

Estatística de Redes Sociais

Antonio Galves

Módulo 2

5a. aula

Grafos aleatórios e redes sociais.

Mundo pequeno, Erdős-Rényi, Watts-Strogatz.

Recapitulando: matriz de adjacência de um grafo

- ▶ A matriz de adjacência é uma forma computacional de representar o grafo $G = (V, E)$.
- ▶ Se o grafo for dirigido, para todo par ordenado de vértices (v, v') , com $v \neq v'$, definimos

$$M(v, v') = 1 \text{ ou } M(v, v') = 0$$

se houver (respectivamente, se não houver) uma flecha (uma aresta dirigida), indo de v a v' .

- ▶ Se o grafo não for dirigido, a ordem (v, v') ou (v', v) não importa e $M(v, v') = M(v', v)$.

Recapitulando: o grafo de Erdős-Rényi

- ▶ Conjunto de vértices: $V = \{1, \dots, N\}$.
- ▶ Os valores das entradas da matriz

$$M = (M(v, v') : v, v' \in V, v \neq v')$$

são variáveis aleatórias, independentes e identicamente distribuídas (i.i.d.) com

$$\mathbb{P}\{M(v, v') = 1\} = p \text{ e } \mathbb{P}\{M(v, v') = 0\} = 1 - p,$$

e $M(v, v) = 0$, para todo $v \in V$.

- ▶ Essa classe de grafos será designada com a notação $G(N, p)$.

Uma noção básica

- ▶ Em um grafo não dirigido $G = (V, E)$, tendo M como matriz de adjacência, o grau $D(v)$ de um vértice v é definido como

$$D(v) = \sum_{v' \in V: v' \neq v} M(v, v')$$

- ▶ No caso de um grafo $G(N, p)$

$$\mathbb{E}[D(v)] = (N - 1)p$$

- ▶ e para todo $k = 0, \dots, N - 1$

$$\mathbb{P}\{D(v) = k\} = \binom{N - 1}{k} p^k (1 - p)^{(N - 1 - k)}$$

- ▶ **Atenção à mudança de notação:** $D(v)$, em vez de $deg(v)$.

O que se diz na literatura sobre grafos e redes sociais

- ▶ Diz-se que os grafos descrevendo redes sociais deveriam ter:
- ▶ as características **mundo pequeno**
- ▶ e para todo vértice v , a distribuição de $D(v)$ deveria ter uma **cauda longa**.

As duas características de um grafo mundo pequeno

- ▶ A primeira característica é que dois *amigos* de um mesmo ator, tem grande probabilidade de também serem amigos.
- ▶ Formalmente, dados três vértices v_1, v_2 e v_3 , se $M(v_1, v_2) = 1$ e $M(v_1, v_3) = 1$, então com alta probabilidade $M(v_3, v_2) = 1$.
- ▶ A segunda característica é que a **distância** entre dois vértices quaisquer é tipicamente muito menor do que $|V|$.
- ▶ A distância entre v e v' é o menor $k \geq 1$ tal que existem vértices v_0, v_1, \dots, v_k , com $v = v_0$ e $v_k = v'$, tais que $M(v_i, v_{i+1}) = 1$, para $i = 0, \dots, k - 1$.
- ▶ Notação: $|V|$ (lê-se *cardinal de V*) denota o número de elementos do conjunto $|V|$.

O exemplo de Watts e Strogatz

- ▶ Um célebre artigo de Watts e Strogatz, publicado em 1998 na revista **Nature**, discute essa questão, através do seguinte modelo:
- ▶ Começamos com um grafo **regular**, tendo $V = \{1, \dots, N\}$ e com matriz de adjacência M satisfazendo: $M(v, v') = 1$, se $1 \leq |v - v'| \leq k$, e $M(v, v') = 0$ caso contrário.
- ▶ Aqui, $k \geq 1$ é um inteiro muito menor do que N .
- ▶ Usamos a convenção $N + 1 = 1$. Em outras palavras, consideramos os elementos de $V = \{1, \dots, N\}$ dispostos numa circunferência, de tal forma que os vértices 1 e N são vizinhos.

