



Instytut Badań Systemowych
POLSKIEJ AKADEMII NAUK

Jan Studziński

**IDENTYFIKACJA, SYMULACJA
I STEROWANIE
OCZYSZCZALNIAMI ŚCIEKÓW**



**IDENTYFIKACJA, SYMULACJA
I STEROWANIE
OCZYSZCZALNIAMI ŚCIEKÓW**

INSTYTUT BADAŃ SYSTEMOWYCH • POLSKA AKADEMIA NAUK

Seria: BADANIA SYSTEMOWE

tom 35

Redaktor naukowy:

Prof. dr hab. inż. Jakub Gutenbaum

Warszawa 2004

Jan Studziński

**IDENTYFIKACJA, SYMULACJA
I STEROWANIE
OCZYSZCZALNIAMI ŚCIEKÓW**

Publikację opiniowali do druku:

Prof. dr hab. inż. Krzysztof Kuczewski

Prof. dr hab. inż. Andrzej Straszak

Copyright © by Instytut Badań Systemowych PAN
Warszawa 2004

Komputerowa edycja tekstu: Anna Gostyńska

ISBN 83-85847-88-X

ISSN 0208-8029

Druk i oprawa: ARGRAF Sp. z o.o.
03-301 Warszawa, ul. Jagiellońska 76
tel. (22) 811 51 11, (22) 614 53 31

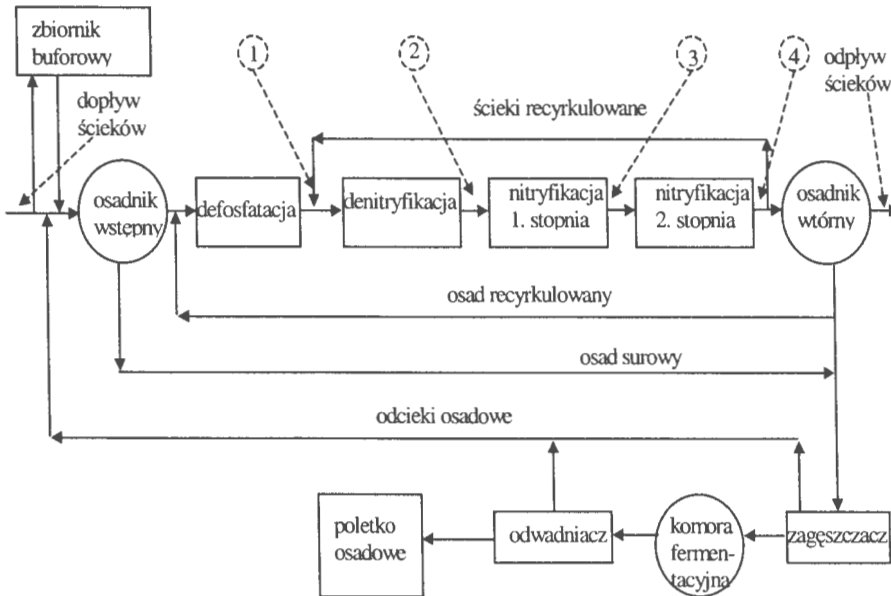
7. STEROWANIE OCZYSZCZALNIĄ

7.1. Sterowanie na podstawie modeli

Oczyszczalnia ścieków jest obiektem trudnym do modelowania matematycznego, ponieważ nie wszystkie procesy w niej zachodzące są dokładnie poznane. Dotyczy to procesów związanych ze wzrostem i obumieraniem bakterii oraz z ich aktywnością biologiczną i chemiczną. Na ogół uważa się na przykład, że bakterie nieaktywne biologicznie, czyli niezdolne do podziału komórkowego, są również nieaktywne chemicznie, czyli niezdolne do dokonywania przemian chemicznych związków zawartych w ściekach. Jednak zdarza się, że bakterie uważane za martwe są w dalszym ciągu aktywne chemicznie [Stephenson, 1928; Wooldrige i Standfast, 1936]. Ponadto niezbyt dokładnie są w szczególności poznane procesy związane z redukcją związków fosforowych, uwzględniane w modelach klasy ASM2 [Cywiński i in., 1983; Bernacka i in., 1992; Dymaczewski i Sozański, 1995].

Niepełna znajomość procesów utrudnia sterowanie oczyszczalnią. Oczyszczalnia traktowana jako obiekt sterowania charakteryzuje się następującymi własnościami [Katebi i in., 1999]:

- procesy mechaniczne i biologiczne zachodzące w oczyszczalni są zwykle w stanie nieustalonym ze względu na zmieniające się natężenie dopływu ścieków a także na zmieniający się ładunek zanieczyszczeń;
- zmienne natężenie dopływu ścieków powoduje zmianę obciążenia hydraulicznego zbiorników oczyszczalni i w konsekwencji zmianę stałych czasowych tych obiektów: przy wielkich dopływach stałe czasowe się zmniejszają a przy małych dopływach zwiększają;
- różne procesy zachodzące w oczyszczalni mają bardzo zróżnicowane skale czasowe, z czasem mierzonym w minutach, dniach, tygodniach i miesiącach: w procesie napowietrzania ścieków w komorach z osadem czynnym tlen w formie gazowej znajdujący się w powietrzu wprowadzanym do ścieków przechodzi w formę tlenu rozpuszczonego w ciągu kilkunastu minut; proces amonifikacji w ściekach trwa około 5 dni, proces nityfikacji około 7 dni; przeciętny wiek bakterii wynosi kilka tygodni; przy zmianie temperatury ścieków na skutek zmiany warunków zewnętrznych zmienia się również aktywność biologiczna i chemiczna bakterii i te procesy trwają kilka miesięcy;
- większość procesów zachodzących w oczyszczalni ma charakter nieliniowy: na przykład szybkość wzrostu bakterii jest opisana funkcją rosnącą asymptotycznie Monoda a szybkość sedimentacji osadu czynnego jest opisana funkcjami wykładniczymi Veselinda i Tacacsa [Monod, 1949; Veselind, 1968; Takacs i in., 1991].



Rys. 7.1. Schemat oczyszczalni z osadem czynnym
(1, 2, 3, 4 – punkty pomiarowe stężeń zanieczyszczeń)

W oczyszczalni steruje się następującymi parametrami (rys. 7.1):

- ilość ścieków surowych doprowadzana do oczyszczalni,
- ilość powietrza wprowadzanego do komór z osadem czynnym,
- wartości stężeń tlenu rozpuszczonego w komorach z osadem czynnym, w których odbywa się nitryfikacji pierwszego i drugiego stopnia,
- ilość ścieków zawracanych pomiędzy komorami z osadem czynnym,
- ilość osadu czynnego zawracanego z osadników wtórnych,
- ilość osadu nadmiernego odprowadzanego do komór fermentacyjnych.

Ponadto, jeżeli w oczyszczalni stosuje się także oczyszczanie chemiczne za pomocą dodatkowych substancji wprowadzanych do ścieków, uzyskuje się następujące parametry sterowania:

- ilości wprowadzanych substancji chemicznych

- punkty w ciągu technologicznym, w których te substancje są wprowadzane.

Do właściwego sterowania oczyszczalnią należy mieć bieżące pomiary następujących podstawowych parametrów:

- przepływy ścieków surowych, oczyszczonych i zawracanych,
- przepływy osadów surowego, nadmiernego i zawracanego,
- poziomy osadu w osadnikach wstępnych i wtórnych,
- przepływ powietrza tłoczonego do komór nityfikacji,
- stężenia ChZT i BZT₅, amoniaku, azotynów i azotanów oraz fosforu w zbiornikach oczyszczalni,
- stężenie tlenu rozpuszczonego w komorach nityfikacji.

Praktycznie wszystkie sterowania wiążą się z pracą pomp, które są bardzo energochłonne. Jednocześnie podstawowy cel oczyszczania, to redukcja zanieczyszczeń w ściekach do zadanych poziomów, ustalanych indywidualnie dla każdej oczyszczalni. Dlatego przy sterowaniu oczyszczalnią ma się do czynienia z dwoma podstawowymi zadaniami optymalizacji [Kayse, 1990; Katebi i in., 1999]:

- minimalizacja zużywanej energii elektrycznej,
- minimalizacja odchyień zawartości zanieczyszczeń w ściekach oczyszczonych od zadanych wartości.


