

# MODELOS ESTOCÁSTICOS APLICADOS À INDÚSTRIA

Prof. Lupércio França Bessegato

Departamento de Estatística  
Universidade Federal de Juiz de Fora  
lupercio.bessegato@ufjf.edu.br  
www.ufjf.br/lupercio\_bessegato

Setembro/2013



# ROTEIRO DA APRESENTAÇÃO

- 1 INTRODUÇÃO
- 2 CADEIAS DE MARKOV
- 3 MODELOS MARKOVIANOS DE DECISÃO
- 4 REFERÊNCIAS BIBLIOGRÁFICAS



1

## INTRODUÇÃO



# PROCESSOS ESTOCÁSTICOS

Sequência de eventos governados por leis probabilísticas

## OBJETIVO

- Investigar estrutura de variáveis aleatórias  $X_t$
- $t$  é um parâmetro em um conjunto de índices  $T$

## ALGUNS TIPOS DE PROCESSOS ESTOCÁSTICOS

Passeio aleatório, processo de renovação, processo de ramificação, filas, movimento Browniano, etc.

Amplas possibilidade de aplicações



## DEFINIÇÕES FUNDAMENTAIS

### DEFINIÇÃO (PROCESSO ESTOCÁSTICO)

Sequência de variáveis aleatórias  $\{X_t : t \in T\}$ , todas definidas em um mesmo espaço de probabilidades e indexadas por um conjunto  $T$

$$X_t : \Omega \rightarrow E \subset \mathbb{R}$$

### ESPAÇO DE ESTADOS ( $E$ )

Conjunto ao qual pertencem todos os possíveis valores de  $X_t$

### ESPAÇO PARAMÉTRICO DE TEMPO ( $T$ )

- Se  $T = 0, 1, \dots$ ,  $\{X_t\}$  é um processo estocástico em tempo discreto
- Se  $T = [0, \infty)$ ,  $\{X_t\}$  é um processo estocástico em tempo contínuo
- $T$  pode não ser unidimensional (Processo de Poisson espacial)



## TIPOS DE PROCESSOS

Atendendo a natureza de  $T$  e  $E$

### $E$ DISCRETO, $T$ DISCRETO

Geralmente:  $E = \mathbb{Z}$  e  $T = \mathbb{N}$

### $E$ DISCRETO, $T$ CONTÍNUO

Geralmente:  $E = \mathbb{Z}$  e  $T = \{t : t \geq 0\}$

### $E$ CONTÍNUO, $T$ DISCRETO

Geralmente:  $E = \mathbb{R}$  e  $T = \mathbb{N}$

### $E$ CONTÍNUO, $T$ CONTÍNUO

Geralmente:  $E = \mathbb{R}$  e  $T = \mathbb{R}_+ \cup \{0\}$



## DISTRIBUIÇÃO FINITO DIMENSIONAL

### DEFINIÇÃO

Para qualquer conjunto finito  $\{t_1, t_2, \dots, t_k\} \subset T$ , a distribuição do vetor  $X_{t_1}, X_{t_2}, \dots, X_{t_k}$  é denominada *distribuição finito dimensional* do processo.

- A totalidade das distribuições finito dimensionais de um processo determinam, sob condições gerais, a distribuição do processo.
- Um processo estocástico é denominado *Gaussiano* se todos os vetores finito dimensionais possuem distribuição normal multivariada
- Para um valor de  $t$  fixo, tem-se a distribuição unidimensional de  $X_t$ .



## ESTATÍSTICAS DE UM PROCESSO

Sejam  $\mu_t = E[X_t]$  e  $\sigma_t^2 = \text{Var}\{X_t\}$ , respectivamente, a média e a variância associadas à  $X_t$ .

### DEFINIÇÃO

- Função média do processo:  $\mu = \{\mu_t : t \in T\}$
- Função variância do processo:  $\sigma^2 = \{\sigma_t^2 : t \in T\}$
- Função covariância do processo:  $\sigma_{s,t} = \{\text{Cov}\{X_t, X_s\} : s, t \in T\}$



## PROCESSOS COM INCREMENTOS INDEPENDENTES

Considerando  $T = [0, \infty)$ , a menos que explicitado em contrário

### DEFINIÇÃO

Se  $X_{t_2} - X_{t_1}, X_{t_3} - X_{t_2}, \dots, X_{t_n} - X_{t_{n-1}}$  são independentes para todas as escolhas de  $0 \leq t_1 < t_2 < \dots < t_{n-1} < t_n$ , dizemos que o processo  $\{X_t\}$  possui *incrementos independentes*.

### CONSEQUÊNCIA

Seja um processo  $\{X_t\}$  a tempo discreto ( $T = \{0, 1, \dots\}$ ) com incrementos independentes.  
 $\{Z_i\}, Z_i = X_i - X_{i-1}$  é uma sequência de variáveis aleatórias independentes, com  $X_i = Z_0 + Z_1 + \dots + Z_i$



## PROCESSO COM INCREMENTOS ESTACIONÁRIOS

### DEFINIÇÃO

Diz-se que o processo tem incrementos estacionários se a distribuição dos incrementos  $X_{t_1+h} - X_{t_1}$  depende somente do comprimento  $h$  e não do tempo  $t_1$ .

### CONSEQUÊNCIA

Para um processo com incrementos estacionários,  
 $X_{t_1+h} - X_{t_1} \stackrel{d}{=} X_{t_2+h} - X_{t_2}$  para qualquer valor de  $t_1, t_2$ , e  $h$ .



## PROPRIEDADE DE MARKOV

### DEFINIÇÃO

Um processo estocástico possui a propriedade de Markov se  $P\{X_t \in A | X_{t_1} = x_1, X_{t_2} = x_2, \dots, X_{t_n} = x_n\} = P\{X_t \in A | X_{t_n} = x_n\}$ , para  $0 \leq t_1 < t_2 < \dots < t_n < t$ .

### CONSEQUÊNCIA

“O futuro não depende do passado quando se conhece o presente”



## DEFINIÇÕES

### DEFINIÇÃO (DISTRIBUIÇÃO INICIAL DO PROCESSO)

É a distribuição de  $X_0$ .

### DEFINIÇÃO (FUNÇÃO DE PROBABILIDADE DE TRANSIÇÃO)

$P(x, s, t, A) = P\{X_t \in A | X_s = x\}, T > s$

### CONSEQUÊNCIA

Conhecidas a distribuição inicial e a função de probabilidade de transição de um processo Markoviano, pode-se calcular todas suas distribuições finito dimensionais.



