

ORIGINAL PAPER

Neural network modeling methods for predicting the air parameters in the city of Tuzla

Džemila Agić¹ | Halid Makić² | Goran Tadić³ | Miladin Gligorić³ | Sejfudin Agić⁴

¹Centar za ekologiju i energiju, FILIPA Kljajića 22, Tuzla, BiH

²Univerzitet u Bihaću, Biotehnički fakultet, Pape Ivana Pavla II 2/2, Bihać, BiH

³Univerzitet u Istočnom Sarajevu, Tehnološki fakultet Zvornik, Karakaj 34A, Zvornik, BiH

⁴Elektrotehnička škola Tuzla, M. H. Uskufija 2, Tuzla, BiH

Correspondence

Dž. Agić

Email: dzemila.agic@bih.net.ba

Abstract

According to the report of the World Health Organization, the city of Tuzla is the second in the world, and the first in Europe in terms of the number of diseases caused by air pollution. Tuzla Canton since 2003 has continuous air monitoring. Concentrations of individual pollutants exceed hourly, daily and annual limit values. In this paper, based on the existing results of air monitoring and meteorological data, using statistical methods and neural network modeling methods, unique and reliable models for predicting the concentration of NO₂ in the air for the City of Tuzla have been developed. The results obtained using these models can be used in strategic decision-making processes and activities related to air quality control and management. This paper, on the example of the City of Tuzla, showed that using existing air monitoring data, concentrations of pollutants can be predicted for a longer period of time, using artificial intelligence methods. Reliable models with a high correlation coefficient can be obtained. In the case of a short or long interruption of the measurement of pollutant concentrations for the City of Tuzla with the help of models, which are the result of this work, it is possible to predict the concentrations of pollutants and plan to take measures based on them.

Keywords: air pollution, air monitoring, artificial intelligence, neural networks, modeling.

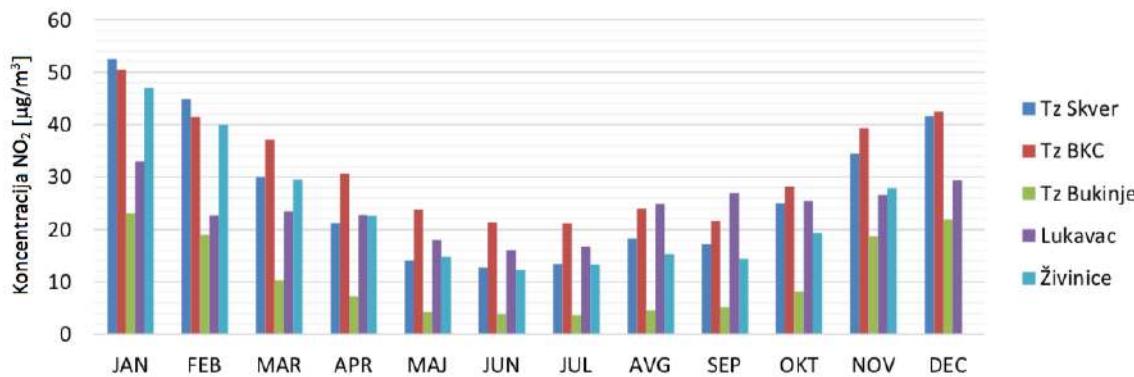
1. UVOD

U Gradu Tuzla, dio industrije u svom procesu rada, kao i veliki broj individualnih stambenih objekata za zagrijavanje, koriste ugalj, što već duži vremenski period dovodi do povećanja zagadenosti vazduha. Ako se tome pridoda i velika koncentracija saobraćaja, tada se ovaj problem još više usložnjava. Među najagresivnjim zagadivačima vazduha su oksidi azota i sumpora, ugljen monoksid, ozon, organska jedinjenja i čvrste čestice. Veće količine bilo koje zagadjujuće materije u vazduhu štetno utiču na zdravlje stanovništva. Zato je sistematsko praćenje koncentracija ovih zagadivača u vazduhu i predviđanje njihovog prisustva i ponašanja veoma važno (Gaffin et al. 2018). U poslednje vrijeme intezivirana su istraživanja na polju predviđanja zagadenja vazduha pomoću vještačkih neuronskih mreža (ANN) (Paas, Stienen, Vorländer, & Schneider 2017). Ove tehnike predviđanja zagadenja vazduha u gradu Tuzli, koriste raspoložive po-

datke zagadenja vazduha, kao i meteopodatke, budući da postoji kontinuirano praćenje kvaliteta vazduha. U cilju adekvatne zaštite okoline i blagovremenog smanjenja emisije zagadjujućih materija u vazduhu, kako bi se njihove koncentracije prilagodile graničnim vrijednostima koje su propisane za 2021. godinu, a na osnovu postojećih rezultata mjerenja, meteoroloških faktora, topografskih varijacija i slično, provedena je analiza i modeliranje dostupnih podataka za NO₂ sa pet imisionih mjernih stanica u Gradu Tuzli. U radu će biti izvršena prezentacija važnih pokazatelja kvaliteta vazduha u Gradu Tuzli, uz odgovarajuću statističku analizu i modeliranje parametara kvaliteta vazduha korištenjem metoda vještačke inteligencije

