

Džemila Agić<sup>1\*</sup>, Halid Makić<sup>2</sup>, Miladin Gligorić<sup>3</sup>, Sejfudin Agić<sup>4</sup>

<sup>1</sup>Centar za ekologiju i energiju, Tuzla, BiH, <sup>2</sup>Univerzitet u Bihaću, Biotehnički fakultet, Bihać, BiH, <sup>3</sup>Univerzitet u Istočnom Sarajevu, Tehnološki fakultet Zvornik, Zvornik, BiH, <sup>4</sup>Elektrotehnička škola u Tuzli, Tuzla, BiH

Naučni rad

ISSN 0351-9465, E-ISSN 2466-2585

UDC: 502.3:504.5:621.43.064:  
004.81:159.953.5

doi:10.5937/zasmat2001019A



Zastita Materijala 61 (1)  
19 - 30 (2020)

## Modeliranje koncentracija lebdećih čestica urbanog područja korištenjem metoda vještačke inteligencije

### IZVOD

*U radu su razvijeni jedinstveni i pouzdani modeli za predviđanje PM<sub>2,5</sub> za Grad Tuzla na osnovu postojećih rezultata monitoringa PM<sub>2,5</sub> i meteoroloških podataka (pritisak, temperatura, vjetar i vlažnost vazduha) korištenjem statističkih metoda i metoda modeliranja neuronskim mrežama i genetskog programiranja.*

*Dokazana je korelacija između koncentracije zagađujućih materija te uticajnih (meteo) faktora kao što su temperatura i vjetar.*

*Razvijeni modeli se mogu koristiti za predviđanje koncentracija PM<sub>2,5</sub> u cilju ranog upozoravanja i zaštite javnosti od štetnog uticaja zagađenog vazduha na zdravlje ljudi. Rezultati dobijeni korištenjem ovih modela se mogu koristiti u procesima donošenja strateških odluka i aktivnosti vezanih za kontrolu i upravljanje kvalitetom vazduha.*

*Modeliranje koncentracije lebdećih materija u urbanim područjima je vrlo značajno za područja gdje se vrši redovno mjerjenje, međutim često nedostaju mjerena prisustva zagađujućih materija.*

*U slučaju da dođe do kratkog ili dužeg prekida mjerena koncentracija zagađujućih materija za Grad Tuzlu, uz pomoć modela, koji su rezultat ovog rada, se može uraditi predviđanje koncentracija zagađujućih materija i na osnovu njih planirati preduzimanje mjera.*

**Ključne riječi:** zagađenje vazduha, monitoring vazduha, neuronske mreže, genetsko programiranje.

### 1. UVOD

Radi boljeg uvida u koncentraciju zagađujućih materija, informisanje građana, zaštite njihovog zdravlja i očuvanja okoline, 2003. godine je u Gradu Tuzla postavljeno 5 imisionih mjernih stanica za, monitoring vazduha i mjerjenje: sumporodiksida (SO<sub>2</sub>), azotnih oksida (NO<sub>x</sub>), lebdećih čestica (PM<sub>2,5</sub>), ugljen-monoksida (CO) i ozona (O<sub>3</sub>). Prema podacima dobijenim iz 5 mjernih stanica, koncentracije SO<sub>2</sub> i PM<sub>2,5</sub> su uglavnom prelazile granične vrijednosti, dnevne: za SO<sub>2</sub> od 125 µg/m<sup>3</sup> dok za PM<sub>2,5</sub> nisu definisane vrijednosti i godišnje: za SO<sub>2</sub> od 50 µg/m<sup>3</sup> i za PM<sub>2,5</sub> od 25 µg/m<sup>3</sup>, a posebno pragovi upozorenja i uzbune, naročito u zimskom periodu.

Pošto koncentracije PM<sub>2,5</sub> zauzimaju vodeću poziciju među zagađujućim materijama i po štetnosti po zdravlje te učestalosti i intenzitetu prelaženja graničnih vrijednosti ovaj rad će se posvetiti njihovoj detaljnoj analizi i prezentaciji rezultata za mernu stanicu Skver, koja se nalazi u centru Grada Tuzla.

U radu je izvršeno modeliranje eksperimentalnih rezultata statističkim metodama na vremenskim serijama poznatih podataka za PM<sub>2,5</sub> za period od 8 godina, od 2010. do 2017. godine. Matematičko modeliranje je u obzir uzelo uticajne faktore, konkretno meteorološke parametre, na koncentraciju PM<sub>2,5</sub> u vazduhu.

Primjenjene metode modeliranja i predviđanja korištene u ovom radu spadaju u grupu metoda iz područja vještačke inteligencije, a široko su zastupljene u ovakvim i sličnim eksperimentalnim istraživanjima [1-3,5]. Dvije metode koje su korištene u radu jesu metoda vještačkih neuronskih mreža i metoda genetskog programiranja.

\*Autor za korespondenciju:Džemila Agić

E-mail: dzemila.agic@bih.net.ba

Rad primljen: 15. 09. 2019.

Rad prihvaćen: 12.11. 2019.

Rad je dostupan na sajtu: [www.idk.org.rs/casopis](http://www.idk.org.rs/casopis)

## 2. EKSPERIMENTALNI DIO

Za predviđanje kvaliteta vazduha postoji veći broj tehnika od vrlo jednostavnih do vrlo kompleksnih. Većina tehnika predviđanja kvaliteta vazduha opisane su u izvještaju U.S. EPA (1999) [1,2].

Za predviđanje zagađenja korišteni su modeli vremenskih serija i modeli u odnosu na uticajne faktore, meteoroloških parametara kvaliteta vazduha [3,4,6,7].

Istraživanje je obuhvatilo modeliranje parametara kvaliteta vazduha, koji su mjereni tokom 8 godina, od 2010. do 2017. godine, na izabranoj imisionoj mjernoj stanicu Skver u Gradu Tuzla, meteoroloških faktora, topografskih varijacija i sl. na osnovu kojih je korištenjem metoda vještačke inteligencije dat model pomoću kojeg se predviđaju koncentracije zagađujućih materija u narednom periodu.

U radu su korišteni softveri:

- Statistička analiza vremenskih serija: *Microsoft Excel*, for Mac, Version 15.25 (160630)
- Neuronske mreže: *MATLAB and Neural Network toolbox*, Release 2015a [[http://ch.mathworks.com/products/new\\_products/release/2015a.html](http://ch.mathworks.com/products/new_products/release/2015a.html)]
- Genetsko programiranje: *GPdotNET* alata za modeliranje, optimizaciju i predikciju pomoću evolucionih algoritama [<http://gpdotnet.codeplex.com>, zadnja posjeta 19.06. 2017.]

Glavni razlog analize modela vremenskih serija, računanjem prosječne vrijednosti i standardne devijacije i linearne i regresivne korelacije je da se u dostupnim podacima odredi veza između podataka i uticajnih faktora.

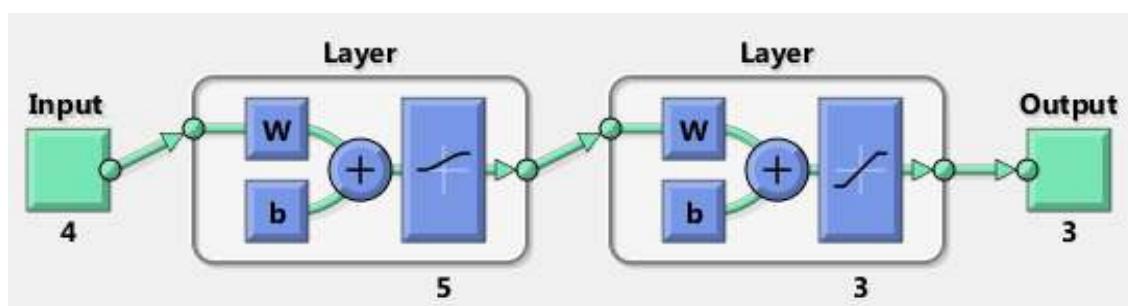
Potvrđena je relevantnost postojećih podataka kao elemenata vremenske serije, izračunati su koeficijenti regresije svih uticajnih faktora koji su bili smjernica u daljem istraživanju.