## DISTRIBUIÇÕES UNIDIMENSIONAIS

Processo Markoviano com espaço de estados finito  $E = \{0, 1, \dots, M\}$

$$\begin{aligned} P\{X_t = j\} &= \sum_{i=0}^M P\{X_0 = i, X_t = j\} \\ &= \sum_{i=0}^M P\{X_t = j | X_0 = i\} P\{X_0 = i\} \\ &= \sum_{i=0}^M P(i, 0, t, j) P\{X_0 = 1\} \end{aligned}$$



## DISTRIBUIÇÕES FINITO DIMENSIONAIS

Processo Markoviano com espaço de estados finito  $E = \{0, 1, \dots, M\}$

$$\begin{aligned} P\{X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_k} = i_k\} &= \\ &= \sum_{i=0}^M P\{X_0 = i, X_{t_1} = i_1, X_{t_2} = i_2, \dots, X_{t_k} = i_k\} \\ &= \sum_{i=0}^M P\{X_0 = i\} P\{X_{t_1} = i_1 | X_0 = i\} P\{X_{t_2} = i_2 | X_{t_1} = i_1\} \dots \\ &\quad P\{X_{t_k} = i_k | X_{t_{k-1}} = i_{k-1}\} \\ &= \sum_{i=0}^M P\{X_0 = i\} P(i, 0, t_1, i_1) P(i_1, t_1, t_2, i_2) \dots P(i_{k-1}, t_{k-1}, t_k, i_k) \end{aligned}$$



2

## CADEIAS DE MARKOV



## INTRODUÇÃO

Em geral, os modelos simples são os mais úteis na análise de problemas práticos

### PROCESSOS MARKOVIANOS

- Permite modelar a incerteza em muitos sistemas reais que evoluem dinamicamente no tempo
- Ampla variedade de campos de aplicação
- Conceitos básicos: estado e transição de estado

### PROPRIEDADE MARKOVIANA

O conhecimento do estado atual do processo é suficiente para prever o comportamento estocástico futuro do processo



## INTRODUÇÃO II

### OBJETIVO

Encontrar descrição adequada de estados de maneira que o processo estocástico associado tenha a propriedade Markoviana

### DESENVOLVIMENTO TEÓRICO

- Processo de Markov a tempo discreto
- Transições de estado ocorrem apenas em tempos fixos



## CADEIA DE MARKOV

Espaço de estados discreto e parâmetro de tempo discreto.

### DEFINIÇÃO

Diz-se que um processo estocástico  $\{X_t : t \in T\}$ , com espaço de estados  $E = \{0, 1, 2, \dots\}$  e  $T = \{0, 1, 2, \dots\}$ , é uma cadeia de Markov (de primeira ordem) se para  $\forall i, j, n$  tem-se que:

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

### NOTAÇÃO

$P_{ij}^{(n, n+1)} = P\{X_{n+1} = j | X_n = i\}$  é a probabilidade de transição de  $i$  para  $j$  no tempo  $n$ .



## CADEIA HOMOGÊNEA

### DEFINIÇÃO

A cadeia é homogênea no tempo quando as probabilidades de transição não dependem de  $t$ .

### CONSEQUÊNCIA

$$P_{ij} = P\{X_{t+1} = j | X_t = i\}, \forall t \in E$$



## PASSEIO ALEATÓRIO

### DEFINIÇÃO

$$X_i = X_{i-1} + Z_i, \text{ com}$$

- $X_0 = 0$
- $P\{Z_i = 1\} = P\{Z_i = -1\} = 1/2, \forall i$

### EXEMPLO (1)

$$P\{X_1 = 1 | X_0 = 0\} = P\{X_1 = -1 | X_0 = 0\} = \frac{1}{2}$$



## EXEMPLO (2)

$$P\{X_2 = 0|X_0 = 0\} = \frac{1}{2}$$

$$P\{X_2 = 0|X_0 = 0, X_1 = 1\} = P\{X_2 = 0|X_1 = 1\} = \frac{1}{2}$$

$$P\{X_2 = 0|X_0 = 0, X_1 = -1\} = P\{X_2 = 0|X_1 = -1\} = \frac{1}{2}$$


$$P\{X_2 = 0|X_0 = 0\} = P\{X_2 = 0|X_1 = 1\}P\{X_1 = 1|X_0 = 0\} + P\{X_2 = 0|X_1 = -1\}P\{X_1 = -1|X_0 = 0\}$$

$$P\{X_t = 0|X_0 = 0\} = \frac{1}{2}, \forall t \in E$$

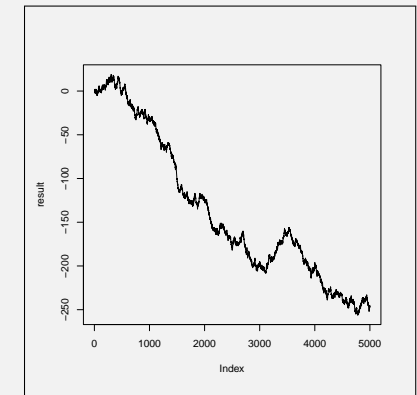


## TRAJETÓRIAS DE PASSEIOS ALEATÓRIOS

5.000 passos com  $p = 0,50$



5.000 passos com  $p = 0,48$



## MATRIZ DE PROBABILIDADES DE TRANSIÇÃO

### DEFINIÇÃO

Se a cadeia é homogênea no tempo, a matriz de probabilidade de transição (em um passo) é:

$$P = (P_{ij}), i, j \in E$$

### PROPRIEDADES DE P

- 1  $P_{ij} \geq 0, \forall i, j$
- 2  $\sum_{j \in E} P_{ij} = 1, \forall i \in E$ , ou seja, para  $i$  fixo,  $\{P_{ij} : j \in E\}$  define uma função de probabilidade.

Toda matriz que satisfaz (1) e (2) é chamada **matriz estocástica**



## DISTRIBUIÇÃO MARGINAL DE $X_0$

### FUNÇÃO DE PROBABILIDADE DE $X_0$

$$\alpha'_0 = [\alpha_0(i); i \in E], \text{ com } \alpha_0(i) = P\{X_0 = i\},$$

em que  $\alpha$  é o vetor que define a função de probabilidade de  $X_0$ .

A função de probabilidade de  $X_0$  é chamada **função de probabilidade inicial** da cadeia



## DISTRIBUIÇÃO MARGINAL DE $X_1$

### FUNÇÃO DE PROBABILIDADE DE $X_1$

$$\begin{aligned}\alpha_1(j) &= \mathbf{P}\{X_1 = j\} \\ &= \sum_{i \in E} \mathbf{P}\{X_0 = i, X_1 = j\} \\ &= \sum_{i \in E} \mathbf{P}\{X_0 = i\} \mathbf{P}\{X_1 = j | X_0 = i\} \\ \alpha_1(j) &= \sum_{i \in E} \alpha_0(i) P_{ij}\end{aligned}$$



## EXEMPLO

### DADOS

Suponha  $E = \{0, 1, 2, 3\}$ ,  $\alpha'_0 = [0, 2; 0, 1; 0, 3; 0, 4]$  e

$$\mathbf{P} = \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$

$$\alpha_1(0) = \mathbf{P}\{X_1 = 0\} = [0, 2; 0, 1; 0, 3; 0, 4] \begin{bmatrix} 0,1 \\ 0 \\ 0,3 \\ 0,6 \end{bmatrix} = 0,35$$



## EXEMPLO (CONT.)

### DISTRIBUIÇÃO MARGINAL DE $X_1$

$$\alpha'_1 = [0, 2; 0, 1; 0, 3; 0, 4] \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$
$$\alpha_1' = [0, 35; 0, 11; 0, 26; 0, 28]$$



