

## Problema 1

Considere o conjunto de dados da tabela, em que  $y$  representa a classe de saída, e  $a_k$  os atributos discretos.

$a_1$	$a_2$	$a_3$	$y$
Z	B	2	0
Z	X	1	0
A	B	2	1
A	B	2	1
A	X	2	0
A	X	2	0
Z	B	1	0
Z	X	2	1

Derive a árvore de classificação para este problema utilizando o algoritmo ID3. Apresente todos os cálculos e determine a percentagem de erros de classificação para a árvore obtida.

## Problema 2

Considere o seguinte conjunto de dados em  $\mathbb{R}^2$

$$\mathcal{T} = \{(-5, -5), (5, 5), (-1, 1), (1, -1)\}$$

- a) Determine os valores próprios e as direcções principais destes dados.
- b) Admita que pretende efectuar uma projecção dos dados  $\mathcal{T}$  em  $\mathbb{R}^1$  de forma a que, a partir desta projecção, seja possível recuperar os dados originais segundo um critério de erro quadrático mínimo (problema de compressão de dados). Como sabe, este resultado pode ser obtido determinando a primeira componente principal dos dados  $\mathcal{T}$ .
  - i) Determine o valor da primeira componente principal relativa a cada uma das observações de  $\mathcal{T}$ .
  - ii) Determine a reconstrução óptima das observações originais a partir das projecções determinadas em i).
  - iii) Indique qual a variância do erro de reconstrução.

### **Problema 3**

Admita que tem um conjunto  $X$  de padrões (vectors de dimensão  $n$ ) cuja densidade de probabilidade  $p(\mathbf{x})$  pretende estimar.

Indique como poderia utilizar uma rede neuronal para estimar esta densidade de probabilidade.

## Problema 4

Em problemas de Aprendizagem Automática é frequente a utilização de métricas euclidianas. O quadrado da distância entre dois pontos é definido por

$$D^2(\mathbf{x}_1, \mathbf{x}_2) = (\mathbf{x}_1 - \mathbf{x}_2)^T (\mathbf{x}_1 - \mathbf{x}_2)$$

No entanto, outras distâncias são frequentemente utilizadas na prática. Uma família que observa as propriedades associadas a métricas e que inclui a distância euclidiana como caso particular é aquela em que o quadrado da distância entre dois pontos é definido por

$$D^2(\mathbf{x}_1, \mathbf{x}_2) = (\mathbf{x}_1 - \mathbf{x}_2)^T \mathbf{G} (\mathbf{x}_1 - \mathbf{x}_2) \quad (1)$$

onde  $\mathbf{G}$  é uma matriz simétrica definida positiva.

Pode mostrar-se que usar a distância definida com a métrica (1) é equivalente a realizar uma transformação linear dos vectores de entrada  $\mathbf{x}$  e calcular a distância euclidiana no espaço transformado. A transformação que conduz a este resultado é definida por  $\mathbf{y} = \mathbf{A}\mathbf{x}$ , com  $\mathbf{A}\mathbf{A} = \mathbf{G}$ . Note que se  $\mathbf{G}$  for simétrica definida positiva, existe sempre uma matriz  $\mathbf{A}$ , igualmente simétrica definida positiva, tal que  $\mathbf{G} = \mathbf{A}\mathbf{A}$  (por este motivo, utiliza-se frequentemente a notação  $\mathbf{A} = \mathbf{G}^{1/2}$ ).

- a) Em aplicações práticas, pode ser útil escolher  $\mathbf{G}$  de acordo com a estrutura dos dados de entrada. Um caso particular corresponde à chamada distância de Mahalanobis, onde a matriz  $G$  é definida pela inversa da matriz de covariância dos dados de entrada, ou seja,  $G = \mathbf{R}_{xx}^{-1}$ , com

$$\mathbf{R}_{xx} = E[(\mathbf{x} - \bar{\mathbf{x}})(\mathbf{x} - \bar{\mathbf{x}})^T]$$

onde  $E[\ ]$  representa a média estatística e  $\bar{\mathbf{x}} = E[\mathbf{x}]$ .

Determine a expressão da matriz de covariância dos dados após a transformação linear  $\mathbf{A}$  no caso particular da distância de Mahalanobis.

b) Considere um conjunto de treino num espaço bidimensional, constituído por quatro padrões:

$$\mathcal{T} = \{(-10, 1), (-10, -1), (10, 1), (10, -1)\}$$

- i) Indique a melhor partição do espaço em dois agrupamentos que seria possível obter com o algoritmo k-médias, admitindo que é utilizada uma distância euclidiana. Justifique a sua resposta sem realizar cálculos.
- ii) Embora a distância de Mahalanobis seja frequentemente vantajosa, no caso particular que se está a considerar a sua utilização não permitiria definir qual a partição óptima dos dados. Justifique.

## Problema 5

Considere o seguinte conjunto de dados unidimensionais:

$$\mathcal{T} = \{-4, -3, 0, 1\}$$

Admita que se pretende aplicar o algoritmo EM com duas gaussianas a estes dados. Admita que a estimativa da fdp é inicializada com

$$p(x) = \pi_0 p_1(x) + \pi_1 p_2(x)$$

sendo:

$$\pi_0 = \pi_1 = 0,5$$

$$p_1(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x+4)^2}{2}\right)$$

$$p_2(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x-1)^2}{2}\right)$$

Indique qual a estimativa da fdp que seria obtida após uma iteração do algoritmo EM.