Kombinacija „naučnog nadzora“ kvaliteta vazduha i sistema ranog upozorenja je efikasan način da se objektivno ocjeni stepen zagađenja vazduha i precizno predvide koncentracije zagađujućih materija. Međutim, integracija procjene kvaliteta vazduha i predviđanja koncentracije zagađujućih materija u vazduhu kako bi se uspostavio sistem kvalitet vazduha nije uobičajen u našem okruženju pa i šire [4].

Nakon identifikovanja uticajnih faktora i ulaznih podataka od interesa za analizu statisitčkom obradom, urađeno je modeliranje podataka metodom vještačkih neuronskih mreža.

Izgrađena je nerekurzivna, direktna (feedforward) neuronska mreža koja je najčešći korišten model za rješavanje nelinearnih klasifikacionih i regresionih zadataka.

Struktura neuronska mreža za mjernu stanicu Skver ima 4 ulaza, 5 neurona u skrivenom sloju (zbog validacija nije potrebno više jer se brzo zaustavi treniranje) i 3 neurona u izlaznom sloju. Model neuronske mreže je prikazan na slici 1.



Slika 1. Struktura neuronske mreže za Skver

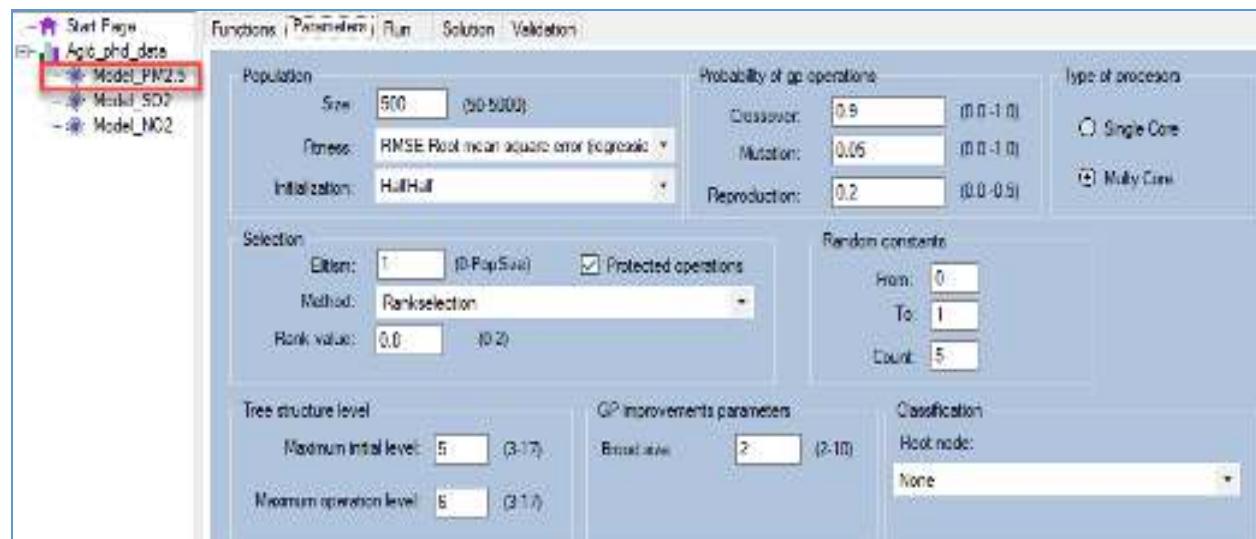
Figure 1. Structure of a neural network for Skver

Na kraju izvršena je analiza rezultata modela dobijenih sa vještačkim neuronskim mrežama i modela dobijenih genetskim programiranjem.

Na slici 2 se vide parametri koji su uzeti za analizu modela za lebdeće čestice PM<sub>2,5</sub> metodom genetskog programiranja.

Skup funkcija  $F=\{+,-,\times,/, \sin\}$ ,

Očekivano su dobijeni rezultati predikcije, za 2017. godinu, znatno bolji nego kod neuronskih mreža uz Pearsonov koeficijent od 0.973, kako je prikazano na slici 13.

Slika 2. Parametri u analizi genetskim programiranjem za PM<sub>2.5</sub>Figure 2. Parameters in genetic programming analysis for PM<sub>2.5</sub>

### 3. REZULTATI I DISKUSIJA

Na osnovu detaljnog uvida u rezultate mjeranja na imisionoj mjernoj stanici Skver u 2017. godini

vidi se da veliki problem predstavljaju povećane koncentracije PM<sub>2.5</sub>, jer prelaze predviđene satne, dnevne i godišnje granične vrijednosti.

Tabela 1. Prikaz statističkih pokazatelja koncentracija lebdećih čestica PM<sub>2.5</sub> za mjernu stanicu Skver u 2017. Godini

Table 1. The overview of Statistical Indicators PM<sub>2.5</sub> concentration of particles in measuring unit Square 2017

Mjerna stanica	Obuhvat validnih mjerena [%]	Srednja godišnja konc. PM <sub>2.5</sub> [µg/m <sup>3</sup> ]	Maksimalna satna konc. u [µg/m <sup>3</sup> ]	Maksimalana dnevna konc. u toku godine [µg/m <sup>3</sup> ]	Broj prekoračenja dnevne granične vrijednosti tokom godine [>50 µg/m <sup>3</sup> ]	Broj prekoračenja dnevne tolerantne vrijednosti tokom godine [>62 µg/m <sup>3</sup> ]
Tuzla Skver	93	46	659	360	96	76

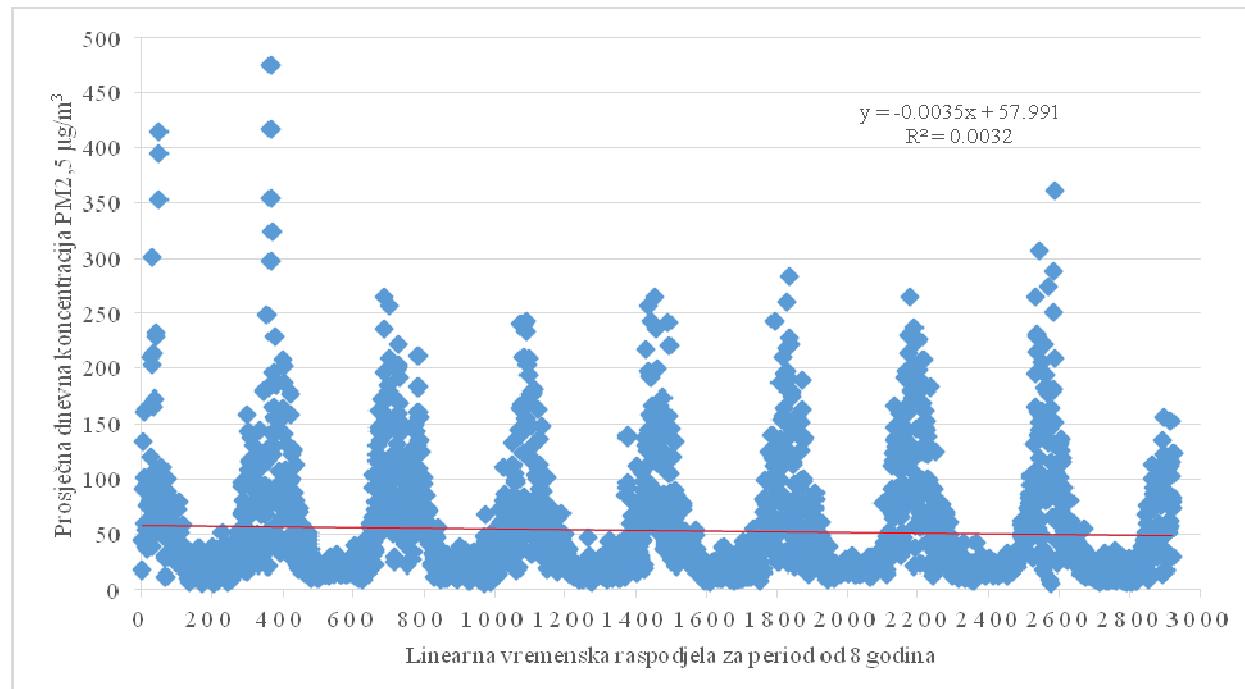
#### 3.1. Linearna i regresivna korelacija za PM<sub>2.5</sub>

