

Model predviđanja otopljenog kisika za različite scenarije - Drava kod Donjeg Miholjca

Rabi, Anamarija

Source / Izvornik: **Common Foundations 2018 - uniSTem: 6th Congress of Young Researchers in the Field of Civil Engineering and Related Sciences, 2018, 200 - 207**

Conference paper / Rad u zborniku

Publication status / Verzija rada: **Published version / Objavljena verzija rada (izdavačev PDF)**

<https://doi.org/10.31534/CO/ZT.2018.28>

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:123:123456>

Rights / Prava: [Attribution-NonCommercial-NoDerivatives 4.0 International/Imenovanje-Nekomercijalno-Bez prerada 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2024-12-01**



Repository / Repozitorij:

[FCEAG Repository - Repository of the Faculty of Civil Engineering, Architecture and Geodesy, University of Split](#)



Model predviđanja otopljenog kisika za različite scenarije - Drava kod Donjeg Miholjca

Anamarija Rabi¹

(1) Sveučilište J.J. Strossmayera u Osijeku, Građevinski fakultet Osijek, Republika Hrvatska, anamarija.rabi@gfos.hr

Sažetak

Rijeke su složeno prirodno okruženje gdje fizikalni, biološki i kemijski procesi koji se istovremeno odvijaju određuju kakvoću vode. Izradom različitih numeričkih modela omogućuje se pouzdanije praćenje kakvoće vode. Za izradu modela predviđanja kakvoće vode primjenom unaprijednih neuronskih mreža odabrana je postaja Donji Miholjac na Dravi za razdoblje od 1993. do 2016. godine. Pri odabiru parametara koji će se modelirati i njima pripadajućih ulaznih parametara korištena je korelacijska analiza (Pearsonova korelacija, korelacija udaljenosti). Klaster analizom i podjelom cijelog skupa na male, srednje i velike vode pomoću percentila definirani su ekstremni hidrološki scenariji. Ovaj će rad pokazati mogućnost predviđanja otopljenog kisika pri različitim hidrološkim scenarijima primjenom modela unaprijednih neuronskih mreža. Na slivu se pretpostavlja primjena određenih mjera poboljšanja. Cilj ovog modela je omogućiti bolje praćenje stanja kakvoće vode. Time bi se dala ocjena učinkovitosti pretpostavljenih mjera poboljšanja pri različitim hidrološkim scenarijima.

Ključne riječi: predviđanje, kakvoća vode, otopljeni kisik, scenariji, neuronske mreže, MatLab

The dissolved oxygen prediction model for different scenarios - location of Donji Miholjac at river Drava

Abstract

Rivers are a complex natural environment with the physical, biological and chemical processes occurring simultaneously, determine the water quality. Various numerical models provide reliable water quality monitoring. Feedforward neural network models were applied for creating water quality prediction models of the river Drava at Donji Miholjac during the 1996. – 2016. period. Correlation analysis (Pearson Correlation, Distance Correlation) was used for selecting the parameters that will be modeled and their corresponding input parameters. Extreme hydrological events are defined by cluster analysis and distribution of the whole dataset into small, medium and large water flows. This paper will show the possibility of predicting dissolved oxygen in different hydrological scenarios using the feedforward neural network model. The implementation of certain improvement measures is assumed on the basin. The model aims to provide a better monitoring of water quality. This would provide an assessment of the effectiveness of the assumed improvement measures at different hydrological scenarios.

Keywords: prediction, water quality, dissolved oxygen, scenarios, neural networks, MatLab

1. Uvod

Razvitak industrije i eksponencijalni rast broja stanovništva znatno utječu na porast količine otpadnih tvari koje se izravno ili neizravno ispuštaju u prirodne vodne sustave. Fizikalni, biološki i kemijski procesi koji se istovremeno odvijaju u vodnim tijelima određuju kakvoću vode koja je važna komponenta održivosti vodnih resursa i upravljanja okolišem. Zbog upotrebljivosti vode za različite namjene, teži se da kakvoća vode ostane na prihvatljivoj razini.

