3. Nacionalna konferencija sa međunarodnim učešćem
Fakultet tehničkih nauka u Čačku, 25-27. Septembar 2015.

3rd National Conference With International Participation
Faculty of Technical Sciences in Čačak, 25-27. September 2015.

UDK: 519.8:004.6 Stručni rad

# PRIMJENA HIBRIDNE TEHNIKE KLASTEROVANJA U INTEGRACIJI RESURSA PROCESA U OBRAZOVANJU

# APPLICATION HYBRID CLUSTERING TECHNIQUES FOR INTEGRATING RESOURCES BUSINESS PROCESSES IN EDUCATION

**Rava Filipović**
**ORAO a.d. Bijeljina**
filipovicrava@yahoo.com

***Apstrakt:*** *U ovom radu je opisana primjena postupka klasterovanja s ciljem formiranja timova, na osnovu prijateljskih veza njihovih članova, kako bi se što efikasnije upravljalo timovima (timskim radom) za potrebe rješavanja većeg broja realnih problema u okviru predškolskog, osnovnog, srednjeg i visokog obrazovanja, u procesu reinženjeringa poslovnih proseca. Za rješavanje problema grupisanja korištena je hibridna tehnika lokalne optimizacije pretraživanja nastala kombinacijom Best Improvement insert i First Improvement insert, kao intuitivno razvijenih efikasnih i efektivnih postupaka grupisanja na grafovima Metodom promjenljivih okolina, koja je vrlo često korištena heuristika. Ovaj rad je implementiran u okviru rješavanja problema podjele u klastere tako da normalizovan presjek, kao jedan od kriterijuma klasterovanja grafa, optimizuje funkciju cilja u društvenim mrežama.*
***Ključne riječi:*** *Klasterovanje, normalizovan presjek, optimizacija, heuristike.*

***Abstract:*** *This paper describes the use of clustering procedure with the aim of forming teams, on the basis of friendly relations of their members, in order to more efficiently manage the teams (team work) for the purpose of resolving a large number of real problems in the preschool, primary, secondary and higher education, business process reengineering cuts. To solve the problem of grouping used a hybrid technique of local search optimization blends Best Improvement insert and First Improvement insert, as intuitively developed efficient and effective methods of grouping the graphs method of changing environment, which is often used heuristics. This work is implemented within the framework of solving the problem of division in the clusters so that the normalized cross-section, as one of the criteria clustering graph, optimizing the objective function in social networks.words.*
***Key words:*** *Clustering, normalized cross-section, optimization, heuristics.*

## 1. UVOD

Prisutno je mišljenje da kreiranje timova i rad u njima ima brojne prednosti te da može povećati organizacijsku uspješnost. Ali kako i na koji način formirati timove, koji će donijeti rezultate i unutar kojih će članovi graditi i produbljivati odnos povjerenja i saradnje? Otkrivanje grupa timova se rješava optimizacijom i to nalaženjem optimalnog rješenja. Optimizacija se bavi razvojem postupaka zasnovanim na heurističkim [1] algoritmima. Heuristike su najčešće bazirane na nekoj opštoj ideji ili analogiji sa prirodnim procesima (u fizici, biologiji, medicini, ...). Te ideje se zatim razvijaju, modifikuju, proširuju, a često i kombinuju (hibridizacija) u cilju povećanja njihove efikasnosti. Heuristike u zadovoljavajućem vremenu nalaze dovoljno dobra rješenja. Jedna od primjena je u rješavanju problema na grafovima, koja se može primijeniti na rješavanje niza realnih problema. Otkrivanje klastera (u ovom slučaju timova) u velikim realnim grafovima, kao što su velike društvene mreže[2] (veliki broj učesnika), je značajan problem od praktičnog interesa.

Da bi se izbjegle moguće nesuglasice, netrpeljivosti, nerazumijevanje, lični interesi, ... moguće je stvoriti grupe unutar skupa ljudi iz različitih razloga bliskosti: zbližavaju se ljudi koji imaju slične vrijednosti, stavove, interes, razmišljanja ili ljudi koji su privučeni istom osobom itd. Na osnovu ovih razloga članovi tima imaju osjećaj posvećenosti zajednički postavljenim ciljevima. Postoji opšte razumijevanje o tome da se lični i timski ciljevi najbolje mogu dostići uz pomoć uzajamne podrške. Svi članovi učestvuju u procesu donošenja odluka. Svojim ličnim znanjima, kvalitetima i stručnošću doprinose uspjehu rada tima. Prisutna atmosfera povjerenja i ohrabrivanja pruža mogućnost da se izraze ideje, mišljenja, neslaganje, osjećanja, ... Članovi tima ulažu napor da se međusobno razumiju, podstiču razvoj i primjenu vještina u toku rada, pri čemu nastaju nove ideje, kreativnosti i dolazi do napretka.