U okviru istraživanja izvršena je analiza linearnih i regresivnih modela za mjernu stanicu Skver za PM<sub>2.5</sub>. Statistička analiza se bazirala na pretpostavci o normalnoj raspodjeli dvodimenzionalne promjenljive ( $X, Y$ ). Predmet analize su bili koeficijenti korelacijske, kao mera jačine i pokazatelj pozitivne ili negativne korelacijske.

U nastavku su pojedinačno predstavljeni linearni modeli korelacijske i izračunat koeficijent korelacijske za prosječne dnevne koncentracije PM<sub>2.5</sub> izmjerene na mjernoj stanicu Skver.

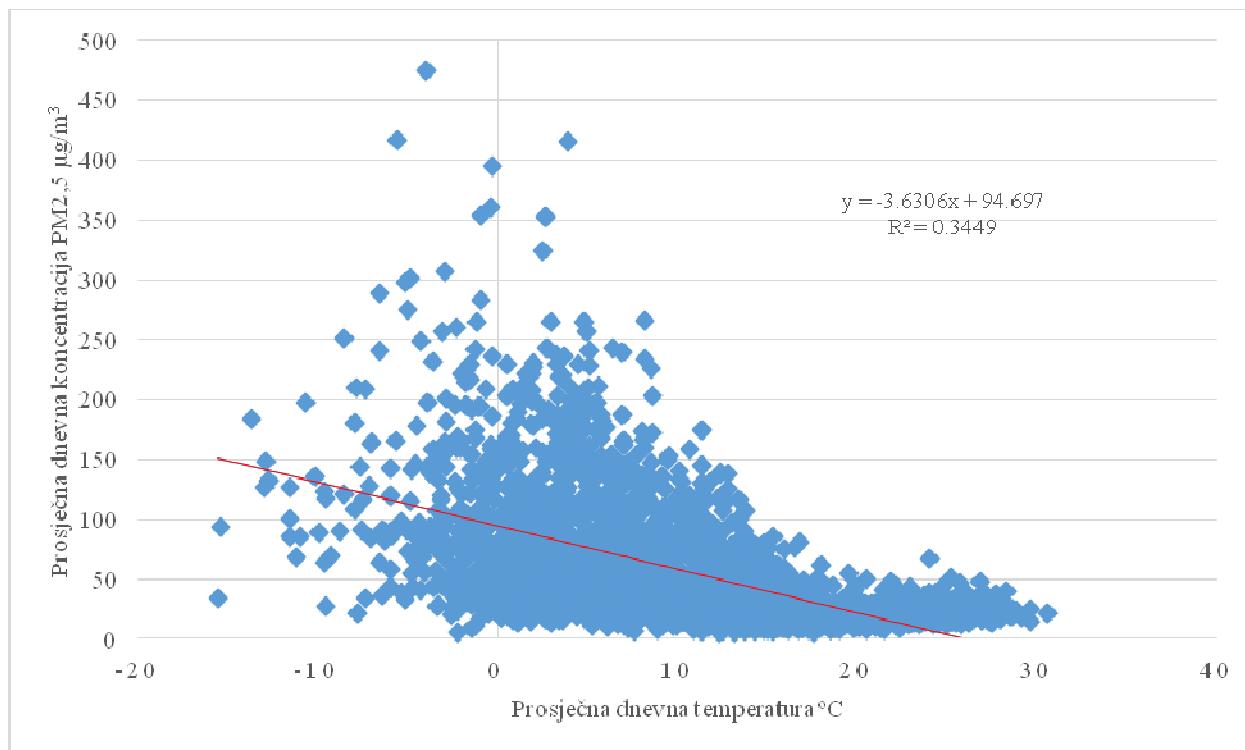
Na slici 3 je grafički prikazan linearni model koncentracije PM<sub>2.5</sub> na mjernoj stanicu Skver od početka 2010. do kraja 2017. godine. Izračunati koeficijent korelacijske iznosi  $r_{xy} = -0,05681$ .

Na slici 4 su prikazani rezultati analize regresivnog modela za prosječne dnevne koncentracije PM<sub>2.5</sub> na mjernoj stanicu Skver od početka 2010. do kraja 2017. godine u odnosu na temperaturu. Izračunati koeficijent korelacijske iznosi  $r_{xy} = -0,58728$  i statistički je značajan [5].



Slika 3. Analiza linearne modela koncentracija PM<sub>2.5</sub> na mjernoj stanici Skver za period 2010-2017.

Figure 3. Analysis of the linear models of PM<sub>2.5</sub> concentration at Skver metering station for the period 2010-2017 year



Slika 4. Analiza regresivnog modela koncentracija PM<sub>2.5</sub> na mjernoj stanici Skveru odnosu na temperaturu za period 2010-2017.

Figure 4. Analysis of the regression model of PM<sub>2.5</sub> concentrations at Skver metering station in relation to temperature for the period 2010-2017. year

Izračunate vrijednosti koeficijenata korelacije, pod pretpostavkom normalne raspodjele dvodimenzionalne promjenljive, za mjeru stanicu Skver nalaze se u tabeli 2.

*Tabela 2. Vrijednosti koeficijenta korelacijske za mjerne stanice Skver*

Table 2. The values of the correlation of coefficients for the metering unit Skver

Mjerna stanica Skver					
	Linerna raspodjela	Brzina vjetra m/s	Rel. vlažnost %	Pritisak vazduha hPa	Temperatura °C
PM <sub>2,5</sub>	-0,05681	-0,06696	0,20873	0,23183	<b>-0,58728</b>

Utvrđeno je postojanje korelacije između PM<sub>2,5</sub> i temperaturom u iznosu 0,58728. Iz statističke teorije se zna da veća vrijednost koeficijenta korelacije nije dokaz da između posmatranih promjenljivih postoji suštinska veza, ali može biti važan putokaz u daljem izražavanju softverskim metodama [5–9].

