



# Analiza omrežij

## 7. Aciklična omrežja in vzorci

Vladimir Batagelj

Magistrski program Uporabna statistika  
Ljubljana, maj 2020



# Kazalo

Analiza  
omrežij

V. Batagelj

Aciklična  
omrežja

Omrežja  
sklicevanj


Rodovniki

Trojice

Motivi

Grafki

- 1 Aciklična omrežja
- 2 Omrežja sklicevanj
- 3 Rodovniki
- 4 Trojice
- 5 Motivi
- 6 Grafki



prof. Vladimir Batagelj: [vladimir.batagelj@mf.uni-lj.si](mailto:vladimir.batagelj@mf.uni-lj.si)  
[prosojnice \(PDF\)](#)

7. maj 2020 ob 00:23/ april 2013



# Aciklična omrežja

Analiza omrežij

V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



acyclic.paj

Omrežje  $\mathcal{G} = (\mathcal{V}, \mathbf{R})$ ,  $\mathbf{R} \subseteq \mathcal{V} \times \mathcal{V}$  je *aciklično*, če v njem ni nobenega (pravega) cikla.

$$\overline{\mathbf{R}} \cap I = \emptyset$$

$\overline{\mathbf{R}}$  je tranzitivna ovojnica relacije  $\mathbf{R}$  – relacija *dosegljivosti*.

Včasih dopuščamo zanke  $\overline{\mathbf{R}} \setminus I \cap I = \emptyset$ . Primeri acikličnih omrežij so: omrežja sklicevanj, rodovniki, projektna omrežja, ...

V dejanskih acikličnih omrežjih običajno obstaja lastnost  $p : \mathcal{V} \rightarrow \mathbb{R}$  (najpogosteje čas), ki je usklajena s povezavami

$$(u, v) \in \mathbf{R} \Rightarrow p(u) < p(v)$$



# Osnovne lastnosti

Če je  $\mathcal{G} = (\mathcal{V}, \mathbf{R})$  acikličen in  $\mathcal{U} \subseteq \mathcal{V}$ , je tudi  $\mathcal{G}|_{\mathcal{U}} = (\mathcal{U}, \mathbf{R}|_{\mathcal{U}})$ ,  
 $\mathbf{R}|_{\mathcal{U}} = \mathbf{R} \cap \mathcal{U} \times \mathcal{U}$  acikličen.


Če je  $\mathcal{G} = (\mathcal{V}, \mathbf{R})$  acikličen, je tudi  $\mathcal{G}' = (\mathcal{V}, \mathbf{R}^{-1})$  acikličen. Dualnost.

Množica *začetkov*  $\text{Min}_{\mathbf{R}}(\mathcal{V}) = \{v : \neg \exists u \in \mathcal{V} : (u, v) \in \mathbf{R}\}$  in množica  
*koncev*  $\text{Max}_{\mathbf{R}}(\mathcal{V}) = \{v : \neg \exists u \in \mathcal{V} : (v, u) \in \mathbf{R}\}$  sta v končnem  
acikličnem omrežju neprazni.

Tranzitivna ovojnica  $\overline{\mathbf{R}}$  aciklične relacije  $\mathbf{R}$  je aciklična.

Relacija  $Q$  je *ogrodje* relacije  $\mathbf{R}$  ntk. je  $Q \subseteq \mathbf{R}$ ,  $\overline{Q} = \overline{\mathbf{R}}$  in je relacija  
 $Q$  minimalna – iz nje ne moremo odstraniti nobene povezave, ne da  
bi 'pokvarili' drugo enakost.

Za splošne relacije (grafe) lahko obstaja več ogrodi; za aciklične pa  
je enolično določeno  $Q = \mathbf{R} \setminus \mathbf{R} * \overline{\mathbf{R}}$ .



Preslikava  $h : \mathcal{V} \rightarrow \mathbb{N}^+$  je *globina*, če so vse razlike na najdaljši poti in vrednost v začetku enake 1.

```
 $\mathcal{U} \leftarrow \mathcal{V}; k \leftarrow 0$   
while  $\mathcal{U} \neq \emptyset$  do  
   $\mathcal{T} \leftarrow \text{Min}_R(\mathcal{U}); k \leftarrow k + 1$   
  for  $v \in \mathcal{T}$  do  $h(v) \leftarrow k$   
   $\mathcal{U} \leftarrow \mathcal{U} \setminus \mathcal{T}$ 
```

Risanje po ravneh. Macro Layers.  
Druge globine. Algoritem Sugiyama.