## DISTRIBUIÇÃO MARGINAL DE $X_2$

### FUNÇÃO DE PROBABILIDADE DE $X_2$

$$\begin{aligned}\alpha_2(j) &= \mathbf{P}\{X_2 = j\} \\ &= \sum_{i \in E} \mathbf{P}\{X_1 = i, X_2 = j\} \\ \alpha_2(j) &= \sum_{i \in E} \alpha_1(i) P_{ij}\end{aligned}$$



## EXEMPLO

### DADOS

Exemplo anterior, com  $\alpha'_1 = [0, 35; 0, 11; 0, 26; 0, 28]$  e

$$\mathbf{P} = \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$

$$\alpha_2(0) = P\{X_2 = 1\} = [0, 35; 0, 11; 0, 26; 0, 28] \begin{bmatrix} 0,1 \\ 0 \\ 0,3 \\ 0,6 \end{bmatrix} = 0,281$$



## EXEMPLO (CONT.)

### DISTRIBUIÇÃO MARGINAL DE $X_2$

$$\alpha'_2 = [0, 35; 0, 11; 0, 26; 0, 28] \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$
$$\alpha_2' = [0,281; 0,153; 0,208; 0,358]$$



## DISTRIBUIÇÃO MARGINAL E CONJUNTA

Dadas a distribuição inicial da cadeia e a matriz de probabilidades de transição, pode-se calcular:

- a distribuição marginal de  $X_k, k \geq 1$
- a distribuição conjunta de  $(X_1, X_2, \dots, X_k)$



## DISTRIBUIÇÕES MARGINAIS

### DISTRIBUIÇÕES MARGINAIS DA CADEIA

Em notação matricial.

$$\alpha'_1 = \alpha'_0 \mathbf{P}$$
$$\alpha'_2 = \alpha'_1 \mathbf{P} = (\alpha'_0 \mathbf{P}) \mathbf{P} = \alpha'_0 \mathbf{P}^2$$
$$\vdots$$
$$\alpha'_k = \alpha'_{k-1} \mathbf{P} = \alpha'_{k-2} \mathbf{P}^2 = \dots = \alpha'_0 \mathbf{P}^k$$

### FUNÇÃO DE PROBABILIDADE DE $X_k$

$$\alpha'_k = \alpha'_0 \mathbf{P}^k$$





## $\alpha'_1$ É FUNÇÃO DE PROBABILIDADE?

$$\begin{aligned}\alpha'_1 &= \alpha'_0 \mathbf{P} \\ \sum_{j \in E} \alpha_1(j) &= \sum_{j \in E} \left( \sum_{i \in E} \alpha_0(i) P_{ij} \right) = \sum_{i \in E} \sum_{j \in E} \alpha_0(i) P_{ij} \\ &= \sum_{i \in E} \alpha_0(i) \sum_{j \in E} P_{ij}\end{aligned}$$

Mas  $\sum_{j \in E} P_{ij} = 1$ . Assim:

$$\sum_{j \in E} \alpha_1(j) = \sum_{i \in E} \alpha_0(i) = 1$$



## DISTRIBUIÇÃO CONJUNTA

### TRAJETÓRIA EM 2 PASSOS

$$\begin{aligned}P\{X_0 = i, X_1 = j, X_2 = k\} &= P\{X_0 = i\} P\{X_1 = j | X_0 = i\} P\{X_2 = k | X_0 = i, X_1 = j\} \\ &= P\{X_0 = i\} P\{X_1 = j | X_0 = i\} P\{X_2 = k | X_1 = j\} \\ &= \alpha_0(i) P_{ij} P_{jk}\end{aligned}$$

### TRAJETÓRIA EM $r$ PASSOS

$$\begin{aligned}P\{X_0 = i_0, X_1 = i_1, \dots, X_r = i_r\} &= P\{X_0 = i_0\} P\{X_1 = i_1 | X_0 = i_0\} \dots \\ &\quad P\{X_r = i_r | X_{r-1} = i_{r-1}\} \\ &= \alpha_0(i_0) P_{i_0, i_1} P_{i_1, i_2} \dots P_{i_{r-1}, i_r}\end{aligned}$$



## EXEMPLO

### DADOS

Calcular  $P\{X_0 = 1, X_1 = 0, X_2 = 0\}$ , com  $E = \{1, 2, 3, 4\}$ ,

$$\alpha'_0 = [0, 2; 0, 1; 0, 3; 0, 4] \text{ e } \mathbf{P} = \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$

### SOLUÇÃO

$$\begin{aligned}P\{X_0 = 1, X_1 = 0, X_2 = 0\} &= P\{X_0 = 1\} P\{X_1 = 0 | X_0 = 1\} P\{X_2 = 0 | X_1 = 0\} \\ &= \alpha_0(1) P_{10} P_{00} = 0\end{aligned}$$



## PROBABILIDADES DE TRANSIÇÃO DE $2^a$ ORDEM

$$\begin{aligned}P\{X_2 = j | X_0 = i\} &= \sum_{k \in E} P\{X_1 = k, X_2 = j | X_0 = i\} \\ &= \sum_{k \in E} P\{X_1 = k | X_0 = i\} P\{X_2 = j | X_1 = k\} \\ &= \sum_{k \in E} P_{ik} P_{kj}\end{aligned}$$

$P\{X_2 = j | X_0 = i\}$  é a célula  $(i, j)$  da matriz  $\mathbf{P}^2$



## TRANSIÇÃO DE 2ª. ORDEM

### MATRIZ DE PROBABILIDADES DE TRANSIÇÃO

#### NOTAÇÃO

$$P_{ij}^{(2)} = P\{X_{n+2} = j | X_n = i\}$$

A matriz  $P^2$  é formada pelas probabilidades de transição de 2ª. ordem.



## PROBABILIDADE DE TRANSIÇÃO DE 2ª. ORDEM

#### DADO

$$P = \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$

#### MATRIZ DE TRANSIÇÃO DE 2ª. ORDEM

$$P^2 = \begin{bmatrix} 0,37 & 0,09 & 0,36 & 0,18 \\ 0,36 & 0,08 & 0,32 & 0,24 \\ 0,33 & 0,13 & 0,24 & 0,30 \\ 0,18 & 0,22 & 0,08 & 0,52 \end{bmatrix}$$

$$P\{X_2 = 0 | X_0 = 1\} = P_{10}^{(2)} = 0,36$$



## PROBABILIDADE DE TRANSIÇÃO DE 3ª. ORDEM

$$\begin{aligned} P\{X_3 = j | X_0 = i\} &= \sum_{k \in E} P\{X_2 = k, X_3 = j | X_0 = i\} \\ &= \sum_{k \in E} P\{X_2 = k | X_0 = i\} P\{X_3 = j | X_2 = k\} \\ &= \sum_{k \in E} P_{ik}^{(2)} P_{kj} = (P^3)_{ij} \\ &= P_{ij}^{(3)} \end{aligned}$$

