

# Hľadanie komunití v sieťach II

Beáta Stehlíková

2-EFM-155 Analýza sociálnych sietí

Fakulta matematiky, fyziky a informatiky, UK v Bratislave, 2019

## Hľadanie komunití v sieťach

## Prístup I

- ▶ Kliky
- ▶ Jadrá

## Prístup II

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

## Teraz

- ▶ zhrnieme si prácu s komunitami
- ▶ podrobnejšie sa pozrieme na `cluster_eigenvector`
- ▶ vysvetlíme si, čo je *modularita*

Modularita

# Definícia

- ▶ Pracujeme s neorientovanými neváženými sieťami
- ▶ 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*
- ▶ 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

- ▶ Treba určiť  $P_{ij}$

# 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 komunit
- ▶ pre náš vektor zo zaradením vrcholov (číslo komunity, kam patrí)

```
data(kite)
com <- cluster_walktrap(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 komunit? 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 v R-ku

- ▶ Metóda `cluster_optimal` priamo optimalizuje modularitu
- ▶ V rozumnom čase zbehne len pre menšie siete

Zhlukovanie na základe vlastného vektora

# Algoritmus M. E. J. Newmana

*M. E. J. Newman: Finding community structure in networks using the eigenvectors of matrices. Phys. Rev. E 74, 036104 (2006)*

<https://arxiv.org/abs/physics/0605087>

Podľa kapitoly 4.A vysvetlite:

- ▶ ako súvisia vlastné hodnoty a vektory (a akej matice) s modularitou
- ▶ ako z vlastného vektora (a akého) získať rozdelenie vrcholov do dvoch komunit

V R-ku

- ▶ funkcia `cluster_leading_eigen` pokračuje ďalších delením (neobmedzuje sa na dve komunity)
- ▶ naprogramujeme si delenie do dvoch komunit podľa algoritmu z článku

## Cvičenie

Absolútna hodnota vlastného vektora hovorí o tom, “ako silno” patrí vrchol do svojej komunity.

```
set.seed(111)
g <- sample_pa(n=20, directed = FALSE, power=0.5)
g <- add_edges(g, c( 1,5, 17, 5, 6, 4, 6, 11, 6,8, 12, 15,9))
lay <- layout_fruchterman_reingold(g)
plot(g, layout=lay, vertex.size=10)
```

- ▶ Rozdeľte vrcholy do dvoch komunit podľa vlastného vektora
- ▶ Vyznačte v grafe farebne komunity (farbou vrcholov alebo obrysmi pomocou `mark.groups`)
- ▶ Veľkosť vrcholov nech je úmerná absolútnej hodnote prvku vlastného vektora (teda veľké vrcholy budú “silne zviazané” so svojou komunitou)

# Cvičenie

