

Univerza v Ljubljani
podiplomski študij statistike

Analiza omrežij 3. Zgradba omrežij: podomrežja

Vladimir Batagelj

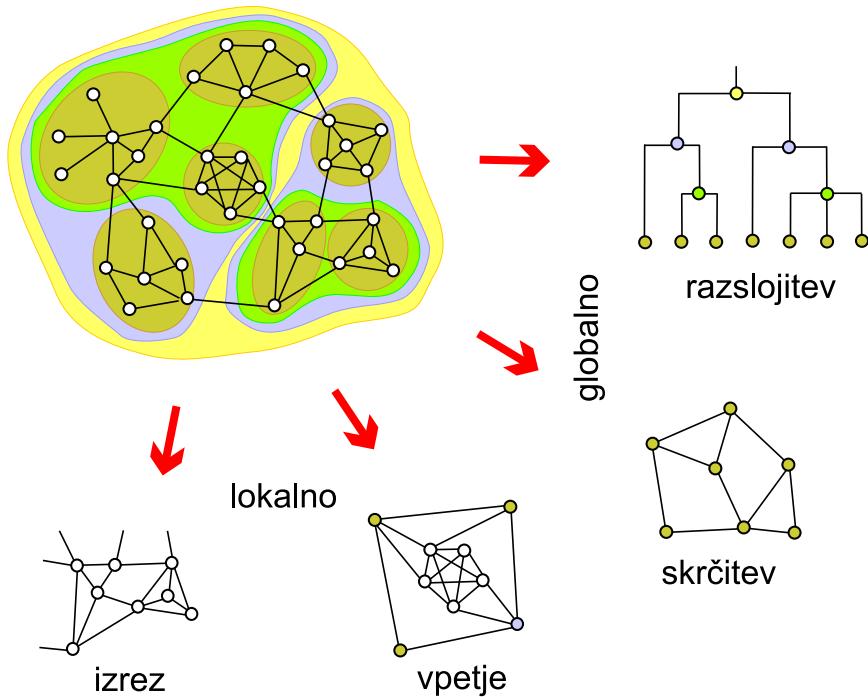
Univerza v Ljubljani

Ljubljana, 17. november 2006 / 10. in 17. november 2003

Kazalo

1	Pristopi k velikim omrežjem	1
2	Stopnje grafa	2
3	Statistika	3
6	Pajek in R	6
8	Slučajni grafi	8
9	Porazdelitve stopenj	9
10	Povezanosti med grafi	10
13	Skupine, razvrstitev, razbitja, razslojitve	13
15	Skrčitev skupine	15
18	Podgraf	18
21	Prerezi	21

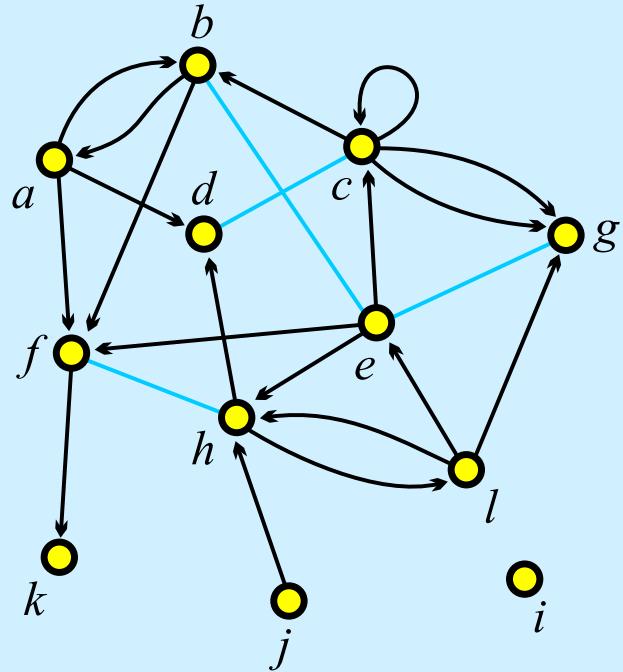
Pristopi k velikim omrežjem



Pri *velikih* omrežjih (več tisoč ali milijonov točk, omrežje je mogoče shraniti v pomnilniku) se moramo odpovedati celoviti sliki, uporabni so le redki postopki.

Za analizo velikih omrežij lahko uporabimo statistiko ali pa izpeljana mala in srednja (pod)omrežja.

Stopnje grafa



stopnja točke v , $\deg(v)$ = je število povezav, ki imajo točko v za krajišče; *vhodna stopnja* točke v , $\text{indeg}(v)$ = je število povezav, ki imajo točko v za konec (krajišče neusmerjene povezave je hkrati njen začetek in konec); *izhodna stopnja* točke v , $\text{outdeg}(v)$ = je število povezav, ki imajo točko v za začetek.

$$n = 12, m = 23, \text{indeg}(e) = 3, \text{outdeg}(e) = 5, \deg(e) = 6$$

$$\sum_{v \in \mathcal{V}} \text{indeg}(v) = \sum_{v \in \mathcal{V}} \text{outdeg}(v) = |\mathcal{A}| + 2|\mathcal{E}|, \sum_{v \in \mathcal{V}} \deg(v) = 2|\mathcal{L}| - |\mathcal{L}_0|$$

Statistika

Vhodni podatki o točkah

- številski → **vector**
- urejenostni → **permutation**
- imenski → **clustering** (razbitje)

Izračunane lastnosti točk

globalne: število točk, usmerjenih/neusmerjenih povezav, komponent; največje sredično število, ...

local: stopnje, sredična števila, indksi (vmesnost, dostopnost, viri in kazala, ...)

pregledi: razbitja, vektorji, vrednosti povezav, ...

Analiza povezanosti med izračunanimi (strukturnimi) lastnostmi in vhodnimi (izmerjenimi) lastnostmi.

... Statistika

Globalne lastnosti izpišejo **Pajekovi** ukazi v poročilo; največ jih je dosegljivih v izbiri **Info**. Pri uporabi *ponavljalajočih* ukazov se shranijo v vektorje.

Lokalne lastnosti izračunajo razni **Pajekovi** ukazi in jih shranijo v vektorje ali razbitja. Njihove vrednosti / porazdelitev si lahko ogledamo v izbiri **Info**.

Za primer si oglejmo omrežje **The Edinburgh Associative Thesaurus**. EAT je omrežje asociacij med besedami zbranimi na študentski populaciji. Točke so besede. Povezave (X, Y) pa so določene z vprašanjem: Katera beseda Y vam pride prva na misel, ko slišite besedo X ? Utež povezave pove, kolikokrat je bila izbrana.

```
File/Network/Read eatRS.net  
Info/Network/General
```

IMA 23219 TOČK IN 325624 USMERJENIH POVEZAV (564 ZANK); 227481 POVEZAV
IMA UTEŽ 1.

