



Polska Akademia Nauk • Instytut Badań Systemowych

AUTOMATYKA STEROWANIE ZARZĄDZANIE

Książka jubileuszowa
z okazji
70-lecia urodzin

PROFESORA KAZIMIERZA MAŃCZAKA

pod redakcją
Jakuba Gutenbauma



Polska Akademia Nauk • Instytut Badań Systemowych

AUTOMATYKA STEROWANIE ZARZĄDZANIE

**Książka jubileuszowa
z okazji
70-lecia urodzin**

PROFESORA KAZIMIERZA MAŃCZAKA

**pod redakcją
Jakuba Gutenbauma**

Warszawa 2002

Książka jubileuszowa z okazji
70-lecia urodzin
Profesora Kazimierza MAŃCZAKA

Redaktor
prof. dr hab. inż. Jakub Gutenbaum

Copyright © by Instytut Badań Systemowych PAN

Warszawa 2002

ISBN 83-85847-78-2

Wydawca: Instytut Badań Systemowych PAN
ul. Newelska 6 01-447 Warszawa
<http://www.ibspan.waw.pl>

Opracowanie składowania: Anna Gostyńska, Jadwiga Hartman

Druk: KOMO-GRAF, Warszawa
nakład 200 egz., 34 ark. wyd., 31 ark. druk.

MODELE HYDRAULICZNE I OPERACYJNE DLA MECHANICZNO-BIOLOGICZNEJ OCZYSZCZALNI ŚCIEKÓW

Lucyna Bogdan, Zbigniew Nahorski, Jan Studziński

Instytut Badań Systemowych, Polska Akademia Nauk

Newelska 6, 01-447 Warszawa,

<(bogdan, studzins, nahorski)@ibspan.waw.pl>

Abstract: The paper presents the mathematical models for municipal mechanico-biological treatment plant. They consist of hydraulic models describing the flow dynamics of sewage in the treatment plant basins and models for forecasting of influent raw sewage as well as for forecasting of purified sewage at the output of the plant. All these models and the physical model presented in (Bogdan et al. 2000) are the elements of a computer aided decision system intended to help the wastewater treatment plant operator. The hydraulic models are in the form of the ordinary differential equations. For forecasting purposes time series or neural nets are used. To train the models the measurements from the experiment performed in the wastewater treatment plant were used.

Keywords: mathematical models, differential equations, wastewater treatment plant, forecasting, neural nets.

1. Wprowadzenie

Automatyka konwencjonalna z regulatorami PID jest od dawna stosowana w oczyszczalniach ścieków. Jest ona użyteczna do stabilizacji pojedynczych procesów, jednak niewystarczająca w przypadkach gwałtownie zmieniających się warunków pracy oczyszczalni, co jest spowodowane np. niestacjonarnym dopływem ścieków do obiektu.

Znając równania matematyczne opisujące procesy cząstkowe zachodzące w oczyszczalni, można sformułować model matematyczny całego procesu oczyszczania. Modele tego rodzaju były już tworzone, ale ich praktyczne wykorzystanie do sterowania obiektami jest dotychczas skromne z powodu ich dużej złożoności i trudności związanych z doбором

parametrów dla konkretnej oczyszczalni. Są to modele oparte na fizycznych, chemicznych i biologicznych zasadach zachowania i obecnie są one głównie wykorzystywane dla lepszego poznania procesu oczyszczania i dla oszacowań jakościowych (tzw. *modele fizykalne*). Jednak są też możliwe bardziej zaawansowane zastosowania tych modeli. Jednym z tych zastosowań jest wspomaganie ręcznego sterowania procesem, na przykład jako elementy systemu eksperckiego, w szczególności komputerowego systemu wspomaganie decyzji (Kayser 1990). Model taki, oparty na modelu standardowym znanym w literaturze pod nazwą *Activated Sludge Model No. 1* (Henze i in. 1987), został przedstawiony w pracy (Szetela 1997).

Jednak modele fizykalne, z powodu swojej dużej złożoności i czasochłonności obliczeń, nie nadają się do bezpośredniego sterowania procesem. Taką funkcję mogą natomiast spełniać proste *modele operacyjne* formułowane w postaci szeregów czasowych lub sieci neuronowych. Są one prostsze w opisie matematycznym i mniej dokładne, za to znacznie szybsze w obliczeniach. Modele tego typu przedstawione poniżej są przeznaczone do prognozowania dopływu ścieków surowych do oczyszczalni oraz prognozowania stanu ścieków oczyszczonych na wyjściu oczyszczalni. Funkcją dokładnego modelu fizykalnego w komputerowym systemie wspomaganie decyzji jest wówczas weryfikacja wyników otrzymanych na podstawie modeli operacyjnych.

