

# RECONHECIMENTO DE PADRÕES<sub>(MIM)</sub>

Faculdade de Ciências da Universidade do Porto  
Hugo Pedro Proença (DI-UBI), 10/04/2010

# Página da Disciplina



<http://www.di.ubi.pt/~hugomcp/PR>

▣ Slides

▣ Fichas de Exercícios

▣ Conjuntos de Dados

# Objectivos

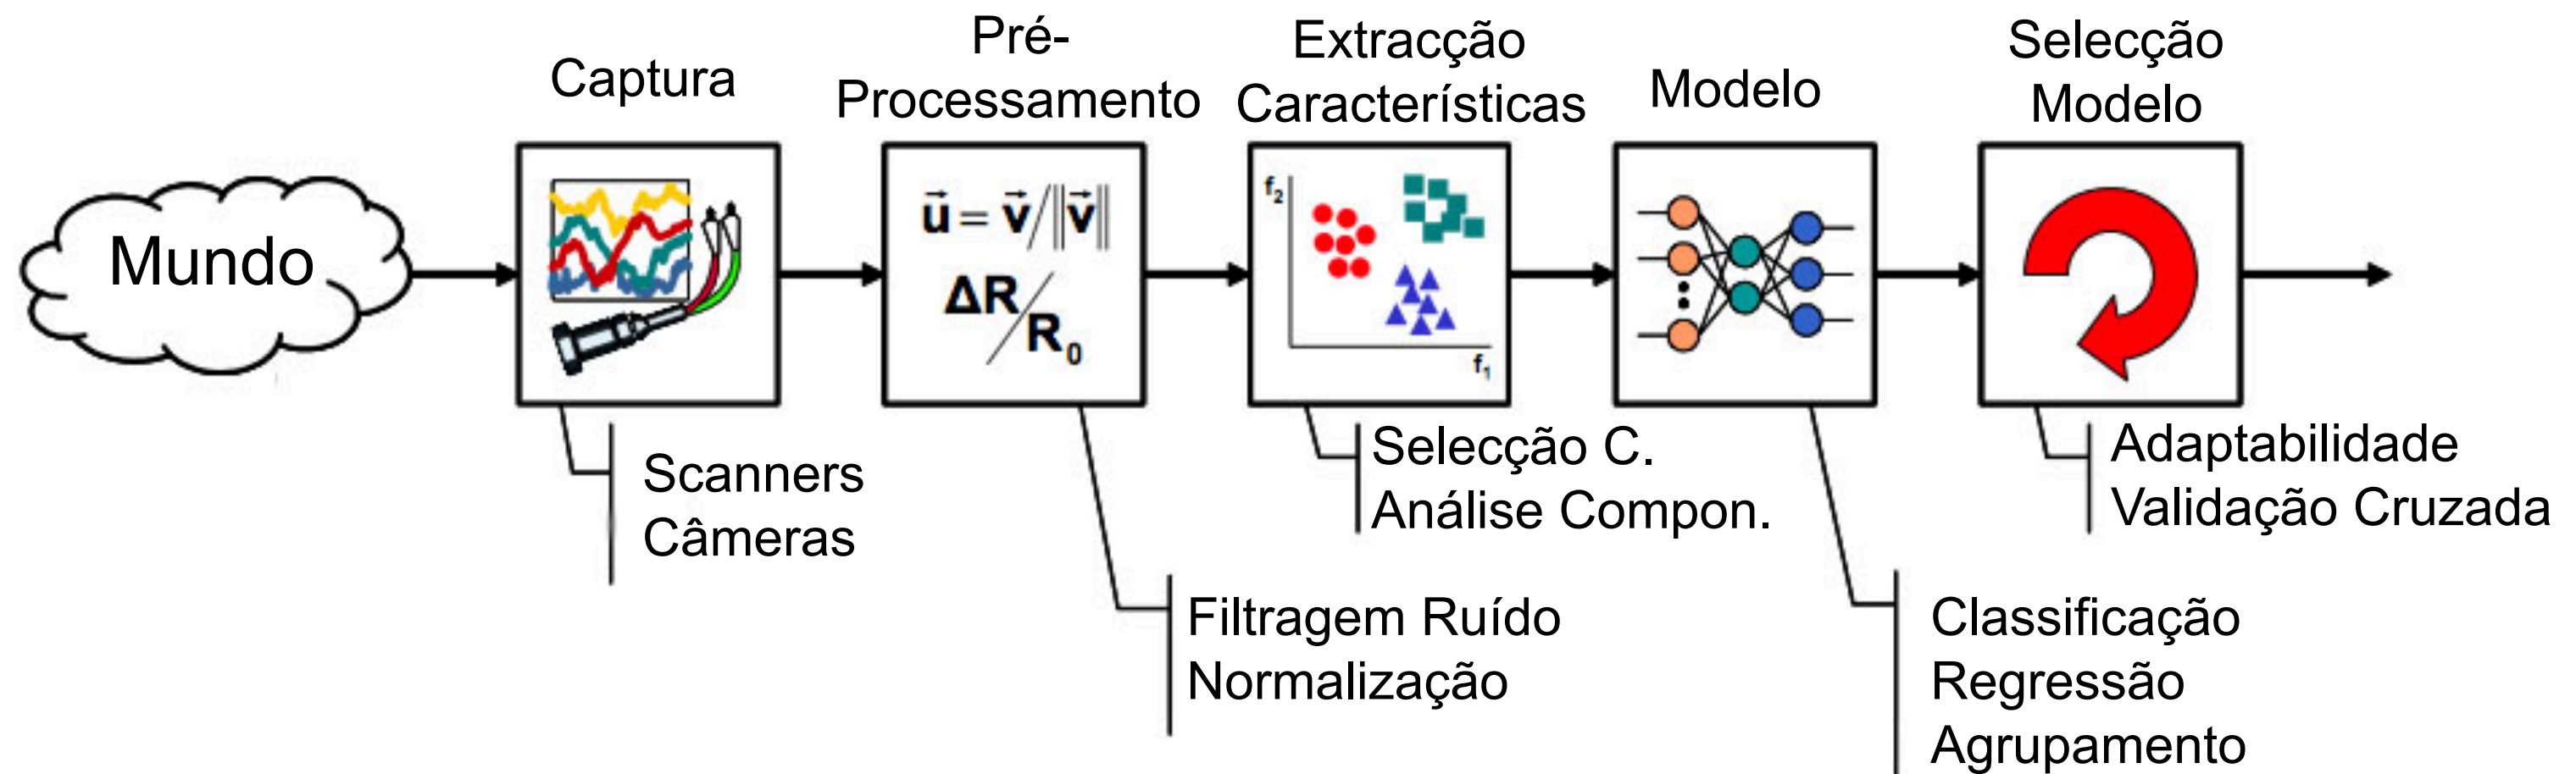


- Este módulo visa a apresentação das noções básicas de um sistema de Reconhecimento de Padrões.
  - Perspectiva de Alto-Nível
  - Definições
  - Estrutura
  - Aplicações
- O ambiente MATLAB (Mathematica) será usado na exemplificação das noções mais importantes.

# Reconhecimento de Padrões

- *“The assignment of a physical object or event to one of several pre-specified categories”* – Duda and Hart
- *“Given some examples of complex signals and the correct decisions for them, make decisions automatically for a stream of future examples”* – Ripley
- *“The science that concerns the description or classification (recognition) of measurements”* – Schalkoff
- *“The process of giving names  $\omega$  to observations  $x$ ”,* – Schürmann
- *“Pattern Recognition is concerned with answering the question “What is this?””* – Morse
- *“The act of taking in raw data and taking an action based on the category of the pattern”* – Duda et al.

