

RUTIRANJE U BEŽIČNIM MREŽAMA BAZIRANO NA KLASTERIZACIJI PRIMENOM VEŠTAČKIH NEURALNIH MREŽA

DYNAMIC ROUTING IN WIRELESS NETWORKS BASED ON CLUSTERING BY ARTIFICIAL NEURAL NETWORKS

Milan Pavlović, Marija Zajeganović Ivančić, Nenad Kojić, Visoka ICT škola, Beograd
Irini Reljin, Ministarstvo za telekomunikacije i informaciono društvo, Elektrotehnički fakultet, Beograd

Sadržaj – Savremene komunikacije se sve više baziraju na primeni bežičnih mreža. Sve veći broj korisnika i servisa koji se nude zahteva upotrebu adaptivnih protokola za rutiranje. Ovi protokoli treba da obezbede pouzdan prenos i optimalnu upotrebu mrežnih resursa. S obzirom da veštačke neuralne mreže daju dobre rezultate u oblasti optimizacije i rutiranja, ovaj rad je baziran na jednoj implementaciji dve vrste neuralnih mreža. Proces rutiranja će biti realizovan u dve faze: prva koja treba da izvrši klasterizaciju linkova bežične mreže i druga koja treba da izvrši rutiranje na bazi klasterizacije. Prva faza je bazirana na primeni samo-organizujuće neuralne mreže, dok je druga bazirana na primeni rekurentne neuralne mreže. U radu će se analizirati predloženo rešenje, koje treba da razmotri veći broj ulaznih parametara, bliskih realnom okruženju.

Abstract – Modern communications are based very often on the use of wireless networks. An increasing number of users and offered services require the use of adaptive routing protocols. These protocols should provide reliable transmission and optimum use of network bandwidth. Since artificial neural networks have good performance in the field of optimization and routing, this paper is based on an implementation of two types of neural networks. Routing process will be implemented in two phases: the first one includes clustering of wireless links, based on the use of self-organizing neural network, and the other one performs process of routing by the application of recurrent neural network. This paper will analyze the proposed solution, which should consider a number of input parameters, close to the real network environment.

1. UVOD

Sve veći broj raznovrsnih uređaja pristupa mrežama. Već neko vreme sve više postoji potreba za bežičnim pristupom zbog potrebe korisnika da konformno, bilo odakle pristupaju resursima i razmenjuju informacije. Mnogi uređaji (mobilni telefoni, laptopovi, PDA, i slično) imaju podršku za bežični pristup. Inicijalno, ovakav vid komunikacije je u pozadini zahtevao žičnu infrastrukturu. Kod takvih bežičnih mreža po pravilu postoji ili centralni uređaj za kontrolu mreže (kao što je na primer bazna stanica) ili uređaj kroz koji prolazi kompletan saobraćaj (kao što je access point). Međutim, realno se sve više nameće potreba za postojanjem bežične mreže bez fiksne infrastrukture. Rešenje za takve mreže su takozvane Wireless Mesh Network (WMN) [1-4].

U WMN osnovu funkcionalisanja čine multihop komunikacije. Nième, svaki uređaj se ponaša i kao predajnik i kao prijemnik, sopstvenih, ali i drugih informacija koje se razmenjuju u ovakvoj vrsti bežične mreže. Neke od motivacija za razvoj mesh bežičnih mreža su dobijanje decentralizovane bežične mreže, minimalna oprema za realizaciju mreže, vrlo mala ulaganja, minimalna potreba za konfiguracijom i održavanjem mreže, povećana redundantnost mreže zbog postojanja više putanja između krajnjih korisnika i slično [5, 6].

Sa druge strane ove mreže mogu da ponude skoro sve funkcionalnosti kao i standardna žičana mreža ili bežična mreža sa fiksnom infrastrukturom.

U ovim mrežama se topologija i brzina prenosa podataka na linkovima menjaju permanentno i to velikom brzinom. Zbog toga je značajna problematika nalaženje efikasnog protokola rutiranja što neminovno utiče na kvalitet servisa.

Brz proces prerutiranja i ponovne uspostave putanja između krajnjih stаницa predstavlja osnovni zahtev koji primjenjeni protokol rutiranja mora da ispunji [7].

