

Kvalitativna procjena rada uređaja za pročišćavanje otpadnih voda modelom neuronske mreže optimiziranim genetskim algoritmom

Sara Dadar

Sveučilište Ferdowsi u Mashhadu, mr. sc., sara.dadar@mail.um.ac.ir

Atena Pezeshki

Sveučilište Ferdowsi u Mashhadu, mr. sc., atena.pezeshki@mail.um.ac.ir

Bojan Đurin

Sveučilište Sjever, prof. dr. sc., bdjurin@unin.hr

Dragana Dogančić

Sveučilište u Zagrebu, dr. sc., ddogan@gfv.unizg.hr

Sažetak: Negativan utjecaj nepravilnog odlaganja prikupljenih i pročišćenih otpadnih voda postao je neizbjegjan. Osim izgradnje uređaja za pročišćavanje otpadnih voda, za postizanje potrebnih ekoloških standarda postoji i potreba za ocjenjivanjem kontinuiranog rada sustava za pročišćavanje. U Iranu se pročišćene otpadne vode većinom koriste u poljoprivredi. Stoga korištenje otpadnih voda loših karakteristika kvalitete može ugroziti zdravlje. U ovoj studiji istražena je uspješnost modela neuronske mreže za predviđanje učinka uređaja za pročišćavanje otpadnih voda Perkandabad u Mashhadu u Iranu. U tu svrhu prvo su utvrđeni faktori koji utječu na parametar UBPK kao jedan od pokazatelja kvalitete efluenta. U sljedećem koraku učinkovitost uređaja za pročišćavanje je predviđena i ocijenjena pomoću genetskog algoritma i ulaznih faktora mreže. Najveći koeficijent korelacije za parametar UBPK iznosio je 0,89%. Rezultati pokazuju da među ulaznim parametrima u modelu najveći utjecaj na ovo predviđanje ima količina onečišćenja organskim tvarima.

Ključne riječi: otpadne vode; neuronska mreža; uređaj za pročišćavanje; genetski algoritam; UBPK

Qualitative Evaluation of Wastewater Treatment Plant Performance by Neural Network Model Optimized by Genetic Algorithm

Abstract: The adverse effects of improper disposal of collected and treated wastewater have become inevitable. To achieve the desired environmental standards, in addition to the construction of wastewater treatment plants, there is also a need to evaluate the continuous performance of treatment systems. In Iran, treated wastewater is mostly used in agriculture. Therefore, the use of wastewater with poor quality characteristics can endanger health. In this study, the neural network model's efficiency was investigated to predict the performance of the Perkandabad wastewater treatment plant in Mashhad in Iran. To achieve this, first, the factors affecting the TBOD parameter were identified as one of the quality indicators of the effluent. In the next step, using a genetic algorithm and network input factors, the performance of the treatment plant was predicted and evaluated. The highest correlation coefficient for the TBOD parameter was 0.89%. The results show that among the input parameters in the model, the amount of organic matter pollution load has the greatest effect on this prediction.

Keywords: wastewater; neural network; treatment plant; genetic algorithm; TBOD

Dadar, S., Pezeshki, A., Đurin, B., Dogančić, D.

Kvalitativna procjena rada uređaja za pročišćavanje otpadnih voda modelom neuronske mreže optimiziranim genetskim algoritmom