Poprawna realizacja tych zadań wymaga posiadania odpowiednich modeli matematycznych procesów zachodzących w oczyszczalni, czyli takich, które są dobrym opisem procesów i jednocześnie są dogodne do wykonywania obliczeń optymalizacyjnych związanych z minimalizacją zadanych kryteriów jakości.

Jednym z podstawowych zagadnień w oczyszczalni jest właściwe sterowanie dopływem powietrza do komór napowietrzania, aby zapewnić prawidłowy przebieg procesów utleniania związków azotowych. W tym celu można sformułować model matematyczny zawartości tlenu w komorach nityfikacji. Dokładny model opisujący zmiany stężenia tlenu rozpuszczonego w ściekach jest w postaci liniowego równania różniczkowego cząstkowego [Flanagan i in., 1977; Rundqwist, 1986; Nahorski, 1996]

$$\frac{\partial c_O(x,t)}{\partial t} = D \frac{\partial^2 c_O(x,t)}{\partial x^2} - v \frac{\partial c_O(x,t)}{\partial x} + k(u)(c_{Om} - c_O(x,t)) - R(x,t) \quad (7.1)$$

gdzie: c_O – stężenie tlenu rozpuszczonego, D – współczynnik dyfuzji tlenu w ściekach, v – szybkość przepływu ścieków przez komorę, $u = u(t)$ – natężenie

dopływu powietrza doprowadzanego do ścieków, $k(u)$ – funkcja szybkości rozpuszczania się tlenu gazowego w ściekach, c_{O_m} – maksymalne możliwe stężenie tlenu w ściekach, $R(x,t)$ – szybkość poboru tlenu rozpuszczonego ze ścieków w rezultacie zachodzących w nich reakcji biologicznych i chemicznych.



Rys. 7.2. Funkcja $k(u)$

Równanie (7.1) opisuje zmiany stężenia tlenu w ściekach spowodowane: dyfuzją, przepływem ścieków przez komorę, rozpuszczaniem się w cieczy tlenu doprowadzanego do ścieków w postaci gazowej poprzez ich napowietrzanie, oraz pobieraniem tlenu przez bakterie uczestniczące w przemianach biochemicznych. Zmienny współczynnik $k(u)$ jest funkcją nieliniową typu wykładniczego (rys. 7.2).

Równanie (7.1) można aproksymować równaniem różniczkowym zwyczajnym przyjmując, że modelowana komora składa się z kilku szeregowo połączonych zbiorników, w których zachodzi proces idealnego mieszania ścieków. W ten sposób proces dyfuzji zastępuje się mieszaniem, natomiast przestrzenny opis przepływu ścieków wzdłuż komory przybliża się szeregiem zbiorników punktowych, w którym wyjście jednego zbiornika jest wejściem następnego. Wtedy równanie (7.1) przyjmuje postać

$$\frac{dc_O(t)}{dt} = \frac{Q(t)}{V} (c_{O_{we}}(t) - c_O(t)) + k(u)(c_{O_m} - c_O(t)) - R(t) \quad (7.2)$$

gdzie: $Q(t)$ – natężenie dopływu ścieków do kolejnego zbiornika, V – objętość tego zbiornika, $c_{O_{we}}(t)$ – stężenie tlenu w dopływie ścieków.

Rozwiązanie tego równania wymaga wykonywania na bieżąco pomiarów $c_{Owe}(t)$, $Q(t)$ i $u(t)$ a także znajomości funkcji $k(u)$ i $R(t)$. Funkcję $k(u)$ można aproksymować funkcją wykładniczą, natomiast $R(t)$ zależy od szybkości rozwoju bakterii heterotroficznych powodujących rozkład związków organicznych i azotowych w komorach nityfikacji. Procesy te są następujące: rozkład związków organicznych do postaci związków amonowych z jonami NH_4^+ przy udziale bakterii heterotroficznych amonifikacyjnych; rozkład związków amonowych do postaci azotynów z jonami NO_2^- przy udziale bakterii heterotroficznych typu *Nitrosomonas*; oraz rozkład azotynów do postaci azotanów z jonami NO_3^- przy udziale bakterii heterotroficznych typu *Nitrobacter*.

Tlen jest pobierany przez bakterie heterotroficzne trzech rodzajów i szybkości ich wzrostu są składnikami funkcji $R(t)$. Przy czym szybkość wzrostu bakterii opisuje się nieliniową funkcją Monoda a jeżeli szybkość ta zależy od kilku czynników, to wtedy jej opis jest iloczynem kilku funkcji Monoda określonych dla każdego czynnika niezależnie.

Kolejne składniki funkcji $R(t)$ są więc następujące [Łomotowski, 1997a; Szetela, 1997]:

- szybkość wzrostu bakterii heterotroficznych amonifikacyjnych

$$\mu_{H1}(c_s, c_O) = \mu_{H1max} \frac{c_s(t)}{K_s + c_s(t)} \frac{c_O(t)}{K_{OH1} + c_O(t)} \quad (7.3)$$

gdzie $c_s(t)$ jest stężeniem w ściekach związków organicznych rozkładanych przez bakterie i stanowiących substrat;

- szybkość wzrostu bakterii heterotroficznych *Nitrosomonas*

$$\mu_{H2}(c_{NH}, c_O) = \mu_{H2max} \frac{c_{NH}(t)}{K_{NH} + c_{NH}(t)} \frac{c_O(t)}{K_{OH2} + c_O(t)} \quad (7.4)$$

gdzie $c_{NH}(t)$ jest stężeniem w ściekach związków amonowych;

- szybkość wzrostu bakterii heterotroficznych *Nitrobacter*

$$\mu_{H3}(c_{NO_2}, c_O) = \mu_{H3max} \frac{c_{NO_2}(t)}{K_{NO_2} + c_{NO_2}(t)} \frac{c_O(t)}{K_{OH3} + c_O(t)} \quad (7.5)$$

gdzie $c_{NO_2}(t)$ jest stężeniem azotynów.

Na podstawie równań (7.3) – (7.5) otrzymuje się następujące wyrażenie dla funkcji $R(t)$

$$R(t) = \mu_{H1}(c_s, c_O)c_{H1}(t) + \mu_{H2}(c_{NH}, c_O)c_{H2}(t) + \mu_{H3}(c_{NO_2}, c_O)c_{H3}(t) \quad (7.6)$$

gdzie c_{H1}, c_{H2}, c_{H3} oznaczają stężenia wymienionych kolejnych rodzajów bakterii w ściekach.

Tak określona funkcja $R(t)$ wprowadza do równania (7.2) sześć nowych zmiennych: $c_s(t), c_{NH}(t), c_{NO_2}(t), c_{H1}(t), c_{H2}(t), c_{H3}(t)$, dla których można sformułować dodatkowe równania bilansowe. Są one następujące:

- zmiana stężenia w ściekach bakterii heterotroficznych amonifikacyjnych

$$\frac{dc_{H1}(t)}{dt} = \frac{Q(t)}{V}(c_{H1in}(t) - c_{H1}(t)) + \mu_{H1max} \frac{c_s(t)}{K_s + c_s(t)} \frac{c_O(t)}{K_{OH1} + c_O(t)} c_{H1}(t) \quad (7.7)$$

- zmiana stężenia bakterii heterotroficznych *Nicrosomonas*

$$\frac{dc_{H2}(t)}{dt} = \frac{Q(t)}{V}(c_{H2in}(t) - c_{H2}(t)) + \mu_{H2max} \frac{c_{NH}(t)}{K_{NH} + c_{NH}(t)} \frac{c_O(t)}{K_{OH2} + c_O(t)} c_{H2}(t) \quad (7.8)$$

- zmiana stężenia bakterii heterotroficznych *Nitrobacter*

$$\frac{dc_{H3}(t)}{dt} = \frac{Q(t)}{V}(c_{H3in}(t) - c_{H3}(t)) + \mu_{H3max} \frac{c_{NO_2}(t)}{K_{NO_2} + c_{NO_2}(t)} \frac{c_O(t)}{K_{OH3} + c_O(t)} c_{H3}(t) \quad (7.9)$$

