

Aula 9. Cadeias de Markov com tempo contínuo I.

Definição

Começamos com a definição. O conjunto de variáveis $\{X(t), t \geq 0\}$ com o espaço enumerável S dos estados, chama-se uma cadeia de Markov com o tempo contínuo, se para quaisquer $t > s > u$

$$P\{X(t) = j \mid X(s) = i, X(u) = k\} = P\{X(t) = j \mid X(s) = i\} \quad (1)$$

Notamos que a definição pode ser usada para caso do tempo discreto também, somente definir o conjunto de valores do "tempo". Se $t \in \mathbb{R}$ então digamos que temos o tempo contínuo. Se $t \in \mathbb{Z}$, neste caso digamos que o tempo é discreto. Nós continuamos usar a expressão "cadeia de Markov", pois a palavra "cadeia" reflete o fato que os estados (valores de variáveis $X(t)$) pertencem ao mesmo conjunto, e conjunto *enumerável*.

Probabilidade $P\{X(t) = j \mid X(s) = i\}$ chama-se a probabilidade de transição, e podemos anotar ela como $p_{ij}(s, t)$. Caso a função $p_{ij}(s, t)$ depende do comprimento do intervalo do tempo $t - s$, neste caso a cadeia chama-se a cadeia homogênea.

Propriedade de falta da memória

Supomos que a cadeia $X(t)$ esta em estado i fixo em instante 0. Qual é a distribuição do tempo de cadeia permanecer neste estado, antes de mudar para o outro estado? Anotamos esse tempo T_i .

$$T_i = \min\{t : X(t) \neq i \text{ dado } X(0) = i\}. \quad (2)$$

Provaremos que a distribuição desse tempo é exponencial. Para isso provamos que esse tempo satisfaz a condição de falta da memória.

$$\begin{aligned} P\{T_i > t + s \mid T_i > s, X(0) = i\} &= P\{T_i > t + s \mid X(u) = i, 0 \leq u \leq s\} \\ &= P\{T_i > t + s \mid X(s) = i\} = P\{T_i > t \mid X(0) = i\} \end{aligned}$$

Definição alternativa

Podemos descrever agora a cadeia em outra maneira. $\{X(t)\}$ chama-se cadeia de Markov, se

1. tempo que a cadeia fica em estado i tem a distribuição exponencial com a taxa v_i ;
2. quando a cadeia saia do estado i a escolha do outro estado ocorre com a probabilidade p_{ij} , onde $i \neq j$, e $\sum_{j \neq i} p_{ij} = 1$, e $p_{ii} = 0$, para cada estado i .

Cadeia embutida

Seja $T_1 < T_2 < \dots < T_n < \dots$ instantes quando a cadeia $X(t)$ altera o seu estado. Consideramos variáveis $X_n = X(T_n)$. A sequência X_n forma uma cadeia de Markov com as probabilidades de transições p_{ij} .

Processo de Poisson é cadeia de Markov

Para o processo de Poisson, mostrar que $v_i = \lambda$ e $p_{ij} = 1$ se $j = i + 1$ e $p_{ij} = 0$ caso contrario. Para o processo de Poisson sabemos também que $p_{ij}(t) = (\lambda t)^{|j-i|} e^{-\lambda t} / (j-i)!$.

A cadeia embutida para processo de Poisson é trivial. As transições $i \rightarrow i + 1$ ocorrem com a probabilidade 1.

Processo de nascimento e morte.

Consideramos uma cadeia com conjunto de estados \mathbb{N} , que vai ser interpretada como o número de indivíduos (pessoas, partículas, ect.) em um sistema (pode ser sistema de filas). Se a cadeia está em estado n (se o número de indivíduos no sistema é igual à n), então

1. um novo indivíduo aparece no sistema com a taxa exponencial λ_n (taxa de chegada ou taxa de nascimento);
2. um indivíduo deixa o sistema com a taxa exponencial μ_n (taxa de partida, ou taxa de morte).

Em termos $\{v_i\}$ e $\{p_{ij}\}$:

$$v_0 = \lambda_0, \quad v_i = \lambda_i + \mu_i$$

$$p_{01} = 1, \quad p_{i,i+1} = \frac{\lambda_i}{\lambda_i + \mu_i}, \quad p_{i,i-1} = \frac{\mu_i}{\lambda_i + \mu_i}$$

Exemplo 1. Processo de Poisson é processo de nascimento e morte com $\lambda_n = \lambda$ e $\mu_n = 0$.