... Statistika

Točke z največjimi stopnjami dobimo takole:

Net/Partitions/Degree/All

Partition/Make vector

Info/Vector +10

V EAT so to:

	vertex	deg	label
1	12720	1108	ME
2	12459	1074	MAN
3	8878	878	GOOD
4	18122	875	SEX
5	13793	803	NO
6	13181	799	MONEY
7	23136	732	YES
8	15080	723	PEOPLE
9	13948	720	NOTHING
10	22973	716	WORK

Pajek in R

Pajek 0.89 (in kasnejši) omogoča uporabo statističnega programa R in tudi drugih programov kot orodij (izbira Tools).

V programu **Pajek** določimo stopnje točk in jih 'podtaknemo' R-ju

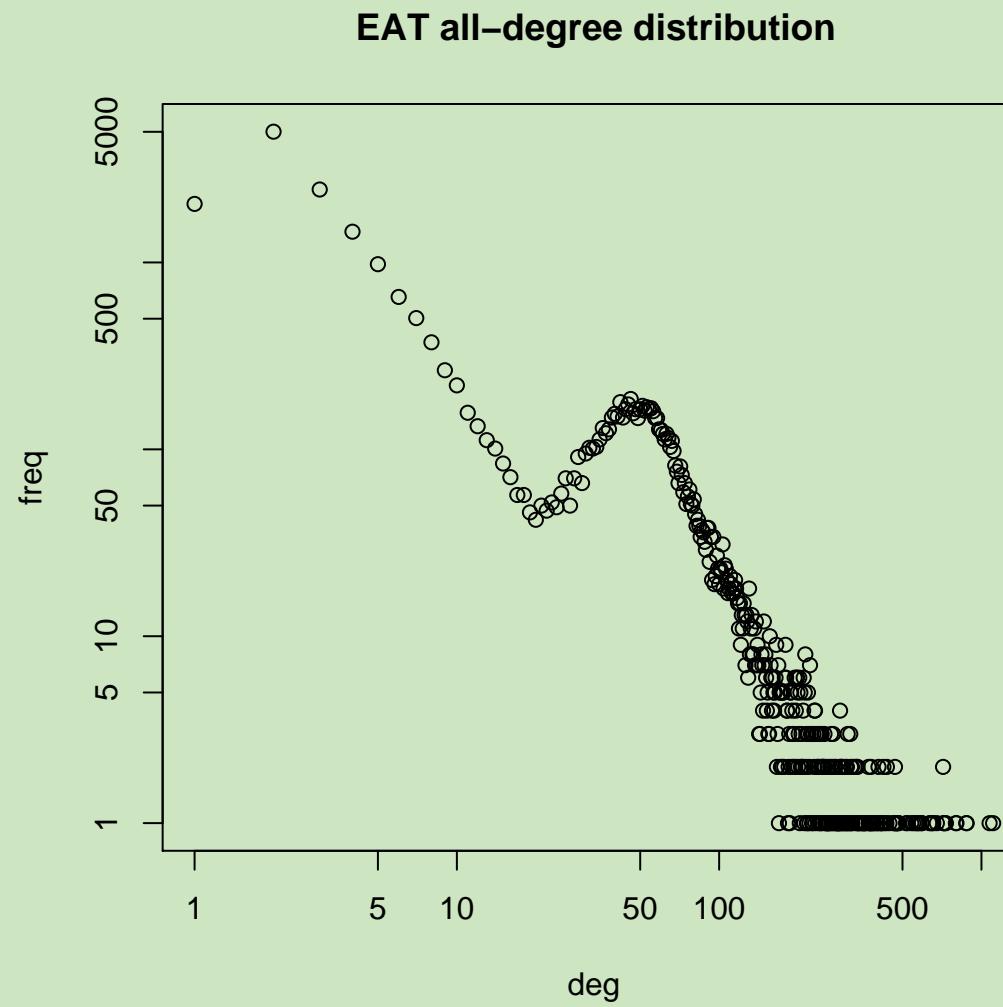
```
info/network/general  
Net/Partitions/Degree/All  
Partition/Make Vector  
Tools/Program R/Send to R/Current Vector
```

Tu določimo porazdelitev stopenj in jo narišemo

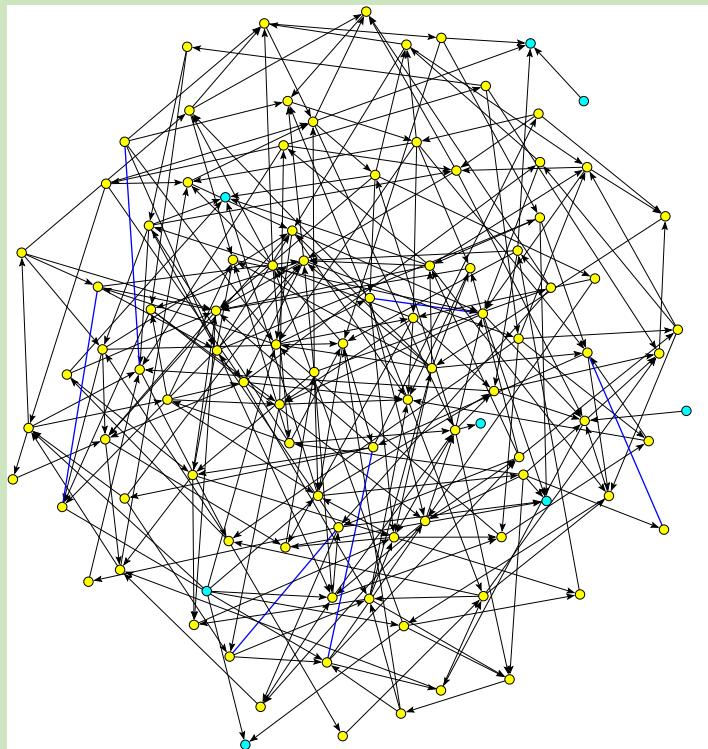
```
summary(v2)  
t <- tabulate(v2)  
c <- t[t>0]  
i <- (1:length(t)) [t>0]  
plot(i,c,log='xy',main='degree distribution',  
     xlab='deg',ylab='freq')
```

Pozor! Če obstajajo točke stopnje 0, jih tabulate ne upošteva.

EAT – porazdelitev stopenj



Slučajni grafi



Erdős in Rényi sta definirala *slučajni graf* takole: vsako mogočo povezavo vključimo v slučajni graf z dano verjetnostjo p .