1. UVOD

Danas su porast broja stanovnika i industrijski razvoj doveli do povećane potrošnje vode, a time i veće proizvodnje otpadnih voda i onečišćenja okoliša [1,2]. Nepravilno zbrinjavanje gradskih i industrijskih otpadnih voda uzrokuje negativne učinke na okoliš. Implementacija projekata otpadnih voda u urbanim i ruralnim područjima smatra se nužnom i temeljnom za napore očuvanja okoliša [3]. Najvažniji ciljevi tijekom izgradnje sustava za pročišćavanje otpadnih voda obuhvaćaju različite aspekte, kao što su očuvanje javnog zdravlja, zaštita okoliša, sprječavanje onečišćenja vodnih resursa i ponovna uporaba pročišćenih otpadnih voda [4]. Kvaliteta efluenta iz uređaja za pročišćavanje važna je kako u pogledu njegove uporabe u sektorima kao što su poljoprivreda i industrija, tako i u pogledu konačnog odlagališta [5]. Kvaliteta prvenstveno ovisi o važnim faktorima kao što su načela i parametri korišteni tijekom projektiranja samog uređaja, preciznost u projektiranju i način njegove uporabe. Stoga su precizno projektiranje i pravilno upravljanje uređajima za pročišćavanje otpadnih voda među najvažnijim faktorima u sektoru voda i otpadnih voda. Trenutno se pri radu mnogih uređaja za pročišćavanje otpadnih voda u našoj zemlji pojavljuju problemi uzrokovani različitim faktorima, kao što su nepravilno projektiranje, kvantitativne i kvalitativne promjene otpadnih voda, procesni uvjeti, kolebanja vremenskih uvjeta tijekom godišnjih doba itd. Stoga je od posebne važnosti korištenje metoda kojima se mogu predvidjeti rad i učinkovitost uređaja za pročišćavanje otpadnih voda i kojima se može pomoći u prevladavanju navedenih problema. Na temelju ovih predviđanja mogu se pružiti kratkoročna i dugoročna rješenja upravljanja. Operateri mogu poduzeti potrebne mjere prije nego što se pojave problemi i provoditi odgovarajuću kontrolu nad radom. Jedna od najčešće korištenih metoda predviđanja u području pročišćavanja voda i otpadnih voda je metoda umjetne neuronske mreže [6].

Važno je naglasiti da sâmo pokretanje uređaja za pročišćavanje otpadnih voda ne rješava sve probleme okoliša, nego se rad uređaja za pročišćavanje mora stalno pratiti kako bi se postigli željeni ekološki standardi [7]. Pročišćavanje otpadnih voda uključuje skup složenih fizikalnih, kemijskih i bioloških procesa čija dinamika je nelinearna i ponekad promjenjiva s vremenom te može izravno utjecati na rad uređaja za pročišćavanje [8]. Među uobičajenim parametrima koji se koriste za procjenu učinkovitosti uređaja za pročišćavanje otpadnih voda je količina kisika potrebna za biokemijske procese (BPK), količina kisika potrebna za kemijske procese (KPK), koncentracije lebdećih i topljivih krutih tvari i pH vrijednosti efluenta iz uređaja za pročišćavanje [9]. Korištenje vode iz uređaja za pročišćavanje otpadnih voda može u nekim slučajevima pomoći u rješavanju krize nestašice vode u sektorima kao što su poljoprivreda i industrija, ali samo ako je broj zagađivača efluenta u skladu sa standardima [10].

Godine 2004. Oliveira Esquerre i sur. koristili su neuronsku mrežu za dobivanje zadovoljavajućeg predviđanja BPK efluenta iz uređaja za pročišćavanje otpadnih voda u Brazilu. U ovoj studiji istraživači su prvo pokušali predvidjeti parametar BPK na ulazu i izlazu uređaja za pročišćavanje pomoću modela linearne regresije. Nisu razmatrali korištenje linearne regresije za modeliranje sustava za pročišćavanje s aeracijskom lagunom u industrijskom uređaju za pročišćavanje prikladnom za izlazne parametre, stoga se ne preporuča korištenje regresijskih modela za aeracijske lagune. Istraživači su zatim primijenili zanimljive modele neuronske mreže na sustav za pročišćavanje otpadnih voda industrije papira u Brazilu, koji je imao aeriranu lagunu, te su procijenili model neuronske mreže za sustave aeriranih laguna i slične sustave [11]. Cao i sur. [12] su koristili umjetnu neuronsku mrežu kako bi predvidjeli utjecaj promjena parametara anaerobnog B-2 sustava na njegov rad i koristili paralelni višepopulacijski genetski algoritam za optimiziranje težina umjetne neuronske mreže. Rezultati ovih istraživača su pokazali da bi kombinacija ovih metoda

Dadar, S., Pezeshki, A., Đurin, B., Dogančić, D.