QUIZ

O grafo regular apresentado nos dois últimos quadros satisfaz as condições **mundo pequeno**?

Coeficiente de aglomeração e diâmetro de um grafo

- ▶ Duas definições são úteis para tornar mais claras as duas características mundo pequeno.
- ▶ Vamos definir o **coeficiente de aglomeração** e o **diâmetro** de um grafo.
- ▶ O coeficiente de aglomeração mede a proporção de amigos de um ator são amigos entre si.
- ▶ O diâmetro de um grafo mede a distância típica entre dois vértices de um grafo.

Coefficiente de aglomeração

- ▶ Dado um vértice v , $D(v) = \sum_{v' \in V, v' \neq v} M(v, v')$ é o número de vizinhos de v .
- ▶ $\binom{D(v)}{2}$ é o número total de triângulos que podemos construir tendo v como vértice e tendo como outros dois vértices vizinhos de v .
- ▶ Isto acontece quando todos os vizinhos de v estão conectados por arestas entre si (grafo completo).
- ▶ $c(v)$ é a fração que tem como denominador $\binom{D(v)}{2}$ e como numerador o número de triângulos que realmente existem tendo v como vértice e vizinhos de v como outros dois vértices.
- ▶ $C(G)$, o coeficiente de aglomeração do grafo, é a média dos valores de $c(v)$ para todos os vértices $v \in V$.

Coeficiente de aglomeração de um grafo

▶ Dado um grafo $G = (V, E)$ e um vértice $v \in V$,



$$c(v) = \frac{1}{\binom{D(v)}{2}} \sum_{v_1, v_2 \in V} M(v, v_1)M(v_1, v_2)M(v_2, v)$$



$$C(G) = \frac{1}{|V|} \sum_{v \in V} c(v)$$

Por que o grafo regular não é um mundo pequeno? Porque o seu diâmetro é muito grande.

- ▶ O diâmetro do grafo regular é proporcional a $|V|$.
- ▶ O que isso significa?
- ▶ Vamos usar a notação $dist(v, v')$ para indicar a distância entre os vértices v e v' .
- ▶ Definimos o diâmetro ($L(G)$) do grafo $G = (V, E)$ como sendo a média das distâncias entre dois vértices quaisquer do grafo.



$$L(G) = \frac{1}{2|E|} \sum_{v, v' \in V, v \neq v'} dist(v, v')$$

- ▶ No caso de um grafo aleatório, $L(G)$ é a esperança das distâncias entre dois vértices quaisquer.

Aleatorizando um grafo regular

- ▶ Para resolver o problema do grande diâmetro do grafo regular, Watts e Strogatz propõe aleatorizá-lo parcialmente.
- ▶ Como isso é feito?
- ▶ Escolhemos um valor $p \in [0, 1]$.
- ▶ Cada aresta do grafo regular é mantida como está com probabilidade $1 - p$, ou alterada com probabilidade p .
- ▶ Se decidirmos alterá-la, uma de suas pontas escolhida com probabilidade $1/2$ é reconectada em um outro vértice escolhido uniformemente dentre todos os vértices, com exceção das extremidades originais da aresta modificada.

Aleatorizando um grafo regular




Figura retirada do artigo do Watts e Strogatz na Nature (1998).

Valores de $C(p)$ e $L(p)$ em função de p




Figura retirada do artigo do Watts e Strogatz na Nature (1998).

QUIZ

- ▶ Que tipo de rede social é bem descrita pelo modelo de Watts-Strogatz?

O $G(N, p)$ tem as características de mundo pequeno?

