

# Aula 15

## Aula passada

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

## Aula de hoje

- Metropolis-Hasting
- Amostrando vértices sem conhecer a rede
- Modelo Hardcore

# Markov Chain Monte Carlo

- **Problema:** gerar amostras de um espaço  $S$  grande e complicado com distribuição  $\pi$ 
  - ex: amostrar grafos conexos com  $n$  vértices com probabilidade proporcional ao número de arestas
- **Solução:** Markov chain Monte Carlo
  - construir uma CM com espaço de estado  $S$  tal que  $\pi$  seja sua distribuição estacionária
  - gerar amostras através de caminhos amostrais de comprimento  $\tau_\epsilon$
- **Dificuldade:** construir CM que seja eficiente em termos de calcular transições e tempo de mistura
  - arte com dicas de engenharia

# Construindo a CM para MCMC

- **Ideia 1:** partindo de uma CM aperiódica e irredutível, transformar cadeia em outra mudando valores de transições não nulas, tq distribuição estacionária seja  $\pi$
- **Ideia 2:** não “aceitar” todas as transições da CM original, continuar no mesmo estado para induzir  $\pi$  qualquer
  - para cada transição não-nula em  $P$ , temos probabilidade de aceite  $a(i, j)$
- **Problema:** encontrar  $a(i, j)$  tq nova CM tenha distribuição  $\pi$

## Algoritmo (ou cadeia) de Metropolis-Hasting

- Aula passada:  $P$  simétrica, ou seja  $P_{ij} = P_{ji}$
- $P$  qualquer no próximo slide

# Metropolis-Hasting

- 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  $a(i, j)$  tal que

$$\pi_i P_{ij} a(i, j) = \pi_j P_{ji} a(j, i)$$

- garante que  $\pi$  é distribuição estacionária de  $P'$
- garante que  $P'$  é reversível

# Metropolis-Hasting

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

$$\pi_i P_{ij} a(i, j) \leq \pi_i \quad \pi_i P_{ij} a(i, j) = \pi_j P_{ji} a(j, i) \leq \pi_j$$

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

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

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

- Ou seja,

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

- Entradas de  $P'$  calculadas desta forma

# Metropolis-Hasting

- Provando que  $a(i, j)$  de fato funciona
- Assumir que  $P_{ij} > 0$  se e somente se  $P_{ji} > 0$
- Mostrar que  $a(i, j) = \min \left\{ 1, \frac{\pi_j P_{ji}}{\pi_i P_{ij}} \right\}$
- Satisfaz  $\pi_i P_{ij} a(i, j) = \pi_j P_{ji} a(j, i)$  para todo  $i, j$
- Caso  $a(i, j) = 1$ . Neste caso, temos que  $\pi_i P_{ij} \leq \pi_j P_{ji}$

- Então

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

- Consequentemente

$$\pi_i P_{ij} = \pi_j P_{ji} a(j, i) = \pi_j P_{ji} \frac{\pi_i P_{ij}}{\pi_j P_{ji}} = \pi_i P_{ij}$$

- O outro caso é análogo

# Amostrando Vértices

- Considere grafo grande e desconhecido (não conhecemos os vértices ou as arestas, a priori)
  - ex. grafo de amizades do facebook
- Podemos percorrer o grafo: a partir de um vértice, descobrir seus vizinhos
- Como gerar amostras de vértices uniformemente?
  - ex. estimar fração de brasileiros no FB
- **Ideia 1:** BFS de raio  $k$ , amostrar uniforme no vértices descobertos
- **Ideia 2:** Passeio aleatório de comprimento  $k$ , retornar vértice  $X_k$

**Como garantir que amostra é uniforme?**

- Ideias 1 e 2 geram amostras enviesadas (não uniformes)


# MCMC to the Rescue

- Construir CM usando algoritmo de Metropolis-Hasting tq  $\pi$  seja uniforme nos vértices
  - $\pi_v = 1/Z$  onde  $Z$  é o número de vértices da rede (desconhecido)
- Modificar CM induzida por um passeio aleatório (que não é simétrica)
- Definindo probabilidade de aceite
  - CM original, temos:  $P_{ij} = 1/d_i$  ,  $P_{ji} = 1/d_j$
- $$a(i, j) = \min \left\{ 1, \frac{\pi_j P_{ji}}{\pi_i P_{ij}} \right\} = \min \left\{ 1, \frac{d_i}{d_j} \right\}$$
- Logo  $P'_{ij} = 1/d_i * \min\{ 1, d_i / d_j \}$
- Enviesa o passeio contra vértices de grau alto, dando distribuição estacionária uniforme
- Método usado na prática, hoje em dia!