# Prikaz parnega grafa Bouchardovega rodovnika

Analiza omrežij

V. Batagelj

Aciklična omrežja

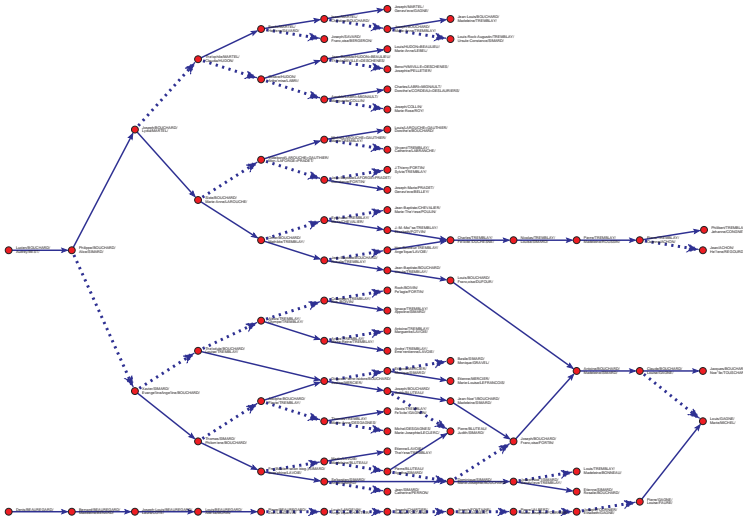
Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



V. Batagelj

Analiza omrežij



# Pravilna oštevilčenja

## Analiza omrežij

V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



Injektivna, z relacijo  $R$  usklajena preslikava  $h : \mathcal{V} \rightarrow 1..|\mathcal{V}|$  je *pravilno oštevilčenje*.

'Topološko urejanje'

$\mathcal{U} \leftarrow \mathcal{V}; k \leftarrow 0$

**while**  $\mathcal{U} \neq \emptyset$  **do**

izberi  $v \in \text{Min}_R(\mathcal{U}); k \leftarrow k + 1$

$h(v) \leftarrow k$

$\mathcal{U} \leftarrow \mathcal{U} \setminus \{v\}$

Matrični prikaz acikličnega omrežja glede na pravilno oštevilčenje ima ničelni spodnji trikotnik.



# ... Pravilna oštevilčenja

Analiza omrežij

V. Batagelj

Aciklična omrežja



Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



```
read or select [Acyclic.paj]
Network/Acyclic Network/Depth Partition/Acyclic
Partition/Make Permutation
File/Network/Export as Matrix to EPS/Using Permutation [acy.eps]
```





# Pravilna oštevilčenja in izračun vrednosti

Naj bo funkcija  $f : \mathcal{V} \rightarrow \mathbb{R}$  definirana na sosedih takole:

- $f(v)$  je znana za  $v \in \text{Min}_{\mathbb{R}}(\mathcal{V})$
- $f(v) = F(\{f(u) : u \mathbf{R} v\})$

Če vrednosti funkcije  $f$  računamo v vrstnem redu določenem z nekim pravilnim oštevilčenjem, dobimo vse vrednosti v enem prehodu – saj so za vsak  $v \in \mathcal{V}$  vrednosti, ki jih potrebujemo pri izračunu  $f(v)$  že določene.



# Pravilna oštevilčenja – primer CPM

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

CPM (Critical Path Method): Projekt je sestavljen iz posameznih opravil. Vozlišča predstavljajo stanja projekta, povezave pa opravila. Za vsako opravilo  $(u, v)$  poznamo čas njegovega trajanja  $t(u, v)$ . Neko opravilo se lahko začne izvajati šele, ko so vsa opravila, ki se končajo v njegovem začetku zaključena. Projektno omrežje je aciklično. Zanima nas, koliko najmanj časa je potrebno za izvedbo projekta.

Naj bo  $T(v)$  čas najzgodnejšega zaključka vseh opravil v stanju  $v$ .

$$T(v) = 0, \quad v \in \text{Min}_R(\mathcal{V})$$

$$T(v) = \max_{u: uRv} (T(u) + t(u, v))$$

Network/Acyclic Network/Critical Path Method – CPM



# Omrežja sklicevanj

## Analiza omrežij

V. Batagelj

Aciklična omrežja

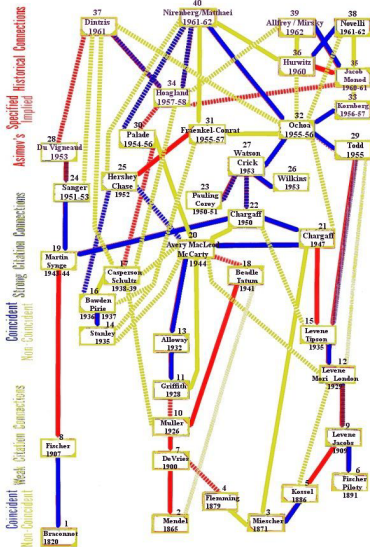
Omrežja sklicevanj

Rodovniki

Trójice

Motivi

Grafki



Analiza omrežij sklicevanj se je pričela leta 1964 s člankom Garfield et al. Leta 1989 sta Hummon in Doreian predlagala tri mere pomembnosti – uteži na povezavah, ki omogočajo računalniško določitev (naj)pomembnejših delov omrežja sklicevanj. Za dve izmed njih obstajata zelo učinkovita postopka za njun izračun.



## ... omrežja sklicevanj

Analiza  
omrežij

V. Batagelj

Aciklična  
omrežja

Omrežja  
sklicevanj

Rodovniki

Trojice

Motivi

Grafki

V dani množici enot/vozlišč  $\mathcal{U}$  (članki, knjige, druga dela, itd.) vpeljemo *relacijo sklicevanja*/množico usmerjenih povezav  $\mathbf{R} \subseteq \mathcal{U} \times \mathcal{U}$

$u\mathbf{R}v \equiv v$  se sklicuje na  $u$

ki določa *omrežje sklicevanj*  $\mathcal{N} = (\mathcal{U}, \mathbf{R})$ .