2. PODACI MONITORINGA I METODE RADA

Na pet postavljenih imisionih mjernih stanica za monitoring vazduha u Gradu Tuzli vrši se mjerjenje sljedećih za-



Slika 1. Srednja mjeseca koncentracija NO_2 izmjerena na mjernim stanicama u Tuzlanskom kantonu u 2017. godini (*Kvalitet vazduha u tuzlanskom kantonu - stranica Ministarstva prostornog uređenja i zaštite okoline TK n.d.*).

gađajućih materija: SO_2 , $PM_{2,5}$, NO_2 , CO i O_3 . U radu je analiziran samo uticaj NO_2 , pri čemu je korišten veliki broj podataka koji su dobijeni mjerjenjem u proteklom vremenskom periodu. Utvrđeno je da su koncentracije ovog polutanta rijetko prelazile definisane granične vrijednosti, a vrlo rijetko pragove upozorenja i ubzune.

2.1. Analiza rezultata mjerena koncentracije NO_2

Na slici 1. je prikazana srednja mjeseca koncentracija NO_2 izmjerena na pet mjernih stanica u Tuzlanskom kantonu u 2017. godini.

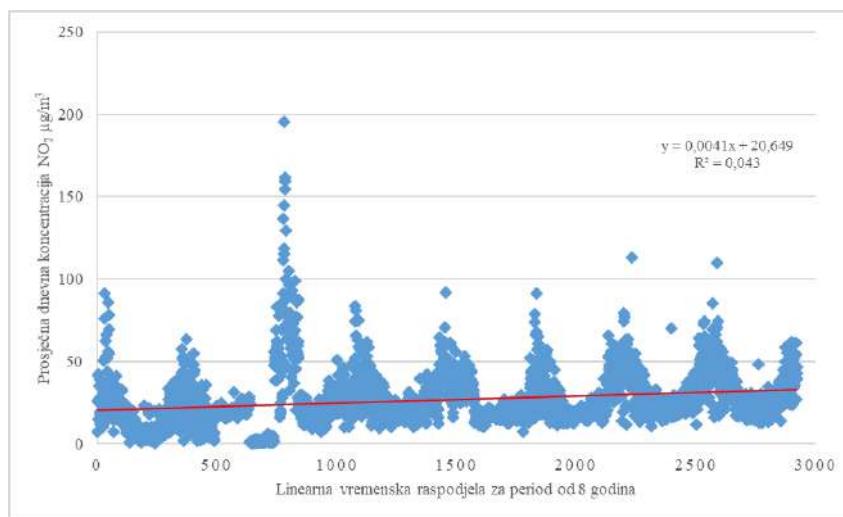
Analizom srednje godišnje koncentracije NO_2 , čija granična vrijednost iznosi 40 g/m^3 , može se utvrditi da u 2017. godini ona nije bila prekoračena ni na jednoj mjernej stanicici. Iz dostupnih podataka (*Kvalitet vazduha u tuzlanskom kantonu - stranica Ministarstva prostornog uređenja i zaštite okoline TK n.d.*) primetno je da je satna granična vrijednost za NO_2 od 200 g/m^3 na MS Skver bila prekoračena 4 puta, a maksimalni dozvoljeni broj prekoračenja iznosi 18 puta. Dnevna granična vrijednosti, koja iznosi 85 g/m^3 bila je prekoračena 3 puta na MS Skver, dva puta na MS Bosanski kulturni centar (BKC) i 2 puta na MS u Živinicama. Praćenjem podataka u dužem vremenskom periodu, zagađenje sa NO_2 u Tuzlanskom kantonu se može smatrati zadovoljavajućim. Međutim, NO_x jedinjenja su, posebno u ljetnim mjesecima, veoma opasna jer učestvuju u hemijskim procesima sa veoma agresivnim produktima, kao što su azotasta kiselina ili elektro smog, tako da je sa navedenog aspekta ovo istraživanje posebno značajno. Granične i tolerantne vrijednosti za pojedine zagadjujuće materije propisane su Pravilnikom o načinu vršenja monitoringa kvaliteta vazduha ("SN" n.d.; *Kvalitet vazduha u tuzlanskom kantonu - stranica Ministarstva prostornog uređenja i zaštite okoline TK n.d.*). Kao odgovor na problem sve većeg zagađenja vazduha moguće je provesti predviđanje kvaliteta vazduha softverskim metodama (Kurt, Gulbagci, Karaca, &