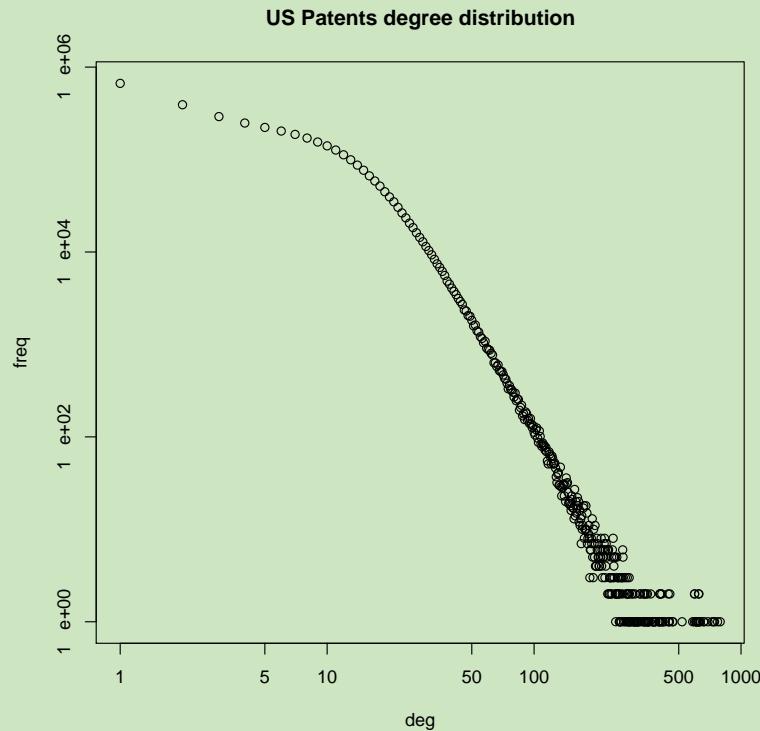
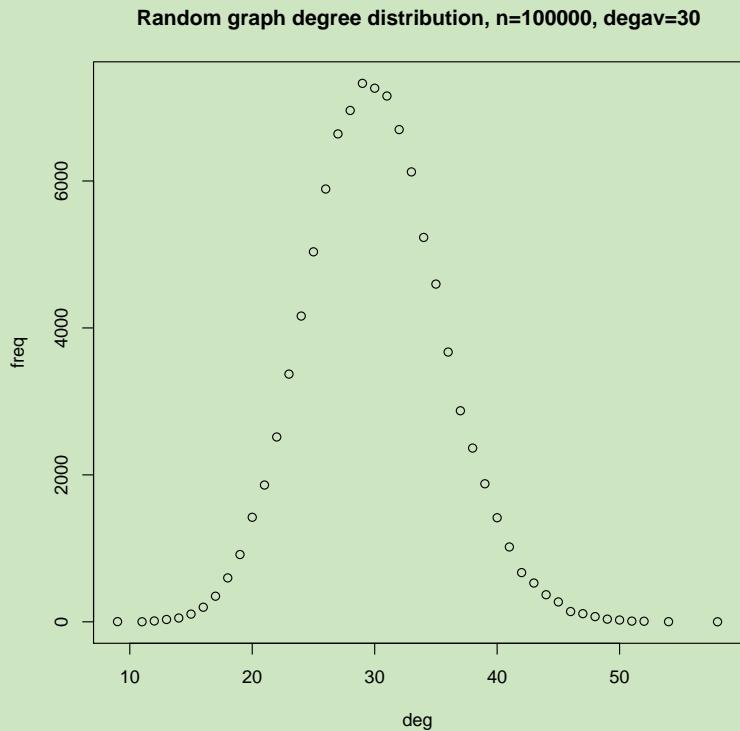
V programu **Pajek** (Net / Random Network / Erdos-Renyi) uporabljam namesto verjetnosti p povprečno stopnjo

$$\overline{\deg} = \frac{1}{n} \sum_{v \in \mathcal{V}} \deg(v)$$

Velja $p = \frac{m}{m_{max}}$ in, za enostavne grafe, še $\overline{\deg} = \frac{2m}{n}$.

Na sliki je prikazan slučajni graf na 100 točkah s povprečno stopnjo 3.

Porazdelitve stopenj



Dejanska omrežja so vse prej kot slučajna. Analiza porazdelitev je dala nov pogled na zgradbo dejanskih omrežij – Watts (**Small worlds**), Barabási (**nd/networks**, **Linked**).

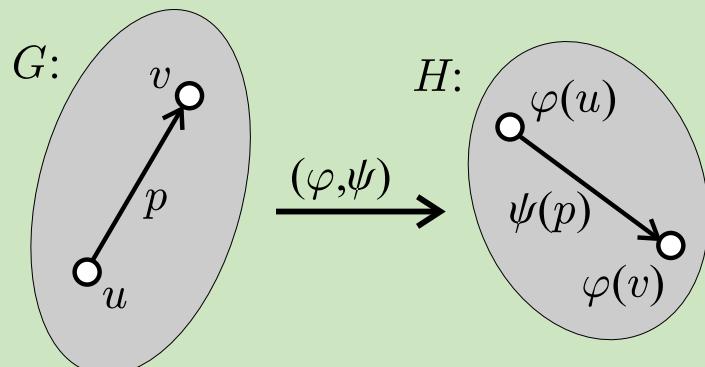
Povezanosti med grafi

Preslikavi (φ, ψ) , $\varphi: \mathcal{V} \rightarrow \mathcal{V}'$ in $\psi: \mathcal{L} \rightarrow \mathcal{L}'$ določata *šibki homomorfizem* grafa $\mathcal{G} = (\mathcal{V}, \mathcal{L})$ v graf $\mathcal{H} = (\mathcal{V}', \mathcal{L}')$ ntk velja:

$$\forall u, v \in \mathcal{V} \forall p \in \mathcal{L} : (p(u : v) \Rightarrow \psi(p)(\varphi(u) : \varphi(v)))$$

in določa *(krepki) homomorfizem* grafa \mathcal{G} v graf \mathcal{H} ntk velja:

$$\forall u, v \in \mathcal{V} \forall p \in \mathcal{L} : (p(u, v) \Rightarrow \psi(p)(\varphi(u), \varphi(v)))$$

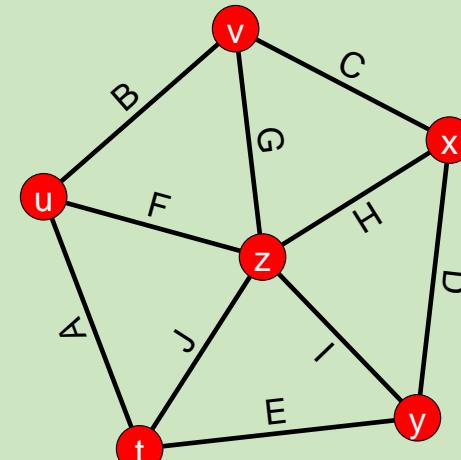
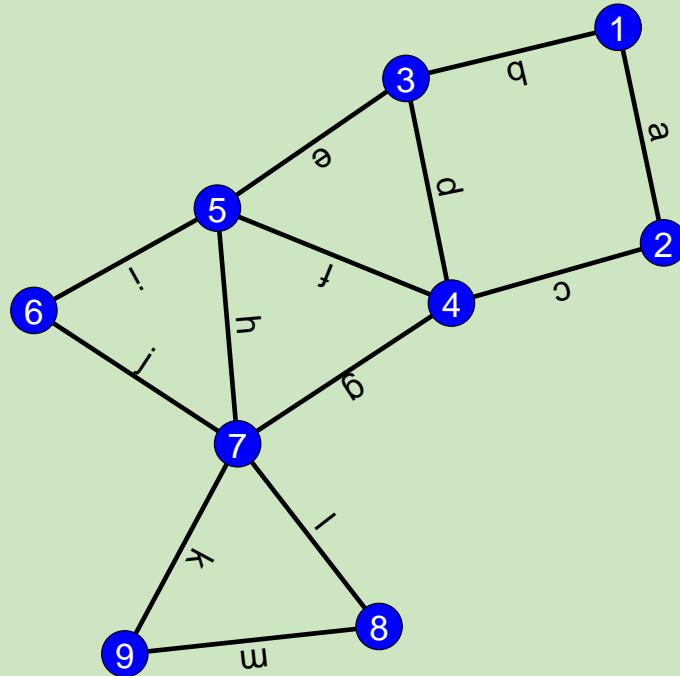


Ko sta φ in ψ bijekciji in ustrezen pogoj velja v obe smeri, govorimo o *izomorfizmu* grafov \mathcal{G} in \mathcal{H} . Da sta grafa šibko izomorfna zapišemo $\mathcal{G} \sim \mathcal{H}$; da sta (krepko) izomorfna pa $\mathcal{G} \approx \mathcal{H}$. Velja $\approx \subset \sim$.

