

# Modeliranje procesa biološke obrade otpadne vode na komunalnom uređaju grada Velika Gorica

KUI – 4/2008  
Prispjelo 31. kolovoza 2006.  
Prihvaćeno 18. srpnja 2007.

M. Čurlin,<sup>a,\*</sup> A. Bevetek,<sup>a</sup> Z. Ležajić,<sup>b</sup> B. Deverić Meštović<sup>b</sup> i Ž. Kurtanjek<sup>a</sup>

<sup>a</sup> Sveučilište u Zagrebu, Prehrambeno-biotehnološki fakultet,  
Pierottijeva 6, 10 000 Zagreb, Croatia

<sup>b</sup> "VG Vodoopskrba" d. o. o., Kolodvorska 64, 10 410 Velika Gorica

Obrada otpadne vode s aktivnim muljem izrazito je složen fizikalni, kemijski i biološki proces. Nestalnost sastava i protoka otpadne vode te vremenski promjenjive reakcije mješovite kulture mikroorganizama uvjetuju njegovu nelinearnost i nestacionarnost. Optimalno vođenje procesa je kompleksan zadatak, ali pravilno izrađen matematički model može poslužiti kao osnova za rješavanje. U ovom radu izrađena su dva modela za opis procesa obrade otpadne vode na uređaju grada Velika Gorica, sa zadaćom predviđanja vrijednosti kemijske potrošnje kisika (KPK) na izlazu iz uređaja u zavisnosti od protoka i značajki ulazne neobrađene vode.

Korišteni podaci dobiveni su svakodnevnim mjerenjem fizikalnih veličina koji ukazuju na kvalitetu ulazne i izlazne vode, na uvjete pri kojima uređaj radi te na kvalitetu aktivnog mulja. Za modeliranje procesa primijenjena je baza podataka od ukupno 223 skupa podataka sa po 26 parametara za kontinuirano razdoblje tijekom 2004. godine, koji su poslužili kao varijable za izradu modela. Iz ukupnog skupa veličina statističkom analizom odabrane su najuvjerljivije varijable za izradu modela.

Izrađeni su viševarijantni linearni model (MLR) sa 16 varijabli te model lokalne linearne regresije (PLR) sa 17 varijabli. Srednja pogreška viševarijantnog linearnog modela iznosi  $\gamma_{\text{KPK}} = 20 \text{ mg O}_2 \text{ L}^{-1}$ , a za model lokalne linearne regresije srednja pogreška iznosi  $\gamma_{\text{KPK}} = 16 \text{ mg O}_2 \text{ L}^{-1}$ .

Ključne riječi: *Komunalna otpadna voda, modeliranje, viševarijantni linearni model (MLR), model lokalne linearne regresije (PLR)*

## Uvod

Biološka obrada otpadne vode već se godinama primjenjuje posvuda u svijetu u različitim procesima. U tu svrhu primjenjuje se i velik broj različitih postupaka, koji variraju zavisno od podrijetla otpadne vode, odnosno od postojećih onečišćenja.

Ipak, jedan od najraširenijih postupaka je biološka obrada otpadne vode s aktivnim muljem.<sup>1</sup> Široka primjena ovog procesa proizlazi iz njegove djelotvornosti, bilo da se radi o obradi vode podrijetlom iz kućanstva (komunalnoj vodi) ili industrijskoj otpadnoj vodi. Biološka obrada otpadne vode veoma je složen, dinamički, nelinearan proces, koji je uvjetovan različitim biološkim, kemijskim i fizikalnim čimbenicima.<sup>1,2</sup> S tim u skladu, razumijevanje tog procesa je otežano, kao i njegovo optimalno vođenje.

Uspješnost procesa utvrđuje se mjerenjem veličina koji ukazuju na kvalitetu obrađene otpadne vode, ali njih je moguće odrediti tek po završetku procesa, odnosno kad je voda već pročišćena, na izlazu je iz uređaja i ispušta se u okoliš. Ukoliko kvaliteta vode nije zadovoljavajuća, za njezino poboljšanje već je prekasno, što ukazuje na potrebu

unaprijednog upravljanja na osnovi matematičkog modela. Kako ne postoji mogućnost naknadnog reagiranja, svaka pogreška u vođenju procesa može uzrokovati ekološku katastrofu manjeg ili većeg razmjera. Iz tog razloga već godinama se nastoje razviti modeli koji bi vjerno opisivali ovaj proces, omogućili njegovo razumijevanje te poslužili kao baza za nadzor i optimalno upravljanje procesom. Kao grubu podjelu modela koji se do danas rabe za opisivanje procesa obrade vode i koji se istražuju može se navesti skupina nestrukturiranih modela i skupina empirijskih modela.

Nestrukturirani modeli procesa biološke obrade otpadne vode s aktivnim muljem zasnovani su na uobičajenim bilancama mase i jednadžbama koje opisuju brzinu rasta mikroorganizama, potrošnju supstrata i formiranje proizvoda.<sup>3</sup>

Activated Sludge Model (ASM) je najčešće primjenjivan model ovog tipa, a postoji u nekoliko oblika različite složenosti (ASM1, ASM2, ASM3). To su modeli koji uključuju velik broj mjernih veličina i bioloških procesa, a opisuju dvije najvažnije faze ovog postupka – biološku oksidaciju i naknadno (sekundarno) taloženje.<sup>4</sup> Ovisno o stupnju obrade vode u pojedinom sustavu, uključuje li on i nitrifikaciju ili denitrifikaciju i uklanjanje fosfora, za modeliranje tog procesa primijeniti će se jedna od tri postojeće varijante

\* Autor za korespondenciju: Mirjana Čurlin, e-mail: [mcurlin@pbf.hr](mailto:mcurlin@pbf.hr)

modela. ASM1 smatra se jednim od najboljih nestrukturiranih modela za opisivanje procesa u kojima se uklanjaju ugljikovi spojevi i dušik.<sup>5,6</sup> Model je prilično složen, a zahtijeva poznavanje 13 različitih masenih koncentracija (varijabli koje opisuju stanje sustava) i osam procesa.<sup>4</sup>

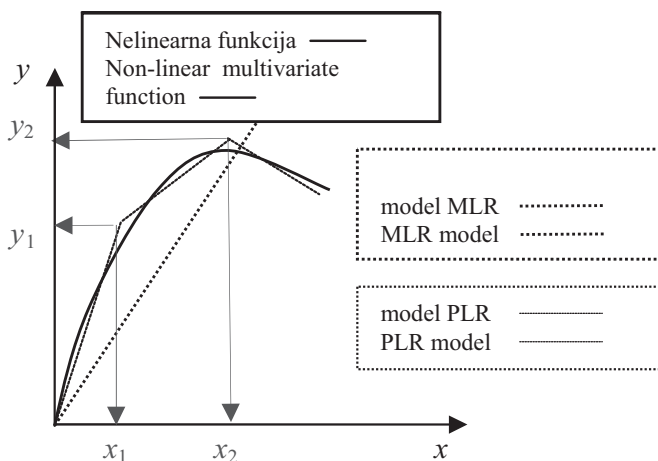
ASM2 je najsloženiji oblik ovog modela, zahtijeva poznavanje 19 koncentracija i 22 biološka procesa, dok je za izgradnju ASM3 potrebno poznavanje 13 komponenta otpadne vode i 12 procesa.<sup>4</sup>