Relacija sklicevanja je običajno *irrefleksivna* (ni zank) in (skoraj) *aciklična*. V nadaljevanju bomo privzeli, da ima ti dve lastnosti.

V dejanskih omrežjih sklicevanj se včasih pojavijo manjše (praviloma 2 ali 3 vozlišča) krepke komponente. Tako omrežje najenostavneje pretvorimo v aciklično tako, da skrčimo krepke komponente in odvržemo zanke, ki pri tem nastanejo. Obstajajo tudi druge možnosti. Omrežje sklicevanj je koristno dopolniti v *standardno* obliko, tako da mu dodamo skupni *izvor*  $s \notin \mathcal{U}$  in skupni *ponor*  $t \notin \mathcal{U}$ . Izvor  $s$  je neposredno povezan v vse minimalne elemente relacije  $\mathbf{R}$ ; ponor  $t$  pa iz vseh maksimalnih elementov relacije  $\mathbf{R}$ . Dodamo še *povratno* povezavo  $(t, s)$ .



# Štetje poti – Search path count method

Analiza omrežij

V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



Metoda *štetja poti* – *search path count method* (SPC) temelji na števcih  $n(u, v)$ , ki štejejo število različnih poti iz izvora  $s$  v ponor  $t$ , ki gredo čez povezavo  $(u, v)$ . Za izračun števcov  $n(u, v)$  vpeljemo dve pomožni količini:  $n^-(v)$  šteje število poti iz izvora  $s$  v vozlišče  $v$ , in  $n^+(v)$  šteje število poti iz vozlišča  $v$  v ponor  $t$ .



# Hitri postopek za izračun števila poti

Iz osnovnih načel kombinatorike izhaja

$$n(u, v) = n^-(u) \cdot n^+(v), \quad (u, v) \in \mathbf{R}$$

kjer je

$$n^-(u) = \begin{cases} 1 & u = s \\ \sum_{v: v\mathbf{R}u} n^-(v) & \text{sicer} \end{cases}$$

in

$$n^+(u) = \begin{cases} 1 & u = t \\ \sum_{v: u\mathbf{R}v} n^+(v) & \text{sicer} \end{cases}$$

Ta zveza je osnova za hiter izračun števec  $n(u, v)$  – najprej vozlišča grafa topološko uredimo in nato uporabljamo v dobljenem vrstnem redu gornjo zvezo. Postopek ima časovno zahtevnost reda  $O(m)$ ,  $m = |\mathbf{R}|$ . Topološka urejenost zagotavlja, da so v gornji zvezi vse količine že izračunane, ko jih potrebujemo.



# Hummon in Doreian-ove uteži in SPC

Hummon in Doreian-ove uteži so takole določene:

- *search path link count* (SPLC) method: utež  $w_l(u, v)$  je enaka številu "vseh možnih poti po omrežju, ki imajo začetek v izvoru" in gredo po povezavi  $(u, v) \in \mathbf{R}$ .
- *search path node pair* (SPNP) method:  $w_p(u, v)$  "upoštevava vse povezanosti parov vozlišč s potmi, ki gredo po povezavi  $(u, v) \in \mathbf{R}$ ".

Uteži SPLC lahko določimo tako, da uporabimo postopek SPC na omrežju, ki ga dobimo, če v standardni obliki omrežja povežemo izvor  $s$  s povezavo še z vsemi neminimalnimi vozlišči iz  $\mathcal{U}$ ; za uteži SPNP moramo temu omrežju dodati še povezave iz vseh nemaksimalnih vozlišč iz  $\mathcal{U}$  v ponor  $t$ .



# Vozliščne uteži

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Količine uporabljene za določitev povezavnih uteži  $w$  lahko uporabimo tudi za določitev ustreznih vozliščnih vrednosti  $t$

$$t_c(u) = n^-(u) \cdot n^+(u)$$

$$t_l(u) = n_l^-(u) \cdot n_l^+(u)$$

$$t_p(u) = n_p^-(u) \cdot n_p^+(u)$$

Te štejejo število poti izbrane vrste skozi vozlišče  $u$ .

V programu Pajek dobimo hkrati uteži  $w$  in lastnost  $t$ .

Network/Acyclic Network/Citation Weights/Search Path Count (SPC)  
Network/Acyclic Network/Citation Weights/Search Path Link Count (SPLC)  
Network/Acyclic Network/Citation Weights/Search Path Node Pair (SPNP)





# Lastnosti uteži SPC

Analiza  
omrežij

V. Batagelj

Aciklična  
omrežja

Omrežja  
sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Vrednosti števecov  $n(u, v)$  določajo tok po omrežju sklicevanj – zanj velja *Kirchoffov vozliščni zakon*: v vsakem vozlišču  $u$  standardnega omrežja sklicevanj velja *vstopni tok = izstopni tok*:

$$\sum_{v: vRu} n(v, u) = \sum_{v: uRv} n(u, v) = n^-(u) \cdot n^+(u)$$

Utež  $n(t, s)$  je enaka celotnemu toku skozi omrežje in ponuja naravni način normalizacije uteži

$$w(u, v) = \frac{n(u, v)}{n(t, s)} \Rightarrow 0 \leq w(u, v) \leq 1$$

in, če je  $C$  minimalni povezavni prerez, velja še  $\sum_{(u,v) \in C} w(u, v) = 1$ . V velikih omrežjih lahko uteži postanejo zelo velike. Na to je potrebno biti pazljiv pri programiranju algoritma.