Alagha 2008). Vještačka inteligencije i softverska rješenja zasnovane na njoj su već široko zastupljene u modeliranju rezultata kvaliteta vazduha i sličnim eksperimentalnim istraživanjima (Deleawe, Kusznir, Lamb, & Cook 2010; Dragomir 2010; Ghazali & Ismail 2011). Izvršeno je prikupljanje satnih koncentracija NO_2 u periodu od 01.01.2010. do 31.12.2017. godine i njihov proračun u prosječne dnevne koncentracije. Statističkom analizom izračunate su prosječne vrijednosti i standardna devijacija i potvrđeno je da podaci predstavljaju vremensku seriju. Izračunata je korelacija između koncentracije NO_2 i meteoroloških faktora: temperature, vlažnosti, brzine vjetra i vazdušnog pritiska. Korištenjem MATLAB softvera (Neural Network toolbox) razvijen je i testiran jedinstven model neuronske mreže za predviđanje kvaliteta ovog parametra vazduha u Gradu Tuzla.

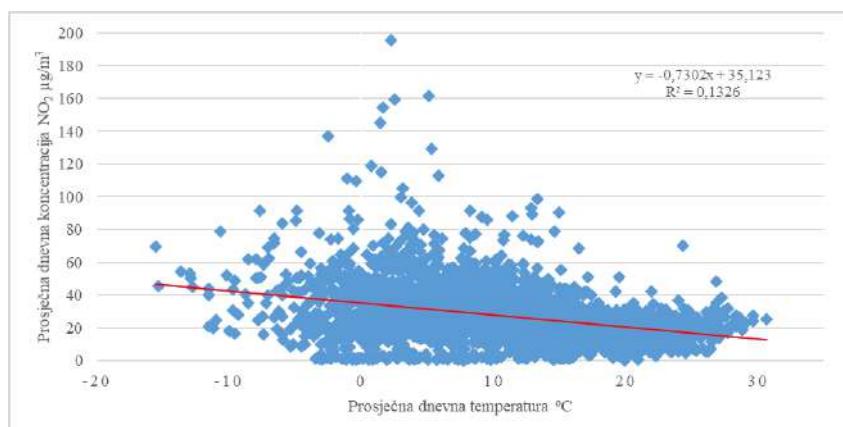
3. REZULTATI I DISKUSIJA

3.1. Statistička analiza vremenskih serija

Vremenske serije su definisane kao nizovi numeričkih podataka uređene po hronologiji. Samim tim podaci vremenskih serija su međusobno zavisni, budući da se u obzir uzima njihov vremenski redoslijed. Upravo na ovakvoj vremenskoj zavisnosti podataka zasnovana je i ova analiza. Postoje dva glavna razloga primjene modela vremenskih serija. Prvi, da se u sistemima koji su nikako ili djelimično razumljivi ipak odredi veza između uzorka i poslijedice. Drugo, glavni interes može biti da se samo predviđi šta će se desiti sa podacima, sistemima ili procesima ali ne i da se odredi zašto se to dešava. Analizane su prosječne vrijednosti i standardne devijacije za izabrane mjerne stanice (Skver, Bosanski kulturni centar i Bukinje) sa najkompletnijim podacima. Izračunati su: prosječna vrijednost, standardna devijacija, maksimalna i minimalna vrijednost, broj podataka uzetih u proračunu na skupu svih podataka tokom 8 godina i



Slika 2. Analiza linearog modela prosječnih dnevnih koncentracija NO_2 na mjerenoj stanici Skver za period 2010-2017. godine ($r_{xy}=0,207459$).



Slika 3. Analiza linearog modela prosječnih dnevnih koncentracija NO_2 na mjerenoj stanici Skver za period 2010-2017. godine ($r_{xy}=0,207459$).