– zmiana stężenia związków organicznych

$$\frac{dc_s(t)}{dt} = \frac{Q(t)}{V} (c_{sin}(t) - c_s(t)) - \mu_{H1max} \frac{c_s(t)}{K_s + c_s(t)} \frac{c_O(t)}{K_{OH1} + c_O(t)} c_s(t) \quad (7.10)$$

– zmiana stężenia związków amonowych

$$\frac{dc_{NH}(t)}{dt} = \frac{Q(t)}{V} (c_{NHin}(t) - c_{NH}(t)) + \mu_{H2max} \frac{c_s(t)}{K_s + c_s(t)} \frac{c_O(t)}{K_{OH2} + c_O(t)} c_{NH}(t) \quad (7.11)$$

– zmiana stężenia azotynów

$$\frac{dc_{NO_2}(t)}{dt} = \frac{Q(t)}{V} (c_{NO_2in}(t) - c_{NO_2}(t)) + \mu_{H3max} \frac{c_{NH}(t)}{K_{NH} + c_{NH}(t)} \frac{c_O(t)}{K_{OH3} + c_O(t)} c_{NO_2}(t) \quad (7.12)$$

W ten sposób otrzymuje się ostatecznie układ siedmiu równań (7.2), (7.7) – (7.12), z których można obliczyć stężenia podstawowych frakcji ścieków uczestniczących w procesach nityfikacji. Równania te można rozwiązać numerycznie stosując na przykład klasyczne ilorazy różnicowe do aproksymacji pochodnych pierwszego rzędu. Na podstawie znanych wartości funkcji $c_s, c_{NH}, c_{NO_2}, c_{H1}, c_{H2}, c_{H3}$ i c_O w chwili t można wówczas wyznaczyć prognozowaną wartość stężenia tlenu rozpuszczonego c_O w chwili $(t+1)$. Można także sformułować zadanie takiego doboru wartości natężenia napowietrzania ścieków u w równaniu (7.2), aby uzyskać zadaną wartość stężenia tlenu c_O .

Jednak zadania wyznaczania takiego sterowania na podstawie modeli matematycznych procesów nie są w praktyce rozwiązywane, ponieważ nie ma odpowiednio dokładnych modeli wyznaczonych dla rzeczywistych procesów i użytecznych dla celów optymalizacji. W oczyszczalniach stosuje się albo algorytmy stabilizacji określonych parametrów procesu na zadanych poziomach przy użyciu sterowników programowalnych, pełniących funkcje regulatorów, albo stosuje się sterowanie ręczne w przypadku, gdy zadane wartości parametrów należy zmienić. Na ogół stabilizuje się poziom tlenu w komorach nityfikacji oraz stopnie recyrkulacji wewnętrznej ścieków i zewnętrznej osadu czynnego. Przy sterowaniu ręcznym jest niezbędna ingerencja operatora procesu, którym jest zwykle technolog oczyszczalni. Następuje ona w przypadkach, gdy wyniki wykonywanych rutynowo pomiarów podstawowych parametrów procesu odbiegają od normy.

Na przykład, dokonując pomiarów w punktach 1, 2, 3 i 4 zaznaczonych na rys. 7.1, powinno się stwierdzić niskie stężenie fosforanów w punkcie 1, niskie stężenie azotanów w punkcie 2, niskie stężenie amoniaku w punkcie 3 i niskie stężenie azotynów w punkcie 4. Jeżeli w punkcie 2 stężenie azotanów jest wysokie, to zwykle zmniejsza się stopień recyrkulacji osadu czynnego. Z kolei, jeżeli stężenie amoniaku jest wysokie w punkcie 3 lub tym bardziej w punkcie 4, to zwiększa się stopień recyrkulacji osadu względnie zmniejsza się ilość doprowadzanego do komór ładunku zanieczyszczeń, kierując część ścieków surowych do zbiornika buforowego [Skaskiewicz, 1996].

Takie sterowanie ręczne wymaga znacznego doświadczenia, które jest trudno przekazywalne. Dlatego podejmuje się próby wspomagania sterowania ręcznego systemami eksperckimi, które generują określone reguły postępowania, tak zwane *reguły decyzyjne*, podpowiadające operatorowi procesu, jakie działania powinien podjąć w sytuacjach odbiegających od normy. Takie systemy mają jednak dotychczas charakter doświadczalny i nie są stosowane w skali technicznej [Kayser, 1990; Watanabe i in., 1993; Carrasco, 2002].

7.2. Wyznaczanie modeli neuronowych


Modele fizykalne oczyszczalni ścieków, takie jak model opisany w rozdziale 7, są obecnie rozwijane przede wszystkim jako narzędzia lepszego poznania modelowanych procesów. Ich struktura jest coraz bardziej komplikowana, uwzględniając coraz większą złożoność technologii biologicznego oczyszczania ścieków stosowanych we współczesnych oczyszczalniach. Jednocześnie jednak tworzenie coraz bardziej złożonych modeli powoduje, że bardzo wydłużają się ich czasy obliczeń i coraz trudniejsze staje się ich użycie do opisu procesów zachodzących w rzeczywistej oczyszczalni. Jest to sytuacja dosyć paradoksalna, bo im model staje się dokładniejszy i bardziej uniwersalny, tym staje się mniej użyteczny w praktyce. Takie modele są wówczas doskonałym narzędziem badawczym i dydaktycznym, ale jednocześnie przestają spełniać funkcję, dla realizacji której w ogóle wyznacza się modele matematyczne procesów. Tą funkcją jest zastosowanie modeli do optymalizacji i sterowania procesami. Modele fizykalne oczyszczalni ścieków, z powodu swojej złożoności, nie nadają się do przeprowadzenia ich identyfikacji, zastępowanej wówczas żmudnym procesem kalibracji [Carstensen, 1994], a więc nie nadają się również do wykonywania innych obliczeń optymalizacyjnych.

Stąd powstaje potrzeba opracowywania również innych modeli oczyszczalni, które będą prostsze w opisie i przede wszystkim szybsze w obliczeniach. W tym rozdziale opisano wyznaczanie modeli opisanych sieciami neuronowymi, nazywanych *modelami neuronowymi*. Ich główną wadą jest brak interpretowalności

fizycznej parametrów, które mają charakter współczynników wagowych w równaniach. To powoduje, że trudniejsza jest interpretacja wyników obliczeniowych i określenie wpływu określonych parametrów na dokładność wyników, tak jak to było możliwe w przypadku modelu fizycznego. Jednak podstawową zaletą takich modeli jest ich przejrzysta i prosta struktura oraz wielka szybkość obliczeniowa, umożliwiającą wykonywanie wielu przebiegów symulacyjnych w stosunkowo krótkim czasie. Dlatego takie modele, jeżeli są jednocześnie dostatecznie dokładne, mogą być używane do optymalizacji i sterowania procesem. Uwzględniając ich przeznaczenie, modele tego typu nazwiemy w dalszym ciągu *modelami operacyjnymi*.

- **Sieci neuronowe**


Modele matematyczne przedstawiane w obecnym rozdziale są opisywane za pomocą sieci neuronowych. Sieci neuronowe traktowano początkowo jako poprawny opis struktury i funkcjonowania mózgu, zbudowanego z neuronów i połączeń między nimi [Haykin, 1994; Żurada, 1992]. Potem okazało się, że jednak działanie mózgu jest zbyt złożone, aby dało się poprawnie opisać stosunkowo prostą strukturą sieci neuronowej, natomiast modele neuronowe okazały się użyteczne w innych zastosowaniach, głównie przy odtwarzaniu brakujących informacji. Dlatego zaczęły być stosowane z powodzeniem do rozpoznawania obrazów czy do interpolacji niekompletnych ciągów pomiarowych w badaniach meteorologicznych [Widman i in., 1898; Hsu i in., 1997; Licznar i in., 2001; Gutenbaum, 2003]. Burzliwy rozwój zastosowań sieci neuronowych nastąpił szczególnie w latach 1990-ych i jest związany z równie gwałtownym rozwojem technologii komputerowych i zdolności obliczeniowych komputerów.