Stalnica ali *invarianta* grafa imenujemo vsako grafu prizadeno število, ki je enako za vse med seboj izomorfne grafe. .

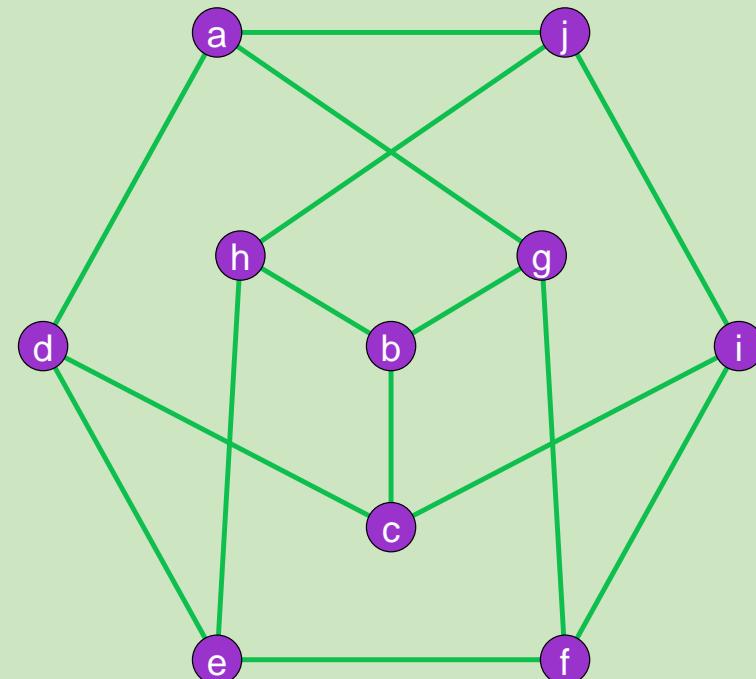
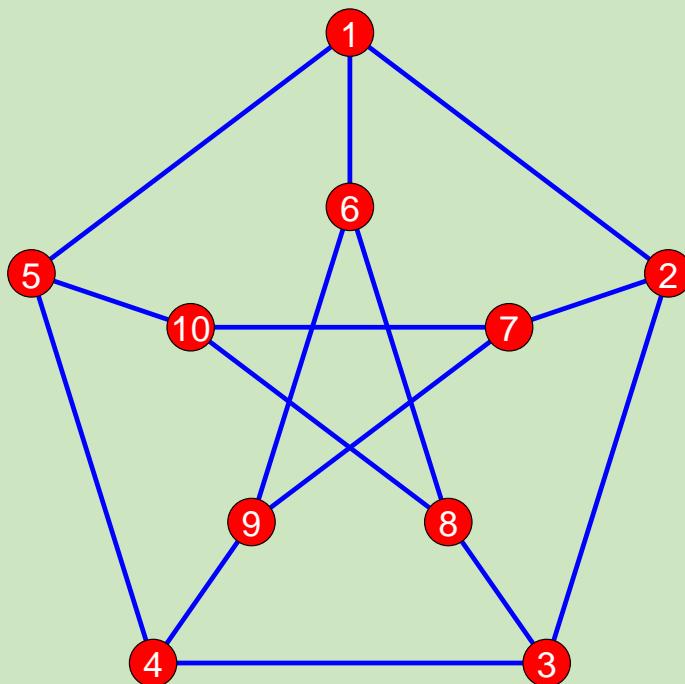
EulerGT

Homomorfizem



φ	1	2	3	4	5	6	7	8	9
	x	y	t	z	x	z	t	z	x
ψ	a	b	c	d	e	f	g	h	i
	D	E	H	J	E	I	J	E	J

Izomorfna grafa


$$\varphi \begin{array}{cccccccccc} & 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & 10 \\ \hline & b & h & j & a & g & c & e & i & d & f \end{array}$$

Skupine, razvrstitev, razbitja, razslojitve

Neprazno podmnožico $C \subseteq \mathcal{V}$ imenujemo *skupina*. Neprazna množica skupin $\mathbf{C} = \{C_i\}$ je *razvrstitev*.

Razvrstitev $\mathbf{C} = \{C_i\}$ je *razbitje* ntk

$$\cup \mathbf{C} = \bigcup_i C_i = \mathcal{V} \quad \text{in} \quad i \neq j \Rightarrow C_i \cap C_j = \emptyset$$

Razvrstitev $\mathbf{C} = \{C_i\}$ je *razslojitev* ali *hierarhija* ntk

$$C_i \cap C_j \in \{\emptyset, C_i, C_j\}$$

Razslojitev $\mathbf{C} = \{C_i\}$ je *polna*, če je $\cup \mathbf{C} = \mathcal{V}$; in je *osnovna*, če je za vsak $v \in \cup \mathbf{C}$ tudi $\{v\} \in \mathbf{C}$.

Primer razbitja in razslojitve

$$\mathcal{V} = \{a, b, c, d, e, f, g\}$$

$$\mathbf{C} = \{\{a, b, e\}, \{c, g\}, \{d, f\}\}$$

$$C_2 = \{c, g\}$$

$$\begin{aligned} \mathbf{H} = & \{\{a\}, \{b\}, \{c\}, \{d\}, \{e\}, \{f\}, \{g\}, \\ & \{a, e\}, \{c, g\}, \{d, f\}, \{a, b, e\}, \\ & \{c, d, f, g\}, \{a, b, c, d, e, f, g\}\} \end{aligned}$$