potvrđena je validnost svih podataka. Slijedeći korak je statistička analiza korelacije modela u odnosu na uticajne parametre. Uticajni faktori su meteorološki podaci za Grad Tuzlu u analiziranom periodu i to: prosječna dnevna temperatura ($^{\circ}\text{C}$), prosječna dnevna brzina vjetra (m/s), prosječna dnevna vlažnost (%) i prosječni dnevni pritisak (hPa). Podaci su ustupljeni od strane Federalnog hidrometeorološkog zavoda u Sarajevu (*Federalni hidrometeorološki zavod BiH n.d.*). Tim slijedom prvo je analiziran linearni model vremenske serije, čiji rezultati za mjeru stanicu Skver su prikazani na slici 2. Koreacionim modelima utvrđuje se postojanje linearne ili približno linearne veze između uticajnih parametara, a na osnovu empirijskog pravila za koeficijent korelacije za koji je jačina linearna veze značajna ako je $0,5 < r_{xy} < 0,7$. Na slici 3. prikazana je korelacija prosječnih dnevnih koncentracija SO_2 ($\mu\text{g}/\text{m}^3$) i prosječne dnevne temperature ($^{\circ}\text{C}$) za period od osam godina. Izračunati koeficijent ko-

relacije iznosi $r_{xy} = -0,35417$. U tabeli 1 predstavljene su vrijednosti koeficijenta korelacije normalne raspodjele promjenljive za izabrane mjerne stanice i četiri uticajna faktora. Rezultati potvrđuju postojanje linearnih veza u odnosu na prosječnu dnevnu temperaturu u posmatranom periodu što se moglo i očekivati. Statistički značajan uticaj dobiten je na mjerenoj stanici BKC, jer je to najveća i najopterećenija saobraćajna raskrsnica u gradu. Statička analiza je imala za cilj utvrđivanje smjernica dalje analize uz pomoć naprednih softvera, što će biti prikazano u nastavku rada.

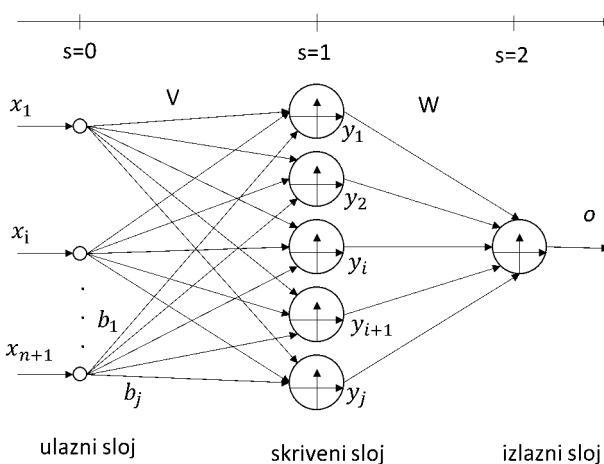
3.2. Vještačke neuronske mreže

Vještačke neuronske mreže su programski ili hardverski modeli fomirani po ugledu na strukturu i funkciju bioloških neurona i nervnog sistema. Vještačke neuronske mreže su sastavljene od velikog broja računarskih jedinica nazvanih - neuroni. Snaga veze između dva neu-

Table 1. Koeficijent korelacija za tri mjerne stanice u periodu 2010.-2017. godina.

Linerna raspodjela	Brzina (m/s)	vjetra	Rel. vlažnost (%)	Pritisak vazduha (hPa)	Temperatura (°C)
Mjerna stanica Skver					
NO_2	0,207459	0,092872	-0,04288	0,095027	-0,35417
Mjerna stanica BKC					
NO_2	-0,34279783	0,017550893	0,106535921	0,121132882	-0,525249138
Mjerna stanica Bukinje					
NO_2	0,207539614	0,092841945	-0,042807754	0,094843194	-0,363985753

rona naziva se težinom. Vrijednosti težina su istinski parametri mreže i predmet procedure obrade u neuronskim mrežama.

**Slika 4.** Nerekurzivna neuronska mreža (Ilić n.d.).

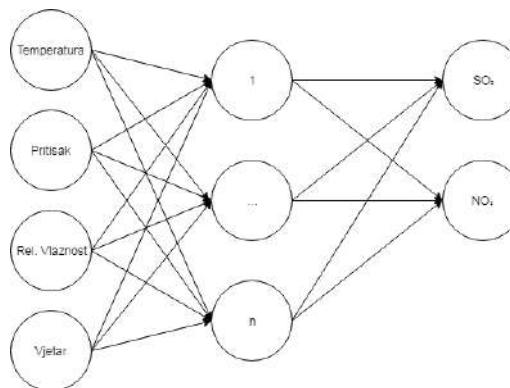
Prema načinu prostiranja signala kroz mrežu, najčešće se u literaturi spominju:

- rekurzivne (povratne ili rekurentne) - viši slojevi vraćaju podatke nižim slojevima i
- nerekurzivne (ili direktnе) - postoji tok signala samo od nižih ka višim nivoima.

