

# Aula 7. Cadeias de Markov: motivação e introdução.

Anatoli Iambartsev

IME-USP

## **Aula 7. Cadeias de Markov: motivação e introdução**

**Video 1.** Assiste como introdução histórica (embora eu acostumei com o ponto de vista diferente, porque Markov criou as suas sequências dependentes)

<https://www.youtube.com/watch?v=KZfItpSXseo>

**Video 2.** Como introdução pode ser

<https://www.youtube.com/watch?v=LUbQcRXLQcE>


com o inicio 3 min 37s até 36 min 39s.

**Video 3.** Finalizando com exemplos de cadeias aplicadas à Atuária

<https://www.youtube.com/watch?v=cVXagizHjxQ>

### Exemplo Introdutório.

Numa ilha o tempo durante o dia é de dois tipos: ou está chovendo, ou não está chovendo. Os indígenas desta ilha sabem que se hoje chove, então com as chances 2 vs 1 não vai chover amanhã, mas se hoje não chove, então com as chances 6 vs 1 não vai chover amanhã.



### Exemplo Introdutório.

Para modelar esse sistema, podemos usar a técnica de cadeias de Markov. Cadeia é construída em dois passos: (1) definimos estados da cadeia, (2) definimos as transições e probabilidades delas, e (3) estado inicial.

No primeiro, definimos os estados do sistema. Neste caso o nosso interesse é o tempo, que pode ficar em dois estados *chove* (podemos codificar este estado como 1) e *não chove* (vamos codificar este estado como 0).

$$\text{Estados} = \{ \textit{chove}, \textit{não chove} \} = \{0, 1\}.$$

**Exemplo Introdutório.**

No segundo passo, temos que descrever TODAS as transições entre os estados. Neste caso, temos 4 possíveis transições:

$$0 \rightarrow 1, 0 \rightarrow 0, 1 \rightarrow 0, 1 \rightarrow 1.$$

Além disso, para cada transição, temos sua respectiva probabilidade.

### Exemplo Introdutório.

Em nosso caso, as probabilidades são

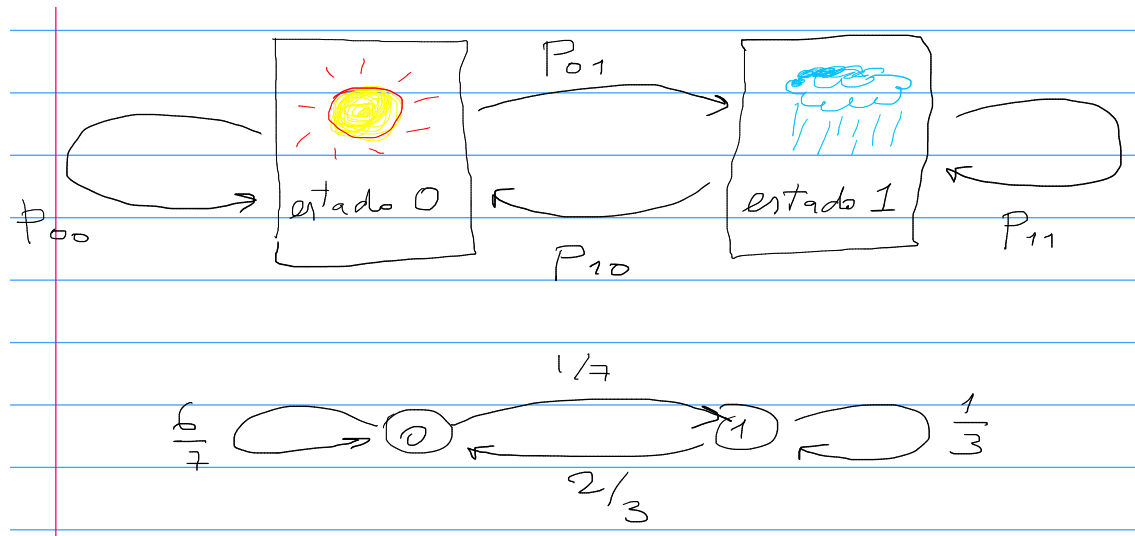
- $0 \rightarrow 1$  – se hoje não chove, então amanhã não vai chover com chances 6 vs 1, ou com probabilidade  $p_{01} = \frac{1}{7}$  vai chover;
- $0 \rightarrow 0$  – se hoje não chove, amanhã não vai chover com probabilidade  $p_{00} = \frac{6}{7}$ ;
- $1 \rightarrow 0$  – se hoje chove, amanhã não chove, isso acontece com as chances 2 vs 1 ou com probabilidade  $p_{10} = \frac{2}{3}$ ;
- $1 \rightarrow 1$  – se hoje chove, então amanhã vai chover com probabilidade  $p_{11} = \frac{1}{3}$ .