Kvalitativna procjena rada uređaja za pročišćavanje otpadnih voda modelom neuronske mreže optimiziranim genetskim algoritmom

mogla biti dobar alat za predviđanje promjena u radu anaerobnog sustava. Istraživači su također zaključili da bi se zahvaljujući prilagodbi ovih alata različitim uvjetima okoliša oni mogli proširiti na druge sustave pročišćavanja. Abu Qdais i sur. [13], su koristili umjetnu neuronsku mrežu i genetski algoritam kao alat za simulaciju i optimizaciju procesa proizvodnje bioplina u digestoru bioplinskog postrojenja Russaifah u Jordanu.

Fang i sur. [14] su razvili sveobuhvatni dinamički model (uključujući mehanički model, model neuronske mreže i genetski algoritam) za simulaciju rada komunalnog uređaja za pročišćavanje otpadnih voda sa značajnim kolebanjima ulaznog protoka, a težine neuronske mreže su optimizirane genetskim algoritmom. Gueguim Kana i sur. [15] su modelirali i optimizirali biopljin proizведен iz otpadnih voda, uključujući piljevinu, kravlju balegu, lišće banane, rižine mekinje i papir, pomoću neuronske mreže koristeći genetski algoritam. Rezultati ovog istraživanja su pokazali učinkovitost modela neuronske mreže - genetskog algoritma za ponašanje nelinearnog sustava i optimizaciju proizvodnje bioplina [15]. Pieuleac i sur. (2013) u radu [16] razvili su metodu optimizacije neuronske mreže i genetski algoritam i primijenili ih na stvarni proces elektrokoagulacije. Provjera rezultata optimizacije pomoću eksperimentalnih podataka pokazala je pogrešku manju od 11%.

Ovo istraživanje je korišteno za razvoj i procjenu učinkovitosti modela neuronske mreže i genetskog algoritma u procjeni rada velikog i važnog uređaja za pročišćavanje u Mashhadu i ocjeni faktora kvalitete njegovog effluenta.

2. MATERIJALI I METODE

Jedno od najvažnijih komunalnih uređaja za pročišćavanje otpadnih voda u Mashhadu je uređaj za pročišćavanje otpadnih voda Perkandabad br. 1 (slika 1), koje se nalazi na južnoj obali sezonske rijeke. Nazivni kapacitet ovog uređaja za pročišćavanje je 15.200 kubika dnevno, a populacija koju pokriva je 100.000 stanovnika. Proces obrade koji se koristi u ovom postrojenju za pročišćavanje je aerirana laguna s potpunim miješanjem, a nepročišćena otpadna voda se obrađuje puštanjem kroz jedinicu za sakupljanje otpada, aeracijske lagune, taložnik, izvodno jezerce i jedinicu za dezinfekciju. Zbog ispuštanja otpadnih voda iz uređaja za pročišćavanje Perkandabad br. 1 u rijeku u određena doba godine, projekt ovog uređaja za pročišćavanje se temelji na ispuštanju površinskih voda.