Rys. 7.3. Neuron z R wejściami i liniową funkcją przejścia: $y = f(x) = a_1u_1 + \dots + a_Ru_R + b$

Sieć neuronowa jest zbudowana z elementów zwanych neuronami. Pojedynczy *neuron* może być traktowany jak obiekt statyczny z jednym lub wieloma

wejściami, jednym wyjściem i liniową lub nieliniową funkcją przejścia zwaną *funkcją aktywacji* (rys. 7.3) [Hagen i in., 1996; Wojtyła, 2003]. W zależności od rodzaju funkcji przejścia są liniowe i nieliniowe sieci neuronowe. Kolejny element sieci, to *warstwa*. Neurony znajdujące się na jednej warstwie nie są ze sobą połączone, natomiast istnieją połączenia między neuronami położonymi na dwóch bezpośrednio ze sobą sąsiadujących warstwach. Połączenia między neuronami mogą być tego rodzaju, że każdy neuron jednej warstwy jest połączony z każdym neuronem warstwy sąsiedniej, lub neurony na jednej warstwie są połączone jedynie z wybranymi neuronami warstwy sąsiedniej (rys. 7.4).



Rys. 7.4. Przykład sieci neuronowej typu *feedforward* z 3 warstwami, 5 wejściami i 2 wyjściami

Formalizując powyższy opis można powiedzieć, że sieć neuronowa składa się z neuronów, z których każdy składa się z kolei z sumatora sygnałów wejściowych u , o współczynnikach wagowych a i sygnale wyjściowym x , oraz z liniowej lub nieliniowej funkcji przejścia $y = f(x)$, przy czym:

$$\begin{aligned} u &= (1, u_1, u_2, \dots, u_R) \\ a &= (b, a_1, a_2, \dots, a_R) \\ x &= b + a_1 u_1 + a_2 u_2 + \dots + a_R u_R \end{aligned} \tag{7.13}$$

Najczęściej stosowanymi nieliniowymi funkcjami przejścia są funkcje nieciągłe w postaci skoku jednostkowego unipolarnego lub bipolarnego, względnie ciągłe odpowiedniki tych funkcji nieciągłych w postaci funkcji logistycznej lub tangensa hiperbolicznego [Gutenbaum, 2003].

Przepływ sygnałów między warstwami może być jednokierunkowy z warstwy jednej do warstwy kolejnej. Powstaje wtedy tak zwana *sieć jednokierunkowa* (*feedforward network*), która ma charakter obiektu statycznego. Jednak są również stosowane sieci, w których istnieją połączenia zwrotne z warstwy kolejnej do poprzedniej lub do warstw wcześniejszych. Wówczas powstaje *sieć rekurencyjna*, która ma charakter obiektu dynamicznego (*recurrent network*). Każda sieć składa się z *warstwy wejściowej*, do której dochodzą sygnały zewnętrzne, z *warstwy wyjściowej*, z której wychodzą sygnały na zewnątrz sieci, oraz z *warstw wewnętrznych*, zwanych także *warstwami ukrytymi*, których neurony nie mają bezpośredniego połączenia z wejściowymi i wyjściowymi sygnałami sieci.

Rozpisanie równań dla wszystkich neuronów sieci daje w rezultacie układ liniowych lub nieliniowych równań algebraicznych. Wyznaczenie modelu neuronowego oznacza obliczenie współczynników wagowych a_i , b dla każdego neuronu sieci w ten sposób, aby sygnały wyjściowe sieci, stanowiącej tworzony model matematyczny badanego obiektu, dopasować do danych pomiarowych będących sygnałami wyjściowymi obiektu.

Jest to klasyczne zadanie optymalizacji statycznej, w którym stosuje się zwykle kwadratową funkcję celu w postaci sumy kwadratów błędów między wyjściami modelu i wyjściami obiektu. Do jego rozwiązania można bezpośrednio zastosować metody najmniejszej sumy kwadratów używane do identyfikacji obiektów wielowymiarowych. W przypadku sieci neuronowych opracowano również specjalne metody obliczeniowe oparte na heurystycznych algorytmach genetycznych [Davidor, 1991; Goldberg, 1998].

Minimalizacji funkcji celu dokonuje się za pomocą gradientowych lub bezgradientowych metod optymalizacji [Tadeusiewicz, 1993; Hagen i in., 1996]. Wyznaczając model sieci neuronowej dzieli się zwykle posiadane ciągi pomiarów na dwie grupy, zawierające podciągi przeznaczone do trenowania względnie uczenia i do testowania sieci. Minimalizację funkcji celu prowadzi się przy użyciu danych z grupy pierwszej, rejestrując jednocześnie wartość sumy resztowej otrzymanej jako wynik symulacji kolejnych wariantów modelu dla danych z grupy drugiej. Stosowane w obliczeniach kryteria w procedurach stopu mogą korzystać z sum resztowych obliczonych dla pierwszej, drugiej lub dla obu grup pomiarów [Licznar i in., 2001].

Liniowe sieci jednokierunkowe ze średniokwadratową funkcją celu, użyte dla celów identyfikacji, są bardzo dogodne pod względem obliczeniowym, ponieważ funkcja celu jest wówczas unimodalna i stosowane algorytmy optymalizacji są zbieżne. Problemy obliczeniowe powstają w przypadku sieci nieliniowych i rekurencyjnych i wówczas na ogół stosuje się dodatkowe algorytmy do

minimalizacji liczby warstw ukrytych sieci oraz liczby rozmieszczonych na tych warstwach neuronów.

- **Modele prognostyczne**

Problemy ze sterowaniem procesem technologicznym w oczyszczalni ścieków są spowodowane głównie szybkimi i niespodziewanymi zmianami natężenia dopływu ścieków surowych i zmianami dopływających ładunków zanieczyszczeń. Dlatego istotne znaczenie dla sterowaniu obiektem ma wyznaczenie poprawnych modeli prognozujących dopływ ścieków i dopływ ładunków zanieczyszczeń. Aby takie modele mogły być użyteczne w praktyce, muszą się one charakteryzować stosunkowo prostym opisem i wielką szybkością obliczeń, czego nie zapewniają złożone modele fizykalne. Dlatego użyto do tego celu sieci neuronowych a dla porównania także klasycznych równań różnicowych [Bhat i McAvoy, 1990; Ayesa i in., 1991]. W badaniach korzystano z rzeczywistych danych pomiarowych uzyskanych z oczyszczalni ścieków w Rzeszowie [Studziński i in., 1999b].

W modelu różnicowym typu ARMA (*autoregressive moving average*) każdy bieżący pomiar chwilowy jest traktowany jak funkcja pewnej liczby poprzednich pomiarów z dodanym zakłóceniem oznaczającym błąd pomiaru. Liczba uwzględnionych poprzednich pomiarów oznacza rząd modelu. Opis modelu jest postaci

$$y_n = a_1 y_{n-1} + a_2 y_{n-2} + \dots + a_R y_{n-R} + v_n \quad (7.14)$$


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 obliczeniu wartości parametrów.

Do obliczeń identyfikacji modelu różnicowego zastosowano metodę najmniejszej uogólnionej sumy kwadratów Clarke'a, stosując standardowe wskaźniki statystyczne do wyznaczenia optymalnego rzędu modelu i oceny estymatorów parametrów. W obliczeniach korzystano z programów biblioteki IDOL, podobnie jak w przypadku wyznaczania modeli przepływowych oczyszczalni [Nahorski i Studziński, 1988].


Najlepsze wyniki modelowania otrzymano dla równania różnicowego 5 rzędu o następujących parametrach: $a_1 = -0,7339$, $a_2 = -0,0609$, $a_3 = -0,1751$, $a_4 = 0,7339$, $a_5 = 0,1797$ (rys. 7.5 i 7.6). Obliczenia przeprowadzono dla pomiarów dopływu ścieków wykonanych w oczyszczalni w ciągu dwóch kolejnych miesięcy. Pomiaru były wykonywane automatycznie co 2 min i przed modelowaniem uśredniono je dla okresów jednogodzinnych. Pomiaru z jednego miesiąca były

używane do wyznaczenia modelu, zaś pomiary z drugiego miesiąca do jego weryfikacji. Czas prognozowania dopływu wynosi 1 godz. Dane do obliczeń zostały przeskalowane i sprowadzone do przedziału $<-1, 1>$, z wartością średnią 0 i wariancją 1. Po zakończeniu obliczeń przeskalowano wyniki ponownie dla otrzymania rzeczywistych wartości przepływów.

