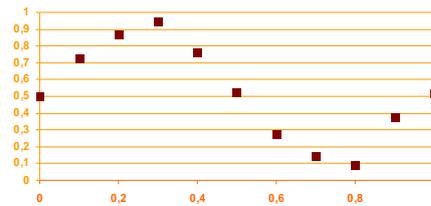
# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Exemplo de overfitting

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

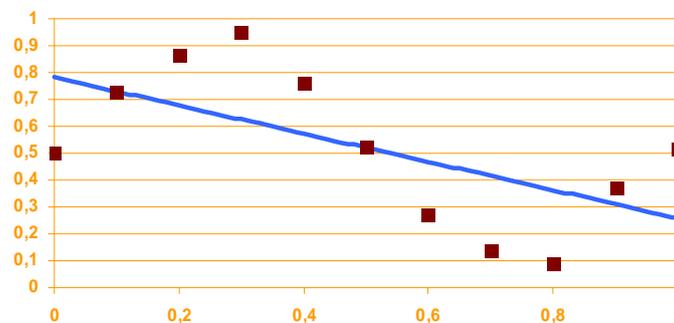
$$y(x) = \sum_{i=0}^M w_i x^i$$



## Aproximação M = 1

$$y(x) = w_0 + w_1 x$$

Erro grande

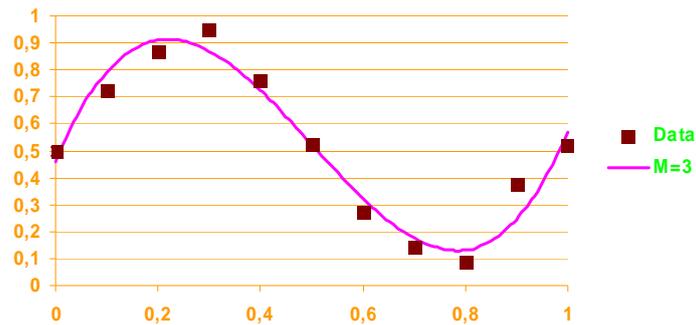


# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

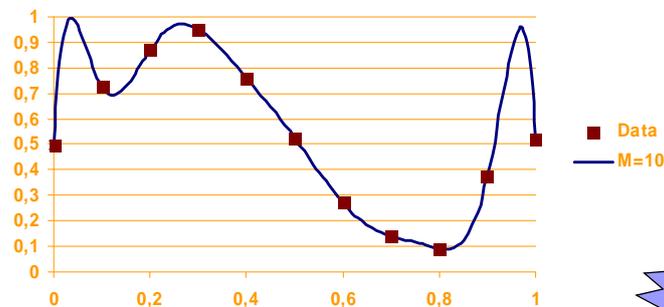
## Aproximação $M = 3$

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



## Aproximação $M = 10$

$$y(x) = w_0 + w_1x + w_2x^2 + w_3x^3 + w_4x^4 + w_5x^5 + w_6x^6 + w_7x^7 + w_8x^8 + w_9x^9 + w_{10}x^{10}$$