Temperatura vode i otopljeni kisik od izuzetne su važnosti za opstanak riba i drugih živih organizama u vodi. Temperatura vode određuje postotak razgradnje organske tvari, sadržaj otopljenog kisika i kemijske reakcije u cjelini. Na stanje kakvoće vode utječe i količina vode koja protječe određenim protjecanim profilom. Pojavom većih protoka u vodotocima dolazi do razrjeđivanja što ima pozitivan učinak na stanje kakvoće vodotoka, međutim problem nastupa pri malim protocima kada je vodotok najosjetljiviji na promjene.

Na vodne resurse djeluju mnogi čimbenici koji dolaze iz poljoprivredne i industrijske djelatnosti, iz urbanih područja, domaćinstava i turističke djelatnosti. Da bi kvaliteta prirodnih vodnih sustava ostala na prihvatljivoj razini, komunalne otpadne vode prije ispuštanja u okoliš moraju udovoljiti određenim uvjetima kakvoće. Potrebno je analizirati učinkovitost pročišćavanja i djelovati na zadovoljavajući i propisan način kako bi se otpadne vode mogle ispustiti u prijamnike. Poznato je da dušik kao biljno hranjivo predstavlja ključni dio visokih prinosa u biljnoj poljoprivrednoj proizvodnji. Najviše se upotrebljava za proizvodnju umjetnih gnojiva za što ga koristi 85% svjetske proizvodnje [1]. Dušik iz mineralnih gnojiva potiče rast algi i vodenih biljaka što može negativno djelovati na kakvoću vode rijeke. Time započinje eutrofikacija pri čemu se povećano troši otopljeni kisik u vodi. Opadanjem koncentracije kisika u vodi dolazi do pomora vodenih organizama koji kisik troše u procesu disanja. Stoga je poboljšanje kakvoće vodnih resursa visoko na popisu prioriteta Europske unije. Propis za ocjenu kakvoće vode koji je usklađen s Okvirnom direktivom o vodama Europske unije (2000/60/EC) donesen je Uredbom o standardu kakvoće voda koja je na snagu stupila 18. lipnja 2013. godine. Nedavno su naširoko priznate zasluge alternativnih pristupa rješavanju problema modeliranja i predviđanja, kao što neuronske mreže (NM). Tijekom posljednja dva desetljeća primjena modela NM u svijetu je vrlo rasprostranjena, u Hrvatskoj se također primjenjuje u raznim područjima pa tako i u hidrologiji.

Cilj ovog rada je pokazati mogućnost predviđanja otopljenog kisika pri različitim hidrološkim scenarijima izradom i primjenom modela predviđanja temeljenog na NM-u. Na slivu se pretpostavlja primjena sljedećih mjera: poboljšanje komunalne odvodnje, smanjenje unosa mineralnih gnojiva na poljoprivredne površine. Cilj modela je omogućiti pouzdanije praćenje učinka provedbe mjera poboljšanja kakvoće vode. To pridonosi ocjeni učinkovitosti ovih mjera u skladu s prihvaćenim europskim direktivama pogotovo u uvjetima recentnih klimatskih promjena.

2. Područje istraživanja

Područje istraživanja smješteno je u donjem toku rijeke Drave na mjestu hidrološke postaje Donji Miholjac (Slika 1). Prema Uredbi o standardu kakvoće voda (NN 73/2013), rijeka Drava je klasificirana kao nizinska vrlo velika tekućica koja ulazi u Hrvatsku kod Dubrave Križovljanske, ulijeva se u Dunav kod Aljmaša. Ukupne je dužine 725 km, od čega je 323 km u Hrvatskoj. Riječni režim Drave je pluvijalno-glacijalnog karaktera, s visokom vodostajima u proljetno-ljetnom razdoblju tijekom svibnja i lipnja, a najmanji vodostaji su u zimskom razdoblju u siječnju i veljači [2].