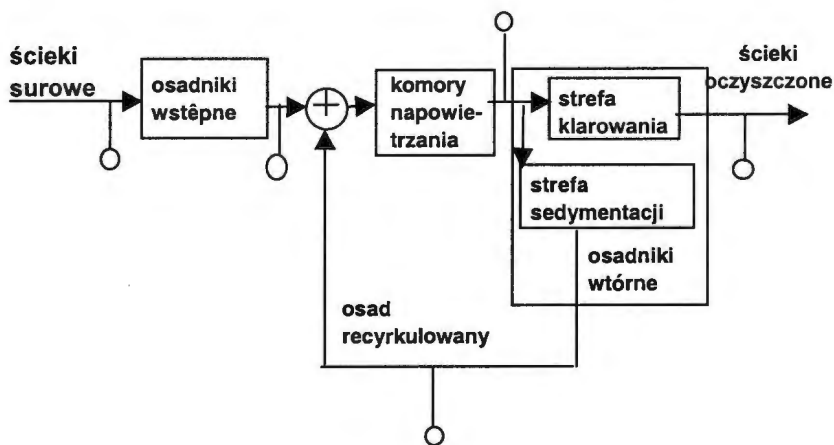
Ponadto w artykule przedstawiono wyniki identyfikacji *modeli hydraulicznych* tworzonych dla różnych zbiorników oczyszczalni. Modele te są opisane równaniami różniczkowymi zwyczajnymi i opisują dynamikę przepływu ścieków przez oczyszczalnię. Jednocześnie służą one do wyznaczania dla tych zbiorników ich objętości czynnych, które są następnie stosowane jako parametry w modelu fizykalnym oczyszczalni (Bogdan i in. 2000 oraz Szetela 1997).

Wszystkie obliczenia modelowania i identyfikacji wykonano na podstawie pomiarów zebranych w miejskiej oczyszczalni ścieków w Rzeszowie w wyniku przeprowadzonego tam aktywnego eksperymentu pomiarowego (Bogdan i in. 1996 oraz Nahorski 1994).

2. Oczyszczalnia ścieków w Rzeszowie

Oczyszczalnia ścieków w Rzeszowie ma wydajność 75.000 m³ ścieków/dzień. Miejski system ścieków jest częściowo typu mieszanego, gdyż w starej części miasta jest połączony z układem kanalizacji deszczowej. Oprócz komunalnych ścieków sanitarnych do oczyszczalni dopływają także ścieki przemysłowe pochodzące z zakładów farmaceutycznych, spożywczych oraz dużych zakładów metalowych. Oczysz-

czalnia składa się z następujących podstawowych obiektów: dwa osadniki wstępne, trzy równoległe komory napowietrzania i dwa osadniki wtórne (por. rys. 1). Przepływ ścieków przez oczyszczalnię i ich oczyszczenie odbywa się następująco. Zanieczyszczone ścieki surowe z miejskiej sieci kanalizacyjnej wpływają do osadników wstępnych, w których następuje sedymentacja zanieczyszczeń stałych (*oczyszczanie mechaniczne*). Ścieki częściowo oczyszczone przepływają do komór z osadem czynnym (który tworzą różnego typu bakterie i mikroorganizmy), do których jest pompowane powietrze. W komorach z osadem czynnym (*napowietrzania*) zanieczyszczenia organiczne ulegają dekompozycji biologicznej w warunkach tlenowych i przy udziale bakterii (*oczyszczanie biologiczne*). Z komór napowietrzania ścieki przepływają do osadników wtórnych, gdzie pod wpływem grawitacji następuje sedymentacja osadu czynnego z wchłoniętymi zanieczyszczeniami (*klarowanie, czyli ponownie oczyszczanie mechaniczne*). Część osadu z osadników wtórnych podlega recyrkulacji do wejścia komór napowietrzania (*recyrkulacja zewnętrzna*), natomiast pozostała część osadu (tzw. *osad nadmierny*) jest usuwana z procesu.



Rys.1. Schemat połączeń głównych zbiorników oczyszczalni ścieków.

Na rys. 1 pokazano grupy zbiorników tego samego typu. Za pomocą kółek oznaczono punkty pomiarowe podczas eksperymentu czynnego. Osadnik wtórny jest podzielony na górną część klarowania i dolną część osadową.