Exemplo 2. (Processo de nascimento com taxa de nascimento linear) Cada indivíduo espera o tempo exponencial com a taxa λ para dar a luz um "filho" dele. Assim $\lambda_n = n\lambda, n \geq 0$. Esse processo é conhecido também como o processo do Yule, depois de G.Yule usar ele em teoria matemática da evolução.

Exemplo 3. (Modelo de crescimento linear com imigração) Neste caso $\mu_n = n\mu, n \geq 1$ e $\lambda_n = n\lambda + \theta, n \geq 0$. Seja $X(t)$ tamanho de população em instante t . Vamos achar neste caso o tamanho médio de população $m(t) = E[X(t)]$. Vamos derivar a equação para $m(t)$. Para isso consideramos o incremento da média em pequeno lapso de tempo h ; o que pode ocorrer durante este tempo?

$$X(t+h) = \begin{cases} X(t) + 1, & \text{com probabilidade } (\theta + \lambda X(t))h + o(h) \\ X(t) - 1, & \text{com probabilidade } X(t)\mu h + o(h) \\ X(t), & \text{com probabilidade } 1 - (\theta + \lambda X(t) + \mu X(t))h + o(h) \end{cases}$$

então

$$E(X(t+h) | X(t)) = X(t) + (\theta + \lambda X(t) - \mu X(t))h + o(h)$$

$$m(t+h) = m(t) + (\lambda - \mu)m(t)h + \theta h + o(h)$$

$$\Leftrightarrow \frac{m(t+h) - m(t)}{h} = (\lambda - \mu)m(t) + \theta + \frac{o(h)}{h}$$

$$\Leftrightarrow m'(t) = (\lambda - \mu)m(t) + \theta \quad (3)$$

Seja $h(t) = (\lambda - \mu)m(t) + \theta$, então se $m(t)$ satisfaz equação (3), então $h(t)$ vai satisfazer a equação $h'(t)/(\lambda - \mu) = h(t)$ e a integração vai dar $\log(h(t)) = (\lambda - \mu)t + c$ ou $h(t) = Ke^{(\lambda - \mu)t}$. Para achar K colocaremos condição inicial: $m(0) = i$. O que vai dar $K = \theta + (\lambda - \mu)i$ assim

$$m(t) = \frac{\theta}{\lambda - \mu}(e^{(\lambda - \mu)t} - 1) + ie^{(\lambda - \mu)t} \quad (4)$$

se $\lambda = \mu$ então $m'(t) = \theta$ e

$$m(t) = \theta t + i. \quad (5)$$

Exemplo 4. (M/M/1) $\mu_n = \mu, n \geq 1, \lambda_n = \lambda, n \geq 0$.

Exemplo 5. (M/M/s)

$$\mu_n = \begin{cases} n\mu, & 1 \leq n \leq s \\ s\mu, & n > s \end{cases} \quad \lambda_n = \lambda, \quad n \geq 0.$$

Exemplo 6. Consideramos um processo de nascimento e morte geral, $X(t)$, com as taxas de transição λ_n, μ_n ; em que supomos que $\mu_0 = 0$. Supomos que o processo começa evoluir em tempo do estado i , seja $T_i = \min\{t > 0 : X(t) = i+1\}$. Estabelecemos aqui uma fórmula recursiva para calcular $E(T_i)$.

Primeiramente observamos que $E(T_0) = 1/\lambda_0$.

Para $i > 0$ primeiro calcularemos as médias condicionando pelo primeiro passo: $I_i = 1$ caso primeiro passo foi $i \rightarrow i+1$ e $I_i = -1$ caso primeiro passo foi $i \rightarrow i-1$; variável I_i é nada mais como incremento do primeiro passo.

$$E(T_i | I_i = 1) = \frac{1}{\lambda_i + \mu_i},$$

$$E(T_i | I_i = -1) = \frac{1}{\lambda_i + \mu_i} + E(T_{i-1}) + E(T_i). \quad (6)$$

