

# Aula 14

## Aula passada

- Autovalores, autovetores, decomposição
- Convergência para estacionaridade
- Tempo de mistura
- Spectral gap
- Tempo de mistura de passeios aleatórios

## Aula de hoje

- Caminho amostral
- Teorema Ergódico
- Estimando  $\pi$
- Simulação de CM
- Gerando amostras
- Markov Chain Monte Carlo (caso simétrico)
- Exemplo

# 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

- Seja  $P$  a matriz de transição de estados de uma CM
- Seja  $X_t$  uma 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:  $\pi(0) = (0.8 \quad 0.2)$



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

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

# O que ocorre com $X_t$ ?

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

**Usar a 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  $X_t$ , com um grande número de amostras ( $k$  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, com um grande número de amostras ( $k$  muito grande)?

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

# 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 consistente (possui viés para tempo  $k$ )
- Outro método para encontrar  $\pi$



# Simulando uma CM


- Como simular uma CM?
  - entrada: matriz  $P$ , distribuição inicial  $\pi(0)$
- Simular cada valor  $X_t$ , para  $t=0,1, \dots$
- Usar  $\pi(0)$  para gerar  $X_0$
- Usar  $P$  (matriz de transição) para gerar  $X_1, X_2, \dots$
- Como gerar  $X_k$  dado  $X_{k-1}$  ?

## Método da transformada inversa!

- Gerar  $U \sim \text{uniforme}(0,1)$ , usar  $(X_{k-1})$ -ésima linha da matriz  $P$  para escolher vizinho, valor de  $X_k$
- Problema: ineficiente (se matriz  $P$  é esparsa)

# Simulando CM Eficientemente


- Representar matriz  $P$  como vetor de adjacência
  - apenas entradas não-nulas são representadas
- $y_j[i]$  = estado da  $i$ -ésima transição não-nula do de  $j$
- $q_j[i]$  = prob. de transição acumulada das primeiras  $i$ -ésimo transições de  $j$



- Complexidade:  $O(\# \text{ transições não-nulas})$
- Método Alias: complexidade  $O(1)$  + custo inicial

# Gerando Amostras

- Considere uma CM com matriz de transição  $P$
- Como gerar amostras de  $X_t$ ?
- Exemplo:  $\pi(0) = (0.8 \ 0.2)$
- Gerar amostras de  $X_{10}$ ?



## • Ideias

- 1) Calcular  $\pi(t)$ , gerar amostras desta distribuição
- 2) Simular CM até  $X_t$ , para cada amostra

**Qual é a melhor abordagem?**

- Depende de  $n$  (tamanho da CM) e  $t$ , e número de amostras

# Espaços Grandes e Complicados

- Considere um espaço amostral grande e complicado
  - grande = muitos elementos
  - complicado = não é fácil enumerar os elementos
- Todos os grafos conexos com  $n$  vértices
  - não é fácil enumerar grafos conexos
- Todos os percursos por  $n$  cidades de comprimento  $L$  ou menor
  - não é fácil enumerar percursos de comp.  $L$  ou menor
- Em geral: espaço amostral combinatorial com restrições que dificultam enumeração

**Como gerar amostras destes espaços?**

# Gerando amostras uniformes

- Como gerar amostras uniformes destes espaços?

## Ideia preliminar

- 1) Aumentar espaço de estado amostral (ex. removendo restrição) – facilitar geração
- 2) Usar método da rejeição – rejeitar amostras que não atendem a restrição, remover viés
- Exemplo: Gerar grafos conexos com  $n$  vértices?
  - modelo  $G(n, p)$  com  $p=1/2$  todos os grafos são equiprováveis (não temos viés)
  - gerar grafo de  $G' \sim G(n, 1/2)$
  - retorna se  $G'$  é conexo, cc gera outro  $G'$

## Problema?

- Pode ser muito ineficiente!

# Markov Chain to the Rescue

- Como usar CM para resolver este problema?
- Construir CM cujos estados correspondem aos elementos de  $S$  (espaço amostral)
- Construir uma matriz de transição  $P$  tal que distribuição estacionária  $\pi$  seja uniforme
- Simular CM para gerar amostras
  - dar  $\tau_\epsilon$  passos para gerar uma amostra

## Markov Chain Monte Carlo (MCMC)

- Método baseado em CM para gerar amostras de uma distribuição qualquer
  - não precisa ser uniforme

# MCMC

## Como construir CM, se $S$ é muito grande?

- Não precisamos construir a priori
- Podemos construir e simular CM ao mesmo tempo, um passo de cada vez

## Qual CM mais apropriada?

- Baixo tempo de mistura  $\tau_\epsilon$ , parar gerar amostras
- Poucas transições de saída em cada estado (ex.  $\log n$ )
- Fácil descrição dos estados vizinhos (a partir do estado atual)
- Tema de grande debate e avanço!