# Omrežja sklicevanj s cikli

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Če v omrežju obstaja cikel, obstaja med nekaterimi vozlišči neskončno število sprehodov. Nastali problem lahko poskušamo rešiti na več načinov: z vpeljavo 'staranja', ki zagotovi, da celotna utež sprehodov gre proti neki končni vrednosti; ali omejimo definicijo uteži na neko končno podmnožico sprehodov – npr. poti ali najkrajše poti. Toda to ustvari nova vprašanja: Kolikšen naj bo faktor 'staranja'? Ali je mogoče učinkovito prešteti (najkrajše) poti?

Druga možnost je, ker so omrežja sklicevanj skoraj aciklična, da jih pretvorimo v aciklična:

- skrčimo vsako ciklično skupino (netrivialno krepko komponento) v vozlišče, ali
- razklenemo cikle z odstranitvijo nekaj povezav, ali
- z uporabo ustreznih transformacij (glej naslednjo prosojnico).



# Transformacija Preprint

## Analiza omrežij

V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



Transformacija *preprint* temelji na naslednji zamisli: Vsako vozlišče (delo) iz krepke komponente se podvoji s svojo predobjavo (preprint). Dela znotraj komponente se sklicujejo na predobjave.

Velike krepke komponente v dejanskih omrežjih sklicevanj običajno pomenijo napako v podatkih. Seveda je to odvisno od načina izgradnje omrežja. Tako, na primer ima omrežje **HEP** – High Energy Particle Physics z **arXiv** veliko večjih krepkih komponent, ker so kot ena enota obravnavane vse različice istega članka. Tudi v tem omrežju bi si lahko pomagali s transformacijo 'preprint'.



# Omrežje SOM

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Poglejmo si omrežje sklicevanj za področje ( $n = 4470$ ,  $m = 12731$ ) SOM (*self-organizing maps*). Določimo uteži SPC.

Pri pregledu porazdelitve vrednosti uteži smo izbrali prag 0.007 in določili pripadajoči povezavni izerez. Odstranimo še vse male komponente ( $k = 5$ ). Ostane ena sama komponenta. Narišemo jo po plasteh in ročno popravimo sliko..

Na sliki označimo samo pomembnejša dela – krajišča povezav z utežjo vsaj 0.05..

S slike vidimo, da v razvoju področja SOM obstajata vsaj dve veji razvoja.



# Omrežje SOM – povezavni izrez 0.007

Analiza omrežij

V. Batagelj

Aciklična omrežja

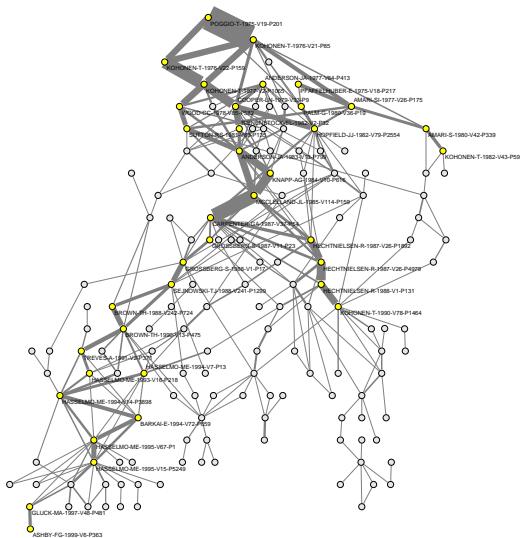
Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafi



V. Batagelj

Analiza omrežij



# Rodovniki

Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj




Rodovniki

Trojice

Motivi

Grafki

Naslednji primer acikličnih omrežij so rodovniki. V poglavju 'Omrežja vsepovsod' smo že opisali naslednje tri omrežne predstavitve rodovnikov:



Orejev graf, parni graph, in dvodelni parni graph

Mormoni, Škofja Loka, ameriški predsedniki; računalništvo, matematika.



# Primerjava predstavitev rodovnikov

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Parni grafi imajo več prednosti (White et al., 1999):

- v parnem grafu je manj vozlišč in povezav kot v Orejevem grafu;
- parni grafi so usmerjeni aciklični grafi;
- vsaka sklenjena veriga v parnem grafu pomeni *poroko med sorodniki*. Obstajata dve vrsti teh porok: *poroke med krvnimi sorodniki*: npr. poroka med bratrancem in sestrično. *poroke med nekrvnimi sorodniki*: npr. brata se poročita s sestrama iz druge družine.
- parni grafi so veliko prikladnejši za analize.