Slika 1. Prikaz rijeke Drave s analiziranom postajom Donji Miholjac

2.1. Baza podataka

Hidrološke parametre (protok, temperatura vode) za razdoblje od 1993. do 2016. godine dao je DHMZ (295 mjerenja), dok su parametre kakvoće vode (električna vodljivost, alkalitet, PH, otopljeni kisik, BPK₅, KPK-Mn, amonij, nitrati, ukupni dušik i ukupni fosfor) dale Hrvatske vode za isto razdoblje (295 mjerenja). Kod Donjeg Miholjca ispušta se komunalna otpadna voda u odvodni kanal koji se ulijeva u rijeku Dravu uzvodno od mjesta uzorkovanja kakvoće vode. Komunalna otpadna voda pročišćava se na postrojenju za pročišćavanje otpadnih voda Donji Miholjac (UPOV DM). Podatci o kakvoći otpadne vode (suspendirana tvar, KPK, BPK₅) na uređaju za pročišćavanje otpadnih voda Donji Miholjac (UPOV DM) preuzeti su od komunalnog gospodarstva Park d.o.o. za razdoblje od 1996. do 2016. godine (134 mjerenja). Od 2012. godine u pogon je uvedeno i biološko pročišćavanje otpadnih voda (III. stupnja pročišćavanja), a do 2012. godine obavljao se samo I. stupanj pročišćavanja. Onečišćenje dušikom iz mineralnih gnojiva koje dolazi s poljoprivrednih površina (F=559km²) unutar malog sliva »Županijski kanal« utječe na kakvoću vode rijeke Drave kod Donjeg Miholjca. Podatak o količini upotrijebljenog dušika iz mineralnih gnojiva je iskazan u tonama na godišnjoj osnovi i podijeljen s brojem mjeseci unutar jedne godine.

3. Metode istraživanja

Osnovna statistička i korelacijska analiza upotrijebljena je za utvrđivanje ulaznih parametara potrebnih za izradu modela otopljenog kisika primjenom NM-a. Pri korelacijskoj analizi između hidroloških parametara i otopljenog kisika koristio se Pearsonov koeficijent korelacije koji je uglavnom osjetljiv na linearni odnos između dvije varijable, dok je za utvrđivanje nelinearnosti, korišten koeficijent korelacije udaljenosti (engl. *Distance correlation*) [3]. Na cijelom skupu podataka dodatno je provedena k-struka klaster analiza (engl. *k-mean cluster analysis*) u cilju grupiranja sličnih objekata iz veće cjeline u manje skupine koje sadrže elemente sličnih svojstava. Cijeli skup podataka dodatno se dijelio na male, srednje i velike vode pomoću percentila. Ovim postupcima definirali su se nepovoljni hidrološki scenariji za predviđanje otopljenog kisika.

3.1. Unaprijedne neuronske mreže (UNM)

Pri modeliranju i predviđanju otopljenog kisika korišten je računalni program za numeričko modeliranje MathWorks MATLAB.

Za izradu modela predviđanja kakvoće vode korišten je model Unaprijednih neuronskih mreža (engl. *Feedforward neural networks*). NM predstavljaju pojednostavljeni matematički model procesa koje obavljaju biološke neuronske mreže, a sastoji se od skupa međusobno povezanih umjetnih neurona čiji se konačan oblik formira nakon završenog procesa učenja. Učenjem mreža stječe znanja o rješavanju određenog problema. Mreža se obično sastoji od tri sloja. Prvi ili ulazni sloj jedini je sloj koji prima signale izvana. On prenosi signale sljedećem sloju (skriveni sloj) koji obrađuje ove podatke i šalje svoje izlazne vrijednosti narednom sloju, trećem sloju mreže. Konačni rezultati obrade dobivaju se na izlazima neurona trećeg ili izlaznog sloja. Postupak učenja NM-a može se definirati kao iterativni postupak podešavanja težinskih parametara (w), koji se odvija prema određenom algoritmu. Cilj učenja mreže je određivanje vrijednosti parametara mreže za koje će pogreška, odnosno funkcija cilja, biti minimalna.