# MCMC – Caso Simétrico

- Considere uma CM com matriz de transição  $P$  simétrica
  - $P_{ij} = P_{ji}$  para todo estado  $i, j$
- Distribuição estacionária é uniforme e a CM é reversível
- Queremos modificar  $P$  para construir uma nova CM cuja distribuição estacionária seja  $\pi$  qualquer
  - $\pi$  é entrada para o problema
- **Ideia:** não “aceitar” todas as transições da CM original
  - continuar no mesmo estado para induzir  $\pi$  qualquer
  - parecido com método da rejeição
- Rejeição é probabilística, para cada transição não-nula em  $P$ , temos  $a(i, j)$



# MCMC – Caso Simétrico

- Considere CM no estado  $i$  e uma proposta de transição da CM original (ou seja, em  $P$ ) para o estado  $j$ 
  - aceita transição com probabilidade  $a(i, j)$ ,  
rejeita com complemento
- Matriz de transição  $P'$  da nova CM

$$P'_{ij} = \begin{cases} P_{ij} a(i, j), & \text{se } i \neq j \\ 1 - \sum_{k:k \neq i} P_{ik} a(i, k), & \text{se } i = j \end{cases}$$

- Temos que escolher  $a(i, j)$  tq  $P'$  tenha distribuição estacionária dada por  $\pi$ , ou seja:

$$\pi_i P_{ij} a(i, j) = \pi_j P_{ji} a(j, i) \quad \leftarrow \text{Garantindo também que } P' \text{ é reversível}$$

# MCMC – Caso Simétrico

- Como  $P_{ij} = P_{ji}$  (por simetria em  $P$ ), temos

$$\pi_i a(i, j) = \pi_j a(j, i)$$

- Como  $a(i, j)$  e  $a(j, i)$  são probabilidades, temos

$$\pi_i a(i, j) \leq \pi_i \quad \pi_i a(i, j) = \pi_j a(j, i) \leq \pi_j$$

- Como  $a(i, j)$  deve ser o maior possível para evitar desperdício, temos

$$a(i, j) = 1, \quad \text{se } \pi_i \leq \pi_j$$

$$a(i, j) = \frac{\pi_j}{\pi_i}, \quad \text{se } \pi_i > \pi_j$$

- Ou seja,

$$a(i, j) = \min \left\{ 1, \frac{\pi_j}{\pi_i} \right\}$$

# Exemplo

- Gerar amostras de pares ordenados  $(x, y)$  em  $[1, n] \times [1, n]$ 
  - grid 2D discreto e quadrado com  $n$  pontos

$$P[(x, y)] = \frac{(x+y)^2}{Z} \quad Z = \sum_{(x, y) \in [1, n]^2} (x+y)^2$$

← constante de normalização

- CM original é torus 2D com  $n \times n$  vértices
  - estado dado por  $(x, y)$ , com  $x, y = 1, \dots, n$
  - todo estado tem 4 transições,  $P_{ij} = 1/4$ , para algum  $i, j$
  - CM é simétrica e conseqüentemente uniforme
- Como transformar  $P$  em  $P'$  para induzir  $\pi$  conforme definição acima?

# Exemplo

- Precisamos CM tal que  $\pi_{(x,y)} = \frac{(x+y)^2}{Z}$
- Seja estado  $i = (x,y)$  e  $j = (x',y')$ . Desta forma, podemos definir  $a(i, j)$  como
$$a(i, j) = \min \left\{ 1, \frac{\pi_j}{\pi_i} \right\} = \min \left\{ 1, \frac{(x'+y')^2}{(x+y)^2} \right\}$$
- Por fim, definimos  $P'$  como anteriormente
  - $P'_{ij} = P_{ij} a(i,j)$  se  $i \neq j$ , etc.
- **Boa notícia:** não precisamos calcular  $Z$  para definir  $a(i, j)$ 
  - seria proibitivo calcular  $Z$
- Para gerar uma amostra, simular CM definida por  $P'$  por  $\tau_\varepsilon$  e retornar o estado atual