Uz složenost, glavni nedostatak ovih modela jest činjenica da su stvoreni poglavito za modeliranje procesa obrade otpadne vode podrijetlom iz kućanstava (komunalne vode), pa im je primjena u modeliranju procesa obrade industrijskih otpadnih voda ograničena, a i ne opisuju dovoljno dobro svu dinamiku ovog procesa.<sup>7</sup>

Ograničenja nestrukturiranih modela prevladavaju se uporabom empirijskih modela. Ti su modeli znatno jednostavniji, a ne zahtijevaju prethodno poznavanje procesa koji je objekt modeliranja te daju i bolje rezultate.<sup>7</sup>

Izgradnja modela zasniva se na statističkoj analizi eksperimentalnih podataka, kojom se utvrđuje međusobna zavisnost pojedinih varijabli. Utvrđena se zavisnost zatim prikazuje funkcijom (jednadžbom modela), a zavisno od prirode funkcije kojom se opisuje zavisnost varijabli, razlikuju se i osnovni tipovi ovih modela (linearni, nelinearni).

Linearni empirijski modeli najčešće se primjenjuju za opisivanje linearnih, ali i nelinearnih procesa, poput složenih biotehnoških procesa. Njihova se primjena pritom temelji na pretpostavci da se i nelinearni procesi mogu lokalno aproksimirati linearnom funkcijom,<sup>8</sup> kako je prikazano na slici 1.



Slika 1 – Prikaz nelinearne funkcije i njezine aproksimacije modelima MLR i PLR

Fig. 1 – Schematic view of linear approximation of non-linear multivariate function by MLR and PLR models

Izgradnja linearnih modela temelji se na primjeni postupaka modeliranja poput viševarijantne linearne regresije (engl. Multiple Linear Regression, MLR) ili metode djelomičnih najmanjih kvadrata (engl. Partial Least Squares, PLS).

Kada je broj utjecajnih varijabli (regresora) malen i kad one nisu međusobno kolinearne te imaju razumljiv utjecaj na ponašanje sustava ili promatranu zavisnu veličinu, MLR-modeli mogu prilično dobro opisivati složene nelinearne procese.<sup>8</sup>

U nelinearnim empirijskim modelima proces se nastoji aproksimirati nekom od uobičajenih nelinearnih funkcija poput logaritamske, eksponencijalne, kvadratne, itd. Obično takvi modeli biotehnoških procesa, koji su uglavnom i nelinearni po prirodi, daju bolje rezultate od linearnih, što je i razumljivo.

U ovom radu analiziran je proces biološke obrade otpadne vode na uređaju za pročišćavanje otpadnih voda grada Velika Gorica. Izrađena su dva modela za opis procesa, viševarijantni linearni model sa 16 varijabli i model lokalne linearne regresije sa 17 varijabli.

Izlazna veličina tih modela ima za zadaću predviđanje KPK-vrijednosti u izlaznom toku nakon završene obrade.

## Eksperimentalni dio

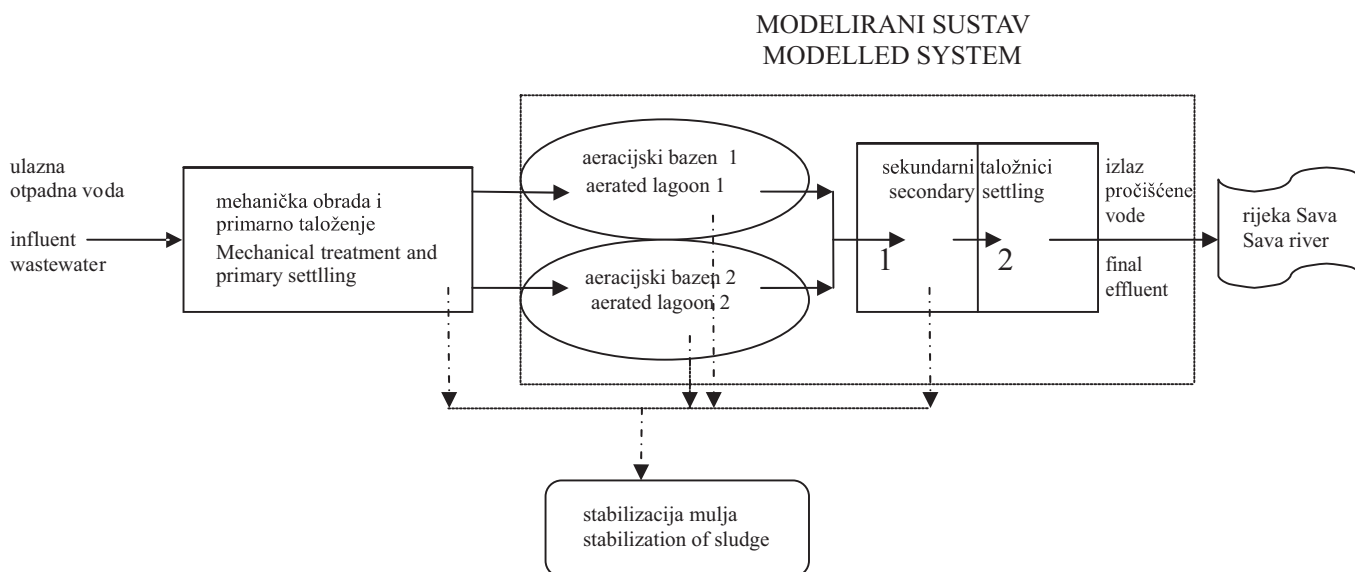
### Opis uređaja za obradu otpadnih voda grada Velika Gorica

Navedeni uređaj je konvencionalan, što znači da se obrada otpadne vode provodi mehaničko-biološkom obradom s aktivnim muljem u dva stupnja (uklanjanjem organskog opterećenja i uklanjanjem amonijaka pretvorbom u nitrate). Shema uređaja prikazana je na slici 2.

Za nadzor rada uređaja svakodnevno se vrše mjerenja različitih veličina koja ukazuju na uspješnost procesa (kvalitetu sirove i obrađene otpadne vode, uvjete u kojima uređaj radi te kvalitetu aktivnog mulja). U tablici 1 prikazane su mjerene veličine analizirane u ovom radu. Mjerenje veličina koji opisuju dio prethodne obrade ulazne otpadne vode (odvojeno smeće, pijesak, mast) provodi se periodički, prilikom njihova uklanjanja, a ono se provodi kad postignu određeni, lako mjerljiv obujam. Mjerenje fizikalnih veličina poput temperature, protoka, oksido-reduktivnog potencijala, pH i provodnosti provodi se svakodnevno u laboratoriju standardnim instrumentima. Oksido-reduktivni potencijal, pH vode i njezina temperatura mjere se instrumentom *Sension™1* (model 51935-00, proizvođač Hach Company). Veličina "protok" zapravo je srednja vrijednost dnevnog protoka otpadne vode, dobivena mjerenjem protoka Dopplerovom metodom (proizvođač Endress+Hauser) u razmacima od 2 sata. Veličine koje ukazuju na sastav i kvalitetu vode prije i nakon obrade (dinamika taloženja, KPK, ukupni ispareni ostatak te njegov organski i anorganski dio, suha tvar aktivnog mulja i dinamika taloženja te indeks aktivnog mulja) određuju se svakodnevno u laboratoriju u sklopu samog uređaja, uobičajenim analitičkim metodama propisanim u "Standard Methods for the Examination of Water and Wastewater".<sup>9</sup> Pritom se za određivanje dinamike taloženja aktivnog mulja i indeksa aktivnog mulja služi obujam mulja istaloženog za 30 minuta.