Umjetni neuron je osnovni dio NM-a. Izlaz statičkom neuronu u nekome trenutku ovisi samo o vrijednostima ulaznih signala i težinskim koeficijentima. Umjetni neuron u k -tom koraku računa odziv o_k prema izrazu (1), gdje p_k označava sumu otežanih m -ulaza definiranu izrazom (2), a φ označava aktivacijsku funkciju dotičnog neurona. Izrazi (1) i (2) predstavljaju matematički model umjetnog neurona čiji su ulazi označeni sa u_k , a vrijednosti težinskih koeficijenata su označene sa w_k [4].

$$o_k = \varphi(p_k) \quad (1)$$

$$p_k = \sum_{n=0}^m (w_k \cdot u_k)_n \quad (2)$$

Iznosi težinskih koeficijenata određuju vladanje mreže, tj. njezinu sposobnost aproksimacije nelinearne funkcije. Izračunavanje odgovarajućih iznosa težinskih koeficijenata ostvaruje se algoritmima učenja. Kod modeliranja primjenom UNM-a na skupu za učenje se obavlja kalibracija podešavanjem težinskih koeficijenata mreže u cilju smanjenja pogreške. Testni

skup je validacijski skup na kojemu se obavlja provjera uspješnosti odnosno kakvoće modela.

Statistički pokazatelji uspješnosti modela korišteni u ovome radu su korijen srednje kvadratne pogreške (RMSE) definiran izrazom (3) i Pearsonov koeficijent korelacije (R) definiran izrazom (4) [5]

$$RMSE = \sqrt{\frac{1}{N} \sum_{s=1}^N (d_s - o_s)^2} \quad (3)$$

$$R = \frac{\sum_{s=1}^N (d_s - \bar{d})(o_s - \bar{o})}{\sqrt{\sum_{s=1}^N (d_s - \bar{d})^2 (o_s - \bar{o})^2}} \quad (4)$$

gdje je: (d_s) - mjerena vrijednost, (o_s) - odziv modela, odnosno predviđena vrijednost, \bar{d} - srednja vrijednost mjerenih podataka, \bar{o} - srednja vrijednost odziva modela.

Osnovni lokalni algoritmi učenja prvog reda za podešavanje parametara UNM-a su propagacija greške unatrag (engl. *error back propagation*, *BP*) te unaprjeđenja izvornog BP algoritma. Lokalni algoritmi učenja drugog reda su quazi-Newtonov algoritam, metoda konjugiranog gradijenta (engl. *conjugate gradient*), Levenberg-Marquardt (LM) algoritam i Bayesova regularizacija (engl. *Bayesian regularization*) koja je nadogradnja LM algoritma [4].

4. Rezultati modela


Modeliranju je prethodila statistička i korelacijska analiza na osnovi koje se može zaključiti da je odnos između hidroloških parametara, ostalih parametara kakvoće vode (električna vodljivost, alkalitet, nitrati) i otopljenog kisika linearan. Peterostrukom klaster analizom i podjelom cijelog skupa na male, srednje i velike vode pomoću percentila definirani su nepovoljni hidrološki scenariji za predviđanje otopljenog kisika. Nepovoljni hidrološki scenariji mogu se odviti pri malim protocima (Q_{min}) i visokim temperaturama vode (T_{max}). Dodatni scenariji koji se promatraju pri predviđanju otopljenog kisika su utjecaj poboljšanja sustava pročišćavanja komunalne otpadne vode (komunalna voda_{min}) i smanjenje unosa dušika iz mineralnih gnojiva na poljoprivredne površine (N_{min}).

