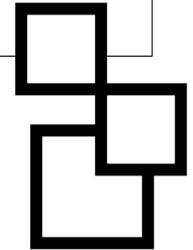


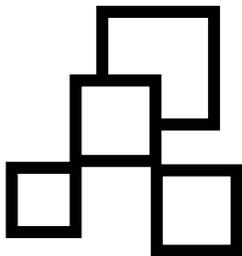
Instituto Tecnológico de Aeronáutica
Divisão de Engenharia Mecânica-Aeronáutica

MOQ-12

Cadeias de Markov



Professora:
Denise Beatriz T. P. do Areal Ferrari
denise@ita.br





Roteiro

- Introdução
- Processos Estocásticos
- Motivação
- Cadeias de Markov
 - Definição
 - Propriedade Markoviana
 - Propriedade de Estacionariedade
 - Matriz de Transição
 - Equação de Chapman-Kolmogorov
 - Vetor de Probabilidades Iniciais
 - Classificação de Estados





Introdução

- Hipótese de Independência
- Cadeias de Markov:
 - podem ser considerados como a generalização mais simples do esquema de experimentos independentes.
- Esses processos são o ponto inicial para o desenvolvimento de um novo e importante ramo da Teoria das Probabilidades:

Teoria dos Processos Estocásticos.





Processos Estocásticos

● Funções Aleatórias

- Intervalo de tempo: *série temporal*

Exemplos:

- flutuações de câmbio;
- sinais (fala, áudio e vídeo);
- dados médicos (eletrocardiograma, pressão sanguínea e temperatura);
- movimentos aleatórios (Movimento Browniano e Passeio Aleatório)

- Região do espaço: *campo aleatório*

Exemplos:

- imagens estáticas;
 - topografias aleatórias (satélite);
 - variações de composição em um material não homogêneo.
- 



Motivação (1)

- Problema em estudo:

Estamos medindo a temperatura do ambiente externo a cada hora, durante um dia.

Temperatura \Rightarrow fenômeno aleatório.

(resulta de uma conjunção de fatores meteorológicos que não podem ser determinados com exatidão)





Motivação (2)

- Para medir esta temperatura, usamos um termômetro que mede desde 0°C até 50°C , com divisões de 10°C .
 - temos um conjunto finito de resultados ou estados possíveis: 0°C , 10°C , 20°C , 30°C , 40°C e 50°C .



Sejam:

X_1 = temperatura medida no início do período (primeira observação)

X_2 = temperatura medida na segunda observação (1 hora depois de X_1)

X_n = temperatura medida no n -ésimo período observado, $n = 1, 2, \dots$

A seqüência X_1, X_2, \dots, X_{24} é um exemplo de Processo Estocástico.





Motivação (3)

A seqüência X_1, X_2, \dots, X_{24} é um exemplo de Processo Estocástico.

- Processo estocástico de *parâmetro discreto*: instantes pontuais de tempo (intervalos a cada hora)

X_1 = estado inicial do processo

X_n = estado do processo no instante n .

- Processo estocástico de *parâmetro contínuo*: Se estivéssemos monitorando a temperatura continuamente.





Motivação (4)

● *Espaço de estados (E):* $X_n \in E$

- **Discreto:**

$$E = \{x \in \mathbb{Z} \mid x \geq 0^\circ\text{C}\} = \{0^\circ\text{C}, 10^\circ\text{C}, 20^\circ\text{C}, 30^\circ\text{C}, \dots\}$$

O termômetro utilizado pode medir apenas um número definido de temperaturas (variações de 10°C).

- **Contínuo:**

$$E = \{x \in \mathbb{R} \mid x \geq 0^\circ\text{C}\}$$

O termômetro utilizado pode medir qualquer temperatura.





Cadeias de Markov

- É um tipo especial de processo estocástico, que satisfaz as seguintes condições:
 - o parâmetro n é discreto (ex: tempo)
 - o espaço de estados \mathbf{E} é discreto (coleção de estados possíveis)
 \mathbf{E} pode ser finito ou infinito e enumerável. Vamos considerar \mathbf{E} finito. As cadeias de Markov deste tipo são chamadas *Cadeias de Markov Finitas*.
 - o estado inicial do processo ou o espaço de estados é conhecido.
 - vale a *propriedade markoviana*
 - vale a *propriedade de estacionariedade*





