

Hľadanie komunit v sieťach

Beáta Stehlíková

2-EFM-155 Analýza sociálnych sietí

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

Hľadanie komunití v sieťach

Prístup I - v ďalšej téme, presne definované pojmy

- ▶ Kliky
- ▶ Jadrá

Prístup II - zhlukovanie

- ▶ *komunita* bez presnej definície, približne: veľa hrán medzi sebou, málo s inými komunitami
- ▶ priebežne počas semestra, v domácej úlohe, v projektoch
- ▶ funkcie `cluster_eigenvector` a pod.

Modularita

Definícia

- ▶ Pracujeme s neorientovanými sieťami, ak sú vážené - väčšia váha znamená silnejšiu väzbu medzi vrcholmi
- ▶ Označenia: A = matica susednosti, m = počet hrán
- ▶ Intuitívne: modularita bude (*počet hrán vrámci komunit*) *mínus* (*očakávaný počet hrán vrámci komunit*) a budeme ju maximalizovať
- ▶ Treba upresniť, čo znamená *očakávaný počet* (teda na základe *akého modelu* ide o očakávaný počet)
- ▶ Nech P_{ij} je pravdepodobnosť, že vznikne hrana medzi vrcholmi i a j
- ▶ Definujme modularitu ako

$$Q = \frac{1}{2m} \sum_{i,j} [A_{ij} - P_{ij}] \delta(g_i, g_j),$$

kde g_i je komunita, do ktorej patrí vrchol i a $\delta(x, y)$ je 1 pre $x = y$ a inak 0. Optimálne zhľukovanie ju bude maximalizovať.

Model Erdősa a Rényiho

- ▶ Voľba tohto modelu na porovnanie s reálnou sieťou by znamenalo, že $P_{ij} = p$ (konštanta).
- ▶ Prirodzená požiadavka: očakávaný počet hrán sa rovná pozorovanému počtu
- ▶ Problém - často výrazne iné rozdelenie stupňa vrcholov

```
data(karate)
g <- karate
hist(degree(karate), 20)
```

Cvičenie: Vygenerujte niekoľko grafov Erdősa a Rényiho a porovnajte rozdelenie stupňa vrcholov s rozdelením pre sieť karate klubu (n rovnaké, p také, aby sa očakávaný počet hrán rovnal pozorovanému počtu)

Lepšia voľba

- ▶ Označme $k_i = \text{degree}_i$ stupeň vrchola i
- ▶ Očakávaný stupeň každého vrchola sa bude rovnať pozorovanému stupňu:

$$\sum_j P_{ij} = k_i,$$

- ▶ P_{ij} má tvar

$$P_{ij} = f(k_i)f(k_j)$$

- ▶ Dostaneme

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

Výpočet v R-ku

- ▶ Funkcia modularity

Dá sa použiť:

- ▶ pre výstup z algoritmov hľadania komúní
- ▶ pre náš vektor zo zaradením vrcholov (číslo komunity, kam patrí)

```
data(kite)
com <- cluster_optimal(kite)
modularity(com)

com.vektor <- c(rep(1, 7), rep(2, 3))
modularity(kite, com.vektor)
```

Cvičenie: Zobrazte komunity pre `com.vektor` - nakreslite sieť a vrcholy odlište farebne podľa komunity. Je toto rozumné delenie vrcholov do komúní? Ako sa to prejaví na modularite?

Výpočet v R-ku

Iný postup pre vlastné komunity - vytvoríme objekt typu `communities` (a pracujeme s ním ďalej ako s výstupom z napríklad `cluster_walktrap`):

```
com2 <- make_clusters(kite, membership = com.vektor)
class(com2)
```


```
## [1] "communities"
```

Potom napr. `plot(com2, kite)`

Vyznačenie skupiny vrcholov v R-ku

Môže byť niekedy užitočné - nevyznačujeme priamo komunity, ale chceme zvýrazniť niektoré vrcholy

```
plot(kite, mark.groups = list(V(kite)[c("A", "C", "D", "F")  
                                V(kite)[c("B", "D", "G", "E")])
```



Optimalizácia modularity

- ▶ Metóda `cluster_optimal` priamo optimalizuje modularitu
- ▶ V rozumnom čase zbehne len pre menšie siete
- ▶ Prečo: rieši sa úloha celočíselného lineárneho programovania, počet premenných je rádu n^2 (n je počet vrcholov siete), premenné sú X_{ij} vyjadrujúce, či sú vrcholy i a j v tom istom zhľuku (hodnota 1) alebo nie (hodnota 0)

Optimalizácia modularity

Z pôvodného článku *U. Brandes et al.: On Finding Graph Clusterings with Maximum Modularity*:

The problem of maximizing modularity can be cast into a very simple and intuitive integer linear program (ILP). Given a graph $G = (V, E)$ with $n := |V|$ nodes, we define n^2 decision variables $X_{uv} \in \{0, 1\}$, one for every pair of nodes $u, v \in V$. The key idea is that these variables can be interpreted as an equivalence relation (over V) and thus form a clustering. In order to ensure consistency, we need the following constraints, which guarantee

reflexivity $\forall u: X_{uu} = 1$,

symmetry $\forall u, v: X_{uv} = X_{vu}$, and

$$\text{transitivity } \forall u, v, w: \begin{cases} X_{uv} + X_{vw} - 2 \cdot X_{uw} \leq 1 \\ X_{uw} + X_{uv} - 2 \cdot X_{vw} \leq 1 \\ X_{vw} + X_{uw} - 2 \cdot X_{uv} \leq 1 \end{cases} .$$


