

 **SYM-OP-IS**
2019



UNIVERSITY OF BELGRADE
FACULTY OF ORGANIZATIONAL SCIENCES

XLVI International Symposium on Operational Research

Conference Proceedings
(Zbornik radova)

Kladovo, September 15-18, 2019
Serbia



XLVI International Symposium on Operational Research
XLVI Simpozijum o operacionim istraživanjima

www.symopis2019.fon.bg.ac.rs

SYM-OP-IS 2019

Kladovo, September 15– 18, 2019

PROCEEDINGS
ZBORNIK RADOVA

Editors/Editori:

Prof. dr Milan Martić
Prof. dr Dragana Makajić-Nikolić
Prof. dr Gordana Savić



UNIVERSITY OF BELGRADE
FACULTY OF ORGANIZATIONAL SCIENCES

PUBLISHER

University of Belgrade, Faculty of Organizational Sciences, Belgrade, Serbia
Jove Ilića 154, 11000 Belgrade, Serbia

YEAR
2019

ISBN: 978-86-7680-363-7

EXECUTIVE ORGANIZER/ORGANIZATOR



CO-ORGANIZERS/ ORGANIZATORI



Visoka građevinsko-geodetska škola, Beograd



Ekonomski fakultet, Beograd



Matematički institut SANU, Beograd



Rudarsko-geološki fakultet, Beograd



Vojska Srbije



Univerzitet u Banjoj Luci



Ekonomski institut, Beograd



Institut "Mihajlo Pupin", Beograd



Matematički fakultet, Beograd



Saobraćajni fakultet, Beograd



Ministarstvo odbrane Republike Srbije



Društvo operacionih istraživača

SUPPORTED BY/ SYM-OP-IS PODRŽAVAJU



Република Србија
Министарство просвете,
науке и технолошког развоја



АКАДЕМИЈА
ИНЖЕЊЕРСКИХ НАУКА
СРБИЈЕ



PREDVIĐANJE INTENZITETA SAOBRAĆAJA NA SISTEMU ZA NAPLATU PUTARINE

PREDICTION OF TRAFFIC INTENSITY AT PAY TOLL STATIONS

ANDRIJA PETROVIĆ^{1,2}, SANDRO RADOVANOVIĆ², UGLJEŠA BUGARIĆ¹, BORIS DELIBAŠIĆ², MILOŠ JOVANOVIĆ²

¹ Mašinski Fakultet, Beograd, aapetrovic2019@mas.bg.ac.rs

² Fakultet organizacionih nauka, Beograd, sandro.radovanovic@fon.bg.ac.rs

Rezime: U radu je predstavljen metod za predviđanje intenziteta saobraćaja na sistemu za naplatu putarine za različit broj unapred određenih naplatnih rampi koje će biti otvorene. Sistem za naplatu putarine je predstavljen kao više jednokanalnih sistema opsluživanja, gde jedan kanal predstavlja jednu naplatnu rampu. Razvijanjem metodologije zasnovane na predviđanju parametra opsluživanja za unapred zadati broj otvorenih kanala, kombinacijom neuronskih mreža i modela masovnog opsluživanja evaluirane su verovatnoće stanja sistema za naplatu putarine i ukupni troškovi istog. LSTM neuronska mreža (eng. Long short term memory) sa unutrašnjom standardizacijom korišćena je za predviđanje parametra opsluživanja. Analizirane su 24 arhitekture mreža, model sa najboljim prediktivnim performansama je izabran i korišćen u cilji predviđanja parametra opsluživanja.

Ključne reči: rekurentne neuronske mreže, intenzitet saobraćaja, teorija masovnog opsluživanja

Abstract: In this paper method for predicting states of toll station system for different number of open toll ramps is developed. The system for toll payment is modeled as single channel queuing model, where one channel presents toll ramp. The novel methodology based on combination of recurrent neural networks and queuing theory is presented. The goal of the methodology is to evaluate total costs and probability of traffic intensity at the pay toll stations. Long short term memory neural network (LSTM) with layer normalization is used as a model for prediction intensity. The 24 different architectures of network are analyzed, and the best one is used as the predictor for intensity of vehicles arriving time.