U ovom radu će se predložiti jedno rešenje algoritma za rutiranje koje ima za cilj da analizira veći broj ulaznih parametara i konačnu odluku o putanji donese što brže. U tom cilju, u radu će se analizirati mogućnost Kohonenove veštačke neuralne mreže, koja na bazi više ulaznih parametara treba da izvrši klasterizaciju postojećih linkova. Na ovaj način, klasteri se mogu rangirati po određenim kriterijumima i indirektno se mogu kategorisati linkovi koji im pripadaju. U ovom radu, nakon rangiranja klastera, linkovima će se dodeliti potpuno novi parametar na osnovu koga će se vršiti traženje najpovoljnije putanje. Na ovaj način veliki broj ulaznih parametara se analizira, ali se svođenjem na jedan, proces traženja putanje skraćuje. Za potrebe traženja najkraće putanje koristiće se Hopfield-ova neuralna mreža.

Ovaj rad je organizovan kroz pet poglavlja. Nakon uvoda, u drugom poglavlju su date osnovne napomene o radu Kohonenove neuralne mreže, dok su u trećem izloženi principi rada Hopfield-ove neuralne mreže. U četvrtom poglavlju se prikazani dobijeni rezultati bazirani na realnim mrežnim uslovima. Zaključak i dalje smernice u istraživanju date su u petom poglavlju.

2. KLASTERIZACIJA I PRIMENA KOHONENOVE NEURALNE MREŽE

Mnoge metode obrade podataka su bazirane na klasterizaciji Q , koje podrazumevaju podelu i grupisanje podataka na klastere Q_i , $i = 1, \dots, C$ tako da su rastojanja

podataka unutar istog klastera minimalna, dok rastojanja podataka između različitih klastera maksimalna. Pritom treba imati u vidu da svaki podatak može pripadati samo jednom klasteru. Neuralne mreže su se pokazale kao efikasan alat u pogledu klasifikacije ulaznih podataka i klasterizacije [7]. Uzimajući u obzir tri glavne paradigme učenja, neuralne mreže se mogu podeliti u tri glavne kategorije: nadgledane - supervised, sa povratnim signalom - reinforced i samostalne-unsupervised. Samo-organizuće mape (SOM), takođe poznate i kao Kohonenove mreže po njihovom izumitelju Teuvo Kohonen-u, pripadaju klasi unsupervised mreža [8, 9]. One same određuju reprezentaciju internih težina za prezentovane ulaznih podataka bez bilo kakvog nadzora korisnika. Samo-organizuće mape predstavljaju vizualizacionu tehniku za predstavljanje podataka, koje redukuju dimenzije podataka kroz upotrebu samo-organizućih neuralnih mreža [8]. Samo-organizuće feature mape (Self-organizing feature maps - SOFM) uče da klasifikuju ulazne vektore prema tome kako su grupisani u ulaznom prostoru.

Samoorganizujuća mapa sastoji se od elemenata koji se nazivaju čvorovi ili neuronii što se može vizualizovati kao neuralna mreža u obliku matrice. Uobičajan raspored čvorova je pravilan poredak u obliku heksagonalne ili pravougaone mreže. Svakom čvoru je pridružen vektor težine iste dimenzije kao i ulazni vektori koji predstavljaju podatke, takođe pridružena je i pozicija u okviru strukture mape [7, 9].

Procedura postavljanja vektora iz prostora podataka na mapu započinje pronalaženjem čvora sa najblžim težinskim vektorom vektoru uzetom iz prostora podataka. Zatim se koordinate u mapi ovog čvora postavljaju na vrednost vektora. Rastojanje između neurona se računaju na osnovu njihovih pozicija pomoću funkcije rastojanja. Kada su ulazni uzorci predstavljeni mreži, vrši se pretraga da bi se odabroa pobednički neuron c . Ulazni vektor x u trenutku t se upoređuje sa svakim od težinskih vektora \mathbf{m}_i koji pripadaju SOM, a minimum Euklidskog rastojanja između ulanog signala i težinskih koeficijenata neurona određuju najbolje poklapanje.

$$\|x(t) - m_c(t)\| = \min_i \{ \|x(t) - m_i(t)\|\} \quad (1)$$

Težinski koeficijenti čvorova se tada ažuriraju uzimajući u obzir okolinu u obliku kruga oko pobedničke jedinice sa funkcijom pojačanja $\alpha(t)$ (vrednosti ove funkcije su $0 < \alpha < 1$) kao što sledi:

