

Notas de Aula de Aplicações de Processos Estocásticos

Prof. Antonio Galves
Transcrito por Giovanna A. de A. Isolani

2º Semestre de 2013

Dada uma amostra $X_{-k}^n = a_{-k}^n$, supondo que ela foi gerada por $p \in \mathcal{M}_k(\mathbb{A})$, calcular a verossimilhança da amostra

$$\begin{aligned} & \mathbb{P}\{X_0^n = a_0^n | X_{-k}^{-1} = a_{-k}^{-1}\} \\ &= \prod_{t=0}^n \mathbb{P}\{X_t = a_t | X_{-k}^{t-1} = a_{-k}^{t-1}\} \end{aligned} \quad (1)$$

Lembrando que $X_t = f(X_{t-k}^{t-1}, U_t)$, logo

$$(1) = \prod_{t=0}^n \mathbb{P}\{X_t = a_t | X_{t-k}^{t-1} = a_{t-k}^{t-1}\}$$

e

$$\mathbb{P}\{X_t = a_t | X_{t-k}^{t-1} = a_{t-k}^{t-1}\} = p(a_t | a_{t-k}^{t-1}).$$

Então,

$$\begin{aligned} (1) &= \prod_{t=0}^n p(a_t | a_{t-k}^{t-1}) \\ &= \prod_{x_{-k}^{-1}} \prod_y p(y | x_{-k}^{-1})^{N_{0:n}(x_{-k}^{-1}, y)} \end{aligned}$$

Onde,

$$N_{0:n}(x_{-k}^{-1}, y) = \sum_{t=0}^n \mathbb{1}_{\{X_{t-k}^{t-1} = x_{-k}^{-1}, X_t = y\}}$$

Para calcularmos verossimilhança, convém usarmos o logaritmo da função de verossimilhança. Assim,

$$\begin{aligned} & \log \mathbb{P}\{X_0^n = a_0^n | X_{-k}^{-1} = a_{-k}^{-1}\} \\ &= \sum_{x_{-k}^{-1} \in A^k} \sum_{y \in A} N_{0:n}(x_{-k}^{-1}y) \log p(y|x_{-k}^{-1}) \end{aligned}$$

Sabemos pela Lei dos Grandes Números que

$$N_{0:n}(x_{-k}^{-1}y) = \sum_{t=0}^n \mathbb{1}_{\{X_{t-k}^{-1} = x_{-k}^{-1}, X_t = y\}} \simeq n \mathbb{P}\{X_{-k}^{-1} = x_{-k}^{-1}, X_0 = y\}$$

$$\mathbb{P}\{X_{-k}^{-1} = x_{-k}^{-1}, X_0 = y\} = \mathbb{P}\{X_{-k}^{-1} = x_{-k}^{-1}\} p(y|x_{-k}^{-1})$$

Sendo que $\mathbb{P}\{X_{-k}^{-1} = x_{-k}^{-1}\}$ é a probabilidade invariante. Agora,

$$\begin{aligned} & \frac{1}{n} \log \mathbb{P}\{X_0^n = a_0^n | X_{-k}^{-1} = a_{-k}^{-1}\} \\ &= \sum_{x_{-k}^{-1} \in A^k} \sum_{y \in A} \frac{N_{0:n}(x_{-k}^{-1}y)}{n} \log p(y|x_{-k}^{-1}) \xrightarrow{\overline{n \rightarrow \infty}} \\ & \xrightarrow{\overline{n \rightarrow \infty}} \sum_{x_{-k}^{-1} \in A^k} \sum_{y \in A} \mu(x_{-k}^{-1}) p(y|x_{-k}^{-1}) \log p(y|x_{-k}^{-1}) = -h(p) \end{aligned}$$

Onde $\mu : A^k \rightarrow [0, 1]$ é a probabilidade invariante com respeito à matriz P e $-h(p)$ é a entropia da cadeia.

Então, para n grande,

$$\mathbb{P}\{X_0^n = a_0^n | X_{-k}^{-1} = a_{-k}^{-1}\} \approx e^{-nh(p)}$$

Proposição: Uma Cadeia de Markov de alcance k em A com matriz $p \in \mathcal{M}_k(A)$ é uma Cadeia de Markov de alcance 1 no alfabeto $\bar{A} = A^k$ e tendo matriz $\bar{p} \in \mathcal{M}(\bar{A})$, onde \bar{p} é $\mathbb{P}\{X_{-k+1}^0 = b_{-k+1}^0 | X_{-k}^{-1} = a_{-k}^{-1}\}$. Calculamos $\mu : \bar{A} \rightarrow [0, 1]$ invariante com respeito à \bar{p} .

$$\frac{1}{n} N_{0:n}(x_{-k}^{-1}) \rightarrow \mu(x_{-k}^{-1})$$

Teorema: $\lim_{n \rightarrow \infty} L_n(p) \rightarrow \sum_{x_{-k}^{-1} \in A^k} \sum_{y \in A} \mu(x_{-k}^{-1}) p(y|x_{-k}^{-1}) \log p(y|x_{-k}^{-1})$
 $= -h(p)$

Dada uma amostra $X_{-k}^n = a_{-k}^n$, com k fixado.

$$p \in \mathcal{M}_k(A) \implies L(p|a_{-k}^n) \in]-\infty, 0[$$

Sabemos que a amostra foi gerada por uma matriz $\bar{p} \in \mathcal{M}(\bar{A})$, mas não conhecemos \bar{p} . Queremos estimar \bar{p} . Para isso vamos introduzir o estimador de máxima verossimilhança.

$$\hat{p}_n = \operatorname{argmax}\{L_p(x_{-k}^n) : p \in \mathcal{M}(A)\},$$

qué a matriz \bar{p} em $\mathcal{M}(A)$ que maximiza a função de verossimilhança.