

# Aula 13

## Roteiro


- Amostrando espaços complicados
- Markov Chain Monte Carlo
- Caso simétrico
- Exemplo
- Metropolis-Hastings
- Amostrando vértices (sem conhecer a rede)

# Espaço Amostral de Objetos

- Considere um espaço amostral de objetos



Frutas



Grafos

**Como gerar amostras destes espaços?**

- amostra é um objeto

# Gerando Amostras Uniformes

- **Ideia 1:**

- 1) Mapear cada elemento para um número natural
- 2) Escolher um número entre  $[1, |S|]$
- 3) Usar o mapeamento para retornar objeto

- **Exemplo**



- banana = 1, maçã = 2, pera = 3, manga = 4, morango = 5, ...
- escolher uniforme em  $[1, 19]$
- retornar a fruta

- Construir mapeamento:  $O(|S|)$

← Proibitivo em alguns casos!

- Gerar amostra:  $O(1)$

# Gerando Amostras Uniformes


- **Ideia 2:** Construir elemento de forma iterativa

1) sequência de escolhas aleatórias levam à escolha do elemento

- Exemplo:  $S = \{ \text{todos os grafos com } n \text{ vértices} \}$

- $|S| = 2^{n(n-1)/2}$

- $n = 3, |S| = 8$



- Se cada aresta é uma Bernoulli( $1/2$ ), resultado é um grafo uniforme!

- Realizar cada aresta gera grafo em tempo  $n(n-1)/2$

# Espaços Grandes e Complicados

- Considere um espaço amostral grande e complicado
  - grande = enorme quantidade de elementos
  - complicado = não é fácil construir elementos de forma iterativa
- Espaço amostral combinatorial (grande) com restrições (complicado)


**Como gerar amostras destes espaços?**

- Ideia 1 e Ideia 2 não funcionam!

# Exemplos


- Todos os grafos conexos com  $n$  vértices

$n = 3,$   
 $|S| = 4$



- Todos os percursos por  $n$  cidades de comprimento  $L$  ou menor

$n = 4,$   
 $L = 10,$   
 $|S| = ?$



Percursos e comprimento:

1,2,3,4  $\rightarrow$  8

1,2,4,3  $\rightarrow$  12

2,3,4,1  $\rightarrow$  10

...

- $|S|$  cresce exponencialmente com  $n$
- Não é fácil construir amostra de forma iterativa

# Gerando Amostras Uniformes

- **Ideia 3:**

- 1) Aumentar espaço de estado amostral (ex. removendo restrição) para usar Ideia 2

- 2) Usar *rejection sampling* para rejeitar amostras que não atendem a restrição

- **Exemplo: Amostrar grafos conexos com  $n$  vértices**

- 1) gerar grafo  $G$  uniforme (usando Ideia 2)

- 2) se  $G$  não é conexo vai para 1), se não retorna  $G$

## Problema?

- Tempo médio para gerar amostra:  $1/p$ , onde  $p$  é a fração de amostras que atendem a restrição

- Se  $p$  é muito baixo (ex. vai a zero com  $n$ ), algoritmo é muito ineficiente

# Markov Chain to the Rescue

- **Ideia 4:** Construir e simular uma cadeia de Markov
- Construir CM cujos estados correspondem aos elementos de  $S$  (espaço amostral)
- Construir 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 espaços arbitrários com qualquer distribuição
  - não precisa ser uniforme



# MCMC

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

- Não precisamos construir a priori
- Podemos simular CM iterativamente (aula passada)

## Como determinar as transições?

- Fácil descrição dos estados vizinhos a partir do estado atual
- Poucas transições de saída de cada estado (ex.  $\log |S|$ )
- Baixo tempo de mistura, *fast mixing*:  $\tau_\epsilon \leq \log |S|$
- Tema de muita pesquisa!

# Receita para MCMC

- **Dado:** descrição do espaço amostral  $S$ , e distribuição de probabilidade sobre os estados,  $\pi$
- **Saída:** uma amostra aleatória de  $S$  de acordo com  $\pi$
- **Receita:**
  - 1) Construir CM irredutível onde cada estado corresponde a um elemento do espaço (cadeia base)
  - 2) Transformar cadeia base em outra CM que é reversível e possui distribuição estacionária  $\pi$
  - 3) Simular caminho amostral longo o suficiente e retornar o estado final
    - outra amostra independente requer simular um novo caminho amostral

# MCMC – Caso Simétrico

- Cadeia base tem matriz de transição  $P$  simétrica
  - $P_{ij} = P_{ji}$  para todo estado  $i, j$
- Modificar  $P$  para construir uma nova CM que seja reversível com distribuição estacionária  $\pi$ 
  - $\pi$  é entrada para o problema
- **Ideia:** nova cadeia não aceita todas as transições da cadeia base
  - continuar no mesmo estado para induzir  $\pi$
  - parecido com método da rejeição
- Aceite é probabilístico e independente para cada transição
  - $a(i, j)$  : probabilidade de aceitar transição  $i \rightarrow j$