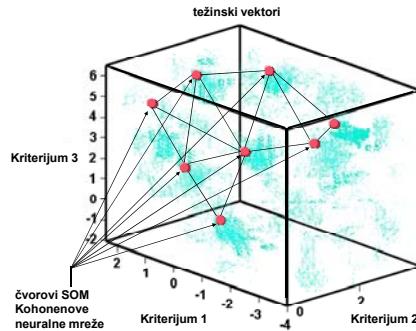
$$m_i(t+1) = m_i(t) + \alpha(t)[x_i(t) - m_i(t)] \quad (2)$$

Izvan ove oblasti težinski koeficijenti ostaju nepromjenjeni:

$$m_i(t+1) = m_i(t) \quad (2)$$

Funkcija pojačanja je linearna, sa najvišim vrednostima u pobedničkom neuronu i najnižim na granicama oblasti. Raspored neurona u SOM gradi diskretnu aproksimaciju raspodele uzoraka koji se koriste za učenje neuralne mreže [8]. Više neurona ukazuju na regije sa visokom koncentracijom uzoraka, a manje njih regije gde su uzorci razređeni. Slika 1. pokazuje uzorce podataka kao i čvorove SOM u krajnjem stanju u koordinantnom sistemu. Krajnje stanje mape zavisi od tri glavna uslova: inicijalnih vrednosti težinskih vektora u mreži, podataka koji se koriste za obučavanje i parametara (karakteristika) mape.

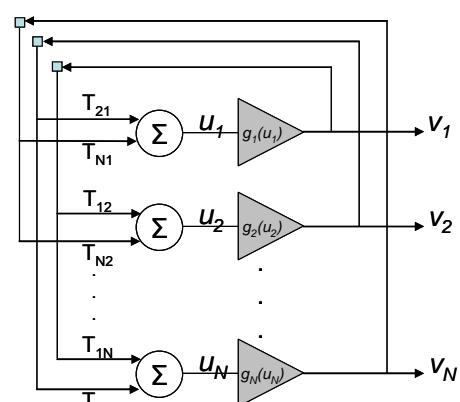
Konfiguracioni parametri mape kao što su broj čvorova mreže, funkcija pojačanja, stepen učenja i rastojanja čvorova predstavljaju glavne elemente koji određuju krajnji rezultat. Samo-organizujuća mapa predstavlja topološki organizator u smislu uređenja podataka, ali ne i samu proceduru za klasterizaciju **Error! Reference source not found.**. Konačni težinski vektori u mapi se koriste za klasterizaciju, što omogućava formiranje klastera sa određenim linkovima mreže.



Slika 1. Raspodela čvorova u okviru SOM na osnovu ulaznih podataka

3. HOPFIELD-OVA NEURALNA MREŽA

Hopfield-ova neuralna mreža pripada grupi rekurentnih veštačkih neuralnih mreža [11]. Ova mreža je našla veliki broj primena u radovima koji se bave optimizacionim problemima [12]. U radu [11], Hopfield i Tank su prezentovali jedno rešenje Hopfield-ove neuralne mreže namenjeno rešavanju problema trgovackog putnika. Ovaj NP complete problem spada u red referentnih problema za testiranje ponuđenih rešenja. Pokazavši dobre rezultate na ovom primeru, predloženi Hopfield Tank model poslužio je kao polazna tačka mnogim drugim radovima koji su u korenju imali potrebu za rešavanjem optimizacionih problema [12, 13]. U radu [13] Ali i Kamoun predlažu rešenje koje ima za cilj traženje optimalne putanje između dve tačke. U mreži proizvoljne topologije, opisane čvorovima i linkovima između njih, svakom linku je dodeljena cena. Ova cena može biti dužina ili bilo koji drugi parametar u skladu sa problemom kojii se rešava.



Slika 2. Struktura Hopfield-ove neuralne mreže

Predloženo rešenje je dizajnirano po modelu klasičnih rekurentnih mreža [11]. Svaki od $i=1,2,\dots,N$ neurona, Slika 3, realizovan je kao sumirajući naponski pojačavač sa sigmoidalno rastućom funkcijom prenosa (aktivacionom funkcijom) [11, 13]

$$V_i = g_i(U_i) = \frac{1}{1 + e^{-a_i \cdot U_i}}. \quad (4)$$

Veličina V_i je izlaz i -og neurona, U_i je ulaz koji je dat težinskom sumom izlaza ostalih neurona u mreži, dok konstanta a_i određuje nagib karakteristike. Izlazne vrednosti su skalirane na opseg od 0 do 1.