Struktura osnovne nerekurzivne neuronske mreže, sa jednim skrivenim slojem, prikazana je na slici 4. Neuronske mreže ovog tipa nazivaju se višeslojni perceptron (Gorić 2017). Kao ulaz u neuronsku mrežu koristiće se meteo podaci (temperatura, pritisak, vlažnost i vjetar), dok su izlazi definisani u jednom širem sklopu proučavanja ovog problema, gdje je pored koncentracije NO_2 određivana i koncentracija SO_2 . U radu prezentujemo samo rezultate za NO_2 (Agić 2020). Na slici 5. je prikazan model takve neuronske mreže, gdje je u skrivenom sloju n broj neurona koji se određuje testiranjem.

Izvršena je dopuna nedostajućih podataka i njihova horizontalna normalizacija. Bazne vrijednosti za normal-

izaciju su: temperatura 10 °C, pritisak 986.92 hPa, relativna vlažnost vazduha 100 %, vjetar 1 m/s, te koncentracije SO_2 i NO_2 1000 $\mu g/m^3$. Normalizacijom se dobijaju bolje performanse neuronske mreže i i kraće vrijeme treniranja. Zbog velikog broja dostupnih podataka po-

**Slika 5.** Model neuronske mreže sa 4 ulaza i 2 izlaza.

daci su podijeljeni na set podataka za treniranje (učenje) i set podataka za testiranje u omjeru 60-40%, respektivno. Neuronska mreža za selektovane mjerne stanice ima 4 ulaza, 5 neurona u skrivenom sloju (zbog validacija nije potrebno više jer se brzo zaustavi treniranje) i 2 neurona u izlaznom sloju. Treniranje se obavlja skupom Matlab naredbi.

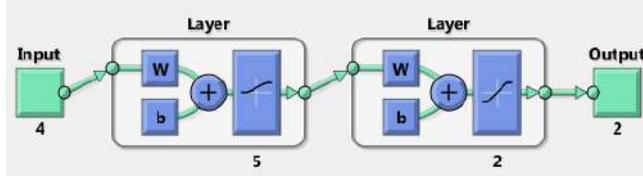
```
net = newff(minmax(X), [5, 2], {'logsig', 'satlin'}, 'trainlm');
net.divideFcn = 'divideint';
[net, tr] = train(net, X, Y);
```

gdje je:

- net – neuronska mreža,
- newff – funkcija za kreiranje nove feedforward neuronske mreže,
- X – ulazni podaci za treniranje 60%,
- Y – izlazni podaci za treniranje 40%,
- minmax(X) – funkcija koja pronađe minimalnu i maksimalnu vrijednost u matrici X, odnosno postavlja granice za treniranje neuronske mreže,

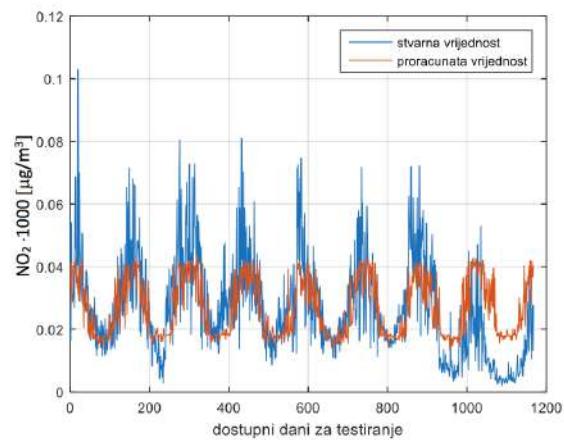
- 5 – broj neurona u skrivenom sloju,
- 2 – broj neurona u izlaznom sloju
- logsig – transfer funkcija u ulaznom sloju,
- satlin – transfer funkcija u izlaznom sloju,
- trainlm – algoritam treniranja,
- divideFcn – podjela podataka na podatke za treniranje/validaciju/testiranje u neuronskoj mreži tokom treniranja.

Model takve neuronske mreže je prikazan na slici 6. Na osnovu smanjenja iznosa vrijednosti parametra MSE

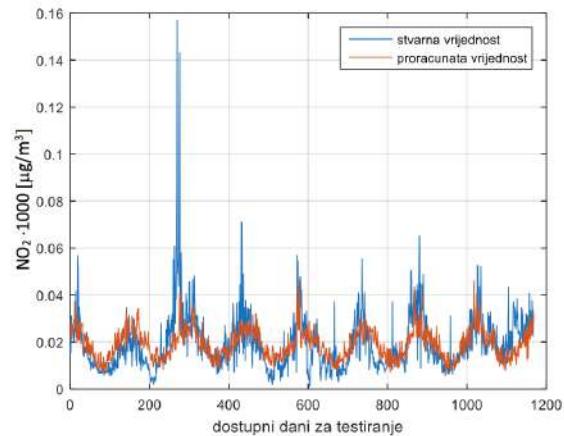


Slika 6. Struktura neuronske mreže za mjerne stанице BKC i Bukiinje.

