

DINAMIČKO PROGNOZIRANJE MREŽNIH SERVISIA

Valentina Radojičić, Slobodan Mitrović
Univerzitet u Beogradu - Saobraćajni fakultet
valentin@sf.bg.ac.rs; s.mitrovic@sf.bg.ac.rs

Rezime: *U cilju dobijanja pouzdane prognoze internet saobraćaja u slučaju pojedinih mrežnih servisa, ovaj rad predlaže novi pristup prognoziranju na osnovu rekonstrukcije vremenskih serija baziran na tehnici tzv. rekonstrukcije faznog prostora za mapiranje statističkih multivarijantnih podataka. Ovaj pristup, pored primene tehnika kratkoročnog i dugoročnog prognoziranja, uključuje i neuronsku mrežu sa radijalnom funkcijom (RBF) poboljšanu algoritmom Levenberg-Markuardt (LM) za dinamičko ažuriranje težina neuronske mreže. Na ovaj način, unapređena je preciznost prognoze a ostvaruje se dinamičko predviđanje saobraćaja u više koraka. Niz eksperimenata je izvedeno na bazi samostalno prikupljenih skupova podataka. Eksperimentalni rezultati pokazuju da je pristup opisan u ovom radu, u pogledu preciznosti, bolji od prethodnih pristupa i pogodniji za prognoziranje u više koraka..*

Gljučne reči: *dinamičko prognoziranje, rekonstrukcija vremenske serije, neuronske mreže*

1. Uvod

Sa sve bržim razvojem mrežne tehnologije na kojoj su bazirani širokopoljanski internet servisi, zahtevi za povećanjem mrežnog opsega rastu, ujedno sa rastom stanovništva u urbanim sredinama. Ovi faktori takođe utiču na povećanje složenosti topologije mreže, što rezultuje i povećanjem učestalosti problema vezanim kako za mrežne performanse, tako i za kvalitet mrežnih servisa. Da bi se zadovoljile potrebe korisnika za kvalitetnim mrežnim servisima, provajderi moraju voditi računa o optimalnom iskorišćenju mrežnih resursa, što zahteva blagovremenu analizu operativnog stanja mreže uz upotrebu alata za nadzor i upravljanje mrežnim komponentama. Da bi se planirale adekvatne mere unapređenja, neophodno je izvršiti prognoziranje vrednosti različitih veličina čime se može dobiti projekcija mogućih stanja mreže. Ovo je posebno bitno u slučajevima kada su na raspolaganju ograničeni mrežni resursi, gde se kroz uspostavljanje modela prognoziranja mrežnog saobraćaja obezbeđuje proaktivan pristup rešavanju različitih problema, koji su ključni za poboljšanje mrežnih performansi i kvaliteta mrežnih servisa.

Imajući u vidu da kompleksnost mreže može uticati na tačnost podataka dobijenih monitoringom mreže, u radu će biti primenjen pristup u rešavanju problema

rekonstrukcije vremenske serije baziran na tehnici tzv. rekonstrukcije faznog prostora za mapiranje statističkih multivarijantnih podataka.

Kada se posmatra intenzitet mrežnog saobraćaja u vremenskim intervalima različitih dužina, lako se dolazi do zaključka da se ovakve vremenske serije mogu modelovati na različite načine, počevši od primene tradicionalnih modela, pa do popularnih modela kao što su *AutoRegressive Moving Average* (ARMA), *AutoRegressive Integrated Moving Average* (ARIMA), *AutoRegressive Conditional Heteroskedasticity* (ARCH), i sl. Osim navedenih sve češće su u upotrebi i alternativni pristupi koji se zasnivaju na primeni alata koji su vezani za mašinsko učenje, primenu neuronskih mreža, fuzzy-logiku i sl.


U ovom radu analizira se proces prognoziranja mrežnog saobraćaja koji je vezan za primenu neuronskih mreža, budući da su istraživanja pokazala da neuronska mreža, koja ima nelinearnu strukturu, može približiti bilo koju nelinearnu funkciju [1]. Imajući u vidu efikasnost učenja, kao i raznovrsne mogućnosti mapiranja, neuronske mreže su u stanju da formiraju nelinearne modele na osnovu podataka koji fluktuiraju između ulaznih i izlaznih tačaka, zbog čega je lako uočena njihova primena u prognoziranju mrežnog saobraćaja [1].

