

# Aula 11

## Aula passada


- *Tudo aquilo que você quis perguntar mas ainda não perguntou*
- Dúvidas

## Aula de hoje

- Cadeias de Markov
- Definição e exemplos
- Modelo On-Off
- Sem memória
- Distribuição no tempo
- Irredutibilidade
- Aperiodicidade

# Sistema Computacional

- Duas CPUs, com respectivos caches, memória compartilhada, dois discos
  - um processo está em um destes recursos em cada tempo

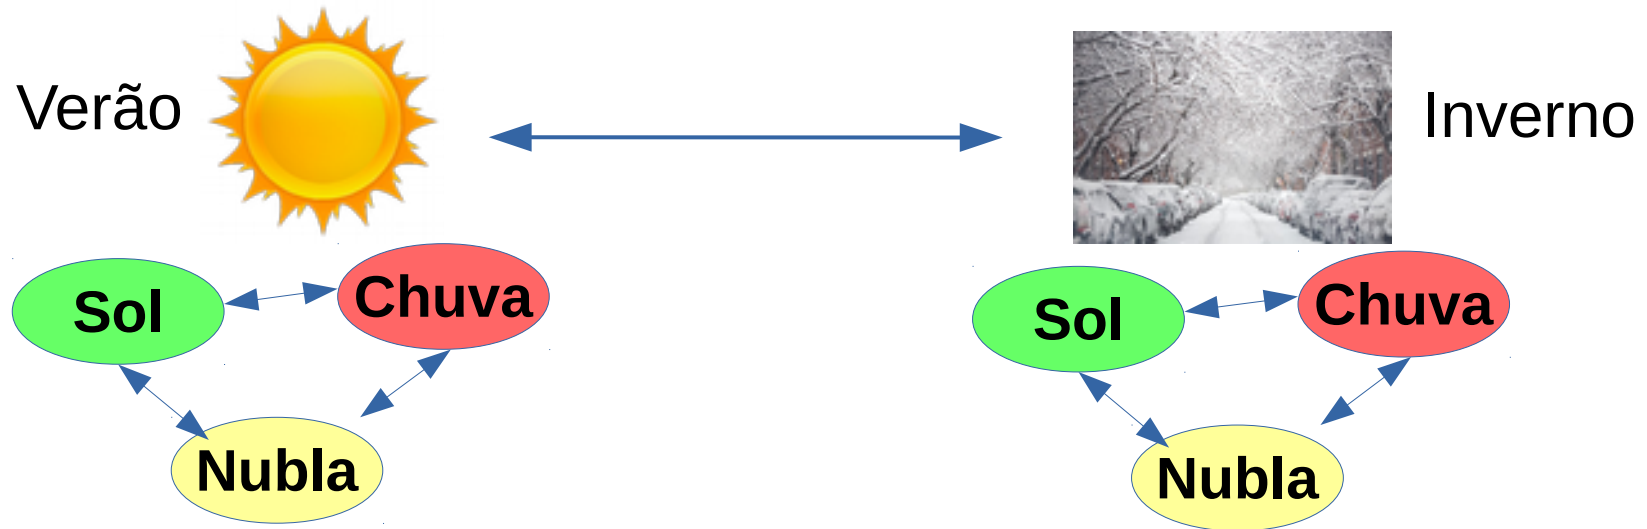


- Objetivo: medir e/ou melhorar desempenho
- Como representar a *dinâmica* deste sistema?

**Modelo matemático!**

# Previsão do Tempo

- Duas estações do ano, e três tipos de dia
  - estações alternam, dias não tem estrutura



- Objetivo: medir e/ou prever os dias
- Como representar a *dinâmica* deste sistema?

**Modelo matemático!**

# Cadeias de Markov


- Ferramenta de modelagem matemática
  - como equações diferenciais
- Representam dinâmica de sistemas com aleatoriedade
  - sequência de variáveis aleatórias dependentes
- Muito poderosa, na teoria e na prática
  - estudada e aplicada amplamente por matemáticos e engenheiros (e médicos, biólogos, etc)
- Simplificação da realidade
  - mas pode codificar praticamente qualquer complexidade
- Estudadas por Andrey Markov (1906)
  - independência não é necessária para lei fraca dos grandes números

# Cadeias de Markov

- **Espaço de estados:** todos os possíveis estados nos quais o sistema pode se encontrar
  - possíveis valores que v.a. pode assumir
  - finito ou infinito, contável ou não (interesse em finito)
- **Matriz de transição:** todas as possíveis transições de estado diretas que o sistema pode fazer
  - transições são aleatórias, dependem do estado atual
- **Tempo discreto:** uma transição a cada passo de tempo
  - tempo contínuo também é possível
- **Estado inicial:** estado onde o sistema começa
  - pode ser escolhido de forma aleatória