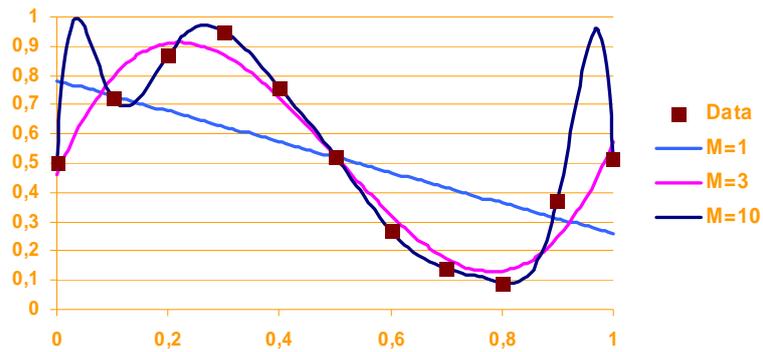


Erro zero

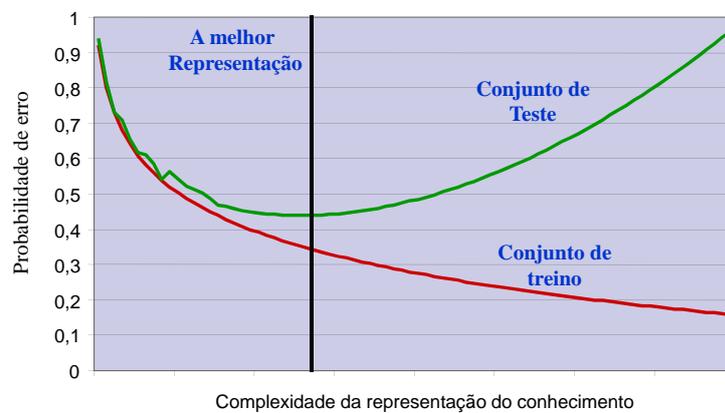
# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Overfitting



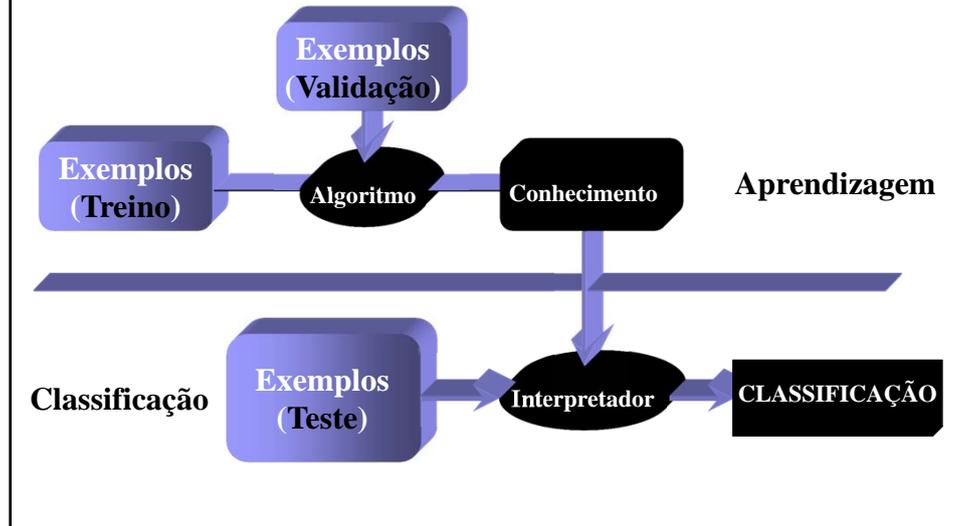
## Curva de Overfitting



# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Fases do processo

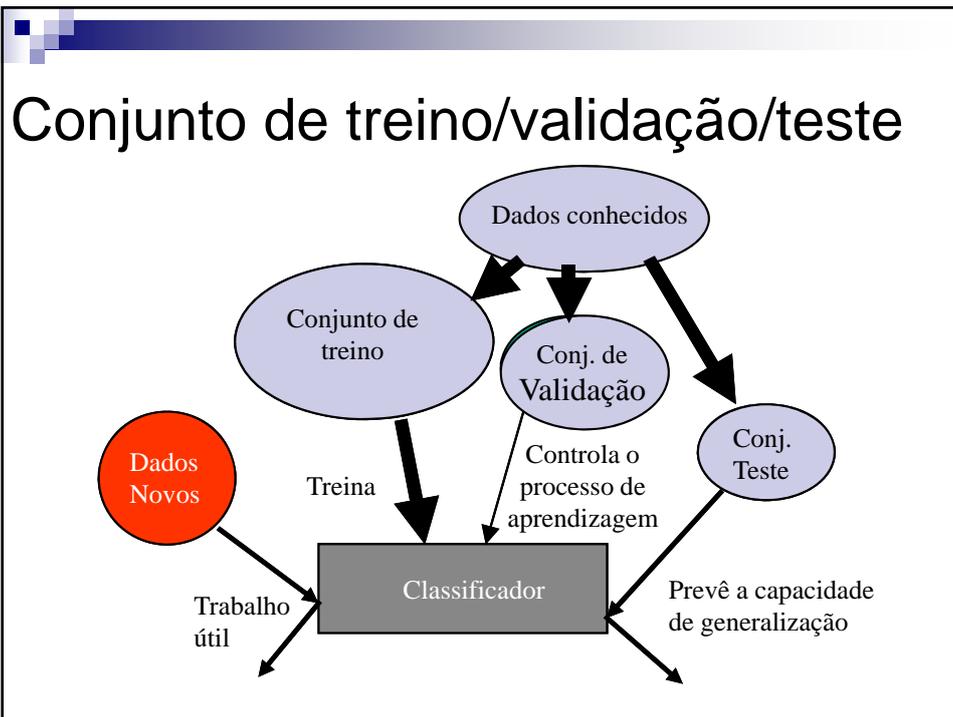


## Generalização

- 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”

