

# Aula 12

## Roteiro

- Caminho amostral
- Teorema Ergódico
- Simulação de CM (eficiente)
- Gerando amostras
- Simulando CM enormes

# Aleatoriedade de CM

- Até agora vimos os seguintes objetos matemáticos
- $P$ : matriz de transição de estados da CM
- $\pi(0)$ : distribuição inicial da CM
- $\pi(t)$ : distribuição da CM no tempo  $t$ , dada por  $\pi(t) = \pi(0)P^t$
- $\pi$ : distribuição estacionária da CM, dada por  $\pi = \pi P$
- $\tau_\varepsilon$ : tempo de mistura da CM, dado  $\varepsilon$

**Qual destes objetos é aleatório?**


- **Nenhum deles!**
- Então o que é aleatório na CM?

# Cadeia de Markov

- $X_t$  : v.a. que determina o estado da cadeia no instante de tempo  $t$ , para  $t = 0, 1, 2, \dots$ 
  - $P[ X_t = s ]$  para todo  $s$  em  $S$

**$X_t$  é aleatório (é uma v.a.)**

- Exemplo:  $\pi(0) = (0.8 \ 0.2)$




- Realização:  $X_0 = 1, X_1 = 0, X_2 = 0, X_3 = 1, X_4 = 0, X_5 = 1, X_6 = 1, \dots$
- Realização:  $X_0 = 0, X_1 = 0, X_2 = 1, X_3 = 1, X_4 = 0, X_5 = 0, X_6 = 1, \dots$
- Realização:  $X_0 = 1, X_1 = 1, X_2 = 0, X_3 = 1, X_4 = 1, X_5 = 1, X_6 = 0, \dots$

# Caminho Amostral

- Uma realização da sequência de v.a.  $X_t$  para  $t = 0, 1, \dots$
- Probabilidade de um caminho amostral  $\omega = (\omega_0, \omega_1, \omega_2, \dots)$ 
  - prob. da CM realizar exatamente  $\omega$

$$\begin{aligned} P[\omega] &= P[X_0 = \omega_0, X_1 = \omega_1, \dots] = \\ &= \pi_{\omega_0}(0) P_{\omega_0, \omega_1} P_{\omega_1, \omega_2} P_{\omega_2, \omega_3} \dots \end{aligned}$$

- Todo caminho amostral  $\omega$  tem uma probabilidade
  - que vai a zero com o comprimento do caminho
- Exemplo:  $\pi(0) = (0.8 \quad 0.2)$



- $\omega = 1, 1, 1, 1, 1, 1, 1, 1, 1$

- $\omega = 0, 1, 0, 1, 0, 1, 0, 1, 0$       $P[\omega] = ?$

# O que ocorre com $X_t$ ?

- Se todo caminho amostral tem probabilidade que vai a zero com  $t$ , o que podemos dizer sobre sequência  $X_t$ ?

**Usar média sobre valores da sequência!**

- Ex. média amostral dos valores de estado observados

$$S_k = \frac{1}{k} \sum_{t=0}^{k-1} X_t$$

- Ex. fração de vezes que um estado  $s$  é visitado

$$f_k(s) = \frac{1}{k} \sum_{t=0}^{k-1} I(X_t = s)$$

# Convergência Intuitiva

- Para onde converge a média amostral de  $X_t$  para um caminho amostral muito longo ( $k$  muito grande)?
  - caminho amostral muito longo pela CM

$$S_k = \frac{1}{k} \sum_{t=0}^{k-1} X_t \longrightarrow E_{\pi}[X] = \sum_s s \pi_s$$

- Para onde converge a fração de visitas a um estado para um caminho amostral muito longo ( $k$  muito grande)?

$$f_k(s) = \frac{1}{k} \sum_{t=0}^{k-1} I(X_t = s) \longrightarrow \pi_s$$

Função indicadora:  
vale 1 quando  $X_t = s$

# Teorema Ergódico

- Seja  $f$  uma função sobre o espaço de estados da CM
  - mapeia cada estado da CM em um valor real
- Se CM é irredutível e aperiódica, com distribuição estacionária  $\pi$ , temos

$$P \left[ \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{t=0}^{k-1} f(X_t) = E_{\pi} [f(X)] \right] = 1$$

Sobre distribuição estacionária

Como lei forte dos grandes números!

- Teorema fundamental: Média no espaço = média no tempo
  - valor esperado de qualquer função pode ser aproximado usando caminho amostral
- Exemplos anteriores são casos especiais

# Estimando $\pi$

- Teorema ergódico garante que método de Monte Carlo funciona também em CM
  - conexão entre teoria (equações) e prática (simulação)
- Exemplo: Como estimar  $\pi$  ?
- Usar a CM para gerar um caminho amostral  $\omega$  bem longo e calcular a fração de visitas a cada estado

$$\hat{\pi}_s(k) = \frac{1}{k} \sum_{t=0}^{k-1} I(\omega_t = s)$$

- Teorema ergódico garante convergência
  - estimador possui viés para tempo  $k$ , mas é consistente (viés vai a zero quando  $k$  aumenta)
- Outro método para calcular  $\pi$



# Simulando uma CM

- Como simular uma CM?
  - entrada: matriz  $P$ , distribuição inicial  $\pi(0)$

**Simular é gerar um caminho amostral!**

**Ideia 0:** usar diretamente os caminhos amostrais

1) enumerar todos os caminhos amostrais de tamanho  $k$


2) determinar probabilidade de cada caminho

3) gerar amostras deste conjunto

- **Intuição:** cada caminho amostral é uma face de um dado enviesado

- sabemos gerar amostras de dado enviesado!

