

Szociális hálók

Szalai Péter

April 17, 2015

Miről lesz szó?

- 1 Megfigyelések
 - Kis világ
 - Power-law
 - Klaszterezhetőség
- 2 Modellek
 - Célok
 - Erdős-Rényi
 - Watts-Strogatz
 - Barabási modell
 - Copy-modell
- 3 Spektrál gráf partícionálás
 - Matek
 - SVD
 - Feladat

Section 1

Megfigyelések

Subsection 1

Kis világ

A kísérlet:

- Milgram
- 1969
- Nebraska → Boston

A kísérlet:

- Milgram
- 1969
- Nebraska → Boston

Eredmény:

- 20%-nak sikerült
- Átlagos lépésszám: 6.5
- Ugyanez facebookon:
 - 2008: 5.28
 - 2011: 4.74

A kísérlet:

- Milgram
- 1969
- Nebraska → Boston

Eredmény:

- 20%-nak sikerült
- Átlagos lépésszám: 6.5
- Ugyanez facebookon:
 - 2008: 5.28
 - 2011: 4.74




Figure: Six degrees of separation

Subsection 2

Power-law

Power-law eloszlás

Az X valószínűségi eloszlása *power-law* eloszlás, ha:


$$Pr(X = x) = Cx^{-\alpha}$$

Power-law eloszlás

Power-law eloszlás

Az X valváltozó eloszlása *power-law* eloszlás, ha:

$$\Pr(X = x) = Cx^{-\alpha}$$



Power-law eloszlás

Az X valószínűségi eloszlása *power-law* eloszlás, ha:

$$p(x) = \Pr(X = x) = Cx^{-\alpha}$$

Vegyük a logaritmusát:

$$\log(p(x)) = \log(C) - \alpha \log(x) \implies \log(y) = -\alpha \log(x) + C'$$

ami log-log skálán:

$$y' = -\alpha x' + C'$$

Power-law eloszlás

Az X valváltozó eloszlása *power-law* eloszlás, ha:

$$Pr(X = x) = Cx^{-\alpha}$$

- Empirikus adatban a leggyakoribb eloszlás.
- "Örökifjú", $f(cx) = g(c)f(x)$ egyetlen megoldása.
- Először *Nature* biológiai vonatkozás
- Példák:
 - Vagyon eloszlás (Pareto 80-20)
 - Hashtagek népszerűség eloszlása
 - Szavak előfordulása
 - Ismeretségi gráfok fokszám eloszlás!!!

Subsection 3

Klaszterezhetőség

- Csoportulások
- Csoportok közötti kapcsolatok = Egyének közötti kapcsolatok
- Skálafüggetlen tulajdonság
- Klaszterezés problémája
- Később




Figure: Facebook klaszterezve

Section 2

Modellek

Subsection 1

Célok

Miért?

- Jelenségek megértése (*Mi történik facebookon?*)
- Szimuláció
- Mérések

Validálás:

- Fokszám eloszlása power-law?
- Kis világ tulajdonság teljesül?
- Klaszterezhetőség?

Néhány hálózatmodell:

- Erdős-Rényi
- Watts-Strogatz
- Barabási-Albert
- Broder

$G(n, p) = (V, E)$, ahol $V = [1, \dots, n]$ és $\Pr((i, j) \in E) = p$

Más megfogalmazás:

$G(N, M) = (V, E)$, ahol $|V| = N$ és $|E| = M$.

Kapcsolat a két modell között:

$$M = \binom{N}{2} p$$

$G(n, p) = (V, E)$, ahol $V = [1, \dots, n]$ és $\Pr((i, j) \in E) = p$

Más megfogalmazás:

$G(N, M) = (V, E)$, ahol $|V| = N$ és $|E| = M$.

Kapcsolat a két modell között:

$$M = \binom{N}{2} p$$




Figure: Erdő gráf azonos N, M esetén

Néhány tulajdonság:

- Átlag fokszám $\frac{2|E|}{n} = \frac{2\binom{n}{2}p}{n} = (n-1)p$
- Fokszám-eloszlás: $Pr(d(v) = k) = \binom{n-1}{k} p^k (1-p)^{n-1-k}$
- Poisson $Pr(d(v) = k) = \frac{d(v)^k e^{-z}}{k!}$
- Összefüggőség:
 - $np < 1$ legnagyobb összefüggő komponens $O(\log(n))$
 - $np = 1$ legnagyobb összefüggő komponens $O(n^{\frac{2}{3}})$
 - $np > 1$ legnagyobb összefüggő komponens $O(n)$
és a második $O(\log(n))$
- Átmérő: $\frac{\log(n)}{\log(p(n-1))}$
- $Pr(G) = p^{|E(G)|} (1-p)^{\binom{n}{2} - |E(G)|}$

Kifejezetten a kis világ tulajdonság modellezésére találták ki.