U fokusu istraživanja je neuronska mreža sa radijalnom funkcijom (*Radial Basis Function* - RBF), koja je jedna od najčešće korišćenih i najuspešnijih neuronskih mreža zahvaljujući karakteristikama, kao što su ulazna i izlazna težina neuronske mreže, skriveni centar i širina jedinice [1]. Razmatrajući problematiku prognoziranja mrežnog saobraćaja, RBF neuronske mreže su pogodne za navedeni oblik primene, zahvaljujući i funkcionalnim karakteristikama, kao što su jednostavnost strukture, adaptabilnost problemima, optimalna sposobnost globalne aproksimacije i sposobnost generalizacije [1]. Tradicionalne metode optimizacije parametara RBF neuronske mreže koriste algoritam gradijentnog spuštanja, koji ima malu brzinu pretraživanja, veliku količinu računanja, veliku potrošnju memorije, kao i određena ograničenja vezana za pretragu globalnog minimuma, zbog čega dobijeni parametri ne moraju biti nužno optimalni [1]. Da bi se izbegla navedena ograničenja [2], u radu je primenjen *Levenberg-Markuardt* (LM) algoritam za dinamičko ažuriranje težine neuronske mreže.

2. Rekonstrukcija vremenske serije

Promena mrežnog hardvera često podrazumeva i delimičnu izmenu pravila vezanih za prikupljanje podataka dobijenih procesom monitoringa posmatranih mrežnih tačaka, i/ili značajnih delova mreže. Imajući u vidu činjenicu da računarske mreže, tokom dužeg perioda eksploatacije uključuju događaje, koji se odnose na otkaz mrežnih komponenti, kao i na nadgradnju aktivne infrastrukture, retki su događaji kada zamena uređaja ne utiče na izmenu karakteristika vremenske serije. Na slici 1, prikazana je vremenska serija dobijena na istoj mernoj tački, gde je monitoring intenziteta saobraćaja obuhvatio prikupljene podatke na 3 generacije mrežne opreme. U slučajevima poput navedenog, prognoziranje intenziteta saobraćaja nije primenljivo ukoliko je potrebno izvršiti prognoziranje na osnovu vremenskih serija koje obuhvataju period u kome je izvršena promena opreme. U ovakvim slučajevima, jedno od mogućih rešenja uključuje proces rekonstrukcije vremenske serije, baziranu na tehnikama rekonstrukcije višedimenzionalnog faznog prostora, pri čemu se za izvor podataka uzimaju rezultati monitoringa topološki susednih mrežnih uređaja, kao i onih mrežnih uređaja, koji

topološki nisu susjedni, ali mogu povećati rezoluciju podataka rezultujuće vremenske serije.



Slika 1. Vremenska serija dobijena procesom monitoringa tri generacije mrežne opreme

Rekonstrukcija višedimenzionalnog faznog prostora podrazumeva konstrukciju strukture faznog prostora originalnog sistema sa smerom „unazad“, kroz jednodimenzionalne vremenske serije. Rekonstrukcija faznog prostora bazirana je na Takensovoj teoriji [2, 3], prema kojoj je razvoj slučajnih promenljivih u sistemu određen interakcijom sa drugim promenljivama, a informacije o relevantnoj promenljivoj implicitne su razvoju bilo koje druge promenljive [2]. Imajući navedeno u vidu, Packard i Takens [3,4] su predložili metodu koordinatne rekonstrukcije sa vremenskim odlaganjem (kašnjenjem), koja koristi sekvencu vremenskog odlaganja za rekonstrukciju faznog prostora [2-4]. Suštinski, koordinatna rekonstrukcija sa vremenskim odlaganjem se zasniva na odloženom uvođenju haotičnih vremenskih serija x_1, x_2, \dots, x_n u proces konstrukcije vektora m -dimenzionalnog faznog prostora, koji se može prikazati na sledeći način [2]:

$$X_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau})^T \quad (i = 1, 2, \dots, M), \quad (1)$$

gde su: $M = n - (m - 1)\tau$ broj rekonstruisanih faznih prostora, τ je vremensko odlaganje, a m je dimenzija prostornog uklapanja, odnosno dimenzija rekonstruisanog faznog prostora. Parametri m i τ se smatraju ključnim u tehnici rekonstrukcije faznog prostora [2]. Na osnovu navedenog, signalima predikcije x_1, x_2, \dots, x_n , koji imaju n tačaka podataka, može se rekonstruisati $M = n - (m - 1)\tau$ tačaka stanja u m -dimenzionalnom faznom prostoru, a njihova veza formira lokus od n tačaka m -dimenzionalnog faznog prostora, kojim se karakteriše evolucija sistema, posmatrano kroz njegov status tokom vremena [1]. Takensovom teorijom je dokazano da ako je dimenzija prostornog uklapanja $m > 2d + 1$, pri čemu je d dinamička dimenzija sistema (tj. prostora), onda su dinamička ponašanja u faznom prostoru (koja su konstruisana sa vrednostima promenljivih kod prvobitnog stanja sistema) jednaka dinamičkim ponašanjima u faznom prostoru (konstruisanom sa vrednostima jednodimenzionalnih promenljivih), pri čemu su atraktori haotičnosti (u dva posmatrana prostora) difeomorfični (tj. mogu se predstaviti

diferencijalnom funkcijom za koju postoji inverzna funkcija, a koja je takođe diferencijalna) [1,3]. Na ovaj način, Takensova teorija osigurava rekonstrukciju topološki ekvivalentnog faznog prostora originalnog sistema, upotrebom jednodimenzionalnih vremenskih nizova i pruža teorijsku osnovu za predviđanje haotičnih vremenskih serija [2].

Vremensko odlaganje τ može se izračunati primenom dve popularne grupe metoda: metodama korelacije sekvence i metodama geometrije faznog prostora. Primer grupe metoda korelacije sekvenci je *metoda autokorelacije*, koja predstavlja jednostavan način za izračunavanje vremenskog odlaganja, ali sa njom se može izvršiti samo ekstrakcija linearne korelacije između vremenskih serija. Među metodama geometrije rekonstrukcije faznog prostora, nalazi se i *metoda prosečnog pomeranja*, koja može uspostaviti vezu sa kriterijumima korelacije, ali ova metoda može imati snažno variranje rezultata i prilikom promene trenda (odnosno, prisutna je slučajnost) [2]. Imajući navedeno u vidu, u radovima se često koristi *metoda višestruke korelacije*, koja kombinuje metodu autokorelacije i metodu prosečnog pomeranja [5]. Metoda višestruke korelacije ima manju složenost proračuna i veliku otpornost na prisustvo „šuma“ u podacima, a postupak proračuna se vrši na sledeći način [2]: neka je prosečno pomeranje vremenskih serija $\{x(n)\}$ u rekonstrukciji m -dimenzionalnog faznog prostora, označeno je sa $\langle S_m^2(\tau) \rangle$ sledećim izrazom:

$$\langle S_m^2(\tau) \rangle = \frac{1}{N} \sum_{i=0}^{N-1} \sum_{j=1}^{m-1} (x_{i+j\tau} - x_i)^2, \quad (2)$$

gde je N - broj tačaka sekvence posmatranja (zanemarujući razliku u graničnim tačkama). Ukoliko se sa E označi izraz:

$$E = \frac{1}{N} \sum_{i=0}^{N-1} x_{i+j\tau}^2, \quad (3)$$

i ako se formula (3) u intervalu $[0, m-1]$ označi kao konstanta; odnosno ako je:

$$E = \frac{1}{N} \sum_{i=0}^{N-1} x_i^2, \quad (4)$$

i potom inkorporira u formulu (2), dobija se sledeći izraz:

$$\langle S_m^2(\tau) \rangle = 2(m-1)E - 2 \sum_{j=1}^{m-1} R_{xx}(j\tau) \quad (5)$$

gde $R_{xx}(j\tau)$ predstavlja autokorelacionu funkciju sekvence u vremenskom rasponu $j\tau$, odnosno:

$$R_{xx}(j\tau) = \frac{1}{N} \sum_{i=0}^{N-1} x_i x_{i+j\tau}, \quad (6)$$

$$R_{xx}^m(\tau) = \sum_{j=0}^{m-1} R_{xx}(j\tau), \quad (7)$$

gde se prva nulta vrednost formule (8) usvaja kao vremensko $j\tau$ [1].