Tim čini grupa ljudi sa znanjem, sposobnostima, posvećenih zajedničkoj misiji i ciljevima, za čije se ostvarenje smatraju međusobno odgovornim. Timovi su osnovne "jedinice" za većinu organizacija. Oni su veoma korisni jer ujedinjuju vještine, iskustva i perspektive ljudi. U cilju rješavanja većine realnih problema ovo istraživanje se može iskoristiti za grupisanje članova u timove, na osnovu odnosa prijateljstva, za rad na projektima, u sekcijama, na organizovanju priprema testiranja, takmičenja, prijemnih ispita, sportskih aktivnosti, ... u okviru predškolskog, osnovnog, srednjeg i visokog obrazovanja, u procesu reinženjeringa poslovnih proseca i to putem društvenih mreža.

U ovom dijelu istraživanja cilj je otkriti što veći broj prijatelja, koji se dobro slažu i koji će biti integrisani u iste klastere[3] (timove) tako da broj prijatelja između različitih klastera bude sveden na minimum.

---

1Heuristika - nauka o metodama i principima pronalaženja novog.

2Društvena mreža (takođe i socijalna mreža) je društvena struktura sastavljena od pojedinaca (ili organizacija) koji se nazivaju "čvorovi", a koji su povezani jednim ili više specifičnih tipova „veza“, kao što su: prijateljstvo, vizije, ideje, finansijski interes, srodstvo, zajednički interes, finansijska razmjena, nedopadanje, ili odnosi povjerenja, znanja ili prestiža.

3Klaster (engl. Cluster) je mala grupa ili gomila nečega.

## 2. PODJELA U KLASTERE

Društvene mreže na Internetu predstavljaju jedan od najrasprostranjenijih i najinteresantnijih fenomena današnjice. Osim što predstavljaju neku vrstu trenda, što doprinosi njihovoj popularnosti, one donose i nove mogućnosti u komunikaciji i olakšano sklapanje kontakata, kao i upotrebu i razmjenu različitih sadržaja, što još više doprinosi njihovom značaju. Društvene mreže pružaju razne mogućnosti i neosporno je da od njih ima dosta koristi. Kako su društvene mreže u ekspanziji i kako postaju sve veće i veće nameće se potreba za efikasnim postupcima kojima bi se članovi tih mreža razvrstali u grupe (klastere). Istraživanje društvenih mreža ima za cilj identifikovanje klastera. Klasterovanje [4], kao jedna od aktivnosti istraživanja podataka, rješava optimizacione probleme grupisanja elemenata na osnovu nekih veza (relacija) koje postoje između njih. Analizu podataka je lakše izvesti nad grupisanim podacima u klastere, jer se time omogućava: pojednostavljenje skupa podataka, proučavanje postupaka, principa grupisanja, identifikacija odnosa, ... Takođe, podjela skupa podataka u manje grupe (klastere) predstavlja izazov u otkrivanju pravila, modela i zakonitosti na osnovu kojih mogu da se donesu važne odluke.

U ovom dijelu istraživanja primijenjena je metoda promjenljivih okolina (Variable Neighborhood Search – VNS) opisana u [13]. Kao jedna od metaheuristika bazirana je na principu lokalnog pretraživanja. Za ovu metodu je neophodno početno (inicijalno) rješenje u čijoj okolini se na slučajan način (postupkom razmrdavanja) bira susjedno (slučajno) rješenje. Ovo slučajno rješenje postaje polazno rješenje za lokalno pretraživanje. Slučajno odabrano rješenje iz okoline trenutnog rješenja se poboljšava kombinacijom (hibrid) tehnika lokalnog pretraživanja, pod određeno definisanim uslovima dobijenim intuitivno kroz veći broj testnih primjera.