$G(n, k, p)$

- 1 Körön elhelyezünk n pontot.
- 2 A k távolságra lévőköt összekötjük.
- 3 Minden élet p valószínűséggel átkötünk véletlen helyre.

Watts-Strogatz

Kifejezetten a kis világ tulajdonság modellezésére találták ki.

$G(n, k, p)$

- 1 Körön elhelyezünk n pontot.
- 2 A k távolságra lévőköt összekötjük.
- 3 Minden élet p valószínűséggel átkötünk véletlen helyre.




Figure: $n=8, k=2$

Kifejezetten a kis világ tulajdonság modellezésére találták ki.

$G(n, k, p)$

- 1 Körön elhelyezünk n pontot.
- 2 A k távolságra lévőköt összekötjük.
- 3 Minden élet p valószínűséggel átkötünk véletlen helyre.

Tulajdonságok:

- $G_{WS}(n, k, p)$ közel azonos a $C_n + 2C_{\frac{n}{2}} + \dots + kC_{\frac{n}{k}} + G_{ER}(n, p)$ gráffal.
- Poisson + konstans fokszámeloszlás.e
- Részgráfok ritkák a függetlenség miatt.
- Grid modell ($\frac{[d(u,v)^{-r}]}{\sum_{v;v \neq u} [d(u,v)^{-r}]}$). Minden decentralizált algoritmus $\Omega(n^{\frac{r-2}{r-1}})$ lépést használ.

- 1 Kiindulunk egy G_0 gráfból m_0 éllel.
- 2 Felveszünk egy új pontot.
- 3 Bekötjük m helyre.
- 4 Bekötés valószínűsége: $p(v) = \frac{d(v,t)}{\sum_{w \in V} d(w,t)}$.

Tulajdonságok:

- Fokszámeloszlás: hatvány.
- Kis világ tulajdonság: teljesül
- Klaszterezhetőség: nem teljesül.

Másolósos modell

- 1 Kiindulunk egy G_0 gráfból m_0 éllel.
- 2 Felveszünk egy új pontot.
- 3 Válsztunk egy már meglévő pontot.
- 4 Ha d élet kell behúzni akkor α valószínűséggel másolunk egy élet és $(1 - \alpha)$ -val egyenletesen választunk egy csúcsot.

Tulajdonságok:

- Fokszámeloszlás: hatvány.
- Kis világ tulajdonság: teljesül
- Klaszterezhetőség: teljesül.

Section 3

Spektrál gráf partícionálás

Négyzetes hiba (*MSE*) Mátrixra

$$\|A - B\|?$$

Négyzetes hiba (*MSE*) Mátrixra

$$\|A - B\|?$$

$(A - B)^2$ nem egy szám \implies nem jó.

Négyzetes hiba (*MSE*) Mátrixra

$\|A - B\|?$

$(A - B)^2$ nem egy szám \implies nem jó.

Megoldás:

Frobénius norma:

$$\|A\| = \sum_{i,j} a_{ij}^2$$

$$\text{MSE: } \|A - B\|_F^2 = \sum_{i,j} (a_{ij} - b_{ij})^2$$

SVD - Singular value decomposition

Tetszőleges A $m \times n$ -es mátrixhoz létezik $Q \in \mathbb{R}^{m \times m}$, $D \in \mathbb{R}^{n \times n}$ és $P \in \mathbb{R}^{n \times n}$ mátrixok, hogy

$$A = Q \times D \times P,$$

ahol:

- Q és P ortonormált.
- D pedig diagonális.

Ekkor:

$$a_{ij} = \sum_k q_{ik} d_k p_{jk}$$

Továbbá: $\|A\|_F = \sum_{i,j} a_{ij}^2 = \sum_i d_i^2$

Legjobb k -rangú közelítése egy mátrixnak:

- Vegyük a k legnagyobb szinguláris értéket.
- A többiit töröljük (0-ra cseréljük) és a hozzá tartozó vektorokat is.

Miért szinguláris?

$$AA^T p_i = P^T D^T Q^T Q D P p_i = P^T D^2 P(0, \dots, 1, \dots, 0)^T = d_i^2 v_i$$

- d_i -k a sajátértékek gyökei.
- P oszlopai az AA^T sajátvektorai.