W tabelicy 1 pokazano charakterystyki dopływu ścieków surowych do oczyszczalni w Rzeszowie. Badany obiekt zalicza się do oczyszczalni średnio obciążonych, przy czym zanieczyszczenia azotowe i fosforowe są

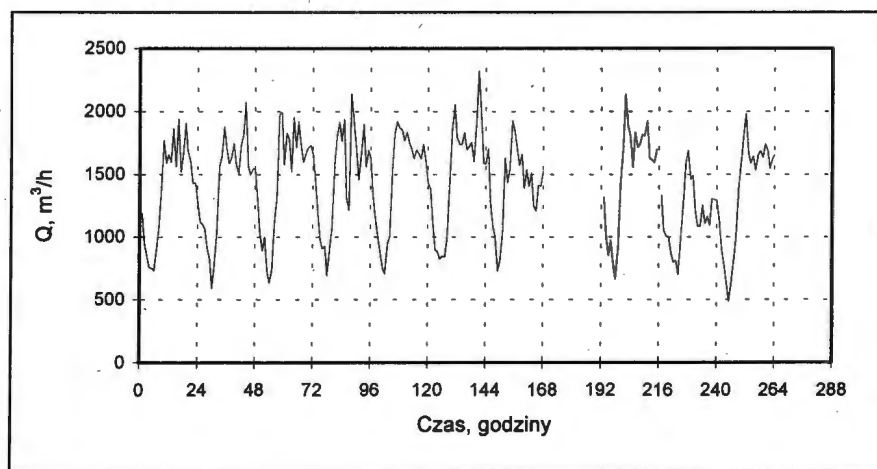
skoncentrowane głównie w materii organicznej (wysokie wartości ChZT – chemiczne zapotrzebowanie tlenu, i BZT₅ – biologiczne zapotrzebowanie tlenu).

Tablica 1. Parametry dopływu ścieków surowych do oczyszczalni.

	Jednostka	min.	średnio	max.
Przepływ	m ³ /d		35 000	
Zawiesina	g/m ³	84.0	309.2	349.1
BZT ₅	gO ₂ /m ³	80.0	416.8	770.0
ChZT	gO ₂ /m ³	325.0	507.6	753.0
Azot amonowy	gN/m ³	14.0	28.3	40.0
Azot całkowity	gN/m ³	29.0	52.9	81.0
Fosfor całkowity	gP/m ³		15.1	
Siarka całkowita	gS/m ³		94.2	

3. Model hydrologiczny

Model hydrologiczny oczyszczalni składa się z połączonych podmodeli jej zbiorników traktowanych jako zbiorniki z idealnym mieszaniem. W każdym podmodelu jedynym nieznanym parametrem jest objętość czynna zbiornika. Jest to ta część jego objętości geometrycznej, która czynnie uczestniczy w dynamice przepływu. W praktyce objętość czynna zbiornika może się znacznie różnić od jego objętości geometrycznej. Główna trudność estymacji objętości czynnej zbiorników jest spowodowana zmiennym dopływem ścieków do oczyszczalni (por. rys. 2).



Rys.2. Dopływ ścieków surowych do oczyszczalni.

Dlatego zastosowany do opisu dynamiki przepływu ścieków w zbiorniku model matematyczny, w postaci równania bilansowego, jest równaniem ze zmiennym parametrem

$$V \frac{dc(t)}{dt} = Q(t)[c_{in}(t) - c(t)] \quad (1)$$

gdzie V jest objętością czynną, $c(t)$ jest koncentracją zanieczyszczenia w zbiorniku, $c_{in}(t)$ jest koncentracją zanieczyszczenia w dopływie i $Q(t)$ jest natężeniem dopływu. Jest to równanie różniczkowe zwyczajne pierwszego rzędu ze zmiennym parametrem. Ze względu na techniczne rozwiązanie odpływu w rzeczywistości zmiana natężenia dopływu powoduje nieznaczną zmianę objętości czynnej zbiornika. Przeprowadzona w (Bogdan i in. 2000) analiza tego zjawiska doprowadziła jednak do wniosku, że błąd spowodowany przyjęciem stałej objętości jest rzędu 1%, a więc nie większy niż błąd estymacji, który na podstawie wyników można oszacować na około 5%.