Dvodelni parni grafi natančneje opisujejo rodovnik – npr. omogočajo razlikovati dve poroki enega izmed bratov od enkratnih porok vsakega izmed njiju; omogočajo razkriti poroke med polbrati in polsestami.



# Rodovniki so redka omrežja

Rodovnik je *navaden*, če ima vsaka oseba največ dva starša. Rodovniki so *redka* omrežja – število povezav je istega reda kot število vozlišč.

Za *navaden Orejev rodovnik* velja ( $\mathcal{V}$  – vozlišča,  $\mathcal{A}$  – usmerjene povezave,  $\mathcal{E}$  – neusmerjene povezave):

$$|\mathcal{A}| \leq 2|\mathcal{V}|, \quad |\mathcal{E}| \leq \frac{1}{2}|\mathcal{V}|, \quad |\mathcal{L}| = |\mathcal{A}| + |\mathcal{E}| \leq \frac{5}{2}|\mathcal{V}|$$

Parni grafi so skoraj drevesa – odstopanja od dreves nastanejo zaradi porok med sorodniki ( $\mathcal{V}_p$ ,  $\mathcal{A}_p$  – vozlišča in povezave parnega grafa):

$$|\mathcal{V}_p| = |\mathcal{V}| - |\mathcal{E}| + n_{mult}, \quad |\mathcal{V}| \geq |\mathcal{V}_p| \geq \frac{1}{2}|\mathcal{V}|, \quad |\mathcal{A}_p| \leq 2|\mathcal{V}_p|$$

Za dvodelni parni graf pa velja:

$$|\mathcal{V}| \leq |\mathcal{V}_b| \leq \frac{3}{2}|\mathcal{V}|, \quad |\mathcal{A}_b| \leq 2|\mathcal{V}| + n_{mult}$$





# Število vozlišč in povezav v Orejevih in parnih grafih

Analiza  
omrežij

V. Batagelj

Aciklična  
omrežja

Omrežja  
sklicevanj

Rodovniki

Trojice

Motivi

Grafki

data	$ \mathcal{V} $	$ \mathcal{E} $	$ \mathcal{A} $	$\frac{ \mathcal{L} }{ \mathcal{V} }$	$ \mathcal{V}_i $	$n_{mult}$	$ \mathcal{V}_p $	$ \mathcal{A}_p $	$\frac{ \mathcal{A}_p }{ \mathcal{V}_p }$
Drame	29606	8256	41814	1.69	13937	843	22193	21862	0.99
Hawlina	7405	2406	9908	1.66	2808	215	5214	5306	1.02
Marcus	702	215	919	1.62	292	20	507	496	0.98
Mazol	2532	856	3347	1.66	894	74	1750	1794	1.03
President	2145	978	2223	1.49	282	93	1260	1222	0.97
RoyalE	17774	7382	25822	1.87	4441	1431	11823	15063	1.27
Loka	47956	14154	68052	1.71	21074	1426	35228	36192	1.03
Silba	6427	2217	9627	1.84	2263	270	4480	5281	1.18
Ragusa	5999	2002	9315	1.89	2347	379	4376	5336	1.22
Tur	1269	407	1987	1.89	549	94	956	1114	1.17
Royal92	3010	1138	3724	1.62	1003	269	2141	2259	1.06
Little	25968	8778	34640	1.67	8412				1.01
Mumma	34224	11334	45565	1.66	11556				1.00
Tilltson	42559	12796	54043	1.57	16967				1.00



# Prepletenost

## Analiza omrežij

V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



Naj bo  $n$  število vozlišč v parnem grafu,  $m$  število povezav,  $k$  število šibkih komponent, in  $M$  število koncev (maksimalnih vozlišč – vozlišč z izhodno stopnjo 0,  $M \geq 1$ ).

**Prepletenost** rodovnika imenujemo število:

$$RI = \frac{k + m - n}{k + n - 2M}$$

Za grafe brez povezav postavimo  $RI = 0$ .

Velja  $0 \leq RI \leq 1$ .  $RI = 0$  natanko takrat, ko je graf gozd. Obstajajo poljubno veliki rodovniki z  $RI = 1$ .



# Iskanje vzorcev

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Če se izbrani *vorec* določen z danim (majhnim) grafom ne pojavlja pogosto v redkem grafu, lahko njegove pojavitve razmeroma učinkovito poiščemo s preprostim pregledom vseh možnosti. Iskanje lahko pospešimo tako, da upoštevamo dodatne lastnosti vzorca:

- vozlišča vzorca in omrežja se morajo ujemati tudi v vrednosti izbrane lastnosti (npr. vrsta atoma v molekuli);
- ujemati se morajo uteži na povezavah (npr. moške/ženske povezave v *parnih grafih*);
- prvo vozlišče iz vzorca pripada dani skupini vozlišč.



# Poroke med sorodniki v Ragusi

Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj


Rodovniki

Trojice

Motivi

Grafki

Iskanje vzorcev smo uporabili npr. pri analizi organskih molekul (iskanje ogljikovih obročev) in pri analizi porok med sorodniki v rodovnikih.