U Hopfield-ovoj realizaciji [11] to znači da za stabilne mreže povratne konduktanse i -og i j -og neurona treba da su međusobno jednake, $T_{ij} = T_{ji}$, i nema povratne veze sa izlaza na ulaz istog neurona ($T_{ii}=0$), Slika 2. U tom slučaju, i ako su pojačanja pojačavača, a, dovoljno velika (npr., $a>100$), kada je prenosna funkcija, praktično, odskočnog oblika, stabilnost Hopfield-ove mreže u smislu Ljapunova se može elegantno dokazati na osnovu ponašanja energijske funkcije, E , koja opisuje stanje mreže:

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{\substack{j=1 \\ i \neq j}}^N T_{ij} v_j v_i - \sum_{i=1}^N I_i v_i. \quad (5)$$

Energijska funkcija E kojom se može naći optimalna putanja između tačaka s i d definisana je kao [13]:

$$\begin{aligned} E = & \frac{\mu_1}{2} \sum_{\substack{x=1 \\ x \neq i}}^n \sum_{\substack{i=1 \\ (x,i) \neq (d,s)}}^n C_{xi} V_{xi} + \frac{\mu_2}{2} \sum_{\substack{x=1 \\ x \neq i}}^n \sum_{\substack{i=1 \\ (x,i) \neq (d,s)}}^n \rho_{xi} V_{xi} + \\ & + \frac{\mu_3}{2} \sum_{x=1}^n \left\{ \sum_{\substack{i=1 \\ i \neq x}}^n V_{xi} - \sum_{\substack{i=1 \\ i \neq x}}^n V_{ix} \right\}^2 + \frac{\mu_4}{2} \sum_{\substack{x=1 \\ x \neq i}}^n V_{xi} (1 - V_{xi}) + \\ & + \frac{\mu_5}{2} (1 - V_{ds}) \end{aligned} \quad (6)$$

U relaciji (6) matrica \mathbf{C} predstavlja ulaznu matricu u kojoj element C_{ij} predstavlja cenu linka između ruteru i i j dok matrica ρ definiše povezanosti čvorova mreže kao:

$$\rho = \begin{cases} 1, & \text{ako link od čvora } x \text{ do čvora } i \text{ ne postoji} \\ 0, & \text{u ostalim slučajevima} \end{cases} \quad (7)$$

Najveći doprinos u radu Ali i Kamouna [13] je definisanje sinaptičkih konduktansi kao konstantnog izraza definisanog kao:

$$T_{xi,yj} = \mu_4 \delta_{xy} \delta_{ij} - \mu_3 (\delta_{xy} + \delta_{ij} - \delta_{jx} - \delta_{iy}) \quad (8)$$

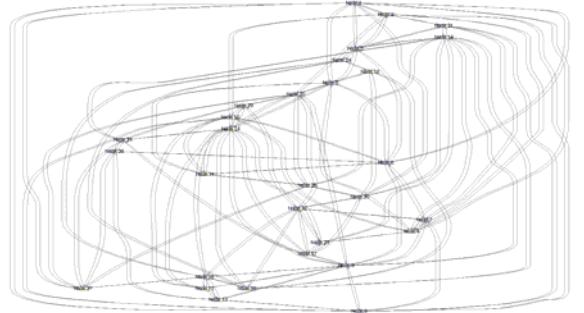
dok je cena linkova i informacije o konekcijama između ruteru u direktnoj vezi sa bias strujom kao:

$$\begin{aligned} I_{xi} = & -\frac{\mu_1}{2} C_{xi} (1 - \delta_{xd} \delta_{is}) - \frac{\mu_2}{2} \rho_{xi} (1 - \delta_{xd} \delta_{is}) \\ & - \frac{\mu_4}{2} + \frac{\mu_5}{2} \delta_{xd} \delta_{is} \\ = & \begin{cases} \frac{\mu_5}{2} - \frac{\mu_4}{2}, & \text{for } (X,i) = (d,s) \\ -\frac{\mu_1}{2} C_{xi} - \frac{\mu_2}{2} \rho_{xi} - \frac{\mu_4}{2}, & \text{otherwise} \end{cases} \end{aligned} \quad (9)$$

Na ovaj način se može kreirati neuralna mreža za rešavanje problema traženja najkratće putanje koja je pogodna za realizaciju u realnom vremenu.

