

Aula 13

Roteiro

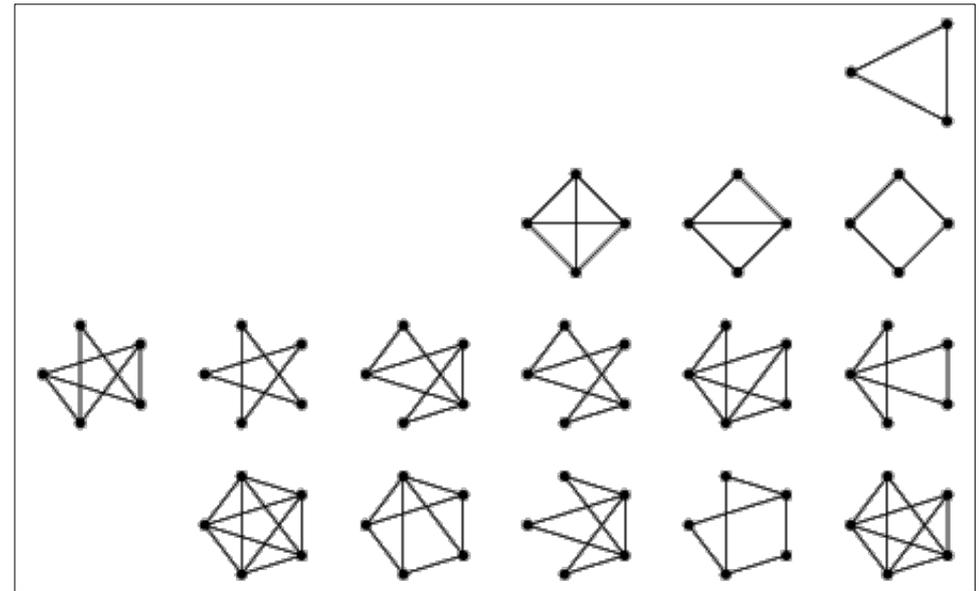
- Amostrando espaços complicados
- Markov Chain Monte Carlo
- Caso simétrico
- Exemplo
- Metropolis-Hastings
- Amostrando vértices (sem conhecer a rede)

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

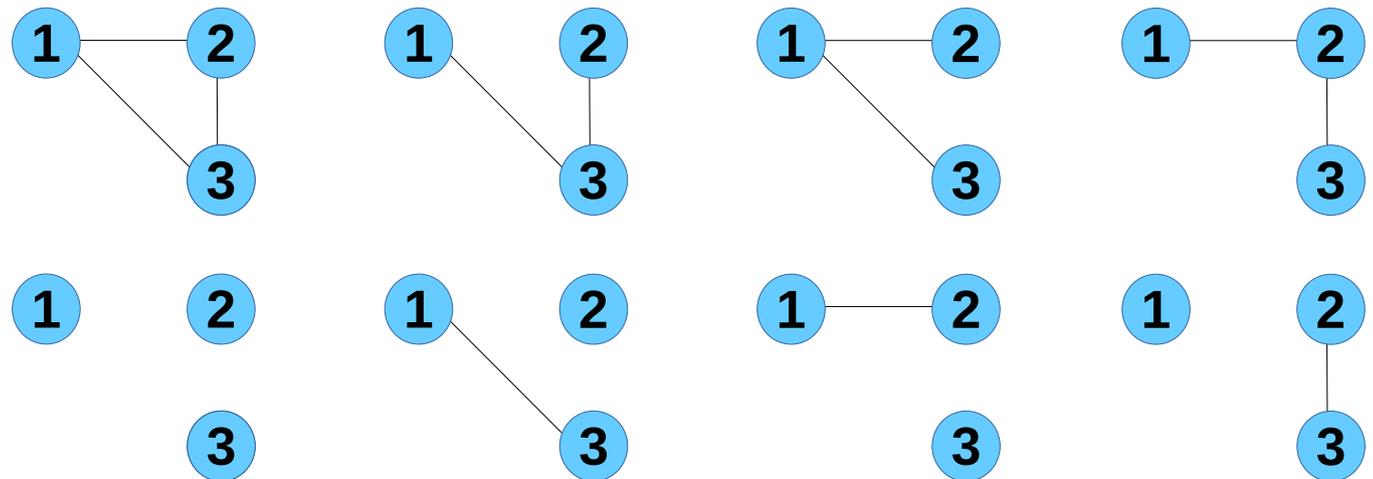
- **Ideia 2:** Construir elemento de forma iterativa

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 escolhido uniformemente

- Realizar cada aresta gera grafo leva 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)

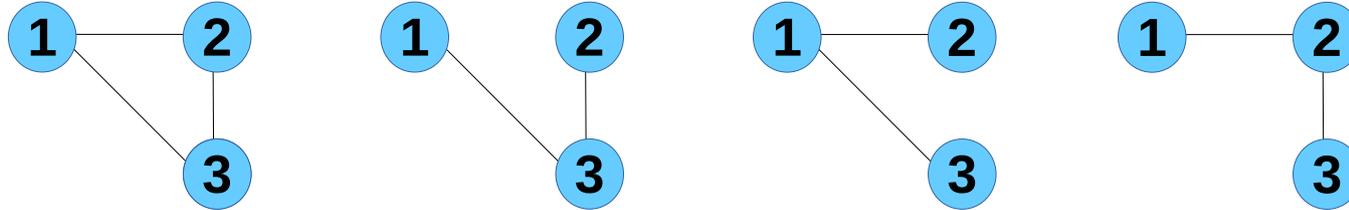
Como gerar amostras destes espaços?

- Ideia 1 e Ideia 2 não funcionam!

Exemplos

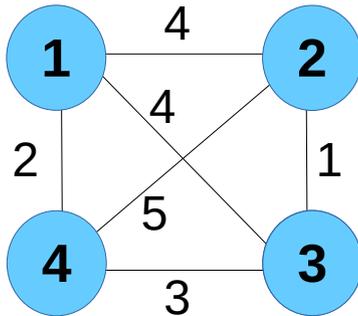
- Todos os grafos **conexos** com n vértices

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



- 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 amostral adicionando elementos (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 π seja uniforme
- Simular CM para gerar amostras
 - dar τ_ϵ 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, π
- **Saída:** uma amostra aleatória de S de acordo com π
- **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 π
 - 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 π
 - π é entrada para o problema
- **Ideia:** nova cadeia não aceita todas as transições da cadeia base
 - continuar no mesmo estado para induzir π
 - 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 π , 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 π 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 τ_ϵ 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 π 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?

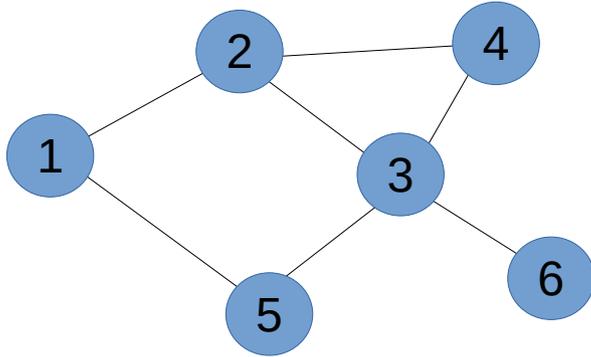
- Ideias 1 e 2 geram amostras enviesadas (não uniformes)

MCMC to the Rescue

- Construir cadeia de Metropolis-Hasting tq π 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!