Propriedade Markoviana

Para $n = 1, 2, \dots$, e qualquer seqüência de estados possíveis s_1, s_2, \dots, s_{n+1} , com X_n, X_{n-1}, \dots, X_1 conhecidos:

$$\begin{aligned} P(X_{n+1} = s_{n+1} \mid X_1 = s_1, X_2 = s_2, \dots, X_n = s_n) = \\ = P(X_{n+1} = s_{n+1} \mid X_n = s_n) \end{aligned}$$

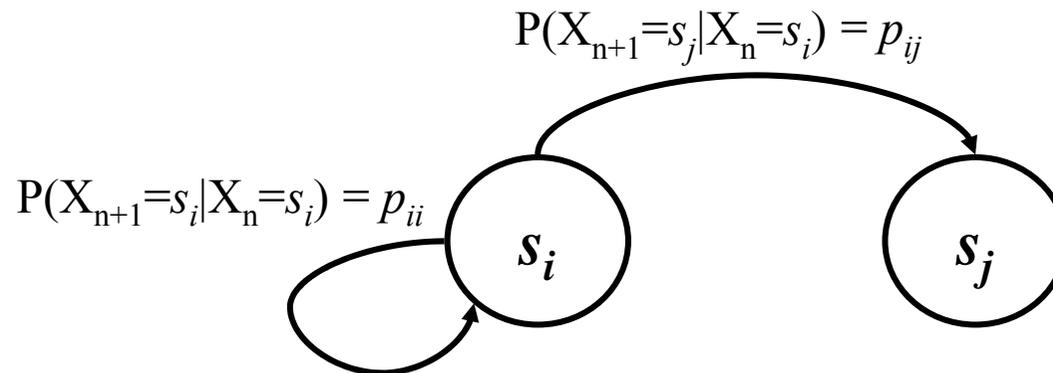
Em palavras:

- As probabilidades de todos os estados futuros X_j ($j > n$) dependem somente do estado atual X_n , mas não dependem dos estados anteriores X_1, \dots, X_{n-1} .

O estado “futuro” do sistema depende do “presente”, mas não depende do “passado”.



Propriedade de Estacionariedade



- *Probabilidades de transição:* $P(X_{n+1}=s_j | X_n=s_i)$
- *Probabilidades de transição estacionárias:*

$$P(X_{n+1} = s_j | X_n = s_i) = cte. = p_{ij} \quad n = 1, 2, \dots$$

A cadeia de Markov é dita *homogênea* ou *estacionária*.



Matriz de Transição

- Cadeia de Markov Finita e Estacionária
- k possíveis estados: s_1, s_2, \dots, s_k

$$P = \begin{matrix} & \begin{matrix} s_1 & s_2 & s_3 \end{matrix} \\ \begin{matrix} s_1 \\ s_2 \\ s_3 \end{matrix} & \begin{bmatrix} p_{11} & p_{12} & p_{13} \\ p_{21} & p_{22} & p_{23} \\ p_{31} & p_{32} & p_{33} \end{bmatrix} \end{matrix}$$
$$p_{ij} \geq 0$$
$$\sum_{j=1}^k p_{ij} = 1, \quad i = 1, \dots, k$$





Exemplo

- Suponha que na Terra de Oz, nunca há dois dias ensolarados consecutivos.
 - Se em um dia qualquer faz sol, no dia seguinte pode tanto nevar quanto chover.
 - Se chover, metade das vezes continua chovendo no dia seguinte e nas outras ocasiões pode tanto fazer sol ou nevar.
 - Se nevar, apenas metade das vezes o dia seguinte também neva.

Queremos:

- Representar graficamente a Cadeia de Markov
- Construir sua matriz de transição
- Determinar a probabilidade de nevar daqui a dois dias?





Equação de Chapman-Kolmogorov

Sejam:

- P a matriz de transição de uma cadeia de Markov.
- O elemento $p_{ij}^{(n)}$ da matriz $P^{(n)}$ representa a probabilidade de que o processo, iniciado no estado s_i , estará no estado s_j , depois de n passos.
- u um instante qualquer entre 0 e n .

$$p_{ij}^{(n)} = \sum_{r=1}^k p_{ir}^{(u)} \cdot p_{rj}^{(n-u)}, \quad 0 < u < n$$

ou, alternativamente:

$$p_{ij}^{(n)} = P(X_n = s_j \mid X_1 = s_i) = \sum_{r=1}^k p_{ir}^{(n-1)} p_{rj}, \quad n = 1, 2, \dots$$





Vetor de Probabilidades Iniciais (*a priori*)

Em muitas situações, não conhecemos o estado da Cadeia de Markov no instante inicial.