# MCMC – Caso Simétrico

- Considere cadeia base no estado  $i$  e uma “proposta” de transição para estado  $j$ 
  - nova cadeia aceita transição com probabilidade  $a(i, j)$
- Matriz de transição  $P'$  da nova cadeia

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

- 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

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

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

- Temos infinitas soluções para o par  $a(i, j)$  e  $a(j, i)$
- Queremos maximizar a probabilidade de aceite, logo

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

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

- Ou seja,

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

# Exemplo

- Gerar amostras de pares ordenados  $(X, Y)$  em  $[1, n] \times [1, n]$ 
  - grid 2D discreto e quadrado com  $n^2$  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 base é torus 2D com  $n \times n$  vértices
  - estado dado por  $(x, y)$ , com  $x, y = 1, \dots, n$
  - todo estado tem 4 transições: norte, sul, leste e oeste,  $P_{ij} = 1/4$  ( $i$  e  $j$  são estados vizinhos)
  - CM é simétrica,  $P_{ij} = P_{ji}$
- Transformar  $P$  em  $P'$  para induzir  $\pi$  conforme definição

# 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  $a(i, j)$ 
  - poderia ser proibitivo calcular  $Z$
- Para gerar uma amostra, simular CM definida por  $P'$  por  $\tau_\varepsilon$  e retornar o estado atual

# MCMC – Caso Geral

- Considere cadeia base no estado  $i$  e uma “proposta” de transição para estado  $j$ 
  - nova cadeia aceita transição com probabilidade  $a(i, j)$
- Matriz de transição  $P'$  da nova cadeia

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

- 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-Hastings

- Temos infinitas soluções para o par  $a(i, j)$  e  $a(j, i)$
- Queremos maximizar a probabilidade de aceite, logo

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

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

- Ou seja,

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

- $P'$  definida com essa probabilidade de aceite é chamada de cadeia de Metropolis-Hastings
  - dando origem ao algoritmo de Metropolis-Hastings

# Metropolis-Hastings

- Mostrando que definição de  $a(i, j)$  satisfaz a condição
- 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 vértices ou arestas, a priori)
- Podemos percorrer o grafo: a partir de um vértice, descobrir seus vizinhos
  - ex. rede de amizades do Facebook
- Como gerar amostras de vértices uniformemente?
  - ex. estimar fração de brasileiros no FB
- **Ideia 1:** BFS de raio  $k$ , amostrar uniforme nos 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 cadeia de Metropolis-Hasting tq  $\pi$  seja uniforme nos vértices
  - $\pi_v = 1/Z$  onde  $Z$  é o número de vértices da rede (desconhecido)
- Cadeia base: passeio aleatório simples
- Definindo probabilidade de aceite
  - CM base, 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, adicionando *self-loops*, tornando a distribuição estacionária uniforme

# Exemplo

- Grafo



- Matriz de transição do passeio aleatório

$$P = \begin{pmatrix} 0 & 1/2 & 0 & 0 & 1/2 & 0 \\ 1/3 & 0 & 1/3 & 1/3 & 0 & 0 \\ 0 & 1/4 & 0 & 1/4 & 1/4 & 1/4 \\ 0 & 1/2 & 1/2 & 0 & 0 & 0 \\ 1/2 & 0 & 1/3 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \end{pmatrix}$$

- Transformação

$$P'_{i,j} = \frac{1}{d_i} \min \left\{ 1, \frac{d_i}{d_j} \right\}$$

- Cadeia de Metropolis-Hastings com distribuição estac. uniforme

$$P' = \begin{pmatrix} 1/6 & 1/3 & 0 & 0 & 1/2 & 0 \\ 1/3 & 1/12 & 1/4 & 1/3 & 0 & 0 \\ 0 & 1/4 & 0 & 1/4 & 1/4 & 1/4 \\ 0 & 1/3 & 1/4 & 5/12 & 0 & 0 \\ 1/2 & 0 & 1/4 & 0 & 1/4 & 0 \\ 0 & 0 & 1/4 & 0 & 0 & 5/4 \end{pmatrix}$$

# Simulação Iterativa

- Mas não conhecemos o grafo!
- Simular caminho amostral iterativamente, a cada passo:
  - descobrir os vizinhos do vértice atual
  - descobrir grau de cada vizinho do vértice atual
  - determinar as probabilidades de transição para cada vizinho (e também *self-loop*)

$$P'_{i,j} = \frac{1}{d_i} \min \left\{ 1, \frac{d_i}{d_j} \right\} \quad \leftarrow \text{Para todo } j \text{ vizinho de } i \text{ (estado atual)}$$

- fazer escolha aleatória, atualizar vértice atual, e repetir
- Método considerado *estado-da-arte* e usado na prática!