U ovome je radu konstruirana troslojna UNM s algoritmom učenja zvanim Bayesova regularizacija [6] za model predviđanja otopljenog kisika. Pri izradi modela otopljenog kisika uzeta su u obzir dva različita modela UNM za različite kombinacije kako slijedi: UNM1 (razdoblje od 1993. do 2016.) – ulazni parametri su: protok, temperatura vode, električna vodljivost, alkalitet, nitrati; UNM2 (razdoblje od 1996. do 2016.) – ulazni parametri su: protok, temperatura vode, električna vodljivost, alkalitet, nitrati, kakvoća komunalne otpadne vode (suspendirana tvar, KPK, BPK_s), dušik iz mineralnih gnojiva. Na 85% nasumično odabranih podataka provedena je kalibracija modela, a na preostalih 15% nasumično odabranih podataka provedena je validacija modela ili provjera kakvoće modela. Optimalan broj neurona potreban za treniranje mreže odabran je pomoću peterostruke unakrsne validacije (eng. *5-fold cross-validation*). Ovim postupkom određena je optimalna mrežna topologija s variranjem broja neurona u skrivenom sloju od 1 do 20. Svaki uzorak na skupu

za učenje tijekom eksperimenta unakrsne validacije ponovljen je 5 puta, a odabrana je srednja vrijednost rezultata za taj uzorak. Za neurone u skrivenom sloju korištena je tansig aktivacijska funkcija, purelin je korišten kao aktivacijska funkcija za izlazni neuron. Statistički pokazatelji uspješnosti modela otopljenog kisika na validacijskom i skupu za učenje prikazani su u Tablici 1. Slika 2 prikazuje učinak najboljeg modela UNM2, na validacijskom skupu, za otopljeni kisik na postaji Donji Miholjca. Mjerene vrijednosti otopljenog kisika kreću se u rasponu 7.5 – 13.9 mgO₂/l. Odabrani model je UNM2 za koji je na skupu za učenje RMSE=0.561 i R=0.928. Na validacijskom skupu je RMSE=0.599 i R=0.891. Za najbolje vrijednosti statističkih pokazatelja model UNM2 odabran je za predviđanje otopljenog kisika.


Tablica 1. Statistički pokazatelji uspješnosti modela (UNM1 i UNM2)

Oznaka Modela (mrežna arhitektura)	Skup za učenje		Validacijski skup	
	RMSE	R	RMSE	R
UNM1 (1 skriveni sloj, br.neurona =5)	0.781	0.868	0.870	0.834
UNM2 (1 skriveni sloj, br.neurona =14)	0.561	0.928	0.599	0.891



Slika 2. Prikaz učinka najboljeg modela UNM2 za otopljeni kisik na postaji Donji Miholjca na validacijskom skupu: a) RMSE=0.599; b) R=0.891; c) kumulativni histogram.

Na Slici 2 c) prikazan je kumulativni histogram na validacijskom skupu za otopljeni kisik iz kojega se može zaključiti da će u 95% slučajeva apsolutna pogreška biti manja od 1. Rezultati predviđanja otopljenog kisika pri različitim scenarijima prikazani su na Slici 3.



Slika 3. Rezultati modela predviđanja otopljenog kisika tijekom narednih 12 mjeseci

Slika 3 prikazuje predviđanje otopljenog kisika ako se pretpostavi da će u budućnosti mjerenja biti slična kao i do sada. Tada se na osnovi različitih scenarija može predvidjeti otopljeni kisik u narednih 12 mjeseci. Tamnoplava krivulja prikazuje otopljeni kisik sa srednjim vrijednostima ulaznih veličina. Zeleno je prikazan otopljeni kisik s ulaznim vrijednostima minimalnih protoka, maksimalnih temperatura vode i minimalnog unosa dušika, a sve ostale su srednje vrijednosti. Ljubičasto prikazan otopljeni kisik s ulaznim vrijednostima minimalnih protoka, maksimalnih temperatura vode i minimalnog onečišćenja od komunalne otpadne vode, a sve ostale su srednje vrijednosti. Svijetloplavo je prikazan otopljeni kisik s ulaznim veličinama minimalnih protoka, maksimalnih temperatura vode, a sve ostale su srednje vrijednosti. Za svaku krivulju promatraju se uzlazne vrijednosti za model UNM2 za razdoblje od 1996. do 2016. godine.

