

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 $\pi(t) = \pi(0)P^t$
- π : distribuição estacionária da CM, dada por $\pi = \pi P$
- τ_ε : tempo de mistura da CM, dado ε

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



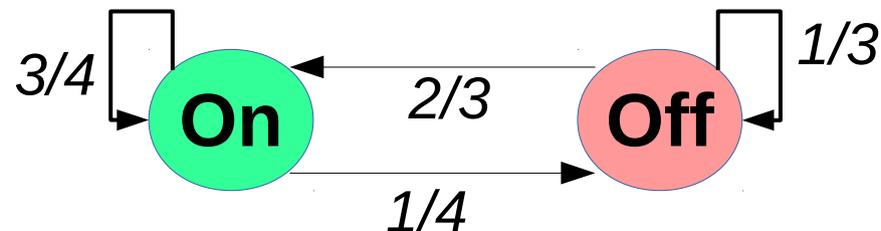
- Realização: $X_0 = 1, X_1 = 2, X_2 = 2, X_3 = 1, X_4 = 2, X_5 = 1, X_6 = 1, \dots$
- Realização: $X_0 = 2, X_1 = 2, X_2 = 1, X_3 = 1, X_4 = 2, X_5 = 2, X_6 = 1, \dots$
- Realização: $X_0 = 1, X_1 = 1, X_2 = 2, X_3 = 1, X_4 = 1, X_5 = 1, X_6 = 2, \dots$

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 ω

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

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



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

- $\omega = 2, 1, 2, 1, 2, 1, 2, 1, 2 \quad P[\omega] = ?$

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 π , 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 π

- Teorema ergódico garante que método de Monte Carlo funciona também em CM
 - conexão entre teoria (equações) e prática (simulação)
- Exemplo: Como estimar π ?
- Usar a CM para gerar um caminho amostral ω 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 com k)
- Outro método para calcular π

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

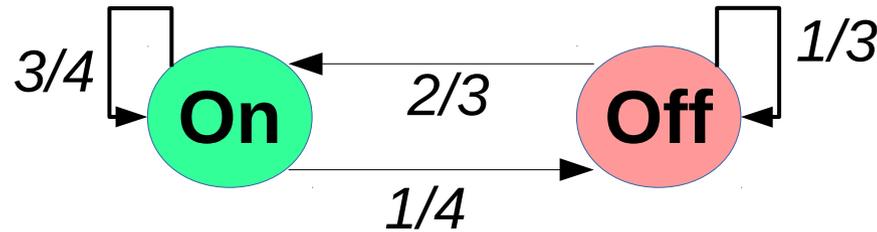
3) gerar amostras deste conjunto

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

- sabemos gerar amostras de dado enviesado!

Exemplo com Modelo On-Off

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



- 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

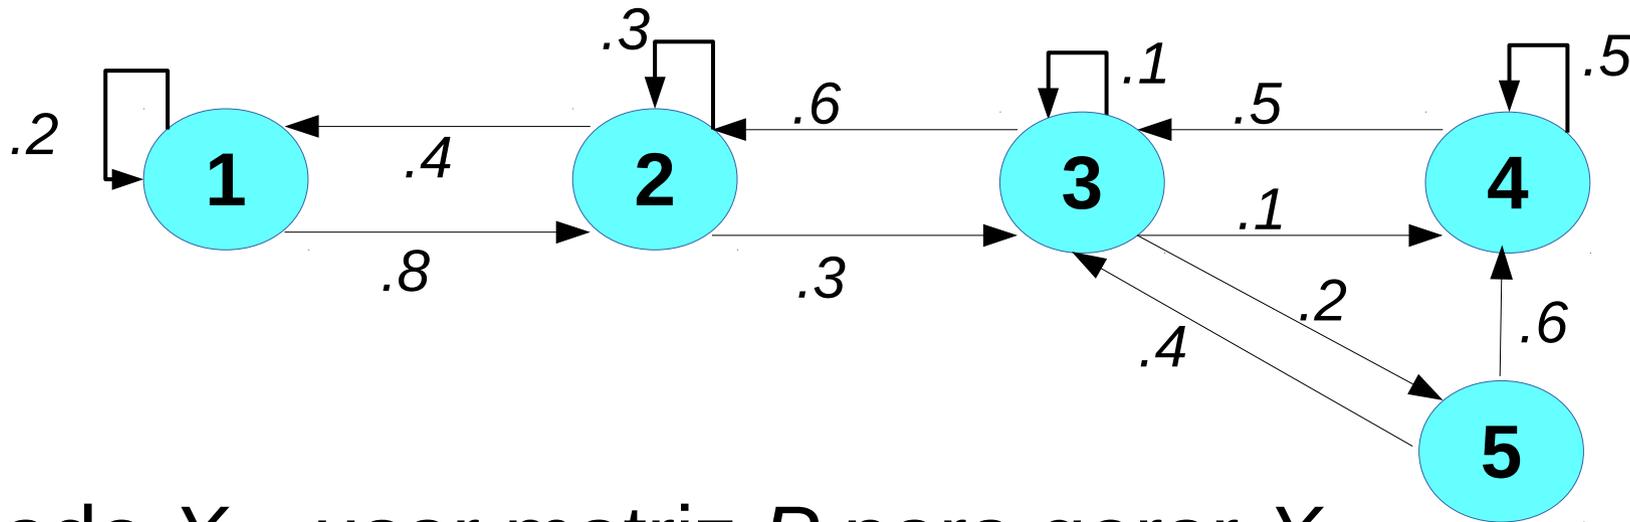
Problema?