Izračunavanje dimenzije prostornog uklapanja zasniva se na Takensovoj teoremi, koja se može opisati na sledeći način [1]: „za idealne jednodimenzionalne

vremenske serije beskonačne dužine i bez šuma, dimenzije prostornog uklapanja m i vremensko odlaganje τ mogle bi imati bilo koju vrednost, ipak, treba imati u vidu da su vremenske serije - nizovi konačne dužine, koji sadrže šum, dimenziju prostornog uklapanja i vremensko odlaganje ne može imati bilo kakvu vrednost, jer bi se time uticalo na kvalitet rekonstrukcije faznog prostora“. Određivanje dimenzije prostornog uklapanja radi se sa ciljem da se originalni i rekonstruisani atraktori učine topološki ekvivalentnim. Shodno navedenom, u [1] je upotrebljena tzv. Cao metoda za izračunavanje dimenzije prostornog uklapanja m [6], u slučaju vremenske serije $\{x(n)\}$:

$$a(i, d) = \frac{\|x_{d+1}(i) - x_{d+1}^{NN}(i)\|}{\|x_d(i) - x_d^{NN}(i)\|}, \quad (8)$$

gde $x_d(i)$ predstavlja i -ti vektor, dok je $x_d^{NN}(i)$ njegova najbliža tačka u d -dimenzionalnom prostoru. Na isti način, $x_{d+1}(i)$ predstavlja i -ti vektor, dok je $x_{d+1}^{NN}(i)$ njegova najbliža tačka u $(d+1)$ -dimenzionalnom prostoru. Izračunata vrednost $a(i, d)$ se nadalje koristi u formulama (9) i (10) [1]:

$$E(m) = \frac{1}{N - m\tau} \sum_{i=1}^{N-m\tau} a(i, m), \quad (9)$$

$$E_1(m) = \frac{E(m+1)}{E(m)}. \quad (10)$$

Ako se utvrdi vremenska serija, tada će varijabla $E_1(m)$ ostati nepromenjena nakon dostizanja određene vrednosti sa porastom m , čime je dimenzija prostornog uklapanja m konačno određena [1].

3. Neuronska mreža sa radijalnom funkcijom RBF

Neuronska mreža sa radijalnom funkcijom (*Radial Basis Function* – RBF), predstavlja poseban tip neuronske mreže koja koristi funkciju radijalne osnove (baze) kao svoju aktivacionu funkciju [7]. Prema načinu propagacije signala unutar mreže, RBF neuronska mreža spada u grupu mreža sa propagacijom unapred (*feedforward*). RBF mreža ima tri sloja: ulazni, skriveni i izlazni sloj (slika 2). Aktivaciona funkcija u slučaju RBF mreže je vezana za jedinice skrivenog sloja. Na taj način se ulazne promenljive mapiraju direktno u prostor skrivenog sloja, tako da se po utvrđivanju centra radijalnih baznih funkcija, odmah određuje i odnos mapiranja između ulaznog i skrivenog sloja. Funkcija radijalne osnove $\varphi_j(x)$ služi za mapiranje centara j , grupisanih u skrivenom sloju na sledeći način [2]:

$$\varphi_j(x) = \exp\left(\frac{-\|x - c_j\|^2}{2\sigma_j^2}\right), \quad j = 1, 2, \dots, m, \quad (11)$$

gde je x – ulazni podatak, c_j je j -ti centar, dok je σ_j njegova širina. Na osnovu navedenog, funkcija izlaznog sloja na jednom izlaznom čvoru i , može se prikazati sledećom formulom

$$y_i = F_i(x) = \sum_{m=1}^N w_m \varphi_m(x), \quad i = 1, \dots, t+k \quad (12)$$


gde je $m=(1, \dots, N)$ broj centara u skrivenom sloju, a w_m težina m -te veze ka izlaznom sloju.