Assim, logo

$$E(T_i) = E(T_i | I_i = 1)P(I_i = 1) + E(T_i | I_i = -1)P(I_i = -1)$$

$$= \frac{1}{\lambda_i + \mu_i} \cdot \frac{\lambda_i}{\lambda_i + \mu_i} + \left(\frac{1}{\lambda_i + \mu_i} + E(T_{i-1}) + E(T_i) \right) \cdot \frac{\mu_i}{\lambda_i + \mu_i}$$

$$= \frac{1}{\lambda_i + \mu_i} + (E(T_{i-1}) + E(T_i)) \frac{\mu_i}{\lambda_i + \mu_i}$$

ou

$$E(T_i) = \frac{1}{\lambda_i} + \frac{\mu_i}{\lambda_i} E(T_{i-1}) \quad (7)$$

Exemplo 6. Consideramos um caso particular para formula (7): seja $\lambda_n \equiv \lambda$ e $\mu_n \equiv \mu$. Neste caso conseguimos a formula fechada para $E(T_i)$. A formula (8) possui neste caso seguinte forma.

$$E(T_i) = \frac{1}{\lambda} + \frac{1}{\lambda}E(T_{i-1}) = \frac{1}{\lambda} \left(1 + \mu E(T_{i-1}) \right). \quad (8)$$

Começando com

$$\begin{aligned} E(T_1) &= \frac{1}{\lambda} \left(1 + \frac{\mu}{\lambda} \right) \\ E(T_2) &= \frac{1}{\lambda} \left(1 + \frac{\mu}{\lambda} + \left(\frac{\mu}{\lambda} \right)^2 \right) \\ &\vdots \\ E(T_i) &= \frac{1}{\lambda} \left(1 + \frac{\mu}{\lambda} + \left(\frac{\mu}{\lambda} \right)^2 + \dots + \left(\frac{\mu}{\lambda} \right)^i \right) \\ &= \frac{1 - (\mu/\lambda)^{i+1}}{\lambda - \mu}, \quad i \geq 0 \text{ and } \lambda \neq \mu; \\ &= \frac{i+1}{\lambda}, \quad i \geq 0 \text{ and } \lambda = \mu; \end{aligned}$$

Observação: caso quando queremos achar a média do tempo $T_{i \rightarrow j}$, quando $j > i$, então

$$\begin{aligned} E(T_{i \rightarrow j}) &= \sum_{n=i}^{j-1} E(T_n) = \sum_{n=i}^{j-1} \frac{1 - (\mu/\lambda)^{n+1}}{\lambda - \mu} \\ &= \frac{j-i}{\lambda - \mu} - \frac{(\mu/\lambda)^{i+1}}{\lambda - \mu} \cdot \frac{1 - (\mu/\lambda)^{j-i}}{1 - \mu/\lambda} \text{ quando } 0 \leq i < j \text{ and } \mu \neq \lambda \\ &= \frac{j(j+1) - i(i+1)}{2\lambda} \text{ quando } 0 \leq i < j \text{ and } \mu = \lambda. \end{aligned}$$

Exemplo 7. Calcularemos aqui a variância de $T_{0 \rightarrow j}$. Notamos que a equação (6) pode ser descrita de seguinte maneira:

$$\begin{aligned} E(T_i | I_i) &= \frac{1}{\lambda_i + \mu_i} + \frac{1 - I_i}{2} \cdot (E(T_{i-1}) + E(T_i)) \\ \text{Var}((E(T_i | I_i))) &= \text{Var}\left(\frac{1 - I_i}{2}\right) (E(T_{i-1}) + E(T_i))^2 \\ &= \frac{\lambda_i \mu_i}{(\lambda_i + \mu_i)^2} (E(T_{i-1}) + E(T_i))^2 \end{aligned}$$

em que

$$\text{Var}\left(\frac{1 - I_i}{2}\right) = \frac{1}{4} \text{Var}(I_i) = \frac{1}{4} (E(I_i^2) - (E(I_i))^2) = \frac{1}{4} \left(1 - \left(\frac{\lambda_i - \mu_i}{\lambda_i + \mu_i} \right)^2 \right) = \frac{\lambda_i \mu_i}{(\lambda_i + \mu_i)^2}.$$

Seja X_i é tempo de estar em estado i até momento de transição, então

$$\text{Var}(T_i | I_i = 1) = \text{Var}(X_i | I_i = 1) = \text{Var}(X_i) = \frac{1}{(\lambda_i + \mu_i)^2} \quad (9)$$

$$\begin{aligned} \text{Var}(T_i | I_i = -1) &= \text{Var}(X_i + T_{i-1} + T_i) = \text{Var}(X_i) + \text{Var}(T_{i-1}) + \text{Var}(T_i) \\ &= \frac{1}{(\lambda_i + \mu_i)^2} + \text{Var}(T_{i-1}) + \text{Var}(T_i). \end{aligned} \quad (10)$$