Keywords: recurrent neural networks, traffic intensity, queueing theory

1. UVOD

U svakodnevnom životu sreću se različiti sistemi opsluživanja koji se mogu modelirati teorijom masovnog opsluživanja. Neki od primera sistema opsluživanja su: čekanja na kasi u samoposluzi [11], čekanja na naplatnim stanicama na autoputevima [3; 12], čekanja na graničnim prelazima itd. S obzirom da su ovi sistemi bazirani na stohastičkim procesima koji se tiču dolazaka vozila i njihovog opsluživanja samim tim usvojeni model može obezbediti informacije koje se tiču verovatnoće stanja sistema, odnosno verovatnoće koliko se trenutno vozila nalazi u sistemu. Informacije o ovoj verovatnoći mogu biti izuzetno korisne zato što se posredstvom njih mogu doneti upravljačke odluke koje će smanjiti očekivane ukupne troškove [8]. Minimizacija očekivanih ukupnih troškova podrazumeva minimizaciju zbira očekivanih troškova čekanja i očekivanih troškova opsluživanja. Jedan od najčešćih načina upravljanja ovim troškovima je izborom broja kanala za opsluživanje koji treba da bude dostupan. Odnosno cilj je naći broj kanala koji će maksimalno umanjiti ukupne troškove opsluživanja u datom vremenskom intervalu ukoliko je model opsluživanja nehomogen. Određivanje optimalnog broja kanala kod sistema opsluživanja je problem koji treba da bude rešen u nekom periodu u budućnosti. Na ovaj način mogu se ispravno isplanirati raspoloživi resursi i angažovati ona količina istih kako bi ukupni troškovi bili minimalni. Stoga je neophodno prevashodno predvideti kako će se menjati verovatnoća stanja sistema u budućnosti, za različiti broj kanala, a zatim izabrati onaj broj koji će maksimalno smanjiti očekivane ukupne troškove sistema.

Različite optimizacione i prediktivne tehnike su prisutne u cilju rešavanja problema povećanog intenziteta saobraćaja. U radu [5] prikazan je način optimizacije potrošnje električne energije na mobilnim mrežama u nekom periodu u budućnosti. Usled velike potrošnje električne energije repetitorskih stanica razvijen je sistem koji će predvideti koji je trenutno stepen opterećenja mreže i odrediti koja repetitorska

stanica može da se ugasi. Na ovaj način smanjeni su troškovi potrošnje električne energije i smanjena emisija CO₂ gasova. Model za navođenje vozila ka naplatnim rampama u cilju smanjenja vremena čekanja, razvijen korišćenjem modela vremenskih serija prikazan je u [9]. Metodologija za optimizaciju uključivanja i isključivanja saobraćajne signalizacije prikazana je u [7]. Prikaz velikog broja strategija i metoda korišćenih za upravljanje saobraćajem prikazan je u [10], dok su na sličan način u [2] predstavljene tehnike predviđanja korišćene u saobraćaju zasnovane na algoritmima mašinskog učenja.

U ovom radu korišćenjem kombinacije arhitekture rekurentnih neuronskih mreža (eng. „*Long short term memory*“, skraćeno LSTM) zajedno sa modelima sistema opsluživanja (teorija masovnog opsluživanja) prikazana je metodologija za predviđanje intenziteta saobraćaja na naplatnim stanicama za izbor strategije otvaranja i zatvaranja naplatnih rampi. Metodologija je primenjena na naplatnoj stanici Vrčin na autoputu E70 u smeru ka Beogradu. Metodologija se dalje može generalizovati na slične sisteme koji se ponašaju na isti način.

2. PRIPREMA PODATAKA

Podaci o prolascima vozila kroz naplatnu stanicu Vrčin u periodu od avgusta do septembra 2017. godine korišćeni su u cilju formiranja skupa podataka na osnovu kojeg je učena i testirana LSTM rekurentna mreža. Takođe na ovom skupu podataka verifikovan je predloženi model, odnosno poređen je ukupan trošak praćenjem strategije koja je dobijena primenom razvijene metodologije, sa ukupnim troškom koji je dobijen za stvarno stanje sistema. Izlazne vrednosti parametara su formirane korišćenjem vremenskog prozora sa intervalom od 180 minuta. Intenziteti dolazaka vozila su prognozirani na svakih 5 minuta. Samim tim svi atributi koji su korišćeni kao ulaz u rekurentnu mrežu predstavljaju izvedene statistike vozila koje su evaluirane na svakih 5 minuta sa istim vremenskim prozorom kojim su traženi intenziteti dolazaka. U tabeli 1 dat je pregled svih korišćenih atributa.