#### NOTAÇÃO

$$P_{ij}^{(3)} = P\{X_{n+3} = j | X_n = i\}$$



## PROBABILIDADE DE TRANSIÇÃO DE 3ª. ORDEM

#### DADO

$$P = \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$

#### MATRIZ DE TRANSIÇÃO DE 3ª. ORDEM

$$P^3 = \begin{bmatrix} 0,253 & 0,165 & 0,180 & 0,402 \\ 0,276 & 0,156 & 0,192 & 0,376 \\ 0,285 & 0,149 & 0,220 & 0,346 \\ 0,354 & 0,106 & 0,312 & 0,228 \end{bmatrix}$$

$$P\{X_3 = 0 | X_0 = 1\} = P_{10}^{(3)} = 0,276$$



## PROBABILIDADE DE TRANSIÇÃO DE ORDEM $r$

Em geral,

$$P_{ij}^{(r)} = P\{X_r = j | X_0 = i\}$$

### CONSEQUÊNCIA

- 1  $P\{X_0 = i, X_r = j\} = \alpha_0(i)P_{ij}^{(r)}$
- 2  $P\{X_{n+r} = j | X_n = i\} = P_{ij}^{(r)}$



## PROBABILIDADE DE TRANSIÇÃO DE 50ª. ORDEM

DADO

$$\mathbf{P} = \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$

MATRIZ DE TRANSIÇÃO DE 3ª. ORDEM

$$\mathbf{P}^{50} = \begin{bmatrix} 0,297 & 0,141 & 0,234 & 0,328 \\ 0,297 & 0,141 & 0,234 & 0,328 \\ 0,297 & 0,141 & 0,234 & 0,328 \\ 0,297 & 0,141 & 0,234 & 0,328 \end{bmatrix}$$

$$P\{X_{50} = 0 | X_0 = i\} = P_{i0}^{(50)} = 0,297, \forall i \in E$$

## EQUAÇÃO DE CHAPMAN-KOLMOGOROV

Estabelece as probabilidades de transição de um estado  $i$  para um estado  $j$  em  $n + r$  passos.

$$P_{ij}^{(n+r)} = \sum_{k \in E} P_{ik}^{(n)} P_{kj}^{(r)}$$

### EXEMPLO

$$\begin{aligned} P\{X_0 = i_0, X_3 = i_3, X_5 = i_5\} &= P\{X_0 = i_0\} P\{X_3 = i_3 | X_0 = i_0\} P\{X_5 = i_5 | X_3 = i_3\} \\ &= \alpha_0(i_0) P_{i_0 i_3}^{(3)} P_{i_3 i_5}^{(2)} \end{aligned}$$



## EXEMPLO

DADOS

Calcular  $P\{X_0 = 1, X_3 = 0, X_6 = 1, X_8 = 3\}$ , com  $E = \{1, 2, 3, 4\}$ ,

$$\alpha'_0 = [0, 2; 0, 1; 0, 3; 0, 4] \text{ e } \mathbf{P} = \begin{bmatrix} 0,1 & 0,3 & 0 & 0,6 \\ 0 & 0,2 & 0,4 & 0,4 \\ 0,3 & 0,1 & 0,2 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \end{bmatrix}$$

SOLUÇÃO

$$\begin{aligned} P\{X_0 = 1, X_3 = 0, X_6 = 1, X_8 = 3\} &= P\{X_0 = 1\} P\{X_3 = 0 | X_0 = 1\} P\{X_6 = 1 | X_3 = 0\} \\ &\quad P\{X_8 = 3 | X_6 = 1\} \\ &= \alpha_0(1) P_{10}^{(3)} P_{01}^{(3)} P_{13}^{(2)} = (0,1)(0,276)(0,165)(0,376) \\ &= 0,002 \end{aligned}$$




## EXEMPLO - RATO

### RATO EM LABIRINTO

Um rato é colocado no labirinto abaixo. Ele move-se ao acaso através dos compartimentos. Ele faz uma troca de compartimento em cada instante de tempo. O estado do sistema é o número do compartimento em que o rato está.

Determine a matriz de probabilidades de transição deste processo.



## SOLUÇÃO

$$\mathbf{P} = \begin{matrix} 1 & \left[ \begin{array}{cccccccc} 0 & 1/2 & 0 & 1/2 & 0 & 0 & 0 & 0 & 0 \\ 1/3 & 0 & 1/3 & 0 & 1/3 & 0 & 0 & 0 & 0 \\ 0 & 1/2 & 0 & 1/2 & 0 & 0 & 0 & 0 & 0 \\ 1/3 & 0 & 0 & 0 & 1/3 & 0 & 1/3 & 0 & 0 \\ 0 & 1/4 & 0 & 1/4 & 0 & 1/4 & 0 & 1/4 & 0 \\ 0 & 0 & 1/3 & 0 & 1/3 & 0 & 0 & 0 & 1/3 \\ 0 & 0 & 0 & 1/2 & 0 & 0 & 0 & 1/2 & 0 \\ 0 & 0 & 0 & 0 & 1/3 & 0 & 1/3 & 0 & 1/3 \\ 0 & 0 & 0 & 0 & 0 & 1/2 & 0 & 1/2 & 0 \end{array} \right. \end{matrix}$$



## EXEMPLO - CLIMA


### CLIMA EM MONTES CLAROS

A probabilidade de não chover amanhã é de 0,8, caso hoje esteja seco. Porém é de apenas 0,6, caso hoje seja chuvoso.

### ESTADOS

$$X_t = \begin{cases} 0 & , \text{ se dia } t \text{ é seco} \\ 1 & , \text{ se dia } t \text{ é chuvoso} \end{cases}$$

### TOPOLOGIA DA CADEIA



## EXEMPLO - CLIMA II

### MATRIZ DE PROBABILIDADES DE TRANSIÇÃO

$$\mathbf{P} = \begin{matrix} 0 & \left[ \begin{array}{cc} 0,8 & 0,2 \\ 0,6 & 0,4 \end{array} \right. \\ 1 & \end{matrix}$$

Quais serão as probabilidades de transição de 365ª ordem (daqui um ano)?



## ALGUMAS APLICAÇÕES DE CADEIA DE MARKOV

### APLICAÇÕES

- Modelo de estoque
- Modelos de manutenção
- Modelos de evolução de ativos
- Modelos crédito



## EXEMPLO - OFICINA

### FALHA DE EQUIPAMENTOS

Há 3 máquinas, que podem falhar a cada dia com uma probabilidade de 0.1, independente uma das outras. Oficina de reparo com capacidade de apenas uma máquina por dia. Máquina reparada não falha no próximo dia. Máquina 1 tem prioridade (gargalo na produção). Máquina 3 tem a menor prioridade.