### Izrada baze podataka i matematički model

Zadaća rada bila je izrada prikladnog modela procesa, temeljem statističke analize podataka o radu uređaja dobi-



Slika 2 – Shema uređaja za obradu otpadnih voda grada Velika Gorica

Fig. 2 – Schematics of the wastewater treatment plant of the town of Velika Gorica

venih svakodnevnim mjerenjem tijekom 2004. godine. Izrađeni model trebao bi vjerno opisivati proces, te poslužiti kao model za predviđanje rada uređaja, odnosno kvalitete efluenta pri različitim uvjetima i konačno, omogućiti nadzor i optimalno vođenje procesa.

Za analizu procesa primijenjen je zapis o svakodnevnim mjerenjima navedenih veličina, u razdoblju 1. siječnja – 31. prosinca 2004. Na taj je način stvorena baza s ukupno 223 skupa podataka od po 26 varijabli s ukupnim brojem od 5700 podataka. Mjerena vrijednost kemijske potrošnje kisika ili KPK u izlaznom toku najbolji je pokazatelj kvalitete rada uređaja, odnosno zaostalog organskog opterećenja, čime ukazuje i na uspješnost procesa. Iz tog razloga navedena varijabla definirana je kao promatrana izlazna veličina, zavisna veličina koja najbolje ukazuje na stanje procesa, odnosno varijabla čiju dinamiku želimo objasniti i predvidjeti modelom. Stoga je pri izradi modela promatrana zavisnost izlazne veličine ( $KPK_{iz}$ ) od skupa nezavisnih varijabli, koji čine sve preostale mjerene varijable, na temelju eksperimentalnih podataka.

Temeljem modela omogućilo bi se, određivanjem nezavisnih varijabli, predviđanje vrijednosti  $KPK_{iz}$ , ukoliko je ona veća od zakonom dopuštene, prema Pravilniku o graničnim vrijednostima pokazatelja opasnih i drugih tvari u otpadnim vodama,<sup>12</sup> omogućilo bi se brzo reagiranje koje bi osiguralo njezino smanjenje na prihvatljivu razinu. Sve statističke analize provedene su u računalnom sustavu "Statistica" (proizvođač "StatSoft")<sup>13</sup> verzija 6.1, od 2005. Za opis pouzdanosti dobivenih rezultata poslužila je prethodno određena razina signifikantnosti rezultata. Odabrana razina signifikantnosti u svim provedenim statističkim analizama jest  $p \leq 0,05$ , što se inače smatra prihvatljivom vrijednošću za pouzdanost rezultata u industrijskim procesima. Kao referentni parametar za prosudbu točnosti modela te za njihovu međusobnu usporedbu, poslužila je vrijednost regresijskog koeficijenta  $R^2$ , koja ukazuje na postotak varijance eksperimentalnih podataka, objašnjen određenim mode-

lom. Vrijednost regresijskog koeficijenta kreće se u granicama 0–1, a računata je prema izrazima za analizu varijance (ANOVA):

$$R^2 = 1 - \frac{SSE}{SST} \quad (1)$$

$$SSE = \sum (y_i - \hat{y}_i)^2 \quad (2)$$

$$SST = SSE + SSR \quad (3)$$

$$SSR = \sum (\hat{y} - \bar{y})^2 \quad (4)$$

#### Viševarijantni linearni model

Viševarijantni linearni model izrađen je kako bi se istražila eventualna linearnost procesa, odnosno linearna zavisnost promatrane izlazne veličine o nezavisnim varijablama. U tu svrhu primijenjena je metoda viševarijantne linearne regresije ("Multiple Linear Regression", MLR). Tom metodom analizira se međuzavisnost (koreliranost) pojedinih varijabli, a jačina korelacija varijabli opisuje se regresijskim koeficijentima  $\beta$  normaliziranih modela.<sup>13</sup> Pri izradi, model je prilagođavan eksperimentalno utvrđenim podacima uzastopnim minimaliziranjem srednjih kvadratnih odstupanja između modelom određene i eksperimentalno utvrđene vrijednosti odabrane izlazne veličine, metodom najmanjih kvadrata. Analizom se određuju vrijednosti veličina modela  $B$  koji izražavaju udjel pojedine nezavisne varijable u modelu, kako je dano općim prikazom modelne jednadžbe:

$$y = f(x_1, x_2, \dots, x_n) \quad (5)$$

$$y = B_0 + B_1 \cdot x_1 + B_2 \cdot x_2 + \dots + B_n \cdot x_n \quad (6)$$

gdje je  $B_0$  odsječak na osi  $y$

za normalizirani model

$$y = \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n \quad (7)$$

T a b l i c a 1 – Mjerene veličine, mjerne jedinice i upotrijebljene oznake za izradu modela

T a b l e 1 – Measured quantities, unit of measure and applied symbol for modelling