Slika prikazuje tri povezane skupine porok med sorodniki v rodovniku dubrovniškega (Ragusa) plemstva. Rodovnik je predstavljen kot parni graf. Polne povezave predstavljajo odnos *– je sin od –*; pikčaste povezave pa odnos *– je hči od –*. V vseh treh skupinah sta se brat in sestra iz ene družine poročila s sestro in bratom iz druge družine.

Networks/Fragment (First in Second)/Find



# Poroke med sorodniki (parni grafi na 2 do 6 vozliščih)

## Analiza omrežij

V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



Na sliki so prikazani **vsi mogoči vzorci** porok med sorodniki na 2 do 6 vozliščih v parnih grafi. Oznake imajo naslednji pomen:

- prvi znak – število začetkov: A – en, B – dva, C – tri.
- drugi znak: število vozlišč v vzorcu (2, 3, 4, 5, ali 6).
- tretji znak: različica, če sta prva znaka enaka.

V vsakem vzorcu je število začetkov enako številu koncev. Poroke med krvnimi sorodniki imajo en začetek in en konec – vse imajo oznako A.



# Primerjava rodovnikov

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Rodovnike lahko primerjamo, tako da primerjamo porazdelitve vzorcev v njih. Za primer smo vzeli naslednje rodovnike: Loka.ged (Škofja Loka), Silba.ged (otok Silba, Hrvaška), Ragusa.ged (dubrovniško plemstvo med 12. in 16. stoletjem, Dremelj et al., 2002) Turcs.ged (turški nomadi, White et al., 1999), RoyalE.ged (evropske kraljevske rodbine).

Vidimo:

generacijski preskok za več kot eno generacijo je (skoraj) neverjeten – vzorci A4.2, A5.2 in A6.3 se ne pojavljajo v rodovnikih, vzorec A6.2 se pojavi 2 krat na Silbi, vzorec B6.4 se pojavi 5 krat v Ragusai in 3 krat pri turkih). Pri turkih je zelo veliko porok vrst A4.1 in A6.1.

V vseh rodovnikih je število porok med nekrvnimi (vzorci B4, B5, C6, B6.1, B6.2, B6.3 in B6.4) sorodniki veliko večje od števila porok med krvnimi sorodniki. Razlogi za poroke med sorodniki so pogosto pogojeni s prizadevanji za ohranitev premoženja znotraj izbranih rodbin.



# Normalizirane pogostosti vzorcev $\times 1000$

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

pattern	Loka	Silba	Ragusa	Turcs	RoyalE
A2	0.07	0.00	0.00	0.00	0.00
A3	0.07	0.00	0.00	0.00	2.64
A4.1	0.85	2.26	1.50	<b>159.71</b>	18.45
B4	3.82	11.28	10.49	<b>98.28</b>	6.15
A4.2	0.00	0.00	0.00	0.00	0.00
A5.1	0.64	3.16	2.00	36.86	11.42
A5.2	0.00	0.00	0.00	0.00	0.00
B5	1.34	4.96	23.48	46.68	7.03
A6.1	1.98	12.63	1.00	<b>169.53</b>	11.42
A6.2	0.00	0.90	0.00	0.00	0.88
A6.3	0.00	0.00	0.00	0.00	0.00
C6	0.71	5.41	9.49	36.86	4.39
B6.1	0.00	0.45	1.00	0.00	0.00
B6.2	1.91	17.59	31.47	<b>130.22</b>	10.54
B6.3	3.32	13.53	40.96	<b>113.02</b>	11.42
B6.4	0.00	0.00	2.50	7.37	0.00
Sum	14.70	72.17	123.88	798.53	84.36

Zelo pogoste se poroke med sorodniki pri turkih; sledijo jim dubrovčani.



# Dvodelni parni grafi: poroka med polbratrancem in polsestrično

Analiza  
omrežij

V. Batagelj

Aciklična  
omrežja

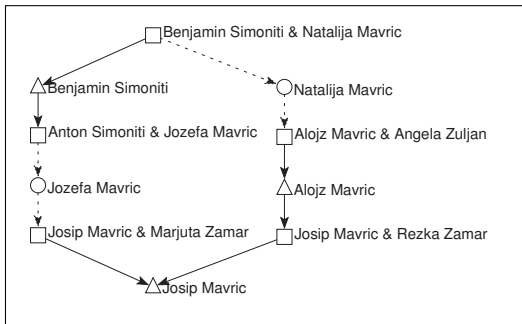

Omrežja  
sklicevanj

Rodovniki

Trojice

Motivi

Grafki







## ... rodovniki – druga vprašanja

### Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Rodoslovce zanimajo še druga vprašanja:

- spremembe v pogostosti vzorcev skozi čas;
- posebnosti: velikokrat poročene osebe, osebe z veliko otrok;
- preverjanje sorodstvene povezanosti med osebama in iskanje najkrajše poti po rodovniku, če obstaja;
- določitev vse prednikov/potomcev izbrane osebe; določitev osebe, ki ima največ prednikov/potomcev;
- največja razlika v letih med možem in ženo; najstarejša/najmlajša oseba pri poroki; najstarejša/najmlajša oseba ob rojstvu otroka; ...
- določitev najdaljše moške/ženske verige;
- odkrivanje napak pri vnosu podatkov (preverjanje pravilnosti omrežja).