Tabela 1. Grupe i opisi atributa korišćenih pri predikciji

Grupe atributa	Opis atributa
Deskriptivni	Broj vozila
	Vreme u časovima i minutima
Statistički	Srednja brzina vozila
	Maksimalna brzina vozila
	Deseti percentil brzine vozila
	Prvi kvartil brzine vozila
	Medijana brzine vozila
	Drugi kvartil brzine vozila
	Devedeseti percentil brzine vozila
Vremenski	Temperatura u °C
	Vlažnost vazduha u %
	Tačka rose u °C
	Brzina vetra u m/s
	Opis vremena
	Vidljivost%

Pored korišćenja vremenskih atributa u Vrčinu korišćeni su i vremenski atributi u Nišu. Opis vremena je prikazan kao vektor sa 15 elemenata. S obzirom na to da se predviđaju intenziteti dolazaka 300 minuta unapred, izlaz predstavlja vektor sa 60 elemenata.

Pored korišćenih atributa kao ulaz u mrežu korišćeni je vektor izlaza iz prethodne sekvence stoga je ukupan broj ulaznih atributa koji je formiran u skupu podataka 90. U slučaju predviđanja intenziteta dolazaka vozila, kao ulazni atribut koji je u narednoj sekvenci korišćen je vektor intenziteta dolazaka vozila iz prethodne sekvence. Ukupan broj instanci korišćen za testiranje i treniranje mreže je 24979. Za treniranje rekurentne mreže koja predviđa očekivanu vrednost intenziteta dolaska korišćeno je 18040, a ostalih 6939 instanci je korišćeno za testiranje.

3. LSTM MREŽA SA UNUTRAŠNJOM STANDARDIZACIJOM SLOJEVA

Jedan od načina smanjivanja visokog troška računanja pri treniranju standardnih neuronskih mreža je normalizacija izlaza iz skrivenih slojeva. Tehnika koja se naziva unutrašnja (serijska) standardizacija [4] (eng. „*batch normalization*”) koristi ulaze u neuron (iz podataka za učenje) kao vrednosti slučajnih promenljivih na osnovu kojih se izračunava očekivana vrednost i varijansa u cilju normalizacije istih tokom treniranja. Ova tehnika se primenjuje za svaki neuron ponaosob i na taj način značajno smanjuje celokupno vreme treniranja neuronske mreže, omogućavajući korišćenje većih koraka prilikom učenja i smanjujući opasnost od eksplozivajućih gradijenata tokom treninga. Na vrlo sličan način unutrašnja standardizacija se može uopštiti na rekurentne neuronske mreže odnosno preciznije rekurentne neuronske mreže sa LSTM ćelijama. LSTM neuronska mreža sastoji se od LSTM ćelija koje poseduju kapije pomoću kojih se informacija iz dalekih sekvenci uspešno čuva. Iako je uspešna u smanjenju numeričkih grešaka nastalih usled množenja gradijenata niskih vrednosti, ista ima visok trošak računanja. Za razliku od standardnog pristupa kod LSTM neuronskih mreža normalizuju se čitavi slojevi, koristeći sumirane ulaze u neurone kao promenljive na osnovu kojih se određuje očekivana vrednost i varijansa za normalizaciju istih. Uticaj ovakvog vida standardizacije deluje da se gradijenti propagiraju stabilnije u smislu toga da ne dolazi do numeričkih grešaka pri izračunavanju istih. Detaljnije o ovom modelu može se pronaći u [6].