# Exemplo com Modelo On-Off



- Todas as sequências binárias com  $k$  dígitos
- $k = 5$ :  $\omega^0 = 0,0,0,0,0$   $\omega^1 = 0,0,0,0,1$ , ...,  $\omega^{31} = 1,1,1,1,1$
- $P[\omega^0] = 0.2 \cdot (1/3)^4$ ,  $P[\omega^1] = 0.2 \cdot (1/3)^3 \cdot 2/3$ , ...
- Dado enviesado com 32 faces
- Gerar amostras do dado
  - tempo constante, usando Método Alias


## Problema?

- Número de caminhos é exponencial em  $k$
- Tempo exponencial para construir o dado!

# Simulando uma CM

- Outra abordagem: amostrar a sequência  $X_t$  de forma iterativa, para  $t=0,1,2, \dots$ 
  - construir dinamicamente o caminho amostral
- Usar  $\pi(0)$  para gerar  $X_0$
- Dado  $X_0$ , usar  $P$  (matriz de transição) para gerar  $X_1$ 
  - $P[X_1 = s_1 \mid X_0 = s_0] = P(s_0, s_1)$
- Dado  $X_1$ , usar  $P$  (matriz de transição) para gerar  $X_2$ 
  - $P[X_2 = s_2 \mid X_1 = s_1] = P(s_1, s_2)$
- De forma geral, dado  $X_k$ , usar  $P$  para gerar  $X_{k+1}$

# Exemplo



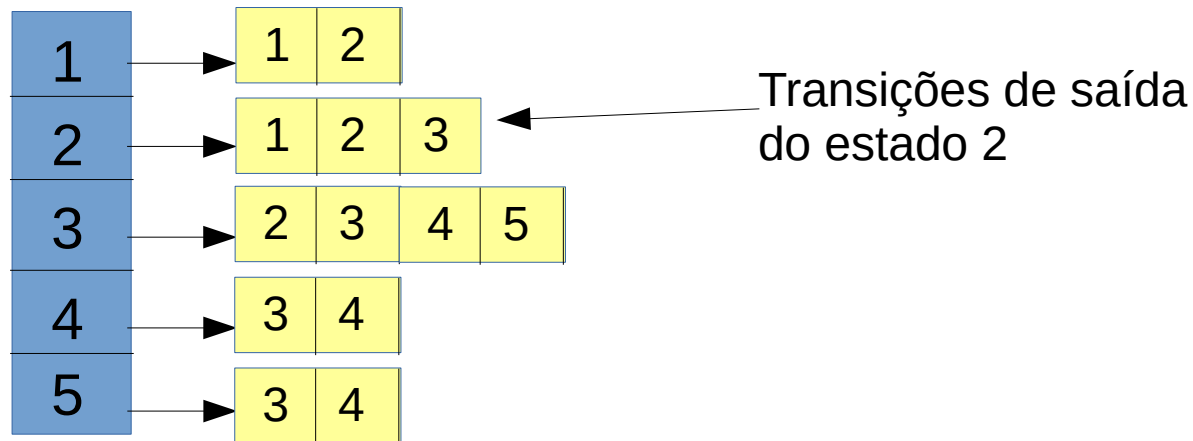
- Dado  $X_k$ , usar matriz  $P$  para gerar  $X_{k+1}$
- Ex. dado  $X_4 = 3$ , como gerar  $X_5$  ?
- $X_5$  é um dos vizinhos de saída do estado 3
  - 4 estados possíveis  $\{2, 3, 4, 5\}$ , cada um possui uma probabilidade, dado por  $P_{3,2}$ ,  $P_{3,3}$ ,  $P_{3,4}$ ,  $P_{3,5}$
  - gerar amostra para  $X_5$  de acordo com essas probabilidades

# Simulando uma CM

- Para gerar  $X_{k+1}$ , usamos a linha  $X_k$  da matriz  $P$
- Temos um dado enviesado para cada linha de  $P$ 
  - cada face corresponde a um estado da CM
- Precisamos escolher uma face
- **Ideia 1:** usar diretamente a linha da matriz  $P$
- Linha  $i$  da matrix  $P$ 
  - $P(i,*) = p_{i,1}, p_{i,2}, p_{i,3}, \dots, p_{i,n}$
- Algoritmo básico para gerar amostra de dado enviesado
  - tempo médio:  $n/2$
- **Problema:** muito ineficiente se matriz  $P$  é esparsa

# Simulando CM Eficientemente


- Representar matriz  $P$  como vetor de adjacência
  - apenas entradas não-nulas são representadas
- Exemplo da CM anterior