# Reconhecimento de Padrões




# Reconhecimento de Padrões



# Características (Features)

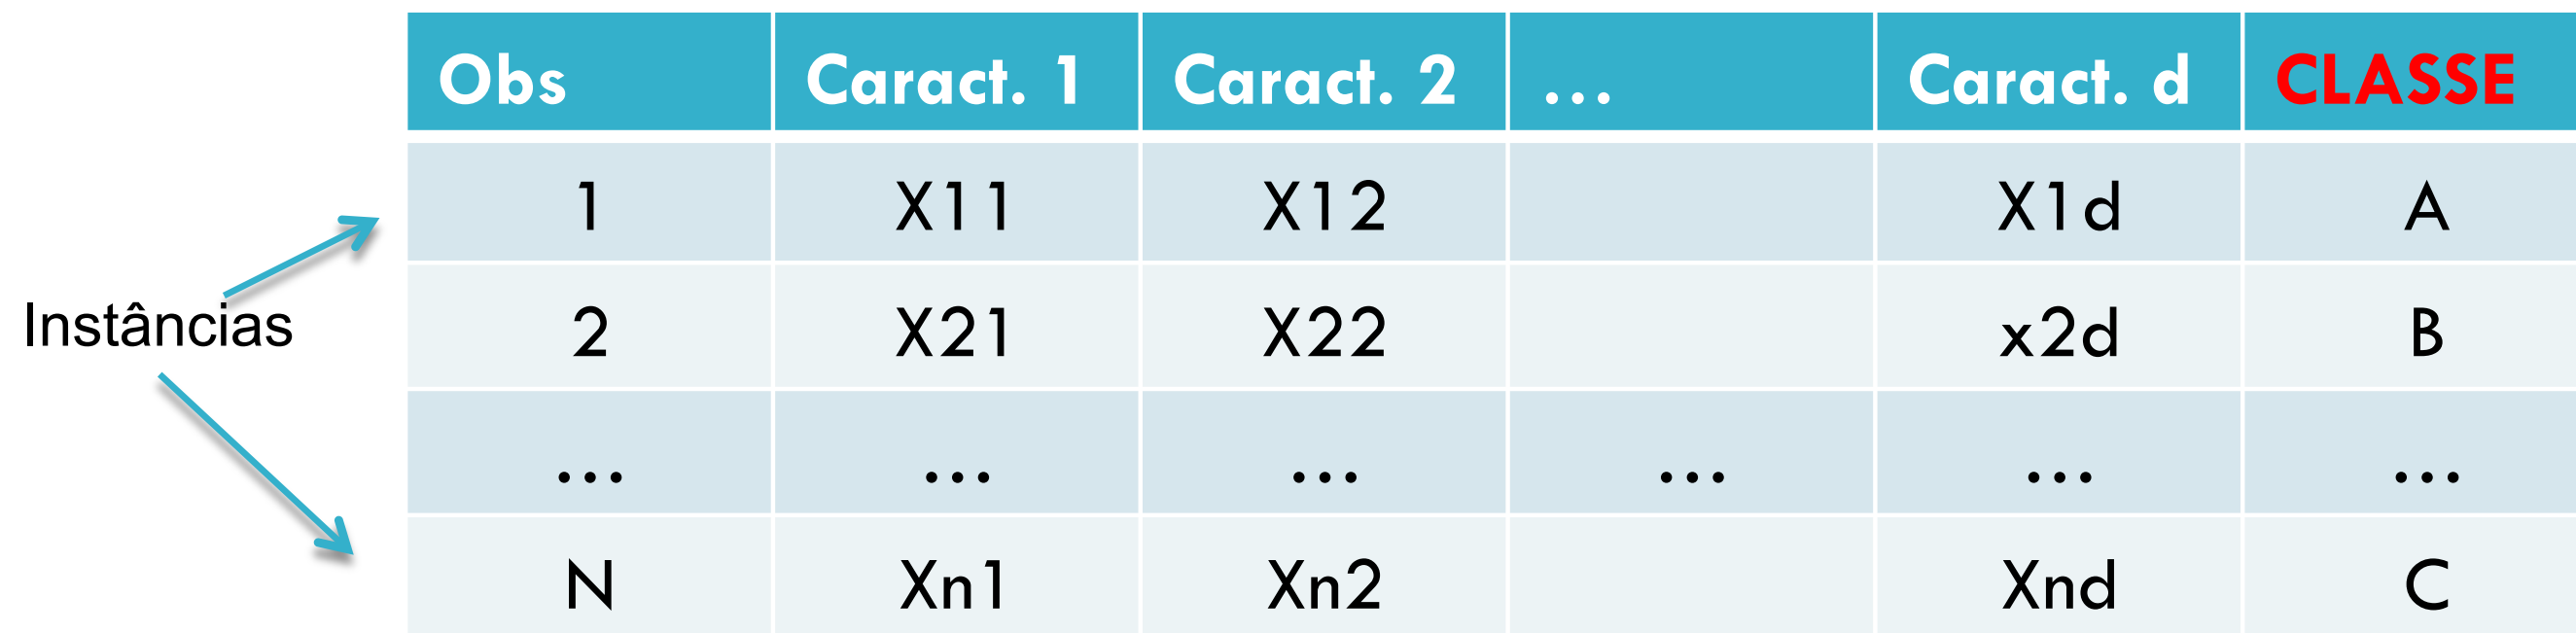
- A noção de **característica (feature)** é a fundamental do reconhecimento de padrões.
  - ▣ Medição (qualitativa ou quantitativa) do objecto de interesse.
- A combinação de “d” características é representada por 1 vector d-dimensional (vector de características).
- O espaço d-dimensional definido pelos vectores de características é chamado o espaço de características.
- Os objectos são representados como pontos no espaço de características.