Na vsa ta vprašanja je mogoče odgovoriti z orodji programa Pajek.



# Trojice

## Analiza omrežij

### V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



Naj bo  $\mathcal{G} = (\mathcal{V}, \mathbf{R})$  enostaven usmerjen graf brez zank. **Trojica** je podgraf porojen z izbranimi tremi vozlišči.

Obstaja 16 neizomorfnih (vrst) trojic, ki so naprej razbite na tri skupine:

- the *ničelna* trojica 003;
- *dvočleni* trojici 012 in 102; ter
- *povezane* trojice: 111D, 201, 210, 300, 021D, 111U, 120D, 021U, 030T, 120U, 021C, 030C in 120C.



# Trojiški spekter

Več lastnosti grafa je mogoče izraziti z uporabo *trojiškega spektra* – porazdelitve vseh njegovih trojic. Ta je tudi osnovna sestavina za *modele omrežij*  $p^*$ . Običajni postopek za določitev trojiškega spektra je reda  $O(n^3)$ ; no, v večini velikih omrežij ga je mogoče določiti precej hitreje. *Algoritem* temelji na naslednjem opažanju: *v velikem in redkem omrežju je večina trojic ničelnih*. Označimo s  $T_1, T_2, T_3$  zaporedoma število ničelnih, dvočlenih in povezanih trojic. Ker je celotno število trojic enako  $T = \binom{n}{3}$  in so zgornje skupine razbitje množice vseh trojic, je zamisel postopka naslednja:

- preštej vse dvočlene  $T_2$  in vse povezane  $T_3$  trojice z njihovimi podvrstami;
- število ničelnih trojic izračunaj po zvezi  $T_1 = T - T_2 - T_3$ .



# ... Trojiški spekter

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

V izvedbi postopka moramo zagotoviti, da bo vsaka neničelna trojica šteta natanko enkrat pri prehodu množice povezav. Vozlišča trojice  $\{v, u, w\}$  lahko v splošnem izberemo na 6 načinov  $(v, u, w)$ ,  $(v, w, u)$ ,  $(u, v, w)$ ,  $(u, w, v)$ ,  $(w, v, u)$ ,  $(w, u, v)$ . Problem izomorfizma lahko rešimo z uvedbo *kanonskih* izbir, ki prispevajo k številu; ostale, nekanonske, lahko preskočimo.

Celotna zahtevnost tega algoritma je reda  $O(\hat{\Delta}m)$  in potemtakem, za grafe z majhno največjo stopnjo  $\hat{\Delta} \ll n$ , ker je  $2m \leq n\hat{\Delta}$ , reda  $O(n)$ .



# Trojice

## Analiza omrežij

### V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Triad:	BA	CL	RC	R2C	TR	HC	39+	p1	p2	p3	p4
003		✓	✓		✓	✓				✓	✓
012					✓	✓	✓			✓	✓
102	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
021D			✓	✓	✓	✓	✓				✓
021U			✓	✓	✓	✓	✓			✓	✓
021C									✓		✓
111D											✓
111U								✓	✓		
030T			✓	✓	✓	✓	✓		✓		✓
030C								✓	✓		✓
201											
120D			✓	✓	✓	✓	✓			✓	✓
120U			✓	✓	✓	✓	✓	✓	✓		✓
120C							✓		✓		
210						✓	✓		✓		
300	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓

**Triad Micro-Models:**  
 BA: Ballance (Cartwright and Harary, '56)      CL: Clustering Model (Davis, '67)  
 RC: Ranked Cluster (Davis & Leinhardt, '72)      R2C: Ranked 2-Clusters (Johnsen, '85)  
 TR: Transitivity (Davis and Leinhardt, '71)      HC: Hierarchical Cliques (Johnsen, '85)  
 39+: Model that fits D&L's 742 mats N 39-72      p1-p4: Johnsen, 1986. Process Agreement Models.

Moody




# Matrično preštevanje vzorcev

V knjigi Estrada: *A First Course in Network Theory* (2015) je podan dolg seznam obrazcev za preštevanje malih podgrafov.




$$|F_1| = \frac{1}{2} \sum_i k_i(k_i - 1)$$



$$|F_2| = \frac{1}{6} \text{tr}(A^3)$$



$$|F_3| = \sum_{(i,j) \in E} (k_i - 1)(k_j - 1) - 3|F_2|$$



$$|F_4| = \frac{1}{6} \sum_i k_i(k_i - 1)(k_i - 2)$$

Fiziki stopnjo vozlišča  $v_i$  označujejo s  $k_i$ .