Na osnovu pripremljenog skupa podataka različite neuronske mreže sa različitim metaparametrima su učene u cilju predviđanja intenziteta dolazaka vozila. U svim slučajevima variran je broj slojeva i broj ćelija po sloju. Korišćeno je 8, 16, 32 i 64 ćelije po sloju, dok se broj slojeva menja u rasponu od 1 do 3. U svim arhitekturama ukupan broj instanci u okviru jedne sekvence je 320. Srednja kvadratna greška je korišćena kao funkcija koju je potrebno svesti na minimum, pri učenju rekurentne neuronske mreže. Nakon učenja mreža, modeli su validirani na test skupu podataka. Ukupno je naučeno 24 različita modela. Početni parametar učenja koji je korišćen pri treniranju je 0,1, narednih 7 epoha ovaj parametar je korišćen za učenje, a nakon toga je isti opadao sa stepenom 0,92. Broj epoha treniranja svih arhitektura je 100. Implementacija modela izvršena je u Python i Tensorflow-u. Rezultati performansi predikcije mreža prikazani su u tabeli 2.

Tabela 2. Prediktivne performanse LSTM modela sa unutrašnjom standardizacijom

R ² skor sa izbacivanjem ćelija					R ² skor bez izbacivanja ćelija			
Broj slojeva	Broj LSTM ćelija po sloju				Broj LSTM ćelija po sloju			
	8	16	32	64	8	16	32	64
1	0,726	0,703	0,624	0,692	0,679	0,517	0,431	0,77
2	0,812	0,834	0,803	0,817	0,855	0,803	0,868	0,856
3	0,781	0,772	0,879	0,653	0,824	0,849	0,843	0,849
Srednje kvadratno odstupanje sa izbacivanjem ćelija					Srednje kvadratno odstupanje bez izbacivanja ćelija			
Broj slojeva	Broj LSTM ćelija po sloju				Broj LSTM ćelija po sloju			
	8	16	32	64	8	16	32	64
1	4,558	4,942	6,253	5,125	5,348	8,04	9,481	3,822
2	3,119	2,761	3,27	3,044	2,408	3,27	2,194	2,391
3	3,698	3,797	2,012	5,784	2,931	2,515	2,609	2,503
Srednja apsolutna greška sa izbacivanjem ćelija					Srednja apsolutna greška bez izbacivanja ćelija			
Broj slojeva	Broj LSTM ćelija po sloju				Broj LSTM ćelija po sloju			
	8	16	32	64	8	16	32	64
1	1,412	1,449	1,576	1,483	1,439	1,763	1,645	1,347
2	1,204	1,149	1,191	1,184	1,025	1,162	1,013	1,029
3	1,338	1,352	0,964	1,524	1,182	1,053	1,073	1,035

Sa stanovništva regularizacije primećuje se da mreže kod kojih se odbacuju ćelije (eng. „*dropout regularization*”) nemaju značajno bolji rezultat u odnosu na arhitekture kod kojih se ćelije ne odbacuju. Usvojeno je da faktor izbacivanja ćelija iznosi 0,8 odnosno 80%. LSTM mreža sa 3 sloja, 32 LSTM ćelije po sloju i regularizacijom postignutom tehnikom izbacivanjem ćelija, prikazuje najbolje performanse predikcije

na test skupu podataka. Odnosno R^2 skor ove mreže je 0,879, srednja kvadratna greška je 2,012, dok je srednja apsolutna greška 0,964. Stoga je ova mreža korišćena pri predviđanju intenziteta dolazaka vozila.

4. ODREĐIVANJE STANJA I UKUPNIH TROŠKOVA NAPLATNE STANICE

Predviđanjem intenziteta dolazaka vozila na naplatnu stanicu moguće je predvideti intenzitet saobraćaja za izabranu strategiju otvaranja naplatnih rampi. Imajući u vidu da se naplatna stanica može modelirati kao više jednokanalnih sistema opsluživanja, gde jedan kanal predstavlja jednu naplatnu rampu, moguće je definisati funkciju cilja na osnovu koje se određuje optimalan broj kanala na istoj. Napomenuto je da se pretpostavlja da je intenzitet dolazaka vozila na svaku rampu isti i jednak količniku intenziteta dolazaka vozila na naplatnu stanicu i trenutnog broja otvorenih naplatnih rampi. Na osnovu prethodno navedenog moguće je pre svega postaviti funkciju cilja na osnovu koje je moguće pronaći optimalni broj naplatnih rampi korišćenjem optimizacionih algoritama. S obzirom da se radi o nestacionarnom sistemu, odnosno sistemu koji je promenljiv u vremenu ukupni troškovi se predstavljaju kao [1]:

$$E(UT) = \int_0^t (T\check{C}(t) + TO(t)) dt \quad (1)$$

gde je $E(UT)$ - očekivani ukupni trošak, $T\check{C}(t)$ - trošak čekanja u trenutku t i $TO(t)$ trošak opsluživanja u trenutku t . Trošak opsluživanja u trenutku t se može zapisati kao [1]:

$$TO(t) = c(t) \cdot C_c \quad (2)$$

gde je C_c - ukupni trošak naplatne rampe izražen u EUR/min, a $c(t)$ je broj otvorenih naplatnih rampi u trenutku t . Ukupni trošak naplatne rampe jednak je zbiru sledećih troškova: Troškovi el. energije C_{el} , troškova radne snage C_{rad} , troškovi grejanja i hlađenja $C_{gr,hl}$ i Ostalih troškova C_{ostl} . Ukupni trošak naplatne rampe dobijeni kao zbir svih nabrojanih troškova $C_c = C_{el} + C_{rad} + C_{gr,hl} + C_{ostl}$ iznosi 0,162 EUR/min.

Troškovi čekanja u trenutku t se mogu predstaviti kao proizvod funkcije troškova čekanja po vozilu $h(t)$ u zavisnosti od vremena t i gustine raspodele verovatnoće vremena provedenog u sistemu $f(t)$, i intenziteta dolazaka vozila $\lambda(t)$ u vremenu t . Odnosno, ovi troškovi se mogu zapisati kao:

$$T\check{C}(t) = \lambda(t) \cdot h(t) \cdot f(t) \quad (3)$$

Ukoliko se funkcija troškova čekanja po vozilu napiše kao linearna zavisnost u funkcije vremena, onda sledi da je [1]:

$$h(t) = C_w \cdot t \quad (4)$$

gde je C_w trošak čekanja izražen u EUR/(min · vozilo). Ovaj trošak je računat kao zbir sledećih troškova: troškova goriva C_{gor} , trošak izgubljenog vremena C_{vr} i ostali troškovi čekanja $C_{w,ostl}$. Ukupni troškovi čekanja po vozilu dobijeni kao zbir $C_w = C_{gor} + C_{vr} + C_{w,ostl}$ iznose 0,155 EUR/(min · vozilo).

Gustina raspodele verovatnoće vremena provedenog u sistemu se može iskazati u sledećem obliku [1]:

$$f(t) = \sum_{k=0}^m q_k \cdot \frac{\mu \cdot (\mu \cdot t)^k \cdot e^{-\mu t}}{k!} \quad (5)$$

gde je m broj mesta u redu, a q_k predstavlja verovatnoću dolazećeg vozila koja se može izraziti preko verovatnoće stanja p_k kao:

$$q_k = \begin{cases} \frac{p_k}{1-p_{k+m}} & k = 0, 1, 2, \dots, m \\ 0 & k = m+1 \end{cases} \quad (6)$$

Verovatnoća stanja sistema se izračunava iz matrične diferencijalne jednačine kao [1]:

$$\frac{dp}{dt} = Q^T q \quad (7)$$

gde p predstavlja vektor verovatnoća stanja sistema $p = [p_0(t), p_1(t), \dots, p_{m+1}(t)]$, a q je vektor verovatnoća dolazećeg vozila $q = [q_0(t), q_1(t), \dots, q_m(t)]$.


Elementi tranzicione matrice Q se određuju kao:

$$Q = \begin{bmatrix} -\frac{\lambda(t)}{c(t)} & \frac{\lambda(t)}{c(t)} & 0 & \dots & 0 \\ \mu & -(\mu + \frac{\lambda(t)}{c(t)}) & \frac{\lambda(t)}{c(t)} & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mu & -\mu \end{bmatrix} \quad (8)$$


Funkcija cilja očekivanih ukupnih troškova se može predstaviti kao:

$$E(UT) = \int_0^t c(t) \cdot (C_c + \lambda(t) \cdot C_w \cdot t \cdot f(t)) dt \quad (9)$$

U cilju verifikacije rada izabrane metodologije na slici 1 prikazana je promena verovatnoće stanja i ukupnih troškova na naplatnoj stanici Vrčin za stvarnu vrednost intenziteta dolazaka vozila, dok je na slici 2 prikazana promena verovatnoće stanja i ukupnih troškova za predviđeni intenziteta dolazaka vozila.



