

# PROCJENA UČINKOVITOSTI RADA UREĐAJA ZA PROČIŠĆAVANJE OTPADNIH VODA UPOTREBOM ALATA STROJNOG UČENJA

## PERFORMANCE ASSESSMENT OF WASTEWATER TREATMENT PLANT WITH MACHINE LEARNING TOOLS

Goran Volf\*, Nataša Atanasova\*\*

### Sažetak

*Uređaji za pročišćavanje otpadnih voda (UPOV) s aktivnim muljem su dinamični i složeni sustavi čije se upravljanje može poboljšati primjenom različitih pristupa modeliranju i predviđanja njihova rada. U ovom radu je korišten alat strojnog učenja (modelska stabla) za izradu modela koncentracije kemijske potrošnje kisika (KPK) na izlazu pročišćene otpadne vode iz UPOV-a s aktivnim muljem. Za modeliranje su korišteni mjereni podaci na ulazu i izlazu otpadne vode iz UPOV-a. U izradi modela koncentracije KPK su korišteni programski alat Weka i algoritam za izradu modelskih stabala M5P. Model dobiven alatom strojnog učenja ima veliku opisnu moć i koeficijent korelacije te se zato može primijeniti u modeliranju koncentracije KPK. Time se u ovom radu ukazuje i na prednosti primjene alata strojnog učenja u izradi modela UPOV-a.*

**Ključne riječi:** *uređaj za pročišćavanje otpadnih voda s aktivnim muljem, strojno učenje, modelska stabla, modeliranje, KPK*

### Abstract

*Wastewater treatment plants (WWTPs) with activated sludge are complex and dynamic systems whose management can be improved by using different modelling and prediction approaches to their work. A machine learning tool for the development of model trees was used in this paper in order to develop a model for chemical oxygen*

---

\* Građevinski fakultet Sveučilišta u Rijeci, Radmile Matejčić 3, 51000 Rijeka

E-mail: [goran.volf@gradri.uniri.hr](mailto:goran.volf@gradri.uniri.hr)

\*\* LEQUEA, Univeristy of Girona, Carrer Pic de Peguera 15, 17003 La Creutea, Giroana, Spain

E-mail: [natasa.atanasova@udg.edu](mailto:natasa.atanasova@udg.edu)

*demand (COD) in the wastewater effluent from the WWTP with activated sludge. The data measured in both the influent and the effluent of WWTP were used for modelling. For the COD model the machine learning tool Weka and the algorithm for the development of model trees M5P were used. The obtained model has a high descriptive power and correlation coefficient and thus can be used for modelling purposes. Also, the purpose of this paper is to show the benefits of using machine learning tools for developing WWTP models.*

**Key words:** *wastewater treatment plant with activated sludge, machine learning, model trees, modelling, COD*

## 1. Uvod

Biološka obrada otpadne vode s aktivnim muljem u današnje je vrijeme jedan od najzastupljenijih tehnoloških procesa na uređajima za pročišćavanje otpadnih voda (UPOV-a) zbog svojih mogućnosti, ekonomičnosti i efikasnosti. Dvije glavne komponente ovog procesa čine aeracijski bazen, odnosno bioreaktor i sekundarni, odnosno naknadni taložnik [1].

Biološka obrada otpadne vode sastoji se od složenih fizikalnih, kemijskih i bioloških procesa kojima se organska tvar, dušik i fosfor uklanjaju iz otpadne vode. Za uspješno pročišćavanje otpadne vode potrebne su odgovarajuće koncentracije te uvjeti za rast mikroorganizama koji se moraju postići u bioreктору [1].

Zbog složenosti i osjetljivosti procesa pročišćavanja teško je kontinuirano održavati optimalne radne uvjete u samom UPOV-u. Samim time modeliranje postaje vrlo koristan i često korišten alat za simulaciju i kontrolu rada UPOV-a. Za modeliranje UPOV-a koriste se obično matematički modeli (npr. modeli aktivnog mulja; eng. *Active sludge models* - ASM; [2]). U ovom radu za modeliranje UPOV-a korišten je alat strojnog učenja Weka [3], odnosno algoritam za izradu modelskih stabala. Za modeliranje UPOV-a do sada su korišteni različiti alati i metode, kao što su npr. statistički modeli [4, 5, 6], ekspertni sustavi [5, 7, 8], pristupi temeljeni na bazama znanja [9], neuronske mreže [5, 10, 11, 12, 13], hibridni pristupi [14, 15, 16, 17] te različite vrste strojnog učenja [5, 12, 18, 19, 20, 21].