### ESTADOS

- |                          |                             |
|--------------------------|-----------------------------|
| 1: máquina 1 falha       | 5: máquinas 1 e 3 falham    |
| 2: máquina 2 falha       | 6: máquinas 2 e 3 falham    |
| 3: máquina 3 falha       | 7: todas máquinas falham    |
| 4: máquinas 1 e 2 falham | 8: todas máquinas trabalham |



## EXEMPLO - OFICINA II

### MATRIZ DE PROBABILIDADES DE TRANSIÇÃO

$$P = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \\ 8 \end{matrix} & \begin{bmatrix} 0 & 0,09 & 0,09 & 0 & 0 & 0,01 & 0 & 0,81 \\ 0,09 & 0 & 0,09 & 0 & 0,01 & 0 & 0 & 0,81 \\ 0,09 & 0,09 & 0 & 0,01 & 0 & 0 & 0 & 0,81 \\ 0 & 0,9 & 0 & 0 & 0 & 0,1 & 0 & 0 \\ 0 & 0 & 0,9 & 0 & 0 & 0,1 & 0 & 0 \\ 0 & 0 & 0,9 & 0 & 0,1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0,081 & 0,081 & 0,081 & 0,009 & 0,009 & 0,009 & 0,001 & 0,729 \end{bmatrix} \end{matrix}$$



## EXEMPLO - OFICINA III

### PROBABILIDADES DE TRANSIÇÃO ATÉ O 50º DIA

$$P = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \\ 8 \end{matrix} & \begin{bmatrix} 0,074 & 0,081 & 0,089 & 0,007 & 0,008 & 0,010 & 0,001 & 0,73 \\ 0,074 & 0,081 & 0,089 & 0,007 & 0,008 & 0,010 & 0,001 & 0,73 \\ 0,074 & 0,081 & 0,089 & 0,007 & 0,008 & 0,010 & 0,001 & 0,73 \\ 0,074 & 0,081 & 0,089 & 0,007 & 0,008 & 0,010 & 0,001 & 0,73 \\ 0,074 & 0,081 & 0,089 & 0,007 & 0,008 & 0,010 & 0,001 & 0,73 \\ 0,074 & 0,081 & 0,089 & 0,007 & 0,008 & 0,010 & 0,001 & 0,73 \\ 0,074 & 0,081 & 0,089 & 0,007 & 0,008 & 0,010 & 0,001 & 0,73 \\ 0,074 & 0,081 & 0,089 & 0,007 & 0,008 & 0,010 & 0,001 & 0,73 \end{bmatrix} \end{matrix}$$



## CLASSIFICAÇÃO DE ESTADOS

### DEFINIÇÃO (ACESSIBILIDADE)

O estado  $j$  é acessível desde o estado  $i$  se existe uma trajetória indo do estado  $i$  para o estado  $j$ .

- Existe  $n_{ij} > 0$  tal que  $P_{ij}^{(n_{ij})} > 0$ .
- Notação:  $i \rightarrow j$ .

### DEFINIÇÃO (COMUNICAÇÃO)

Os estados  $i$  e  $j$  comunicam-se entre eles se  $i \rightarrow j$  e  $j \rightarrow i$ .

- Existem  $n_{ij}$  e  $n_{ji}$  tal que  $P_{ij}^{(n_{ij})} > 0$  e  $P_{ji}^{(n_{ji})} > 0$ .
- Notação:  $i \leftrightarrow j$ .



## RELAÇÃO DE COMUNICAÇÃO

A relação de comunicação define uma relação de equivalência, isto é:

- $i \leftrightarrow i$
- Se  $i \leftrightarrow j$ , então  $j \leftrightarrow i$
- Se  $i \leftrightarrow j$  e  $j \leftrightarrow k$ , então  $i \leftrightarrow k$



## DECOMPOSIÇÃO DO ESPAÇO DE ESTADOS

A relação de estados comunicantes induz uma partição do espaço de estados:

$$E = C_1 \cup C_2 \cup \dots \cup C_r \cup T$$

### CLASSES DE EQUIVALÊNCIA ( $C$ )

Todos os estados em  $C_i$  comunicam-se entre si, mas nenhum de seus estados é acessível desde qualquer estado pertencente à  $C_j, j \neq i$ .

### ESTADOS TRANSITÓRIOS

Conjunto  $T$  é formado por estados a partir dos quais há trajetórias para algum estado das classes  $C_i, i = 1, 2, \dots, r$ .

(Dessas classes não é possível retornar ao conjunto  $T$ )



## EXEMPLO

### DADO

$$P = \begin{bmatrix} 0 & 0,3 & 0,2 & 0,5 & 0 & 0 & 0 \\ 1 & 0,2 & 0,4 & 0,4 & 0 & 0 & 0 \\ 2 & 0,6 & 0 & 0,4 & 0 & 0 & 0 \\ 3 & 0 & 0 & 0 & 0 & 1 & 0 \\ 4 & 0 & 0 & 0 & 1 & 0 & 0 \\ 5 & 0,1 & 0,2 & 0,3 & 0,1 & 0 & 0,3 \end{bmatrix}$$

### SOLUÇÃO

$$0 \leftrightarrow 1 \leftrightarrow 2$$

$$3 \leftrightarrow 4$$

$$5 \rightarrow 0 \not\leftrightarrow 5$$

$$5 \rightarrow 3 \rightarrow 4 \not\leftrightarrow 5$$

$$C_1 = \{0, 1, 2\}$$

$$C_2 = \{3, 4\}$$

$$T = \{5\}$$



## EXEMPLO II

Comportamento da cadeia à longo prazo

DADO

$$P = \begin{matrix} & \begin{matrix} 0 & 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix} & \begin{bmatrix} 0,3 & 0,2 & 0,5 & 0 & 0 & 0 \\ 0,2 & 0,4 & 0,4 & 0 & 0 & 0 \\ 0,6 & 0 & 0,4 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0,1 & 0,2 & 0,3 & 0,1 & 0 & 0,3 \end{bmatrix} \end{matrix}$$

$$P^{50} = \begin{matrix} & \begin{matrix} 0 & 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix} & \begin{bmatrix} 0,419 & 0,140 & 0,442 & 0 & 0 & 0 \\ 0,419 & 0,140 & 0,442 & 0 & 0 & 0 \\ 0,419 & 0,140 & 0,442 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0,359 & 0,119 & 0,379 & 0,033 & 0,110 & 0 \end{bmatrix} \end{matrix}$$



## IRREDUTIBILIDADE

DEFINIÇÃO

Uma cadeia de Markov é **irredutível** se existe uma única classe de equivalência, isto é,  $E = C_1$

A cadeia é irredutível se **todos** os estados comunicam-se entre si.



## PERIODICIDADE

DEFINIÇÃO

Período do estado  $i$  é definido como:

$$d(i) = \begin{cases} \text{m.d.c. } \{n\} & , \text{ se } P_{ii}^{(n)} > 0, \\ 0 & , \text{ se } P_{ii}^{(n)} = 0 \end{cases}$$

onde m.d.c. é o máximo divisor comum.

DEFINIÇÃO

Um estado  $i \in E$  é **aperiódico** se  $d(i) = 1$ .

PROPRIEDADE

Se  $i \leftrightarrow j$ , então  $d(i) = d(j)$ .



