


Hálózattudomány

SZTE Informatikai Intézet
Számítógépes Optimalizálás Tanszék
Előadó: London András

5. Előadás


Közösségek hálózatban



ábra. Facebook kapcsolati háló

Közösségek hálózatban


- Egyszerű mértékek: átlagos fokszám, fokszámeloszlás, klaszterezettség, átlagos úthossz → sok információ a hálózatról **DE**
- elrejtetik az eloszlás heterogenitását



ábra. Háromszögek száma nagy, de azok csak a hálózat egy részén található

- Mi a magas szintű szerveződés mintázata?
- Kis méretű hálózat: szemmel látható (?); nagy méretű hálózat: kvantitatív eszközök szükségesek

Magas szintű szerveződési mintázatok



ábra. Közösségszerkezet, mag-periféria szerkezet, rendezett (lineáris hierarchia) szerkezet (forrás: Aaron Clauset, Network analysis and modelling course)

Asszortatív kapcsolódás

- Bizonyos **attribútumok** (tulajdonságok, jellemzők) kapcsolatára az meglévő élek világítanak rá → pl. ismerőseink egy részének közös jellemzője a középiskola, ahová jártak
- Társadalmi hálózatokban jellemző, hogy olyan ismerőseink vannak akik **hasonlítanak** ránk. Pl. életkor, nyelv, születési hely, végzettségi szint, anyagi helyzet

Fontos kérdés: (1) az él a hasonlóság miatt létezik, vagy (2) az él létezése (ismeretség) miatt hasonlóvá válnak az attribútumok? (ld. pl. politikai beállítottság)

(Egy modellezési lehetőség: **Fitness modell** (a későbbiekben tárgyaljuk, esetleg projektfeladat))

A modularitás függvény

- Az adott gráf mennyire tér el egy ugyanolyan fokszámeloszlású véletlen gráftól?

Modularitás = $\#\{\text{közösségen belüli élek}\} - \mathbb{E}[\#\{\text{közösségen belüli élek}\}]$ egy azonos fokszámeloszlású véletlen gráfban]

- **Newman-modularitás**¹

$$Q = \frac{1}{2m} \sum_{i,j} (a_{ij} - e_{ij}) \delta(C_i, C_j),$$

δ a Dirac-delta függvény ($\delta(C_i, C_j) = 1$, ha $i = j$ és 0 különben), e_{ij} az i és j közti élek számának várható értéke (általában 0 és 1 között) egy véletlen (null-modell) gráfban

¹ Newman, *Physical Review E*, 2004

De mi legyen a null-modell?

- A síma véletlen gráf $G(n, p)$ általában „messze van” a valós hálózatoktól.
- Használjuk a **konfiguráció modellt**

Azaz ha az eredeti gráf fokszámsorozata (k_1, k_2, \dots, k_n) akkor

$$e_{ij} = \frac{k_i k_j}{2m}$$

így

$$Q = \frac{1}{2m} \sum_{i,j} (a_{ij} - \frac{k_i k_j}{2m}) \delta(C_i, C_j),$$


A cél pedig a **pontok osztályozása** (szétosztása) C_1, \dots, C_k ($k=?$) osztályokba (klaszterekbe), hogy Q minél nagyobb (maximális) legyen.

Modularitás maximalizálás

- Ha S a G gráf pontjainak **összes lehetséges partícionálása** (klaszterezése) akkor egy $f : S \rightarrow \mathbb{R}$ függvény méri egy adott $P \in S$ felosztás „jóságát” (Mitől jó?)
- Q egy lehetséges ilyen függvény \rightarrow „minél nagyobb, annál jobban klaszerezünk”
- S mérete exponenciálisan nagy (miért?), továbbá Q -t maximalizálni NP -nehéz
- Léteznek jól működő heurisztikák

Egy mohó algoritmus

- 1 Kezdetben minden pont egy önálló közösség
- 2 Majd mohó módon olvasztunk össze közösségeket, aszerint, hogy a lépés minél jobban növeli Q értékét



ábra. Közösségek és hierarchikus szerkezet

Az eljárás implementálásra számos különböző technika létezik (ld. pl. *single linkage*, *average linkage*, etc.)

Algoritmusok sokasága

- **Modularitás optimalizálás** számos változata
- Más kiértékelő függvények használata (Mit tartunk fontosnak közösségkeresés esetén?)
- **Sztochasztikus blokk modell** (tárgyaljuk részletesebben)
- Átfedő közösségek keresése
- Spektrális módszerek, dinamikus közösségkeresés
- ...

Jegyzet, további olvasnivaló:

- Véletlen gráfok: Jackson könyv IV. fejezet, Newman cikk IV. szakasz
- Közösségek: Newman III. szakasz
- Közösségkeresés összefoglaló cikk: Santo Fortunato (2010):
Community detection in graphs, *Physics Reports*

Feladat:

- Próbáljunk ki különböző közösségkereső algoritmusokat egy valós gráfon, nézzük meg a különbségeket