Drugi sposób modelowania dopływu polega na zastosowaniu sieci neuronowych. Zastosowano sieć typu BP (*back propagation feedforward network*), składającą się z 3 warstw: wejściowej, ukrytej i wyjściowej, oraz mającej liniowe funkcje przejścia [Studzinski i in., 1999c]. Wyznaczono dwa modele 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 na warstwie wejściowej, 7 neuronów na warstwie ukrytej i 1 neuron na warstwie wyjściowej, natomiast model NNBP (*neural netback propagation model*) na identycznych 3 warstwach ma odpowiednio 5, 6 i 1 neuron.



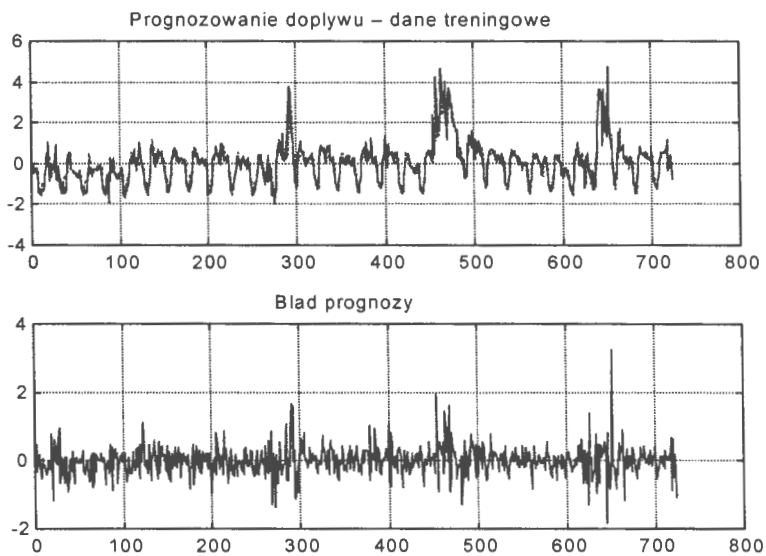
Rys. 7.5. Wyniki modelowania dla modelu autoregresji 5 rzędu (wykres górny) oraz dla modeli neuronowych NNAR i NNBP – dane treningowe (wykresy środkowy i dolny; linia przerywana oznacza pomiary)




Rys. 7.6. Wyniki modelowania dla modelu autoregresji 5 rzędu (wykres górny) oraz dla modeli neuronowych NNAR i NNBP – dane testujące (wykresy środkowy i dolny; linia przerywana oznacza pomiary)

Przed przystąpieniem do obliczeń dokonano skalowania danych pomiarowych, przy czym dane dla modelu NNAR sprowadzono do przedziału $\langle -1, 1 \rangle$ z wartością średnią 0 i wariancją 1, podobnie jak w przypadku modelu różnicowego ARMA, natomiast dane dla modelu NNBP sprowadzono do przedziału $\langle 0, 1 \rangle$.


Obliczenia modelowania wykonano przy użyciu pakietu obliczeniowego MATLAB [Demuth i Beale, 2000]. Przy wyznaczeniu modelu NNAR zastosowano algorytm badania istotności połączeń między neuronami i usuwania połączeń nieistotnych (*pruning*). Danych pomiarowych przy tworzeniu modeli i prognozowaniu, czyli w fazie uczenia i fazie testowania sieci neuronowej, używano w identyczny sposób, jak w modelu różnicowym, to znaczy w przesuwającym się oknie pomiarowym o długości 6 pomiarów, 5 pierwszych pomiarów oznaczało zawsze wejścia modelu a szósty pomiar oznaczał wyjście modelu.




Rys. 7.7. Błąd prognozowania dla modelu neuronowego NNAR; dane treningowe



Rys. 7.8. Funkcja autokorelacji dla błędu prognozowania modelu NNAR; dane treningowe




Rys. 7.9. Błąd prognozowania dla modelu neuronowego NNAR; dane testujące



Rys. 7.10. Funkcja autokorelacji dla błędu prognozowania modelu NNAR; dane testujące

Ocena otrzymanych wyników jest pozytywna, ponieważ modele, tak różnicowy jak i neuronowe, wyznaczają poprawne prognozy dopływu ścieków do oczyszczalni. Na rys. 7.7 i 7.10 pokazano, że błąd prognozowania – na przykładzie modelu NNAR – ma charakter białego szumu. Obliczenia wskazują również, że sieci neuronowe jako modele prognostyczne są konkurencyjne w stosunku do klasycznych równań różnicowych.

Celem tworzenia tych modeli jest prognozowanie obciążenia hydraulicznego zbiorników oczyszczalni dla potrzeb sterowania. Modele te mogą również służyć do prognozowania dopływu ładunków zanieczyszczeń do oczyszczalni, ponieważ przebiegi dopływu ścieków i przebiegi dopływających ładunków zanieczyszczeń wykazują znaczne podobieństwa [Łomotowski, 1998a; Szetela, 1998]. Na rys. 7.11 pokazano przykładowe dobowe przebiegi dopływu ścieków i ładunku związków organicznych dla oczyszczalni w Rzeszowie.



Rys. 7.11. Wykresy zmienności dopływu ścieków surowych (*cienka linia ciągła*) i zawartego w nich ładunku związków organicznych (*gruba linia ciągła*)

- **Modele symulacyjne procesu technologicznego**

Sieci neuronowe mogą służyć również do modelowania całego ciągu technologicznego w oczyszczalni ścieków i prognozowania stanu procesu na wyjściu obiektu [Arnold i in., 2002]. W ten sposób stosunkowo prosty model neuronowy może być użyty do badań symulacyjnych procesu zamiast złożonego modelu fizycznego. Również ta hipoteza została przetestowana numerycznie za pomocą obliczeń symulacyjnych wykonanych na podstawie rzeczywistych danych pomiarowych.

Dla wyznaczenia modeli neuronowych obiektu testowego posłużono się pomiarami wykonywanymi rutynowo w oczyszczalni w Rzeszowie. Są to pomiary laboratoryjne podstawowych parametrów procesu zbierane w czterech punktach oczyszczalni jednorazowo w ciągu każdej zmiany, czyli trzy razy dziennie. Punkty pomiarowe są zlokalizowane w dopływie ścieków surowych, w komorach

napowietrzania, w odpływie ścieków oczyszczonych i w przepływie osadu zawracanego z osadników wtórnych do komór napowietrzania.

Mierzone parametry są następujące:

w ściekach surowych:

- stężenie BZT_{5-ss},
- stężenie ChZT_{ss},
- stężenie azotu ogólnego N_{og-ss} ,
- stężenie azotu amonowego s_{NH-ss} ,
- stężenie zawiesiny ogólnej x_{og-ss} ,
- natężenie dopływu ścieków Q_{we} ;

w komorach napowietrzania:

- stężenie tlenu rozpuszczonego s_O ,
- stężenie zawiesiny osadu czynnego x_{og-kn} ,
- opadalność osadu v_{os} ;

w ściekach oczyszczonych:

- stężenie BZT_{5-so},
- stężenie ChZT_{so},
- stężenie azotu ogólnego N_{og-so} ,
- stężenie azotu amonowego s_{NH-so} ,
- stężenie zawiesiny ogólnej x_{og-so} ;

w osadzie zawracanym:

- stężenie zawiesiny osadu czynnego x_{og-r} ,
- natężenie przepływu osadu zawracanego Q_r .

Biorąc pod uwagę nieliniowości modelowanego procesu technologicznego, wybrano do badań symulacyjnych nieliniowe sieci neuronowe. Są to sieci typu BP, podobnie jak w przypadku modeli dopływu ścieków, złożone z trzech warstw: wejściowej, ukrytej i wyjściowej, z nieliniowymi funkcjami przejścia na warstwie pierwszej i drugiej oraz z liniowymi funkcjami przejścia na warstwie trzeciej.

Funkcje nieliniowe są funkcjami logistycznymi postaci

$$y_i = \frac{1}{1 + \exp(-a_{ij}u_{ij} - b_i)} \quad (7.15)$$

gdzie y_i jest wyjściem neuronu i , natomiast u_{ij} jest wejściem j neuronu i .