Određivanje optimalnog broja centara, kao i njihovih položaja u skrivenom sloju ima veliku važnost, jer se time utiče na stepen složenosti mreže, kao i sposobnost da se na efikasan način dođe do kvalitetnih rezultata. Ako je broj centara u skrivenom sloju nedovoljan, mreža ne može da bude efikasno istrenirana na osnovu ulaznih podataka (*underfitting*). U suprotnom, prevelik broj centara dovodi do pojave efekta prevelike istreniranosti (*overfitting*).

4. Levenberg-Markuardt pristup optimizaciji težina neuronske mreže

Kao što je već navedeno, metode optimizacije parametara RBF neuronske mreže koriste metode poput algoritma gradijentnog spuštanja, koji imaju određena ograničenja, zbog čega ponekad imaju sklonost ka pronalaženju lokalnih minimuma. To ima za rezultat da dobijeni parametri mreže ne moraju biti nužno optimalni. Jedan od pristupa koji mogu predstavljati rešenje za navedeni problem je tzv. *Levenberg-Markuardt* (LM) pristup optimizaciji težina neuronske mreže (slika 2).

Ovaj pristup predstavlja kompromis između Newton metode i metode gradijentnog spuštanja [2]. Pristup koristi približni izvod drugog reda za rešavanje optimalne vrednosti funkcije drugog reda $f(W)$, gde $W = [w_1, w_2, \dots, w_L]$ predstavlja vektor težina između između skrivenog i izlaznog sloja (L je ukupan broj težina). Ovaj pristup se zasniva na sledećim principima: ako sa g označimo vektor izvoda funkcije, a sa H - odgovarajuću Hessian matricu, onda se optimalno podešavanje vektora težina W može realizovati primenom izraza $\Delta W = (H + \lambda I)^{-1}g$, gde je I jedinična matrica ista kao H , a λ - regularni koeficijent koji garantuje pozitivni definitiv $H + \lambda I$ [2].