- 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



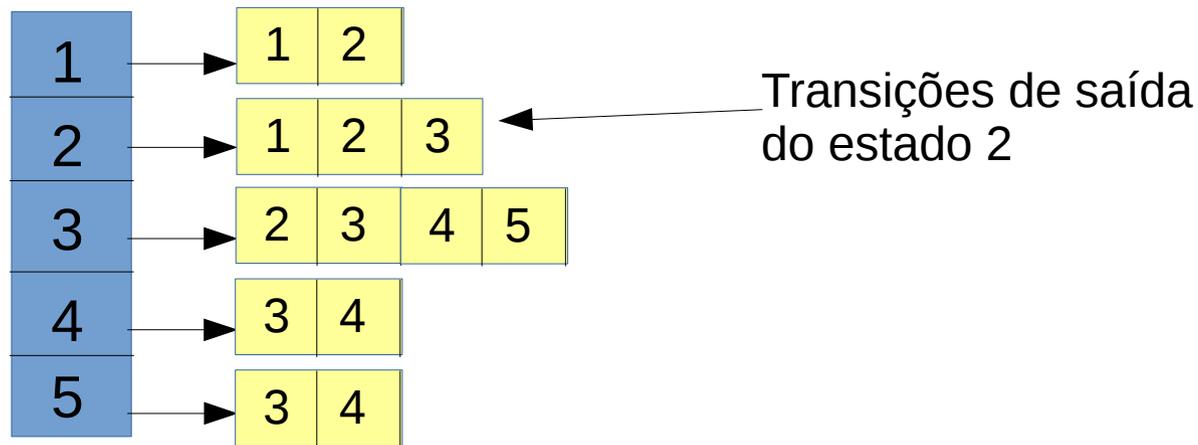
- Dado X_k , usar matriz P para gerar X_{k+1}
- Ex. dado $X_4 = 3$, como gerar X_5 ?
- X_5 é um dos vizinhos de saída do estado 3
 - 4 estados possíveis $\{2, 3, 4, 5\}$, cada um possui uma probabilidade, dado por $P_{3,2}$, $P_{3,3}$, $P_{3,4}$, $P_{3,5}$
 - gerar amostra para X_5 de acordo com essas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