Przeprowadzono badania symulacyjne różnych modeli, badając wpływ wygładzania pomiarów, zmiany zadanej liczby neuronów na wszystkich warstwach sieci oraz zmiany kroku prognozowania na wyniki modelowania [Studziński i in., 1999b]. Do wygładzania pomiarów użyto metody falek (*wavelets*) [Buckheit i Donoho, 1995; Daubechies, 1992]. Do optymalizacji funkcji celu zastosowano metodę Gaussa-Newtona w wersji Levenberga-Marquardta [Hagen i in., 1996]. Jest to metoda szczególnie niezawodna w przypadku sieci nieliniowych, kiedy stosowanie metod gradientowych prowadzi często do niestabilnych procesów zbiegania algorytmu obliczeniowego do rozwiązania.

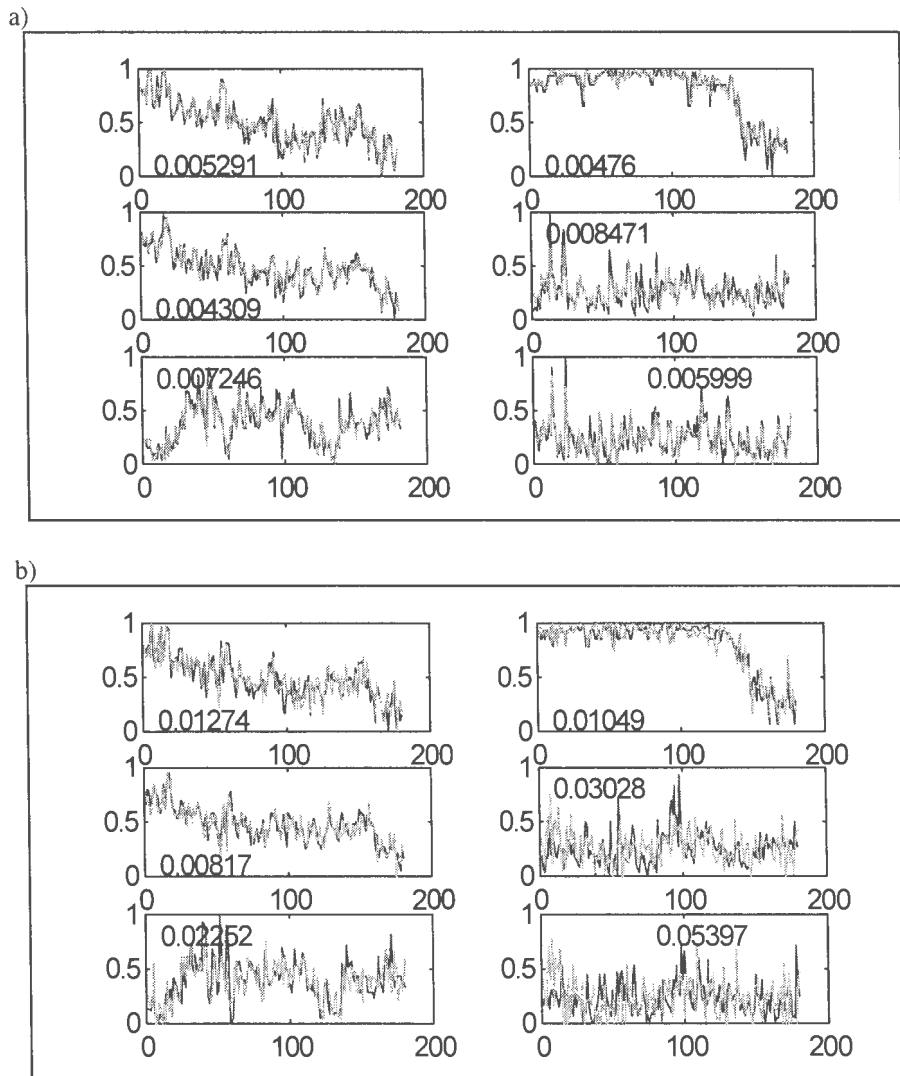
Jako wejścia modeli przyjmowano zawsze wejścia procesu, czyli parametry ścieków surowych, w chwili t , natomiast jako wyjścia modeli przyjmowano wyjścia procesu, czyli parametry ścieków oczyszczonych, w chwili $t+T$, gdzie T jest założonym krokiem prognozowania. Badano również przyjmowanie innych parametrów procesu jako dodatkowych wejść lub wyjść modeli. Obliczeniową jednostką czasu jest 8 godz, czyli okres jednej zmiany.

Ocenę modeli prowadzono na podstawie ich sumy resztowej, przy czym sumę resztową obliczano jako średnią arytmetyczną sum resztowych wyznaczonych dla każdego wyjścia modelu. Najlepsze modele otrzymano dla sieci neuronowych o następującej strukturze: 12 neuronów na warstwie wejściowej, 6 neuronów na warstwie ukrytej i 6 neuronów na warstwie wyjściowej, z parametrami procesu BZT_{5-ss} , s_{NH-ss} , x_{og-ss} , Q_{we} , s_O , x_{og-kn} , v_{os} , BZT_{5-so} , s_{NH-so} , x_{og-so} , x_{og-r} , Q_r w chwili t jako wejściami modelu, i parametrami x_{og-kn} , v_{os} , BZT_{5-so} , s_{NH-so} , x_{og-so} , x_{og-r} w chwili $t+T$ jako wyjściami modelu (modele NNBP(6)).

Przykładowe wyniki otrzymane dla modeli NNBP(6), liczonych przy użyciu pomiarów zakłóconych i wygładzonych, pokazano na rys. 7.12 i 7.13. Poszczególne wykresy na rysunkach oznaczają (*od lewej do prawej i od góry do dołu*): x_{og-kn} , v_{os} , x_{og-r} , BZT_{5-so} , s_{NH-so} , x_{og-so} . Na wykresach są umieszczone sumy resztowe obliczone dla wyjść modelu.


Wyniki obliczeń są wyraźnie lepsze dla danych wygładzonych. Od wyników otrzymanych dla danych zakłóconych różnią się one o rząd wielkości w wartościach sum resztowych dla etapu testowania modeli (tabl. 7.1). Najlepsze wyniki prognozowania stanu procesu uzyskano dla $T = 8$ godz. Najlepszą liczbę neuronów

na warstwie ukrytej sieci oraz najlepszy krok prognozowania ustalono za pomocą obliczeń symulacyjnych. (rys. 7.14).




Rys. 7.12. Wyniki modelowania dla sieci NNBP(6) dla danych zakłóconych; a) dane treningowe, b) dane testujące (ciemniejszą linią zaznaczono pomiary)

a)




b)




Rys. 7.13. Wyniki modelowania dla sieci NNBP(6) dla danych wygładzonych; a) dane treningowe, b) dane testujące (punktami zaznaczono pomiary)


a)




b)



Rys. 7.14. Badanie wpływu liczby neuronów na warstwie ukrytej sieci (a) i zmiany kroku prognozowania (b) na wyniki modelowania (wykresy dolne na rysunkach otrzymano dla etapu trenowania, a wykresy górne – dla etapu testowania sieci)



Rys. 7.15. Wyniki modelowania dla sieci NNBP(8) dla danych wygładzonych; dane treningowe



Rys. 7.16. Wyniki modelowania dla sieci NNBP(8) dla danych wygładzonych; dane testujące

Poprawne wyniki otrzymano również dla modeli bardziej złożonych, o następującej strukturze sieci: 16 neuronów na warstwie wejściowej, 8 neuronów na warstwie ukrytej i 8 neuronów na warstwie wyjściowej. Jako wejścia modelu przyjęto parametry: BZT_{5-ss} , $ChZT_{ss}$, N_{og-ss} , s_{NH-ss} , x_{og-ss} , Q_{we} , s_O , x_{og-kn} , v_{os} , BZT_{5-so} , $ChZT_{so}$, N_{og-so} , s_{NH-so} , x_{og-so} , x_{og-r} , Q_r w chwili t , natomiast jako wyjścia modelu przyjęto parametry: x_{og-kn} , v_{os} , BZT_{5-so} , $ChZT_{so}$, N_{og-so} , s_{NH-so} , x_{og-so} , x_{og-r} w chwili $t+T$ (modele NNBP(8)). Przykładowe wyniki obliczeń dla modelu NNBP(8) przedstawiono na rys. 7.15 i 7.16, gdzie poszczególne wykresy oznaczają (od lewej do prawej i od góry do dołu): x_{og-kn} , v_{os} , x_{og-r} , BZT_{5-so} , $ChZT_{so}$, N_{og-so} , s_{NH-so} , x_{og-so} .

