

# MAE 0580/MAC 6926 - 1ª Prova (Turma A)

13 de setembro 2017

Esta é uma prova individual, sem consulta. Em cada questão uma e só uma opção é correta. A nota da prova será calculada pela fórmula  $\text{Nota} = \max\{0, C - E/3\}$ . Nesta expressão,  $C$  é o número de respostas certas e  $E$ , o número de respostas erradas. Questões deixadas em branco e respostas rasuradas *não serão consideradas* no cálculo da nota.

## Notações e definições básicas

Seja  $(X, Y) \in \mathcal{X} \times \{0, 1\}$  um par de variáveis aleatórias distribuídas de acordo com uma distribuição desconhecida  $P$ . Observamos uma sequência  $(X_i, Y_i)_{i=1, \dots, n}$  de pares i.i.d. tendo a mesma distribuição de  $(X, Y)$ . O objetivo é construir uma função de classificação  $g: \mathcal{X} \rightarrow \{0, 1\}$ , tal que  $g(X)$  esteja probabilisticamente próximo de  $Y$ .

O *risco* de  $g$  é definido como,

$$R(g) = \mathbb{P}(g(X) \neq Y).$$

O *risco empírico* de  $g$  calculado a partir de uma amostra é definido como,

$$R_n(g) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{g(X_i) \neq Y_i\}}.$$

Seja  $\eta(x) = \mathbb{P}(Y = 1 | X = x)$ . O classificador de Bayes é definido como

$$f^*(x) = \mathbb{1}_{\{\eta(x) \geq 1/2\}}.$$

**Desigualdade de Chebyshev:** Seja  $(Z_k)_{k \geq 1}$  uma sequência de variáveis aleatórias i.i.d assumindo valores em  $\{0, 1\}$ , tal que  $\mathbb{P}(Z_k = 1) = p$ , para todo  $k$ . A desigualdade de Chebyshev é dada por

$$\mathbb{P}\left(\left|\frac{1}{n} \sum_{k=1}^n Z_k - p\right| > \epsilon\right) \leq \frac{1}{4n\epsilon^2}$$

**Desigualdade de Hoeffding:** Seja  $(Z_k)_{k \geq 1}$  uma sequência de variáveis aleatórias i.i.d assumindo valores em  $\{0, 1\}$ , tal que  $\mathbb{P}(Z_k = 1) = p$ , para todo  $k$ . A desigualdade de Hoeffding é dada por

$$\mathbb{P}\left(\left|\frac{1}{n} \sum_{k=1}^n Z_k - p\right| > \epsilon\right) \leq 2 \exp(-2n\epsilon^2)$$

Dado um alfabeto finito  $A$ , para todo  $k \geq 1$ , definimos  $\mathcal{M}_k(A)$  da seguinte maneira

$$\mathcal{M}_k(A) = \{p: A^k \times A \rightarrow [0, 1] : \forall a_{-k}^{-1} \in A^k, \sum_{b \in A} p(b | a_{-k}^{-1}) = 1\}.$$

Dado  $n \geq 0, k \geq 0$  e dada uma amostra  $X_{-k}, \dots, X_n$  e uma sequência  $a_{-k}^0 \in A^{k+1}$ , definimos a função de contagem

$$N_{0:n}(a_{-k}^0) = \sum_{t=0}^n \mathbb{1}_{\{X_{t-k}^t = a_{-k}^0\}}.$$

O passado nas probabilidades de transição é indicado do símbolo mais recente ao símbolo mais remoto:

$$p(b | a_{-1}, \dots, a_{-k}) = p(b | a_{-k}^{-1}) = \mathbb{P}\{X_0 = b | X_{-k}^{-1} = a_{-k}^{-1}\}, \text{ para } b \in A \text{ e } a_{-k}^{-1} = (a_{-k}, \dots, a_{-1}) \in A^k.$$

Dada uma amostra  $X_{-k}, \dots, X_n$  de símbolos no alfabeto  $A$ , gerada por uma cadeia de Markov de alcance  $k$ , definimos

$$\hat{\mathbb{P}}_k(X_0^n | X_{-k}^{-1}) = \prod_{a_{-1}^{-k} \in A^k} \prod_{b \in A} \hat{p}_n(b | a_{-1}^{-k})^{N_{0:n}(a_{-1}^{-k} b)},$$

onde  $\hat{p}_n(b | a_{-1}^{-k}) = \frac{N_{0:n}(a_{-1}^{-k} b)}{\sum_{z \in A} N_{0:n}(a_{-1}^{-k} z)}$  é o estimador de máxima verossimilhança em  $\mathcal{M}_k(A)$ .