4. REZULTATI

Za potrebe simulacije korišćena je mrežna topologija od 30 ruteru i 100 linkova. Raspodala linkova između ruteru je slučajno izabrana, slika 3.



Slika 3. Prikaz topologije korišćene mreže

Ruter 3 je izabran za izvorišni, dok je ruter 29 odredišni ruter za sve simulacije. Sav kod je napisan u programskom jeziku Matlab. Postupak simulacije se odvija u dve osnove faze:

1. Klasterizacija postojećih linkova
2. Izvor optimalne putanje primenom Hopfield-ove neuralne mreže

Klasterizacija linkova je urađena primenom Kohonenove neuralne mreže na način opisan u 2. poglavljju. Kao ulazi su korišćene četiri matrice Bandwidth (**B**), Load (**L**), Delay (**D**) i odnos Signal/Šum (**S**). Sa aspekta realnog saobraćaja, najbitnije je posmatrati preostali resur na linku, pa su inicijalno prva dva parametra posmatrani u formi **B-L**. Na ovaj način, link koji ima veću vrednost je poželjniji u konačnoj putanju. Kako Hopfield neuralna mreža traži putanju sa minimalnom cenom, ovaj parametar za link l_{ij} između ruteru $i-j$ se posmatra u obliku 1 - ($B_{ij}-L_{ij}$), uz pretpostavku da su vrednosti svih ulaznih matrica inicijalno skalirane u interval [0-1]. Parametar **D**, kojim se opisuje pojedinačno kašnjenje na linkovima, je posmatran u obliku $D_{max}-D_{ij}$. Na ovaj način se kašnjenje posmatra kao relativan parametar na nivou cele mreže. Manja vrednost ovog parametra definiše bolje uslove na linku i treba da bude „stimulisan“ da se nađe u konačnoj putanji. Na sličan način, odnos Signal/Šum se posmatrana u obliku 1 - (S_{ij}), s obzirom da je sa aspekta mreže bolje da link ima veći nivo odnosa Signal/Šum, dok se na ovaj način on prilagođava logici rada Hopfield-ove neuralne mreže.

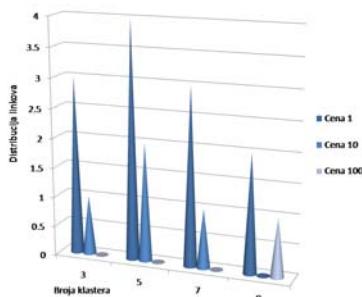
U radu je posmatran efekat klasterizacije kroz više različitih kombinacija. Na taj način, mreža je deljena u 3, 5, 7 i 9 klastera. Svaki od linkova je nakon primene Kohonenove neuralne mreže pripao nekom od tih klastera. Kako su klasteri dobijeni na bazi četiri ulazna parametra, rangiranje dobijenih klastera je izvršeno prema najbitnijem od njih, tj. 1 - ($B_{ij}-L_{ij}$). Na ovaj način linkovi u klasterima su dobili nove vrednosti, koje smo nazvali Cena. Numeričke vrednosti su dodeljene po osnovu kriterijuma da najbolji klaster ima cenu 10^0 , sledeći 10^1 , dok poslednji u nizu rangiranja ima cenu 10^{n-1} , gde je n broj klastera u mrežnoj topologiji. Na taj način se link koji je opisan sa četiri parametra, menja jednim, koji nije u linearnoj vezi sa njima, pa je moguće vršiti direktni uticaj na stimulaciju ili zabranu korišćenja pojedinih grupa linkova.

Druga faza podrazumeva automatsko generisanje potrebnih parametara za primenu Hopfield-ove neuralne mreže, a za cilj je traženje najkratće optimalne putanje. Ovo podrazumeva promenu parametara svakom linku u skladu sa novodobijenom cenom, i prilagođavanje topologije mreže eventualnim restriktivnim uslovima (administrativom odbacivanje pojedinih ruteru ili linkova za koje se odluči da ne treba da učestvuju u izboru putanje).