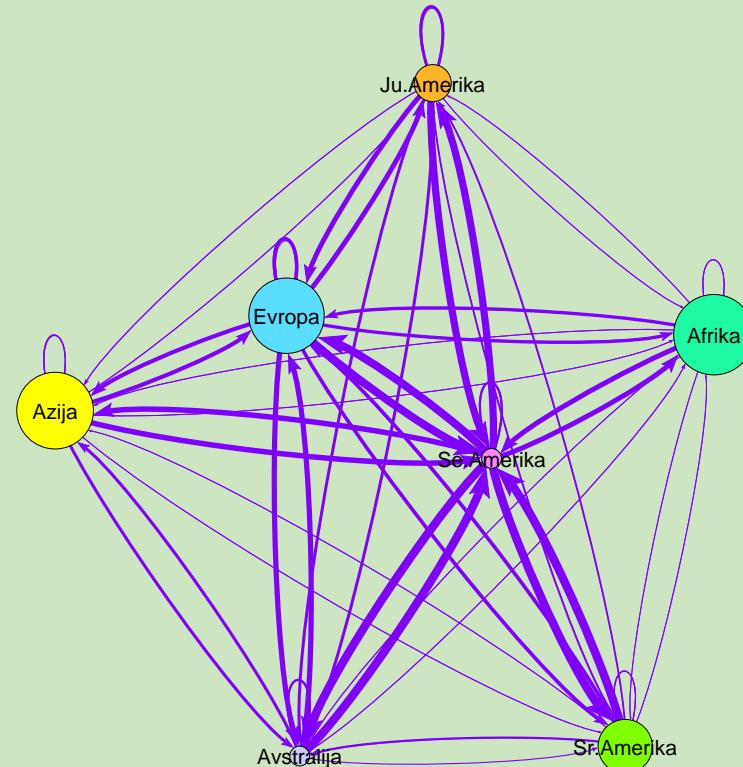
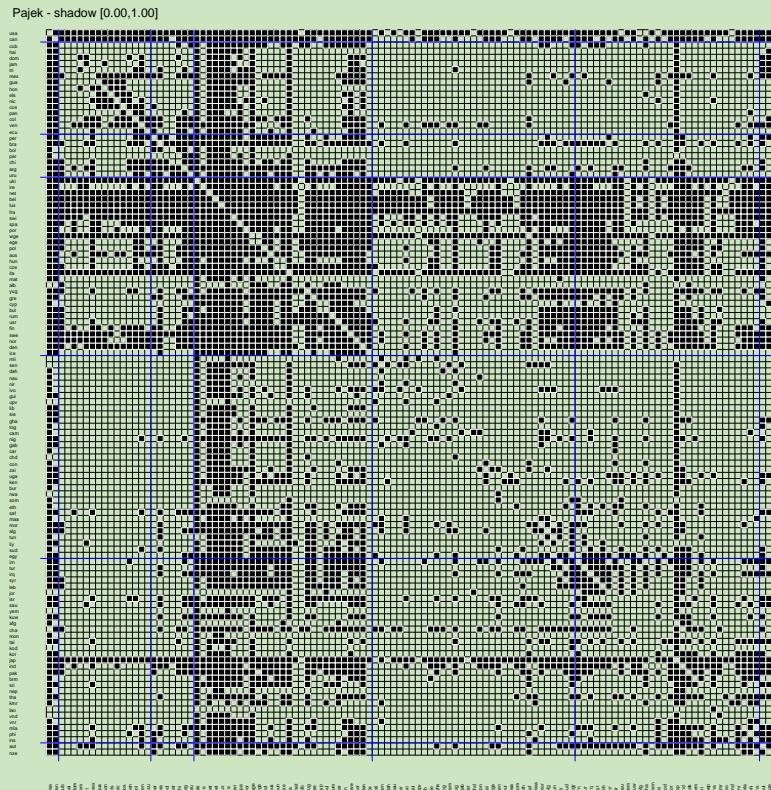
Skrčitev skupine

Skrčitev skupine C imenujemo graf \mathcal{G}/C , ki ga dobimo tako da vse točke skupine C zamenjamo z eno točko, recimo c . Natančneje $\mathcal{G}/C = (\mathcal{V}', \mathcal{L}')$, kjer je $\mathcal{V}' = (\mathcal{V} \setminus C) \cup \{c\}$ in \mathcal{L}' sestavlja povezave iz \mathcal{L} , ki imajo obe krajišči v $\mathcal{V} \setminus C$. Poleg teh pa še 'zvezda' z vrhom c in krakom (v, c) , če $\exists p \in \mathcal{L}, u \in C : p(v, u)$, oziroma krakom (c, v) , če $\exists p \in \mathcal{L}, u \in C : p(u, v)$. V točki c je zanka (c, c) , če $\exists p \in \mathcal{L}, u, v \in C : p(u, v)$.

V omrežju nad grafom \mathcal{G} moramo povedati še, kako so določene vrednosti/uteži v skrčenem delu. Običajno kar kot vsota ali maksimum/minimum izvornih vrednosti.

Operations / Shrink Network / Partition

Skrčitev skupin – trgovanje med državami



Snyder in Kickovi podatki o trgovaju med državami. Matrični prikaz gostih omrežij.

$$w(C_i, C_j) = \frac{n(C_i, C_j)}{n(C_i) \cdot n(C_j)}$$

Izračun uteži w

File / Pajek Project File / Read [SKtrade.paj]
 Operations / Shrink Network / Partition [1] [0]

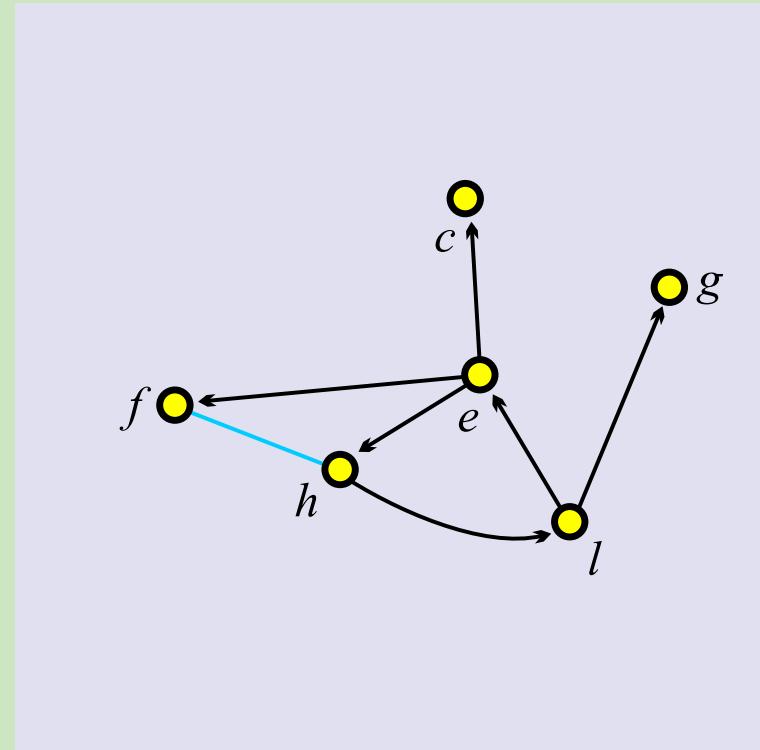
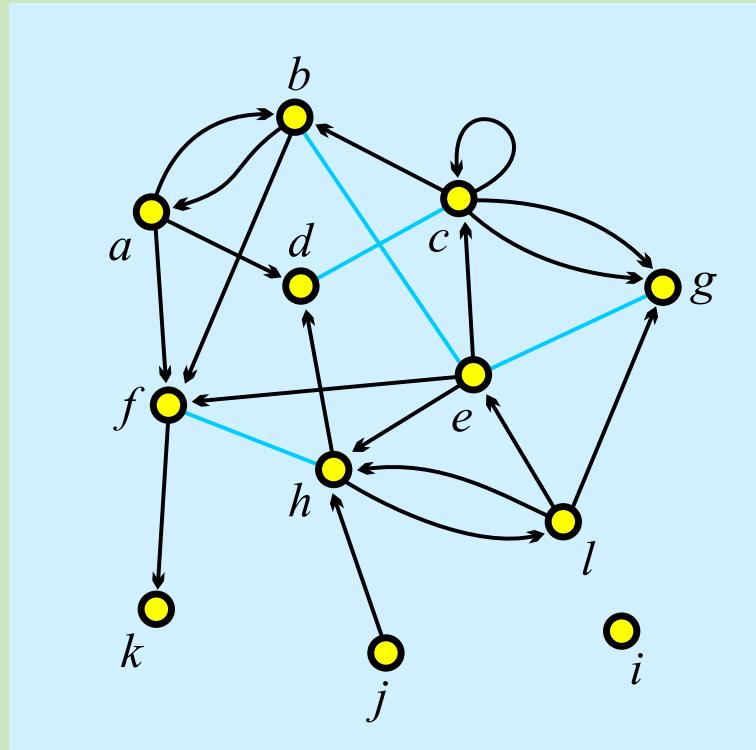
	1	2	3	4	5	6	7
#usa	1.	2	30	13	56	42	45
#cub	2.	30	74	25	196	20	37
#per	3.	12	28	33	124	16	36
#uki	4.	55	217	130	695	427	483
#mli	5.	42	8	14	406	122	117
#irn	6.	43	37	43	444	142	307
#aut	7.	4	4	5	39	9	30
count		2	15	7	29	33	30
							2

```
select partition SKtrade.clu
Partition / Count
Partition / Make Vector
Vector / Create Identity Vector [7]
select as second vector From partition ...
Vectors / Divide First by Second
select network Shrinking N? according to C?
Operations / Vector # Network / input
Operations / Vector # Network / output
```