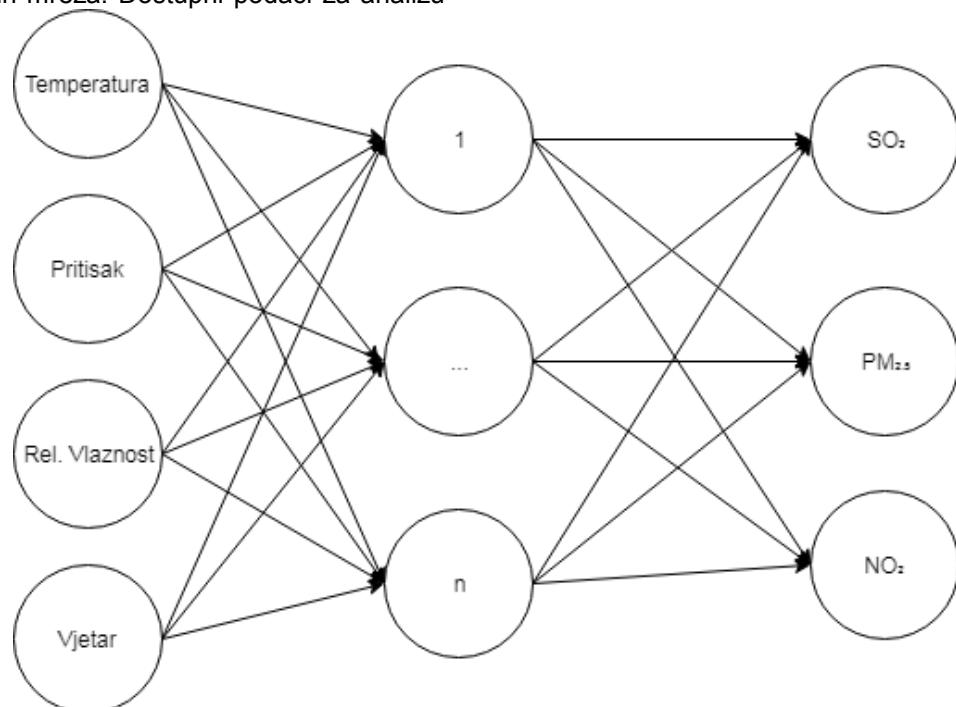
### 3.2. Analiza koncentracija lebdećih čestica primjenom neuronskih mreža

Za analizu i predikciju PM<sub>2,5</sub> korišten je programski alat Matlab, Release 2015a. Taj programski alat sadrži paket koji se naziva Neural Network toolbox koji može obavljati zadatak treniranja i analize neuronskih mreža. Dostupni podaci za analizu

su prosječne dnevne vrijednosti za meteorološke podatke od 2010. do 2017. godine, odnosno temperatura, pritisak, relativna vlažnost vazduha, vjetar i prosječne dnevne vrijednosti SO<sub>2</sub>, NO<sub>2</sub> i PM<sub>2,5</sub> sa mjerne stanice Skver.

Za ulaze podatke su korišteni meteorološki podaci (temperatura, pritisak, vlažnost i vjetar), dok su izlazi SO<sub>2</sub>, PM<sub>2,5</sub> i NO<sub>2</sub>. Na slici 5 je prikazan model takve neuronske mreže.

U ulaznom sloju neuronske mreže se nalaze temperatura, pritisak, vlažnost i vjetar, u skrivenom sloju je n broj neurona koji se određuje testiranjem i u izlaznom sloju SO<sub>2</sub>, PM<sub>2,5</sub> i NO<sub>2</sub>. Na taj način se dobija model neuronske mreže kao na slici 5.



*Slika 5. Model neuronske mreže za mjeru stanicu Skver sa 4 ulaza i 3 izlaza*

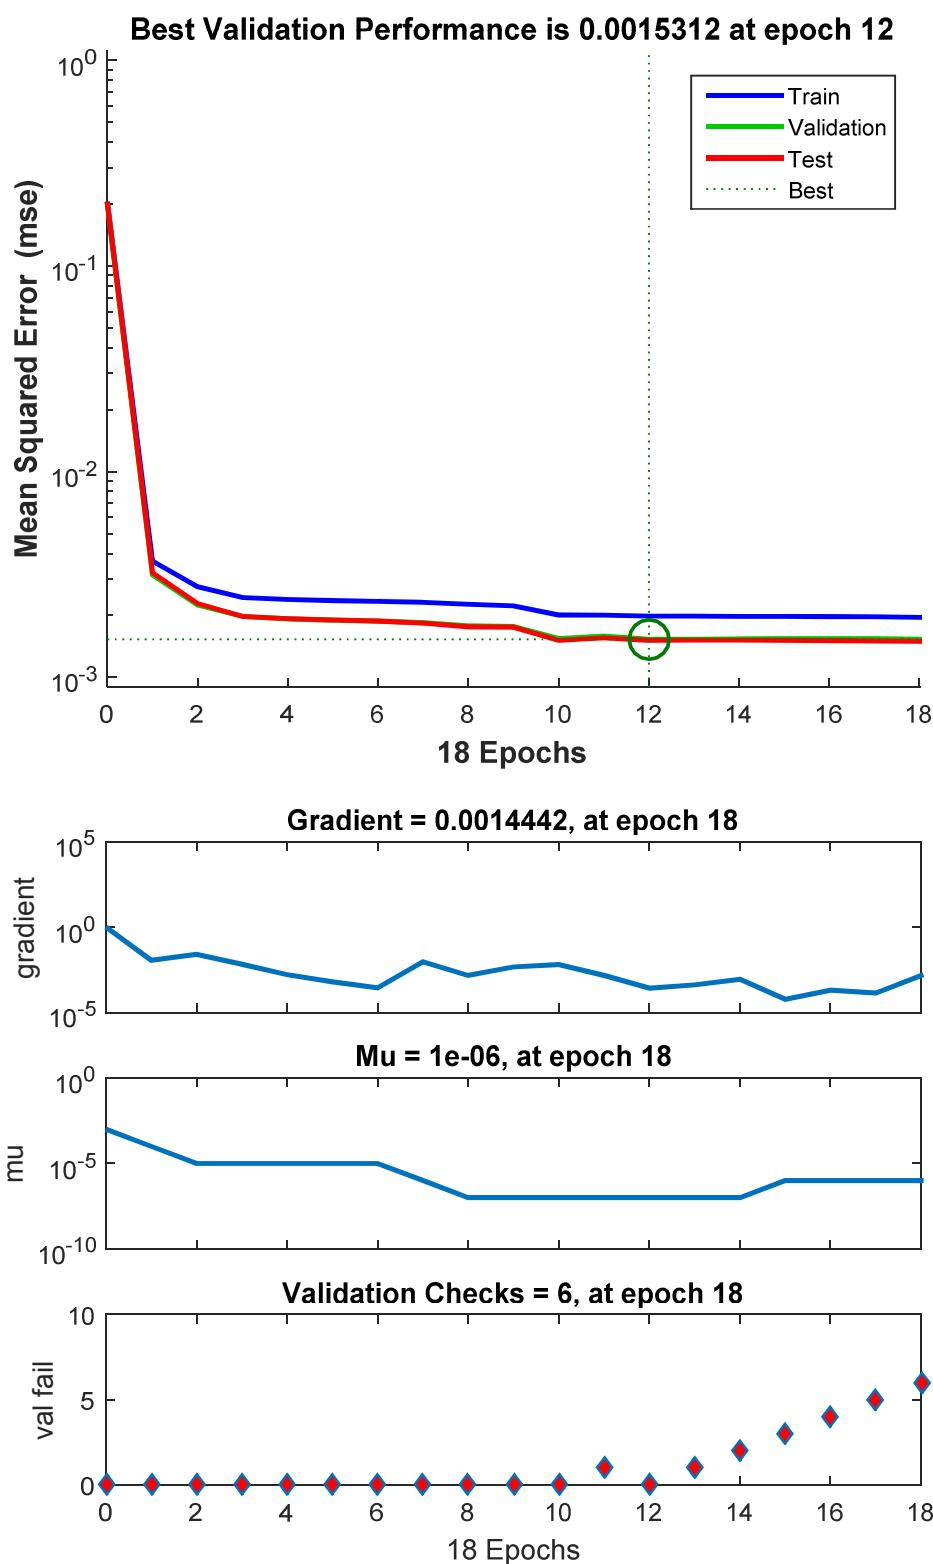
Figure 5. A neural network model for the Skver metering station with 4 inputs and 3 outputs