Notamos que

$$p_{00} + p_{01} = 1 \text{ e } p_{10} + p_{11} = 1.$$

Isso reflete o fato que qualquer que seja o tempo hoje, amanhã vai ser ou 0 ou 1:  $p_{a0} + p_{a1} = 1, \forall a = 0, 1$ .

**Exemplo Introdutório.** As transições podem ser representadas através do diagrama de transições:



Note, de novo que  $p_{00} + p_{01} = 1$  e  $p_{10} + p_{11} = 1$ . O que reflete a nossa confiança em chegada de amanhã.

## Teoria geral (informal).

Vamos considerar o processo estocástico  $\{X_n, n = 0, 1, 2, \dots\}$  em tempo discreto. As variáveis aleatórias  $X_n$  assumem valores do mesmo conjunto  $E$  que pode ser finito ou enumerável. Este conjunto chama-se o conjunto de estados e pode ser representado como o conjunto de números não-negativos  $E = \{0, 1, 2, \dots\}$ . Quando  $X_n = i$ , dizemos que o processo está no estado  $i$  em tempo  $n$ . Suponha que para cada estado  $i$ , existem as probabilidades fixas  $p_{ij}$  de que o processo esteja no estado  $i$  e no próximo passo esteja no estado  $j$ .



## Teoria geral (informal).

Para cada estado  $i$ , fixamos as probabilidades  $p_{ij}$ ,  $j \in E$  de que o processo esteja no estado  $i$  e no próximo passo esteja no estado  $j$ .

$$\begin{aligned}\mathbb{P}(X_{n+1} = j \mid X_n = i, X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0) \\ = \mathbb{P}(X_{n+1} = j \mid X_n = i) = p_{ij}.\end{aligned}$$

Isto significa que as chances de estar no estado  $j$  no próximo instante  $n+1$ , depende somente do estado no instante (presente)  $n$ , mas não depende da toda história do processo  $(X_0, X_1, \dots, X_{n-1})$ .

Essa propriedade do processo chama-se propriedade de Markov, ou propriedade markoviana. Notamos que as probabilidades  $p_{ij}$  não dependem do tempo  $n$ . Estes tipos de cadeias de Markov chamam-se cadeias *homogêneas* em relação ao tempo.

**Teoria geral (informal).**



As probabilidades podem ser organizadas em matriz

$$\mathbf{P} = \begin{vmatrix} p_{00} & p_{01} & p_{02} & \dots \\ p_{10} & p_{11} & p_{12} & \dots \\ \vdots & \vdots & \vdots & \ddots \\ p_{i0} & p_{i1} & p_{i2} & \dots \\ \vdots & \vdots & \vdots & \ddots \end{vmatrix}$$

com as propriedades:

$$p_{ij} \geq 0, \text{ e para qualquer } i \sum_{j=0}^{\infty} p_{ij} = 1.$$

A matriz chama-se a matriz de probabilidades de transição em um passo.

**Exemplo Introdutório.**

$$P = \begin{pmatrix} P_{00} & P_{01} \\ P_{10} & P_{11} \end{pmatrix} \Rightarrow P = \begin{pmatrix} \frac{6}{7} & \frac{1}{7} \\ \frac{2}{3} & \frac{1}{3} \end{pmatrix}$$

**Exercício 1.**

Considere sequencia de variáveis aleatórias independentes e identicamente distribuídas  $X_i, i = 0, 1, 2, \dots$ . Supomos que a distribuição deles é Bernoulli  $X_i \sim B(p)$ . Falaram que essa sequencia pode ser considerada como uma cadeia de Markov, será que isso é verdade? e se caso verdade, descreve a cadeia, oferecendo: (i) conjunto de estados da cadeia; (ii) matriz de transição; e (iii) estado (distribuição) inicial.

## Equações de Kolmogorov-Chapman.

Definimos as probabilidades de transição a  $n$  passos. A probabilidade  $p_{ij}^{(n)}$  definida como

$$p_{ij}^{(n)} = \mathbb{P}(X_{n+m} = j \mid X_m = i), n \geq 0, i, j \geq 0,$$

chama-se a probabilidade de transição de  $i$  para  $j$  depois de  $n$  passos. Evidentemente  $p^{(1)} = p_{ij}$ . As equações de Kolmogorov - Chapman são

$$p_{ij}^{(n+m)} = \sum_{k=0}^{\infty} p_{ik}^{(n)} p_{kj}^{(m)}$$

para todos  $n, m \geq 0$ , e todos  $i, j \in E$ .