	1	2	3	4	5	6	7
#usa	1.	0.50	1.00	0.93	0.97	0.64	0.75
#cub	2.	1.00	0.33	0.24	0.45	0.04	0.08
#per	3.	0.86	0.27	0.67	0.61	0.07	0.17
#uki	4.	0.95	0.50	0.64	0.83	0.45	0.56
#mli	5.	0.64	0.02	0.06	0.42	0.11	0.12
#irn	6.	0.72	0.08	0.20	0.51	0.14	0.34
#aut	7.	1.00	0.13	0.36	0.67	0.14	0.50

Ker so na diagonali 0,
 bi jih bilo smiselno pred
 izračunom postaviti na 1.

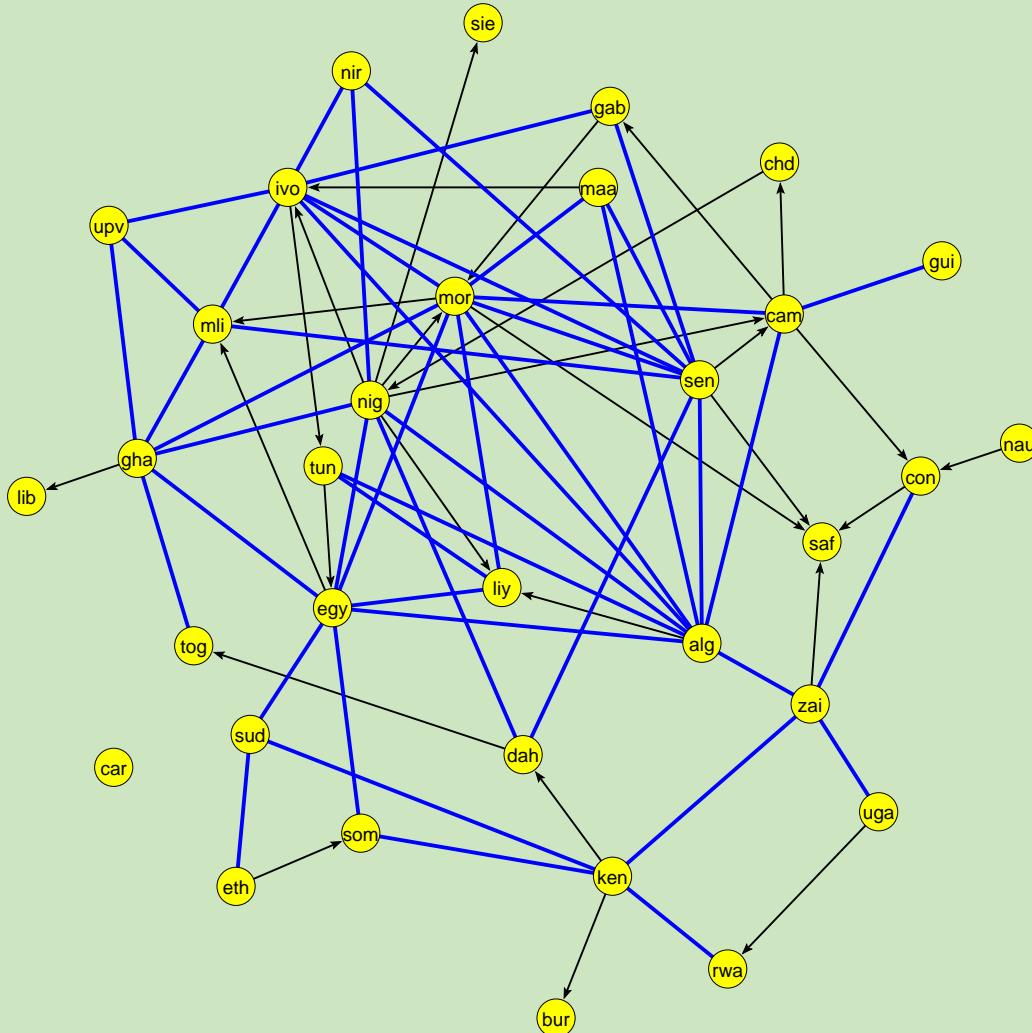
Podgraf



Podgraf $\mathcal{H} = (\mathcal{V}', \mathcal{L}')$ danega grafa $\mathcal{G} = (\mathcal{V}, \mathcal{L})$ je graf, katerega povezave \mathcal{L}' so vsebovane v povezavah grafa \mathcal{G} , $\mathcal{L}' \subseteq \mathcal{L}$, točke \mathcal{V}' pa v točkah grafa \mathcal{G} , $\mathcal{V}' \subseteq \mathcal{V}$, in vsebujejo tudi vsa krajišča povezav \mathcal{L}' .