Mire jó az SVD?

- Mult óra vége.
- Ajánló rendszerek (Robi)
- Spektrál felbontás

Subsection 3

Feladat

Legyen $G(V, E)$ egy gráf és X_G a gráfot reprezentáló mátrix. Preferenciák gráf klaszterezésnél:

- Hasonlók egy klaszterbe kerüljenek.
- A különböző klaszterekbe kerülők ne hasonlítsanak.

Tehát a célunk:

- 1 Maximalizálni az csoporton belüli össz súlyt.
- 2 Minimalizálni a csoportok közöttit.

Legyen a két klaszter G_A és G_B és A, B hozzájuk tartozó ponthalmaz.

$$cut(A, B) = \sum_{i \in A, j \in B} x_{ij}$$

Spektrál klaszterezés hasonlósági gráfokra

Legyen $G(V, E)$ egy gráf és X_G a gráfot reprezentáló mátrix.
Preferenciák gráf klaszterezésnél:

- Hasonlók egy klaszterbe kerüljenek.
- A különböző klaszterekbe kerülők ne hasonlítsanak.

Tehát a célunk:

- 1 Maximalizálni az csoporton belüli össz súlyt.
- 2 Minimalizálni a csoportok közöttit.

Legyen a két klaszter G_A és G_B és A, B hozzájuk tartozó ponthalmaz.

$$cut(A, B) = \sum_{i \in A, j \in B} x_{ij}$$

$$\min cut(A, B)$$

Spektrál klaszterezés hasonlósági gráfokra

Legyen $G(V, E)$ egy gráf és X_G a gráfot reprezentáló mátrix.
Preferenciák gráf klaszterezésnél:

- Hasonlók egy klaszterbe kerüljenek.
- A különböző klaszterekbe kerülők ne hasonlítsanak.

Tehát a célunk:

- 1 Maximalizálni az csoporton belüli össz súlyt.
- 2 Minimalizálni a csoportok közöttit.

Legyen a két klaszter G_A és G_B és A, B hozzájuk tartozó ponthalmaz.

$$cut(A, B) = \sum_{i \in A, j \in B} x_{ij}$$

$$\min cut(A, B)$$

Nem elég. Lehet, hogy elfajuló.

Megoldás

$$\min \left(\frac{\text{cut}(A, B)}{\text{vol}(A)} + \frac{\text{cut}(A, B)}{\text{vol}(B)} \right),$$

ahol $\text{vol}(A)$ az A -ból induló össz élsúly.

Laplace mátrix

Legyen $D(i, i) = \sum_j x_{ij}$, fokszám mátrix. Ekkor

$$L = D - X,$$

a Laplace mátrix.

Legyen f egy n dimenziós vektor (csúcsok száma). Ekkor:

$$f^T L f = f^T D f - f^T X f = \sum_i d_i f_i^2 - \sum_{i,j} f_i f_j w_{ij} =$$

$$\frac{1}{2} \left(\sum_i \left(\sum_j x_{ij} \right) f_i^2 - 2 \sum_{ij} f_i f_j x_{ij} + \sum_j \left(\sum_i x_{ij} \right) f_j^2 \right) =$$

$$\frac{1}{2} \sum_{ij} x_{ij} (f_i - f_j)^2$$

Miért jó ez?

$$\frac{1}{2} \sum_{ij} x_{ij} (f_i - f_j)^2$$

Jelentése $f \in \{-1, 1\}^n$ esetén?

$$\min_p \left(\sum_{i,j} x_{ij} (p_i - p_j)^2 \right) = \min_p (p^T L p)$$

- $p = (1 \ 1 \ \dots \ 1)^T$ a minimumot adja.
- Legyen plusz feltétel $\sum_i p_i = 0$, jelentése, hogy $|A| = |B|$.

Normalizáljuk L -t:

$$L' = D^{0.5}(D - A)D^{0.5}$$

A felbontás második sajátvektora a jó klasszifikáló.

Más megoldás

Klikk perkoláció (második óra).

NP-nehéz probléma.

Miről volt szó?

1 Megfigyelések

- Kis világ
- Power-law
- Klaszterezhetőség

2 Modellek

- Célok
- Erdős-Rényi
- Watts-Strogatz
- Barabási modell
- Copy-modell

3 Spektrál gráf partícionálás

- Matek
- SVD
- Feladat