# Matrično preštevanje vzorcev

## Analiza omrežij

V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki



$$|F_8| = \frac{1}{10} (\text{tr}(A^5) - 30|F_2| - 10|F_6|)$$

$$|F_9| = \frac{1}{2} \sum_{k_i \geq 4} t_i (k_i - 2)(k_i - 3)$$

$$|F_{10}| = \frac{1}{2} \sum_i (k_i - 2) \times \sum_{i,j} \binom{(A^2)_{ij}}{2} - 2|F_7|$$



# Matrično preštevanje vzorcev

## Analiza omrežij

V. Batagelj

Aciklična omrežja


Omrežja sklicevanj

Rodovniki


Trojice

Motivi

Grafki



$$|F_{17}| = \sum_{(i,j) \in E} \binom{(A^2)_{ij}}{3}$$



$$|F_{18}| = \sum_i l_i \cdot \sum_{i \neq j} \binom{(A^2)_{ij}}{2} - 6|F_7| - 2|F_{14}| - 6|F_{17}|$$





# Motivi

## Analiza omrežij

V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Omrežni motivi so podomrežja, ki se v danem omrežju pojavljajo pogosteje kot je pričakovano. Domnevamo lahko, da odražajo lokalno organiziranost v omrežju, ki omogoča njegovo učinkovitejše delovanje.

Milo, R, Shen-Orr, S, Itzkovitz, S, Kashtan, N, Chklovskii, D, Alon, U: Network Motifs: Simple Building Blocks of Complex Networks. Science, 298, October 2002, p. 824-827.

Wikipedia: [Motifs](#)



# Motivi

## Analiza omrežij

### V. Batagelj

Aciklična omrežja

Omrežja sklicevanj

Rodovniki

Trojice

Motivi

Grafki

Network	Nodes	Edges	$N_{real}$	$N_{rand} \pm SD$	Z score	$N_{real}$	$N_{rand} \pm SD$	Z score	$N_{real}$	$N_{rand} \pm SD$	Z score
<b>Gene regulation (transcription)</b>					<b>Feed-forward loop</b>			<b>Bi-fan</b>			
<i>E. coli</i>	424	519	40	7 ± 3	10	203	47 ± 12	13			
<i>S. cerevisiae</i> *	685	1,052	70	11 ± 4	14	1812	300 ± 40	41			
<b>Neurons</b>					<b>Feed-forward loop</b>			<b>Bi-fan</b>			<b>Bi-parallel</b>
<i>C. elegans</i> †	252	509	125	90 ± 10	3.7	127	55 ± 13	5.3	227	35 ± 10	20
<b>Food webs</b>					<b>Three chain</b>			<b>Bi-parallel</b>			
Little Rock	92	984	3219	3120 ± 50	2.1	7295	2220 ± 210	25			
Ythan	83	391	1182	1020 ± 20	7.2	1357	230 ± 50	23			
St. Martin	42	205	469	450 ± 10	NS	382	130 ± 20	12			
Chesapeake	31	67	80	82 ± 4	NS	26	5 ± 2	8			
Coachella	29	243	279	235 ± 12	3.6	181	80 ± 20	5			
Skipwith	25	189	184	150 ± 7	5.5	397	80 ± 25	13			
B. Brook	25	104	181	130 ± 7	7.4	267	30 ± 7	32			



# Motivi

Analiza omrežij

V. Batagelj

Aciklična omrežja










Omrežja sklicevanj

Rodovniki

Trójice

Motivi

Grafki

Electronic circuits (forward logic chips)				Feed-forward loop		Bi-fan		Bi-parallel			
s15850	10,383	14,240	424	2 ± 2	285	1040	1 ± 1	1200	480	2 ± 1	335
s38584	20,717	34,204	413	10 ± 3	120	1739	6 ± 2	800	711	9 ± 2	320
s38417	23,843	33,661	612	3 ± 2	400	2404	1 ± 1	2550	531	2 ± 2	340
s9234	5,844	8,197	211	2 ± 1	140	754	1 ± 1	1050	209	1 ± 1	200
s13207	8,651	11,831	403	2 ± 1	225	4445	1 ± 1	4950	264	2 ± 1	200
Electronic circuits (digital fractional multipliers)				Three-node feedback loop		Bi-fan		Four-node feedback loop			
s208	122	189	10	1 ± 1	9	4	1 ± 1	3.8	5	1 ± 1	5
s420	252	399	20	1 ± 1	18	10	1 ± 1	10	11	1 ± 1	11
s838†	512	819	40	1 ± 1	38	22	1 ± 1	20	23	1 ± 1	25
World Wide Web				Feedback with two mutual dyads		Fully connected triad		Uplinked mutual dyad			
nd.edu§	325,729	1.46e6	1.1e5	2e3 ± 1e2	800	6.8e6	5e4 ± 4e2	15,000	1.2e6	1e4 ± 2e2	5000

R: igraph::motifs



# Grafki

Analiza  
omrežij

V. Batagelj

Aciklična  
omrežja

Omrežja  
sklicevanj

Rodovniki

Trojice

Motivi

Grafki

*Grafki* (graphlets) so majhni neizomorfni porojeni podgrafi danega omrežja. Grafki se razlikujejo od motivov, ker so porojeni podgrafi, motivi pa splošni podgrafi.


Grafke je vpeljala Pržulj Nataša: Biological network comparison using graphlet degree distribution. *Bioinformatics*, Volume 23, Issue 2, 15 January 2007, Pages e177–e183, [PDF](#)

Wikipedia: [/Graphlets](#)

iGraph: [graphlet](#); [ORCA](#)



# Grafki na 2–5 vozliščih z orbitami avtomorfizmov



Vozlišča iste barve pripadajo isti orbiti v grafku.