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: 005.6:519.816 Stručni rad

STRATEGIJE LOKALNOG PRETRAŽIVANJA NA UPRAVLJANJU TIMOVA PRI FORMIRANOJ INICIJALNOJ PODJELI U KLASTERE

STRATEGY FOR LOCAL SEARCH THE MANAGEMENT TEAMIN THE DIVISION OF THE INITIAL FORMED IN CLUSTERS

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

Apstrakt: *U ovom radu je opisan podjela u klastere tako da se broj susjeda prijatelja, između različitih grupa timova, svede na minimum, sa posebnim naglaskom da su se za inicijalnu podjelu u klastere koristila formirana inicijalna rješenja na grafovima u čijoj okolini su se nastojala dobit poboljšanja primjenom lokalnih pretraživanja Best Improvement insert (u jednom slučaju) i First Improvement insert (u drugom slučaju) Metodom promjenljivih okolina (VNS), kako bi se što efikasnije formirali timovi, za različite potrebe rješavanja većeg broja realnih problema u okviru predškolskog, osnovnog, srednjeg i visokog obrazovanja, u procesu reinženjeringa poslovnih proseca. Tokom procesa testiranja, na skupovima instanci, napravljena su tabelarna poređenja (za oba slučaja) VNS metode, u odnosu na referentna rješenja. 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 reči: *Klasterovanje, normalizovan presjek, optimizacija, heuristike.*

Abstract: *This paper describes the division into clusters so that the number of neighbors friends, between different groups of teams to a minimum, with a special emphasis that the initial division of the clusters formed using the initial decision on graphs environment in which they sought to gain improvement using local search Best Improvement insert (in one case) and First Improvement insert (in another case) Method of changing environment (VNS) in order to more efficiently formed teams for different needs solving a large number of real problems in the preschool, primary, secondary and higher education, in business process reengineering cuts. During the testing process, papers instance, made the tabular comparisons (for both cases) VNS methods, in relation with the reference solutions. 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 optimizes the objective function in social networks.*
Key words: *Clustering, normalized cross-section, optimization, heuristics.*

1. UVOD

Timski rad je pokazao svoju vrijednost povećanjem kvaliteta i ostvarivanjem postavljenih ciljeva. Upravljanje timovima je povećalo vjerovatnost uspješnog uvođenja produktivnog tima. Te se u raznim sferama ljudskog djelovanja otkriva da osmišljeno odabrani timovi raspoloživih ljudskih resursa i timski rad pridonose gotovo u svakom segmenmtu poslovanja. Upravljanje timovima pruža podršku i samopouzdanje neophodno za pokretanje i upravljanje timskim radom, za procjenu njihovog uspjeha i za poticanje članova tima na koordiniran i disciplinovan rad. Jedan od načina formiranja grupa timova, unutar kojih će članovi (sa jedne strane) graditi i produbljivati odnos povjerenja, saradnje i (sa druge strane) što efikasnije i efektnije riješiti postavljene zadatke, jeste optimizacijom i to nalaženjem optimalnog rješenja na bazi heurističkih algoritama.

Otkrivanje klastera (u ovom slučaju timova) u velikim realnim grafovima, kao što su velike društvene mreže (veliki broj učesnika), je značajan problem od praktičnog interesa. U osnovi ovog dijela istraživanja je razoj efikasnih i efektivnih postupaka, koji u prostupku kretanja kroz prostor rješenja stvaraju grupe timova sa najmanjim brojem međuklasterskih (prijateljskih) veza. Cilj je otkriti što veći broj prijatelja, koji će biti uključeni u iste klastere (timove) tako da broj prijatelja između različitih klastera (timova) bude sveden na minimum. Za potrebe rješavanja većine realnih problema ovaj prijedlog se može iskoristiti za integraciju velikog broja učesnika u timove neophodne za rad: na projektima, u sekcijama, na organizovanju i pripremi specifičnih događaja, kao što su testiranja, takmičenja, prijemni ispiti, sportske aktivnosti, ... u okviru predškolskog, osnovnog, srednjeg i visokog obrazovanja, u procesu reinženjeringa poslovnih proseca, putem društvenih mreža.

Ovaj rad je implementiran u okviru rješavanja problema podjele u klastere tako da normalizovan presjek [12], kao jedan od kriterijuma klasterovanja grafa optimizuje funkciju cilja u društvenim mrežama. Za potrebe ovog dijela istraživanja korištena je metoda promjenljivih okolina (Variable Neighborhood Search – VNS) opisana u [13]. Preduslov za ovu metodu je početno (inicijalno) rješenje pri čemu su uzeta formirana inicijalna rješenja Graclus za unaprijed definisan broj klastera na grafovima testnih instanci, u društvenim mrežama.