5. Zaključak

Prema statističkim pokazateljima uspješnosti modela, može se zaključiti da model UNM2, iako ima kraći niz mjerenja (1996-2016), daje bolje rezultate od UNM1 za duži niz mjerenja (1993-2016). Međutim model UNM2 ima više ulaznih podataka koji se uzimaju u obzir prilikom izrade modela. Prema tome se može zaključiti da poboljšanje komunalne otpadne vode (suspendirana tvar, KPK, BPK₅) i smanjenje unosa dušika s poljoprivrednih površina pozitivno utječu na koncentraciju otopljenog kisika u vodi. Prema rezultatima predviđanja otopljenog kisika za narednih 12 mjeseci pri različitim scenarijima može se zaključiti da otopljenog kisika ima najviše u zimskom razdoblju kada je temperatura vode u rijeci najniža, a kada je temperatura vode viša, vrijednost otopljenog kisika u rijeci opada. Rezultati otopljenog kisika (Slika 3) tijekom narednih 12 mjeseci, dobiveni modelom predviđanja pomoću UNM2, upućuju na to da će se vrijednosti otopljenog kisika pri nepovoljnim hidrološkim scenarijima u ljetnim mjesecima, kada je rijeka najosjetljivija na dodatne utjecaje, najviše povećati kada se onečišćenje od komunalne otpadne vode (ljubičasta linija) i unosa nitrata s poljoprivrednih površina (zelena linija) svede na minimum. Najbolje

rezultate otopljenog kisika prikazuje ljubičasta linija za scenarij poboljšanja sustava komunalne odvodnje pri nepovoljnim hidrološkim uvjetima. Dakle povećanje protoka i smanjenje temperature vode u ljetnim mjesecima može samo pogodovati povećanju otopljenog kisika koji je pod utjecajem predviđenih mjera poboljšanja. Prema rezultatima se može zaključiti da se modeli UNM mogu primijeniti pri izradi modela predviđanja otopljenog kisika za različite scenarije.

Literatura

- [1] Jambrošić, S.: Određivanje dušikovih spojeva u otpadnim vodama s pročistača otpadnih voda, Završni rad, 2016.
- [2] Jelić, M., Jelić, D., Žutinić, P., Čaleta M.: Fish fauna of the lower reaches of the river Drava and surrounding marshland habitats near Donji Miholjac (Eastern Croatia). *Croatian Journal of Fisheries*, 70 (4), 153–167, 2012. doi:10.1214/009053607000000505.
- [3] Szekely, G. J., Rizzo, M. L., Bakirov, N. K.: Measuring and Testing Independence by Correlation of Distances, *Annals of Statistics*, 35 (6): 2769–2794, 2007.
- [4] Matić, P.: Kratkoročno predviđanje hidrološkog dotoka pomoću umjetne neuronske mreže, doktorska disertacija, Fakultet elektrotehnike strojarstva i brodogradnje u Splitu, Sveučilište u Splitu, 2016.
- [5] Rabi, A., Hadzima-Nyarko, M., Šperac, M.: Modelling river temperature from air temperature: case of the River Drava (Croatia), *Hydrological sciences journal*. 60, 9; 1490-1507, 2015. doi: 10.1080/02626667.2014.914215.
- [6] MacKlay, D.: Bayesian Methods for Adaptive Models. Doctoral dissertation. California Institute of Technology Pasadena, California, 1992.