Mjerene veličine Measured quantities	Upotrijebljena oznaka/mjerna jedinica Applied symbol/unit of measure	
temperatura zraka air temperature	$\vartheta_{\text{zrak}} / ^\circ\text{C}$ $\vartheta_{\text{air}} / ^\circ\text{C}$	
protok otpadne vode wastewater flow rate	$q_v$ (otpadne vode) / $\text{L s}^{-1}$ $q_v$ (wastewater) / $\text{L s}^{-1}$	
odvojeni sirovi mulj removed raw activated sludge	$q_v$ (aktivni mulj) / $\text{m}^3 \text{d}^{-1}$ $q_v$ (activated sludge) / $\text{m}^3 \text{d}^{-1}$	
odvojeni pijesak removed sand	$q_v$ (pijesak) / $\text{m}^3 \text{d}^{-1}$ $q_v$ (sand) / $\text{m}^3 \text{d}^{-1}$	
odvojena mast removed fat	$q_v$ (mast) / $\text{m}^3 \text{d}^{-1}$ $q_v$ (fat) / $\text{m}^3 \text{d}^{-1}$	
odvojeno smeće removed garbage	$q_v$ (smeće) / $\text{m}^3 \text{d}^{-1}$ $q_v$ (garbage) / $\text{m}^3 \text{d}^{-1}$	
suha tvar aktivnog mulja dry activated sludge	$\gamma_x$ / $\text{kg m}^{-3}$ $\gamma_x$ / $\text{kg m}^{-3}$	
indeks aktivnog mulja index of activated sludge	$I_m$ / $\text{mL g}^{-1}$ $I_s$ / $\text{mL g}^{-1}$	
Mjerene veličine na ulazu i izlazu iz uređaja Measured input and output quantities of the plant	U sirovoj otpadnoj vodi In raw wastewater	U obrađenoj otpadnoj vodi In refine wastewater
temperatura vode water temperature	$\vartheta_{ul} / ^\circ\text{C}$ $\vartheta_{in} / ^\circ\text{C}$	$\vartheta_{iz} / ^\circ\text{C}$ $\vartheta_{eff} / ^\circ\text{C}$
oksidoreduktivni potencijal Oxide-reduction potential	ORP <sub>ul</sub> V/mV ORP <sub>in</sub> V/mV	ORP <sub>iz</sub> V/mV ORP <sub>eff</sub> V/mV
pH pH	pH <sub>ul</sub> pH <sub>in</sub>	pH <sub>iz</sub> pH <sub>eff</sub>
dinamika taloženja settling dynamics	d.t. <sub>ul</sub> $\sigma$ / $\text{mL L}^{-1}$ s.d. <sub>in</sub> $\sigma$ / $\text{mL L}^{-1}$	d.t. <sub>iz</sub> $\sigma$ / $\text{mL L}^{-1}$ s.d. <sub>eff</sub> $\sigma$ / $\text{mL L}^{-1}$
kemijska potrošnja kisika chemical oxygen demand	KPK <sub>ul</sub> $\gamma$ / $\text{mg L}^{-1}$ COD <sub>in</sub> $\gamma$ / $\text{mg L}^{-1}$	KPK <sub>iz</sub> $\gamma$ / $\text{mg L}^{-1}$ COD <sub>eff</sub> $\gamma$ / $\text{mg L}^{-1}$
ukupni ispareni ostatak volatile suspend solid	UIO <sub>ul</sub> $\gamma$ / $\text{mg L}^{-1}$ VSS <sub>in</sub> $\gamma$ / $\text{mg L}^{-1}$	UIO <sub>iz</sub> $\gamma$ / $\text{mg L}^{-1}$ VSS <sub>eff</sub> $\gamma$ / $\text{mg L}^{-1}$
organski dio isparenog ostatka organic volatile suspend solid	UIO(org) <sub>ul</sub> $\gamma$ / $\text{mg L}^{-1}$ VSS(org) <sub>in</sub> $\gamma$ / $\text{mg L}^{-1}$	UIO(org) <sub>iz</sub> $\gamma$ / $\text{mg L}^{-1}$ VSS(org) <sub>eff</sub> $\gamma$ / $\text{mg L}^{-1}$
anorganski dio isparenog ostatka inorganic volatile suspend solid	UIO(anorg) <sub>ul</sub> $\gamma$ / $\text{mg L}^{-1}$ VSS(inorg) <sub>in</sub> $\gamma$ / $\text{mg L}^{-1}$	UIO(anorg) <sub>iz</sub> $\gamma$ / $\text{mg L}^{-1}$ VSS(inorg) <sub>eff</sub> $\gamma$ / $\text{mg L}^{-1}$
	U naknadnim taložnicima In secondary settler	
providnost transparency	nt <sub>1</sub> / cm ss <sub>1</sub> / cm	nt <sub>2</sub> / cm ss <sub>2</sub> / cm

Kao promatrana zavisna veličina odabrana je vrijednost KPK u izlaznom toku  $KPK_{iz}$ , a analiziran je utjecaj preostalih mjenjenih veličina na tu zavisnu veličinu, analizom signifikantnih regresijskih koeficijenata  $\beta$ .

### Model lokalne linearne regresije

Nelinearnost procesa procijenjena je metodom lokalne linearne regresije ("Piecewise Linear Regression", PLR), a za uzastopnu minimalizaciju odstupanja modela od eksperimentalno utvrđenih vrijednosti primijenjena je približna Newtonova metoda (engl. quasi Newton method).

Na taj način određena je vrijednost  $KPK_{iz}$ , koja očituje točku loma ( $y_0$ ), kao i veličine modela  $B$ , koji ukazuju na jakost i prirodu utjecaja nezavisnih varijabli, kako je prikazano općom jednadžbom za model lokalne linearne regresije:

$$y \leq y_0; y_1 = B_{1,0} + B_{1,1} \cdot x_1 + B_{1,2} \cdot x_2 + \dots + B_{1,n} \cdot x_n$$

$$y \geq y_0; y_2 = B_{2,0} + B_{2,1} \cdot x_1 + B_{2,2} \cdot x_2 + \dots + B_{2,n} \cdot x_n \quad (8)$$

### Rezultati i rasprava

Analize su provedene s razinom signifikantnosti  $p < 0,05$ , što je prihvatljiva razina pogreške u ovakvom biotehničkom procesu, koji je vrlo složen i nestacionaran zbog brojnih stalno promjenljivih čimbenika. Složena priroda procesa i njegova osjetljivost, odnosno podložnost raznim utjecajima, potvrđeni su rezultatima analiza navedenim u ovom radu. Naime, u svim su modelima u ovom radu kao "prediktori" uključeni parametri koji opisuju, klimatske utjecaje, biološku komponentu sustava i kvalitetu "sirovine", odnosno ulazne otpadne vode. Vidljivo je da se kvaliteta obrađene otpadne vode, a s tim dakle i uspješnost procesa, mijenja zavisno od velikog broja čimbenika, čiji utjecaj na proces, kako je i utvrđeno, nije podjednak, što je u skladu s rezultatima u drugim znanstvenim radovima<sup>6,10,11</sup> u kojima je obrađivana ova problematika.

Iako se uglavnom za opis tako složenih procesa primjenjuju složeniji modeli odnosno naprednije metode modeliranja kao što je umjetna inteligencija,<sup>5,7,14</sup> možemo reći da se i ovim jednostavnijim modelima MLR i PLR može dovoljno uspješno prikazati složenost ovog procesa i ukazati na njegovu nestacionarnost. Izrađeni modeli u ovom radu, svaki na svoj način i sa svojim stupnjem uspješnosti, mogu se primijeniti za opisivanje ovog procesa te predviđanje njegovog ponašanja u različitim uvjetima.

### Viševarijantni linearni model

Linearni model izrađen je pomoću metode viševarijantne linearne regresije (MLR), s razinom signifikantnosti  $p \leq 0,05$ , a broj nezavisnih varijabli uključenih u model određen je njihovim postupnim isključivanjem iz modela prema prethodnom teorijskom znanju i rezultatima korelacijske matrice.

Prije same obrade podataka metodom MLR, izrađena je korelacijska matrica kako bi se istražila opća linearna zavisnost varijable  $KPK_{iz}$  o ostalim nezavisnim varijablama, a dobiveni Paersonovi koeficijenti ( $r$ ) prikazani su u tablici 2.