- Cadeia de Markov Finita e Estacionária
- k possíveis estados: s_1, s_2, \dots, s_k

● Para $i=1, \dots, k$:

v_i = probabilidade de que o processo esteja no estado s_i no instante inicial

$$v_i \geq 0 \quad \text{e} \quad \sum_{i=1}^k v_i = 1$$

- A qualquer vetor $\mathbf{w} = (w_1, \dots, w_k)$, tal que $w_i \geq 0$ e $w_1 + w_2 + \dots + w_k = 1$ chamamos **vetor de probabilidades**.
- O vetor $\mathbf{v} = (v_1, \dots, v_k)$ é chamado **vetor de probabilidades iniciais**, pois representa as probabilidades dos vários estados da cadeia no instante de início do processo.





Vetor de Probabilidades Iniciais (*a priori*)

● Teorema:

- Seja P a matriz de transição de uma cadeia de Markov
- \mathbf{v} o vetor de probabilidades iniciais.

Então, a probabilidade de que o processo esteja no estado s_j depois de n passos é a j -ésima componente do vetor:

$$\mathbf{v}^{(n)} = \mathbf{v} \cdot P^n$$

onde:

$$\mathbf{v}^{(n)} = [v_1^{(n)} \ v_2^{(n)} \ \dots \ v_k^{(n)}]$$

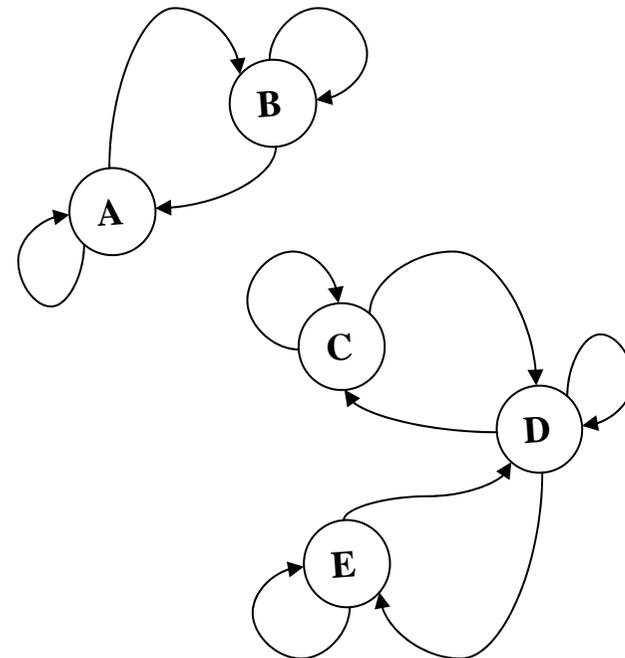
$$v_i^{(n)} = P(X_n = s_i)$$



Classificação de Estados

- A fim de ilustrar as próximas definições, vamos utilizar a Cadeia de Markov representada a seguir:

$$P = \begin{matrix} & \begin{matrix} A & B & C & D & E \end{matrix} \\ \begin{matrix} A \\ B \\ C \\ D \\ E \end{matrix} & \begin{bmatrix} 0.4 & 0.6 & 0 & 0 & 0 \\ 0.5 & 0.5 & 0 & 0 & 0 \\ 0 & 0 & 0.3 & 0.7 & 0 \\ 0 & 0 & 0.5 & 0.4 & 0.1 \\ 0 & 0 & 0 & 0.8 & 0.2 \end{bmatrix} \end{matrix}$$





- Definição: ***Caminho***

Dados dois estados s_i e s_j , um *caminho* entre s_i e s_j é uma seqüência de transições que começam em s_i e terminam em s_j , tais que cada transição tem uma probabilidade positiva de ocorrência.

1. Um estado s_j é ***acessível*** a partir do estado s_i se existe um caminho que liga s_i a s_j .
2. Dois estados s_i e s_j são ***comunicáveis*** se s_j é acessível a partir de s_i e s_i é acessível a partir de s_j .





3. Um conjunto de estados \mathbf{E} em uma cadeia de Markov é uma *classe* se nenhum estado fora de \mathbf{E} é acessível por qualquer estado em \mathbf{E} .

Se a cadeia inteira é formada por uma única classe, isto é, todos os estados são comunicáveis, a cadeia é dita *irredutível*.