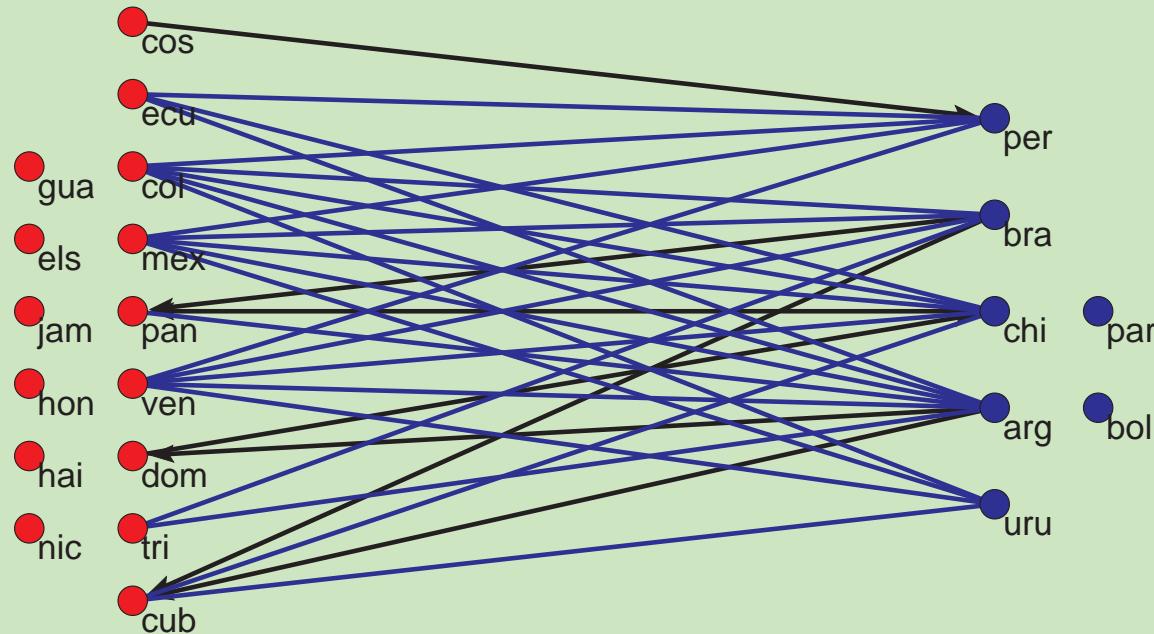
Podgraf je lahko *porojen* z dano podmnožico točk ali povezav. Podgraf je *vpet*, če je $\mathcal{V}' = \mathcal{V}$.

Izrez: Snyder in Kick – Afrika



Izrez: Snyder in Kick

Latinska Amerika : Južna Amerika



Operations/Extract from Network/Partition [5]

Operations/Extract from Network/Partition [2, 3]

Operations/Transform/Remove lines/Inside clusters [2, 3]

[Draw] Move/Grid

Prerezi

Točkovni prerez omrežja $\mathcal{N} = (\mathcal{V}, \mathcal{L}, p)$, $p : \mathcal{V} \rightarrow \mathbb{R}$, na ravni t je podomrežje $\mathcal{N}(t) = (\mathcal{V}', \mathcal{L}(\mathcal{V}'), p)$, določeno z množico točk

$$\mathcal{V}' = \{v \in \mathcal{V} : p(v) \geq t\}$$

kjer je $\mathcal{L}(\mathcal{V}')$ množica vseh povezav iz \mathcal{L} , ki imajo obe krajišči v \mathcal{V}' .

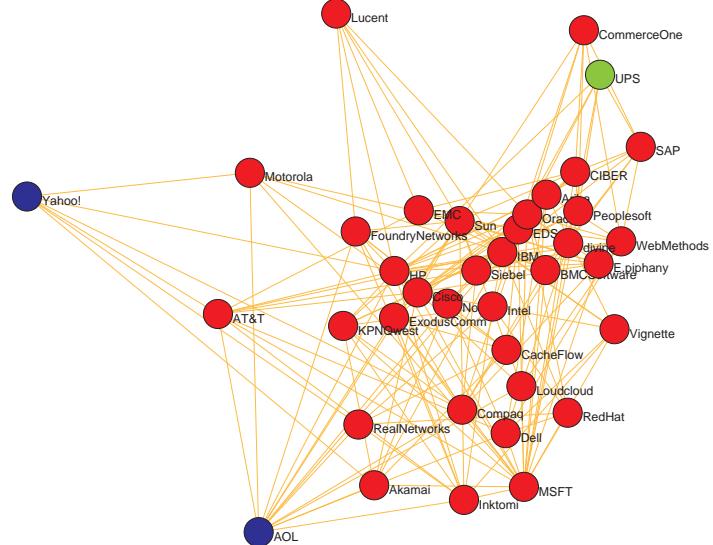
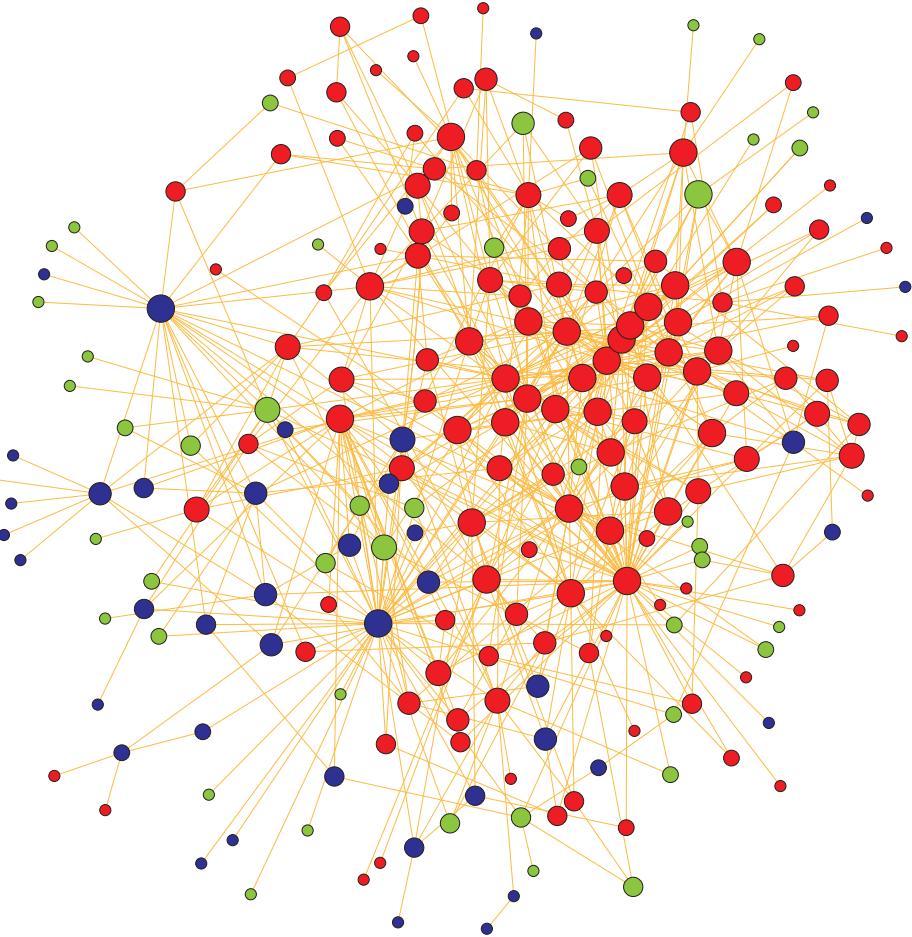
Povezavni prerez omrežja $\mathcal{N} = (\mathcal{V}, \mathcal{L}, w)$, $w : \mathcal{L} \rightarrow \mathbb{R}$, na ravni t je določeno z množico povezav

$$\mathcal{L}' = \{e \in \mathcal{L} : w(e) \geq t\}$$

To je podomrežje $\mathcal{N}(t) = (\mathcal{V}(\mathcal{L}'), \mathcal{L}', w)$, kjer je $\mathcal{V}(\mathcal{L}')$ množica vseh krajišč povezav iz \mathcal{L}' .