Svrha je modela izrađenog upotrebom metode strojnog učenja u ovom radu modelirati koncentraciju kemijske potrošnje kisika (KPK) na izlazu otpadne vode iz uređaja. Vrijednosti KPK na izlazu iz uređaja smatraju se najboljim pokazateljima kvalitete rada uređaja, odnosno zaostalog organskog opterećenja, te se time ukazuje i na uspješnost samog procesa pročišćavanja [4, 22, 23]. Zbog toga se navedena varijabla definira kao promatrana izlazna veličina koja najbolje ukazuje na stanje procesa, te kao


varijabla čiju se dinamiku želi objasniti i predvidjeti modelom strojnog učenja. Upotreba modela bi omogućila predviđanje vrijednosti KPK, a u slučajevima kad ta premaši dopušteno ograničenje propisano Pravilnikom o graničnim vrijednostima emisija otpadnih voda [24] bi omogućila i pravovremenu reakciju kojom bi se smanjila na prihvatljivu razinu [4].

Zato je cilj ovog rada, ne samo modelirati koncentraciju KPK na izlazu iz UPOV-a primjenom strojnog učenja, nego i ukazati na neke od prednosti modeliranja alatima strojnog učenja.

## 2. Uređaj za pročišćavanje otpadnih voda

### 2.1. Opis uređaja

Uređaj modeliran alatom strojnog učenja predstavlja uređaj drugog stupnja pročišćavanja otpadnih voda. Veličina uređaja iznosi 9.500 ekvivalent stanovnika (ES). UPOV se na liniji vode sastoji od mehaničkog predtretmana i drugog stupnja pročišćavanja. Mehanički predtretman sastoji se od grube i fine rešetke te aeriranog pjeskolova-mastolova. Drugi stupanj pročišćavanja sastoji se od selektora, aeracijskih bazena i sekundarnih taložnica. Tok je vode na uređaju ovaj: otpadna voda ulazi u kanal u kojemu je uzvodno smještena gruba, a nizvodno i fina rešetka, nakon koje otpadna voda dolazi do aeriranog pjeskolova-mastolova. Nakon toga voda se transportira u selektor, gdje se odvija selekcija mikroorganizama (kontakt biomase s otpadnom vodom). Voda se zatim transportira u aeracijske bioreaktore, gdje se odvija biološko pročišćavanje otpadne vode s aktivnim muljem. Na kraju se mješavina vode i aktivnog mulja transportira u sekundarne taložnice, gdje se flokule aktivnog mulja talože, a pročišćena se voda ispušta u recipijent (more) kroz podmorski ispušt. Dio istaloženog mulja iz sekundarnih taložnica vraća se povratnim tokom nazad u selektor, odnosno aeracijski bioreaktor, kako bi se održala potrebna koncentracija aktivnog mulja za uspješan tretman procesa u aeracijskim bioreaktorima.



**Slika 1.** Shema toka vode na UPOV-u

## 2.2. Baza podataka

Podaci korišteni za modeliranje mjereni su na ulazu sirove otpadne vode na UPOV te na samom izlazu pročišćene otpadne vode s UPOV-a. Podaci su prikazani kao srednje vrijednosti tijekom jednog dana, to jest jedan zapis u bazi predstavlja jednodnevnu situaciju operacije UPOV-a. Baza se sastoji od ukupno 718 situacija (dana).

Za nadopunu podataka koji nedostaju u ukupnom skupu podataka korištena je metoda kubne „spline“ interpolacije između izmjerenih vrijednosti.