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_d \end{bmatrix}$$



# Características (Features)

- Em abstracto, um problema de reconhecimento de padrões é representado por uma matriz de dados, com “n” instâncias (observações) e “d” características:



The diagram shows a data matrix with 6 columns and 4 rows. The columns are labeled 'Obs', 'Caract. 1', 'Caract. 2', '...', 'Caract. d', and 'CLASSE'. The rows are labeled '1', '2', '...', and 'N'. The 'CLASSE' column is highlighted in red. A blue arrow labeled 'Instâncias' points to the first three rows of the matrix.


Obs	Caract. 1	Caract. 2	...	Caract. d	<b>CLASSE</b>
1	X11	X12		X1d	A
2	X21	X22		x2d	B
...	...	...	...	...	...
N	Xn1	Xn2		Xnd	C



# Características (Features)

- O que são boas características?
  - ▣ A **qualidade** de um vector de características é dada pela sua capacidade para **discriminar** os exemplos de diferentes classes.
    - Exemplos da mesma classe deverão ter valores semelhantes para cada característica.
    - Exemplos de classes diferentes deverão ter valores evidentemente diferentes.

Boas Características



Más Características



# Características (Features)

- Suponhamos que pretendíamos discriminar entre jogadores de basket (X) e jogadores de xadrez (O).
- Característica “Altura”:



- Característica “Côr dos Olhos”:



# Características (Features)

- As características a extrair para um dado problema são bastantes dependentes do **conhecimento pericial** e determinam em grande medida o sucesso do sistema de reconhecimento de padrões.
  - Quantitativas
    - Contínuas (Exl<sup>o</sup>: peso, altura, temperatura...)
    - Discretas (Exl<sup>o</sup>: n<sup>o</sup> de vértices, total de arestas,...)
  - Qualitativas
    - Exl<sup>o</sup> nível de nublosidade (muito/pouco nublado, limpo)

# Características (Features)

- Para as características qualitativas, é comum atribuir uma etiqueta numérica, sendo posteriormente normalizadas como tal.

Observ.	Nublosidade	Temperatura
1	Pouco nublado	25.2
2	Limpo	27.3
3	Muito Nublado	17.2



Observ.	Nublosidade	Temperatura
1	2	25.2
2	1	27.3
3	3	17.2

# Características (Features)

- Normalmente, diferentes características têm unidades de grandeza muito diferentes e distribuem-se por intervalos heterogêneos.
- O processo de **normalização** consiste em uniformizar esses intervalos, por forma a que o processo de classificação não sofra desvios resultantes de diferentes unidades de grandeza.
  - ▣ **Min-Max:** Passagem para intervalo fixo  $[0,1]$ . Ao maior valor observado atribui-se “1”, ao menor “0”. Os restantes recebem valores de forma linear.
  - ▣ **Média-Variância:** Igual média e variância. Calcula-se a média e variância dos valores observados. Os novos valores são dados pelo valor antigo subtraído da média e dividido pela variância.


# Normalização: Exercício

- Considere a seguinte matriz de dados, referente a uma estatística sobre a produtividade dos empregados de uma empresa de entrevistas. Normalize-a das duas formas diferentes descritas no acetato anterior.