Wyniki modelu NNBP(8) są o rząd wielkości gorsze, niż w przypadku modelu NNBP(6), tak ze względu na wartości sum resztowych otrzymane dla etapu testowania modeli, jak i na uzyskiwane czasy obliczeń (tabl. 7.1).

Tablica 7.1. Wyniki obliczeń dla neuronowych modeli symulacyjnych

Model	Pomiary	Liczba neuronów na warstwach 1/2/3	Suma resztowa etap trenowania	Suma resztowa etap testowania	Czas obliczeń [sek]
NNBP(6)	zakłócone	12/6/6	0,006013	0,023028	998
NNBP(6)	wygładzone	12/6/6	0,002944	0,005243	670
NNBP(8)	wygładzone	16/8/8	0,001697	0,018093	9743


- **Modele sterowania**

Kolejna możliwość zastosowania sieci neuronowych, to użycie ich jako narzędzia wspomagającego decyzje operatora sterującego proces oczyszczania ścieków. Przypomnijmy, że procesy technologiczne w oczyszczalniach ścieków są obecnie stabilizowane za pomocą układów regulacji automatycznej. Jeżeli warunki procesu są stabilne, to również ustalone nastawy regulatorów sterujących poziomem tlenu rozpuszczonego w komorach z osadem czynnym i natężeniem przepływów recyrkulacyjnych, w ogólnym przypadku, ścieków i osadu czynnego, nie ulegają zmianie. Zmiana warunków wymaga zmiany tych nastaw i wówczas jest potrzebna ingerencja operatora procesu, korzystającego ze swojej wiedzy i doświadczenia. Często takie działania są spóźnione i obciążone błędem, co powoduje pogorszenie jakości procesu oczyszczania.


Odpowiednie modele matematyczne mogą generować wartości nastaw regulatorów, odpowiadające zmienionym warunkom procesowym i wymaganiom dotyczącym skuteczności oczyszczania. Zbadano możliwość wyznaczenia również takich modeli za pomocą sieci neuronowych. Badano sieci typu BP, trzywarstwowe, z nieliniowymi logistycznymi funkcjami przejścia na warstwie pierwszej i drugiej oraz z liniowymi funkcjami przejścia na warstwie trzeciej. Do badań użyto wygładzonych danych pomiarowych stosowanych także do wyznaczenia neuronowych modeli symulacyjnych [Studziński i in., 1999b].

W przypadku badanej oczyszczalni ścieków w Rzeszowie traktowanej jako obiekt testowy, zmiennymi sterującymi są: stężenie tlenu rozpuszczonego s_o w komorach napowietrzania i natężenie przepływu Q_r zwracanego osadu czynnego. Stąd, jako wyjścia badanych modeli przyjęto parametry s_o i Q_r w chwili t . Liczba i rodzaj wejść modelu wynikają przede wszystkim z przesłanek technologicznych. Jako wejścia modeli przyjęto w obliczeniach następujące zmienne procesu: BZT_{5-ss} , s_{NH-ss} , x_{og-ss} , Q_{we} w chwili t ; x_{og-kn} , v_{os} , BZT_{5-50} , s_{NH-50} , x_{og-50} ,

x_{og-r} w chwili t , oraz ponownie x_{og-kr} , v_{os} , BZT_{5-30} , S_{NH-30} , x_{og-30} , x_{og-r} w chwili $t+T$. Przyjęcie jako wejście modelu zmiennych procesowych w chwilach t i $t+T$ symuluje wyznaczanie sterowań obiektem dla chwili t w zależności od aktualnego stanu procesu i stanu, jaki operator chce uzyskać w przyszłym czasie $t+T$.



Rys. 7.17. Badanie wpływu liczby neuronów na warstwie ukrytej sieci na wyniki modelowania (wykres dolny otrzymano dla etapu trenowania, a wykres górny – dla etapu testowania sieci)



Rys. 7.18. Wyniki modelowania dla generatora sterowań (wykresy górne – dane treningowe, wykresy dolne – dane testujące; punktami zaznaczono pomiary)

Najlepsze modele otrzymane na podstawie wykonanych przykładowych obliczeń symulacyjnych mają następującą strukturę: 16 neuronów na warstwie wejściowej, 16 neuronów na warstwie ukrytej i 2 neurony na warstwie wyjściowej. Liczba i rodzaj wyjść modelu wynikają z rodzaju zmiennych sterujących występujących w obiekcie. Liczbę neuronów na warstwie ukrytej sieci ustalono za pomocą obliczeń symulacyjnych. (rys. 7.17). Przyjęty krok prognozowania sterowań wynosi 8 godz.

Na rys. 7.18 przedstawiono przykładowe wyniki modelowania, przy czym wykresy na rysunkach oznaczają kolejno (od lewej do prawej) s_0 i Q_r .

- **Ocena wyników**

Przedstawione rozważania dotyczą wyznaczania modeli neuronowych, które mogą być stosowane do zadań operacyjnych w oczyszczalni ścieków, takich jak prognozowanie stanów procesu technologicznego oraz sterowanie. Przy tym możliwość prognozowania stanów obiektu jest ważnym elementem procesu sterowania.


Badania mają charakter symulacyjny, to znaczy wszelkie ustalenia dotyczące modeli i formułowane wnioski są wynikiem obliczeń komputerowych. Przy tym w obliczeniach korzystano z rzeczywistych danych pomiarowych, umożliwiających weryfikację wyników w praktyce.

Ogólny wniosek jest taki, że sieci neuronowe są dobrym i dogodnym narzędziem do modelowania procesów oczyszczania ścieków. Wyznaczane modele są dokładne i szybkie w obliczeniach. Przy tym już stosunkowo proste sieci zbudowane z trzech warstw poprawnie aproksymują przebiegi pomiarowe.


W badanych przypadkach modelowania oczyszczalni ścieków istotny wpływ na wyniki ma fakt wygładzenia pomiarów oraz odpowiedni dobór liczby neuronów na warstwie ukrytej sieci neuronowej. Przy czym zbyt mała i również zbyt wielka liczba neuronów pogarsza jakość modelowania. Jednocześnie komplikowanie struktury sieci poprzez zwiększanie liczby wejść lub wyjść modelu znacznie wydłuża czas obliczeń.

Decydujący wpływ na wyniki ma również liczba pomiarów użytych do uczenia względnie trenowania sieci. Na rys. 7.19 pokazano, jak zmienia się dokładność obliczeń w funkcji liczby pomiarów przy modelowaniu dopływu ścieków do oczyszczalni za pomocą sieci neuronowej NNBP. Wykresy na rys. 7.19 a) i b) otrzymano dla 200 pomiarów a wykresy na rys. 7.7.1 c) i d) otrzymano dla 1.300 pomiarów, przy czym uzyskane sumy resztowe wynoszą odpowiednio 1,0642 oraz 0,2823.


a)




b)



c)



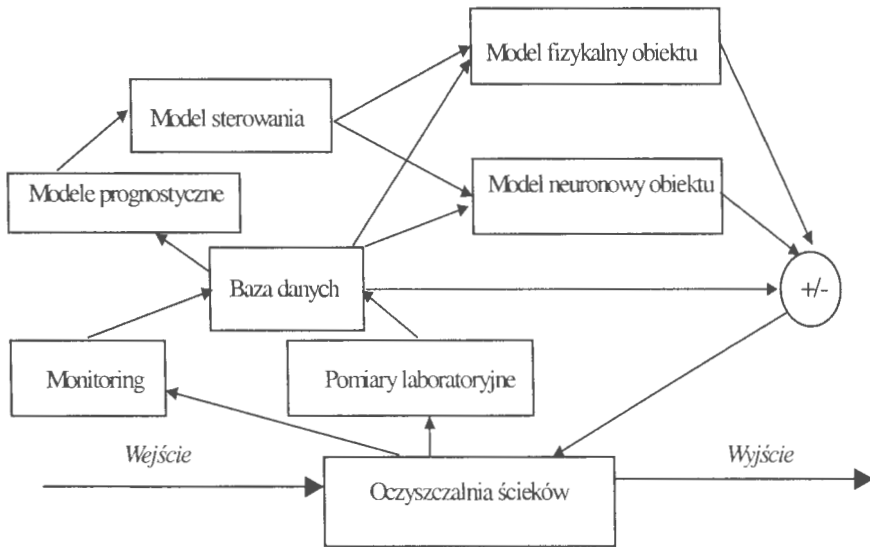
d)