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012



## Divisão dos dados

- Conjunto de **treino**
  - Usado para construir o classificador
  - Quanto maior, melhor o classificador obtido
- Conjunto de **validação**
  - Usado para controlar a aprendizagem (opcional)
  - Quanto maior, melhor a estimação do treino óptimo
- Conjunto de **teste**
  - Usado para estimar o desempenho
  - Quanto maior, melhor a estimação do desempenho do classificador

# Introdução ao Datamining

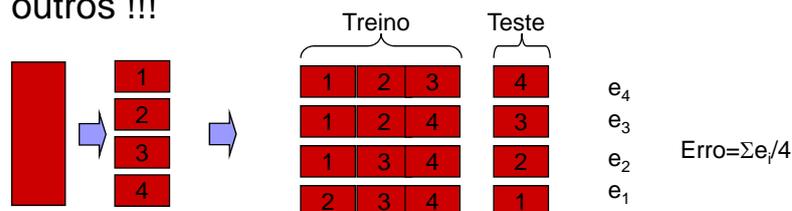
V 1.4, V.Lobo, EN/ISEGI, 2012

## Estimativas do erro do classificador

- Em problemas de classificação
  - **Taxa de erro** =  $n^{\circ}$  de erros/total (ou *missclassification error*)
  - Possibilidade de usar o “custo do erro”
- Em problemas de regressão
  - **Erro quadrático médio**, erro médio, etc...
- Estimativas optimistas ou não-enviesadas
  - Erro no conjunto de treino (erro de resubstituição)
    - Optimista
  - Erro no conjunto de validação
    - Ligeiramente optimista
  - **Erro no conjunto de teste**
    - Não enviesado. A melhor estimativa possível
    - (no entanto...se estes dados fossem usados para treino...)

## Estimativas robustas do erro

- **Validação cruzada**
  - **Cross-validation**, ou *leave-n-out*
  - Dividir os mesmos dados em diferentes partições treino/teste
  - Calcular erro médio
  - Nenhum dos classificadores é melhor que os outros !!!



# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Outras medidas de erro em classificação

### ■ Matriz de confusão

- Separa os diversos tipos de erro

- Falso Positivo (FP)
  - O classificador diz que é, e não é
- Falso Negativo (FN)
  - O classificador não detecta que é

Matriz de Confusão	Classificado como SIM	Classificado como NÃO
Realmente é SIM	<i>TP</i>	<i>FN</i>
Realmente é NÃO	<i>FP</i>	<i>TN</i>

- Permite compreender em que é que o classificador é bom

### ■ Medidas de erro


- Taxa de erro =  $(FP+FN)/n$  Erro mais tradicional
- Confiança positiva =  $TP/(TP+FP)$  Quão "definitivo" é um resultado positivo (por vezes "precision")
- Confiança negativa =  $TN/(TN+FN)$  Quão "definitivo" é um resultado negativo
- Sensibilidade =  $TP/(TP+FN)$  Quão bom é a apanhar os positivos (por vezes "recall")
- Precisão (accuracy) =  $(TP+TN)/n$  O complementar da taxa de erro
- Há mais medidas, adaptadas a cada problema em particular !

## 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

# Introdução ao Datamining

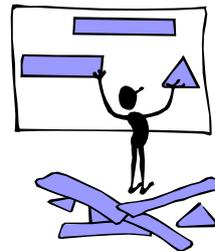
V 1.4, V.Lobo, EN/ISEGI, 2012

A graphic of a staircase with several steps, rendered in shades of blue and grey, positioned to the left of the text.