Cilj ovih simulacija je da se proveri logika opisanog algoritma i efikasnost njegovog rada. U tom ciju je posmatran scenario koji obuhvata testiranje algoritma kroz više realnih mrežnih okolnosti:

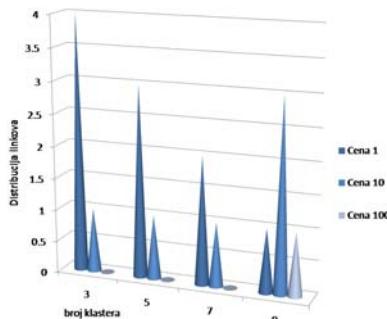
1. Sukcesivnu ukidanje linkova koji se nalaze u izabranim putanjama (čime se simulira pad ili nedostupnost pojedinih linkova). Na ovaj način se testirala adaptivnost algoritma na novonastala premene kao i brzina detekcije istih.
2. Sukcesivno ukidanje rutera koji se nalaze u izabranim putanjama (na ovaj način se analizira ključni aspekt bežične ad hoc mreže gde je svaki ruter u stvari bežični korisnik, koji svakog trenutka može da prekine svoj rad u mreži).
3. Dinamičke promene ulaznim parametara
4. Promena topologije mreže i
5. Promene cena linkova kao posledice promene broja klastera u mreži.

Efekat algoritma treba da bude takav da u konačnoj putanji „stimuliše“ pojavljivanje linkova koji pripadaju klasterima koji su rangirani kao najbolji. Provera ove karakteristike predloženog modela je prikazana na slikama 4, 5 i 6. Za svaku mrežnu topologiju i vrednosti ulaznih parametara, posmatran je efekat klasterizacije kroz broj klastera i distribuciju linkova iz pojedinih klastera u konačnoj putanji. Ono što se očekuje je da linkovi koji pripadaju najboljim klasterima, i koji imaju najmanju cenu, budu što više zastupljeni u konačnoj putanji. Na slici 4 je prikazana zastupljenost linkova iz pojedinih klastera u svakoj od mreža sa 3, 5, 7 i 9 klastera. Vidi se da je najzastupljenija grupa linkova sa cenom 1, koja pripada najboljem klasteru. Međutim, u mreži sa 9 klastera pojavljuje se i jedan link sa cenom 100.



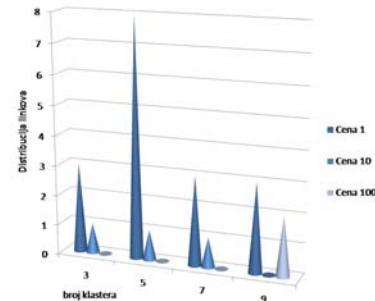
Slika 4. Zastupljenost linkova klastera unutar putanje

Na isti način posmatrana je i adaptivnost algoritma na promenu dostupnosti linkova. U konkretnom slučaju, link 2-10, koji je sastavni deo putanja, je proglašen nedostupnim. U tom slučaju je rezultat rada algoritma prikazan na slici 5.



Slika 5. Zastupljenost linkova klastera unutar putanje pri ukidanju linka 2-10

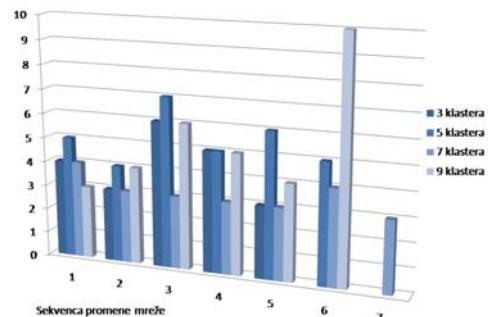
I u ovoj situaciji, primećuje se da je verovatnoća pojave linkova sa najmanjom cenom najveća, sem u slučaju sa 9 klastera, kada prednjači broj linkova sa cenom 10, dok su linkovi sa cenom 100 i 1 ravnomerne raspodeljeni. Simulacijom pada rutera (u ovom slučaju ruter 6, jer se nalazi u svakoj od putanja) algoritam daje rezultate kao na slici 6. Primećuje se da mreža sa 5 kalstera ima izuzetno povoljne rezultate. Ostale klasterizacije su relativno dobro odreagovale na ovu promenu u mreži.