Tablica 2 – Značenje linearnog utjecaja pojedine nezavisne varijable na  $KPK_{iz}$  prikazan Paersonovim koeficijentima ( $r$ ). Masno su otisnuti izdvojeni signifikantni rezultati ( $p \leq 0,05$ )


Table 2 – Significance of linear influence of process variables on  $COD_{eff}$  presented as coefficient of Paerson. Significant results ( $p \leq 0.05$ ) are bolded

Varijabla	Variable	KPK iz COD eff
$\vartheta_{zrak}$	$\vartheta_{air}$	<b>-0,37</b>
$\vartheta_{ul}$	$\vartheta_{in}$	<b>-0,23</b>
$\vartheta_{iz}$	$\vartheta_{eff}$	<b>-0,26</b>
pH <sub>ul</sub>	pH <sub>in</sub>	0,08
pH <sub>iz</sub>	pH <sub>eff</sub>	0,08
ORP <sub>ul</sub>	ORP <sub>in</sub>	-0,07
ORP <sub>z</sub>	ORP <sub>eff</sub>	-0,13
d.t. <sub>ul</sub>	s.d. <sub>in</sub>	0,01
d.t. <sub>iz</sub>	s.d. <sub>eff</sub>	<b>0,22</b>
nt <sub>1</sub>	ss <sub>1</sub>	<b>-0,71</b>
nt <sub>2</sub>	ss <sub>2</sub>	<b>-0,74</b>
$q_v$ (smeće)	$q_v$ (garbage)	0,07
$q_v$ (pjesak)	$q_v$ (sand)	0,07
$q_v$ (mulj)	$q_v$ (sludge)	0,01
KPK <sub>ul</sub>	COD <sub>in</sub>	<b>0,22</b>
UIO <sub>ul</sub>	VSS <sub>in</sub>	<b>0,16</b>
UIO <sub>iz</sub>	VSS <sub>eff</sub>	<b>0,33</b>
UIO(org) <sub>ul</sub>	VSS(org) <sub>in</sub>	0,13
UIO(org) <sub>iz</sub>	VSS(org) <sub>eff</sub>	<b>0,33</b>
UIO(anorg) <sub>ul</sub>	VSS(inorg) <sub>in</sub>	0,11
UIO(anorg) <sub>iz</sub>	VSS(inorg) <sub>eff</sub>	<b>0,15</b>
$\gamma_x$	$\gamma_x$	<b>-0,34</b>
$I_m$	$I_s$	<b>-0,41</b>
$q_v$ (mast)	$q_v$ (fat)	0,01
$q_v$ (otpadne vode)	$q_v$ (wastewater)	0,05

Na temelju rezultata korelacijske matrice pristupilo se izradi linearnog viševarijantnog modela. Razina tolerancije kolinearnosti nezavisnih varijabli podešena je na minimalnu vrijednost od 0,0001 i temeljem toga postupno su uklanjane suvišne varijable (od varijabli s manjim Pearsonovim koeficijentima prema većim, s iznimkom da su razinu tolerancije metode udovoljile varijable  $UIO(org)_{ul}$ ,  $ORP_{ul}$ ,  $ORP_{iz}$  i  $q_v$ , a varijabla  $UIO(anorg)_{iz}$  nije prihvaćena. U izradu modela stoga je uključeno ukupno 16 varijabli. U obzir su uzeti samo potpuni skupovi podataka, koji sadrže podatke za sve navedene varijable ( $N = 202$ ). Analizom podataka MLR metodom određeni su regresijski koeficijenti  $\beta$  i  $B$  za normalizirani i izvorni oblik modela.


Regresijski koeficijent tako izrađenog modela iznosio je  $R^2 = 0,686$ , a grafički prikaz slaganja modela za vrijednosti  $KPK_{iz}$  dobivenih modelom i mjerenih vrijednosti po pojedinom skupu podataka prikazan je na slici 3.

Analizom ostataka, odnosno razlika između vrijednosti  $KPK_{iz,m}$  i  $KPK_{iz,e}$  utvrđen je nedosljedni skup podataka ("outliers"), kod kojih je to odstupanje veće od uobičajenog



Slika 3 – Slaganje modela MLR s eksperimentalno određenim vrijednostima  $KPK_{iz}$  po pojedinom skupu podataka

Fig. 3 – Comparison of the MLR model with experimental value  $COD_{eff}$  for individual set of data.



Slika 4 – Slaganje "pročišćenog" MLR-modela s eksperimentalno određenim vrijednostima  $KPK_{iz}$  po pojedinom skupu podataka

Fig. 4 – Comparison of the "refined" MLR model with experimental value  $COD_{eff}$  for individual set of data

( $\pm 2 \cdot \sigma$ ), i ti su skupovi podataka uklonjeni iz analize. Ponovnom analizom pomoću metode MLR na smanjenoj bazi podataka ( $N = 176$ ), uz iste promatrane nezavisne varijable, utvrđeni su koeficijenti  $\beta$  i  $B$  tzv. "pročišćenog" modela.

Regresijski koeficijent izrađenog modela iznosio je  $R^2 = 0,722$ , a grafički prikaz slaganja "pročišćenog" MLR-modela za  $KPK_{iz}$  dobivenog modelom i vrijednosti  $KPK_{iz}$  iz eksperimentalnih podataka po pojedinom skupu podataka prikazani su na slici 4.

Kako bi se provjerila mogućnost predviđanja ponašanja sustava ovim modelom, cjelokupna baza podataka razdvojena je, nasumičnim odabirom, na dva dijela, u omjeru 4:1. Veći dio baze podataka (80 % svih podataka) primijenjen je za izradu modela, odnosno određivanje svih veličina modela (uz istu razinu tolerancije i razinu signifikantnosti  $p$ ).

Regresijski koeficijent tako izrađenog modela iznosio je  $R^2 = 0,734$ , a grafički prikaz slaganja MLR-modela i eksperimentalno određenih vrijednosti  $KPK_{iz}$  po pojedinom skupu podataka prikazana je na slici 5.

Model je zatim provjeren na novom skupu podataka za testiranje ("verifikaciju") modela (preostalih 20 % svih podataka,  $N = 39$ ), uvrštavanjem eksperimentalno određenih vrijednosti nezavisnih varijabli u modelnu jednadžbu. Dobivene, modelom predviđene vrijednosti ( $KPK_{iz,m}$ ) prikazane su na slici 5a uz pripadajuće eksperimentalno od-

ređene vrijednosti ( $KPK_{iz,e}$ ). Srednja pogreška MLR modela iznosi  $\gamma = 20 \text{ mg L}^{-1}$ , što je zadovoljavajuće s obzirom na dinamičnost procesa i utjecaj mnogih čimbenika koji utječu na kvalitetu izlazne vode.

## Model lokalne linearne regresije

Model je izrađen kako bi se istražila nelinearnost procesa, a broj ulaznih veličina modela određen je postupnim isključivanjem varijabli iz modela prema rezultatima korelacijske matrice, uz usporedbu točnosti svakog novoizgrađenog modela. Iz baze podataka izdvojene su veličine koje se zapravo odnose na mehanički dio obrade otpadne vode (prema korelacijskoj matrici imaju neznatan ili nikakav utjecaj na  $KPK_{iz}$ , a i većina se određuje tek periodički) pa je model izrađen pomoću 21 nezavisne varijable i na temelju ukupno 202 skupa podataka.