Iterações sucessivas  
do sistema de  
aprendizagem

## Tarefas do projecto do sistema

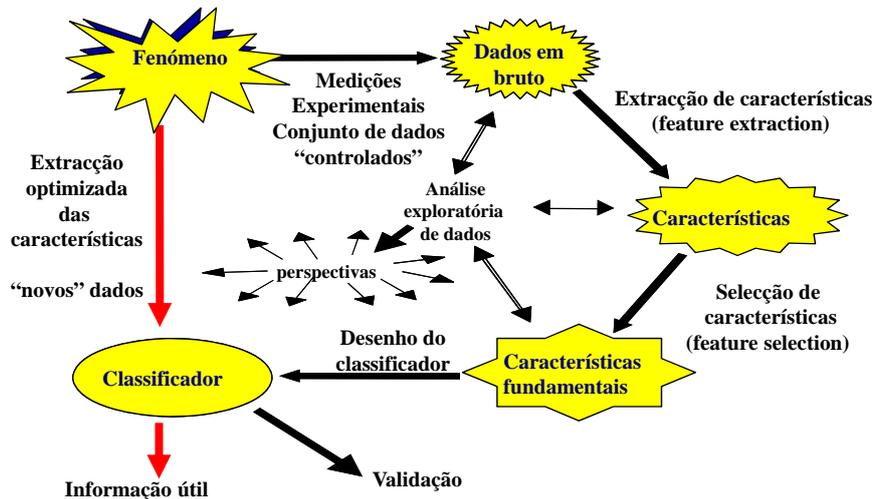
- Preparação dos dados.
- Redução dos dados.
- Modelação e predição dos dados.
- Casos e análise das soluções



# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Aproximação exploratória...

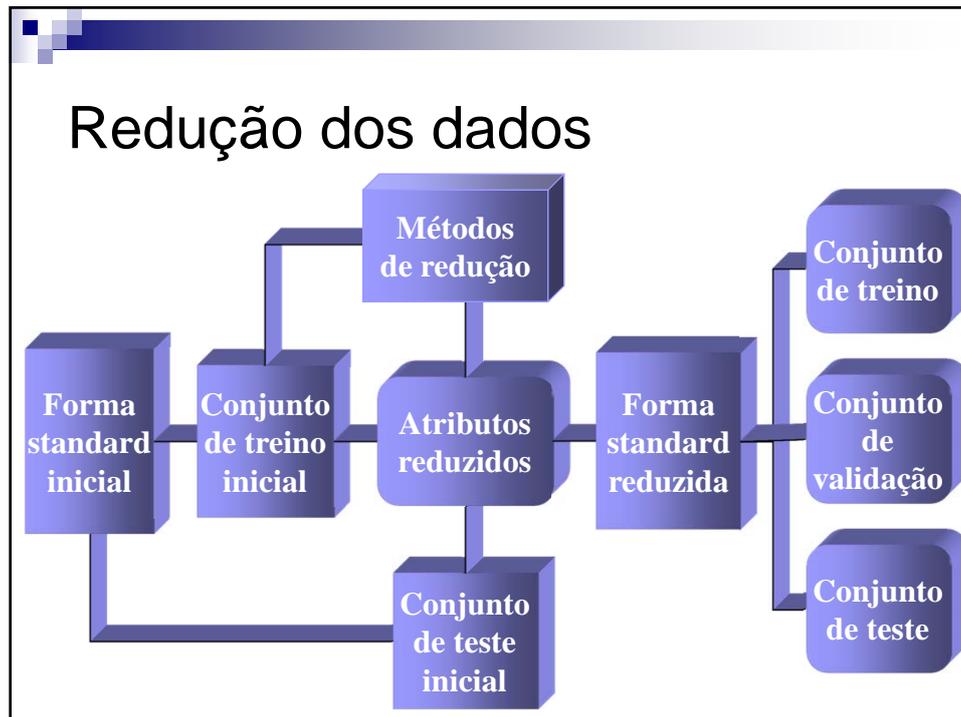


## Preparação dos dados



# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012



# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Análise das soluções



## Os principais paradigmas

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

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## 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 os exemplos ? 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?

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Pré-Processamento dos dados

### Porquê pré-processar os dados

- Valores omissos (missing values)
- Factores de escala
- Invariância a factores irrelevantes
- Eliminar dados contraditórios
- Eliminar dados redundantes
- Discretizar ou tornar contínuo
- Introduzir conhecimento “à priori”
- Reduzir a “praga da dimensionalidade”
- Facilitar o processamento posterior

Crucial !