Rys. 7.19. Wpływ liczby pomiarów na wyniki modelowania:
a) i c) – wykresy wyjścia modelu; b) i d) – wykresy błędu modelowania
(punktami zaznaczono pomiary)

7.3. System wspomaganie decyzji operatora oczyszczalni

Przedstawione i omówione w poprzednich rozdziałach modele matematyczne oczyszczalni ścieków mają różne własności i różne przeznaczenie. Model fizyczny, wyprowadzony na podstawie bilansów masy i opisany równaniami różniczkowymi, jest bardzo dokładny i jednocześnie wolny pod względem obliczeniowym i trudny w użyciu. Estymacja jego parametrów przebiega w sposób ręczny i jest bardzo żmudnym i czasochłonnym procesem. Wymaga ona przy tym znacznego doświadczenia użytkownika modelu. Dlatego w obecnej postaci model fizyczny nie może być stosowany do celów optymalizacji, natomiast dobrze nadaje się do pojedynczych symulacji komputerowych obiektu. Jego istotną zaletą, oprócz dokładności, jest fizyczna interpretowalność parametrów.



Rys. 7.20. Schemat systemu komputerowego wspomaganie decyzji operatora oczyszczalni

Z kolei modele neuronowe a także modele opisane szeregami czasowymi mają prostą i jednorodną strukturę a ich opis jest w postaci prostszych równań algebraicznych. To powoduje, że mają stosunkowo krótkie czasy obliczeń a obliczenia optymalizacyjne z ich użyciem są proste i w pełni zautomatyzowane.

Ich wadą jest jednak mniejsza dokładność i większa trudność interpretacyjna wyników, ponieważ parametry modeli są współczynnikami wagowymi w równaniach, bez znaczenia fizycznego. W takiej postaci te modele mogą mieć zastosowanie jako modele operacyjne, przeznaczone głównie dla celów prognozowania i wspomagania procesów decyzyjnych [Bogdan i in., 2002d; Studziński i in., 1999b].

Można więc zauważyć, że własności obu rodzajów modeli uzupełniają się i łącznie tworzą one dobre narzędzie do dokładnego opisu oczyszczalni oraz do optymalizacji procesu technologicznego. Na podstawie tego spostrzeżenia opracowano koncepcję systemu komputerowego wspomagania decyzji operatora oczyszczalni [Studziński, 2001, 2002a, b, c, d]. System, pokazany schematycznie na rys. 7.20, stosuje wszystkie opracowane modele oczyszczalni i jego działanie jest następujące:

- parametry procesu oczyszczania są mierzone na bieżąco, w części automatycznie za pomocą zainstalowanego w oczyszczalni systemu monitoringu, a w części laboratoryjnie, w ramach badań rutynowych prowadzonych na obiekcie;
- dane pomiarowe są rejestrowane w tak zwanej branżowej bazie danych, gdzie są również poddawane opracowaniu statystycznemu polegającemu głównie na wygładzaniu, uśrednianiu i skalowaniu danych;
- przewidywane natężenie dopływu ścieków surowych oraz przewidywane ładunki zanieczyszczeń są wyznaczane za pomocą neuronowych modeli prognostycznych i na podstawie przetworzonych pomiarów z branżowej bazy danych;
- parametry sterujące procesem są obliczane za pomocą neuronowego modelu sterowania oraz na podstawie wyznaczonych wartości dopływu i ładunków zanieczyszczeń;
- obliczone sterowania są następnie weryfikowane za pomocą obliczeń symulacyjnych przy użyciu prostszego modelu neuronowego procesu względnie dokładnego modelu fizycznego;
- w przypadku pozytywnej weryfikacji obliczone sterowania są uwzględniane w oczyszczalni;
- jeżeli weryfikacja jest negatywna, operator nie akceptuje obliczonych sterowań i samodzielnie podejmuje decyzje dotyczące sterowania procesem technologicznym.

W ten sposób system nie zastępuje operatora procesu a jedynie wspomaga jego procesy decyzyjne. Wydaje się, że jest to słuszne podejście w odniesieniu do procesów tak złożonych, jak biologiczne oczyszczanie ścieków. Z jednej strony,

procesy te nie są jeszcze dokładnie rozpoznane i wiarygodnie opisane, szczególnie w przypadku pełnego oczyszczania biologicznego z usuwaniem związków fosforowych. Z drugiej strony, wszelkie niewłaściwe decyzje technologiczne mogą mieć groźne konsekwencje tak procesowe, jak i środowiskowe, szczególnie w przypadku wielkich oczyszczalni miejskich, o wydajnościach do kilkuset tysięcy m³ ścieków na dobę.

Elementy tego systemu dotyczące różnego typu modeli matematycznych były opracowane i testowane przy użyciu danych pomiarowych z miejskiej oczyszczalni ścieków w Rzeszowie. Prowadzone w oczyszczalni badania doprowadziły także do sformułowania następujących wniosków:

- praktykowane zwykle koncepcje budowy albo złożonych modeli fizykalnych procesów oczyszczania albo jedynie prostych modeli operacyjnych nie są właściwe, gdyż nie dają w rezultacie możliwości użycia tych modeli w praktyce: skomplikowane modele fizykalne nie nadają się do obliczeń optymalizacyjnych, natomiast uproszczone modele operacyjne są często za mało dokładne, aby na ich podstawie podejmować bezkrytycznie decyzje technologiczne;
- właściwym rozwiązaniem wydaje się prowadzenie prac uwzględniających równoczesne opracowywanie modeli obu rodzajów, aby wyniki uzyskane za pomocą modeli prostszych mogły być następnie weryfikowane za pomocą modeli dokładnych;
- przy tworzeniu modeli fizykalnych jest konieczne zastąpienie dotychczasowego sposobu estymacji parametrów za pomocą ręcznej kalibracji przez przynajmniej częściową automatyzację procesu identyfikacji; kalibracja jest bardzo żmudnym i dosyć niedokładnym procesem i dlatego powinna dotyczyć ewentualnie parametrów o w miarę ustalonych wartościach i takich, względem których system wykazuje stosunkowo małą wrażliwość; pozostałe parametry powinny być estymowane za pomocą numerycznych metod optymalizacji;
- przy tworzeniu modeli fizykalnych jest istotne, aby dokładnie wyznaczać objętości czynne zbiorników oczyszczalni, gdyż zachodzą w praktyce istotne różnice między objętościami czynnymi i odpowiadającymi im objętościami geometrycznymi; przy wyznaczaniu objętości czynnych za pomocą specjalnych modeli przepływowych sprawą podstawową jest właściwe opracowanie i przeprowadzenie odpowiedniego eksperymentu czynnego;
- sieci neuronowe wydają się dobrym narzędziem do budowy szybkich modeli operacyjnych procesu, służących zarówno do celów prognozowania, jak i sterowania.

Jan Studziński

**IDENTYFIKACJA, SYMULACJA I STEROWANIE
OCZYSZCZALNIAMI ŚCIEKÓW**

Monografia dotyczy problematyki modelowania i sterowania mechaniczno-biologicznymi oczyszczalnymi ścieków. Przedstawione badania obejmują opracowanie modeli matematycznych oczyszczalni, ich identyfikację oraz zastosowanie do celów sterowania. Omówiono aktualny stan badań oraz wskazano pożądane kierunki ich rozwoju. Opisano szczegółowo zagadnienia związane z wykonywaniem eksperymentów pomiarowych, opracowywaniem modeli przepływowych wydzielonych zbiorników oczyszczalni, wyznaczeniem modelu fizycznego oczyszczalni oraz modeli neuronowych. Wszystkie rozważania są ilustrowane wynikami przykładowych badań wykonanych pod kierunkiem autora w miejskiej oczyszczalni ścieków w Rzeszowie.

ISSN 0208-8029
ISBN 83-85847-88-X