2. BEST IMPROVEMENT TEHNIKA LOKALNOG PRISTUPA

Best Improvement insert lokalno pretraživanje traži najbolji potez u prostoru pretraživanja. Ova strategija se koristi u slučaju kada se pretražuje čitava okolina slučajnog rješenja. Suma para trenutnih vrijednosti Ncut klastera se umanji 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 premješten čvor (koji je donio poboljšanje). Na isti način, postupak se nastavlja premještanjem sledećih čvorova. Ovim načinom premještanja traži se najbolji potez para klastera. Odnosno, traži se čvor (učesnik) čijim premještanjem iz jednog u drugi klaster (tim) će doći do popravke slučajnog rješenja. Najbolji upamćen čvor, koji je dao popravku, se premjesti u drugi klaster. Ako je novo rješenje bolje onda bolje rješenje mijenja slučajno rješenje, kome se pridruži vrijednost funkcije cilja. Promijenjena vrijednost Ncut para klastera postaje trenutna popravljena vrijenost Ncut slučajnog rješenja. U slučaju lošijeg rješenja odbacuje se premještanje čvora. Postupak se nastavlja od početka premještanjem redom odabranih čvorova, iz sledećeg redom odabranog para klastera.

3. FIRST IMPROVEMENT TEHNIKA LOKALNOG PRISTUPA

First Improvement insert tehnika lokalnog pristupa se zaustavlja kada se dobije prvo bolje rješenje, koje postaje trenutno najbolje slučajno popravljeno rješenje. Ova strategija se koristi iz razloga da se ne troši suviše mnogo vremena i kako se ne bi istraživala čitava okolina slučajnog rješenja. Za svaki (redom odabran) par klastera slučajnog rješenja se računa vrijednost funkcije cilja Ncut. Suma para trenutnih vrijednosti Ncut klastera se umanji od ukupne vrijednosti funkcije cilja slučajnog rješenja. Potom se radi provjera premještanja čvora iz prvog 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 vrijednošću funkcije cilja Ncut slučajnog rješenja. Ako je novo rješenje bolje promijenjena vrijednost Ncut para klastera postaje trenutno najbolja vrijenost Ncut slučajnog rješenja i čvor, koji je donio poboljšanje, se premjesti. U slučaju lošijeg rješenja odbacuje se premještanje čvora. Vrijednost funkcije cilja slučajnog rješenja ostaje nepromijenjena. Na isti način, postupak se nastavlja premještanjem sledećeg redom odabranog čvora.

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, kao jedan od najpoznatijih kriterijuma postupka klasterovanja grafa (opisan detaljno u [13]) 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. 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. TEHNIKE LOKALNOG PRETRAŽIVANJA

Glavna ideja lokalnog pretraživanja je sledeća: ukoliko u okolini slučajnog rješenja nema boljeg rješenja pretraživanje se nastavlja u novoj okolini trenutno najboljeg rješenja. Ukoliko i tada 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 principa lokalnog pretraživanja Best Improvement insert, u jednom slučaju i First Improvement insert, u drugom slučaju. Složenost pretraživanja okoline se smanjuje generisanjem slučajnog rješenja u okolini trenutno najboljeg rješenja gdje se iterativno traži bolje rješenje.

U prvom slučaju, u okviru primjene metode VNS, radi se strategija najbolje popravke (*Best Improvement*) u kojoj lokalno pretraživanje nastoji poboljšat slučajno dobijeno rješenje pri čemu traži najbolji potez u prostoru pretraživanja u okviru metode promjenljivih okolina.

U drugom slučaju, u okviru primjene metode promjenljivih okolina, radi se strategija sa kojom se prelazi u bolje slučajno rješenje i to u prvo na koje naiđe iz kog razloga je ova tehnika lokalnog pretraživanja *First Improvement* karaktera. Ova strategija se koristi iz razloga da se ne troši suviše mnogo vremena kako se ne bi istraživala čitava okolina slučajnog rješenja.

Da bi se provjerila efikasnost i kvalitet pronadjenog rješenja razvijenih algoritama, neophodno je testne rezultate ovih algoritma uporediti sa testnim rezultatima drugih heuristika. Ta dva algoritma su se izvršavala na istom skupu instanci, kako bi se uporedile njihove karakteristike.