Garbage in /  
Garbage out

# Introdução ao Datamining

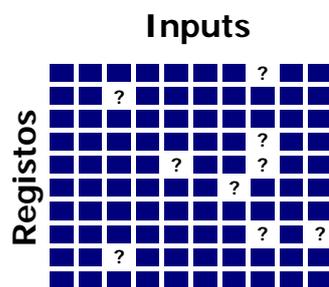
V 1.4, V.Lobo, EN/ISEGI, 2012

## Valores omissos

- Usar técnicas que lidem bem com eles
- Substituí-los
  - Por valores “neutros”
  - Por valores “médios” (média, mediana, moda, etc)
  - Por valores “do vizinho mais próximo”
    - K-vizinhos, parzen, etc
  - Interpolações
    - Lineares, com “splines”, com Fourier, etc.
  - Com um estimador “inteligente”
    - Usar os restantes dados para fazer a previsão

## Alternativa: Eliminar valores omissos

- Eliminar registos
  - Podemos ficar com poucos dados
  - (neste caso 3 em 10)
- Eliminar variáveis
  - Podemos ficar com poucas características
  - (neste caso 4 em 9)



## Abordagem iterativa

- Usar primeiro uma aproximação “grosseira”
  - Eliminar registos / variáveis
  - Usar simplesmente valores médios
- Observar os resultados
  - Conseguem-se boas previsões ?
  - Resultados são realistas ?
- Abordagem mais fina
  - Estimar valores para os omissos
  - Usar “clusters” para definir médias

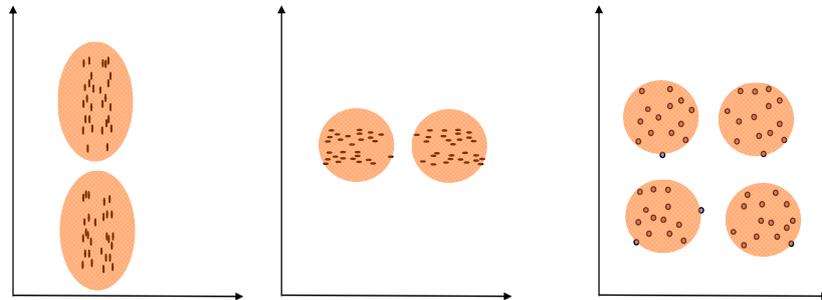
Normalização dos  
dados

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Nomalização

### ■ Efeitos de mudanças de escala



O que é perto do quê ?

## Porquê normalizar

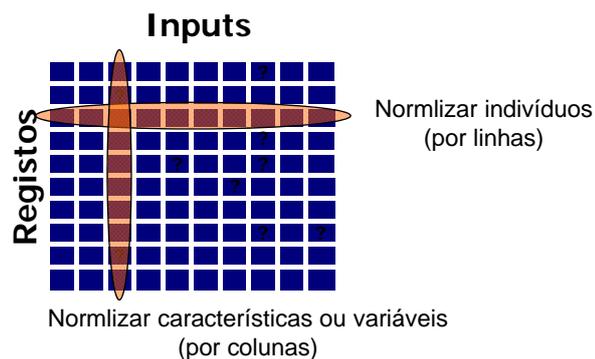
- Para cada variável individual
  - Para não comparar “alhos com bugalhos” !
- Entre variáveis
  - Para que métodos que dependem de distâncias (logo de escala) não fiquem “trancados” numa única característica
  - Para que as diferentes características tenham importâncias proporcionais.

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Porquê normalizar

- Entre indivíduos
  - Para insensibilizar a factores de escala
  - Para identificar “prefis” em vez de valores absolutos



## Objectivos possíveis

- Aproximar a distribuição de uniforme
  - “Espalha” maximamente os dados
- Aproximar a distribuição normal
  - Identifica bem os extremos e deixa que estes sejam muito diferentes
- Ter maior resolução na “zona de interesse”