# Cadeias de Markov

- Representada por um grafo direcionado com pesos
  - vértices: estados do sistema
  - arestas: possíveis transições
  - pesos: probabilidade (soma dos pesos de saída igual a 1)
- Modelo On-Off
  - a mais simples e mais usada cadeia de Markov
  - dois estados: On e Off, todas possíveis transições




$$P = \begin{pmatrix} 1 - p & p \\ q & 1 - q \end{pmatrix}$$

Matriz de transição de estados.  
 $P[i,j]$  = prob. de transição do estado  $i$  para estado  $j$

# Sistema Computacional

- Versão simplificada, apenas um recurso de cada tipo, tempo discreto
- Estados: recurso sendo utilizado pelo processo
- Transições: definidas empiricamente (ou modelagem)
  - possíveis transições e valores de probabilidade




$$P = \begin{pmatrix} p_{11} & p_{12} & 0 & 0 \\ p_{21} & p_{22} & p_{23} & 0 \\ 0 & p_{32} & p_{33} & p_{34} \\ 0 & 0 & p_{43} & p_{44} \end{pmatrix}$$

$$\sum_{j=1}^4 p_{ij} = 1, \text{ para todo } i$$

- probabilidade de saída tem que somar 1

# Definição Formal

- Seja  $S$  o espaço de estados da CM e  $P$  sua matriz de transição de estados
- Seja  $X_t$  uma v.a. que determina o valor do estado do sistema no instante de tempo  $t$ , para  $t = 0, 1, 2, \dots$
- Para cada  $t$ ,  $X_t$  possui uma distribuição diferente
  - $P[X_t = s]$  para todo  $s$  em  $S$
- Exemplo: Modelo On-Off,  $p=1/4$ ,  $q=2/3$ 
  - $X_0 = 1$  (On)  $\rightarrow P[X_0 = 1] = 1$
  - $P[X_1 = 1] = ?$ ,  $P[X_1 = 2] = ?$
  - $P[X_2 = 1] = ?$ ,  $P[X_2 = 2] = ?$





# Propriedade *Sem Memória*

- CM não tem memória (*memoryless property*)
  - próximo estado só depende do estado atual, e não de como chegamos ao estado atual
- Considere uma trajetória de estados pelo sistema
  - $X_0 = s_0, X_1 = s_1, \dots, X_{t-1} = s_{t-1}, X_t = s_t$
  - onde  $s_i$  é um estado qualquer em  $S$

- Temos que

$$\begin{aligned} P[X_{t+1} = s | X_0 = s_0, X_1 = s_1, \dots, X_t = s_t] &= P[X_{t+1} = s | X_t = s_t] \\ &= p_{s_t, s} \end{aligned}$$

- Distribuição de  $X_{t+1}$  só depende de  $X_t$ , e não da trajetória
  - toda a evolução é função da matriz  $P$

# Distribuição Inicial

- CM começa em algum estado no tempo  $t = 0$ 
  - escolha é de quem constrói a cadeia!
- Estado inicial pode também ser aleatório
  - $P[ X_0 = s ] = \pi_s(0)$  , para todo  $s$  em  $S$
  - tal que  $\sum_{s \in S} \pi_s(0) = 1$
- Podemos começar em um único estado?
- Sim!  $\pi_s(0) = 1$  para um  $s$  qualquer
- No exemplo do Modelo On-Off  
 $\pi(0) = (\pi_1(0) \ \pi_2(0)) = (1 \ 0)$  ← Vetor inicial

# Distribuição no Tempo $t$

- Usaremos vetor  $\pi(t)$  para denotar a distribuição de  $X$  (estado da CM) ao longo do tempo  $t$


- $P [ X_t = s ] = \pi_s(t)$

- Em forma vetorial

$$\pi(t) = (\pi_1(t) \quad \pi_2(t) \quad \dots \quad \pi_n(t)) = (P[X_t=1] \quad \dots \quad P[X_t=n])$$

- Quanto vale  $\pi(t)$ ?

- No exemplo do modelo On-Off?