Nakon normalizacija i transformacija podataka sa ciljem da se dobijaju bolje performanse neuronske mreže pristupilo se treniranju same

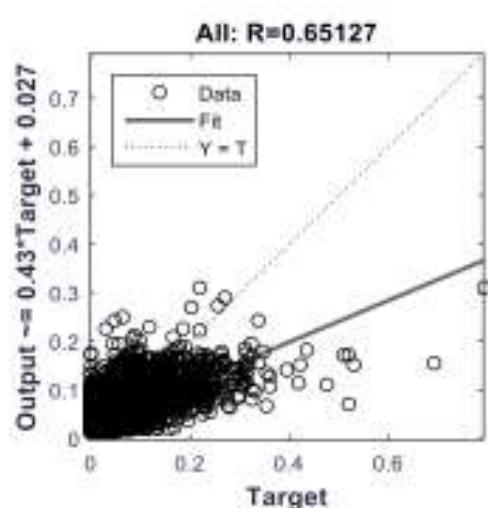
mreže, analizi uticaja pojedinih meteoroloških parametara i pronalasku načina za predikciju podataka u budućnosti.

Dostupni podaci su podijeljeni na set podataka za treniranje i set podataka za testiranje, (60%: 40%).

Performanse treniranja neuronske mreže za mjernu stanicu Skver prikazani su na slici 6.



Slika 6. Performanse treniranja neuronske mreže za mjernu stanicu Skver  
Figure 6. Neural Network Coaching Performance for the Skver Meter



Slika 7. Regresija tokom treniranja neuronske mreže

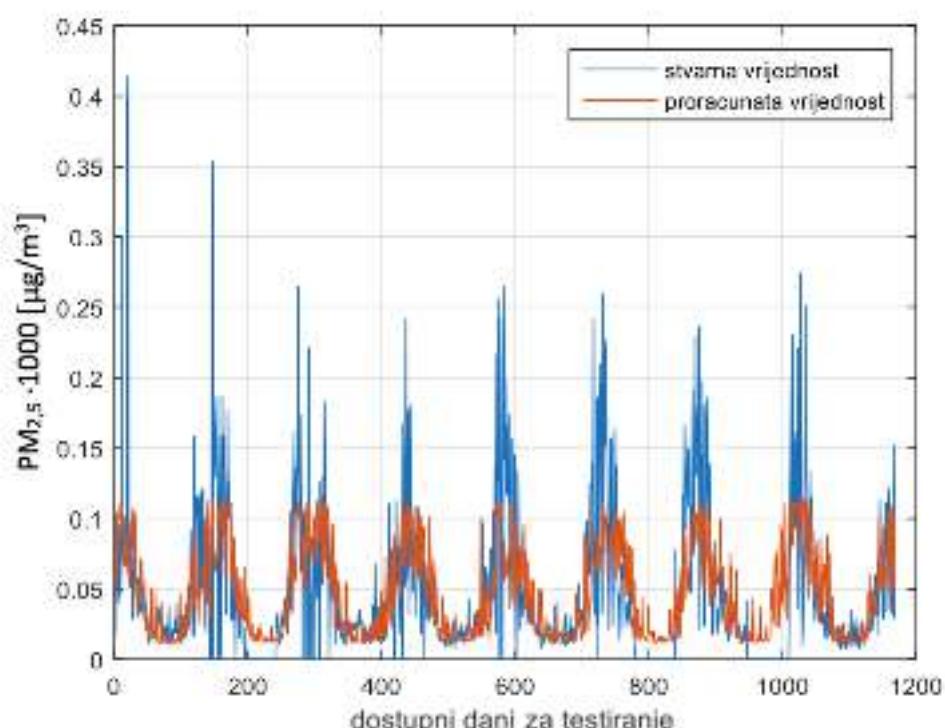
Figure 7. Regression during neural network training

Sa slike 6 se uočava da mreža sa 5 neurona u skrivenom sloju daje najbolje rezultate od 12. epohe ali se zbog validacija zaustavlja na 18. epohi. Regresija za ovaku mrežu iznosi 0.65127 kako je prikazano na slici 7.

### 3.3. Testiranje neuronske mreže za Skver

Nakon treniranja, kako je opisano, pristupa se testiranju dobijene mreže. U ovom slučaju koristi se ranije dobijena varijabla *testInd*, odnosno dobijeni set podataka od 40% ulaznih podataka ( $0,4 \cdot 2.922$  dana  $\approx 1.169$  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.

Korištenjem funkcije *plot* u Matlabu za stvarne i proračunate vrijednosti za svaki izlaz iz mreže dobije se dijagram na slici 8.



Slika 8. Poređenje proračunatih i tačnih vrijednosti za PM<sub>2.5</sub>

Figure 8. Comparison of calculated and accurate values for PM<sub>2.5</sub>

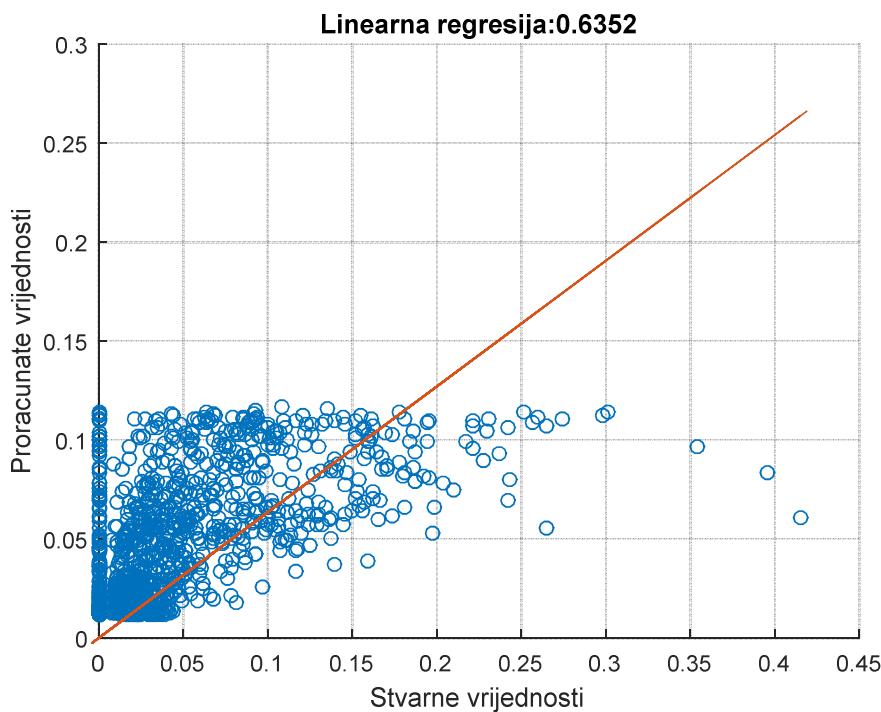
Za provjeru kvaliteta dobijenih rezultata bilo je potrebno proračunati regresiju kao odnos tačnih vrijednosti i proračunatih vrijednosti. Za ovu svrhu je napravljena skripta u Matlabu koja se zove *calc\_regression*. Izvršavanjem te skripte dobijaju se rezultati kao na slici 9.

