

Aula 8. Cadeias de Markov: medida invariante.

Anatoli Iambartsev

IME-USP

Exemplo Introdutório.

Consideramos a seguinte matriz de transição: $\mathbf{P} = \begin{pmatrix} 0.2 & 0.8 \\ 0.4 & 0.6 \end{pmatrix}$
e calculamos \mathbf{P}^2 , \mathbf{P}^4 e \mathbf{P}^8 :

$$\mathbf{P}^2 = \begin{pmatrix} 0.36 & 0.64 \\ 0.32 & 0.68 \end{pmatrix}, \quad \mathbf{P}^4 = \begin{pmatrix} 0.3344 & 0.6656 \\ 0.3328 & 0.6672 \end{pmatrix},$$
$$\mathbf{P}^8 = \begin{pmatrix} 0.3333350 & 0.6666650 \\ 0.3333325 & 0.6666675 \end{pmatrix}.$$

Notamos que para todos os i 's, a probabilidade $p_{ij}^{(n)}$ converge (quando $n \rightarrow \infty$) para algum número que é o mesmo para todos os estados i . Em outras palavras, existe uma probabilidade limite de que o processo, depois de um número grande de passos, esteja no estado j , e esta probabilidade limite não depende do estado inicial. Para formular este teorema sobre a probabilidade limite, vamos precisar de propriedades adicionais de cadeia de Markov.

Continuamos classificação de estados.

Definição: Diz-se que o estado i tem **período** d se $p_{ii}^{(n)} = 0$ se e somente se n não se divide em d , i.e. n/d tem resto diferente de zero. Estado com $d = 1$ chama-se estado **aperiódico**.

O passeio aleatório simples é um exemplo onde qualquer estado é periódico com $d = 2$. Seja T_i o tempo de voltar para o estado i começando do i :

$$T_i = \min\{n > 0 : X_n = i\}, \quad X_0 = i.$$

Definição: Se o estado i é recorrente, então ele chama-se **recorrente positivo** se $\mathbb{E}(T_i) < \infty$. O estado i chama-se estado **ergódico**, se este estado é aperiódico e recorrente positivo.

Teorema principal (ergódica).

Agora estamos prontos para formular o teorema principal de teoria de cadeias de Markov.

Teorema: *Para qualquer cadeia de Markov ergódica (todos os estados dela são ergódicos) o limite $\lim_{n \rightarrow \infty} p_{ij}^{(n)}$ existe e não depende do i .*

Seja

$$\pi_j = \lim_{n \rightarrow \infty} p_{ij}^{(n)}, \quad j \geq 0.$$

Então o vetor $\pi^T = (\pi_0, \pi_1, \dots)$ é solução única do seguinte sistema

$$\begin{cases} \pi_j = \sum_{i=0}^{\infty} \pi_i p_{ij}, & j \geq 0 \\ \sum_{j=0}^{\infty} \pi_j = 1 \end{cases}$$

Teorema principal (ergódica). Observações.

(i) Notamos que a segunda equação do sistema mostra que o vetor π é uma distribuição de probabilidade no conjunto de estados da cadeia de Markov em consideração.

(ii) Interpretamos o limite π_j como a probabilidade do processo estar no estado j . Também pode ser interpretada como a fração de tempo que a cadeia passa no estado j (teorema ergódico para cadeia de Markov).

(iii) Em caso de cadeia irredutível, recorrente positiva, mas *periódica*, mostra-se que $\pi = (\pi_j, j \geq 0)$ é uma solução única não-negativa da equação, mas, nesse caso π_j não pode ser interpretada como a probabilidade limite (em caso de cadeia periódica não existe o limite $\lim_{n \rightarrow \infty} p_{ij}^{(n)}$). Mas, neste caso, π_j pode ser interpretada como a proporção de tempo que a cadeia de Markov visita o estado j .

Exemplo 1.

Sabemos que se hoje chove, então, amanhã vai chover com probabilidade α , e se hoje não chove, então, vai chover amanhã com probabilidade β . Construa uma cadeia de Markov correspondente e ache as probabilidades limite desta cadeia.

Exemplo 1. Solução. “chove” \rightarrow “chove” com probabilidade α , e “não chove” \rightarrow “chove” com probabilidade β .