Wprowadzamy nową zmienną (Niemi 1988)

$$\xi(t) = \int_0^t Q(\tau) d\tau$$

będącą ilością ścieków, które przepłynęły przez zbiornik od początku okresu obserwacji do chwili t . Ponieważ $Q(t) > 0$, więc istnieje różniczkowalna funkcja odwrotna $t = g(\xi)$. Podstawiając ją do (1), otrzymujemy

$$V \frac{dc(\xi)}{d\xi} \frac{d\xi}{dt} = Q(\xi)[c_{in}(\xi) - c(\xi)]$$

gdzie $c(\xi) = c(g(\xi))$, i analogicznie dla $c_{in}(\xi)$ i dla $Q(\xi)$. Dla uproszczenia rozważań będziemy używać tej samej notacji dla funkcji $c(t)$ oraz dla superpozycji funkcji $c(g(\xi))$. Ponieważ zachodzi $d\xi/dt = Q(t)$, więc

$$V \frac{dc(\xi)}{d\xi} = c_{in}(\xi) - c(\xi) \quad (2)$$

Jeżeli upływ czasu będzie mierzony nie w jednostkach czasu, a w jednostkach przepływu cieczy przez zbiornik, to wówczas z opisu zbiornika (1) otrzymamy opis (2) w postaci równania ze stałym parametrem.

Dla wyznaczenia modeli hydraulicznych oczyszczalni przeprowadzono eksperyment czynny, polegający na podaniu na wejście oczyszczalni pewnego zanieczyszczenia w postaci sygnału wymuszającego. Ze względów technologicznych wybrano sygnał wymuszający odcinkami stały, tzn. $c_{in}(\xi)$

$= c_{in}(\xi_{n-1})$ dla $t_{n-1} \leq t < t_n$, gdzie $\xi_{n-1} = \xi(t_{n-1})$ i t_{n-1}, t_n są odpowiednio $(n-1)$ -szym i n -tym momentem obserwacji. Wtedy równanie (2) można przekształcić do postaci

$$c(\xi_n) = \frac{1}{V} \int_0^{\xi_n} e^{-\frac{\xi_n - \tau}{V}} c_{in}(\tau) d\tau = e^{-\frac{\Delta_n}{V}} c(\xi_{n-1}) + (1 - e^{-\frac{\Delta_n}{V}}) c_{in}(\xi_{n-1}) \quad (3)$$

gdzie $\Delta_n = \xi_n - \xi_{n-1}$ jest krokiem obserwacji.

Dane wykorzystane do estymacji objętości czynnej V zostały zebrane podczas eksperymentu, w którym jako znacznika użyto jonów chloru. Osiągnięto to przez dodanie soli (NaCl) do dopływu ścieków surowych. Zgodnie z otrzymanymi w (Nahorski 1994) wynikami optymalizacji przyjęto, że optymalny odcinkami stały sygnał wymuszający, dla stałego kroku obserwacji Δ , jest okresowy z długością okresu zawartą między 4V i 6V (zależnie od wartości Δ). Optymalny krok obserwacji zawiera się między V a $1.5V$.

Jeżeli stężenie znacznika w ściekach mierzy się z dostatecznie dobrą dokładnością, wtedy objętość V może być estymowana na podstawie wyrażenia

$$\frac{c(\xi_n) - c_{in}(\xi_{n-1})}{c(\xi_{n-1}) - c_{in}(\xi_{n-1})} = e^{-\frac{\Delta_n}{V}}, n = 1, 2, \dots, N \quad (4)$$

przy czym do estymacji można zastosować metodę najmniejszych kwadratów.

Ze względów technicznych nie było możliwe mierzenie stężeń jonów chloru oddzielnie na wejściu i wyjściu każdego zbiornika oczyszczalni i dlatego dokonano pomiarów dla grup zbiorników tego samego rodzaju: dwóch osadników wstępnych, trzech komór napowietrzania i dwóch osadników wtórnych. Zastosowano dwie metody estymacji: (i) liniową metodę najmniejszych kwadratów (LS) przy użyciu równania (3) oraz (ii) nieliniową metodę najmniejszych kwadratów (NL) przy użyciu równania (4). Aby zastosować metodę LS, zastosowano interpolację sygnałów $c(\xi_n)$ i $c_{in}(\xi_n)$, otrzymując stałą wartość $\Delta_n = \xi_n - \xi_{n-1} = \Delta$. W ten sposób równanie (3) może być przekształcone do postaci $c(\xi_n) = ac(\xi_{n-1}) + bc_{in}(\xi_{n-1})$, gdzie $b = 1 - a$ i $a = \exp(-\Delta/V)$ są stałymi parametrami. W tablicy 2 przedstawiono przykładowe wyniki obliczeń z opisanych szerzej w (Bogdan i in. 1996).