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Pré-processamento

### ■ Algumas normalizações mais comuns

#### □ Min-Max

- $y' \in [0,1]$

$$y' = \left( \frac{y - \min}{\max - \min} \right)$$

#### □ Z-score

- $y'$  centrado em 0 com  $\sigma=1$

$$y' = \frac{y - \text{média}}{\text{Desvio Padrão}}$$

#### □ Percentis

- Distribuição final sigmoidal

$$y' = n^{\circ} \text{ de ordem}$$

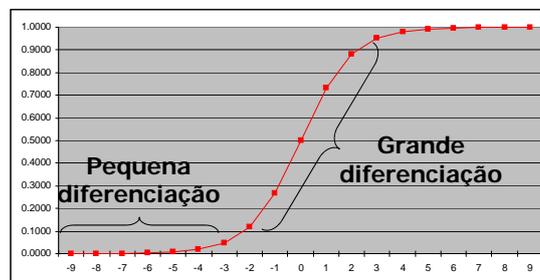
#### □ Sigmoidal (logística)

- $y'$  com maior resoução “no centro”

$$y' = \frac{1 - e^{-y}}{1 + e^{-y}}$$

## Normalização sigmoidal

### ■ Diferencia a “zona de transição”



# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Transformações dos dados

### Projecções sobre espaços visualizáveis ou de dimensão menor

- Ideia geral:
  - Mapear os dados para um espaço de 1 ou 2 dimensões
- Mapear para espaços de 1 dimensão
  - Permite definir uma ordenação
- Mapear para espaços de 2 dimensões
  - Permite visualizar a “distribuição” dos dados (semelhanças, diferenças, clusters)

## Problemas com as projecções

- Perdem informação
  - Podem perder MUITA informação e dar uma imagem errada
- Medidas para saber “o que não estamos a ver”
  - Variância explicada
  - Stress
  - Outros erros (erro de quantização, topológico, etc)

## Dimensão *intrínseca*

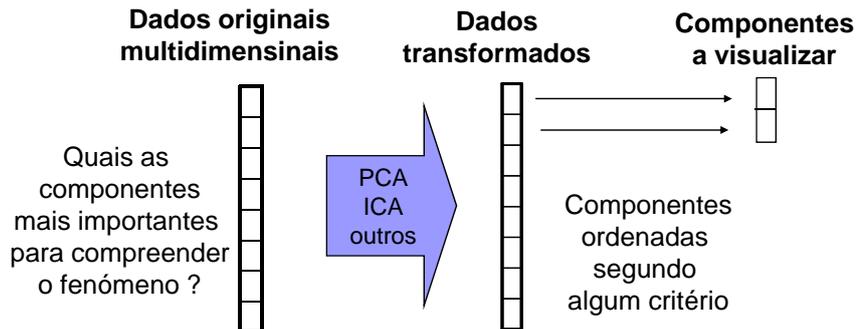
- Dimensão do sub-espaco dos dados
  - Pode ou não haver um mapeamento linear
- Estimativas da dimensão intrínseca
  - Com PCA – Verificar a diminuição dos V.P.
    - Basicamente, medir a variância explicada
  - Com medidas de stress (em MDS)
  - Com medidas de erro

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Seleccionar componentes mais “relevantes” para visualização

- Será sempre uma “boa” escolha ?



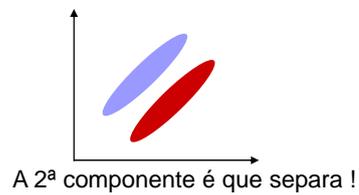
## PCA – Principal Component Analysis

- Principal Component Analysis
  - Análise de componente principais
  - Transformada (discreta) de Karhunen-Loève
  - Transformada linear para o espaço definido pelos **vectores próprios** da matriz de **covariância dos dados**.
    - Não é mais que uma **mudança de coordenadas** (eixos)
    - Eixos ordenados pelos valores próprios
    - Utiliza-se normalmente SVD