Primijenjena tehnika lokalnog pretraživanja je hibrid, koja je nastala od dvije tehnike First Improvement insert i Best Improvement insert, u okviru metode promjenljivih okolina. First Improvement se zaustavlja kada se dobije prvo bolje rješenje, koje postaje trenutno najbolje. Best Improvement lokalno pretraživanje traži najbolji potez u prostoru pretraživanja. Prva strategija se koristi iz razloga da se ne troši suviše mnogo vremena kako se ne bi istraživala čitava okolina slučajnog rješenja. Druga strategija se koristi u krajnjem slučaju kada se pretražuje čitava okolina slučajnog rješenja, tj. ako se ne naiđe ni na jedno poboljšanje ili se pretraživanje zaustavlja ako istekne unaprijed određeno vrijeme. Udružene strategije lokalnog pretraživanja (First improvement i Best improvement) daju hibrid, koji je doveo do značajnih poboljšanja.

## 3. HIBRIDNO LOKALNO PRETRAŽIVANJE

Na početku, za svaki par (redom odabranih) klastera slučajnog rješenja se računa vrijednost funkcije cilja Ncut. Suma Ncut pojedinačnih vrijednosti (para klastera) se oduzme od ukupne vrijednosti funkcije cilja slučajnog rješenja. Odabere se redom čvor iz prvog klastera i potom se radi provjera premještanja. Računa se vrijednost promjene

4"Klastering" (Clustering): Klasterovanje se odnosi na grupisanje podataka po sličnosti.

funkcije cilja Ncut para klastera. Ova vrijednost se doda na trenutno izmijenjenu vrijednost Ncut-a slučajnog rješenja. Nova vrijednost slučajnog rješenja se pamti i predstavlja novo rješenje (lokalni optimum). Ako je novo rješenje bolje od trenutno najboljeg slučajnog rješenja ono mijenja trenutno najbolje slučajno rješenje. Ovim provjera premještanja je donijela popravak. Čvor se premjesti iz prvog u drugi klaster. Promijenjena vrijednost Ncut para klastera postaje trenutno najbolja vrijenost Ncut slučajnog rješenja. U slučaju lošijeg rješenja odabran čvor se ne premješta. Za odabran par klastera postupak se nastavlja provjerom premještanja redom odabranih sledećih čvorova, iz prvog klastera.

Kada se završi prebacivanje čvorova, iz ovog para klastera tehnikom First improvement insert, algoritam se vraća na početak, odnosno primijeni se druga tehnika (Best improvement insert) na odabran par klastera. Suma para trenutnih vrijednosti Ncut klastera se oduzme od ukupne vrijednosti funkcije cilja slučajnog rješenja. Potom se radi provjera premještanja čvorova iz prvog u drugi klaster, odnosno traži se najbolji potez premještanja. Redom odabran čvor iz prvog klastera se premjesti u drugi klaster. Računa se vrijednost promjene funkcije cilja Ncut para klastera. Ova vrijednost se doda na trenutno izmijenjenu vrijednost Ncut slučajnog rješenja. Dobijeno novo rješenje je lokalni optimum, kome je pridružena vrijednost funkcije cilja Ncut. Ova vrijednost se upoređuje sa nekom unaprijed definisanom vrijednošću funkcije cilja Ncut. Ako je novo rješenje bolje pamti se vrijednost funkcije cilja Ncut (ovog boljeg rješenja) i pamti se čvor (koji je donio poboljšanje). Na isti način, postupak se nastavlja provjerom premještanja sledećih čvorova. Ovim načinom premještanja traži se najbolji potez para klastera. Odnosno, traži se čvor čijim premještanjem iz jednog u drugi klaster će doći do popravke trenutno najboljeg slučajnog rješenja. Ako je novo rješenje bolje od trenutno najboljeg slučajnog rješenja bolje rješenje mijenja trenutno najbolje slučajno rješenje. Najbolji upamćen čvor, koji je dao popravku, se premjesti iz prvog u drugi klaster. Promijenjena vrijednost Ncut para klastera postaje trenutno najbolja vrijednost Ncut slučajnog rješenja. U slučaju lošijeg rješenja odbacuje se premještanje čvora. Postupak se nastavlja od početka provjerom premještanja redom odabranog čvora, iz sledećeg redom odabranog para klastera.