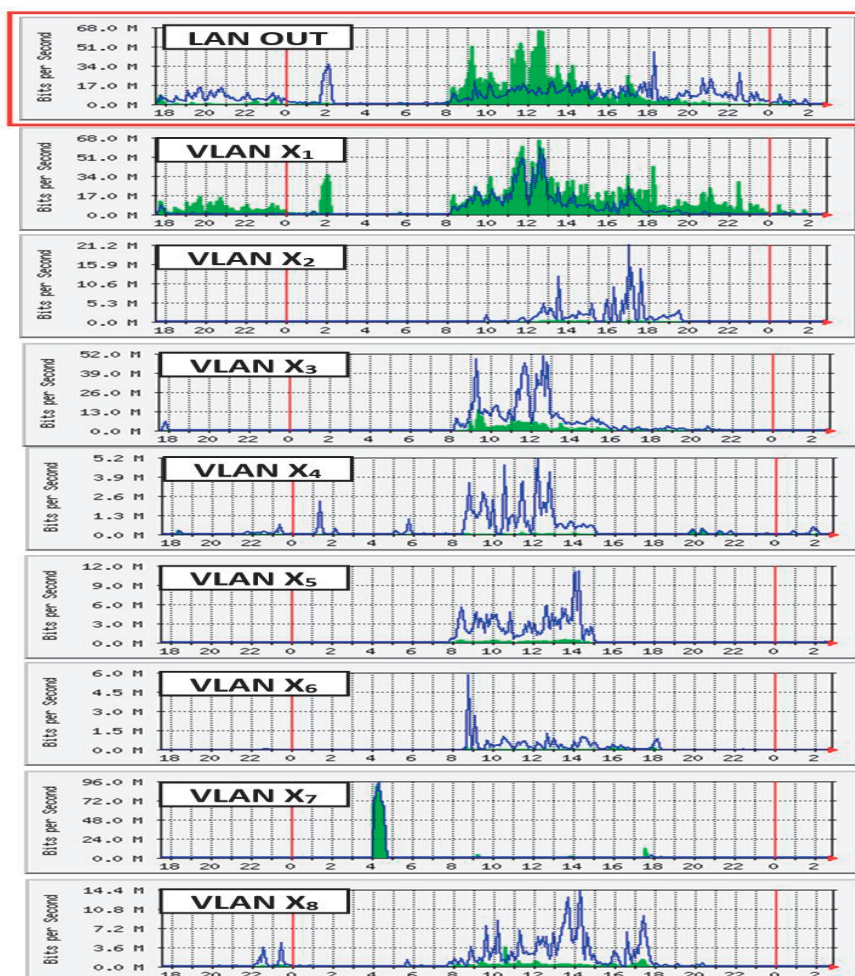


Slika 2. RBF neuronska mreža

Primenom navedenog pristupa u toku faze treniranja, dobija se brzina optimizacije neuronske mreže koja je veća u odnosu na brzinu dobijenu primenom metode gradijentnog spuštanja.

5. Numerički primer

Za potrebe ovog eksperimenta upotrebljeni su podaci, dobijeni kao rezultat monitoringa mrežnog saobraćaja lokalne računarske mreže (LAN) Saobraćajnog fakulteta u Beogradu. Snimanje saobraćaja je izvršeno primenom monitoring platforme *The Multi Router Traffic Grapher* (MRTG) [10]. Opservacije saobraćaja realizovanog u okviru navedenih virtuelnih LAN mreža, vršene su za dnevni nivo na svakih 300 sec (5min), a podaci su snimljeni u odgovarajuće MRTG *log* datoteke. Podaci na dnevnom nivou su namerno odabrani, upravo zbog navedenog intervala za opservacije, jer je na tom nivou usled različitih operativno-tehničkih faktora najveća verovatnoća gubitka podataka. Tehnika rekonstrukcije faznog prostora primenjena je nad snimljenim podacima intenziteta saobraćaja realizovanog u okviru 8 virtuelnih LAN mreža, čiji su grafikoni prikazani na slici 3 (VLAN X₁ - VLAN X₈).