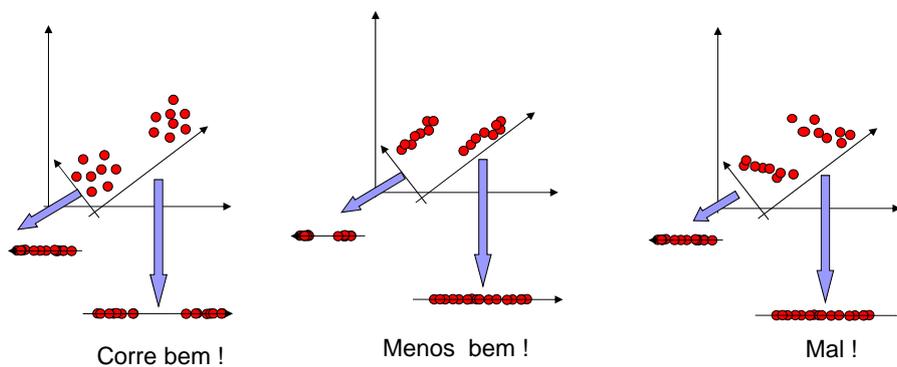
## Componentes principais

### ■ Mudança de eixos

- Os novos eixos estão “alinhados” com as direcções de maior de variação
- Continuam a ser eixos perpendiculares
- Podem “esconder aspectos importantes”

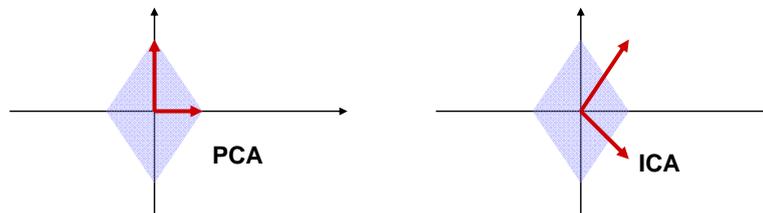


## Problemas com ACP



## Componentes Independentes

- ICA – Independent Component Analysis
  - Maximizam a independência estatística (minimizam a informação mútua)
- Diferenças em relação a PCA



## Componentes Independentes

- Bom comportamento para clustering
  - Muitas vezes melhor que PCA por “espalhar” melhor os dados
- Bom para “blind source separation”
  - Separar causas independentes que se manifestam no mesmo fenómeno
- Disponibilidade
  - Técnica recente... ainda pouco divulgada
  - Boas implementações em Matlab e C
  - Livro de referencia (embora não a ref.original):
    - Hyvärinen, A., J. Karhunen, et al. (2001). Independent Component Analysis, Wiley-Interscience.

## Referências sobre ICA

- Primeiras referências
  - B.Ans, J.Herault, C.Jutten, "Adaptative Neural architectures: Detection of primitives", COGNITIVA'85, Paris, France, 1985
  - P.Comon, "Independant Component Analysis, a new concept ?", Signal Processing, vol36,n3,pp278-283, July 1994
- Algoritmo mais usado. FastICA
  - Hyvärinen, A., J. Karhunen, et al. (2001). Independent Component Analysis, Wiley-Interscience.
  - V.Zarzoso, P.Comon, "How Fast is FastICA?", Proc.European Signal Processing Conf., Florence, Italy, Setember 2006
- Recensão recente
  - A.Kachenoura et al., "ICA: A Potential Tool for BCI Systems", IEEE Signal processing Magazine, vol25, n.1, pp 57-68, January 2008
- Código freeware e material de apoio
  - FastICA para Matlab, R, C++, Python, e muitos apontadores para informação
  - <http://www.cis.hut.fi/projects/ica/fastica/>

## MDS – MultiDimensional Scaling

- Objectivo
  - Representação gráfica a 2D que preserva as distâncias originais entre objectos
- Vários algoritmos (e por vezes nomes diferentes)
  - Sammon Mapping (1968)
  - Também conhecido como Perceptual Mapping
  - É um processo iterativo
  - Não é, rigorosamente, um mapeamento...
- Stress
  - Mede a distorção que não foi possível eliminar

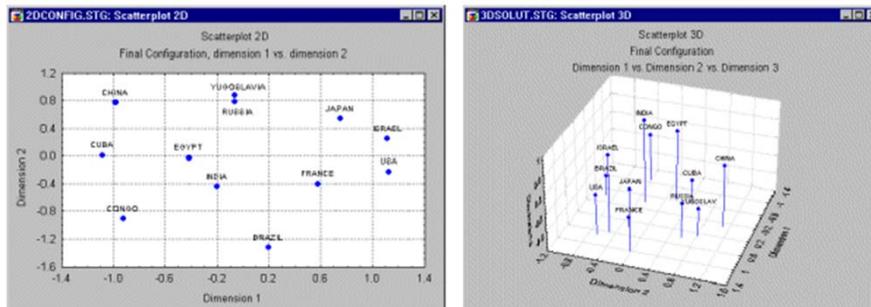
$$Stress = \sqrt{\frac{(d_{ij} - \hat{d}_{ij})^2}{(d_{ij} - \bar{d})^2}}$$