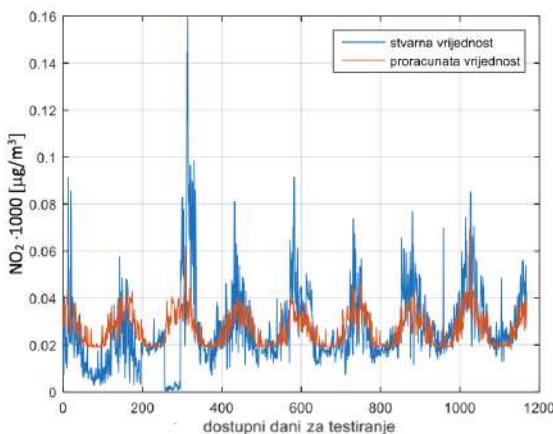
(Mean Squared Error) dolazi se do zaključka da neuronska mreže učenjem kroz epohe poboljšava rezultate, odnosno svoje znanje. Nakon treniranja pristupa se testiranju dobijene mreže. U ovom slučaju koristi se dobijeni set od 40% ulaznih podataka ($0,4 \times 2.922$ dana ≈ 1.169 dana). Formirani set su ulazni podaci, koji predstavljaju ulaze u već formiranoj neuronskoj mreži, a na osnovu kojih će ona dati nove rezultate i izlazne podatke koji predstavljaju stvarne vrijednosti. Grafički prikaz, uz korištenje funkcije plot, dobivenih rezultata neuronskih mreža u MATLAB-u za stvarne i proračunate vrijednosti u neuronskoj mreži za NO_2 prikazane su na slikama 7, 8, 9.



Slika 8. Rezultati poređenja proračunatih i stvarnih vrijednosti koncentracije NO_2 za mjeru stanicu BKC.



Slika 9. Rezultati poređenja proračunatih i stvarnih vrijednosti koncentracije NO_2 za mjeru stanicu Bukiinje.



Slika 7. Rezultati poređenja proračunatih i stvarnih vrijednosti koncentracije NO_2 za mjeru stanicu Skver.

Za provjeru kvaliteta dobijenih rezultata bilo je potrebno proračunati regresiju kao odnos stvarnih i proračunatih vrijednosti. Za ovu svrhu je napravljena skripta

u MATLAB-u, a njenim izvršavanjem za svaku mjeru stanicu dobijaju se rezultati prikazani na slikama 10, 11, 12.

Može se zaključiti da su dobijene vrijednosti linearne regresije na svim mernim stanicama zadovoljavajuće i da se kreću u intervalu od 0,76532 do 0,83563. Dobijena neuronska mreža se može analitički predstaviti jednačinom 1:

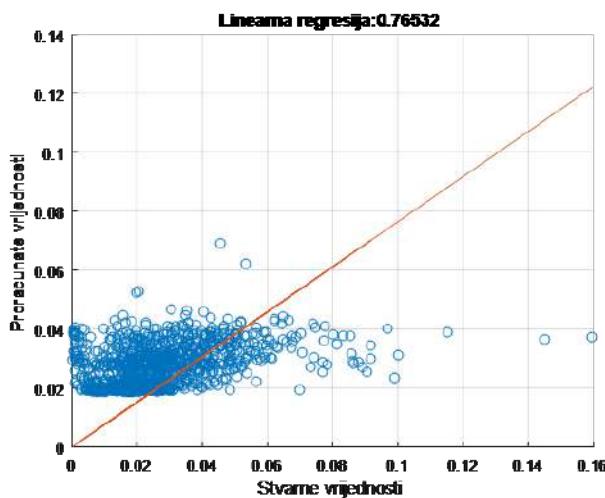
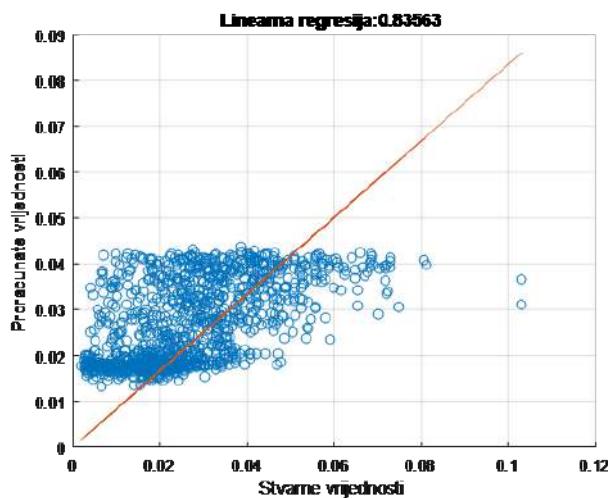
$$Y = k_1x_1 + k_2x_2 + k_3x_3 + k_4x_4 \quad (1)$$

gdje su: $k_1 \dots k_4$ - koeficijenti koji su dati u tabeli 2, x_1 - temperatura, x_2 - pritisak, x_3 - relativna vlažnost, x_4 - brzina vjetra i Y - funkcija u zavisnosti od k i x kojom se određuje koncentracija NO_2 .