W osadnikach wtórnych stężenia znacznika były mierzone niezależnie w części górnej i dolnej zbiorników (w części górnej zbierają się ścieki

oczyszczone, natomiast w części dolnej zbiera się osad). Dokonano estymacji obu części osadników wtórnych a otrzymane wyniki obliczeń umieszczono w prawej części tablicy 2. W przypadku obu metod estymacji suma obu objętości czynnych jest bardzo zbliżona do objętości geometrycznej osadników. W osadnikach wstępnych mierzono stężenie znacznika tylko w wypływającym strumieniu ścieków, ponieważ w trakcie pomiarów osad w tych zbiornikach nie był usuwany. Jego objętość wpływała na zmniejszenie się objętości czynnej w stosunku do objętości geometrycznej w tych osadnikach. W rezultacie tego estymowana objętość czynna osadników wstępnych jest istotnie mniejsza niż ich objętość geometryczna. Istnieją czynniki, które mogą powodować, że również estymowana objętość czynna komór napowietrzania jest mniejsza niż ich objętość geometryczna. Za najbardziej prawdopodobne uważa się, że odpowiadają za to objętości pęcherzyków powietrza wprowadzanego do komór napowietrzania.

Tablica 2. Estymatory objętości czynnych V zbiorników oczyszczalni, w [m³].

	Osadniki wstępne	Komory napowietrzania	Osadniki wtórne	
			część górna	część dolna
LS	5676	11246	4723	6303
NL	6283	12087	4612	6514
Średnia obu wartości	5980	11667	4668	6408
Objętości geometryczne	7820	13500	11060	
Średnia [%] Geometryczna	76,5	86,4	~ 100	

4. Modele prognozowania dopływu ścieków surowych

Modele prognostyczne pozwalają przewidywać przyszłe stany na wejściu obiektu i przygotować z odpowiednim wyprzedzeniem działania eliminujące ewentualne zakłócenia, tzn. wyznaczyć odpowiednie sterowania procesem. Jednym ze sposobów modelowania dopływu ścieków jest wyznaczanie modeli różnicowych typu ARMA (*autoregressive moving average*). W takim modelu każdy bieżący pomiar chwilowy jest traktowany jak funkcja pewnej liczby poprzednich pomiarów z dodanym zakłóceniem wynikającym z błędów pomiarowych. Liczba uwzględnionych poprzednich pomiarów jest rzędem modelu (*równania różnicowego*). Rozważane poniżej modele różnicowe są postaci (Studziński i in. 1998):

$$y_n = a_1 y_{n-1} + a_2 y_{n-2} + \dots + a_R y_{n-R} + v_n$$

gdzie R jest rzędem modelu, a_i jest parametrem modelu a v_n oznacza błąd pomiaru. Wyznaczenie modelu różnicowego polega na wyznaczeniu jego rzędu oraz wartości parametrów. Służą do tego różne metody sprowadzone najczęściej do minimalizacji sumy kwadratów różnic między wyjściem obiektu (*danymi pomiarowymi*) i wyjściem modelu (*wynikami obliczeń*).

Na rysunkach 3 i 4 (*górne wykresy*) przedstawiono przykładowe wyniki otrzymane dla modelu autoregresji 5. rzędu (*model AR*) o następujących parametrach uzyskanych z identyfikacji:


$a_1 = -0.7339$, $a_2 = -0.0609$, $a_3 = -0.1751$, $a_4 = 0.7339$, $a_5 = 0.1797$. Obliczenia przeprowadzono dla pomiarów dopływu ścieków wykonanych w oczyszczalni Rzeszów w marcu i maju 1996 r. Pomiaru dopływu były wykonywane automatycznie co 2 min. Przed modelowaniem uśredniono je dla okresów jednogodzinnych (*tzn. dla kolejnej godziny przyjmowano wartość średnią z 30 pomiarów dwuminutowych*). Wykres na rys. 3 przedstawia częściowe wyniki dopasowania wyjść modelu po identyfikacji (*dla pierwszych 150 godz miesiąca*) otrzymane na podstawie pomiarów z jednego miesiąca (*marca*), natomiast wykres na rys. 4 przedstawia częściowe wyniki prognozowania dla niezależnych danych otrzymane za pomocą wyznaczonego modelu dla pomiarów z drugiego miesiąca (*maja*). Czas prognozowania dopływu wynosi 1 godz.