The objective function of modularity then becomes

$$\frac{1}{2m} \sum_{(u,v) \in V^2} \left(E_{uv} - \frac{\deg(u) \deg(v)}{2m} \right) X_{uv} ,$$

with $E_{uv} = \begin{cases} 1 & , \text{ if } (u, v) \in E \\ 0 & , \text{ otherwise} \end{cases} .$

Optimalizácia modularity: príklad

```
library(igraphdata)
data(karate)
komunityty <- cluster_optimal(karate)
plot(komunityty, karate)
```



Motivácia pre tvorbu iných algoritmov

- ▶ Potrebujeme zhlukovanie aj pre väčšie (aj pre veľmi veľké) siete
- ▶ Optimalizácia modularity nemá vždy “ideálne” vlastnosti - pozrime sa na príklady z citovaného článku:
 - ▶ Príklad 1: pridáme jeden vrchol a výrazne to zmení zhlukovanie (a navyše vrchol, ktorému sa nezmenia susedia, je po novom zaradený do iného zhluku)
 - ▶ Príklad 2: neintuitívny výsledok
 - ▶ Príklad 3: Ak vytvoríme sieť z dvoch identických komponentov, výsledné zhlukovanie nemusí zodpovedať zhlukovaniu každého z komponentov samostatne
- ▶ Môžeme chcieť zadať vlastný počet zhlukov (`cluster_optimal` to neumožňuje)

Motivácia - príklad 1

Non-Locality. At a first view, modularity seems to be a local quality measure. Recalling Equation (1), each cluster contributes separately. However, the example presented in Figures 1(a) and 1(b) exhibit a typical non-local behavior. In these figures, clusters are represented by colors. By adding an additional node connected to the leftmost node, the optimal clustering is altered completely. According to Lemma 2 the additional node has to be clustered together with the leftmost node. This leads to a shift of the leftmost white node from the white cluster to the black cluster, although locally its neighborhood structure has not changed.






Fig. 1. Non-local behavior. Clusters are represented by colors.

Motivácia - príklad 2

Sensitivity to Satellites. A *clique with leaves* is a graph of $2n$ nodes that consists of a clique K_n and n leaf nodes of degree one, such that each node of the clique is connected to exactly one leaf node. For a clique, the trivial clustering with $k = 1$ has maximum modularity. For a clique with leaves, however, the optimal clustering changes to $k = n$ clusters, in which each cluster consists of a connected pair of leaf and clique nodes.



Motivácia - príklad 3

Scaling Behavior. Figures 2(a) and 2(b) display the scaling behavior of modularity. By simply doubling the graph presented in Figure 2(a), the optimal clustering is altered completely. While in Figure 2(a) we obtain three clusters each consisting of the minor K_2 , the clustering with maximum modularity of the graph in Figure 2(b) consists of two clusters, each being a graph equal to the one in Figure 2(a).




Fig. 2. Scaling behavior. Clustering by colors.


Walktrap algoritmus

Walktrap algoritmus

- ▶ *walk* - prechádzka, *trap* - pasca
- ▶ pri náhodnej prechádzke po vrchoch siete by sme mali zostať s veľkou pravdepodobnosťou v tej istej komunite
- ▶ v R-ku `cluster_walktrap`

Walktrap - príklad

```
komunity <- cluster_walktrap(karate)  
plot(komunity , karate)
```



Walktrap - náš počet zhlukov


```
nase_rozdelenie_3 <- cut_at(komunity, no = 3) # chceme tri  
nase_rozdelenie_3
```

```
## [1] 2 2 2 2 3 3 3 2 1 1 3 2 2 2 1 1 3 2 1 2 1 2 1 1 1
```

Takže napríklad:

```
plot(karate,  
     vertex.color = c("blue", "green")[nase_rozdelenie_3],  
     vertex.shape = c("square", "circle")[V(karate)$  
                                           Faction])
```

Walktrap - náš počet zhlukov



Walktrap - náš počet zhlukov

Porovnajme modularitu:

```
for (i in 2:6){  
  nase_rozdelenie <- cut_at(komunity, i)  
  print(modularity(karate, nase_rozdelenie))  
}
```

```
## [1] 0.3714661
```

```
## [1] 0.3990796
```

```
## [1] 0.4111604
```

```
## [1] 0.398833
```

```
## [1] 0.3908613
```


Label propagation algoritmus

Label propagation algoritmus

- ▶ label - nálepka, značka, propagation - šírenie
- ▶ vrcholy dostanú značky a potom sa značky menia tak, aby mal vrchol takú značku ako väčšina jeho susedov
- ▶ v R-ku: `cluster_label_prop`

Label propagation - príklad

```
komunity <- cluster_label_prop(karate)  
plot(komunity , karate)
```



Počet zhlukov sa v tomto prípade nedá zadať:

```
> nase_rozdelenie_3 <- cut_at(komunity, no = 3)
Error in cut_at(komunity, no = 3) :  
  Not a hierarchical community structure
```

Ďalšie algoritmy v R-ku

Ďalšie algoritmy

- Sú aj ďalšie algoritmy:

> cluster_

◆ cluster_edge_betweenness	{igraph}	^
◆ cluster_fast_greedy	{igraph}	
◆ cluster_infomap	{igraph}	
◆ cluster_label_prop	{igraph}	
◆ cluster_leading_eigen	{igraph}	
◆ cluster_louvain	{igraph}	
◆ cluster_optimal	{igraph}	
◆ cluster_springlass	{igraph}	▼

- Niektoré umožňujú vlastný počet zhlukov, niektoré nie
- V literatúre stále vznikajú nové algoritmy