Treniranje neuronske mreže je pokazalo da 5 neurona u skrivenom sloju daje najbolje rezultate, a povećanje broja neurona u ulaznom i skrivenom sloju dovodi do usporenje procesa analize. Primjetno je da model neuronske mreže ne prati dobro vršne vrijednosti

Table 2. Koeficijenti u analitičkom izrazu modela za odgovarajuću mjernu stanicu

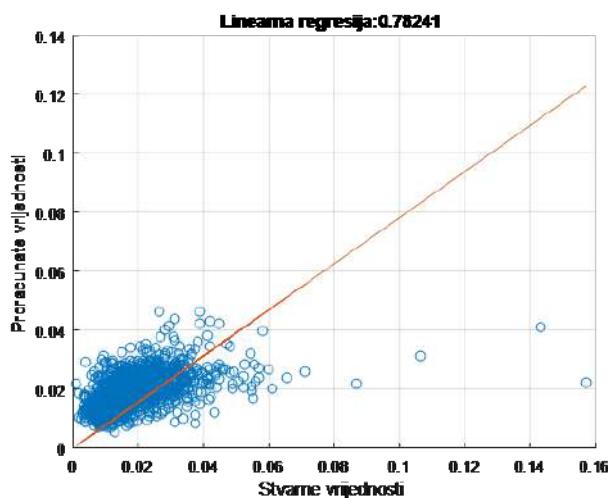
	k_1	k_2	k_3	k_4
Skver	-	0.008819272404390	0.050059728396524	0.014516838248407
BKC	-	0.011303568752086	0.060034610219301	0.023116019965790
Bukinje	-	0.007789909311929	0.041908436528711	0.001493812940943

Slika 10. Linerna regresija za NO_2 na mjernoj stanici Skver.Slika 11. Linerna regresija za NO_2 na mjernoj stanici BKC.

ulaznih podataka, pa nije najpodesniji za predviđanje vremenskih serija, ali su postignuti rezultati zadovoljavajući, jer je analizirana velika količina ulaznih podataka. Razlog dobijanja dobrih rezultata pomoću neuronske mreže može biti i to, što raspoloživi ulazni podaci nisu širokog opsega.

4. ZAKLJUČCI

U radu je pokazano na primjeru Grada Tuzle, kako se koristeći meteorološke podatke i postojeće podatke monitoringa vazduha, za jedan duži vremenski period, uz pomoć metoda vještacke inteligencije mogu dobiti pouzdani modeli sa veoma visokim koeficijentima korelacije za predviđanje koncentracija zagadjujućih materija. Statičkim metodama utvrđena je korelacija između zagađujuće materije NO_2 i uticajnih parametara, meteoroloških faktora. Značajan koeficijent korelacije u odnosu na temperaturu potvrđuje postojanje linearne zavisnosti u odnosu na ovaj najuticajniji faktor u vremenskom modelu. Korištenjem neuronskih mreža razvijen je i testiran jedinstven model za predviđanje koncentracija NO_2 u vazduhu u Gradu Tuzla sa zadovoljavajućom regresijom dobivenih proračunatih podataka u odnosu na poznate podatke u posmatranom vremenskom periodu od 8 godina. Dobijeni rezultati, za posmatrani vremenski period, u poređenju sa

Slika 12. Linerna regresija za NO_2 na mjernoj stanici Bukinje.

rezultatima drugih autora su zadovoljavajući (Abd Rahman, Lee, Latif, & Suhartono 2013; Chaloulakou, Saisana, & Spyrellis 2003; Dedovic, Avdakovic, Turkovic, Dautbasic, & Konjic 2016; Lal Benjamin, Sharma, Pendharker, & Srivastava 2014; Pandey, Srivastava, Sharma, & Srivastava 2014; Vlachogianni, Kassomenos, Karppinen, Karakitsios, & Kukkonen 2011). Na osnovu dobivenih grafičkih i analitičkih rezultata moguće je definisati mjere koje