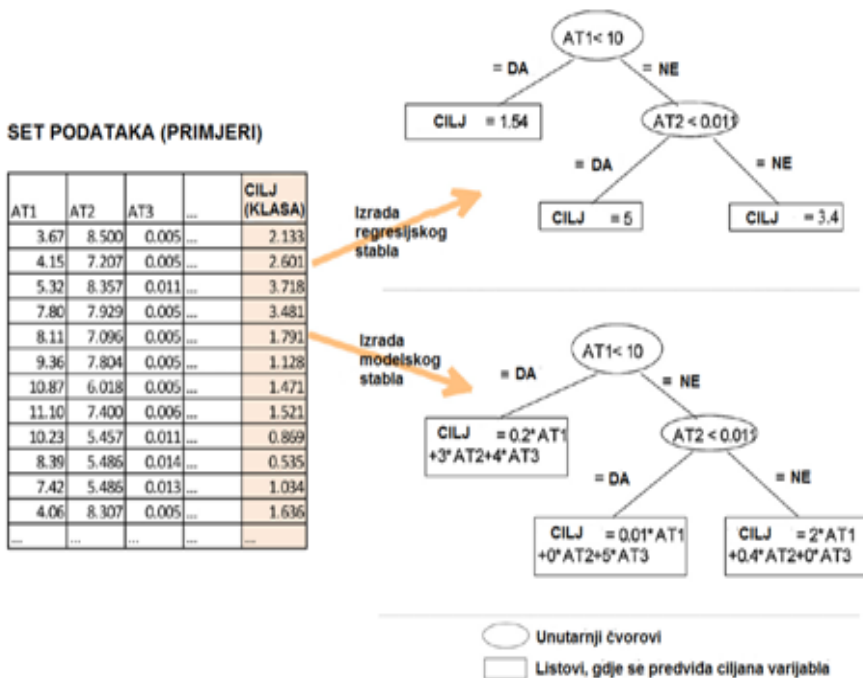
**Tablica 1.** Mjereni podaci na UPOV-u

Podatak	Opis	Mjerna jedinica	Mjesto uzorkovanja
$Q_{ulaz}$	Protok na ulazu	$m^3/s$	Ulaz vode na uređaj
$Q_{izlaz}$	Protok na izlazu	$m^3/s$	Izlaz vode iz uređaja
$T_{izlaz}$	Tempertaura na izlazu	$^{\circ}C$	Izlaz vode iz uređaja
$KPK_{ulaz}$	Kemijska potrošnja kisika na ulazu	$mg/l$	Ulaz vode na uređaj
$KPK_{izlaz}$	Kemijska potrošnja kisika na izlazu	$mg/l$	Izlaz vode iz uređaja
$NH_4-N_{ulaz}$	Amonij na ulazu	$mg/l$	Ulaz vode na uređaj
$NH_4-N_{izlaz}$	Amonij na izlazu	$mg/l$	Izlaz vode iz uređaja
$SS_{ulaz}$	Ukupna suspendirana tvar na ulazu	$mg/l$	Ulaz vode na uređaj

## 3. Strojno učenje, regresijska i modelska stabla

Za razliku od jednostavne linearne regresije, koja izračunava jednu jednadžbu za cijeli skup podataka, regresija strukturirana u obliku stabla dijeli skup podataka u nekoliko podskupova na koje se može primijeniti ujednačena vrijednost klase ili pak linearna jednadžba. Podjela na podskupove temelji se na testovima vrijednosti ulaznih atributa, koji se postavljaju kao čvorišta u regresijskom ili modelskom stablu. Prema tome su regresijska i modelska stabla hijerarhijske strukture sastavljene od čvorova i grana, gdje unutarnji čvorovi sadrže testove na ulaznim atributima. Svaka grana unutarnjeg testa odgovara rezultatima testa te su predviđanja za vrijednosti ciljane varijable (klase) pohranjene u listovima stabala koji čine terminalne čvorove u stablu. Listovi u regresijskom stablu

sadrže jednu prosječnu vrijednost za predviđanje klase, dok u modelskom stablu listovi sadrže jednažbu koja predviđa vrijednost ciljane varijable, odnosno klase. Slika 2 prikazuje postupak izrade regresijskih i modelskih stabala.



**Slika 2.** Primjer izrade regresijskih i modelskih stabala

Jedan je od najčešće korištenih algoritama za izradu regresijskih i modelskih stabala algoritam M5 [25]. Za potrebe eksperimenta u ovom radu korištena je varijacija algoritama M5 pod nazivom M5P, koji je kao takav implementiran u programski paket Weka [3].