## 4. RJEŠENJE PROBLEMA

### 4.1. REPREZENTACIJA PROBLEMA

Proučavan problem klasterovanja se može definisati na sledeći način:

Dat je skup od N osoba i matrica prijateljstava između osoba. Rasporediti datih N osoba u K klastera tako da se minimizira funkcija Ncut. Normalizovan presjek [12], kao jedan od najpoznatijih kriterijuma postupka klasterovanja grafa, minimizira funkciju cilja.

### 4.2. PODJELA U KLASTERE

Skup od N osoba (čvorova), se grupiše u K disjunktnih podskupova, koji predstavljaju upravo tih K particija [13]. Dobijeno rješenje predstavlja inicijalno (početno) rješenje, neophodno za primjenu metode promjenljivih okolina.

## 4.3. POSTUPAK RAZMRDAVANJA

Postupak razmrdavanja mijenja strukturu inicijalnog (početnog) rješenja i u njegovoj okolini generiše slučajno rješenje. Ovo rješenje je neophodno za postupak lokalnog poboljšanja, kojim će se nastojat popravit trenutno najbolje rješenje. Za slučajno odabran čvor nađe se klaster, u kome se trenutno nalazi taj čvor. Potom se na slučajan način odabere sledeći klaster, različit od prvog, i u njega se prebaci slučajno odabran čvor. Postupak se ponavlja t puta (unaprijed definisana vrijednost inicijalne okoline). Dobijenom slučajnom rješenju se pridruži vrijednost funkcije cilja Ncut.

## 4.4. PRIMJENA HIBRIDNE TEHNIKE LOKALNOG PRETRAŽIVANJA

U ovom dijelu istraživanja primijenjena je hibridna tehnika lokalne popravke u okviru metode promjenljivih okolina kako bi se uradila testiranja na skupovima podataka (instancama), potom uporedila i istakle njene prednosti u odnosu na referentne vrijednosti [12]**.** Lokalno pretraživanje nastoji pronaći bolje rješenje popravljanjem slučajno dobijenog rješenja, odnosno vrijednosti funkcije Ncut postupka pretresa.

Glavna ideja je sledeća: ukoliko u okolini slučajnog rješenja nema boljeg rješenja pretraživanje se nastavlja u novoj okolini trenutno najboljeg rješenja. Ukoliko i tada se ne pronađe bolje rješenje, prelazi se u sledeću okolinu, itd. sve dok se ne dođe do maksimalno unaprijed definisane okoline. Međutim, ukoliko u nekoj od okolina se pronađe bolje rješenje pretraživanje ponovo počinje od prve okoline. Prostor dopustivih rješenja se pretražuje na slučajan način uz primjenu objedinjenih principa lokalnog pretraživanja First improvement insert i Best improvement insert. Složenost pretraživanja okolina se smanjuje generisanjem slučajnog rješenja u okolini trenutno najboljeg rješenja, gdje se iterativno traži bolje rješenje. Strategija sa kojom se prelazi u bolje rješenje i to u prvo na koje naiđe je *First Improvement* (FI) karaktera. Nakon čega se lokalno pretraživanje nastavlja strategijom najbolje popravke (*Best Improvement*), koja traži najbolji potez u prostoru pretraživanja.

Lokalno pretraživanje okolina se odvija pod uslovom da je par klastera povezan makar jednom vezom prijateljstva i da čvorovi imaju prijatelja u susjednom klasteru. Kada se završi pretraživanje svakog para klastera radi se provjera u kojoj se upoređuje trenutno najbolje rješenje i popravljeno slučajno rješenje. Posle postupka provjere postupak lokalnog pretraživanja se vraća na postupak razmrdavanja trenutno najboljeg rješenja. Ovim se proširuje okolina trenutno najboljeg rješenja i u njoj se ponovo bira slučajno rješenje.

Treba napomenuti da prilikom premještanja čvorova, u postupku razmrdavanja i postupku lokalnog pretraživanja, se vodi računa da se ne isprazni klaster (iz koga se premješta).