1. Seja  $X = (X(1), X(2), X(3))$  uma variável aleatória que toma valores em  $\mathcal{X} = \{0, 1\}^3$ , isto é  $\mathcal{X}$  é o conjunto de todas as sequências ordenadas com três elementos, assumindo os valores 0 ou 1. Seja  $Y \in \{0, 1\}$  uma variável de classificação assim definida:  $Y = X(1)$ . Definimos a função de classificação  $g : \mathcal{X} \rightarrow \{0, 1\}$  da seguinte maneira

$$g(x) = \mathbb{1}_{\left\{\frac{x(1)}{2} + \frac{x(2)}{4} + \frac{x(3)}{8} \geq 0.75\right\}}.$$

Assumindo que  $\mathbb{P}(X = x) = \left(\frac{1}{2}\right)^3$ , para todo  $x \in \mathcal{X}$ , diga qual das afirmações abaixo é verdadeira:

- $R(g) = 0.5$
  - $R(g) = 0.25$
  - $R(g) = 0.75$
  - Nenhuma das respostas anteriores.
2. Seja  $X \in \mathcal{X} = [0, 1]$  uma variável aleatória e seja  $Y \in \{0, 1\}$  uma variável de classificação assim definida

$$Y = Z\mathbb{1}_{\{X \geq 1/2\}} + (1 - Z)\mathbb{1}_{\{X < 1/2\}},$$

onde  $Z$  é uma variável aleatória com valores em  $\{0, 1\}$ , independente de  $X$  e tal que  $\mathbb{P}(Z = 1) = 0.9$ . Queremos calcular o classificador de Bayes para o par  $(X, Y)$ . Diga qual das afirmações abaixo é verdadeira:

- $f^*(x) = \mathbb{1}_{\{x \geq 0.9\}}$
  - $f^*(x) = \mathbb{1}_{\{x \geq 0.5\}}$
  - $f^*(x) = \mathbb{1}_{\{x \geq 0.1\}}$
  - Nenhuma das respostas anteriores.
3. Seja  $(X_1, Y_1), \dots, (X_{10}, Y_{10})$ , com  $(X_i, Y_i) \in [0, 1] \times \{0, 1\}$  uma sequência de variáveis aleatórias. Seja  $g : [0, 1] \rightarrow \{0, 1\}$  uma função definida por  $g(x) = \mathbb{1}_{\{|x - \frac{1}{2}| \leq 0.2\}}$ . Dado uma amostra

$$\begin{aligned} X_1 &= 0.4, & Y_1 &= 0 \\ X_2 &= 0.1, & Y_2 &= 0 \\ X_3 &= 0.7, & Y_3 &= 1 \\ X_4 &= 0.3, & Y_4 &= 1 \\ X_5 &= 0.2, & Y_5 &= 0 \\ X_6 &= 0.8, & Y_6 &= 0 \\ X_7 &= 0.3, & Y_7 &= 1 \\ X_8 &= 0.9, & Y_8 &= 0 \\ X_9 &= 0.2, & Y_9 &= 1 \\ X_{10} &= 0.5, & Y_{10} &= 1, \end{aligned}$$

diga qual das seguintes afirmações é verdadeira

- $R_n(g) = 2/10$
  - $R_n(g) = 1/10$
  - $R_n(g) = 5/10$
  - Nenhuma das respostas anteriores.
4. Seja  $(X_i, Y_i)_{i=1, \dots, n}$  uma sequência de variáveis aleatórias i.i.d com  $X_i \in \mathcal{X}$  e  $Y_i \in \{0, 1\}$ , e seja  $g(x) = \mathbb{1}_{\{x \geq p\}}$ , com  $p \in [0, 1]$  fixado. Usando a desigualdade de Hoeffding queremos obter uma majoração para

$$\mathbb{P}(|R_n(g) - R(g)| > 0.01).$$

Diga qual das seguintes afirmações é verdadeira (use, se necessário, que  $\ln(0.005) = -5.2983$  e  $\ln(0.025) = -3.6889$ )

- $\mathbb{P}(|R_n(g) - R(g)| > 0.01) \leq 0.01, \quad \forall n \geq 30000$
- $\mathbb{P}(|R_n(g) - R(g)| > 0.01) \leq 0.05, \quad \forall n \geq 15000$
- $\mathbb{P}(|R_n(g) - R(g)| > 0.01) \geq 0.01, \quad \forall n \geq 30000$