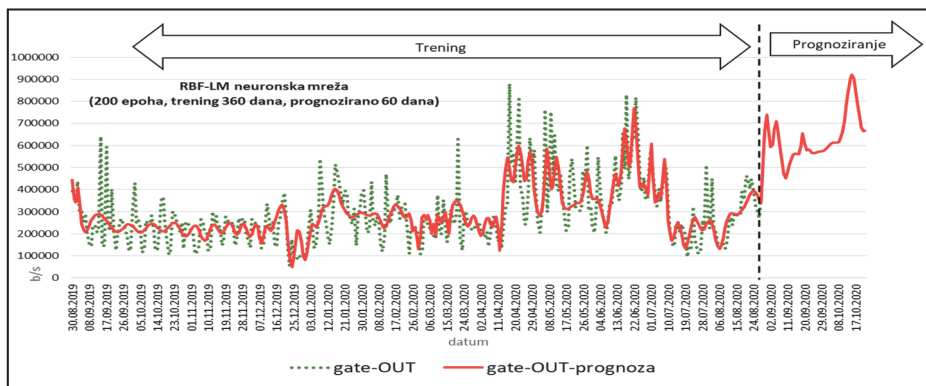


Slika 3. Prikaz rekonstrukcije faznog prostora

Treba napomenuti da saobraćaj koji je realizovan u okviru navedenih virtuelnih LAN mreža, uključuje kako saobraćaj koji je realizovan unutar LAN mreže Fakulteta, tako i saobraćaj čije se izvorište ili destinacija nalazi van lokalne mreže Fakulteta. Takođe, posmatrana mrežna infrastruktura sastoji se i od određenog broja virtuelnih mreža, čiji podaci nisu bili dostupni za potrebe istraživanja. Imajući u vidu da su postojali podaci po istim vremenskim preseccima, usvojeno je da nema vremenskog odlaganja ($\tau=0$), tako da se primenom formula (9) i (10) rekonstrukcija svela na trivijalan slučaj, jer je veličina E_I odmah postala konstanta. Rekonstruisani podaci su nadalje inkorporirani u vremensku seriju na kome su zabeležene opservacije za godišnji novi saobraćaja, skaliranjem podataka sa intervala od 300sec na 86400sec (24h) uz izračunavanje srednjih vrednosti i maksimuma, u skladu sa tehnikom generisanja MRTG datoteke [10]. Iz ove datoteke upotrebljena je vremenska serija od 726 opservacija u periodu od 04.09.2018. godine do 29.08.2020. godine. Period od 30.08.2019 do 29.09.2020. godine upotrebljen je za treniranje mreže, dok je period 30.08.- 23.10.2020 predviđen za potrebe prognoziranja. Ova vremenska serija je potom upotrebljena za deo eksperimenta koji se odnosi na dinamičko prognoziranje primenom RBF neuronske mreže, koja je nadgrađena *Levenberg-Markuardt* (LM) algoritmom za optimizaciju težina (nadalje RBF-LM mreža). Ova mreža je implementirana u programskom jeziku *Python* (v.3.9), u *PyCharm Community* IDE okruženju na PC hardverskoj platformi Intel(R) Core(TM) i5-3470 CPU@3.20GHz, 16GB RAM, Windows 10. Beleženje podataka se vršilo manipulacijom datoteka u lokalnom fajl okruženju. Posmatrana vremenska serija podeljena je u dva dela – deo za treniranje neuronske mreže i deo za prognoziranje. Treniranje je izvršeno upotrebom tehnike „kliznih prozora“ (*sliding windows*), sa *lookback* periodom od 60 dana, dok je period „pomeranja kliznih prozora“ definisan na 15 dana, na osnovu čega je izvršeno ukupno 24 „pomeranja“, kojima je uključeno poslednjih 360 opservacija, kao i dodatnih 60 opservacija u zoni kranjeg levog *lookback* perioda. Treniranje je ponovljeno sa unapred predefinisanim brojem epoha (100, 200, 400, 600, 800 i 1200). Nakon faze treniranja, RBF-LM mreža je ušla u fazu dinamičkog prognoziranja, koje je realizovano u 4 uzastopna perioda od po 15 dana, odnosno, za ukupno 60 dana. Dobijeni podaci prikazani su na slici 4. Za utvrđivanje pouzdanosti prognoze, upotrebljena su tri standardna testa: srednja kvadratna greška reziduala (*Mean Square Error*, MSE), srednja apsolutna greška reziduala (*Mean Absolute Error*, MAE), kao i srednja apsolutna procentna greška (*Mean Absolute Percentage Error*, MAPE). Ovi testovi su realizovani na dva nivoa: prvi se odnosi na periode od po 60 dana, koji odgovaraju pojedinačnim „pomeranjima prozora“, dok se drugi nivo odnosi na period od poslednjih 360 dana. Dobijeni podaci prikazani su u tabelama 1 i 2, pri čemu treba napomenuti da su u Tabeli 1 prikazani reprezentativni podaci, za jedno „pomeranje prozora“.

Kao i u prethodnim istraživanjima, izračunate su vrednosti MAPE testova, koji se ocenjuju na osnovu Lewis-ove skale za procenu tačnosti prognoziranih vrednosti [12].

Uvidom u navedenu skalu, pokazano je da se prognozirane vrednosti za period 01.07.2020. – 29.08.2020. (60 dana) mogu oceniti kao „dobre“, gde su navedeni rezultati dobijeni nakon realizacije 200 epoha rada RBF-LM neuronske mreže. U slučaju perioda 30.08.2019. do 29.08.2020. godine (360 dana), prognozirane vrednosti se mogu oceniti kao „razumne“, pri čemu su navedeni rezultati dobijeni nakon 600 epoha rada navedene mreže.