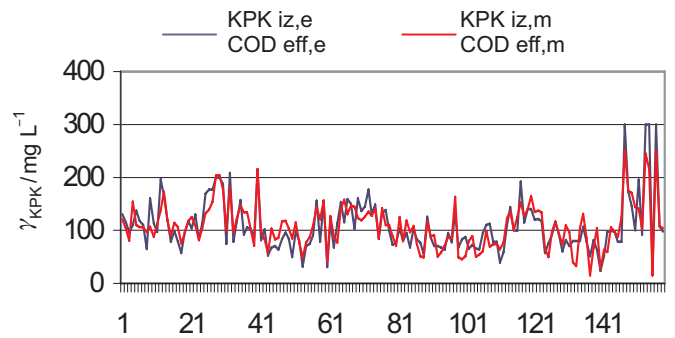
Optimalan model dobiven je nakon 80 ponavljanja ("iteracija") minimiziranja srednjih kvadratnih odstupanja modela od eksperimentalnih podataka približnom Newtonovom metodom. Tako su određene veličine modela ( $B$ ) i vrijednost  $KPK_{iz}$ , koja predočuje točku loma ( $\gamma_0$ ). Regresijski koeficijent ovog modela iznosio je  $R^2 = 0,861$ , a slaganje modelom predviđenih i eksperimentalno određenih vrijednosti  $KPK_{iz}$  po pojedinom skupu podataka vidljivo je sa slike 6.

Sa zadaćom smanjenja broja ulaznih veličina modela, iz daljnje analize izdvojene su nezavisne varijable koje prema korelacijskoj matrici imaju neznatan utjecaj na veličinu  $KPK_{iz}$  ( $pH_{ul}$ ,  $pH_{iz}$  i  $d.t_{ul}$ ) i izrađen je model s ukupno 18 nezavisnih varijabli, na temelju 202 skupa podataka. Istim postupkom kao i u ranijoj analizi (80 iteracija približne Newtonove metode) određene su veličine  $B$  i točka loma reduciranog modela. Regresijski koeficijent ovog modela iznosio je  $R^2 = 0,847$ , a slaganje modela s eksperimentalnim podacima vidljivo je na slici 7. Srednja pogreška modela sa 21 varijablom i modela sa 18 varijablom iznosila je  $\gamma = 15,8 \text{ mg L}^{-1}$ . Iz svega navedenog vidljivo je da u ovom slučaju smanjenje broja veličina ne utječe bitno na točnost modela.

Daljnje smanjenje broja ulaznih veličina modela provedeno je izdvajanjem nezavisne varijable  $UIO(anorg)_{iz}$ , a ponavljanjem analize uz isti broj iteracija određene su veličine modela s preostalim 17 nezavisnih varijabli.

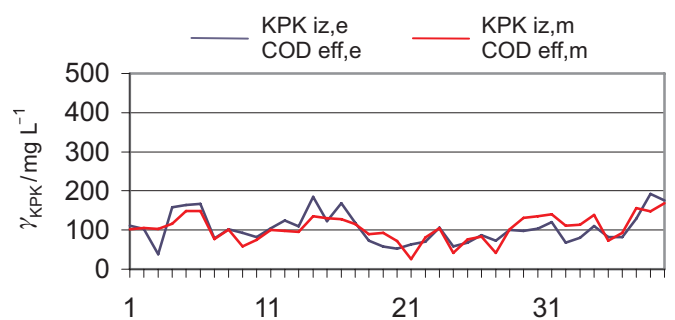
Regresijski koeficijent ovog modela kao i kod modela sa 18 varijablom iznosio je  $R^2=0,847$  uz nešto povećanu srednju pogrešku, koja u ovom slučaju iznosi  $\gamma = 16,2 \text{ mg L}^{-1}$ . Slaganje modela s eksperimentalnim podacima vidljivo je iz grafičkog prikaza na slici 8. Prema regresijskom koeficijentu vidljivo je da i ove veličine možemo slobodno zanemariti prilikom predviđanja ponašanja sustava te se isti neće odraziti na točnost pretpostavljenog modela.

Za potrebe provjere uspješnosti ("verifikacije") modela, cjelokupna baza podataka podijeljena je nasumičnim odabirom na 2 dijela, u omjeru 4:1. Na većem dijelu ( $N = 154$ ) provedena je ponovno analiza sa zadaćom utvrđivanja veličina modela s odabranim 17 nezavisnih varijabli. Regresijski koeficijent ovog modela iznosio je  $R^2 = 0,869$ , a slaganje modela s eksperimentalnim podacima vidljivo je iz grafičkog prikaza na slici 9. Model je zatim provjeren na




Slika 5 – Slaganje modela MLR s eksperimentalno određenim vrijednostima  $KPK_{iz}$  po pojedinom skupu podataka za provjeru modela

Fig. 5 – Comparison of the MLR model with experimental value  $COD_{eff}$  for data selected for the model validation



Slika 5a – Slaganje modela MLR s eksperimentalno određenim vrijednostima  $KPK_{iz}$  na preostalom skupu podataka za provjeru modela

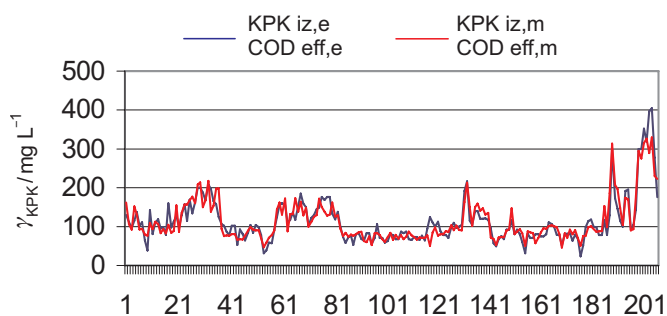
Fig. 5a – Comparison of the MLR model with experimental value  $COD_{eff}$  on remained set of data for model validation



Slika 6 – Slaganje modela  $PLR_{21}$  ( $KPK_{iz,m}$ ) s eksperimentalno određenim vrijednostima  $KPK_{iz,e}$  po pojedinom skupu podataka