## 4.5. TESTNI REZULTATI

Algoritam je implementiran u C#. Za potrebe testiranja korišteni su grafovi[5]. Broj čvorova (n) i grana za svaki graf (skup podataka) je dat u Tabeli 1. Ograničenja postavljena u toku rada algoritma su ukupno vrijeme izvršavanja jednog VNS-a 1000 sec i definisani parametri okolina (1):

$$t_{min} = \min\{20, (n/100) + 1\},$$
$$t_{step} = \min\{20, (n/100) + 1\},$$
$$t_{max} = \min\{200, (n/5) + 1\}. \quad (1)$$

Tabela 1. Karakteristike grafova

| Skup podataka | Broj čvorova grafa \|V\| | Broj grana grafa \|E\| |
|---|---|---|
| add32 | 4960 | 9462 |
| finance256 | 37376 | 130560 |
| gupta2 | 62064 | 2093111 |
| memplus | 17758 | 54196 |
| pcrystk02 | 13965 | 477309 |
| rajat10 | 37376 | 130560 |
| ramage02 | 62064 | 2093111 |

Testni rezultati prezentovani u Tabeli 2. daju pregled najboljih rješenja za pet prolaza VNS-a za datu instancu (skup podataka) i definisan broj klastera [12]. Svako pojedinačno rješenje predstavljeno distribucijom cijelih brojeva (čvorova) po klasterima je zbog dozvoljenog prostora neizvodljivo prikazati, ali je dat prikaz dobijenih vrijednosti funkcije cilja Ncut metodom promjenljivih okolina (Hibrid VNS) i referentne vrijednosti VNS prema [12]:

Tabela 2. Testni rezultati VNS

| Instanca | Broj klastera | Hibrid VNS | VNS |
|---|---|---|---|
| add32 | 2 | 0.012 | 0.002 |
| | 4 | 0.032 | 0.012 |
| | 8 | 0.069 | 0.059 |
| | 16 | 0.212 | 0.214 |
| | 32 | 0.978 | 0.766 |
| | 64 | 2.342 | 2.441 |
| | 128 | 10.558 | 10.668 |
| | 256 | 34.765 | 34.808 |

5downloaded from http://userweb.cs.utexas.edu/users/dml/Software/graclus.html

## 5. NAUČNI DOPRINOS

Najvažniji novi rezultati dobijeni istraživanjem prikazanim u ovom radu su definisana: varijanta problema podjele u klastere, koja je realnija (više odgovara praktičnim potrebama), odgovarajuća funkcija cilja i nov način kodiranja prezentacije rješenja cijelim brojevima, potom grupisanje ili izdvajanje sličnih objekata iz neke veće cjeline u manje grupe pojednostavljuje analiza podataka, razvoj efikasnih i efektivnih tehnika klasterovanja., kao i generisanje novih teorijskih rezultata.

Glavni doprinos je razvoj hibridne tehnike lokalnog pretraživanja, u okviru metode promjenljivih okolina, na sasvim nov način za prethodno uvedenu varijantu problema klasterovanja, pri čemu su dobijeni novi teorijski rezultati, koji predstavljaju nove referentne vrijednosti u odnosu na dobijena rješenja [12]. Rješenje ovog problema moguće primijeniti na neku čitavu klasu problema. Razvoj ovog algoritma je zahtjevao da se razvije:

- Novi način predstavljanja potencijalnih rješenja.
- Postupak za formiranje inicijalnih rješenja.
- Postupak razmrdavanja okoline trenutnog rješenja.
- Redoslijed po kome se vrši pretraživanje.
- Strategija promjene okoline.
- Postupak proširenja okoline trenutnog rješenja.
- Razvijeni postupci hibridnog lokalnog pretraživanja.
- Kriterijum zaustavljanja.

Realizovani algoritam samostalno razvijen u zadovoljavajućem vremenu pronalazi izuzetno dobru podjelu u klastere. Kao što se može vidjeti iz eksperimentalnih rezultata, predložen metod promjenljivih okolina je veoma uspješan pri rješavanju problema podjele u klastere i namijenjen je rješavanju problema velikih dimenzija [12]. Zbog svega gore navedenog, naučno istraživanje opisano u ovom radu daje doprinos oblastima kombinatorne optimizacije i lokacijskih problema.

## 6. ZAKLJUČAK

Na ovaj način stvorene grupe timova (klastera) imaju vjerovatnoću sklapanja prijateljstava značajno povećanu u odnosu na slučajno odabrane grupe. Dakle te grupe predstavljaju stvarne grupe ljudi u svakodnevnom životu. Potrebno ih je samo razotkriti. Ako ih razotkrijemo na osmišljen način, neće li to donijeti mnoge blagodeti, olakšice i pogodnosti svakom pojedincu ponaosob?