Nakon što se od seta podataka za treniranje (učenje) stablo izradi, treba procijeniti i kvalitetu modela, tj. točnost predviđanja. To se može učiniti simulacijom modela na testnom setu podataka te uspoređivanjem predviđenih vrijednosti ciljane varijable sa stvarnim (izmjerenim) vrijednostima podataka. Druga mogućnost je odabir križne validacije (engl. *Cross-validation*), gdje se skup podataka za treniranje podijeli na odabrani broj podskupova ( $n$ ), svaki se podskup koristi za testiranje, a ostatak ( $n-1$ )

skupa se koristi treniranje modela. Konačna pogreška je prosjek pogrešaka od svih modela tijekom cjelokupnog postupka izrade modela.


Veličina pogreške između stvarne (mjerene) i predviđene vrijednosti se može izračunati, a između nekoliko poznatih mjera za ocjenu točnosti modela je najznačajniji koeficijent korelacije ( $R$ ).

#### **4. Postavke eksperimenta**

Za eksperiment je korišten algoritam strojnog učenja M5P, implementiran u programski paket Weka [3]. Eksperiment je postavljen tako da omogući izradu model koncentracije KPK na izlazu pročišćene otpadne vode iz UPOV-a. Koncentracija KPK na izlazu iz UPOV-a je definirana kao zavisna varijabla, dok su protok, koncentracija KPK, amonij i ukupne suspendirane tvari na ulazu sirove otpadne vode na UPOV definirane kao nezavisne varijable.

#### **5. Rezultati i diskusija**

Svrha modela izrađenog metodom strojnog učenja je predvidjeti promjenu koncentracije KPK na izlazu pročišćene otpadne vode iz UPOV-a primjenom mjerenih varijabli na ulazu sirove otpadne vode na UPOV. Od danog seta podataka (Tablica 1) je izrađen model koncentracije KPK na izlazu iz uređaja (Slika 3). Model se sastoji od ukupno 7 listova i 6 čvorova koji sadrže vrijednosti varijabli mjerenih na ulazu otpadne vode na UPOV (vidjeti Tablicu 1). Svaki od listova sadrži po jednu jednadžbu kojom se proračunava koncentracija KPK na izlazu pročišćene vode iz UPOV-a, ovisno o samoj strukturi stabla. Jednažbe u pojedinim listovima stabala su prikazane u Tablici 2. Koeficijent korelacije  $R$  za prikazani model upotrebom križne validacije iznosi 0,64.




**Slika 3.** Model koncentracije KPK na izlazu iz UPOV-a

**Tablica 2.** Jednadžbe modela sa Slike 3 za proračun koncentracije KPK na izlazu iz UPOV-a

Broj jednadžbe	Jednadžba
1	$KPK_{izlaz} = -0,0088 * Q_{ulaz} + 0,0954 * KPK_{ulaz} - 1,0529 * NH_4N_{ulaz} - 0,0215 * SS_{ulaz} + 45,669$
2	$KPK_{izlaz} = -0,0049 * Q_{ulaz} + 0,038 * KPK_{ulaz} - 0,1132 * NH_4N_{ulaz} - 0,0172 * SS_{ulaz} + 20,0079$
3	$KPK_{izlaz} = -0,0006 * Q_{ulaz} + 0,0016 * KPK_{ulaz} - 0,0016 * NH_4N_{ulaz} - 0,0153 * SS_{ulaz} + 20,1564$
4	$KPK_{izlaz} = -0,0006 * Q_{ulaz} + 0,0016 * KPK_{ulaz} - 0,0034 * NH_4N_{ulaz} - 0,0153 * SS_{ulaz} + 23,1117$
5	$KPK_{izlaz} = -0,0009 * Q_{ulaz} + 0,0046 * KPK_{ulaz} + 0,1559 * NH_4N_{ulaz} - 0,0957 * SS_{ulaz} + 24,0748$
6	$KPK_{izlaz} = -0,0009 * Q_{ulaz} + 0,0046 * KPK_{ulaz} + 0,1559 * NH_4N_{ulaz} - 0,0818 * SS_{ulaz} + 17,0162$
7	$KPK_{izlaz} = -0,0009 * Q_{ulaz} + 0,005 * KPK_{ulaz} + 1,3378 * NH_4N_{ulaz} - 0,3479 * SS_{ulaz} - 7,1299$