Inny sposób modelowania dopływu polega na zastosowaniu sieci neuronowych (Studziński i in. 1998). Sieci neuronowe można traktować jako układy równań algebraicznych wynikających z zadanej struktury sieci. Sieć neuronowa jest zbudowana z jednego lub większej liczby neuronów. Każdy neuron generuje wyjście a na podstawie wejścia p oraz współczynnika wagowego w , współczynnika obciążenia b i funkcji przejścia F :

$$a = F(wp + b)$$

Zarówno w jak i b są nastawialne. Proces poszukiwania optymalnych wartości jest nazywany trenowaniem sieci. Trening może się odbywać poprzez zastosowanie różnych metod optymalizacji w zależności od architektury sieci, mocy komputera i charakteru błędu. Architektura sieci może być różna, co wiąże się ze specyficznymi właściwościami modelowanego procesu. Sieć składa się z jednej warstwy lub wielu warstw. Powszechnie dla celów modelowania stosuje się modele typu *back propagation* składające się z 3 warstw: wejściowej, ukrytej i wyjściowej. Każdy neuron w warstwie jest połączony przez macierz wag $w(i,j)$ z wybranym neuronem następnej warstwy. Każdy neuron sumuje odpowiadające mu wejścia i dodaje obciążenie. W zależności od tego, czy


funkcja przejścia jest liniowa czy nieliniowa, otrzymujemy liniowe lub nieliniowe modele neuronowe.



Rys.3. Wyniki dopasowania dopływu ścieków po identyfikacji dla modelu autoregresji (wykres górny) oraz dwóch modeli neuronowych (wykresy środkowy i dolny; linia przerywana oznacza pomiary).

Wyznaczenie modelu neuronowego polega wobec tego na zadaniu określonej struktury sieci (tzn. określeniu liczby warstw, liczby neuronów dla każdej warstwy oraz określeniu połączeń między neuronami z sąsiednich warstw), przyjęciu postaci funkcji przejścia oraz obliczeniu wartości współczynników wagowych poprzez przeprowadzenie procesu uczenia sieci. Przy czym to ostatnie oznacza określenie macierzy wag i wektora obciążenia każdej warstwy tak, aby dopasować wyjście sieci do rzeczywistego wyjścia procesu. Porównanie wyjścia sieci i wyjścia procesu (obiektu) dokonuje się poprzez ocenę sumy resztowej modelu. Do minimalizacji błędu może być wykorzystana np. metoda gradientowa optymalizacji. W tej metodzie problemem jest szybkość uczenia. Może wtedy dojść do powolnego i częściowo niestabilnego procesu uczenia, szczególnie dla sieci nieliniowych. Lepsze wyniki uzyskuje się stosując metodę *Gaussa-Newtona* (lub jej uogólnioną wersję *Levenberga-Marquardta*). Metoda ta wymaga większej pamięci, ale w pobliżu minimum funkcji błędu jest szybsza

i dokładniejsza. Proces uczenia sieci zatrzymuje się po osiągnięciu zdefiniowanej wartości progowej ε . W przedstawionych w pracy obliczeniach wartość ε wynosiła 0.2.



Rys.4. Wyniki prognozowania dopływu ścieków dla modelu autoregresji 5. rzędu (wykres górny) oraz dla dwóch modeli neuronowych (wykresy środkowy i dolny).

Na rysunkach 3 i 4 (środkowe i dolne wykresy) przedstawiono przykładowe wyniki modelowania otrzymane dla liniowych modeli neuronowych typu *back propagation* przy użyciu tych samych danych pomiarowych, na podstawie których wyznaczono model autoregresji. Oba modele neuronowe różnią się strukturą wewnętrzną: model NNAR (*neural net autoregressive model*) posiada 5 neuronów w warstwie wejściowej, 7 neuronów w warstwie ukrytej i 1 neuron w warstwie wyjściowej, natomiast model NNBP (*neural netback propagation model*) w identycznych 3 warstwach ma odpowiednio 5, 6 i 1 neuron. Przy wyznaczaniu obu modeli dokonano normowania danych pomiarowych, przy czym dane po unormowaniu w przypadku modelu NNAR miały wartość średnią 0 i wariancję 1, natomiast w przypadku modelu NNBP mieściły się w przedziale $\langle 0,1 \rangle$. Ponadto, przy wyznaczaniu modelu NNAR zastosowano

algorytm badania istotności połączeń między neuronami i usuwania połączeń nieistotnych (*pruning*). Danych pomiarowych przy tworzeniu modeli i prognozowaniu (*faza uczenia i testowania sieci neuronowej*) używano w identyczny sposób, jak w modelu różnicowym, tzn. w przesuwającym się oknie pomiarowym o długości 6 pomiarów 5 pierwszych pomiarów dotyczyło zawsze wejść modelu, a szósty pomiar dotyczył wyjścia modelu (*aktualna wartość wyjścia była funkcją 5 poprzednich pomiarów*).