Slika 6. Zastupljenost linkova klastera unutar putanje pri ukidanju rutera 6

Pripadnost linkova iz pojedinih klastera konačnoj putanji, ne mora uvek biti dobar pokazatelj kvaliteta rutiranja. U tom smislu, potrebno je dodatno posmatrati ukupan broj hop-ova između dva rutera (3 i 29). S obzirom da Hopfield-ova neuralna mreža koristi kriterijum najmanje cene, konačna putanja je opisana ukupnom cenom, pa je i ovaj parametar vrlo bitan u smislu kvaliteta rutiranja. Ova posmatranja su urađena za ista tri prethodna scenarija: inicijalnu mrežnu topologiju, toplogiju nakon ukidanja linka 2-10 koji se nalazi u prvobitnoj putanji i ukidanjem rutera 6, koji je takođe sastavni deo putanje. U sva tri slučaja ukupna putanja je najveća u strukturi sa 9 klastera, dok je u slučaju 5 klastera najpovoljnija. Sa druge strane, broj hopova je skoro uvek sličan i ne pokazuje veliko odstupanje od srednje vrednosti.

Ako se isti parametri posmatraju u vremenu, i u zavisnosti od promena koje se sekvencialno dešavaju u mreži, dobija se rezultat na slici 7.



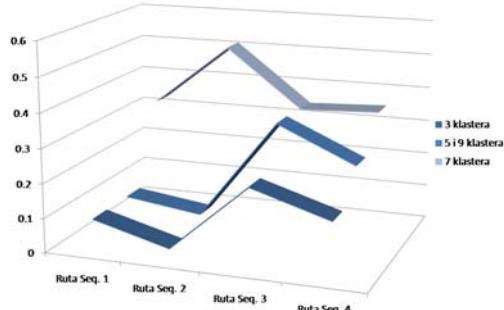
Slika 7. Broj hopova u odnosu na sekvencu promena u mreži

Naime, kroz nekoliko uzastopnih sekvenci je vršeno ukidanje linka ili rutera koji se nalazi u izabranoj putanji i praćen broj hopova algoritma za svaku novonastalu situaciju i izabranu putanju. Ovo merenje je vršeno za svaku mrežnu podelu po klasterima. Pokazuje se da je najbolji rezultat u slučaju 7 klastera, jer je dugoročno uvek među putanjama sa najmanjim brojem hopova, ali i bez velikih turbulencija u svakoj od promena u mreži. Ako se na isti način posmatra i ukupna cena konačne putanje, primetno je da je kvalitet putanje skoro direktno srazmeran broju klastera, stim što je

bolja putanja povezana sa manjim brojem klastera. Međutim, uzimajući u obzir i cenu i stabilnost rešenja (sa aspekta ukupne cene) može se izvojiti topologija sa 5 klastera kao najbolja.

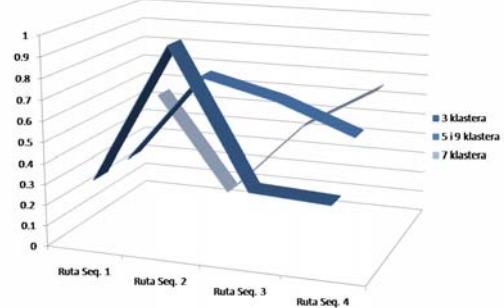
Sve do sada prikazani rezultati su pokazali efekat rada algoritma u slučaju korišćenja novoformiranog parametra Cena. S obzirom da ovaj parametar nema direktnе linearne zavisnosti sa ulaznim parametrima, neophodno je proveriti kvalitet dobijenih rešenja u odnosu na realne ulazne vrednosti. Da bi se to realizovalo urađena je sledeća analiza: za svaki od posmatranih scenarija, beležena je konačna putanja (redosled rutera u putanji) koji je baziran na matrici Cena. Za ove putanje su retroaktivno posmatrani ulazni parametri i njihove vrednosti na odgovarajućim linkovima.

Na taj način, za svaku topologiju, dobijeni su dijagrami koji pokazuju kvalitet putanje u odnosu na konkretni ulazni parametar. Na slici 8, prikazan je kavalitet dobijenih rešenja u odnosu na raspoloživi propusni opseg. Primećuje se da su rešenja za 3, 5 i 9 klastera u najvećoj meri koristilo linkove na kojima postoji najveći procenat slobodnog propusnog opsega.