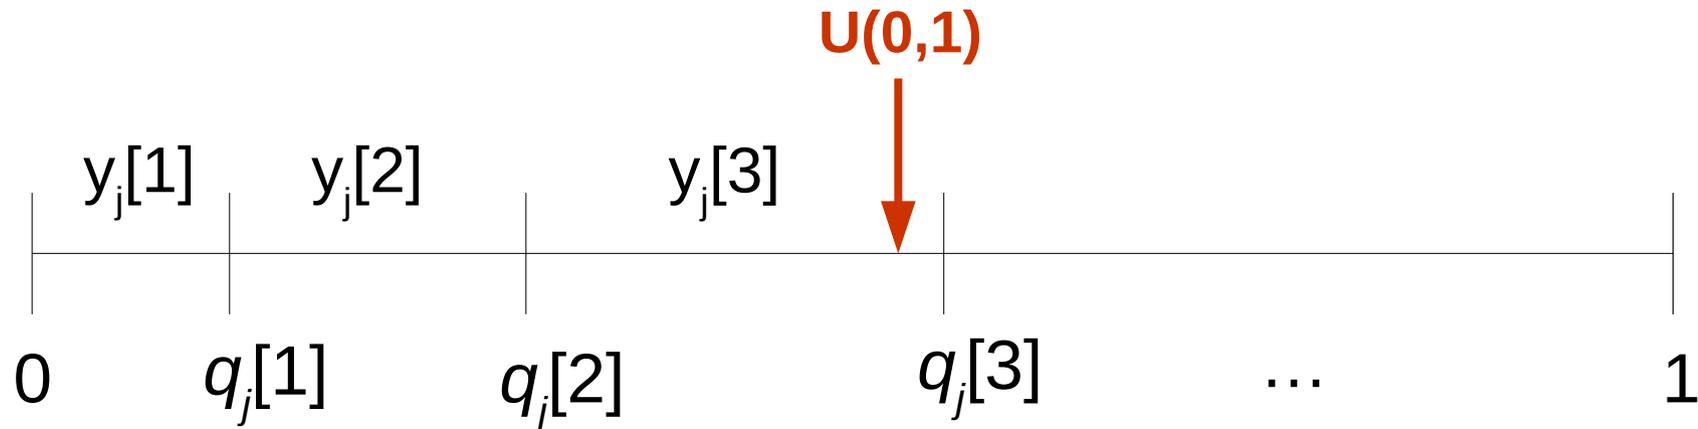
- Representar matriz P como vetor de adjacência
 - apenas entradas não-nulas são representadas
- Exemplo da CM anterior



- 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:



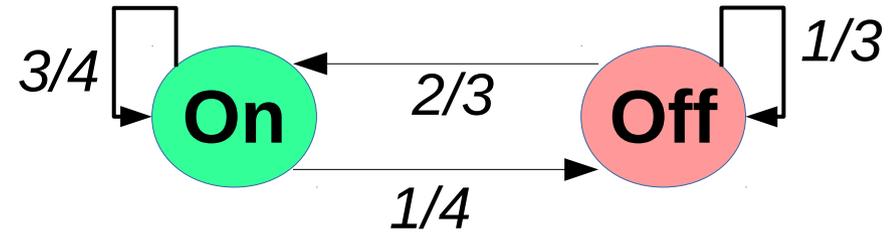
- No exemplo, $y_j[3]$ é o próximo estado!
- Complexidade: $O(d)$, onde d é grau de saída do estado
- Método Alias: complexidade $O(1)$ + custo inicial
 - vantagem depende do retorno ao mesmo estado e tamanho do caminho amostral

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)

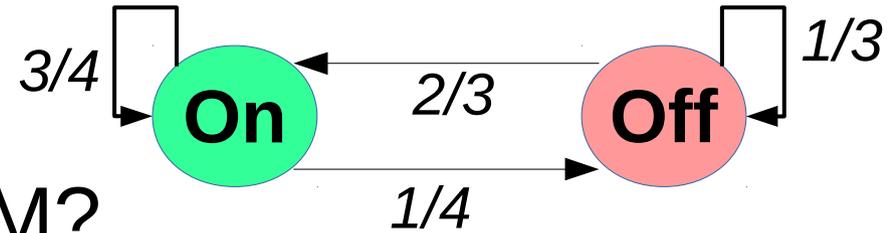
Gerando Amostras

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!

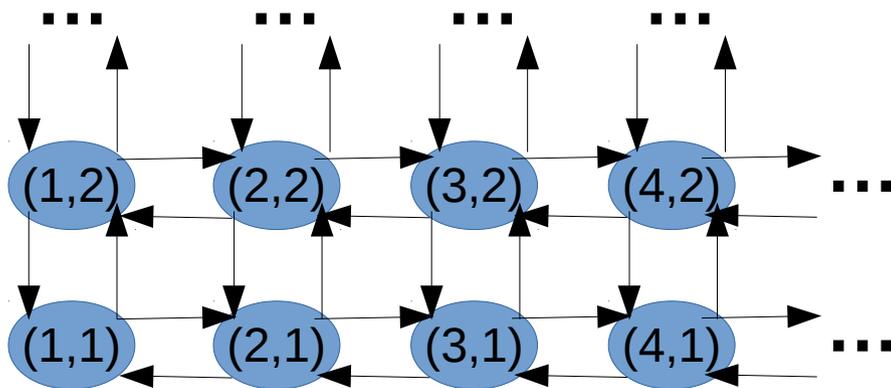
- **Ideia 1:**
 - 1) Calcular π (distribuição estacionária)
 - 2) Gerar amostras desta distribuição
- **Ideia 2:**
 - 1) Simular CM até X_t para t suficiente grande
 - tempo de mistura τ_ϵ
 - 2) Retornar a amostra gerada para X_t

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