Obs.	Salário	Idade	Peso	Côr Olhos
1	1000	27	75	Castanhos
2	2100	26	86	Verdes
3	750	42	68	Castanhos
4	1562	29	65	Azuis
5	2100	23	56	Castanhos

# Características e Dependência

- De entre o conjunto de características julgadas relevantes para um problema, é comum que algumas delas “variem em conjunto”.
- ▣ Por exemplo, se fizermos a medição do peso e altura de um conjunto de pessoas, será provável que – em média – as pessoas maiores tenham mais peso.



# Características e Dependência

- A matriz de co-variância fornece uma medida da **variação relativa** de cada par de características.
- Uma matriz de dados com “d” características dá origem a uma matriz de co-variância de “d” linhas e “d” colunas.
  - Simétrica em relação à diagonal principal,  $\text{Valor}(x,y)=\text{Valor}(y,x)$

v1	c12	c13	c14	c15
c21	v2	c23	c24	c25
c31	c32	v3	c34	c35
c41	c42	c43	v4	c45
c51	c52	c53	c54	v5



# Características e Dependência

- Para calcular a matriz de co-variância começa-se por calcular o vector de médias (por característica):

$$E[X] = [E[X_1] E[X_2] \dots E[X_N]]^T = [\mu_1 \mu_2 \dots \mu_N] = \mu$$

- A matriz é dada por:

$$\text{COV}[X] = \Sigma = E[(X - \mu)(X - \mu)^T]$$

$$= \begin{bmatrix} E[(x_1 - \mu_1)(x_1 - \mu_1)] & \dots & E[(x_1 - \mu_1)(x_N - \mu_N)] \\ \dots & \dots & \dots \\ E[(x_N - \mu_N)(x_1 - \mu_1)] & \dots & E[(x_N - \mu_N)(x_N - \mu_N)] \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & \dots & c_{1N} \\ \dots & \dots & \dots \\ c_{1N} & \dots & \sigma_N^2 \end{bmatrix}$$

# Características e Dependência

- A matriz de co-variâncias tem propriedades importantes, uma vez que permite inferir padrões nos dados:
  - ▣ Quando  $x(i)$  e  $x(j)$  aumentam/diminuem conjuntamente,  $c(ij) > 0$
  - ▣ Quando  $x(i)$  e  $x(j)$  variam inversamente,  $c(ij) < 0$
  - ▣ Se  $x(i)$  e  $x(j)$  são independentes,  $c(ij) = 0$
  - ▣ Os valores na diagonal principal expressam a variância da característica.



# Classificador Bayesiano

- O Teorema de Bayes é fundamental na variante estatística de reconhecimento de Padrões.
- ▣ Utilizando a noção de probabilidade condicional e o teorema de probabilidade total, o Reverendo Thomas Bayes (1702-1761) propôs como forma de classificação a maximização da probabilidade à-posteriori:



$$P[\omega_j | \mathbf{x}] = \frac{P[\mathbf{x} | \omega_j] \cdot P[\omega_j]}{\sum_{k=1}^N P[\mathbf{x} | \omega_k] \cdot P[\omega_k]} = \frac{P[\mathbf{x} | \omega_j] \cdot P[\omega_j]}{P[\mathbf{x}]}$$

# Classificador Bayesiano

- $P(A | B)$ : Probabilidade condicional. É a probabilidade de ocorrer “A”, sabendo que “B” ocorreu. É dada por:

$$P[A | B] = \frac{P[A \cap B]}{P[B]}$$

- $P(W_i)$ : Probabilidade à-priori.
- $P(W_i | x)$ : Probabilidade à-posteriori. Probabilidade de ocorrer a classe “ $W_i$ ”, para uma dada observação “ $x$ ” (ocorrida).
- $P(x | W_i)$ : Função de (densidade de) probabilidade. Probabilidade de ocorrência de valores de “ $x$ ” na classe “ $W_i$ ”.
- $P(x)$ : Probabilidade de ocorrência de uma observação.

# Classificador Bayesiano

- Assim, um exemplo é classificado na classe “k” se essa classe maximizar as probabilidades à-posteriori, isto é:

$$k = \arg \max_j P[W_j | \mathbf{x}]$$

- Na prática, calculam-se as probabilidades à-posteriori para cada classe e assume-se a classe com maior valor.