As equações fornecem o cálculo de probabilidades de transição em  $n$ -passos.

## Equações de Kolmogorov-Chapman.

Formalmente, isso pode ser mostrado do seguinte modo:

$$\begin{aligned} p_{ij}^{(n+m)} &= \mathbb{P}(X_{n+m} = j \mid X_0 = i) \\ &= \sum_{k=0}^{\infty} \mathbb{P}(X_{n+m} = j, X_n = k \mid X_0 = i) \\ &= \sum_{k=0}^{\infty} \mathbb{P}(X_{n+m} = j \mid X_n = k, X_0 = i) \mathbb{P}(X_n = k \mid X_0 = i) \\ &= \sum_{k=0}^{\infty} p_{kj}^{(m)} p_{ik}^{(n)} = \sum_{k=0}^{\infty} p_{ik}^{(n)} p_{kj}^{(m)}. \end{aligned}$$

### Equações de Kolmogorov-Chapman.

Seja  $\mathbf{P}^{(n)}$  a matriz de probabilidades de transição em  $n$  passos. A equação pode ser representada através de matrizes como

$$\mathbf{P}^{(n+m)} = \mathbf{P}^{(n)}\mathbf{P}^{(m)}.$$

Particularmente, para dois passos, temos

$$\mathbf{P}^{(2)} = \mathbf{P}^{(1)}\mathbf{P}^{(1)} = \mathbf{P}\mathbf{P} = \mathbf{P}^2$$

$$\Rightarrow \text{por indução} \Rightarrow \mathbf{P}^{(n)} = \mathbf{P}^n.$$

**Exercício 2.**

Para a matriz de transições do exercício anterior, calcule a matriz de transições em dois passos.

**Solução.** A matriz de transições a um passo é

$$P = \begin{pmatrix} 6/7 & 1/7 \\ 2/3 & 1/3 \end{pmatrix}$$

Porém

$$\begin{aligned} P^{(2)} = P^2 &= \begin{pmatrix} \frac{6}{7} & \frac{1}{7} \\ \frac{2}{3} & \frac{1}{3} \end{pmatrix} \cdot \begin{pmatrix} \frac{6}{7} & \frac{1}{7} \\ \frac{2}{3} & \frac{1}{3} \end{pmatrix} = \begin{pmatrix} \frac{6}{7} \cdot \frac{6}{7} + \frac{1}{7} \cdot \frac{2}{3} & \frac{6}{7} \cdot \frac{1}{7} + \frac{1}{7} \cdot \frac{1}{3} \\ \frac{2}{3} \cdot \frac{6}{7} + \frac{1}{3} \cdot \frac{2}{3} & \frac{2}{3} \cdot \frac{1}{7} + \frac{1}{3} \cdot \frac{1}{3} \end{pmatrix} \\ &= \begin{pmatrix} \frac{122}{147} & \frac{25}{147} \\ \frac{50}{63} & \frac{13}{63} \end{pmatrix}. \end{aligned}$$

Note que

$$\frac{122}{147} + \frac{25}{147} = 1 \quad \frac{50}{63} + \frac{13}{63} = 1.$$

□



**Estado inicial.** Para achar a distribuição de probabilidades de estados de uma cadeia de Markov, junto com as probabilidades de transições, que são na realidade as probabilidades condicionais, precisa-se saber as probabilidades não-condicionais do sistema estar em um estado em instante inicial  $n = 0$  ou, em outras palavras, precisa-se saber a distribuição da variável  $X_0$ . Sejam

$$\alpha_i \equiv \mathbb{P}(X_0 = i), \quad i \geq 0 \text{ e } \sum_{i=0}^{\infty} \alpha_i = 1.$$

Todas as probabilidades não-condicionais podem ser calculadas condicionando pelo estado inicial:

$$\mathbb{P}(X_n = j) = \sum_{i=0}^{\infty} \mathbb{P}(X_n = j \mid X_0 = i) \mathbb{P}(X_0 = i) = \sum_{i=0}^{\infty} p_{ij}^{(n)} \alpha_i.$$

**Exercício 3.** Para a matriz de transições

$$\mathbf{P} = \begin{vmatrix} 6/7 & 1/7 \\ 2/3 & 1/3 \end{vmatrix}$$

calcule a probabilidade de que  $X_1 = 0$  sabendo que  $X_0$  tem distribuição uniforme.