## EXEMPLO

DADO

$$P = \begin{matrix} & \begin{matrix} 0 & 1 & 2 & 3 & 4 \end{matrix} \\ \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \end{matrix} & \begin{bmatrix} 0 & 0,3 & 0 & 0,4 \\ 0,6 & 0 & 0,4 & 0 \\ 0 & 0,5 & 0 & 0,5 \\ 0,3 & 0 & 0 & 0,7 \end{bmatrix} \end{matrix}$$

```
> potmatriz(matriz4,2)
[,1] [,2] [,3] [,4]
[1,] 0.39 0.00 0.61 0.00
[2,] 0.00 0.38 0.00 0.62
[3,] 0.45 0.00 0.55 0.00
[4,] 0.00 0.44 0.00 0.56

> potmatriz(matriz4,3)
[,1] [,2] [,3] [,4]
[1,] 0.000 0.422 0.000 0.578
[2,] 0.414 0.000 0.586 0.000
[3,] 0.000 0.410 0.000 0.590
[4,] 0.432 0.000 0.568 0.000
```

```
potmatriz(matriz4,50)
[,1] [,2] [,3] [,4]
1,] 0.425 0.000 0.575 0.000
2,] 0.000 0.415 0.000 0.585
3,] 0.425 0.000 0.575 0.000
4,] 0.000 0.415 0.000 0.585

potmatriz(matriz4,51)
[,1] [,2] [,3] [,4]
1,] 0.000 0.415 0.000 0.585
2,] 0.425 0.000 0.575 0.000
3,] 0.000 0.415 0.000 0.585
4,] 0.425 0.000 0.575 0.000
```

$$\begin{cases} P_{00} = 0 \\ P_{00}^{(2)} \geq P_{01}P_{10} > 0 \end{cases} \\ d(0) = \text{m.d.c. } \{2, 4, \dots\} \\ \Rightarrow d(0) = 2$$



## CADEIAS APERIÓDICAS

### DEFINIÇÃO

Diz-se que uma cadeia é **aperiódica** se ela é irredutível e um de seus estados tem período 1.

Nossos estudos estarão concentrados em cadeias aperiódicas.



## RECORRÊNCIA I

### DEFINIÇÃO

Suponha que  $X_0 = i, i \in E$ . O tempo de primeiro retorno ao estado  $i$ , é definido como  $\tau_i = \min\{n : X_n = i\}$ .

### DEFINIÇÃO

Um estado  $i$  é **recorrente** se, e somente se,  $\sum_{n=0}^{\infty} P_{ii}^{(n)} = \infty$ , ou, equivalentemente,  $P\{\tau_i < \infty | X_0 = i\} = 1$ .

### DEFINIÇÃO

Seja  $i$  um estado recorrente. Diz-se que  $i$  é **recorrente positivo** se  $\lim_{n \rightarrow \infty} P_{ii}^{(n)} = \pi(i) > 0$ . Se  $\lim_{n \rightarrow \infty} P_{ii}^{(n)} = 0$ , diz-se que o estado  $i$  é **recorrente nulo**.



## RECORRÊNCIA II

### PROPRIEDADE

Recorrência é uma propriedade de classe, isto é, se  $i \leftrightarrow j$  e  $i$  é recorrente, então  $j$  também é recorrente.

Se  $i$  é recorrente positivo (nulo) e  $i \leftrightarrow j$ , então  $j$  também é recorrente positivo (nulo).

### DEFINIÇÃO

Se um estado não é recorrente, ele é **transitório**.



## RECORRÊNCIA DE CADEIAS FINITAS

### DEFINIÇÃO

Em uma cadeia de Markov com espaço de estados **finito**, existe pelo menos um estado **recorrente**.

### COROLÁRIO

Se uma cadeia finita é irredutível, então todos os estados são recorrentes positivos.





## CADEIAS ERGÓDICAS

### DEFINIÇÃO (CADEIA ERGÓDICA)

Uma cadeia, não necessariamente finita, é **ergódica** se ela é irreduzível, aperiódica e recorrente

### DEFINIÇÃO (CADEIA FORTEMENTE ERGÓDICA)

Diz-se que uma cadeia é **fortemente ergódica**, se ela é ergódica e se pelo menos um de seus estados (e portanto todos) é recorrente positivo.



## EXEMPLO

### DADO

$$P = \begin{bmatrix} 0,3 & 0,2 & 0,5 \\ 0,2 & 0,4 & 0,4 \\ 0,6 & 0 & 0,4 \end{bmatrix}$$

$$P^{50} = \begin{bmatrix} 0,419 & 0,140 & 0,442 \\ 0,419 & 0,140 & 0,442 \\ 0,419 & 0,140 & 0,442 \end{bmatrix}$$

- Cadeia é finita irreduzível, logo todos os estados são recorrentes positivos (nenhum é transitório).
- $P_{ii}^n > 0, \forall n$



## DISTRIBUIÇÃO INVARIANTE I

### DEFINIÇÃO

Se uma cadeia é fortemente ergódica, então, para cada estado  $i$  existe  $\lim_{n \rightarrow \infty} P_{ii}^{(n)} = \pi(i) > 0$ .

Esse limite não depende do estado inicial da cadeia, ou seja,  $\lim_{n \rightarrow \infty} P_{ji}^{(n)} = \pi(i)$ .

### DEFINIÇÃO (DISTRIBUIÇÃO INVARIANTE)

Dessa maneira, define-se a distribuição invariante da cadeia, que é representada por:

$$\pi' = [\pi(0), \pi(1), \dots, \pi(i), \dots], i \in E.$$



## DISTRIBUIÇÃO INVARIANTE II

### TEOREMA

Se a cadeia for fortemente ergódica, então, para  $\forall i, j \in E$ :

1

$$\pi(i) = \frac{1}{E_i(\tau_i)},$$

com  $E_i(\tau_i) = E[\tau_i | X_0 = i]$  e  $\tau_i = \min\{n : X_n = i\}$

2  $\lim_{n \rightarrow \infty} P_{ji}^{(n)} = \pi(i)$ , ou seja, esse limite não depende do estado inicial da cadeia



## DISTRIBUIÇÃO INVARIANTE III

Se a cadeia é finita, aperiódica e irredutível, existe a distribuição invariante, que pode ser obtida das seguintes maneiras:

- 1 Calcula-se  $\lim_{n \rightarrow \infty} \mathbf{P}^n$ . Essa matriz existe e tem a forma  $\mathbf{1}\pi'$ , onde  $\mathbf{1}$  é um vetor de uns. O vetor  $\pi$  é qualquer das linhas dessa matriz-limite.
- 2 O vetor  $\pi$  é a solução dos sistema de equações lineares  $\pi' = \pi' \mathbf{P}$ , sujeito à restrição  $\sum_{i \in E} \pi(i) = 1$ . A condição de ergodicidade forte garante que a solução existe e é única.

As probabilidades  $\pi(i)$ ,  $i \in E$  podem ser vistas com a proporção de vezes que a cadeia passa pelo estado  $i$  em uma quantidade suficientemente grande de passos.