# Classificador Bayesiano

- Em termos práticos, o modelo de classificação Bayesiano tem um problema sério: a aproximação das funções de probabilidade  $P(x | W_i)$ .
  - ▣ Mais evidente em problemas de elevada dimensionalidade.
  - ▣ Exigência de conjuntos de dados de dimensões gigantescas, ou mesmo impraticáveis.
  - ▣ Como obter um valor fiável para  $P([x_1, x_2, \dots, x_d] | W_i)$ ?

# Naive-Bayes

- O classificador Naive-Bayes é baseado no teorema Bayesiano e é particularmente útil quando a dimensionalidade do espaço de características é elevada.
- Funciona como uma simplificação (aproximação) ao problema cujo desempenho é comumente comparável aos métodos de classificação mais sofisticados.
- A ideia fundamental é considerar os valores de cada característica ( $x_i$ ) independentes.
  - ▣  $P([x_1, x_2, \dots, x_d] | W_i) = P(x_1 | W_i) \times P(x_2 | W_i) \times \dots \times P(x_d | W_i)$



# Classificador Bayesiano

- Exercício: A partir do seguinte conjunto de dados pretende-se construir 1 sistema de reconhecimento de padrões para auxílio no diagnóstico de gripe:

Training Example	N (running nose)	C (coughing)	R (reddened skin)	F (fever)	Classification
$d_1$	+	+	+	-	positive (ill)
$d_2$	+	+	-	-	positive (ill)
$d_3$	-	-	+	+	positive (ill)
$d_4$	+	-	-	-	negative (healthy)
$d_5$	-	-	-	-	negative (healthy)
$d_6$	-	+	+	-	negative (healthy)


- Qual a classificação dada pelo modelo “Naive-Bayes” para a observação “+ - - +”?

# KNN

- O algoritmo de classificação dos K-vizinhos mais próximos é especialmente simples e intuitivo.
- Classifica 1 exemplo simplesmente de acordo com a sua semelhança em relação ao conjunto de treino.
- Algoritmo:
  - ▣ Seja  $x=[x_1, \dots, x_d]$  o exemplo a classificar.
  - ▣ Encontrar os K-vizinhos mais próximos de “x”, de acordo com uma medida de distância (Euclideana, Mahalanobis, ...)
  - ▣ Atribuir a “x” a classe mais frequente entre os k-vizinhos.

# KNN

- Neste exemplo, seria atribuído ao exemplo “x” a classe ( $\omega_1$ ), uma vez que está em maioria entre os seus vizinhos mais próximos.




# Aplicação Prática

- Suponhamos que um sistema de automático de captura de imagem regista caracteres manuscritos.
  - ▣ Para simplificar, caracteres numéricos [0,9]
- Pretendemos desenvolver um sistema de reconhecimento de padrões que seja capaz de “entender” essa informação.
  - ▣ Não homogénea, irregular.

9  
6  
∅  
4  
5

# Aplicação Prática

- O ambiente *MATLAB* facilita de sobremaneira a interacção “programador (utilizador)  $\leftrightarrow$  máquina”.
  - ▣ Linguagem de programação de alto (altíssimo) nível.
  - ▣ Conjunto de funções (*toolboxes*) disponíveis.
  - ▣ Linguagem interpretada. Código-fonte das funções disponível.
  - ▣ Vasta comunidade de utilizadores
    - Google, ...
- *Mathematica*, *R* funcionam como alternativas menos dispendiosas.



# Aplicação Prática

- As diferentes imagem de caracteres (30x20) foram previamente gravadas numa matriz binária com dimensões 90.000 (300x30x10) x 20.
  - ▣ Linha 1:30 (1º caract), 31:100 (2º caract)...
- Passo 1: Leitura da Matriz
  - ▣ `>> Dados=load('OCRDataSet.txt');`
- Passo 2: Função para aceder individualmente a cada caracter (30x20)

# Aplicação Prática

```
% x=y(a:b,c:d)
```

%Acesso a matrizes

Desde a coluna "c" até "d"

Desde a linha "a" até "b"

Retorno

Parâmetros

```
Function ret=getImagem(Matriz, indice)
```

```
ret= Matriz((indice-1)*30+1:indice*30,1:end);
```