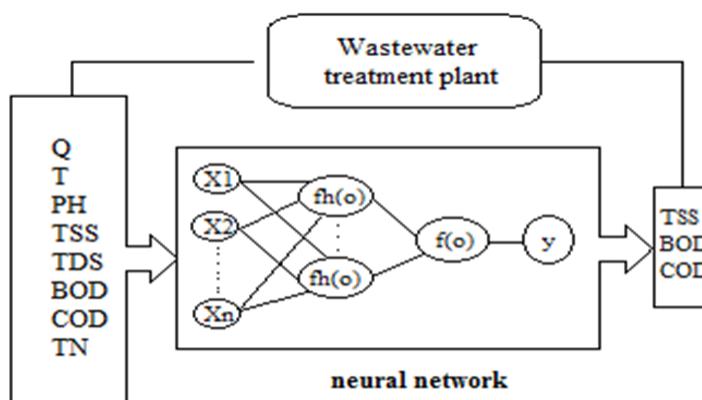
Slika 1. Uredaj za pročišćavanje otpadnih voda Perkandabad

Dadar, S., Pezeshki, A., Đurin, B., Dogančić, D.

Kvalitativna procjena rada uređaja za pročišćavanje otpadnih voda modelom neuronske mreže optimiziranim genetskim algoritmom

Ispitani parametri za ocjenu kvalitete otpadne vode bili su BPK5 (biokemijska potreba za kisikom u 5 dana), KPK (kemijska potreba za kisikom), ULČ (ukupne lebdeće čestice) i pH. Korišteni su i meteorološki podaci, uključujući prosječnu dnevnu temperaturu zraka, trajanje sijanja sunca i dnevnu količinu oborina.

Za početak modeliranja neuronske mreže, prvo su podaci nasumično podijeljeni za ispitivanje. Ulazni i izlazni podaci i arhitektura modela prikazani su na slici 2.



Slika 2. Model arhitekture modela neuronske mreže

Najsloženija umjetna mreža, koja često uključuje parametre razmatrane u ovom istraživanju, je umjetna MLP (eng. multi-layer perceptron) mreža. S obzirom da je prema Kolmogorovljevom teoremu maksimalni broj slojeva nelinearne mreže 3 sloja, od kojih je jedan izlazni sloj, time 2 sloja mogu riješiti problem.

Prije unošenja karakteristika u model, razmatrana je odgovarajuća težina za svaki parametar. U ovoj studiji vektori [0,1] su definirani za model tako da ako je težina svojstva nula, to svojstvo će praktično biti bez djelovanja u sustavu.

Uz pretpostavku da postoji n neurona u svakom sloju u ovom modelu, to uključuje ispitivanje strukture n^2+n različitih stanja (n stanja u prvom sloju i n stanja u drugom sloju), ali s obzirom na to da postoji način brisanja sloja, tada postoji ukupno $n+1$ stanje. Statistički pokazatelji korišteni u ovoj analizi uključuju koeficijent korelacije, srednju kvadratnu relativnu pogrešku i absolutnu srednju postotnu relativnu pogrešku.

Na temelju kvantitativnih i kvalitativnih podataka o dolaznoj otpadnoj vodi, procesni uvjeti, meteorološki podaci i konačno, efluent su određeni kao faktori koji utječu na rad uređaja za pročišćavanje. Sljedeći korak je bilo predviđanje koncentracija parametara u efluentu na temelju određujućih faktora i modela neuronske mreže. Kako bi se postigla veća točnost u modeliranju uređaja za pročišćavanje, korišten je genetski algoritam za optimizaciju neuronske mreže. Konačno, predviđena je koncentracija svakog od tri parametra u efluentu te su u stvarnim vrijednostima izmjereni statistički kriteriji koeficijenta korelacije R, relativna srednja kvadratna pogreška predviđanja (rRMSPE) i relativna srednja apsolutna postotna pogreška (rMAPE), i time je model procijenjen [17]. Treba napomenuti da postotak dvaju pokazatelja, rRMSPE i rMAPE, ne smije biti veći od 20%.

Koeficijent korelacije:

$$R = \frac{\sum (y_{i, \text{opazeno}} - \mu_{y, \text{opazeno}})(y_{i, \text{simulirano}} - \mu_{y, \text{simulirano}})}{n(\sigma_{y, \text{opazeno}})(\sigma_{y, \text{simulirano}})}$$

Dadar, S., Pezeshki, A., Đurin, B., Dogančić, D.