- Dois vetores para cada estado  $j$
- $y_j[i]$  = estado destino da  $i$ -ésima transição não-nula de  $j$
- $q_j[i]$  = probabilidade de transição acumulada pelas primeiras  $i$ -ésimas transições de saída de  $j$
- Ex:  $y_2[2] = 2$  ,  $q_2[2] = .7$  ,  $y_5[2] = 4$  ,  $q_5[2] = 1$

# Simulando CM Eficientemente

- Usar vetores  $y$  e  $q$  para simular o dado enviesado
- Sendo  $j$  o estado atual, temos:



- No exemplo,  $y_j[3]$  é o próximo estado!
- Complexidade:  $O(d)$ , onde  $d$  é grau de saída do estado
- Método Alias: complexidade  $O(1)$  + custo inicial
  - vantagem depende do retorno ao mesmo estado e tamanho do caminho amostral


# Gerando Amostras

- Como gerar amostras de  $X_t$ ?
  - caminho amostral não interessa, apenas amostra no tempo  $t$
- **Ideia 1:**
  - 1) Calcular  $\pi(t)$  (distribuição no tempo  $t$ )
  - 2) Gerar amostras desta distribuição
    - lembrando:  $\pi(t) = \pi(0)P^t$
- **Ideia 2:**
  - 1) Simular CM até  $X_t$ , gerando caminho amostral
  - 2) Retornar a amostra gerada para  $X_t$



# Exemplo

- Exemplo:  $\pi(0) = (0.8 \ 0.2)$
- Gerar amostras de  $X_{10}$  ?



- **Ideia 1:** calcular  $\pi(10) = (0.727 \ 0.273)$
- Gerar amostra para  $X_{10}$  usando  $\pi(10)$
  
- **Ideia 2:** gerar caminho amostral  $X_0, X_1, X_2, \dots, X_{10}$ 
  - ex.  $\omega = 1, 2, 1, 1, 2, 2, 1, 2, 1, 2, 2$
- Retornar  $X_{10} = 2$  (Off)


# Gerando Amostras

## Qual abordagem é mais eficiente?

- Depende de  $n$  (tamanho da CM), de  $t$ , do número de amostras de  $X_t$  (supor  $r$  amostras)
- Calcular  $\pi(t)$  tem complexidade  $O(t n^2)$ 
  - $t$  multiplicações de vetor por matriz
  - gerar uma amostra tem complexidade  $O(n)$
  - mas se  $r$  for grande podemos usar Método Alias em  $\pi(t)$
- Gerar  $X_t$  tem complexidade  $O(t d)$ , para cada amostra
  - se  $r$  for grande podemos usar Método Alias nas transições da CM, ao custo amortizado de  $O(t)$  por amostra

# Amostras Estacionárias

- Como gerar amostras da distribuição estacionária da CM?



**Mesma abordagem!**


- **Ideia 1:**
  - 1) Calcular  $\pi$  (distribuição estacionária)
  - 2) Gerar amostras desta distribuição
- **Ideia 2:**
  - 1) Simular CM até  $X_t$  para  $t$  suficiente grande
    - tempo de mistura  $\tau_\epsilon$
  - 2) Retornar a amostra gerada para  $X_t$

# Simulando CM Enormes

- Como simular CM com muitos estados?
  - até mesmo com espaço de estado infinito
- **Problema:** impossível representar CM na memória (mesmo com representação esparsa)
- **Ideia:** gerar apenas possíveis próximos estados a partir do estado atual
  - determinar as transições de saída do estado atual
  - construir dado enviesado
  - escolher próximo estado de acordo
- **Restrição:** gerar transições de saída a partir do estado atual (sem conhecer a CM)
  - regras que definem possíveis transições

# Exemplo 1

- Látice de duas dimensões nos naturais
  - probabilidades de transição para norte, sul, leste, oeste:  
 $p_n + p_s + p_l + p_o = 1$
  - self-loops nos estados de borda



- Representar estado como  $(i, j)$
  - Dado estado atual, sabemos os possíveis próximos estados e respectivas probabilidades de transição
- Dado estado  $(i, j)$ , escolher:
    - $(i+1, j)$  com  $p_o$ ,  $(i-1, j)$  com  $p_l$ ,  $(i, j+1)$  com  $p_n$ ,  $(i, j-1)$  com  $p_s$
    - atenção com estados de borda  $(1, j)$  ou  $(i, 1)$
  - Muito eficiente:  $O(1)$  de memória para simular CM infinita!

# Exemplo 2

- Passeio aleatório em Hipercubo de 100 dimensões
  - CM tem  $2^{100}$  estados, impossível representar em qualquer computador
- Estado da CM é um vetor binário com 100 bits
- Estados vizinhos são os vetores que diferem do atual em exatamente 1 bit
  - definição de hipercubo
- Passeio aleatório escolhe vizinho uniformemente
  - escolher um bit uniformemente, inverter o bit (não precisa nem enumerar os vizinhos)
  - $O(1)$  para fazer uma transição