- ▶ Na próxima aula faremos contas. Daqui até lá, estime o valor de $C(G(N, p))$.
- ▶ Faça isso simulando $G(N, p)$ muitas vezes, independentemente umas das outras, e com $N = 100$.
- ▶ Observe que em cada simulação, os valores de $c(v)$ para $v = 1, \dots, 100$ são variáveis aleatórias identicamente distribuídas. O mesmo acontece com as variáveis aleatórias $D(v)$.
- ▶ Para cada simulação, calcule $c(v)$ para todos os valores de v e em seguida calcule a média para aquela simulação.
- ▶ Calcule o histograma dos valores de $C(G(N, p))$ obtidos nas diversas simulações.

QUIZ

- ▶ Estamos trabalhando com o grafo $G(100, p)$ onde $p \in (0, 1)$.
- ▶ Saber que $D(1) = 0$ nos diz algo a respeito de $D(100)$?

Lembrando

- ▶ Na literatura sobre grafos e redes sociais
- ▶ diz-se que os grafos descrevendo redes sociais deveriam ter:
- ▶ as características **mundo pequeno**
- ▶ **e para todo vértice v , a distribuição de $D(v)$ deveria ter uma cauda longa.**
- ▶ O que quer dizer ter **cauda longa**?
- ▶ Na próxima aula discutiremos esta última questão.

Enquanto a próxima aula não chega

- ▶ Vamos olhar a distribuição de $D(v)$ em $G(N, p)$, escrevendo $D_N(v)$ em vez de $D(v)$.
- ▶ Vamos calcular o limite $D_N(v)/N$ quando $N \rightarrow \infty$.



$$\frac{D_N(1)}{N} = \frac{1}{N} \sum_{v=2}^N M(1, v).$$

- ▶ As variáveis aleatórias $(M(1, v))_{v=2, \dots, N}$ são i.i.d. Portanto, pela **Lei dos Grandes Números**,

$$\lim_{N \rightarrow \infty} \frac{D_N(1)}{N} = \mathbb{E}(M(1, 2)) = p.$$

- ▶ Podemos dizer mais sobre esse limite.

Flutuações de $D_N(1)/N$ em torno de p

- ▶ O **Teorema-Limite Central** diz que a distribuição de

$$\sqrt{N} (D_N(1)/N - p) = \frac{D_N(1) - Np}{\sqrt{N}}$$

converge para uma distribuição $N(0, p(1-p))$ quando $N \rightarrow \infty$.

- ▶ Ou seja, para todo $t \in \mathbb{R}$, vale o limite

$$\lim_{N \rightarrow \infty} \mathbb{P} \left(\frac{D_N(1) - Np}{\sqrt{N}} < t \right) = \frac{1}{\sqrt{2\pi p(1-p)}} \int_{-\infty}^t e^{-\frac{1}{2} \frac{s^2}{p(1-p)}} ds.$$

- ▶ Essa é a famosa aproximação normal da distribuição binomial. Ela diz, entre outras coisas, algo sobre a concentração $D_N(1)$ em torno de Np , e isso tem consequências sobre as características que se esperam de um grafo que representa uma rede social.

Exercício

1. Calcule o coeficiente de aglomeração e o diâmetro do grafo regular.
2. Simule várias vezes $G(N, p)$ com N, p fixados. Use essas simulações para estimar o coeficiente de aglomeração e o diâmetro de $G(N, p)$.
3. Leia no artigo de Watts e Strogatz a discussão sobre o diâmetro e o coeficiente de aglomeração do grafo regular com diversas taxas de aleatorização.
4. Reveja a aproximação normal da distribuição binomial e suas aplicações estatísticas.

Referências

- ▶ Esta é uma leitura indispensável.
Watts, D., Strogatz, S. Collective dynamics of 'small-world' networks. Nature 393, 440–442 (1998).
<https://doi.org/10.1038/30918>
- ▶ Este artigo pode ser interessante.
Random graphs with arbitrary degree distributions and their applications M. E. J. Newman, S. H. Strogatz, and D. J. Watts
Phys. Rev. E 64, 026118