$d_{ij}$  = distância verdadeira  
 $\hat{d}$  = distância no grafico  
 $\bar{d}$  = média das distâncias

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Exemplos de MDS



Exemplo com países do mundo caracterizados por indicadores socio-económicos

### ■ Nota:

- Ao acrescentar mais um dado é necessário recalculá-lo tudo !

## Transformações tempo/frequência

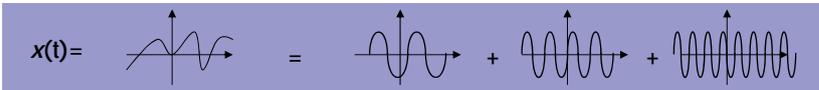
- Transformada de Fourier
  - É uma mudança de referencial !
  - Projecta um espaço sobre outro
- Transformadas tempo/frequência
  - Wavelets
  - Wigner-Ville
  - Identificam a ocorrência (localizada no tempo) de fenómenos que se vêem melhor na frequência...

## Transformada de Fourier

- Aplicações
  - Análise de séries temporais
  - Análise de imagens
  - Análise de dados com dependências “periódicas” entre eles
- Permite:
  - Invariância a “tempo”
  - Invariância a “posição”
- O que é:
  - Um decomposição em senos e cosenos
  - Uma projecção do espaço original sobre um espaço de funções

## Transformada de Fourier

- O que é a “decomposição” ?

$$x(t) = \text{[Complex Wave]} = \text{[Low Freq Wave]} + \text{[Mid Freq Wave]} + \text{[High Freq Wave]}$$


- Com o que é que fico ? Com o que quiser...
  - Com as amplitudes de cada frequência...
  - Com os valores das 2 frequências mais “fortes”...
- Notas:
  - Para não perder informação  $N$ -pontos geram  $N$ -pontos
  - Posso calcular a transformada mesmo que falem valores

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Curvas principais, SOM, etc

- Curvas principais
  - Hastie 1989
  - Define-se parametricamente a família de curvas sobre o qual os dados são projectados
- SOM
  - Kohonen 1982
  - Serão discutidas mais tarde

## Bibliografia

- Sammon, J. W., Jr (1969). "A Nonlinear Mapping for Data Structure Analysis." IEEE Transactions on Computers **C-18**(5)
- Hastie, T. and W. Stuetzle (1989). "Principal curves." Journal of the American Statistical Association **84**(406): 502-516.
- Hyvarinen, A. and E. Oja (2000). "Independant component analysis: algorithms and applications." Neural Networks **13**: 411-430
- Hyvärinen, A., J. Karhunen, et al. (2001). Independent Component Analysis, Wiley-Interscience.

## Outros problemas de pré-processamento

### Eliminar outliers

- Efeito de alavanca dos outliers
- Efeito de “esmagamento” dos outliers
- Eliminar outliers
  - Estatística (baseado em  $\sigma$ )
  - Problema dos “inliers”
  - Métodos “detectores” de outliers
    - Com k-médias
    - Com SOM

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## Conversões entre tipos de dados

- Nominal / Binário
  - 1 bit para cada valor possível
- Ordinal / Numérico
  - Respeitar ou não a escala ?
- Numérico / Ordinal
  - Como discretizar ?

## Outras transformações

- Médias para reduzir ruído
- Ratios para insensibilizar a escala
- Combinar dados
  - É introdução de conhecimento “à priori”

## Quanto pré-processamento ?

- Mais pré-processamento
  - Maior incorporação de conhecimento à priori
  - Mais trabalho inicial, tarefas mais fáceis e fiáveis mais tarde
- Menos pré-processamento
  - Maior esforço mais tarde
  - Maior “pressão” sobre sistema de classificação/ previsão / clustering
  - Princípio: “garbage in – garbage out”

Exemplos de  
problemas

# Introdução ao Datamining

V 1.4, V.Lobo, EN/ISEGI, 2012

## 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?