Assim (9) e (10) podem ser unidas como

$$\text{Var}(T_i | I_i) = \frac{1}{(\lambda_i + \mu_i)^2} + \frac{1 - I_i}{2} (\text{Var}(T_{i-1}) + \text{Var}(T_i)).$$

Logo,

$$E(\text{Var}(T_i | I_i)) = \frac{1}{(\lambda_i + \mu_i)^2} + \frac{\mu_i}{\lambda_i + \mu_i} (\text{Var}(T_{i-1}) + \text{Var}(T_i)).$$

Usando a fórmula para variância condicional obtemos

$$\begin{aligned} \text{Var}(T_i) &= \frac{1}{(\lambda_i + \mu_i)^2} + \frac{\mu_i}{\lambda_i + \mu_i} (\text{Var}(T_{i-1}) + \text{Var}(T_i)) + \frac{\lambda_i \mu_i}{(\lambda_i + \mu_i)^2} (E(T_{i-1}) + E(T_i))^2 \\ &= \frac{1}{\lambda_i (\lambda_i + \mu_i)^2} + \frac{\mu_i}{\lambda_i} \text{Var}(T_{i-1}) + \frac{\lambda_i \mu_i}{(\lambda_i + \mu_i)^2} (E(T_{i-1}) + E(T_i))^2 \end{aligned}$$

Exercícios domésticos. Exercícios para Lista: 2,3,4.

1. Considere um Processo de Poisson com parâmetro λ e $X(t)$ denotando o número de ocorrências no intervalo $(0, t]$.
 - (a) Encontre a probabilidade condicional de que hajam m ocorrências nas primeiras s unidades de tempo, dado que houveram n ocorrências nas primeiras t unidades de tempo, onde $0 \leq m \leq n$ e $0 \leq s \leq t$.
 - (b) Seja T_m o tempo até a m -ésima ocorrência. Encontre a distribuição de probabilidade de T_m .
Dica: $\{T_m \leq t\} = \{X(t) \geq m\}$.
 - (c) Encontre a densidade da variável aleatória T_m .
Dica: Considere inicialmente casos específicos, por exemplo $m = 1, 2, 3$.

2. Seja T uma variável aleatória que é independente dos tempos em que ocorrem os eventos. Suponha que T tenha densidade exponencial com parâmetro v :

$$f_T(t) = ve^{-vt}, t > 0; f_T(t) = 0, t \leq 0.$$

Encontre a distribuição de $X(T)$, que representa o número de eventos que ocorrem no tempo T . *Dica:* Use as equações:

$$P(X(t) = n) = \int_0^{\infty} F_T(t)P(X(t) = n|T = t)dt$$

e:

$$P(X(t) = n|T = t) = P(X(t) = n).$$

3. Considere $X(t)$ um processo de nascimento puro da seguinte forma: T é uma variável aleatória exponencial (independente do processo) com a taxa λ . A cada ocorrência de T , população gera só um novo indivíduo.
 - (a) o processo descrito é o processo de nascimento e morte? em caso "sim" calcule λ_n e μ_n .
 - (b) Supomos que no momento $t = 0$, existem m indivíduos: $X(0) = m > 0$. Prove que $\lim_{t \rightarrow \infty} X(t) = \infty$.
4. Considere $X(t)$ um processo de nascimento puro da seguinte forma: T é uma variável aleatória exponencial (independente do processo) com a taxa λ . A cada ocorrência de T , cada indivíduo gera independentemente um novo indivíduo com probabilidade p (ou não gera com probabilidade $1 - p$).
 - (a) Calcule $\{v_i\}$ e probabilidades de transição $\{p_{ij}\}$ para esse processo.
 - (b) O processo é o processo de nascimento e morte pela definição da aula? caso "sim", calcule λ_n, μ_n .
 - (c) O que dizer de $\lim_{t \rightarrow \infty} X(t)$?
 - (d) Quando é que o processo definido nesse exercício é igual o processo do exercício anterior?

Referências

- [1] S.M.Ross (1997) *Introduction to probability models*. Chapter 6.