Slika 1. Promena stanja sistema, troškova i strategije otvaranja kanala za stvarne vrednosti intenziteta dolazaka vozila



Slika 2. Promena stanja sistema, troškova i strategije otvaranja kanala za predviđane vrednosti intenziteta dolazaka vozila

Može se videti da je razlika u oceni stanja sistema između stvarnog prikaza rada i rada sistema koji je dobijen primenom LSTM mreže sa unutrašnjom standardizacijom zanemarljiv. To znači da se može uspešno predvideti kako će izabrana polisa otvaranja naplatnih rampi uticati na očekivani ukupan trošak i pojave povećanja intenziteta saobraćaja u sistemu. Razvijena metodologija se dalje može primeniti na mnogo kompleksnijim sistemima u drugim domenima opsluživanja gde je potrebno oceniti verovatnoće stanje sistema na osnovu zadatih ulaznih atributa.

5. ZAKLJUČAK

Na osnovu razvijene metodologije i njene primene na sistem naplatne stanice može se izvesti nekoliko zaključaka:

- LSTM mreža sa unutrašnjom standardizacijom ima visoke performanse ($R^2=0,879$) predikcije pri predviđanju intenziteta dolazaka vozila u periodu od 300 minuta.
- Stanja sistema i ocena očekivanih ukupnih troškova korišćenjem realnog intenziteta dolazaka vozila i vrednosti koja je dobijena primenom LSTM mreže sa unutrašnjom standardizacijom se ne razlikuju značajno.
- Razvijena metodologija može koristiti kao sredstvo menadžmenta pri donošenju odluka koliko naplatnih rampi (kanala) treba da bude otvoreno u nekom periodu u budućnosti.

Dalja istraživanja treba da budu usmerena ka uključivanju modela matematičkog programiranja u cilju određivanja optimalnog broja naplatnih rampi koji treba da bude otvoren u nekom periodu u budućnosti kako bi troškovi sistema opsluživanja bili minimalni.

LITERATURA

- [1] Bugarić, U., & Petrović, D. (2011). Modeliranje sistema opsluživanja. *Mašinski fakultet Beograd, Beograd*.
- [2] Castillo, E., Grande, Z., Calviño, A., Szeto, W. Y., & Lo, H. K. (2015). A state-of-the-art review of the sensor location, flow observability, estimation, and prediction problems in traffic networks. *Journal of Sensors, 2015*.
- [3] Drew, D. R. (1968). Traffic flow theory and control.
- [4] Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*.
- [5] Ishak, S., & Alecsandru, C. (2004). Optimizing traffic prediction performance of neural networks under various topological, input, and traffic condition settings. *Journal of Transportation Engineering, 130(4)*, 452-465.
- [6] Lei Ba, J., Kiros, J. R., & Hinton, G. E. (2016). Layer normalization. *arXiv preprint arXiv:1607.06450*.
- [7] Mihăiță, A. S., Dupont, L., & Camargo, M. (2018). Multi-objective traffic signal optimization using 3D mesoscopic simulation and evolutionary algorithms. *Simulation Modelling Practice and Theory, 86*, 120-138.
- [8] Neely, M. J. (2010). Stochastic network optimization with application to communication and queueing systems. *Synthesis Lectures on Communication Networks, 3(1)*, 1-211.
- [9] Neuhold, R., Garolla, F., Sidla, O., & Fellendorf, M. (2019). Predicting and Optimizing Traffic Flow at Toll Plazas. *Transportation Research Procedia, 37*, 330-337.
- [10] Papageorgiou, M., Diakaki, C., Dinopoulou, V., Kotsialos, A., & Wang, Y. (2003). Review of road traffic control strategies. *Proceedings of the IEEE, 91(12)*, 2043-2067.
- [11] Qiu, C. M., & Zhang, W. (2016). Managing long queues for holiday sales shopping. *Journal of Revenue and Pricing Management, 15(1)*, 52-65.
- [12] Vandaele, N., Van Woensel, T., & Verbruggen, A. (2000). A queueing based traffic flow model. *Transportation Research Part D: Transport and Environment, 5(2)*, 121-135.