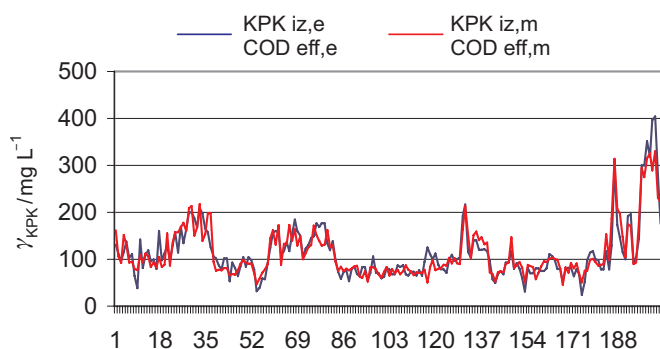
Fig. 6 – Comparison of the  $PLR_{21}$  model ( $COD_{eff,m}$ ) with experimental values of  $COD_{eff,e}$  for individual set of data

novom skupu podataka (preostalim 20 % svih podataka,  $N = 39$ ), uvrštavanjem eksperimentalno određenih vrijednosti nezavisnih varijabli u modelne jednadžbe. Njihovo slaganje s eksperimentalno dobivenim vrijednostima može se opisati utvrđenim regresijskim koeficijentom  $R^2 = 0,682$ , što je grafički prikazano slikom 9a. Srednja pogreška u oba modela za provjeru iznosila je  $\gamma = 16,4 \text{ mg L}^{-1}$ . S obzirom na regresijski koeficijente dobivene provjerom modela na



Slika 7 – Slaganje modela  $PLR_{18}$  ( $KPK_{iz,m}$ ) s eksperimentalno određenim vrijednostima  $KPK_{iz,e}$  po pojedinom skupu podataka

Fig. 7 – Comparison of the  $PLR_{18}$  model ( $COD_{eff,m}$ ) with experimental values of  $COD_{eff,e}$  for individual set of data



Slika 8 – Slaganje modela  $PLR_{17}$  ( $KPK_{iz,m}$ ) s eksperimentalno određenim vrijednostima  $KPK_{iz,e}$  po pojedinom skupu podataka

Fig. 8 – Comparison of the  $PLR_{17}$  model ( $COD_{eff,m}$ ) with experimental values of  $COD_{eff,e}$  for individual set of data


većem skupu podataka i dobivenu srednju pogrešku na ovom modelu možemo zaključiti da se ovim modelom može dobro opisati dinamika procesa obrade otpadne vode uključujući mjerenja 17 veličina. Pritom je potrebno naglasiti da sve mjerene veličine ne utječu podjednako na vrijednost KPK na izlazu iz sustava, te je potrebno naprednijim tehnikama modeliranja odrediti utjecaj pojedine varijable na vrijednost KPK izlaza.

Za bolje opisivanje procesa i definiranje vrijednosti svih veličina odnosno njihovih odnosa svakao bi trebalo primijeniti još složenije empirijske modele kao npr. model neuronskih mreža.

## Zaključak


Zadaća ovog istraživanja je utvrditi granice primjenljivosti modela MLR i PLR za opis procesa biološke obrade komunalne otpadne vode. Iako je to izrazito nelinearan proces, rezultati dobiveni modelom PLR, koji se može smatrati i nelinearnim, pokazuju da je očekivana pogreška za predviđanje izlaznih vrijednosti KPK prihvatljiva s obzirom na ukupnu pogrešku analitičkih metoda određivanja kvalitete ulazne i izlazne vode, uvjete pri kojima uređaj radi te na metodu određivanja kvalitete aktivnog mulja.

Jednostavnom usporedbom regresijskih koeficijenata izrađenih modela vidljivo je da je sposobnost predviđanja



Slika 9 – Slaganje modela  $PLR_{17}$  ( $KPK_{iz,m}$ ) s eksperimentalno određenim vrijednostima  $KPK_{iz,e}$  po pojedinom skupu podataka za provjeru modela

Fig. 9 – Comparison of the  $PLR_{17}$  model ( $COD_{eff,m}$ ) with experimental values of  $COD_{eff,e}$  for individual set of data for model validation



Slika 9a – Slaganje modela  $PLR_{17}$  ( $KPK_{iz,m}$ ) s eksperimentalno određenim vrijednostima  $KPK_{iz,e}$  na preostalom skupu podataka za provjeru modela

Fig. 9a – Comparison of the  $PLR_{17}$  model ( $COD_{eff,m}$ ) with experimental values of  $COD_{eff,e}$  on remaining set of data for model validation

ponašanja sustava koju ima linearni model (MLR), kojim je objašnjeno 54,79 % varijabilnosti svih podataka, lošija od složenijeg modela lokalne linearne regresije (PLR), kojim je objašnjeno 68,25 % podataka, što svakako navodi na zaključak da se radi o procesu koji je izrazito složen, nelinearne i dinamične prirode, te da bi za opis takvog procesa svakako trebalo primijeniti složeniji model i naprednije postupke modeliranja, kao što su umjetna inteligencija (neuronske mreže ili genetički algoritam).

Iz rezultata dobivenih ovim modelima vidljivo je da na proces, odnosno kvalitetu obrađene izlazne vode utječe velik broj različitih bioloških, kemijskih i fizikalnih čimbenika, te je od osobite važnosti da se u sve modele uključuju iste nezavisne varijable kao veličine predikcije.

Sve mjerene veličine uzete u analizu kao nezavisne varijable ne utječu podjednako na promatranu zavisnu veličinu ( $KPK_{iz}$ ). Ovisno o primijenjenom modelu, neki od mjerenih veličina mogu se u potpunosti zanemariti u predviđanju ponašanja procesa i njegovom optimalnom vođenju. Tako je od 25 mogućih za izradu MLR-modela bilo potrebno tek 16, za izradu PLR-modela 17 nezavisnih varijabli, a bez izrazitog gubitka točnosti modela ili čak uz povećanje točnosti.

**Literatura:**

1. Tchobanoglous, G., *Wastewater Engineering, Treatment, Disposal, Reuse*, McGraw-Hill Inc., Metcalf and Eddy, New York, London, Hamburg, (1991).
2. G. M. Zeng, X. S. Qin, L. He, G. H. Huang, H. L. Liu, Y. P. Lin, *Eng. Appl. Artif. Intel.* **16** (2003) 121.
3. K. P. Oliveira-Esquerre, M. Mori, R. E. Bruns, *Braz. J. Chem. Eng.* **19** (2002) 365.
4. G. Reichl, *International Modelica Conference*, Linköping, (2003) str. 171–176.
5. D. S. Lee, C. O. Jeon, J. M. Park, K. S. Chang, *Biotechnol. Bioeng.* **78** (2002) 670.
6. C. K. Yoo, P. A. Vanrolleghem, I. Lee, *J. Biotechnol.* **105** (2003) 135.
7. D. S. Lee, P. A. Vanrolleghem, J. M. Park, *J. Biotechnol.* **115** (2005) 317.
8. K. P. Oliveira-Esquerre, D. E. Seborg, R. E. Bruns, M. Mori, *Chem. Eng. J.* **104** (2004) 73.
9. *Standard Methods for the Examination of Water and Wastewater* (1996) American Public Health Association (APHA), Washington.
10. S. Yordanova, N. Noikova, *Bioprocess Eng.* **15** (1996) 201.
11. J. Zhu, J. Zurcher, M. Rao, M. Q. Meng, *Eng. Appl. Artif. Intel.* **11** (1998) 747.
12. *Pravilnik o graničnim vrijednostima pokazatelja, opasnih i drugih tvari u otpadnim vodama* (1999), Zagreb, Narodne novine, broj 40 (NN 40/99).
13. StatSoft, Inc. (2003) STATISTICA (data analysis software system) version 6.1., <http://www.statsoft.co>
14. Y. S. T. Hong, M. R. Rosen, R. Bhamidimarri, *Wat. Res.* **37** (2003) 1608.