Kvalitativna procjena rada uređaja za pročišćavanje otpadnih voda modelom neuronske mreže optimiziranim genetskim algoritmom

Srednja kvadratna relativna postotna pogreška::

$$rRMSPE = \sqrt{\frac{\sum \left(\frac{y_{i, \text{opaženo}} - y_{i, \text{simulirano}}}{y_{i, \text{opaženo}}} \right)^2}{n}} \times 100$$

Relativna srednja apsolutna postotna pogreška:

$$rMAPE = \frac{\left| \sum \left(\frac{y_{i, \text{opaženo}} - y_{i, \text{simulirano}}}{y_{i, \text{opaženo}}} \right) \right|}{n} \times 100$$

3. REZULTATI

U ovoj studiji, genetskim algoritmom je tražen optimalni odgovor za 450 generacija i procijenjeno je 150 mogućih odgovora u prostoru traženja u svakoj generaciji. Za parametar BPK u efluentu sažeti su rezultati 5 izvođenja modela. Maksimalna i minimalna vrijednost koeficijenta korelacijskog rezultata dobivenih iz modela bile su jednake 0,93, 0,86, odnosno 1,08, a njihov prosjek je izračunat kao prikladan broj zbog polu-suvremene prirode uređaja za pročišćavanje (Tablica 1).

Tablica 1. Prediktivni rezultati parametara ULČ, BPK i KBK uređaja za pročišćavanja otpadnih voda

Parametar	R	MSE
BPK	0,89	2,3
KPK	0,82	34,2
ULČ	0,83	2,07

Ispitivanje broja odabralih neurona u prvom i drugom skrivenom sloju pokazalo je da u 16% slučajeva mreža ima dva skrivena sloja, pri čemu je prosječan broj neurona u prvom sloju 16, a u drugom sloju 11. U preostalih 84% mreža je imala samo jedan skriveni sloj, s prosječno 14 neurona. U prosjeku, najbolja mrežna struktura je imala dva skrivena sloja s prosječnim brojem neurona 15 u prvom sloju i 2 u drugom sloju. Nadalje, mreža je imala samo jedan skriveni sloj s 11 neurona pri maksimalnoj vrijednosti koeficijenta korelacijskog rezultata (R). Model genetskog algoritma - umjetne neuronske mreže (eng. GA-ANN) s maksimalnim koeficijentom korelacijskog rezultata od 0,93 i stopama pogreške rRMSPE i rMAPE od 10% i 7% bio je učinkovit model u predviđanju koncentracije parametra BPK i dao je točne rezultate. To znači da se može koristiti u modeliranju uređaja za pročišćavanje. Zbog biološke obrade, parametri koji utječu na rast i aktivnost mikroorganizama kao što su ulazni omjer UKPKul/UBPKul, sadržaj otopljenog kisika, temperatura aeracije lagune i ulazno opterećenje UBPK su također bili prioritet u predviđanjima modela. Na temelju rezultata dobivenih iz optimiziranog modela umjetne mreže, faktori koji utječu na uspješnost spomenutog pročišćavanja određeni su parametrom UBPK. U tablici 2 prikazan je sažetak rezultata, skupa s težinom svakog parametra.

Dadar, S., Pezeshki, A., Đurin, B., Dogančić, D.