Vrijednost parametra MSE za treniranu mrežu, za mjernu stanicu Skver je iznosila:

TRAINLM, Epoch 0/18, MSE 0.0107220/0

TRAINLM, Epoch 6/18, MSE 0.0071907/0

TRAINLM, Epoch 12/18, MSE 0.0015312/0

Slika 9. Linerna regresija za PM<sub>2.5</sub>Figure 9. Linear regression for PM<sub>2.5</sub>

Na osnovu smanjenja iznosa vrijednosti parametra MSE za mjernu stanicu Skver u različitim epohama se dolazi do zaključka da neuronska mreža učenjem kroz epohe poboljšava rezultate, odnosno svoje znanje.

#### 3.4. Predikcija vrijednosti PM<sub>2.5</sub>

Za dobijenu neuronsku mrežu postavlja se pitanje da li može da predviđa izlazne vrijednosti u budućnosti. Može se napraviti nova neuronska mreža čiji bi zadatak bio samo predikcija na osnovu prethodnih podataka. Međutim ovo rješenje nije zadovoljavajuće za ovaj rad i problem koji se rješava jer ulazni podaci (temperatura, pritisak, vlažnost i vjetar) ne bi imali uticaja na takve izlazne rezultate.

Trenutna vrijednost vremenske serije se može predstaviti kao:

$$X_t = k_1 X_{t-1} + k_2 X_{t-2} + \dots + k_n X_{t-n}$$

gdje je:

$x_t$  trenutna vrijednost,  $k_1 \dots k_n$  koeficijenti koji se računaju,  $x_{t-1} \dots x_{t-n}$  prethodne vrijednosti,  $n$  posmatrani broj prethodnih vrijednosti

Na osnovu relacije može se trenutna vrijednost dobiti kao funkcija prethodnih vrijednosti, tako da ukoliko se posmatra period npr. od 7 dana i prepo-

stavi se da je trenutno 30.01.2018, tada će jednačina za računanje dana unaprijed biti:

$$X_{31.01.2018} = k_1 X_{30.01.2018} + k_2 X_{29.01.2018} + k_7 X_{29.01.2018}$$

Na ovaj način se može računati predikcija mjeseca dana (ili više) unaprijed.

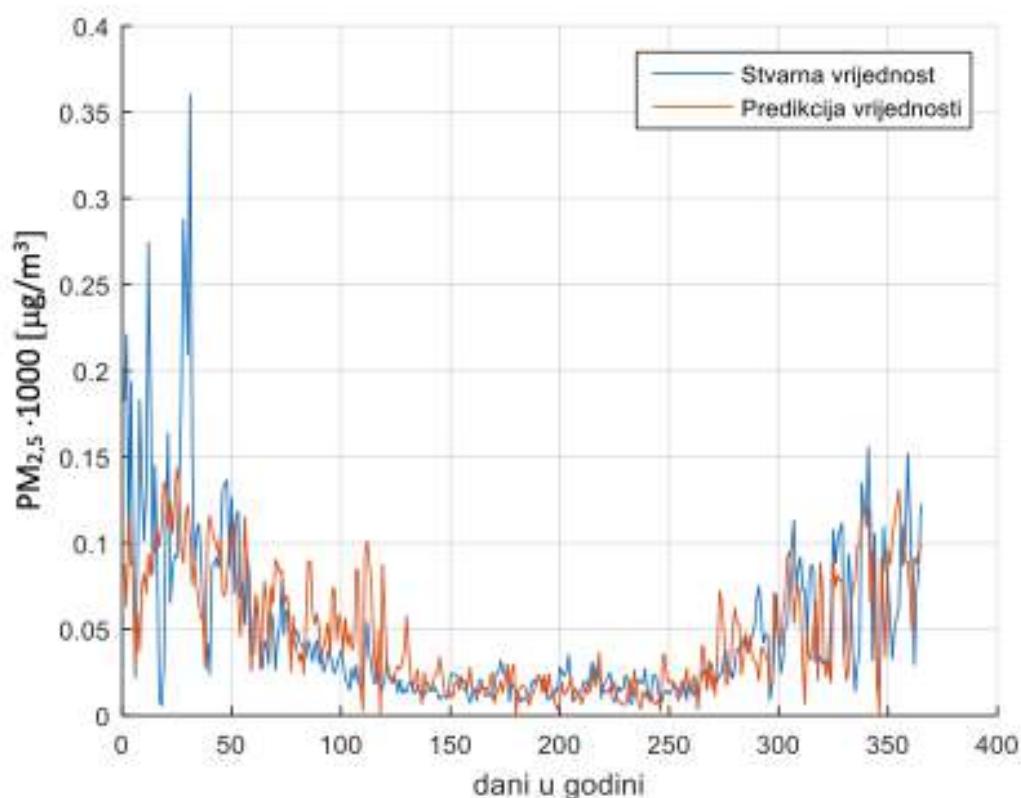
Prije nego se pristupi izradi novih modela neuronskih mreža, potrebno je provjeriti da li je već dobijena neuronska mreža sposobna za predikciju budućih vrijednosti PM<sub>2.5</sub>.

To će obaviti na način da se mreža istrenira sa podacima od 2010. do 2016. godine (uzima se slučaj da je trenutni datum 01.01.2017, tako mreža treba da "predviđa" vrijednosti u 2017. godini). Nakon treniranja, mreži će se proslijediti ulazni podaci iz 2017. godine (temp, pritisak, vlažnost i vjetar) a zatim uporediti dobijeni rezultati sa tačnim rezultatima.

#### 3.5. Testiranje modela neuronske mreže za predikciju

Model mreže je isti kao u ranije opisani (razlika je samo što 2017. godina nije uvrštena u set podataka za teniranje), te su zbog toga preskočeni dijagrami tokom treniranja mreže.

Nakon treniranja, mreži su proslijedeni ulazni podaci (temp, pritisak, vlažnost i vjetar) te su dobijeni rezultati poređeni sa pravim rezultatima.



Slika 10. PM<sub>2.5</sub> stvarna vrijednost i predikcija; linear regresija: 0.713425594934398

Figure 10. PM<sub>2.5</sub> real value and prediction; linear regression: 0.713425594934398

Na osnovu slike 10 može se zaključiti da mreža daje relativno dobre rezultate (regresija u svima slučajevima je preko 0.7) ukoliko joj se proslijede tačne vrijednosti ulaznih podataka.

Na pitanje da li neuronska mreža može predviditi vrijednosti PM<sub>2.5</sub> u budućnosti, može se odgovoriti da je mreža sposobna to uraditi ukoliko je moguće predvidjeti meteorološke podatke.

Tokom provedenih istraživanja dobijena je neuronska mreža koja može obavljati predikciju vrijednosti PM<sub>2.5</sub> za godinu dana unaprijed.

### 3.6. Predikcija meteoroloških podataka - temperatura

Logičan smjer istraživanja se pojavio sa pitanjem da li je moguća pouzdana predikcija meteoroloških podataka. Međutim, to je veoma zahtjevan zadatak jer ga je nemoguće tačno obaviti (čak i uz pomoć sofisticiranih uređaja) zbog same prirode tih podataka.

U dobijenim rezultatima prikazano je da predikcija mreže za zagađenje vazduha zavisi od pouz-

dane predikcije meteo parametara, tj. potrebno je na neki način dobiti te podatke. To se može riješiti na način da se za svaki parametar (temperatura, pritisak, vjetar i vlažnost) napravi neuronska mreža koja će predviđati te vrijednosti u željenoj budućnosti (npr 1 mjesec unaprijed).