**Kratice:**

- ul – ulazni tok sirove otpadne vode  
 in – inflow of raw wastewater  
 iz – izlazni tok pročišćene vode  
 eff – effluent of refined wastewater  
 m – model  
 e – eksperimentalna vrijednost  
 – experimental value

**Nomenklatura:**

- KPK – kemijska potrošnja kisika  
 COD – chemical oxygen demand  
 MLR – viševarijantni linearni model  
 MLR – multiple linear regression  
 PLR – model lokalne linearne regresije  
 PLR – Piecewise Linear Regression

- PLS – model djelomičnih najmanjih kvadrata  
 PLS – Partial Least Squares  
 ASM – model aktivnog mulja  
 ASM – activated sludge model  
 $R^2$  – regresijski koeficijent  
 $R^2$  – coefficient of regression  
 SSE – suma kvadratnih odstupanja (modelna i eksperimentalna vrijednost)  
 SSE – sum of squared errors (model and experimental value)  
 SSR – suma kvadratnih odstupanja (modelna i srednja eksperimentalna vrijednost)  
 SSR – sum of squared residuals (model and average experimental value)  
 SST – ukupna suma svih kvadratnih odstupanja  
 SST – total sum of squared residuals  
 $\hat{y}$  – modelom predviđena vrijednost  
 $\hat{y}$  – appropriate value of prediction by model  
 $\bar{y}$  – srednja vrijednost  
 $\bar{y}$  – mean value  
 $\beta$  – regresijski koeficijent normaliziranog modela  
 $\beta$  – regression coefficient of the normalised model  
 B – veličina modela  
 B – model quantities  
 $y_0$  – vrijednost odabrane izlazne veličine  
 $y_0$  – referent value of the output value  
 r – Paersonov koeficijent  
 r – Pearson's coefficient  
 p – pripadajuća razina signifikantnosti  
 p – corresponding level of significance

**Veličine, oznake i jedinice:**

- temperatura zraka  $\vartheta_{\text{zrak}} / ^\circ\text{C}$   
 air temperature  $\vartheta_{\text{air}} / ^\circ\text{C}$   
 protok otpadne vode  $q_v$  (otpadne vode) /  $\text{L s}^{-1}$   
 wastewater flow rate  $q_v$  (wastewater) /  $\text{L s}^{-1}$   
 odvojeni sirovi mulj  $q_v$  (aktivni mulj) /  $\text{m}^3 \text{d}^{-1}$   
 removed raw activated sludge  $q_v$  (activated sludge) /  $\text{m}^3 \text{d}^{-1}$   
 odvojeni pijesak  $q_v$  (pijesak) /  $\text{m}^3 \text{d}^{-1}$   
 removed sand  $q_v$  (sand) /  $\text{m}^3 \text{d}^{-1}$   
 odvojena mast  $q_v$  (mast) /  $\text{m}^3 \text{d}^{-1}$   
 removed fat  $q_v$  (fat) /  $\text{m}^3 \text{d}^{-1}$   
 odvojeno smeće  $q_v$  (smeće) /  $\text{m}^3 \text{d}^{-1}$   
 removed garbage  $q_v$  (garbage) /  $\text{m}^3 \text{d}^{-1}$   
 suha tvar aktivnog mulja  $\gamma_x$  /  $\text{kg m}^{-3}$   
 dry activated sludge  $\gamma_x$  /  $\text{kg m}^{-3}$   
 indeks aktivnog mulja  $l_m$  /  $\text{mL g}^{-1}$   
 index of activated sludge  $l_s$  /  $\text{mL g}^{-1}$   
 obujamna koncentracija  $\sigma$  /  $\text{m L}^{-1}$   
 volume concentration  $\sigma$  /  $\text{m L}^{-1}$



## SUMMARY

**Modelling of Activated Sludge Wastewater Treatment Process in Municipal Plant in Velika Gorica***M. Čurlin,<sup>a</sup> A. Bevetek,<sup>a</sup> Z. Ležajić,<sup>b</sup> B. Deverić Meštrovic,<sup>b</sup> and Ž. Kurtanjek<sup>a</sup>*

Activated sludge wastewater treatment is a highly complex physical, chemical and biological process, and variations in wastewater flow rate and its composition, combined with time-varying reactions in a mixed culture of microorganisms, make this process non-linear and unsteady.

The efficiency of the process is established by measuring the quantities that indicate quality of the treated wastewater, but they can only be determined at the end of the process, which is when the water has already been processed and is at the outlet of the plant and released into the environment. If the water quality is not acceptable, it is already too late for its improvement, which indicates the need for a feed forward process control based on a mathematical model.

Since there is no possibility of retracing the process steps back, all the mistakes in the control of the process could induce an ecological disaster of a smaller or bigger extent. Therefore, models that describe this process well may be used as a basis for monitoring and optimal control of the process development.

This work analyzes the process of biological treatment of wastewater in the Velika Gorica plant. Two empirical models for the description of the process were established, multiple linear regression model (MLR) with 16 predictor variables and piecewise linear regression model (PLR) with 17 predictor variables. These models were developed with the aim to predict COD value of the effluent wastewater at the outlet, after treatment.

The development of the models is based on the statistical analysis of experimental data, which are used to determine the relations among individual variables.

In this work are applied linear models based on multiple linear regression (MLR) and partial least squares (PLR) methods.

The used data were obtained by everyday measurements of the quantities that indicate the quality of the input and output water, working conditions of the plant and the quality of the activated sludge. The database contains 223 groups, each with 26 parameters, for the entire year of 2004. The variables were analyzed for determination of the most important factors.

The analyses were done with significance level of  $p < 0.05$ , which is a commonly acceptable error level in the industrial process. The complex nature of the process and its sensitivity, depending on different factors, have been confirmed by the results of the analyses in this work. In all of the developed models the quantities that describe climatic influence, biological components and the quality of the "raw material" i.e. incoming wastewater, have been included as predictors. It is clear that the quality of the treated wastewaters, and thus the efficiency of the process are changing depending on a number of factors that influence the process differently.

Even though more intricate models, like artificial intelligence, are used to describe such complex processes, it can be concluded that even such simple models like MLR and PLR can present the complexity and dynamics of this process with acceptable reliability.

In this work for the developed models, the obtained average error of multiple linear regression model is  $\gamma_{\text{KPK}} = 16 \text{ mg L}^{-1} \text{ O}_2$  and the average error of piecewise linear regression model is  $\gamma_{\text{KPK}} = 16 \text{ mg L}^{-1} \text{ O}_2$ .

<sup>a</sup> University of Zagreb, Faculty of Food Technology and Biotechnology, Pierottijeva 6, 10 000 Zagreb, Croatia

Received August 31, 2006  
Accepted July 18, 2007

<sup>b</sup> "VG Vodoopskrba" d. o. o., Kolodvorska 64, 10 410 Velika Gorica, Croatia