## EXEMPLO

### EQUAÇÃO DA INVARIANTE

$$[\pi(0), \pi(1), \pi(2)] = [\pi(0), \pi(1), \pi(2)] \begin{bmatrix} 0,3 & 0,2 & 0,5 \\ 0,2 & 0,4 & 0,4 \\ 0,6 & 0 & 0,4 \end{bmatrix}$$

$$\begin{cases} 0,3\pi(0) + 0,2\pi(1) + 0,6\pi(2) = \pi(0) \\ 0,2\pi(0) + 0,4\pi(1) + 0\pi(2) = \pi(1) \\ 0,5\pi(0) + 0,4\pi(1) + 0,4\pi(2) = \pi(2) \\ \pi(0) + \pi(1) + \pi(2) = 1 \end{cases}$$

### SOLUÇÃO

$$\pi' = [0,4186, 0,1395, 0,4419]$$



3

## MODELOS MARKOVIANOS DE DECISÃO



## PROCESSOS MARKOVIANOS DE DECISÃO

Em geral, o modelo de Markov é apropriado para sistemas dinâmicos com movimentos regulados por determinada lei probabilística.

Mesmo em presença de dinamismo e incerteza, há situações em que as transições dos estados podem ser controladas por uma sequência de ações.

### MODELO DE DECISÃO DE MARKOV

É uma ferramenta poderosa para analisar processos probabilísticos de decisão sequencial com um horizonte infinito de planejamento.



## MODELO DE DECISÃO

### APLICAÇÕES POTENCIAIS

- Controle de estoque
- Manutenção
- Fabricação
- Comunicação

### CRITÉRIO DE OTIMIZAÇÃO

Custo (ou recompensa) médio à longo prazo (*long-run*) por unidade de tempo

### OUTROS CRITÉRIOS

- Custo esperado total
- Custo descontado (fluxo de caixa) esperado total

## UM MODELO DE ESTOQUE

Produto é estocado para satisfazer demanda continuada.

### DEMANDA

$D_{t+1}$ : demanda agregada entre os instantes  $t$  e  $t + 1$   
 $\{D_t\}_{t \geq 1}$  são independentes e identicamente distribuídas

### ESTOQUE

Dado  $X_t = i$ ,  $X_{t+1}$  depende apenas da demanda em  $t + 1$ , ou seja, não é afetada pelo histórico do estoque anterior ao instante  $t$ .

### REPOSIÇÃO DO ESTOQUE

Ocorre no imediatamente após o pedido.

## POLÍTICA DE ESTOQUE

### ESTRATÉGIA $(s, S)$

Se no instante  $t$  o estoque ( $X_t$ ) é menor ou igual a  $s$ , então ele é trazido para o nível  $S$  no instante  $t + 0$ . Caso contrário, não se toma nenhuma ação.

### HIPÓTESES

- O estoque inicial ( $X_0$ ) não é maior que  $S$
- Não há reposição instantânea, caso a demanda no instante  $t$  seja maior que o estoque.

### CONSEQUÊNCIA

Espaço de estado de  $\{X_t\}_{t \geq 1}$ :  $E = \{S, S - 1, S - 2, \dots, 0\}$

## EVOLUÇÃO DO ESTOQUE

### EQUAÇÃO DINÂMICA DO MODELO

$$X_{t+1} = \begin{cases} \max\{X_t - D_{t+1}, 0\} & , \text{ se } s < X_t \leq S \\ \max\{S - D_{t+1}, 0\} & , \text{ se } X_t \leq s \end{cases}$$

## EXEMPLO - ESTOQUE

### O PROBLEMA

- $X_t$ : quantidade itens de produto X em estoque no final da semana  $t$
- $D_t$ : demanda do produto X na semana  $t$ , com  $D_t \sim \text{Poisson}(1)$
- $(0, 3)$ : política  $(s, S)$  de estoque

Demanda

$D_t = i$	$P\{D_t = i\}$
0	0,368
1	0,368
2	0,184
$\geq 3$	0,080



## ESTOQUE - MODELO PROBABILÍSTICO

### SITUAÇÕES PARA TRANSIÇÕES

$$\mathbf{P} = \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \end{matrix} \begin{bmatrix} D_t \geq 3 & D_t = 2 & D_t = 1 & D_t = 0 \\ D_t \geq 1 & D_t = 0 & 0 & 0 \\ D_t \geq 2 & D_t = 1 & D_t = 0 & 0 \\ D_t \geq 3 & D_t = 2 & D_t = 1 & D_t = 0 \end{bmatrix}$$

### MATRIZ DE PROBABILIDADES DE TRANSIÇÃO

$$\mathbf{P} = \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \end{matrix} \begin{bmatrix} 0,080 & 0,184 & 0,368 & 0,368 \\ 0,632 & 0,368 & 0 & 0 \\ 0,264 & 0,368 & 0,368 & 0 \\ 0,080 & 0,184 & 0,368 & 0,368 \end{bmatrix}$$



## ESTOQUE - INVARIANTE

### DISTRIBUIÇÃO ESTACIONÁRIA DA CADEIA

$$\pi' = [0,286; 0,285; 0,263; 0,166]$$

Os valores da invariante podem ser interpretados como a proporção de vezes que o estoque atinge cada um destes estados após um número muito grande de semanas



## ESTOQUE - TEMPOS DE RECORRÊNCIA

### TEMPO ESPERADO DE RECORRÊNCIA

$$\mu_{ii} = \frac{1}{\pi(i)}$$

### ESTOQUE - TEMPOS DE RECORRÊNCIA

$$\mu_{00} = \frac{1}{0,286} = 3,50 \text{ sem.}$$

$$\mu_{22} = \frac{1}{0,263} = 3,80 \text{ sem.}$$

$$\mu_{11} = \frac{1}{0,285} = 3,51 \text{ sem.}$$

$$\mu_{33} = \frac{1}{0,166} = 6,02 \text{ sem.}$$



## CUSTO MÉDIO POR UNIDADE DE TEMPO

### CUSTOS (OU PENALIDADES)

$C(X_t)$ : custo (ou função perda) incorrido quando o processo se encontrar no estado  $X_t$ , no instante  $t$

### MODELO DE CUSTO

- $C(X_t)$  é variável aleatória que assume os valores  $C(0), C(1), \dots, C(M)$
- A função  $C(\cdot)$  é independente de  $t$

### CUSTO MÉDIO INCORRIDO EM $n$ PERÍODOS

$$E \left[ \frac{1}{n} \sum_{t=1}^n C(X_t) \right]$$



## CUSTO ESPERADO EM LONGO PRAZO

### CUSTO ESPERADO POR UNIDADE DE TEMPO

Para um horizonte infinito de planejamento:

$$\lim_{n \rightarrow \infty} E \left[ \frac{1}{n} \sum_{t=1}^n C(X_t) \right] = \sum_{j \in E} \pi(j) C(j)$$

### RESULTADO PRECEDENTE

Pode-se provar que:

$$\lim_{n \rightarrow \infty} \left( \frac{1}{n} \sum_{k=1}^n P_{ij}^{(k)} \right) = \pi(j)$$



## ESTOQUE - CUSTO SEMANAL ESPERADO

### ESTOQUE - FUNÇÃO DE CUSTO

$$C(X_t) = \begin{cases} \$0 & , \text{ se } X_t = 0 \\ \$2 & , \text{ se } X_t = 1 \\ \$8 & , \text{ se } X_t = 2 \\ \$18 & , \text{ se } X_t = 0 \end{cases}$$

### CUSTO DE ESTOQUE ESPERADO A LONGO PRAZO

$$[0,286 \quad 0,285 \quad 0,263 \quad 0,166] \begin{bmatrix} 0 \\ 2 \\ 8 \\ 18 \end{bmatrix} = 5,662$$



## FUNÇÕES DE CUSTO COMPLEXAS

### SITUAÇÃO

Além do estado da cadeia, o custo também pode depender de alguma variável aleatória.