će dovesti do ispunjavanja zahtjeva o graničnim i tolerančnim vrijednostima čija bi implementacija imala veliki doprinos za poboljšanje kvaliteta vazduha i smanjenjem štetan utjecaj na okolinu i zdravlje ljudi u Gradu Tuzli. Nadležne institucije vrše mjerena i objavljaju rezultate, ali ne vrše analizu rezultata kako bi prognozirali situaciju u budućnosti i pripremili konkretnu strategiju preventivnog djelovanja u cilju smanjenja rizika po zdravlje građana i zadovoljavanja postavljenih graničnih vrijednosti u važećim pravilnicima. Ovakav koncept, uz primjenu metoda vještačke inteligencije, može se koristiti i u drugima gradovima u BiH i šire, a njegovu primjenu je moguće proširiti i na druge segmente životne sredine gdje je razvijen monitoring. Modeli dobiveni korištenjem vještačkih neuronskih mreža mogu se uzeti u obzir kao pouzdani pristup u sistemu ranog upozoravanja javnosti o kvalitetu vazduha, stanju kvaliteta vazduha koji bi mogao utjecati na njihovo zdravlje, a takođe u procesima donošenja strateških odluka i akcija kontrole i upravljanja kvalitetom vazduha.

LITERATURA

- (n.d.). *Službene novine Federacije BiH*, 1(12).
- Abd Rahman, N. H., Lee, M. H., Latif, M. T., & Suhartono, S. (2013). Forecasting of air pollution index with artificial neural network. *Jurnal Teknologi*, 63(2).
- Agić, D. (2020). *Modeliranje parametara kvaliteta vazduha urbanog područja korištenjem metoda vještačke inteligencije* (Unpublished doctoral dissertation). Univerzitet u Istočnom Sarajevu, Tehnološki fakultet Zvornik.
- Chaloulakou, A., Saisana, M., & Spyrellis, N. (2003). Comparative assessment of neural networks and regression models for forecasting summertime ozone in athens. *Science of the Total Environment*, 313(1-3), 1-13.
- Dedovic, M. M., Avdakovic, S., Turkovic, I., Dautbasic, N., & Konjic, T. (2016). Forecasting pm10 concentrations using neural networks and system for improving air quality. In *2016 xi international symposium on telecommunications (bihTEL)* (pp. 1-6).
- Deleawe, S., Kusznir, J., Lamb, B., & Cook, D. J. (2010). Predicting air quality in smart environments. *Journal of ambient intelligence and smart environments*, 2(2), 145-154.
- Dragomir, E. G. (2010). Air quality index prediction using k-nearest neighbor technique. *Bulletin of PG University of Ploiești, Series Mathematics, Informatics, Physics*, LXII, 1(2010), 103-108.
- Federalni hidrometeorološki zavod bih (Tech. Rep.). (n.d.). <http://www.fhmzbih.gov.ba/latinica/vazduh/izvjestaji.php>
- Gaffin, J. M., Hauptman, M., Petty, C., Sheehan, W., Lai, P., Wolfson, J., ... Phipatanakul, W. (2018). Nitrogen dioxide exposure in school classrooms of inner-city children with asthma. *J. Allergy Clin. Immunol.*, 141, 2249-2255. <https://doi.org/10.1016/j.jaci.2017.08.028>
- Ghazali, S., & Ismail, L. H. (2011). Air quality prediction using artificial neural network.
- Gori, M. (2017). *Machine learning: A constraint-based approach*. Morgan Kaufmann.
- Ilić, V. (n.d.). *Neuronske mreže*. <http://solair.eunet.rs/~ilicv/neuro.html#Model%20mreze>
- Kurt, A., Gulbagci, B., Karaca, F., & Alagha, O. (2008). An online air pollution forecasting system using neural networks. *Environment international*, 34(5), 592-598.
- Kvalitet vazduha u tuzlanskom kantonu - stranica ministarstva prostornog uređenja i zaštite okoline tk.* (n.d.). <http://www.monitoringvazduhatk.info>
- Lal Benjamin, N., Sharma, S., Pendharker, U., & Shrivastava, J. (2014). Air quality prediction using artificial neural network. *IJCS*, 2(4), 07-09.
- Paas, B., Stienen, J., Vorländer, M., & Schneider, C. (2017). Modelling of urban near-road atmospheric pm concentrations using an artificial neural network approach with acoustic data input. *Environments*, 4(2), 26.
- Pandey, S., Srivastava, A., Sharma, A. K., & Srivastava, J. (2014). Modeling of ambient for rspm and spm pollutants through artifical neural network in sensitive area of ujjain city. *I Control Pollution*, 30(1).
- Vlachogianni, A., Kassomenos, P., Karppinen, A., Karakitsios, S., & Kukkonen, J. (2011). Evaluation of a multiple regression model for the forecasting of the concentrations of nox and pm10 in athens and helsinki. *Science of the total environment*, 409(8), 1559-1571.