4. Um estado s_i é absorvente se $p_{ii} = 1$.
5. Um estado s_i é transiente se existe um estado s_j que é acessível a partir de s_i , mas o estado s_i não é acessível a partir de s_j .
6. Se um estado não é transiente ele é recorrente.





7. Um estado s_i é *periódico* com período $T > 1$ se T é o menor número tal que todos os caminhos que levam do estado s_i de volta a s_i tem comprimento múltiplo de T . Se um estado recorrente não é periódico ele é *aperiódico*.

8. Se todos os estados em uma Cadeia de Markov são recorrentes, aperiódicos e comunicáveis entre si, então a cadeia é dita *ergódica*.





Exemplo

- Suponha que só existem dois refrigerantes: guaraná e soda.
 - Se uma pessoa escolheu guaraná, existe 90% de chance de peça novamente guaraná.
 - Se a pessoa tiver escolhido soda, a chance de que peça este refrigerante outra vez é de 80%.
- 1. Se uma pessoa é atualmente consumidora de soda, qual a probabilidade de que escolha guaraná no segundo pedido futuro?
- 2. Se a pessoa é atualmente consumidora de guaraná, qual é a probabilidade de que escolha guaraná no terceiro pedido futuro?





Solução

- Os pedidos de cada consumidor podem ser interpretados como uma Cadeia de Markov de dois estados, descritos como:

Estado 1 = a pessoa escolheu guaraná da última vez (G)

Estado 2 = a pessoa escolheu soda da última vez (S)

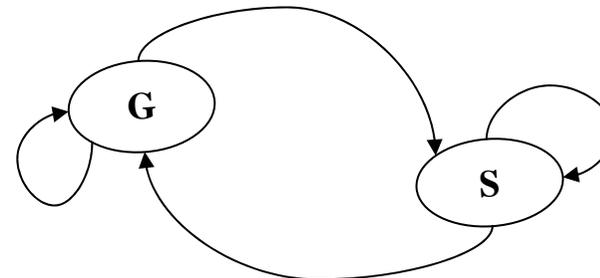
Vamos definir:

X_0 = refrigerante escolhido no presente

X_n = refrigerante escolhido no n-ésimo pedido futuro

A seqüência X_0, X_1, \dots pode ser descrita como a seguinte Cadeia de Markov:

$$P = \begin{array}{c} \begin{array}{cc} & \text{G} & \text{S} \\ \text{G} & \begin{bmatrix} 0.9 & 0.1 \end{bmatrix} \\ \text{S} & \begin{bmatrix} 0.2 & 0.8 \end{bmatrix} \end{array} \end{array}$$



Agora sim, podemos responder às perguntas...



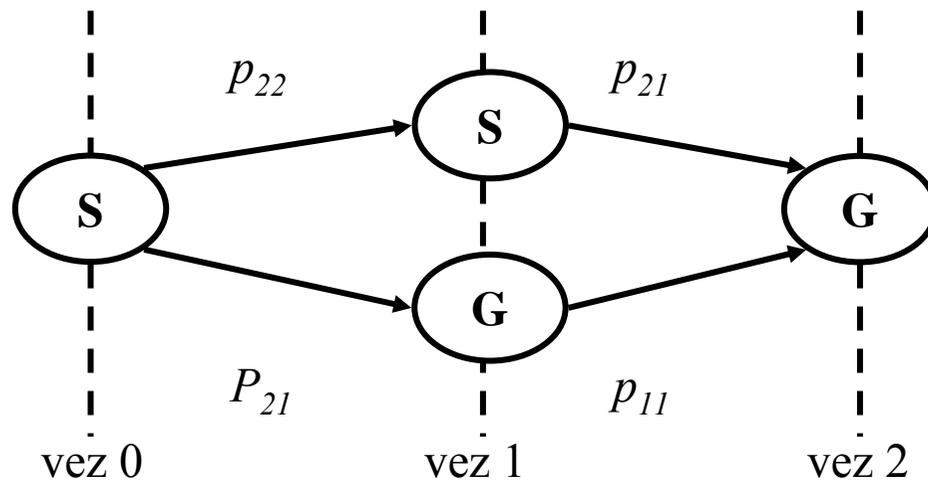


1. Se uma pessoa é atualmente consumidora de soda, qual a probabilidade de que escolha guaraná no segundo pedido futuro?

Queremos: $P(X_2 = G \mid X_0 = S) = p_{21}^{(2)}$

$$P^2 = \begin{bmatrix} 0.9 & 0.1 \\ 0.2 & 0.8 \end{bmatrix} \begin{bmatrix} 0.9 & 0.1 \\ 0.2 & 0.8 \end{bmatrix} = \begin{bmatrix} 0.83 & 0.17 \\ \boxed{0.34} & 0.66 \end{bmatrix}$$