# Exemplo – *Hardcore Model*

- Modelo *hardcore*: atribuir bolinhas aos vértices de um grafo tal que vértices vizinhos não possuam bolinhas
  - vértice pode ter 0 ou 1 bolinha



- Dado um grafo  $G=(V, E)$ ,  $S$  é o conjunto de todas as configurações, e  $S'$  o subconjunto de configurações válidas
  - $|S| = 2^n$  , para grafo com  $n$  vértices
- **Problema:** qual é o valor esperado do número de bolinhas de uma configuração?
  - distribuição uniforme sobre o espaço  $S'$

# Exemplo – Hardcore Model

- Seja  $n(C)$  o número de bolinhas de uma configuração  $C$ , escolhida ao acaso (uniformemente)

- Então

$$E[n(C)] = \frac{1}{Z} \sum_{c \in S'} n(c) \quad Z = |S'| = \sum_{c \in S} 1 (c \text{ é válida})$$

- **Problemas:**

(1) como enumerar  $S'$  de forma eficiente?

(2) como lidar com o tamanho de  $S'$  (exponencial)?

- **Solução:** Markov Chain Monte Carlo

# MCMC para *Hardcore Model*

- Construir CM onde estados são elementos de  $S'$ 
  - configurações válidas
- Fazer com que distribuição estacionária desta CM seja uniforme,  $\pi_c = 1/Z$  para toda configuração  $c$
- Gerar caminho amostral pela CM e usar configurações
  - $X_k$  estado da CM no passo  $k$
- Monte Carlo para estimar valor esperado

$$\hat{n}(k) = \frac{1}{k} \sum_{l=1}^k n(X_l) \xrightarrow[\text{(teorema ergódico)}]{\text{converge quando } k \rightarrow \text{infinito}} E[n(C)]$$

↑  
Estimador do número médio de bolinhas após  $k$  amostras

# MCMC para *Hardcore Model*

- Construir a CM é equivalente a definir as transições para cada estado
  - cada configuração leva a outras configurações
- **Algoritmo**
  - 1) Escolher vértice  $v$  do grafo aleatoriamente
  - 2) Se todos os vizinhos de  $v$  estão em 0, colocar  $v$  em 1 com probabilidade  $\frac{1}{2}$ ; caso contrário colocar  $v$  em 0
  - 3) Manter configuração de todos os outros vértices
- CM acima é aperiódica e irredutível, e possui distribuição estacionária uniforme
  - usar equações de reversibilidade para mostrar  $\pi$

$$\pi_i P_{ij} = \pi_j P_{ji}$$

 i e j são duas configurações

# Mostrando

$$\pi_i P_{ij} = \pi_j P_{ji}$$

- Seja  $i$  e  $j$  duas configurações quaisquer em  $S'$
- Seja  $d(i,j)$  o número de vértices em que  $i$  e  $j$  diferem
- $d(i,j) = 0 \rightarrow$  duas configurações são idênticas ( $i = j$ )
- $d(i,j) > 1 \rightarrow$  não temos transições, pois apenas um vértice troca de valor por vez (vale a relação, pois  $P_{ij} = 0$ )
- $d(i,j) = 1 \rightarrow$  diferem na configuração de um único vértice  $v$ 
  - vizinhos de  $v$  são todos zero, pois são válidas
  - $P_{ij} = 1/n * 1/2$  ( $v$  em 1  $\rightarrow$   $v$  em 0)
  - $P_{ji} = 1/n * 1/2$  ( $v$  em 0  $\rightarrow$   $v$  em 1)
  - Logo,  $\pi_i = \pi_j = 1/Z$