Kvalitativna procjena rada uređaja za pročišćavanje otpadnih voda modelom neuronske mreže optimiziranim genetskim algoritmom

Tablica 2. Sažetak učinkovitih faktora u predviđanju parametra UBPK efluenta skupa s njihovim pripadajućim težinama

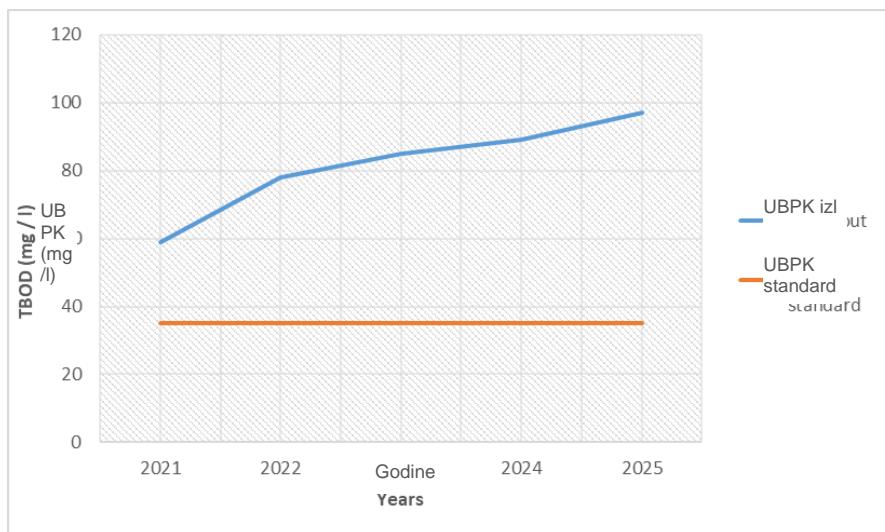
Važni parametri	Težina značajke u predviđanju koncentracija UBPK
Q	0,8
OK	0,88
Ulazno opterećenje zagađenja UBPK	0,89
Br. aeratora	0,66
T _L	0,85
T _{ZRAKA}	0,73

U gornjoj tablici, dva parametra (ispuštanje i opterećenje onečišćenja) su među ulaznim parametrima koji imaju važnu ulogu u predviđanju kvalitete otpadnih voda. Na temelju dostupnih podataka uočeno je da je brzina protoka u većini slučajeva veća od projektirane, a jedno od dostupnih rješenja moglo bi biti smanjenje ulaznog protoka. Među procesnim parametrima, otopljeni kisik (OK) i temperatura lagune imali su veliku prednost u predviđanju UBPK efluenta. Općenito, vrsta sustava aeracije i njegova brzina se mogu izravno povezati s otopljenim kisikom. Temperatura lagune, kao i stopa taloženja ULČ, bili su učinkoviti. Jedan od najboljih načina za poboljšanje rada uređaja za pročišćavanje bila je primjena sustava dubinske aeracije umjesto površinske aeracije, čime se učinkovito povećava koncentracija otopljenog kisika, povećava se temperatura sadržaja aeracijske lagune i stvara željeno miješanje. Budući da se sustav aeracijske lagune nalazi na otvorenom, praktički i izravno je nemoguće poduzeti učinkovite mjere za kontrolu utjecaja temperature zraka (T_{ZRAKA}) na sustav obrade. Međutim, korištenjem dubinskih aeratora umjesto površinskih, može se smanjiti utjecaj temperature zraka na temperaturu sadržaja aeracijske lagune. Budući da je zrak više u dodiru s površinom aeracijske lagune, do najvećeg gubitka toplinske energije dolazi u površinskim aeratorima. Prema ispitnim rezultatima ovog istraživanja, najvažniji parametar u predviđanju kvalitete otpadnih voda je bila količina dotoka. Na temelju statistike i podataka iz projekta može se dobiti ulazni tok u uređaj za pročišćavanje u sljedećim godinama uz dobru aproksimaciju, uz stopu povećanja ulazne koncentracije UBPK i ULČ koja za svakih 10 godine iznosi 5%. Zbog toga se, s obzirom na ovu rastuću stopu, koncentracija UBPK i ULČ otpadne vode koja ulazi u uređaj za pročišćavanje svake godine u razdoblju 2021. – 2025. procjenjuje na 1,005. Kako bi se predvidjela kvaliteta efluenta, uz pretpostavku da nema korektivnih mjera za poboljšanje rada uređaja za pročišćavanje, model je proveden u dva režima. U prvom scenariju, struktura mreže i težina značajki su razmatrani za slučaj kada je model imao najveći koeficijent korelacijske. U drugom slučaju, prosječan broj neurona u svakom sloju i srednja težina značajki u 15 izvedbi modela su uzeti u obzir za strukturu i težinu značajki. U prvom slučaju implementacija modela o parametru UBPK dala je bolje rezultate, koji su sažeti na slici 3.