Za predviđanje koncentracije KPK na izlazu iz uređaja treba iz modela prikazanoga na Slici 3 odabrati odgovarajuću linearnu jednadžbu ovisno o vrijednostima pojedinih atributa u čvorovima stabla. Ako je vrijednost  $KPK_{ulaz}$  u glavnom čvoru najviše 559,89 mg/l, prelazi se na sljedeći čvor  $SS_{ulaz}$ . Ako je vrijednost u čvoru  $SS_{ulaz}$  najviše 1,48 mg/l, proračunava se vrijednost  $KPK_{izlaz}$  prema jednadžbi 1. Za vrijednosti  $SS_{ulaz}$  iznad 1,48 mg/l te u sljedećem čvoru  $SS_{ulaz}$  najviše 3,40 mg/l proračunavaju se vrijednosti  $KPK_{izlaz}$  prema jednadžbi 2. Za vrijednosti  $SS_{ulaz}$  iznad 3,40 mg/l prelazi se na idući čvor  $NH_4N_{ulaz}$ , te ako je vrijednost u čvoru najviše 37,27 mg/l, proračunavaju se vrijednosti  $KPK_{izlaz}$  prema jednadžbi 3, a u suprotnom prema jednadžbi 4. Za slučajeve kada je u glavnom čvoru vrijednost  $KPK_{ulaz}$  iznad 559,89 mg/l, prelazi se na idući čvor  $KPK_{ulaz}$ , gdje se za vrijednosti u čvoru iznad 790,31 mg/l proračunavaju vrijednosti  $KPK_{izlaz}$  prema jednadžbi 7. Za vrijednosti u čvoru  $KPK_{ulaz}$  najviše 790,31 mg/l prelazi se na idući čvor  $SS_{ulaz}$ , te se za vrijednosti iznad 5,95 mg/l vrijednost  $KPK_{izlaz}$  proračunava prema jednadžbi 6, a u suprotnom prema jednadžbi 5.


Sa Slike 3 može se vidjeti kako koncentracija KPK na izlazu iz UPOV-a najviše ovisi o koncentraciji KPK na ulazu u UPOV (početni čvor), zatim o  $SS$  te o  $NH_4N$ , dok se protoci ( $Q$ ) uopće ne pojavljuju u samom stablu, već samo u jednadžbama pojedinih listova. Obradom rezultata modela (Slika 5) veće vrijednosti KPK na izlazu iz UPOV-a daje desna strana modela, odnosno stabla prikazanoga na Slici 3, a manje vrijednosti lijeva strana modela. Prema tome, manje vrijednosti koncentracije KPK na izlazu povezane su s čvorovima u kojima se nalaze  $SS$  te  $NH_4N$ , a veće vrijednosti s  $KPK$  te  $SS$  na ulazu u UPOV.



**Slika 4.** Koeficijent korelacije „R“ između mjerenih i modeliranih vrijednosti koncentracije KPK na izlazu iz UPOV-a



Prikaz izmjerenih i modeliranih vrijednosti koncentracije KPK na izlazu iz UPOV-a vidi se na Slici 4. Usporedba vremenske serije mjerenih i modeliranih vrijednosti koncentracije KPK može se vidjeti na Slici 5. Sa Slike 5 može se također vidjeti dobra prilagodba mjerenih i modeliranih vrijednosti koncentracije KPK, a također se vizualnom inspekcijom može zaključiti da se vršne točke zadovoljavajuće dobro podudaraju.