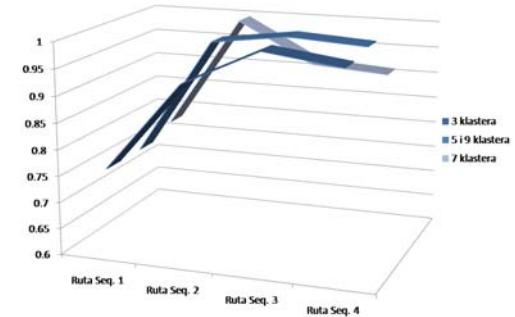
Slika 8. Raspoloživ propusnih opseg izabralih linkova u odnosu na sekvencu promena u mreži

Na slici 9, prikazan je kavalitet dobijenih rešenja u odnosu na vreme kašnjenja. Kriva koja opisuje mrežu sa 7 klastera ima najbolje rezultate, mada su sve krive gledano na ukupnoj putanji izabrale linkove takve da ukupno kašnjenje po celoj putanji bude relativno slično.



Slika 9. Kašnjenje izabralih linkova u odnosu na sekvencu promena u mreži

Na slici 10, prikazan je kavalitet dobijenih rešenja u odnosu na odnos Signal/Šum pojedinačnih linkova. Vidi se da je za svaki broj klastera izabrano rešenje takvo da teži linkovima sa što većim odnosom Signal/Šum, bez obzira na scenario koji je testiran.



Slika 10. Odnos Signal/Šum izabranih linkova u odnosu na sekvencu promena u mreži

Iako nije vršena multikriterijumska optimizacija, pokazano je da više parametara može biti podjednako kvalitetno zadovoljeno i u slučaju primene Hopfield-ove neuralne mreže na samo jedan novoformirani parametar Cena.

5. ZAKLJUČAK

U radu je predstavljeno jedno rešenje algoritma za rutiranje u bežičnim mrežama. Predloženo rešenje je bazirano na inicijalnoj klasterizaciji mrežne topologije, i kategorizaciji linkova srazmerno rangiranju dobijenih klastera. Na ovaj način klasterizacija se vrši na osnovu više (u ovom slučaju 4 ulazna parametra po linku) a konačna odluka donosi na bazi jednog (parametra Cena) primenom Hopfield-ove neuralne mreže. Prikazano rešenje je adaptivno i namenjeno radu sa dinamičkim parametrima, što odgovara realnim uslovima rada.

Dalja istraživanje biće usmerena na primeni Hopfield-ove neuralne mreže u izboru optimalne putanje na osnovu više kriterijuma.

LITERATURA

- [1] E. Perahia, R. Stacey, *Next Generation Wireless LANs: Throughput, Robustness, and Reliability in 802.11n*, Cambridge University Press, 2008.
- [2] B. Bing, *Emerging Technologies in Wireless LANs: Theory, Design, and Deployment*, Cambridge University Press, 2007.
- [3] M. Gast, *802.11 Wireless Networks: The Definitive Guide*, O'Reilly Media; Second Edition edition, 2005.
- [4] P. Mohapatra, S. Krishnamurthy, *Ad Hoc Networks: Technologies and Protocols*, Springer, 2004.
- [5] C. S. R. Murthy, B.S. Manoj, *Ad Hoc Wireless Networks: Architectures and Protocols*, Prentice Hall, 2004.
- [6] C. E. Perkins, *Ad Hoc Networking*, Addison-Wesley Professional, 2008
- [7] D. B. Johnson, D. A. Maltz, "Dynamic Source Routing in Ad Hoc Wireless Networks", *Mobile Computing*, sec. 5, pp. 153–181. Kluwer Academic Publishers, 1996.
- [8] T. Kohonen, *Self-Organization and Associative Memory*, New York, Springer-Verlag, 1988.
- [9] T. Kohonen, *Self-Organizing Maps*, New York, Springer-Verlag, 1997.
- [10] N.R. Pal, J. C. Bezdec, E. C-K. Tsao, "Generalized clustering networks and Kohonen's self-organizing scheme", *IEEE Trans. Neural Networks*, vol. 4, no. 4, pp. 549–557, 1993.
- [11] J. J. Hopfield, D. W. Tank, "‘Neural’ computations of decision in optimization problems", *Biol. Cybern.*, Vol. 52, pp. 141-152, 1985.
- [12] N. Kojić, I. Reljin, B. Reljin, "Neural network for optimization of routing in communication networks", *FACTA Universitatis, Series: Electronics and Energetics*, Vol. 19, No. 2, pp. 317-329, August 2006.
- [13] M. Ali, F. Kamoun, "Neural networks for shortest path computation and routing in computer networks", *IEEE Trans. on Neural Networks*, Vol. 4, No. 6, pp. 941-953, 1993.