## 4. REZULTATI PREDIKCIJA KVALITETA VAZDUHA GENETSKIM PROGRAMIRANJEM

Prilikom pripreme podataka i predikcije rezultata genetskim programiranjem (GP) su korišteni isti podaci monitoringa vazduha i meteorološki podaci za PM<sub>2.5</sub> za mjernu stanicu Skver kao i za metodu neuronskih mreža.

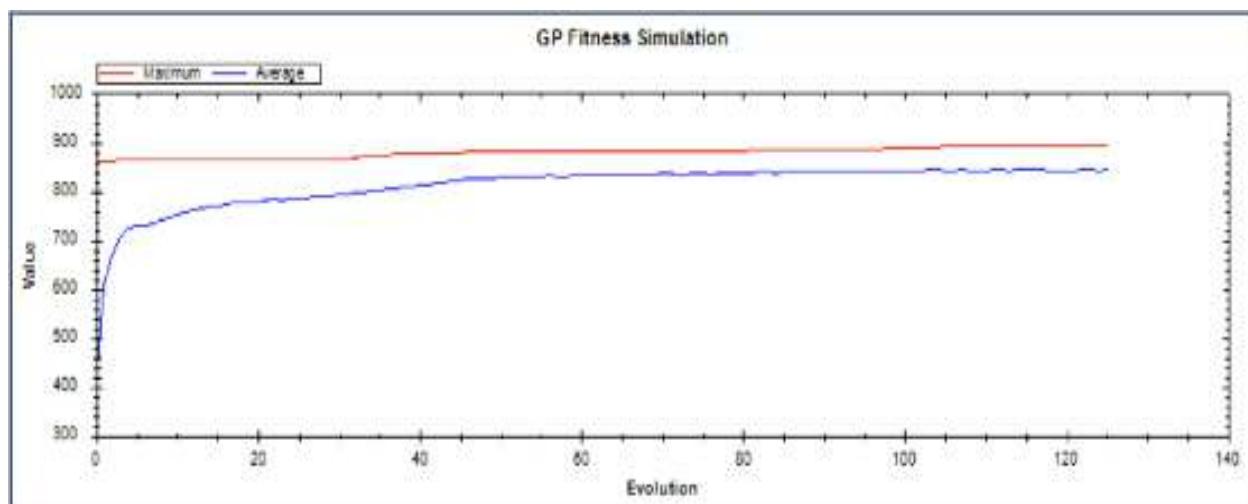
Svi podaci učitani su u GPdotNET – program za modeliranje i predikciju, formatirani i definisan je skup za testiranje koji je označavao vrijednosti za 2017. godinu. Kako se radi o mjesecnim podacima zadnjih 12 vrsta predstavljao je skup za testiranje.

Skup po kojim su trenirani svi modeli predstavljao je podatke od 2010. do 2016. godine dok je predikcija vršena za 2017. godinu.

#### 4.1. Izrada modela genetskim programiranjem za PM<sub>2,5</sub>

Analiziran je model za lebdeće čestice PM<sub>2,5</sub> sa već predstavljenim parametrima koji su uzeti za modeliranje genetskim programiranjem.

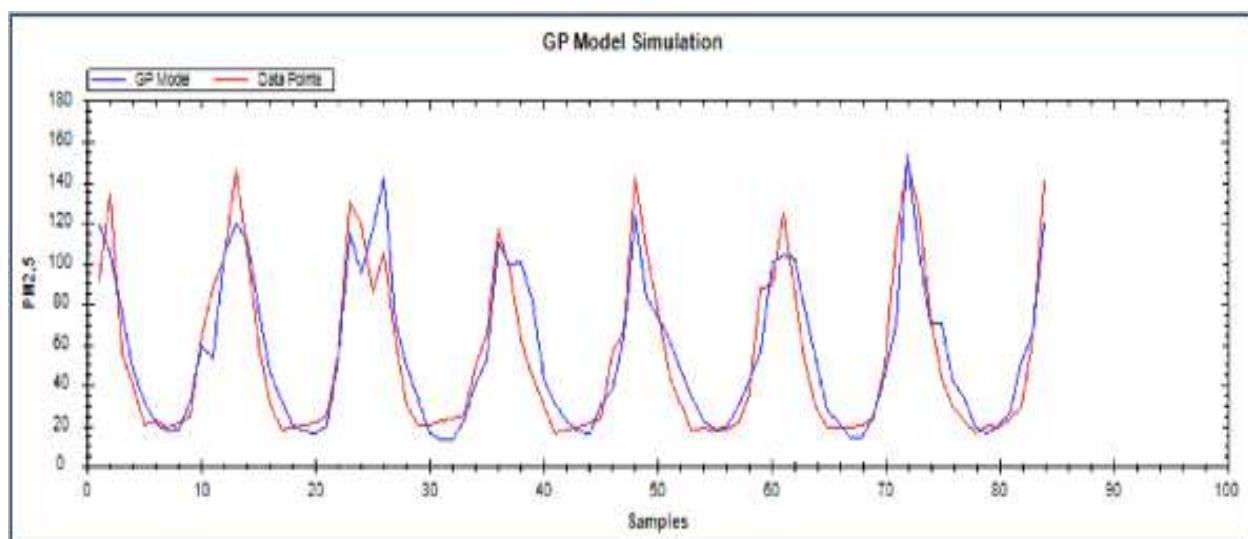
Kako se vidi na slici 11 model je dobijen u 125. iteraciji od ukupno 500 iteracija koliko je bilo zadano.



Slika 11. Evaluacija provedene simulacije

Figure 11. Evaluation of the simulation performed

Model koji je dobijen prikazan je na slici 12.



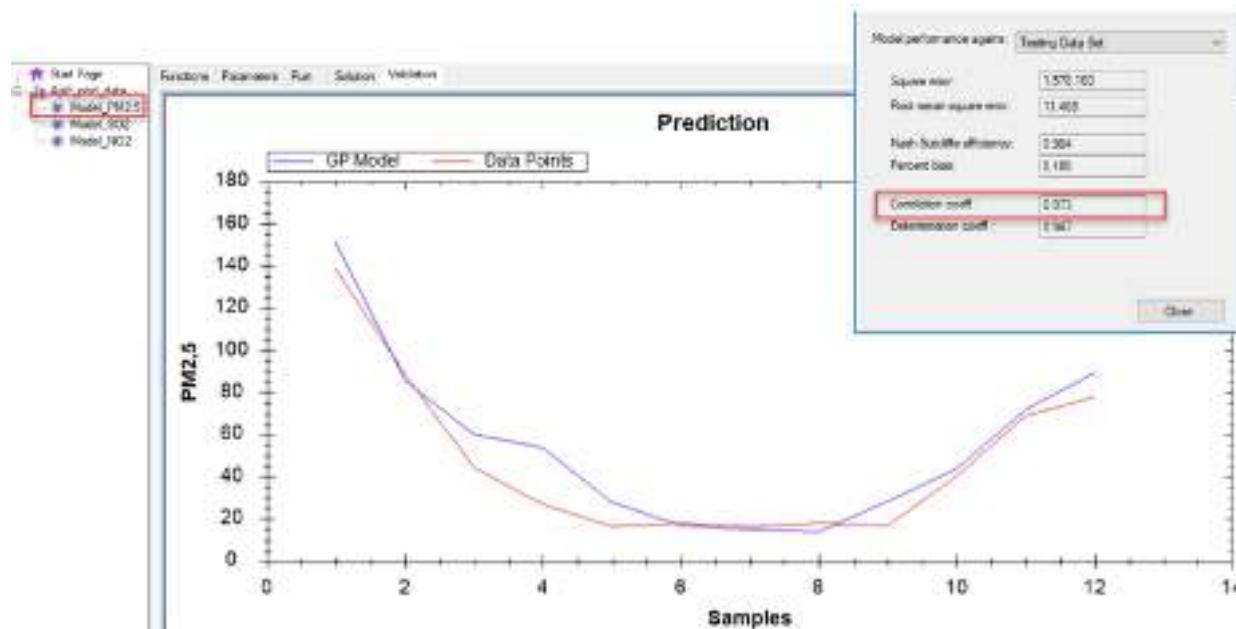
Slika 12. Dobijeni model genetskim programiranjem za PM<sub>2,5</sub>