**Slika 5.** Usporedba vremenske serije mjerenih i modeliranih vrijednosti koncentracija KPK na izlazu iz UPOV-a

Rezultati provedenog eksperimenta pokazuju da je pri modeliranju korisno primjenjivati različite pristupe. Za ovu i svaku drugu metodu modeliranja upotrebom mjerenih podataka je bitno u bazu podataka uključiti dovoljno različitih situacija iz kojih se algoritam strojnog učenja može naučiti predviđati zavisnu varijablu. Za poboljšanje rezultata modela bilo bi korisno raspolagati s više onih mjerenih parametara na ulazu sirove otpadne vode na UPOV koji utječu na zavisnu varijablu, poput temperature vode, pH, koncentracije klorida (radi li se o UPOV-u u priobalnom području poput ovog koji se razmatra u ovom radu), starosti mulja, povratnog toka mulja, koncentracije otopljenog kisika u aeracijskom bioreaktoru, odnosa  $F/M$  (engl. *Food to Mass ratio*) i svih drugih za koje se procijeni da u duljem vremenskom razdoblju mogu značajno utjecati na KPK [1]. Budući da baza podataka koja je korištena u ovom radu sadrži relativno malo ulaznih parametara, točnije predviđanje izlaznih koncentracija KPK iz UPOV-a se ne može očekivati, ali se može ocijeniti kako se dobiveni model ponaša očekivano i daje zadovoljavajuće rezultate.

## 6. Zaključak

Upotreba metode strojnog učenja za izradu modela iz baza podataka, u ovom radu korištenih modelskih stabala, uspješno je primijenjena za modeliranje UPOV-a, odnosno koncentracije KPK na izlazu pročišćene otpadne vode iz UPOV-a. Dobiveni model je ponajprije jednostavan, razumljiv te relativno točan u predviđanjima koncentracija KPK na izlazu iz UPOV-a.

Za ovakav pristup modeliranju je važno da baza podataka sadrži stvarne vrijednosti atributa i da postoji informacija o vremenu kada su podaci sakupljeni kako bi se u model mogla ukomponirati i dinamika sustava koji se modelira.

Iz ovoga se mogu izdvojiti neke od prednosti upotrebe alata strojnog učenja pri modeliranju, a to su izgradnja opisnih, odnosno modela bijele kutije, koji interpretaciju samih modela olakšava, a uvid u funkcioniranje modela, odnosno sustava koji se modelira, čini model razumljivijim.

Kako je to u ovom radu i prikazano, za jednostavnije i učinkovitije upravljanje UPOV-ima je važno istaknuti prednosti koje u tomu može imati korištenje alata strojnog učenja.

Buduća istraživanju i rad na nadogradnji i poboljšanju točnosti modela usmjerena su na povećanje i obogaćivanje baze podataka koja bi omogućila modeliranje i drugih parametara, poput dušika i fosfora, te bi se samim time mogle otkriti i nove veze te uzorci među podacima.

## Literatura

- [1] Henze, M.; Herremoes, P.; Jansen, J.C.; Arvin E. 2002. *Wastewater Treatment-Biological and Chemical Processes*, Third edition. Springer. New York. US.
- [2] IWA Task group on mathematical modelling for design and operation of biological wastewater treatment, *Activated sludge models ASM1, ASM2, ASM2d and ASM3*. 2000. IWA Publishing. London. UK.
- [3] Witten, I.H.; Frank, E. 2000. *Data mining-Practical machine learning Tools and Techniques with Java implementations*. Academic Press.
- [4] Čurlin, M.; Bevetek, A.; Ležajić, Z.; Deverić-Meštrović, B.; Kurtanjek, Ž. 2008. *Modeliranje procesa biološke obrade otpadne vode na komunalnom uređaju grada Velika Gorica*. *Kemija u industriji* 57, 2, 59-67.
- [5] Dürrenmatt, D.J. and Gujer, W. 2011. *Data-driven modeling approaches to support wastewater treatment plant operation*, *Environmental Modelling & Software*, 30, 47-56.
- [6] Razifa, M.; Bagyo Yanuwadib, S.; Rachmansyahb, A.; Belgiawanc, P.F. 2014. *Implementation of Regression Linear Method to predict WWTP cost for EIA: case*