Ocena wyników nie jest jednoznaczna, wydaje się jednak, że wyznaczone modele, tak różnicowy, jak i neuronowe, mają podobne własności i w miarę poprawnie prognozują dopływ ścieków do oczyszczalni.

5. Model prognozowania stanu ścieków oczyszczonych

Do utworzenia tego modelu prognostycznego w postaci sieci neuronowej użyto danych zebranych w 4 punktach pomiarowych obiektu. Są to punkty (por. rys. 1): na wejściu obiektu, w komorach napowietrzania, w układzie recyrkulacji zewnętrznej oraz na wyjściu obiektu. Ponadto mierzono parametry ścieków surowych i oczyszczonych oraz sterowań procesu.


Zebrane pomiary obejmują:

- BZT₅, stężenia azotu, amoniaku i zawiesiny oraz natężenie dopływu ścieków na wejściu obiektu;
- stężenia tlenu i osadu czynnego oraz szybkość opadania osadu w komorach napowietrzania;
- natężenie przepływu osadu recyrkulowanego (*stopień recyrkulacji*) oraz stężenie osadu w recyrkulacji;
- BZT₅, stężenia azotu, amoniaku i zawiesiny na wyjściu obiektu.


W celu stworzenia modelu neuronowego podzielono całość danych na 3 grupy: danych wejściowych, wyjściowych i sterujących. Parametry ścieków surowych stanowią dane wejściowe, stężenie tlenu i stopień recyrkulacji stanowią dane sterujące, a reszta mierzonych parametrów stanowi dane wyjściowe modelu neuronowego. Należy zwrócić uwagę na to, że przy tworzeniu modelu neuronowego jest konieczna informacja o istotności parametrów wejściowych i wyjściowych, w czym mogą być użyteczne bądź metody statystyczne, bądź wiedza na temat samego procesu.

Naszym zamiarem jest określenie wyjścia rzeczywistego procesu technologicznego biologicznej oczyszczalni ścieków z wyprzedzeniem jednego kroku czasowego. Proces jest nieliniowy, więc należy wybrać taką sieć, która poradzi sobie z tymi nieliniowościami. Jest to możliwe

w przypadku sieci typu *back propagation* z nieliniowymi funkcjami przejścia. Wybrano sieć o trzech warstwach (wejście – warstwa ukryta – wyjście).



Rys.5. Uczenie sieci dla sześciu wyjściowych parametrów modelu procesu (punkty – dane, linia ciągła – sieć).



Rys.6. Testowanie sieci dla tych samych parametrów procesu, co na rys.5.

Funkcja przejścia dla pierwszej i drugiej warstwy jest funkcją logistyczną postaci $a_j = 1/(1 + \exp(-p_j - b_j))$. Funkcja ta przekształca wartości od $-\infty$ do $+\infty$ w wartości z zakresu od 0 do 1. Funkcja przejścia trzeciej warstwy ma postać liniową $a_j = p_j + b_j$. W przypadku liniowej funkcji przejścia wyjście może przyjąć każdą wartość. Pomiarów były zbierane w ciągu pierwszych czterech miesięcy 1997 r. Składają się one z jednego zbioru danych na jedną zmianę, przy trzech zmianach w ciągu doby. W sumie wszystkie dane składają się z 364 zbiorów danych ($D_1 - D_{364}$). Dane zostały wygładzone metodą falek (*wavelet shrinkage method* (Buckheit i in. 1995)).

W modelu neuronowym oczyszczalni ścieków wejście obiektu w czasie t , dane sterujące w czasie t oraz wyjście obiektu w czasie t stanowią wejścia sieci, a wyjście obiektu w czasie $t+T$ stanowi wyjście sieci. W wyniku otrzymuje się 12 parametrów wejściowych i 6 parametrów wyjściowych modelu. Z obliczeń wykonanych podczas uczenia sieci wynika, że najlepsze dopasowanie sieci do danych pomiarowych otrzymuje się dla $T = 8$ godz oraz dla 6 neuronów umieszczonych w ukrytej warstwie sieci. Ostatecznie zastosowano 12 neuronów w pierwszej warstwie, 6 neuronów w warstwie ukrytej i 6 w warstwie wyjściowej. Wyniki modelowania otrzymane dla fazy uczenia i fazy testowania neuronowego modelu procesu pokazano na rysunkach 5 i 6. Na podstawie wyników można stwierdzić oczekiwaną zgodność między danymi pomiarowymi (*obiektem*) a siecią (*modelem*).