Slika 4. Grafički rezultati dinamičkog prognoziranja primenom RBF-LM neuronske mreže

Tabela 1. Rezultati testova pouzdanosti prognoze za period 01.07 – 29.08.2020. (60 dana)

Br. epoha	MAE	MSE	MAPE(%)
100	45416.17	3.34×10^9	19.23
200	38490.88	2.95×10^9	16.19
400	46427.81	4.41×10^9	19.74
600	43529.92	4.32×10^9	18.15
800	40699.08	2.64×10^9	16.47
1200	41132.09	3.89×10^9	17.37

Tabela 2. Rezultati testova pouzdanosti prognoze za period 30.08.2019 – 29.08.2020. (360 dana)

Br. epoha	MAE	MSE	MAPE(%)
100	73291.74	9.36×10^9	29.24
200	66988.46	8.49×10^9	26.87
400	68688.13	8.71×10^9	27.96
600	60459.54	7.65×10^9	24.05
800	61553.59	7.75×10^9	24.80
1200	63683.16	7.49×10^9	25.37

6. Zaključak

U ovom radu primenjen je pristup za dinamičko prognoziranje mrežnog saobraćaja, u slučaju kada je potrebno prethodno izvršiti rekonstrukciju vremenske serije. Imajući u vidu da se za rekonstrukciju koriste vremenske serije intenziteta saobraćaja realizovanog na topološki susjednim uređajima, predložena je tehnika rekonstrukcije faznog prostora, gde vrednost parametra vremenskog odlaganja može imati nultu vrednost. Nadalje, sprovedeno je dinamičko prognoziranje upotrebom RBF neuronske mreže, koja je nadgrađena *Levenberg-Markwardt* (LM) algoritmom za optimizaciju težina, imajući u vidu da je ova vrsta mreže poznata po mnogo bržoj stopi konvergencije u poređenju sa platformama na bazi mašinskog učenja (MLP). U slučaju izvedenog eksperimenta (RBF-LM mreža) dobijeni su zadovoljavajući rezultati prognoziranja sa malim brojem realizovanih epoha. Takođe, primećeno je da povećanje broja epoha dovodi do *overfitting* efekta, kao uzroka smanjene pouzdanosti prognoze.

Zahvalnica

Ovaj rad delimično je podržan od strane Ministarstva prosvete, nauke i tehnološkog razvoja Republike Srbije.

Literatura

- [1] D. Wei, „Network traffic prediction based on RBF neural network optimized by improved gravitation search algorithm“, *Neural Computing and Applications*, t. 28, p. 2303–2312, 2017.
- [2] P. Zhang, L. Wang, W. Li, H. Leung and W. Song, „A web service QoS forecasting approach based on multivariate time series“, *IEEE International Conference on Web Services (ICWS)*, 2017.
- [3] F. Takens, „Detecting strange attractors in turbulence“, *Dynamical systems and turbulence*, Warwick 1980, Springer, p. 366–381, 1981.
- [4] N. H. Packard, J. P. Crutchfield, J. D. Farmer and R. S. Shaw, „Geometry from a time series“, *Physical review letters*, t. 45, p. 712, 1980.
- [5] J. Wang, L. Sun, X. Fei and B. Zhu, „Chaos analysis of the electrical signal time series evoked by acupuncture“, *Chaos, Solitons & Fractals*, t. 33, p. 901–907, 2007.
- [6] M.-Y. Cheng, C.-H. Ko, „A genetic-fuzzy-neuro model encodes FNNs using SWRM and BRM“, *Engineering Applications of Artificial Intelligence*, t. 19, p. 891–903, 2006.
- [7] D. S. Broomhead, D. Lowe, „Multivariable functional interpolation and adaptive networks“, *Complex systems*, vol. 2, 1988.

Abstract: *In order to obtain a reliable forecast of Internet traffic in the case of partial timeseries data loss, this paper proposes an approach that includes techniques such as phase space reconstructions for mapping statistical multivariate data. This approach, in addition to the application of short-term and long-term forecasting techniques, includes a Radial Basis Function neural network (RBF) enhanced by the Levenberg-Marquardt (LM) algorithm for dynamic updating of the neural network weight. A series of experiments were performed on the basis of independently collected data sets. Experimental results show that the approach described in this paper, in terms of accuracy, is better than previous approaches and more suitable for multi-step forecasting.*

Keywords: *dynamic forecasting, time series reconstruction, neural networks*

DYNAMIC FORECASTING OF NETWORK SERVICES

Valentina Radojičić, Slobodan Mitrović