- study of ten malls in Surabaya City*, Procedia Environmental Sciences, 28, 158-165.
- [7] Baeza, J.; Gabriel, D.; Lafuente, J. 1999. *An expert supervisory system for a pilot WWTP*. Environmental Modelling and Software 14, 383-390.
- [8] Roda, I.R.; Comas, J.; Sàncnes-Marré, M.; Cortés, U.; Lafuente, J.; Poch, M. 1999. *Expert system development for a real wastewater treatment plant*. Chemical Industry and Environment III, Proceedings. Kraków, Poland, 653-660.
- [9] Comas, J.; Rodríguez-Roda, I.R.; Sàncnes-Marré, M.; Cortés, U.; Freixó, A.; Arráez, J.; Poch, M. 2003. *A knowledge-based approach to the defloculation problem: integrating on-line, off-line, and heuristic information*, Water Research 37, 2377-2387.
- [10] Belanche, L.I.; Valdes, J.J.; Comas, J.; Roda, I.R.; Poch, M. 1999. *Towards a Model of Input-Output Behaviour of Wastewater Treatment Plants using Soft Computing Techniques*, Environmental Modelling and Software 14, 409-419.
- [11] Zhao, H.; Hao, O.J.; McAvoy, T.J. 1999. *Approaches to modeling nutrient dynamics: ASM2, simplified model and neural nets*. Water Science and Technology 39, 1, 227-234.
- [12] Hong, G.; Kwanho, J.; Jiyeon, L.; Young M.K.; Jong-pyo, P.; Joon, H.K.; Kyung, H.C. 2015. *Prediction of effluent concentration in a wastewater treatment plant using machine learning models*, Journal of Environmental Sciences 32, 90-101.
- [13] Mjalli, F.S.; Al-Asheh, S. and Alfadala, H.E. 2007. Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance, Journal of Environmental Management, 83, 3, 329-338.
- [14] Sàncnes-Marré, M.; Cortés, U.; Lafuente, J.; Roda, I.R.; Poch, M. 1996. *DAI-DEPUR: a distributed architecture for wastewater treatment plants supervision*. Artificial Intelligence in Engineering 10, 3, 379-423.
- [15] Grieu, S.; Traoré, A.; Polit, M.; Colprim, J. 2005. *Prediction of parameters characterising the state of a pollution removal biologic process*. Engineering Applications of Artificial Intelligence 18, 559-573.
- [16] Picioreanu, C.; Kreft J.U.; van Loosdrecht, M.C.M. 2004. *Particle-based multidimensional multispecies biofilm model*. Microbiology 70, 5, 3024-3040.
- [17] Picioreanu, C.; van Loosdrecht, M.C.M. 2003. *Use of mathematical modeling to study biofilm development and morphology*. IWA Publishing, University of Manchester (UK).
- [18] Comas, J.; Dzeroski, S.; Gibert, K.; Roda, I.R.; Sanchez-Marre, M. 2001. *Knowledge discovery by means of inductive methods in wastewater treatment data*. AI Communication 14, 45-62.
- [19] Atanasova, N.; Kompore, B. 2002. *Uporaba odločitvenih dreves pri modeliranju čistilne naprave za odpadno vodo*. Acta hydrotechnica 20, 33, 351-370.
- [20] Kompore, B.; Levstek, M.; Atanasova, N. 2006. *Two approaches to wastewater treatment plant modelling*. Acta hydrotechnica 24, 40, 45-64.
- [21] Manu, D.S. and Thalla, A.K. 2017. Artificial intelligence models for predicting the performance of biological wastewater treatment plant in the removal of

- Kjeldahl Nitrogen from wastewater. *Applied Water Science*. DOI 10.1007/s13201-017-0526-4.
- [22] Henze, M.; Herremoes, P.; Jansen, J.C.; Arvin E. 2002. *Wastewater Treatment-Biological and Chemical Processes*, Third edition. Springer. New York. US.
- [23] Tchobanoglous, G.; Burton, FL.; Stensel, HD. 2003. *Wastewater Engineering-Treatment and Reuse*. Fourth edition. McGraw-Hill,
- [24] *Pravilnik o graničnim vrijednostima emisija otpadnih voda*. Narodne novine br. 153/09, 63/11, 130/11 i 56/13, 2013, 80/13, 43/14, 27/15, 3/2016.
- [25] Quinlan, J.R.; *Learning with continuous classes*. 1992. Proc. AI'92, 5th Australian Joint Conference on Artificial Intelligence, Singapore. In: Adams & Sterling (Editors). World Scientific, 343-348.