**Solução.** Sabe-se que  $\alpha_0 = \mathbb{P}(X_0 = 0) = \alpha_1 = \mathbb{P}(X_0 = 1) = 1/2$  ou em forma vetorial  $(\alpha_0, \alpha_1) = (1/2, 1/2)$ . A distribuição depois de um passo é

$$\begin{aligned} \alpha\mathbf{P} = (\alpha_0, \alpha_1)\mathbf{P} &= (1/2, 1/2) \begin{vmatrix} 6/7 & 1/7 \\ 2/3 & 1/3 \end{vmatrix} \\ &= \left( \frac{1}{2} \cdot \frac{6}{7} + \frac{1}{2} \cdot \frac{2}{3}, \frac{1}{2} \cdot \frac{1}{7} + \frac{1}{2} \cdot \frac{1}{3} \right) \\ &= \left( \frac{16}{21}, \frac{5}{21} \right). \end{aligned}$$

□

**Exercício 3.** Para a matriz de transições

$$\mathbf{P} = \begin{pmatrix} 6/7 & 1/7 \\ 2/3 & 1/3 \end{pmatrix}$$

calcule a probabilidade de que  $X_2 = 0$  sabendo que  $X_0$  tem distribuição uniforme.

**Solução.** Sabe-se que  $\alpha_0 = \mathbb{P}(X_0 = 0) = \alpha_1 = \mathbb{P}(X_0 = 1) = 1/2$  ou em forma vetorial  $(\alpha_0, \alpha_1) = (1/2, 1/2)$ . A distribuição depois de um passo é

$$\begin{aligned} \alpha \mathbf{P}^2 &= (\alpha_0, \alpha_1) \mathbf{P}^2 = (1/2, 1/2) \begin{pmatrix} 6/7 & 1/7 \\ 2/3 & 1/3 \end{pmatrix}^2 \\ &= (1/2, 1/2) \begin{pmatrix} \frac{122}{63} & \frac{25}{63} \\ \frac{50}{63} & \frac{147}{63} \end{pmatrix} = \left( \frac{358}{441}, \frac{83}{441} \right). \end{aligned}$$

□

### Exercício 4.

Imagine seguinte experimento. Temos duas urnas, verde (com 4 bolas verdes e 1 amarela) e amarela (com 2 bolas amarelas e 1 verde). Experimento consiste em retirada sequencial de bolas de urnas com reposição seguindo seguinte regras:

1. para começar retiramos bola da urna verde e registramos o cor dela, denotamos  $X_0$ ; supomos que isso seja retirada com número 0;
2. seja  $X_i$  é cor registrada depois da  $i$ -ésima retirada, então, para registrar a próxima  $X_{i+1}$  cor seguimos:
  - (a) se  $X_i = \text{verde}$ , então  $X_{i+1}$  é cor da bola retirada da urna verde;
  - (b) se  $X_i = \text{amarelo}$ , então  $X_{i+1}$  é cor da bola retirada da urna amarela.

Descreve a cadeia, oferecendo: (i) conjunto de estados da cadeia; (ii) matriz de transição; e (iii) estado (distribuição) inicial.

**Exercício 5.**

3. A matriz de transição de uma cadeia de Markov com dois estados 1 e 2 é dada pela seguinte matriz

$$P = \begin{pmatrix} 0.4 & 0.6 \\ 0.3 & 0.7 \end{pmatrix}.$$

A distribuição de estado inicial é definido pelo vetor-linha  $\pi_0^T = (0.1, 0.9)$ . Achar:

1. matriz de transição para dois passos da cadeia;
2. distribuição de estados em instante  $t = 2$ ;
3. a probabilidade de que em instante  $t = 1$  estar em estado 2;

### **Exercício 6. Veja exemplo de Video 3.**

4. Supondo o modelo fora de realidade: depois de fazer seguro de vida um individuo tem a probabilidade de 90% estar vivo no próximo ano.

1. Representa o modelo como uma cadeia de Markov, oferecendo: (i) conjunto de estados da cadeia; (ii) matriz de transição; e (iii) estado (distribuição) inicial.
2. Supondo que cada ano individuo paga mil reais de seguro-vida. Achar a média e a variância de montante que a seguradora ganha desse indivíduo.
3. Supondo que em caso da morte a seguradora vai pagar 10 mil reais; achar a média de ganho da seguradora durante a vida desse individuo.
4. Supondo a validade desse modelo para cada individuo, construa a cadeia de Markov que descreve a vida de um casal oferecendo: (i) conjunto de estados da cadeia; (ii) matriz de transição; e (iii) estado (distribuição) inicial.