De outra maneira:



$$p_{21}^{(2)} =$$

(probabilidade de que o próximo pedido seja soda e o segundo pedido seja soda)

+

(probabilidade de que o próximo pedido seja guaraná e o segundo pedido seja soda)

$$= p_{21}p_{11} + p_{22}p_{21}$$

$$= (0.2)(0.9) + (0.8)(0.2) = 0.34$$



2. Se a pessoa é atualmente consumidora de guaraná, qual é a probabilidade de que escolha guaraná no terceiro pedido futuro?

Queremos: $P(X_3 = G | X_0 = G) = p_{11}^{(3)}$

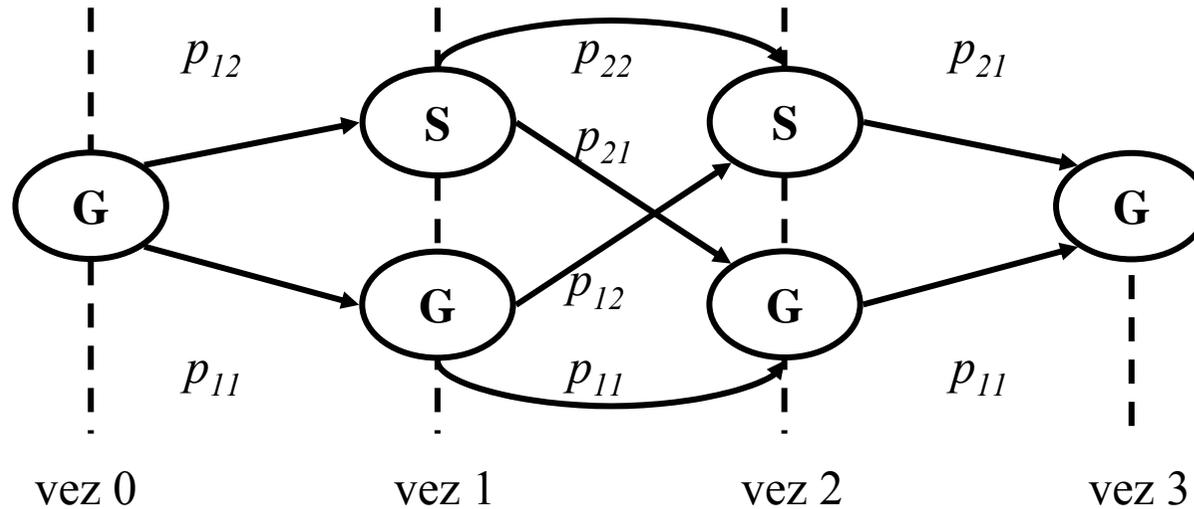
$$P^3 = P.P^2 = \begin{bmatrix} 0.9 & 0.1 \\ 0.2 & 0.8 \end{bmatrix} \begin{bmatrix} 0.83 & 0.17 \\ 0.34 & 0.66 \end{bmatrix} = \begin{bmatrix} \boxed{0.781} & 0.219 \\ 0.438 & 0.562 \end{bmatrix}$$





2. Se a pessoa é atualmente consumidora de guaraná, qual é a probabilidade de que escolha guaraná no terceiro pedido futuro?

De outra maneira:



$$\begin{aligned} p_{11}^{(3)} &= p_{12}p_{22}p_{21} + p_{12}p_{21}p_{11} + p_{11}p_{12}p_{21} + p_{11}p_{11}p_{11} = \\ &= (0.1)(0.8)(0.2) + (0.1)(0.2)(0.9) + (0.9)(0.1)(0.2) + (0.9)(0.9)(0.9) = 0.781 \end{aligned}$$





Suponha, que 60% das pessoas bebem guaraná e 40% bebem soda agora.
Daqui a três pedidos, que fração das pessoas beberá guaraná?

Queremos: $\mathbf{v}^{(3)} = \mathbf{v} \cdot P^3$

Temos: $\mathbf{v} = [0.6 \quad 0.4]$

Portanto:

$$\mathbf{v}^{(3)} = \mathbf{v} \cdot P^3 = [0.6 \quad 0.4] \begin{bmatrix} 0.781 & 0.219 \\ 0.438 & 0.562 \end{bmatrix} = [0.6438 \quad 0.3562]$$