Seja o estado “0” corresponde a um dia que chove, e o estado “1” quando não chove. A matriz de transição é

$$\mathbf{P} = \begin{vmatrix} \alpha & 1 - \alpha \\ \beta & 1 - \beta \end{vmatrix}.$$

Cadeia irredutível. As probabilidades limite é solução do sistema de equações:

$$\begin{aligned} \begin{cases} \pi^T \mathbf{P} = \pi^T \\ \sum \pi_j = 1 \end{cases} &= \begin{cases} \pi_0 = \pi_0 \alpha + \pi_1 \beta \\ \pi_1 = \pi_0 (1 - \alpha) + \pi_1 (1 - \beta) \\ \pi_0 + \pi_1 = 1 \end{cases} \Leftrightarrow \begin{cases} \pi_0 = \pi_0 \alpha + \pi_1 \beta \\ \pi_1 = 1 - \pi_0 \end{cases} \\ \Leftrightarrow \begin{cases} \pi_0 = \pi_0 \alpha + (1 - \pi_0) \beta \\ \pi_1 = 1 - \pi_0 \end{cases} &\Leftrightarrow \begin{cases} \pi_0 = \frac{\beta}{1 - \alpha + \beta} \\ \pi_1 = 1 - \pi_0 \end{cases} \Leftrightarrow \begin{cases} \pi_0 = \frac{\beta}{1 - \alpha + \beta} \\ \pi_1 = \frac{1 - \alpha}{1 - \alpha + \beta} \end{cases} \end{aligned}$$

Problema da ruína do jogador.

Consideramos dois jogadores A e B. O jogador A ganha um jogo com probabilidade p e recebe 1 real do parceiro B. O jogador B ganha um jogo com probabilidade $q = 1 - p$ e recebe 1 real do seu parceiro. Não tem empate neste jogo. Todas as apostas são independentes. Seja N o número total de reais que os jogadores têm. O jogo vai parar quando um dos dois jogadores fica com todos os N reais.

Achar a probabilidade de jogador A ganhar o jogo, se ele começa com i reais.

Problema da ruína do jogador. Solução.

Se X_n é a grana do jogador A depois da n -ésima aposta, então, X_n forma uma cadeia de Markov com estados $\{0, 1, 2, \dots, N\}$ e probabilidades de transições

$$p_{00} = p_{NN} = 1, \quad p_{i,i+1} = p, \quad p_{i,i-1} = q = 1 - p,$$

A cadeia possui três classes: $\{0\}$, $\{1, 2, \dots, N - 1\}$ e $\{N\}$. Classes $\{0\}$ e $\{N\}$ são recorrentes. A segunda classe é transitória, isso significa, que o jogo acaba (em tempo finito), i.e., com probabilidade 1 ou A ou B estará com toda grana.

Problema da ruína do jogador. Solução.

Seja P_i probabilidade de que o jogador A ganhe o jogo, dado que ele começou com i reais:

$$P_i = \mathbb{P}(\exists n : X_n = N \mid X_0 = i).$$

Condicionando pelo resultado da primeira jogada, obtemos

$$\begin{aligned} P_i &= \mathbb{P}(\exists n : X_n = N \mid X_1 = i + 1)\mathbb{P}(X_1 = i + 1 \mid X_0 = i) \\ &\quad + \mathbb{P}(\exists n : X_n = N \mid X_1 = i - 1)\mathbb{P}(X_1 = i - 1 \mid X_0 = i) \\ &= pP_{i+1} + qP_{i-1}, \quad i = 1, 2, \dots, N - 1. \end{aligned}$$

Reescrevemos isso de outra forma, usando o fato que $p + q = 1$:

$$\begin{aligned} (p + q)P_i &= pP_{i+1} + qP_{i-1} \\ \Rightarrow P_{i+1} - P_i &= \frac{q}{p}(P_i - P_{i-1}), \quad i = 1, 2, \dots, N - 1. \end{aligned}$$

Problema da ruína do jogador. Solução.

A probabilidade P_0 é igual a zero, logo

$$P_2 - P_1 = \frac{q}{p}(P_1 - P_0) = \frac{q}{p}P_1$$

$$P_3 - P_2 = \frac{q}{p}(P_2 - P_1) = \left(\frac{q}{p}\right)^2 P_1$$

⋮

$$P_i - P_{i-1} = \left(\frac{q}{p}\right)^{i-1} P_1$$

⋮

$$P_N - P_{N-1} = \left(\frac{q}{p}\right)^{N-1} P_1.$$

Logo

$$P_i - P_1 = P_1 \left[\left(\frac{q}{p}\right) + \left(\frac{q}{p}\right)^2 + \dots + \left(\frac{q}{p}\right)^{i-1} \right]$$

ou

$$P_i = \begin{cases} \frac{1-(q/p)^i}{1-(q/p)} P_1, & \text{se } \frac{q}{p} \neq 1 \\ iP_1, & \text{se } \frac{q}{p} = 1. \end{cases}$$

Problema da ruína do jogador. Solução.

$$P_i = \begin{cases} \frac{1-(q/p)^i}{1-(q/p)^N} P_1, & \text{se } \frac{q}{p} \neq 1 \\ iP_1, & \text{se } \frac{q}{p} = 1. \end{cases}$$

Usando $P_N = 1$, obtemos

$$P_1 = \begin{cases} \frac{1-(q/p)}{1-(q/p)^N}, & \text{se } p \neq \frac{1}{2} \\ \frac{1}{N}, & \text{se } p = \frac{1}{2} \end{cases}$$

Assim, segue que

$$P_i = \begin{cases} \frac{1-(q/p)^i}{1-(q/p)^N}, & \text{se } p \neq \frac{1}{2} \\ \frac{i}{N}, & \text{se } p = \frac{1}{2}. \end{cases} \quad (1)$$

Problema da ruína do jogador. Solução.