Te koncentracije su mnogo veće od standardnog parametra UBPK u efluantu. Stoga je potrebno implementirati odgovarajuće strategije kako bi se što prije poboljšala kvaliteta efluenta i osigurala učinkovitost rješenja i stvarno poboljšanje kvalitete efluenta tijekom različitih faza prema predviđanjima modela.

Dadar, S., Pezeshki, A., Đurin, B., Dogančić, D.

Kvalitativna procjena rada uređaja za pročišćavanje otpadnih voda modelom neuronske mreže optimiziranim genetskim algoritmom



Slika 3. Predviđanje prosječne godišnje koncentracije parametra UBPK u efluentu uređaja za pročišćavanje (mg/L)

4. ZAKLJUČAK

Ova studija je provedena kako bi se procijenila učinkovitost uređaja za pročišćavanje otpadnih voda Mashhad i ocijenili faktori kvalitete ulazne otpadne vode i efluenta kako bi se razvio optimizirani model mreže umjetne inteligencije i procijenila njegova učinkovitost. Općenito, na temelju rezultata provedene studije, rezultati su bili kako slijedi. U polumehaničkim uređajima za pročišćavanje, različiti faktori utječu na rad sustava. Općenito, ovi faktori se mogu podijeliti u tri skupine: kvantitativni i kvalitativni parametri ulazne otpadne vode, procesni parametri i klimatski parametri. Na temelju dobivenih rezultata, najvažniji faktori koji utječu na rad uređaja za pročišćavanje Mashhad bili su ulazni protok, omjer UKPKul/UBPKul, temperatura i opterećenje organske tvari u ulaznoj otpadnoj vodi, a među procesnim faktorima količina otopljenog kisika, temperatura i pH u sadržaju lagune i nekoliko aktivnih aeratora. Klimatski faktori koji su utjecali na rad bili su temperatura zraka i broj sunčanih sati. Model neuronske mreže optimiziran je algoritmom genetskog pretraživanja uz potpunu pretragu, a rezultati su dobiveni u maksimalnom koeficijentu korelacije za parametar UBPK od 0,89 i odgovarajućim rRMSE i rMAPE za kvalitativni parametar od 10%, odnosno 7%. Model neuronske mreže izdvojio je važne parametre u predviđanju koncentracije parametra UBPK u efluentu – brzinu ispuštanja i opterećenje onečišćenjem organskim tvarima ulazne otpadne vode, među procesnim faktorima – koncentraciju otopljenog kisika, temperaturu sadržaja lagune i nekoliko aktivnih aeratora i od klimatskih uvjeta – temperaturu zraka. Ulazni protok istraživanog uređaja za pročišćavanje u usporedbi s drugim ulaznim karakteristikama imao je veću težinu u predviđanju koncentracije parametra UBPK efluenta. Stoga, kako bi se poboljšao učinak navedenog uređaja za pročišćavanje, potrebno je poduzeti potrebne mjere za smanjenje i kontrolu ulaznog toka u različite jedinice uređaja za pročišćavanje

Dadar, S., Pezeshki, A., Đurin, B., Dogančić, D.