5. Wnioski

W pracy przedstawiono wyniki identyfikacji modeli hydraulicznych podstawowych zbiorników mechaniczno-biologicznej oczyszczalni ścieków. Modelowanymi zbiornikami są: dwa osadniki wstępne (*traktowane jak jeden zbiornik*), trzy komory napowietrzania (*traktowana jak jeden zbiornik*) i dwa osadniki wtórne (*traktowane również jak jeden zbiornik*). Zbiorniki są połączone rurami doprowadzającymi i odprowadzającymi ścieki.

Estymowanymi parametrami modeli są objętości czynne zbiorników. Dla celów estymacji zebrano z obiektu pomiary w trakcie eksperymentu czynnego, w którym jako znacznik zastosowano jony chloru. Uzyskane oceny objętości czynnych są traktowane jako parametry w równaniach modelu fizycznego.

Przedstawiono również wyniki modelowania procesu oczyszczania ścieków za pomocą równań różnicowych i sieci neuronowych. Opracowano w ten sposób modele procesu służące do prognozowania dopływu ścieków

do oczyszczalni i stanu ścieków oczyszczonych na wyjściu oczyszczalni. Wyniki obliczeń symulacyjnych stwierdzają przydatność sieci neuronowych do modelowania procesów hydraulicznych i technologicznych zachodzących w oczyszczalniach. Opracowywanie neuronowych modeli operacyjnych jest znacznie prostsze od wyznaczania modelu fizykalnego opisanego równaniami różniczkowymi i również są one znacznie szybsze w obliczeniach. Dlatego modele neuronowe dobrze nadają się do wszelkich zadań o charakterze optymalizacyjnym, gdzie wielokrotnie wykonuje się obliczenia symulacyjne modelu. Natomiast model fizykalny, znacznie wolniejszy w obliczeniach, jest jednocześnie znacznie bardziej dokładny, stąd jego przydatność do badań czysto symulacyjnych, w tym również np. do weryfikacji strategii sterowania oczyszczalnią wyznaczonej na podstawie modeli neuronowych.

Literatura

- Bogdan L., Łomotowski J., Nahorski Z., Studziński J., Szetela R. (2000) Mathematical and neural network modelling of a wastewater treatment plant. *Arch. Control Sciences*, **10**, 89-118.
- Kayser R. (1990) Process control and expert systems for advanced wastewater treatment plant. W: *Instrumentation, Control and Automation of Water and Wastewater Treatment and Transport Systems*, R. Briggs, ed. Pergamon Press, Oxford.
- Henze M., Grady C. P. L. Jr., Marais G. R., Matsuo T. (1987) Activated sludge model No. 1. *IAWPRC Scientific and Technical Reports No. 1*, IAWPRC, London.
- Szetela R. (1997) Wstępna kalibracja modelu symulacyjnego WTPD dla oczyszczalni ścieków w Rzeszowie. *Raport 22/2/S-17/97*, IBS PAN, Warszawa.
- Bogdan L., Nahorski Z., Studziński J. (1996) Estymacja objętości czynnych zbiorników przy zmiennych przepływach. *Raport PWSO 7/96*, IBS PAN, Warszawa.
- Nahorski Z. (1994) Planowanie eksperymentu dla identyfikacji modeli elementów hydraulicznych w oczyszczalni ścieków w Rzeszowie. *Raport 19/9/S-10/96*, IBS PAN, Warszawa.
- Niemi A. J. (1988) Variable parameter model of the continuous flow vessel. *Math. Comp. Modelling*, **11**, 32-37.

- Studziński J., Tesche T., Łomotowski J. (1998) Modele komputerowe procesów i obiektów oczyszczalni ścieków dla cełków symulacji, prognozowania i sterowania. W: *Mat. II Międzyn. Symp. Nauk.-Szkolen. nt. Problemów monitoringu i automatyzacji oczyszczalni ścieków, Ustr. Morskie*, J. Lemański, J. Łomotowski, S. Zabawa, red., 4-17, PZiITS Poznań.
- Studziński J., Tesche T., Bogdan L. (1998) Control of wastewater treatment plants using neural networks for decision making and forecasting. W: *Proceedings of 10th Europ. Simul. Symp. and Exhibition ESS'98 on Simul. in Industry and Simul. Technology*, Nottingham, A. Bargiela, E. Kerckhoffs, eds., 633-637.
- Buckheit J., Donoho, D. (1995) *WaveLab Version 0.700*. Stanford University.

Praca wykonana w ramach grantu KBN 8T 11A 0 1016

ISBN 83-85847-78-2