Notamos que se $N \rightarrow \infty$

$$P_i \longrightarrow \begin{cases} 1 - \left(\frac{q}{p}\right)^i, & \text{se } p > \frac{1}{2} \\ 0, & \text{se } p \leq \frac{1}{2}. \end{cases}$$

Se a probabilidade de ganhar numa jogada é maior de que 50%, então, a probabilidade de que a quantia de reais cresce para sempre é positiva. Este tipo de jogo as vezes chama-se um jogo com o Universo (ou Natureza).

Problema da ruína do jogador. Exemplo 2.

Suponha que A é mais esperto do que B : A ganha uma aposta com probabilidade $p = 0.6$. Qual é a probabilidade de que o jogador A ganhe a banca se ele começa com 5 reais, enquanto o jogador B começa com 10 reais? E se A começa com 10 reais e B começa com 20 reais?

A probabilidade desejada pode ser calculada através da fórmula, usando $i = 5, N = 15$, e $p = 0.6$. Assim, obtemos que a probabilidade é

$$P_5 = \frac{1 - \left(\frac{q}{p}\right)^5}{1 - \left(\frac{q}{p}\right)^{15}} = \frac{1 - \left(\frac{2}{3}\right)^5}{1 - \left(\frac{2}{3}\right)^{15}} \approx 0.87.$$

A outra probabilidade é

$$\frac{1 - \left(\frac{2}{3}\right)^{10}}{1 - \left(\frac{2}{3}\right)^{30}} \approx 0.98.$$

Processo de ramificação.

Supomos que um indivíduo gera k filhos com probabilidade p_k . Seja X_0 o número inicial de indivíduos e suponha que cada indivíduo gera filhos independentemente um do outro. Filhos de X_0 indivíduos formam a primeira geração X_1 , filhos da primeira geração formam segunda geração X_2 , etc. $\{X_n, n = 0, 1, \dots\}$ forma uma cadeia de Markov com estados $\mathbb{N} \cup \{0\}$. Notamos que o estado 0 é um estado absorvente ($p_{00} = 1$).

Notamos também que se $p_0 > 0$, então todos os outros estados são transitórios (porque a probabilidade de acessar o estado absorvente é positiva $p_{i0} = p_0^i$). Assim, se $p_0 > 0$, então, a população ou vai ser extinta ou vai crescer até o infinito.

Processo de ramificação.

Sejam μ e σ^2 a média e variância do número de filhos.

$$\mu = \sum_{k=0}^{\infty} kp_k \quad \sigma^2 = \sum_{k=0}^{\infty} (k - \mu)^2 p_k$$

Calculamos a média e a variância de X_n . Notamos que X_n pode ser representado da seguinte forma:

$$X_n = \sum_{k=1}^{X_{n-1}} Z_k,$$

onde Z_k representa o número de filhos do k -ésimo indivíduo da $(n - 1)$ -ésima geração. Temos

$$\mathbb{E}(X_n) = \mathbb{E}(\mathbb{E}(X_n | X_{n-1})) = \mathbb{E}\left(\mathbb{E}\left(\sum_{k=1}^{X_{n-1}} Z_k \mid X_{n-1}\right)\right) = \mathbb{E}(X_{n-1}\mu) = \mu\mathbb{E}(X_{n-1}).$$

A última equação nos diz que se $X_0 = 1$, então $\mathbb{E}(X_n) = \mu^n$.

Processo de ramificação. Exercício 2.

Prove que

$$\text{Var}[X_n] = \begin{cases} \sigma^2 \mu^{n-1} \left(\frac{\mu^n - 1}{\mu - 1} \right), & \text{if } \mu \neq 1 \\ n\sigma^2, & \text{if } \mu = 1 \end{cases}$$

Processo de ramificação. Probabilidade de extinção.

Seja π_0 a probabilidade de extinção da população

$$\pi_0 = \lim_{n \rightarrow \infty} \mathbb{P}(X_n = 0 \mid X_0 = 1).$$

Notamos que $\pi_0 = 1$ se $\mu < 1$ e

$$\begin{aligned} \mu^n &= \mathbb{E}(X_n) = \sum_{k=1}^{\infty} k \mathbb{P}(X_n = k) \geq \sum_{k=1}^{\infty} \mathbb{P}(X_n = k) \\ &= \mathbb{P}(X_n \geq 1) \rightarrow 0 \text{ quando } n \rightarrow \infty. \end{aligned}$$

Pode ser provado que quando $\mu = 1$, também temos $\pi_0 = 1$. E quando $\mu > 1$, π_0 é solução da seguinte equação:

$$\pi_0 = \sum_{k=0}^{\infty} \pi_0^k p_k.$$

References:

[Ross] S.Ross. *Introduction to Probability Models*.
9th edition, Academic Press, 2007.