### EXEMPLO - ESTOQUE

Custos as serem considerados:

- Custo da encomenda
- Custo de penalidade para demanda não atendida
- Custo de armazenagem

O custo total por semana  $t$  é função do estoque na semana anterior ( $X_{t-1}$ ) e da demanda na semana corrente ( $D_t$ )



## CUSTO MÉDIO ESPERADO

### CUSTO MÉDIO ESPERADO A LONGO PRAZO POR UNIDADE DE TEMPO

$$\lim_{n \rightarrow \infty} E \left[ \frac{1}{n} \sum_{t=1}^n C(X_{t-1}, D_t) \right] = \sum_{j \in E} k(j) \pi(j),$$

onde  $k(j) = E [C(j, D_t)]$  que é a esperança condicional de  $C(X_{t-1}, D_t)$  dado  $X_{t-1} = j$ .



## CUSTOS ADICIONAIS - ESTOQUE

### CUSTOS DO MODELO

- Custo de encomenda: \$25 por unidade encomendada mais um valor fixo de \$10 por encomenda
- Penalidade por demanda não atendida: \$50
- Custo de armazenamento: considerado desprezível

### EQUAÇÃO DINÂMICA DO CUSTO SEMANAL

$$C(X_{t-1}, D_t) = \begin{cases} 10 + (25)(3) + 50 \max\{D_t - 3, 0\} & , \text{ se } s < X_{t-1} = 0 \\ 50 \max\{D_t - X_{t-1}, 0\} & , \text{ se } X_t \geq 1 \end{cases},$$

em qualquer instante de tempo  $t$ .



## CUSTO DO ESTADO 0

### CUSTO DO ESTADO 0

$$C(0, D_t) = 85 + 50 \max\{D_t - 3, 0\}$$

### CUSTO ESPERADO CONDICIONADO AO ESTADO 0

$$\begin{aligned} k(0) &= E [C(X_{t-1}, D_t) | X_{t-1} = 0] = 85 + 50E [\max\{D_t - 3, 0\}] \\ &= 85 + 50 [P_D(4) + 2P_D(5) + 3P_D(6) + \dots] \\ &= \$86,2 \end{aligned}$$

onde  $P_D(i) = P \{D_t = i\}$ .

### PROBABILIDADES DEMANDAS

$P_D(2) = 0,184$	$P_D(5) = 0,003$
$P_D(3) = 0,061$	$P_D(6) = 0,001$
$P_D(4) = 0,015$	$P_D(7) = 0,000$

## CUSTO DO ESTADO 1

### CUSTO DO ESTADO 1

$$C(1, D_t) = 50 \max\{D_t - 1, 0\}$$

### CUSTO ESPERADO CONDICIONADO AO ESTADO 1

$$\begin{aligned} k(1) &= E [C(X_{t-1}, D_t) | X_{t-1} = 1] = 50E [\max\{D_t - 1, 0\}] \\ &= 50 [P_D(2) + 2P_D(3) + 3P_D(4) + \dots] \\ &= \$18,4 \end{aligned}$$



## CUSTO DO ESTADO 2

### CUSTO DO ESTADO 2

$$C(2, D_t) = 50 \max \{D_t - 2, 0\}$$

### CUSTO ESPERADO CONDICIONADO AO ESTADO 2

$$\begin{aligned} k(2) &= E[C(X_{t-1}, D_t) | X_{t-1} = 2] = 50E[\max \{D_t - 1, 0\}] \\ &= 50 [P_d(3) + 2P_D(4) + 3P_D(5) + \dots] \\ &= \$5,2 \end{aligned}$$



## CUSTO DO ESTADO 3

### CUSTO DO ESTADO 3

$$C(3, D_t) = 50 \max \{D_t - 3, 0\}$$

### CUSTO ESPERADO CONDICIONADO AO ESTADO 3

$$\begin{aligned} k(3) &= E[C(X_{t-1}, D_t) | X_{t-1} = 3] = 50E[\max \{D_t - 3, 0\}] \\ &= 50 [P_d(4) + 2P_D(5) + 3P_D(6) + \dots] \\ &= \$1,2 \end{aligned}$$



## CUSTO SEMANAL ESPERADO (*Long-Run*)

$$\sum_{j=0}^3 k(j) \pi(j) \begin{bmatrix} 86,2 \\ 18,4 \\ 5,2 \\ 1,2 \end{bmatrix} = \boxed{\$31,46}$$



## CONDIÇÕES DE VALIDADE DO MODELO

### HIPÓTESES DO MODELO

- $\{X_t\}$  é uma cadeia de Markov irredutível ( $E$  finito)
- Há uma sequência de variáveis aleatórias condicionalmente independentes associadas a essa cadeia
- Para um  $m = 0, \pm 1, \pm 2, \dots$  fixo, um custo  $C(X_{t-1}, D_{t+m})$  é incorrido no instante  $t$ .
- A sequência  $X_0, X_1, X_2, \dots$  é independente de  $D_{t+m}$



## RESULTADOS FUNDAMENTAIS

Atendidas as condições enunciadas

### RESULTADO 1

$$\lim_{n \rightarrow \infty} E \left[ \frac{1}{n} \sum_{t=1}^n C(X_t, D_{t+m}) \right] = \sum_{j \in E} k(j) \pi(j),$$

em que  $k(j) = E[C(j, D_{t+m})]$

### RESULTADO 2

$$\lim_{n \rightarrow \infty} \left[ \frac{1}{n} \sum_{t=1}^n C(X_t, D_{t+m}) \right] = \sum_{j \in E} k(j) \pi(j),$$

para basicamente todos os caminhos do processo.



## MELHOR POLÍTICA

### EXEMPLO ESTOQUE

Encontrou-se o custo médio semanal (*long-run*) para a política  $((0, 3))$

### POLÍTICA ÓTIMA

Quais os valores de  $(s, S)$  que minimizam o custo médio semanal de estoque (*long-run*)?








4

## REFERÊNCIAS BIBLIOGRÁFICAS



## BIBLIOGRAFIA

-  TIJMS, H. C.  
*A First Course in Stochastic Models*  
Wiley, 2003
-  ROSS, S. M.  
*Introduction to Probability Models*  
Academic Press, 2010
-  ROSS, S. M.  
*Stochastic Processes*  
Wiley, 1996
-  KARLIN, S.; TAYLOR, H. M.  
*A First Course in Stochastic Processes*  
Academic Press, 1975
-  ATUNCAR, G. S.  
*Conceitos Básicos de Processos Estocásticos*  
Dep. Estatística/UFMG, 2011





# MODELOS ESTOCÁSTICOS APLICADOS À INDÚSTRIA

Prof. Lupércio França Bessegato

Departamento de Estatística  
Universidade Federal de Juiz de Fora  
lupercio.bessegato@ufjf.edu.br  
www.ufjf.br/lupercio\_bessegato

Setembro/2013

