



ET658 - Processos Estocásticos para Atuária

Universidade Federal de Pernambuco - UFPE



Cadeias de Markov a tempo discreto: exemplos e problemas



Prof. Pablo M. Rodriguez

<https://www.pablo-rodriguez.org/et658-processos-estocasticos>



UNIVERSIDADE
FEDERAL
DE PERNAMBUCO

CCEN

CENTRO DE CIÊNCIAS EXATAS
E DA NATUREZA

Conteúdo da Aula 4

- ▶ Cadeias de Markov a tempo discreto.
 - ▶ Exemplos;
 - ▶ Problemas.



Lembrete: Cadeia de Markov

Uma cadeia de Markov a tempo discreto (CMTD) com espaço de estados \mathcal{S} é um processo estocástico $(X_n)_{n \geq 0}$ com valores em \mathcal{S} tal que

$$P(X_{n+1} = j | X_0 = i_0, X_1 = i_1, \dots, X_{n-1} = i_{n-1}, X_n = i) = P(X_{n+1} = j | X_n = i),$$

futuro passado presente

para todo $n \geq 0$ e para todo subconjunto $\{i_0, i_1, \dots, i_{n-1}, i, j\} \subset \mathcal{S}$.

Lembre que: para todo $i, j \in \mathcal{S}$ denotamos

- ▶ $p(i, j) := P(X_{n+1} = j | X_n = i)$, para todo $n \geq 0$;
- ▶ $p_n(i, j) := P(X_{m+n} = j | X_m = i)$, para todo $m, n \geq 0$.

Equações de Chapman-Kolmogorov

Proposição 4.1

Seja $(X_n)_{n \geq 0}$ uma CMTD com espaço de estados \mathcal{S} . Então,

$$p_{n+r}(i, j) = \sum_{k \in \mathcal{S}} p_n(i, k) p_r(k, j),$$

para todo $n, r \geq 0$ e $i, j \in \mathcal{S}$.

Exemplo 4.1

Considere uma CMTD com $\mathcal{S} = \{1, 2, 3\}$. Para calcular $p_2(1, 3)$:

$$p_2(1, 3) = p(1, 1)p(1, 3) + p(1, 2)p(2, 3) + p(1, 3)p(3, 3).$$



Problema 1

Considere a cadeia de Markov $(X_n)_{n \geq 0}$ com espaço de estados $\mathcal{S} = \{0, 1, 2\}$ e matriz de transição dada por

$$P = \begin{pmatrix} 0,4 & 0 & 0,6 \\ 0,1 & 0,9 & 0 \\ 0,4 & 0,1 & 0,5 \end{pmatrix}$$

com $P(X_0 = 0) = 0,2$, $P(X_0 = 1) = 0,3$, $P(X_0 = 2) = 0,5$. Calcule:


- $P(X_0 = 0, X_1 = 0, X_2 = 2)$;
- $P(X_1 = 2, X_2 = 1 | X_0 = 0)$;
- $P(X_2 = 1, X_3 = 1 | X_0 = 0)$.



Solução do Problema 1. Como

$$P = \begin{pmatrix} p(0,0) & p(0,1) & p(0,2) \\ p(1,0) & p(1,1) & p(1,2) \\ p(2,0) & p(2,1) & p(2,2) \end{pmatrix} = \begin{pmatrix} 0,4 & 0 & 0,6 \\ 0,1 & 0,9 & 0 \\ 0,4 & 0,1 & 0,5 \end{pmatrix}$$


temos:



Solução do Problema 1. Como

$$P = \begin{pmatrix} p(0,0) & p(0,1) & p(0,2) \\ p(1,0) & p(1,1) & p(1,2) \\ p(2,0) & p(2,1) & p(2,2) \end{pmatrix} = \begin{pmatrix} 0,4 & 0 & 0,6 \\ 0,1 & 0,9 & 0 \\ 0,4 & 0,1 & 0,5 \end{pmatrix}$$


temos:



Solução do Problema 1. Como

$$P = \begin{pmatrix} p(0,0) & p(0,1) & p(0,2) \\ p(1,0) & p(1,1) & p(1,2) \\ p(2,0) & p(2,1) & p(2,2) \end{pmatrix} = \begin{pmatrix} 0,4 & 0 & 0,6 \\ 0,1 & 0,9 & 0 \\ 0,4 & 0,1 & 0,5 \end{pmatrix}$$


temos:




Solução do Problema 1. Como

$$P = \begin{pmatrix} p(0,0) & p(0,1) & p(0,2) \\ p(1,0) & p(1,1) & p(1,2) \\ p(2,0) & p(2,1) & p(2,2) \end{pmatrix} = \begin{pmatrix} 0,4 & 0 & 0,6 \\ 0,1 & 0,9 & 0 \\ 0,4 & 0,1 & 0,5 \end{pmatrix}$$

temos:



... continuação do Problema 1. Então




a.

$$\begin{aligned} P(X_0 = 0, X_1 = 0, X_2 = 2) &= P(X_0 = 0) \times p(0,0) \times p(0,2) \\ &= 0,2 \times 0,4 \times 0,6 \\ &= 0,048 \end{aligned}$$



... continuação do Problema 1. Da mesma forma




b.

$$\begin{aligned} P(X_1 = 2, X_2 = 1 | X_0 = 0) &= p(0, 2) \times p(2, 1) \\ &= 0,6 \times 0,1 \\ &= 0,06 \end{aligned}$$



... continuação do Problema 1. Finalmente



c. $P(X_2 = 1, X_3 = 1 | X_0 = 0) = p_2(0, 1) \times p(1, 1)$ e como

$$p_2(0, 1) = p(0, 2) \times p(2, 1) = 0,6 \times 0,1 = 0,06$$

concluimos que $P(X_2 = 1, X_3 = 1 | X_0 = 0) = 0,06 \times 0,9 = 0,054$.



Outra forma de definir uma cadeia de Markov

Seja $(X_n)_{n \geq 0}$ um processo com valores no conjunto \mathcal{S} . Se existe uma sequência de variáveis aleatórias i.i.d.

$$U_1, U_2, \dots$$

com distribuição comum uniforme no intervalo $(0, 1)$ e uma função

$$f : \mathcal{S} \times (0, 1) \rightarrow \mathcal{S}$$

tal que

$$X_{n+1} = f(X_n, U_n),$$

para todo $n \geq 0$, dizemos que $(X_n)_{n \geq 0}$ é uma cadeia de Markov a tempo discreto.



Exemplo 4.2

Considere o passeio aleatório em \mathbb{Z} , $(Y_n)_{n \geq 0}$. Se U_1, U_2, \dots são i.i.d. com $U_1 \sim \text{Uniforme}(0, 1)$ então podemos escrever

$$Y_{n+1} = f(Y_n, U_n),$$

onde a função $f : \mathbb{Z} \times (0, 1) \rightarrow \mathbb{Z}$ é dada por

$$f(i, u) := \begin{cases} i + 1, & \text{si } u < p, \\ i - 1, & \text{si } u \geq p. \end{cases}$$



Exemplo: o processo de ramificação

Considere uma variável aleatória discreta X com função de probabilidade


$$P(X = i) = p_i,$$

para $i \in \mathbb{N} \cup \{0\}$.

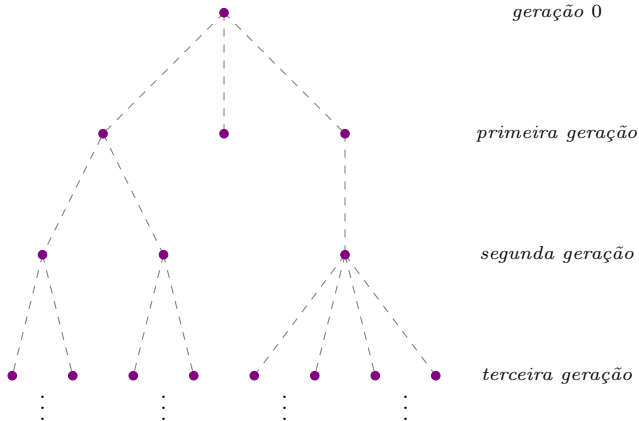
No que segue, todas as variáveis são cópias independentes de X .



Processo de ramificação: ideia



Processo de ramificação: gerações



Processo de ramificação: a cadeia de Markov

Considere, para cada $n \geq 0$, a variável aleatória:

$$Z_n = \# \text{ de partículas da } n\text{-ésima geração,}$$

e note que para todo $n \geq 1$ temos:

$$Z_{n+1} = \sum_{i=1}^{Z_n} X_i,$$

onde X_1, X_2, \dots são i.i.d. à v.a. X . A sequência $(Z_n)_{n \geq 0}$ chama-se processo de ramificação ou processo de Galton-Watson e é uma cadeia de Markov com espaço de estados $\mathbb{N} \cup \{0\}$ e probabilidades de transição:

$$p(i, j) = P(Z_{n+1} = j | Z_n = i) = \begin{cases} P\left(\sum_{r=1}^i X_r = j\right), & \text{para } i \geq 1 \text{ e } j \geq 0, \\ 0, & \text{para } i = 0 \text{ e } j > 0, \\ 1, & \text{para } i = 0 \text{ e } j = 0. \end{cases}$$



Referência!




Ross, S. Introduction to Probability Models. 10th ed. Academic Press. 2010.



UNIVERSIDADE
FEDERAL
DE PERNAMBUCO

CCEN

CENTRO DE CIÊNCIAS EXATAS
E DA NATUREZA



Bom estudo!