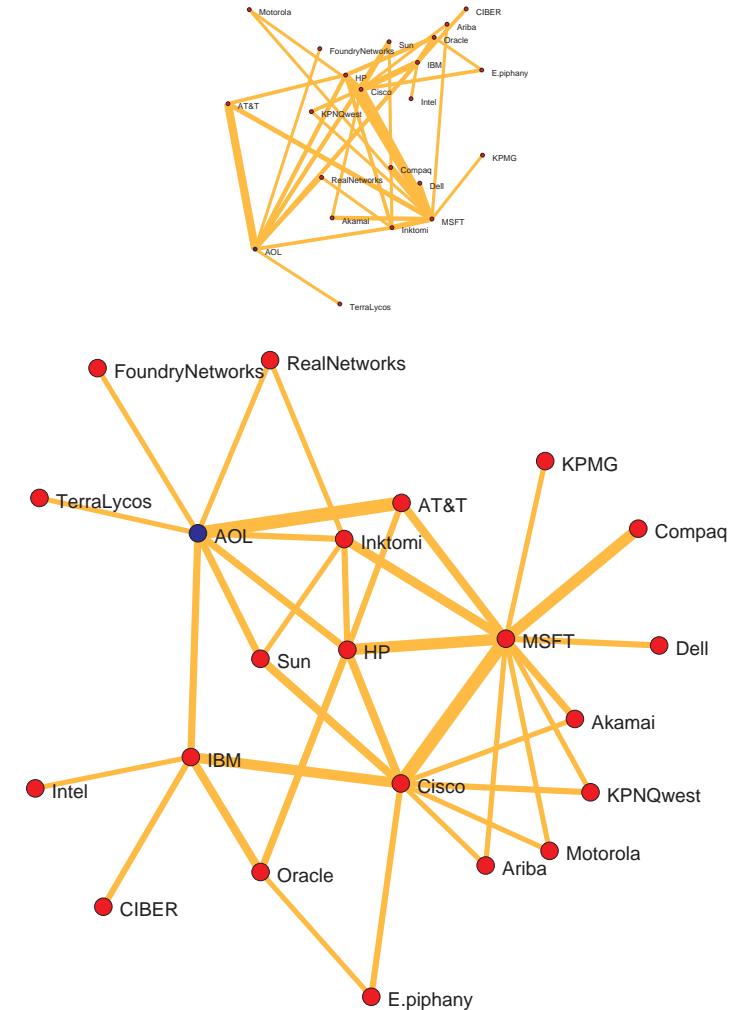
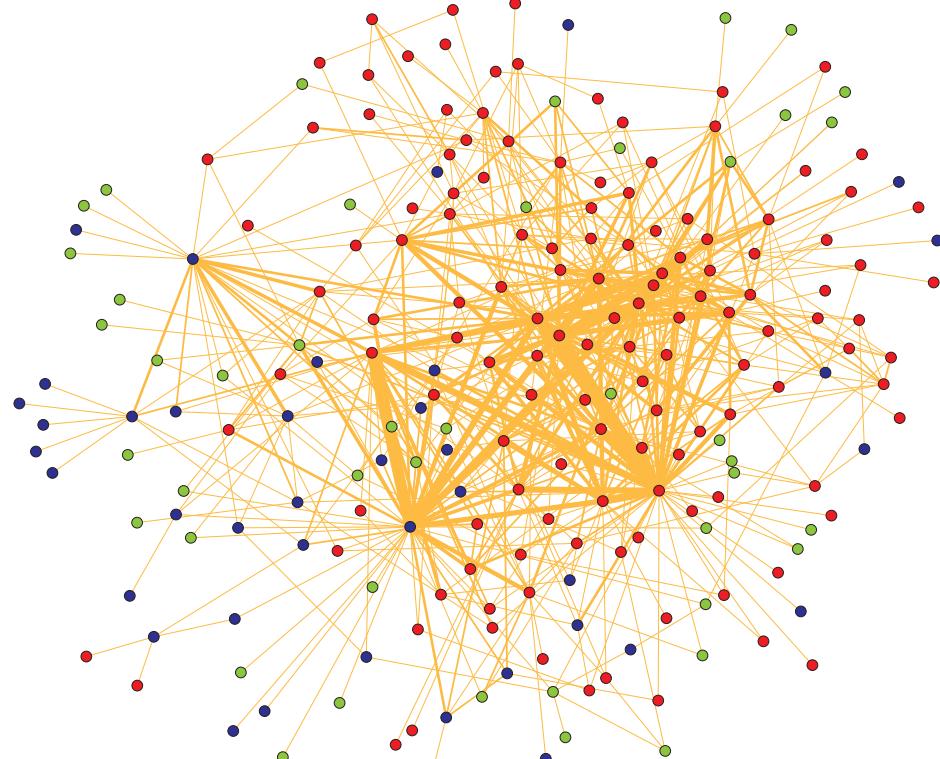
Vrednosti ravni t določimo na osnovi porazdelitve vrednosti funkcij w oziroma p . Običajno nas zanimajo komponente prereza, ki niso niti prevelike, niti premajhne.

Točkovni prerez: Krebsova spletna podjetja, core=6



Vsaka točka predstavlja spletno podjetje dejavno v obdobju 1998 do 2001. $n = 219$, $m = 631$. rdeča – vsebina, modra – podporne storitve, zelena – trgovina. Podjetji sta povezani, če sta najavili skupni posel ali drugo obliko sodelovanja.

Povezavni prerez: Krebsova spletna podjetja, $w_3 \geq 5$



Povezavni prerez: EAT

File/Network/read eatRS.net

Info/Network/Line values ... >= 70

Net/Transform/Remove/Lines with Value/lower than 70

Net/Partitions/Degree/All

Operations/Extract from Network/Partition 1-*

Net/Components/Weak

Draw/Draw-Partition



Analiza omrežja s prerezi

Prerezi ponujajo enostaven pristop k analizi omrežij. Za izbrano lastnost/utež in raven t določimo pripadajoči prerez $\mathcal{N}(t)$. Pozornost posvetimo njegovim komponentam.

Število in velikost komponent je odvisna od ravni t . Pogosto se pojavi več majhnih komponent. Pri analizi nas običajno zanimajo le komponente 'prave' velikosti – vsaj k in ne večje kot K . Premajhne komponente zavrzemo kot 'nezanimive'; prevelike komponente pa ponovno prererežemo na neki višji ravni.

Vrednost t , k in K določimo s pregledom porazdelitve vrednosti lastnosti/uteži in z upoštevanjem dodatnega vedenja o značilnostih omrežja in ciljih raziskave.

V program **Pajek** je vgrajenih nekaj novih, učinkovito izračunljivih lastnosti/uteži.