4.5. TESTNI REZULTATI

Treba napomenuti da 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.

Prilikom premještanja čvorova, u postupku razmrdavanja i postupku lokalnog pretraživanja, se vodi računa da se ne isprazni klaster (iz koga se premješta). Da bi se provjerila efikasnost razvijenih algoritama metode promjenljivih okolina Best Improvement insert ili First Improvement insert lokalne pretrage, testni rezultati ovih algoritama su se uporedili kako međusobno tako i sa referentnim rezultatima [12], kako bi se istakle prednosti prethodno opisanih tehnika lokalnog pretraživanja.

Algoritam je implementiran u C#. Za potrebe testiranja korišteni su grafovi. 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. 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 (VNS1 - primjenom tehnike Best Improvement insert i VNS2 - primjenom tehnike First Improvement insert) i referentne vrijednosti prema [12]:

Tabela 2. Testni rezultati VNS

Instanca	Broj klastera	VNS1	VNS2	VNS
add32	2	0.022	0.21	0.002
	4	0.039	0.038	0.012
	8	0.068	0.069	0.059
	16	0.213	0.215	0.214
	32	0.988	0.987	0.766
	64	2.440	2.443	2.441
	128	10.666	10.667	10.668
	256	34.802	34.803	34.808

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), ali zato kompleksnija za rješavanje, odgovarajuće funkcije cilja, nov način kodiranja prezentacije rješenja cijelim brojevima, izdvajanje sličnih objekata iz neke veće cjeline u manje grupe, čime se pojednostavljuje analiza podataka, razvoj efikasnih i efektivnih tehnika klasterovanja, kao i generisanje novih teorijskih rezultata.

Glavni doprinos je razvoj 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 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

Strateška rješenja bazirana na identifikaciji grupa timova pomažu u donošenju važnih odluka. Generisanjem većeg broja rješenja (strukture podjele članova u grupe), odnosno smanjivanjem broja međuklasterskih veza mogu se pratiti (mjeriti) efekti procesa rada grupa timova. Za slučaj da se pojedinci teško uklapaju u timski koncept rada, odnosno da se ne mogu ili, zbog „neodgovarajućeg“ sastava tima, ne žele da prihvate timski koncept rada. U oba slučaja, kod čovjeka se stvara napetost koja vodi stresu i frustraciji. Tako, u slučaju neuklapanja člana u jednom timu sledećom varijantom podjele u grupe pruža se mogućnost ispravke nekih od nedostataka rada u timskim grupama. Ovim se nastoji problematičan član (članovi) ili tim zamijeniti drugim članovima kako bi se prevazišli problemi neuklapanja i nehomogenosti tima.

Grupisanje članova tima, na osnovu prijateljstava, predstavlja dobro vođenje i upravljanje timskim radom. Prethodno opisani postupci formiranja timova sa najmanjim brojem međuklasterskih prijateljstava prevazilazi vrijeme upoznavanja, sticanja sigurnosti, iskrenosti i povjerenja. Takođe, daju mogučnost proširenja radne sposobnosti u sticanju novih vještina, znanja, intuicije i međusobne saradnje. Ovim se dobija na efektnosti i efektivnosti rješavanja svakog problema stavljenog pred dobro odabranu grupu tima. Radom u timu, na osnovu prijateljskih odnosa članovi tima imaju veću motivaciju i izraženo zadovoljstvo što se ogleda u proširenju ličnih znanja, sposobnosti i osjećaju poštovanja. Ovako stvorene grupe timova daju mogućnost lakšeg vođenja, upravljanja, praćenja i ocjenjivanja radne uspješnosti i nagrađivanja, putem društvenih mreža.

Proces lokalnog pretraživanja se odvija u iteracijama i zaustavlja kada u okolini novog rješenja ne postoji bolje rješenje, što je i osnovni nedostatak lokalnog pretraživanja. Prednost metode promjenljivih okolina je u tome što, primjenom novih strategije Best Improvement insert i First Improvement insert lokalnog pretraživanja, prevazilazi zaglavljivanje u lokalnim minimumima. Uspjeh lokalnog pretraživanja zavisi od početnog rješenja, strukture okoline i načina pretraživanja okoline.

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, koji su dali rezultate, na osnovu minimalnog presjeka grafa. Dalja istraživanja će se kretati u pravcu primjene iste ili 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] 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.