- d) Nenhuma das respostas anteriores.
5. Seja  $(X_i, Y_i)_{i=1, \dots, n}$  uma sequência de variáveis aleatórias i.i.d com  $X_i \in \mathcal{X}$  e  $Y_i \in \{0, 1\}$ , e seja  $g(x) = \mathbb{1}_{\{x \geq p\}}$ , com  $p \in [0, 1]$  fixado. Fixamos  $\epsilon \in [0, 1/2]$  e queremos obter uma majoração para  $\mathbb{P}(|R_n(g) - R(g)| > \epsilon)$ . Sejam  $\delta_c(n, \epsilon)$  e  $\delta_h(n, \epsilon)$  as majorações fornecidas pelas desigualdades de Chebyshev e Hoeffding respectivamente. Diga qual das seguintes afirmações é verdadeira
- $\lim_{n \rightarrow \infty} \frac{\delta_c(n, \epsilon)}{\delta_h(n, \epsilon)} = +\infty$
  - $\lim_{n \rightarrow \infty} \frac{\delta_c(n, \epsilon)}{\delta_h(n, \epsilon)} = 0$
  - $\lim_{n \rightarrow \infty} \frac{\delta_c(n, \epsilon)}{\delta_h(n, \epsilon)} = 1$
  - Nenhuma das respostas anteriores.
6. Seja  $(X_n)_{n \in \mathbb{Z}}$  uma cadeia de Markov de alcance 1 assumindo valores em  $A = \{0, 1\}$ . Diga qual é o maior valor que  $\mathbb{P}(X_0^{10} = (0, 1, 1, 0, 1, 0, 0, 0, 1, 0, 0) | X_{-1} = 0)$  pode assumir
- $(1/2)^{11}$
  - $(1/2)^5 (3/4)^3 (1/4)^3$
  - $(4/7)^4 (3/7)^3 (3/4)^3 (1/4)$
  - Nenhuma das respostas anteriores.
7. Seja  $(X_n)_{n \in \mathbb{Z}}$  uma cadeia com memória de alcance variável, assumindo valores no alfabeto  $A = \{0, 1\}$ , tendo como árvore de contextos  $\tau = \{\{X_{-1} = 0\}, \{X_{-2} = 0, X_{-1} = 1\}, \{X_{-2} = 1, X_{-1} = 1\}\}$  e tendo família associada de probabilidades de transição definida por

$$p(1|0) = \alpha, \quad p(1|11) = \beta, \quad p(1|10) = \gamma,$$

onde  $\alpha, \beta, \gamma$  são três parâmetros pertencentes ao intervalo aberto  $(0, 1)$ . Dada uma amostra  $X_0^{12} = (0, 1, 1, 1, 0, 0, 0, 1, 0, 1, 1, 1, 1)$  gerada por esta cadeia, diga qual das seguintes afirmações é correta:

- $\mathbb{P}(X_0^{12} = 0, 1, 1, 1, 0, 0, 0, 1, 0, 1, 1, 1, 1 | X_{-1} = 0) = \alpha^3 (1 - \alpha)^3 \beta^3 (1 - \beta) \gamma^2 (1 - \gamma)$
  - $\mathbb{P}(X_0^{12} = 0, 1, 1, 1, 0, 0, 0, 1, 0, 1, 1, 1, 1 | X_{-1} = 0) = \alpha^3 (1 - \alpha)^3 \beta (1 - \beta)^3 \gamma (1 - \gamma)^2$
  - $\mathbb{P}(X_0^{12} = 0, 1, 1, 1, 0, 0, 0, 1, 0, 1, 1, 1, 1 | X_{-1} = 0) = (\alpha \beta \gamma)^{13}$
  - Nenhuma das respostas anteriores.
8. Dado  $A = \{1, 2, 3\}$ , seja  $p \in \mathcal{M}_1(A)$  assim definida:

$$\begin{array}{c} \begin{array}{ccc} & 1 & 2 & 3 \\ \begin{array}{c} 1 \\ 2 \\ 3 \end{array} & \begin{pmatrix} 1/4 & 1/2 & 1/4 \\ 1/3 & 1/3 & 1/3 \\ 1/4 & 1/4 & 1/2 \end{pmatrix} \end{array} \end{array}.$$

Queremos simular uma cadeia de Markov  $(X_n)_{n \geq 0}$ , tendo essa matriz de probabilidades de transição, usando o seguinte algoritmo:

*Passo 1.* Escolho  $X_0$ ;

*Passo 2.* Para  $n \geq 1$ , definimos  $X_n = F(X_{n-1}, U_n)$ , onde  $(U_n)_{n \geq 1}$  é uma sequência de variáveis aleatórias i.i.d com distribuição uniforme em  $[0, 1]$  e  $F(x, u)$  é uma função definida por:

$$F(x, u) = \begin{cases} 1, & \text{se } 0 \leq u < h_1(x) \\ 2, & \text{se } h_1(x) \leq u < h_2(x) \\ 3, & \text{se } h_2(x) \leq u \leq 1. \end{cases}$$

Diga qual das linhas abaixo, definindo  $h_1(3)$  e  $h_2(3)$ , está correta:

- $h_1(3) = 1/3, h_2(3) = 2/3$
- $h_1(3) = 1/4, h_2(3) = 3/4$
- $h_1(3) = 1/4, h_2(3) = 1/2$
- Nenhuma das respostas anteriores.