

MAE 0580/ MAC 6926 - Lista 3

4 de outubro de 2017

Notações e definições básicas

Neste resumo $(X_n)_{n \geq -k}$ é uma cadeia com memória de alcance variável gerada por (τ, p) , sendo τ uma árvore de altura k . Denotamos por $c_\tau(X_{-k}^n)$ o contexto de τ associado à sequência X_{-k}, \dots, X_n .

Dado $n \geq 1$ e dada uma amostra X_{-k}, \dots, X_n , definimos a função de contagem

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

para toda sequência $a_{-k}^0 \in A^{k+1}$.

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 com árvore de contextos τ , com altura de τ igual a k , definimos

$$\hat{\mathbb{P}}_\tau(X_0^n | X_{-k}^{-1}) = \prod_{\omega \in \tau} \prod_{a \in A} \hat{p}_n(a|\omega)^{N_{0:n}(\omega a)},$$

onde $\hat{p}_n(a|\omega) = \frac{N_{0:n}(\omega a)}{N_{0:n-1}(\omega)}$ é o estimador de máxima verossimilhança da matriz de probabilidades de transição dado τ .

Definimos o estimador

$$\tilde{p}_n(a|w) = \frac{1}{n} \sum_{k=1}^n \mathbf{1}_{\{X_{k-w+1}^k = a\}}.$$

Desigualdade de Hoeffding para variáveis aleatórias binárias e i.i.d.: Sejam Y_1, Y_2, \dots assumindo valores no alfabeto $\{0, 1\}$ com $\mathbb{P}(Y_n = 1) = p$. Então para todo $\delta > 0$,

$$\mathbb{P}\left(\sum_{i=1}^n Y_i > n(p + \delta)\right) \leq \exp\{-2n\delta^2\}$$

Algoritmo Contexto:

Dada uma amostra $X_{-k}^n = (X_{-k}, \dots, X_n)$ de símbolos do alfabeto finito, definimos para toda sequência $w = w_{-k}^{-1} \in A^k$, com $1 < k < n$, a seguinte quantidade

$$\Delta_n(w_{-k}^{-1}) = \max_{a, b \in A} \left| \hat{p}_n(a|w_{-(k-1)}^{-1}) - \hat{p}_n(a|w_{-(k-1)}^{-1}b) \right|.$$

Fixado $\delta \in (0, 1)$, se $\Delta_n(w_{-k}^{-1}) < \delta$, então podemos os símbolos mais remotos (representados pela letra b) das sequências $\{bw_{-(k-1)}^{-1} : b \in A\}$. Caso contrário, mantemos as sequências $\{bw_{-(k-1)}^{-1} : b \in A\}$.

1. Seja $(\xi_n)_{n \geq 1}$ uma sequência de variáveis aleatórias independentes e identicamente distribuídas, assumindo valores no conjunto $A = \{0, 1\}$, com

$$\mathbb{P}(\xi_n = 1) = p.$$

Diga qual das afirmativas abaixo é verdadeira.

(a) $\mathbb{E}\left(2^{\sum_{m=1}^n \xi_m}\right) = (p+1)^n$

- (b) $\mathbb{E} \left(2^{\sum_{m=1}^n \xi_m} \right) = 2^{n(p+1)}$
(c) $\mathbb{E} \left(2^{\sum_{m=1}^n \xi_m} \right) = (1/2)^n$
(d) Nenhuma das respostas anteriores.

2. Seja $(X_n)_{n \geq 1}$ uma seqüência de variáveis aleatórias iid, assumindo valores no alfabeto $A = \{0, 1\}$, tal que $\mathbb{P}(X_n = 1) = p$, onde $0 < p < 1$. Usando a desigualdade de Hoeffding, diga qual das seguintes afirmações é verdadeira (use, se necessário, que $\log(0.01) = -4.6$, $\log(0.05) = -3$ e $\log(0.02) = -3.91$)

- (a) $\mathbb{P} \left(\frac{1}{n} \sum_{i=1}^n X_i - p > 0.02 \right) \leq 0.01, \forall n \geq 5.000$
(b) $\mathbb{P} \left(\frac{1}{n} \sum_{i=1}^n X_i - p > 0.02 \right) \leq 0.05, \forall n \geq 4.000$
(c) $\mathbb{P} \left(\frac{1}{n} \sum_{i=1}^n X_i - p > 0.02 \right) \geq 0.02, \forall n \geq 3.000$
(d) Nenhuma das respostas anteriores.

3. Dada a amostra $(0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 1, 1, 0, 0, 0, 1)$, diga qual é a árvore de contextos $\hat{\tau}$ de altura menor ou igual a 2, obtida aplicando o Algoritmo Contexto, utilizando $\delta = 0.05$ no critério de poda.

- (a) $\hat{\tau} = \{1, 0\}$
(b) $\hat{\tau} = \{1, 00, 10\}$
(c) $\hat{\tau} = \{0, 11, 01\}$
(d) Nenhuma das respostas anteriores.