Cilj ovog istraživanja je bio doprinos procesu reinženjeringa, u stvaranju i upravljanju timovima, za potrebe rješavanja većeg broja realnih problema u okviru predškolskog, osnovnog, srednjeg i visokog obrazovanja. Prethodno opisan način podjele u klastere stvara dobre i efikasne timove u procesu reinženjeringa, koje odlikuje uvažavanje i podsticanje razmjene mišljenja i ideja, prepoznavanje potreba i interesa. Članovi, na ovaj način formiranih timova, su fleksibilni i lako odgovaraju na promjene zahtjeva ili okruženja. Većom brzinom, tačnošću i efikasnošću prilagođavaju svoj pristup novim

informacijama. Ulažu dosta vremena i napora u istraživanje, oblikovanje i slaganje oko svrhe postojanja. Na osnovu relacije prijateljstva, formirane grupe timova odlikuje odnos povjerenja, poštovanja, podrške i pomoći. Saradnja je otvorena i poštena. Svi učestvuju u donošenju odluka i prisutna je posvećenost zajedničkim postavljenim ciljevima. Rad u ovakvom timu prevazilazi strukturu ljudi različitog porijekla, sa raznorodnim iskustvima, pristupima, gledištima, vrijednostima i očekivanjima, pri čemu uključuje više slaganja, tolerancije i otvorenosti za saradnju. Članovi tima, na osnovu prijateljskih veza, međusobno se dopunjavaju i tako doprinose bogatstvu kreativnog procesa pri čemu su neizostavni rezultati za postavljene ciljeve.

Proučavani problem, postupka podjele u klastere je bio složen i zahtijevao je izvođenje velikog broja eksperimenata. Intuitivnim postupcima smještanja osoba u klastere došlo se intuitivno do parametara, na osnovu minimalnog presjeka grafa. Dalja istraživanja će se kretati u pravcu primjene drugih heuristika i njihovih kombinacija, na istom proučavanom problemu, u cilju što efikasnijeg rješavanja proučavanog problema klasterovanja u odnosu na dobijene rezultate [12].

## LITERATURA

[1] D. Aloise and P. Hansen, “Clustering,” in Handb. of Discrete and Combinatorial Mathematics, D. Shier, Ed. CRC Press, to appear.

[2] Z. Wu and R. Leahy, “An optimal graph theoretic approach todata clustering: Theory and its application to image segmentation,” IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 15, pp. 1101–1113, 1993.

[3] N. Mladenović and P. Hansen, “Variable neighborhood search,” Computers and Operations Research, vol. 24, pp. 1097–1100, 1997.

[4] J. Shi and J. Malik, “Motion segmentation and tracking using normalized cuts,” in Proc. of the 6th Int’l Conf. on Computer Vision, 1998, pp. 1154–1160.

[5] J. Shi and J. Malik, “Normalized cuts and image segmentation,” IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 22, pp. 888–905, 2000.M.

[6] P. Hansen and N. Mladenovi´c, “Variable neighborhood search: principles and applications,” European Journal of Operational Research, vol. 130, pp. 449–467, 2001.

[7] S. Yu and J. Shi, “Multiclass spectral clustering,” in Int’l Conf. Computer Vision, 2003.

[8] M. Newman and M. Girvan, “Finding and evaluating community structure in networks,” Phys. Rev. E, vol. 69, p. 026113, 2004.

[9] M. Lagrange, L. Martins, J. Murdoch, and G. Tzanetakis, “Normalized cuts for predominant melodic source separation,” IEEE Trans. on Audio, Speech, and Language Processing, vol. 16, pp. 278–290, 2004.

[10] I. Dhillon, Y. Guan, and B. Kulis, “Weighted graph cuts without eigenvectors: A multilevel approach normalized cuts and image segmentation,” IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 29, pp. 1944–1957, 2007.

[11] P. Hansen, N. Mladenovi´c, and J. P´erez, “Variable neighborhood search: methods and applications,” 4OR, vol. 6, pp. 319–360, 2008.

[12] P Hansen, M Ruiz, D Aloise, “A Variable Neighborhood Search Heuristic for Normalized Cut Clustering,”, - 2010 - gerad.ca

[13] R. Filipović, “Particionisanje grafa - problem MIN-CUT”, 2015.