Figure 12. Model obtained by genetic programming for PM2.5

#### 4.2. Predikcija PM<sub>2,5</sub> za 2017. godinu

Na osnovu urađenog modela izvršena je predikcija vrijednosti PM<sub>2,5</sub> za 2017. godinu koja je prikazana je na slici 13.

Zaključuje se da je predikcija jako dobra jer Pearsonov koeficijent iznosi 0.973.



Slika 13. Predviđanje modela PM<sub>2,5</sub> za poznate podatke u 2017. godini, korelacija: 0,973

Figure 13. Prediction of PM<sub>2,5</sub> for known data in 2017, correlation: 0.973

Matematički izraz za predikciju modela PM<sub>2,5</sub> prema ovoj metodi dat je u obliku:

$$f(x_1, x_2, x_3, x_4, x_5, x_6) = 16.09 + \frac{(2.27 \times 10^6 - 1.05 \times 10^5 x_4)}{529.59 + 268.95 x_4 + 38.21 x_4^2 + x_4^3 + x_2(45.46 + 21.56 x_4 + 2.55 x_4^2) + 2.22 \times 10^4 \sin(50.31 + x_5(-0.5 + 0.0011 x_6) - 1.05 x_6)}$$

gdje je:

$x_1$  - godina (2010, 2011, 2012, 2013, ..., 2016),  
 $x_2$  - mjesec,(1, 2, ...12),  
 $x_3$  - vjetar,  
 $x_4$  - temperatura,  
 $x_5$  - pritisak,  
 $x_6$  - vлага.

Poređenjem koeficijenata korelaciije dobijenih za modele na mjernej stanici Skver vještačkim neuronskim mrežama PM<sub>2,5</sub>=0,713 i modele dobijene genetskim programiranjem PM<sub>2,5</sub>=0,973 pokazano je da je genetsko programiranje superiornije u odnosu na neuronske mreže.

## 5. ZAKLJUČAK

Naučni doprinos ovog rada se ogleda u tome što su, na osnovu postojećih rezultata monitoringa vazduha i meteoroloških podataka za 8 godina, korištenjem statističkih metoda, metoda vještačkih neuronskih mreža i genetskog programiranja, pomoću GPdotNET alata za modeliranje,

optimizaciju i predviđanje uz pomoću evolucionih algoritama razvijeni i testirani jedinstveni matematički modeli za predviđanje koncentracije PM<sub>2,5</sub> u Gradu Tuzla sa visokom pouzdanostju njegove primjene.

U radu je dokazan uticaj temperature, vjetra i pritiska na koncentraciju PM<sub>2,5</sub> i proračunata korelacija između njih. Pokazano je kakav uticaj na koncentraciju PM<sub>2,5</sub> bi moglo imati ako dođe do povećanja ili smanjenja prosječnih temperatura.

U cilju dobijanja pouzdanijih predviđanja koncentracija zagađujućih materija pripremljeni su i testirani modeli za predviđanje temperature sa visokim koeficijentom korelaciije pri čemu je pokazano da se puno bolji rezultati dobiju metodom genetskog programiranja.

Na taj način su napravljene osnove za dalja istraživanja u ovoj oblasti.

Ovakav koncept uz primjenu računarskih metoda može se koristiti i u drugima gradovima u BiH i šire, a njegovu primjenu je moguće proširiti i na druge segmente zaštite okoline gdje je razvijen monitoring.

## 6. LITERATURA

- [1] [https://www3.epa.gov/airnow/aq\\_forecasting\\_guidance-1016.pdf](https://www3.epa.gov/airnow/aq_forecasting_guidance-1016.pdf), 27.06.2019.
- [2] L.Bai, J.Wang, X.M. Id, H.Lu (2018) Air Pollution Forecasts: An Overview, Int. J. Environ. Res. Public Health, 15, 780-787.
- [3] Y.Tong, B.Wan (2001) Methods of forecasting air pollution and their development at home and abroad. In Proceedings of the Sixth National Academic Conference on Environmental Monitoring BT, Chengdu, Sichuan, China, p.10–12.
- [4] Y.Zhongshan, W.Jian (2017) A new air quality monitoring and early warning system: Air quality assessment and air pollutant concentration prediction, Environmental Research, 158, 105-117.
- [5] S.Vukadinović (1990) Elements of Theory of Probability and Mathematical Statistics, Privredni pregleđi, Belgrade.
- [6] A.Gargava, A.L.Aggarwal (1999) Emission inventory for an industrial area of India prashant, Environmental Monitoring and Assessment, 55, 299–304.
- [7] <https://www.epa.gov/air-emissions-inventories/air-emissions-inventory-improvement-programing>, 30.06.2019.
- [8] J.Brandt, J.D.Silver, J.H.Christensen, M.S. Andersen, J.Bønløkke, T.Sigsgaard, C.Geels, A. Gross, A.B.Hansen, K.M.Hansen, G.B.Hedegaard, E.Kaas, L.M.Frohn (2013) Contribution from the ten major emission sectors in Europe to the Health-Cost Externalities of Air Pollution using the EVA Model System – an integrated modelling approach. Atmos. Chem. Phys., 13, 7725-7746.
- [9] Y. Zhongshan, W. Jian (2017) A new air quality monitoring and early warning system: Air quality assessment and air pollutant concentration prediction, Environmental Research, 158, 105-117.

## ABSTRACT

### MODELING OF SUSPENDED PARTICLES CONCENTRATIONS IN THE URBAN AREA USING ARTIFICIAL INTELLIGENCE METHODS

*The paper develops unique and reliable models for predicting PM<sub>2,5</sub> for the City of Tuzla based on the existing monitoring results of PM<sub>2,5</sub> and meteorological data (pressure, temperature, wind and humidity) using statistical methods, neural network modeling and genetic programming methods. A correlation between the concentration of pollutants and the influence factors such as temperature and wind has been demonstrated.*

*The developed models can be used for the prediction of PM<sub>2,5</sub> concentrations for the early warnings and public protection from the harmful effects of polluted air on human health. The obtained results can be used in the process of making strategic decisions and activities related to air quality control and management.*

*Designing of suspended materials concentration in urban areas is very significant when regular measurements are performed, but the measurements of polluting materials are often lacking. In case of the interruption of the pollutants concentration measurements in Tuzla City for a short or longer time, appliance of the model that is resulting from this work can predict the concentration of pollutants and plan actions based on them.*

**Keywords:** air pollution, air monitoring, neural networks, genetic programming.

*Scientific paper*

*Paper received: 15. 09. 2019.*

*Paper accepted: 12. 11. 2019.*

*Paper is available on the website: [www.idk.org.rs/journal](http://www.idk.org.rs/journal)*