4. Seja X_0^n uma amostra gerada por uma cadeia de alcance variável assumindo valores no alfabeto $A = \{0, 1\}$. Sob a hipótese nula

H_0 : A seqüência 00 é um contexto e $p(\cdot | 00)$ é a probabilidade de transição associada a esse contexto,

e, fixado $\delta > 0$, assinale a alternativa correta:

- (a) $\mathbb{P}(|\hat{p}_n(1|00) - \hat{p}_n(1|000)| > \delta) \leq \mathbb{P}(|\hat{p}_n(1|00) - p(1|00)| > \frac{\delta}{2}) + \mathbb{P}(|\hat{p}_n(1|000) - p(1|000)| > \frac{\delta}{2})$
(b) $\mathbb{P}(|\hat{p}_n(1|00) - \hat{p}_n(1|000)| > \delta) \leq \mathbb{P}(|\hat{p}_n(1|00) - p(1|00)| > \frac{\delta}{2}) + \mathbb{P}(|\hat{p}_n(1|0) - p(1|0)| > \frac{\delta}{2})$
(c) $\mathbb{P}(|\hat{p}_n(1|00) - \hat{p}_n(1|000)| > \delta) > \mathbb{P}(|\hat{p}_n(1|0) - p(1|0)| > \frac{\delta}{2})$
(d) Nenhuma das respostas anteriores.

5. Dada uma amostra X_{-k}, \dots, X_n de símbolos do alfabeto $A = \{0, 1\}$, diga qual das seguintes afirmações é verdadeira:

- (a) $N_{0:n}(0^k 0) + N_{0:n}(0^k 1) = N_{0:n-1}(0^k)$
(b) $N_{0:n}(0^k 0) = N_{0:n}(0^k 1)$
(c) $N_{0:n}(0^k 0) + N_{0:n}(0^k 1) = N_{0:n+1}(0^k)$
(d) Nenhuma das respostas anteriores.

6. Seja $(X_n)_{n \geq 0}$ uma cadeia com memória de alcance variável assumindo valores no alfabeto $A = \{0, 1\}$. Seja $X_{-2}^1 = 00111000101111$ uma amostra gerada por essa cadeia. Aplicando o Algoritmo Contexto, obtemos $\hat{\tau} = \{1, 00, 10\}$. Para obter tal resultado, o valor de δ utilizado foi:

- (a) $\delta = 0.05$
- (b) $\delta = 0.03$
- (c) $\delta = 0.01$
- (d) Nenhuma das respostas anteriores.

7. Seja $(X_n)_{n \geq -1}$ uma cadeia com memória de alcance variável assumindo valores em $A = \{0, 1\}$ tendo como árvore de contextos

$$\tau = \{\{X_{-1} = 1\}, \{X_{-2} = 1, X_{-1} = 0\}, \{X_{-2} = 0, X_{-1} = 0\}\}$$

e família de probabilidades de transição p desconhecida. Dada a amostra

$$X_{-1}^{14} = (1, 0, 0, 1, 1, 1, 0, 1, 0, 0, 0, 0, 1, 0, 0, 1)$$

gerada por esta cadeia, os estimadores de máxima verossimilhança para $p(1|1), p(1|00)$ e $p(1|01)$ são, respectivamente:

- (a) $\hat{p}_n(1|1) = 1/2, \hat{p}_n(1|00) = 2/5$ e $\hat{p}_n(1|01) = 1/4$.
- (b) $\hat{p}_n(1|1) = 1/3, \hat{p}_n(1|00) = 3/5$ e $\hat{p}_n(1|01) = 1/4$.
- (c) $\hat{p}_n(1|1) = 1/3, \hat{p}_n(1|00) = 3/5$ e $\hat{p}_n(1|01) = 3/4$.
- (d) Nenhuma das respostas anteriores.

8. Seja τ a árvore de contextos indexada pelos símbolos do alfabeto $A = \{0, 1\}$ assim definida

$$\tau = \{\{\omega_{-1} = 0\}, \{\omega_{-2} = 0, \omega_{-1} = 1\}, \{\omega_{-2} = 1, \omega_{-1} = 1\}\}.$$

Associamos a τ a família de probabilidade de transição p assim definida

$$p(0|0) = 0.2, p(0|10) = 0.4, p(0|11) = 0.6.$$

Simulamos uma amostra X_{-1}^5 da cadeia estocástica assumindo valores no alfabeto $A = \{0, 1\}$ usando o seguinte algoritmo:

Passo 1. $X_{-1} = 0$

Passo 2. Para $n \geq 0$, definimos $X_n = \mathbf{1}_{\{U_n \geq p(0|c_n(X_{-1}^{n-1}))\}}$ em que U_0, U_1, \dots é uma sequência de v.a. i.i.d. com distribuição uniforme no intervalo $[0, 1]$.

Supondo que o sorteio das variáveis uniformes produziu a sequência

$$U_0 = 0.77, U_1 = 0.92, U_2 = 0.12, U_3 = 0.44, U_4 = 0.59, U_5 = 0.14.$$

diga qual das opções abaixo é correta

- (a) $X_0 = 0, X_1 = 0, X_2 = 1, X_3 = 0, X_4 = 0, X_5 = 1$
- (b) $X_0 = 1, X_1 = 0, X_2 = 0, X_3 = 1, X_4 = 0, X_5 = 1$
- (c) $X_0 = 1, X_1 = 1, X_2 = 0, X_3 = 1, X_4 = 1, X_5 = 0$
- (d) Nenhuma das respostas anteriores.