- $\pi_1(t) = 3/4 * \pi_1(t-1) + 2/3 * \pi_2(t-1)$

- $\pi_2(t) = 1/4 * \pi_1(t-1) + 1/3 * \pi_2(t-1)$

# Distribuição no Tempo $t$

- Generalizando a ideia anterior, temos o seguinte

$$\begin{aligned}\pi_i(t) &= P[X_t = i] = \sum_j P[X_t = i | X_{t-1} = j] P[X_{t-1} = j] \\ &= \sum_j P_{ji} \pi_j(t-1)\end{aligned}$$

Lei prob tota!!

- De forma matricial ( $\pi$  é vetor linha), temos

$$\pi(t) = \pi(t-1)P = \pi(t-2)PP = \dots = \pi(0)P^t$$

- onde  $P$  é a matriz de transição de estados, e  $P^t$  é a multiplicada por ela mesma  $t$  vezes
- **Boa notícia:** para encontrar a distribuição  $\pi(t)$  basta multiplicar pela matriz  $P$
- **Má notícia:** multiplicação de matriz é  $O(n^3)$

# Comunicação entre Estados

- Veremos algumas propriedades importantes
- Considere dois estados  $s_i$  e  $s_j$  em  $S$
- Dizemos que  $s_i$  se comunica com  $s_j$ , ou seja  $s_i \rightarrow s_j$ , sse existe algum  $t > 0$  tal que

$$P[X_{t_0+t} = s_j | X_{t_0} = s_i] > 0$$


- Esta propriedade não depende de  $t_0$ , e a prob é dada simplesmente por  $P^t[i, j]$ 
  - basta haver caminho de  $s_i$  para  $s_j$  no grafo direcionado
- Se  $s_i \rightarrow s_j$  e  $s_j \rightarrow s_i$  então dizemos que  $s_i$  e  $s_j$  se intercomunicam, ou seja  $s_i \leftrightarrow s_j$

# Irredutível

- Uma CM é dita irredutível (*irreducible*) se para todo par de estados  $s_i$  e  $s_j$  em  $S$ , temos que  $s_i \leftrightarrow s_j$ 
  - caso contrário a CM é dita redutível (*reducible*)
- Considerando o grafo direcionado induzido pela matriz de transição  $P$ 
  - se há caminho direcionado entre qualquer par de vértices, então CM é irredutível
  - grafo fortemente conexo = CM irredutível

# Exemplos

- Exemplo do Modelo On-Off é irreduzível?



**Sim!**

- CM definida por  $P$  abaixo é irreduzível?

$$P = \begin{pmatrix} 0 & .2 & .8 & 0 \\ .6 & 0 & 0 & .4 \\ 0 & 0 & .9 & .1 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

**Não!**

# Periodicidade

- Seja  $A = \{a_1, a_2, \dots\}$  um conjunto de inteiros
- $\gcd(A)$  = maior divisor comum dos inteiros em  $A$ 
  - ex.  $A = \{9, 15, 30\} \rightarrow \gcd(A) = 3$
  - ex.  $B = \{4, 6, 3\} \rightarrow \gcd(B) = 1$
- Seja  $s_i$  um estado da CM, e  $A_i$  o conjunto dos comprimentos de caminho que iniciam e terminam em  $s_i$ 
  - $A_i = \{t : P^t[i, i] > 0\}$
  - Prob. positiva de sair e voltar a  $s_i$  em  $t$  passos
- O período de  $s_i$  é dado por  $d(s_i) = \gcd(A_i)$




# Aperiódica

- Seja  $s_i$  um estado da CM, e  $d(s_i)$  seu período
- Dizemos que  $s_i$  é aperiódico sse  $d(s_i) = 1$ 
  - caso contrário,  $s_i$  é dito periódico
- Intuitivamente,  $s_i$  é aperiódico se existe caminho de volta a  $s_i$  de todos os comprimentos maiores que um determinado valor
- Uma CM é dita aperiódica se todos os seus estados são aperiódicos
  - caso contrário, a CM é dita periódica

# Exemplos

- Exemplo do Modelo On-Off é aperiódico?




**Sim!**

- CM definida por  $P$  abaixo é aperiódica?

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

- **Não!** Período de qualquer estado é 2

- Não consigo voltar ao estado 1 em tempo ímpar



# Exemplo e Propriedade

- Considere uma CM irreductível, tal que existe  $s_i$  em  $S$  tal que  $p_{ii} > 0$ 
  - CM tem ao menos um estado com aresta em *loop*
- Esta CM é aperiódica ou periódica?

**Aperiódica!**

- Podemos usar *loop* para gerar qualquer tempo de retorno grande o suficiente
- **Lema:** Em uma CM irreductível, todos os estados são aperiódicos ou todos são periódicos com o mesmo período!
  - basta caracterizar um estado para caracterizar a cadeia