Kvalitativna procjena rada uređaja za pročišćavanje otpadnih voda modelom neuronske mreže optimiziranim genetskim algoritmom

LITERATURA

1. Vajedi M., Shahhosseini S.H.: Modeling of Activated Sludge Process Using Sequential Adaptive Neuro-fuzzy Inference System (In Persian). *J. Water Wastewater* 2013, 335, 121–131.
2. Qasim S.R.: *Wastewater Treatment Plants: Planning, Design, and Operation*, Chemical Rubber Company (CRC): Boca Raton, FL, USA, 1998, p. 1126.
3. Metcalf & Eddy, Burton F.L., Stensel H.D.: *Wastewater Engineering: Treatment and Reuse*, McGraw-Hill Series in Civil and Environmental Engineering, McGraw Hill: New York, NY, USA, 2004; p. 1819.
4. Pescod M.B.: *Wastewater Treatment and Use in Agriculture, Food and Agriculture Organization of the United Nations*: Rome, Italy, 1992, p. 4.
5. Saeedi M., Khalvati F., Ahiliani, A.: Application of electro-coalescence to reduce COD of the southern Pars gas refinery wastewater (In Persian). *J. Water Wastewater* 2012, 73, 40–48.
6. Qasim S.R.: *Wastewater Treatment Plants: Planning, Design and Operation*, 2nd ed., McGraw Hill: New York, NY, USA, 1991.
7. Arceivala S.J.: *Water Pollution Control*, McGraw Hill: New York, NY, USA, 1989; Volume 2, pp. 189–193.
8. Raha D.: Exploring Artificial Neural Networks Modeling for a Biological Nutrient Removal (BNR) Sewage Treatment Plant (STP) to Forecast Effluent Suspended Solids, Indian Inst. Chem. Eng. 2010, 49, 205–220.
9. Eckenfelder W.W.: *Industrial Water Pollution Control*, McGraw Hill: New York, NY, USA, 2000; Volume 2, pp. 189–193.
10. Zare Abiane H., Bayat Varkeshi M., Bayat Varkeshi J.: Evaluation of Ekbatan wastewater treatment plant using artificial neural network (In Persian), *J. Envirol.* 2013, 38, 85–98.
11. Oliveira-Esquerre K.P., Seborg D.E., Bruns, R.E., Mori, M.: Application of Steady-State and Dynamic Modeling for the Prediction of the BOD of an Aerated Lagoon at a Pulp and Paper Mill: Part I. Linear Approaches, *Chem. Eng. J.* 2004, 104, 73–81.
12. Cao G., Li M., Mo C.: Prediction of the Anaerobic Systems Based on Neural Network with Multipopulation Parallel Genetic Algorithm. In Proceedings of the Second International Symposium on Intelligent Information Technology Application, Shanghai, China, 20–22 December 2008; pp. 947–951.
13. Abu Qdais H., Bani Hani K., Shatnawi N.: Modeling and Optimization of Biogas Production from a Wastewater Digester Using Artificial Neural Network and Genetic Algorithm. *J. Resour. Conserv. Recycle.* 2010, 54, 359–363.
14. Fang F., Ni B.J., Xie W.M., Sheng, G.P., Liu S.G., Tong Z.H., Yu H.Q.: An Integrated Dynamic Model for Simulating a Full-Scale Municipal Wastewater Treatment Plant Under Fluctuating Conditions, *Chem. Eng. J.* 2010, 160, 522–529.
15. Gueguim Kana E.B., Oloke J.K., Lateef A., Adesiyen M.O.: Modeling and Optimization of Biogas Production on Saw Dust and Other Co-Substrates Using Artificial Neural Network and Genetic Algorithm, *Renew. Energy* 2010, 46, 276–281.
16. Piuleac C.G., Curteanu S., Rodrigo M.A., Sáez C., Fernández F.J.: Optimization Methodology Based on Neural Networks and Genetic Algorithms Applied to Electro-Coagulation Processes, *Cent. Eur. J. Chem.* 2010, 11, 1213–1224.
17. Armstrong J.S., Collopy F.: Error Measure for Generalizing About Forecasting Methods, Empirical Comparisons. *Int. J. Forecast.* 1992, 8, 69–80.