



Matematyczne modelowanie sieci wodociągowych

*Stanisław Biedugnis, Mariusz Smolarkiewicz
Szkoła Główna Służby Pożarniczej*

*Andrzej Czapczuk
Politechnika Warszawska*

1. Wstęp

Woda jest czynnikiem niezbędnym dla prawidłowego funkcjonowania człowieka. Każdy człowiek w ciągu doby potrzebuje określoną ilość wody pitnej aby żyć i móc się rozwijać. W warunkach ekstremalnych ilość wody potrzebna do przeżycia człowieka (w ciągu doby) równa jest kilku litrom. W warunkach wysokiego komfortu życia ilość wody potrzebna do prawidłowego funkcjonowania osiąga wartość zbliżoną do 150 l/Md. Konieczność prawidłowego, bezawaryjnego, optymalnego funkcjonowania systemu wodociągowego staje się jednym z głównych priorytetów społecznych dzisiejszych czasów.

Po roku 1989, na skutek przemian polityczno-społecznych, wprowadzono reformę administracyjną kraju zwiększającą zakres uprawnień władz lokalnych. Spowodowało to przeniesienie majątku państwowego, w tym systemów wodociągowych i kanalizacyjnych w ręce samorządów gminnych. Gminy jako jednostki zarządzające często nie były przygotowane do prowadzenia: eksploatacji, konserwacji i budowy systemów wodociągowych na swoim terenie. Szereg istniejących syste-

mów wodociągowych nie jest w zadowalającym stanie technicznym. W takich warunkach problematyczne staje się przygotowanie prawidłowo funkcjonującej gospodarki wodno-ściekowej na danym terenie. Z pomocą w rozwiązaniu tych problemów przychodzą systemy komputerowe wyposażone w aplikacje pozwalające na prawidłowe, efektywne projektowanie systemów wodociągowo-kanalizacyjnych i analizę działania już istniejących za pomocą różnego typu modeli matematycznych w tym modeli hybrydowych.

Dlatego celowe jest podjęcie prac i badań nad modelami systemów sieci wodociągowych zmierzających do bardziej dogłębnego poznania ich struktury oraz do racjonalizacji projektowania, użytkowania i eksploatacji tych systemów. W efekcie końcowym wyniki prac w tym zakresie powinny przyczynić się do poszerzenia wiedzy o systemach wodociągowych, określenia zależności pomiędzy poszczególnymi częściowymi elementami tych systemów, ułatwienia w projektowaniu i eksploatacji systemów wodociągowych oraz zwiększenia poziomu ich niezawodności, co w konsekwencji poprawi zaopatrzenie użytkowników w wodę.

Dotychczas nie prowadzono komputerowych badań nad modelami sieci z wykorzystaniem hybrydowych modeli neuronowo-matematycznych. Większość prowadzonych badań i rozważań opierała się na istniejących modelach matematycznych sieci wodociągowych.

2. Sieci neuronowe

Zastanawiamy się czasem nad tym, w jaki sposób błyskawicznie rozpoznajemy twarze znanych nam osób? Przeważnie dzieje się to tak szybko i jest dla nas tak naturalne, że nie widzimy w tym nic dziwnego – po prostu rozpoznajemy twarze (budynki, litery, głosy...) i już. Cudów jednak nie ma. Nie możemy rozpoznać twarzy, której nasz mózg się nie nauczył. Musi ona być już gdzieś zapamiętana, aby nie została uznana za obcą. W klasycznym komputerze wzorce poszczególnych twarzy wypełniałyby jakąś bazę danych, a algorytm porównywałby każdą ujrzaną twarz z tymi, które są mu znane. Oczywiście przy takiej liczbie twarzy, jaką pamięta przeciętny człowiek, praca owego algorytmu trwałaby bardzo długo, ale nie w tym rzecz. Otóż komputer zapamiętuje obraz w ten sposób, że zamienia go na ciąg liczb. W uproszczeniu: obraz jest dzielo-

ny na małe punkciki (pixele) i każdemu z nich zostaje przyporządkowana liczba zależna od jego koloru (mam nadzieję, że graficy zechcą nam wybaczyć te nieścisłości). Co się zatem dzieje, gdy wprowadzimy do bazy danych dwa zdjęcia tej samej twarzy wykonane pod nieco innym kątem i przy innym oświetleniu? Mówiąc slangiem, w tym momencie program „się wyklada” – nie potrafi dostrzec podobieństwa między owymi zdjęciami. Podobieństwa, które my, za pomocą naszej „sieci neuronowej”, dostrzegamy w ułamku sekundy. Zobaczywszy kogoś potrafimy go później rozpoznać mimo makijażu, innej fryzury, innej pory dnia i innych niedogodności. Dla klasycznego algorytmu jest to niezmiernie trudne.

2.1. Kojarzenie

Jest ono w zasadzie bardzo zbliżone do rozpoznawania. Czym jest, bowiem rozpoznawanie? Niczym innym, jak kojarzeniem tego, co próbujemy rozpoznać z tym, co już znamy. I znowu: dwa obiekty (obrazki, dźwięki) mogą dla człowieka być podobne, natomiast klasyczny algorytm nie stwierdzi między nimi podobieństwa. Dla niego są to dwa różne ciągi znaków. Można oczywiście programowo „obejść” to utrudnienie – „powiedzieć” komputerowi, jakie cechy obiektu są bardziej znaczące i mogą zaważyć na podobieństwie (lub niepodobieństwie) dwóch (lub więcej) obiektów. Jest to jednak dla programisty wysoce trudne zadanie. Natomiast w przypadku SSN nie ma potrzeby nakazywania sieci brania pod uwagę tej czy innej cechy – odnajdzie je sama. Więcej – może zaważyć takie zależności, o których programista nawet nie wie. Ciekawe jest to, iż potrafimy zaprojektować skomplikowaną sieć, skutecznie jej użyć, ale nie mamy pewności, co do tego, w jaki sposób dokładnie działa, co się dzieje w jej głębi.

2.2. Przewidywanie

Jeśli znamy dobrze jakieś zjawisko, to wiedząc, jaki jest jego stan w danej chwili, potrafimy mniej więcej określić, jak się będzie zachowywać w najbliższej przyszłości, nieprawdaż? Otóż SSN mogą służyć do tego samego. Stosuje się je głównie do opracowywania prognoz ruchów na giełdzie i do przewidywania pogody. Tak, nawet, zdawałoby się, tak przypadkowe zmiany, jak zmiany giełdowe, podlegają jakimś prawom. Doświadczony gracz potrafi przewidzieć, czy dana operacja zakończy się powodzeniem. Nazywamy to przecuciem, szóstym zmysłem, lecz jest to

jedynie podświadome korzystanie z wiedzy nabytej również nieświadomie przez lata obserwacji procesów giełdowych. A trzeba pamiętać, że mózg człowieka, choć ogromny (w porównaniu z SSN), zajmuje się przecież niezliczoną ilością innych zadań, jak choćby utrzymywanie ciała w równowadze, itd. itp. Sieć natomiast jest przeznaczona wyłącznie do jednego zadania i jemu poświęca cały swój potencjał. Podobnie, jak dobry gracz, sieć potrafi trafnie prognozować ruchy giełdowe, choć nie wiemy dokładnie, w jaki sposób to robi (tak, jak nie wiemy, na czym polega intuicja gracza).

2.3. Sterowanie

Naukowcy próbujący stworzyć robota o postawie humanoidalnej borykają się głównie z problemem jego ruchu. Dość trudno jest zaprojektować i oprogramować robota w taki sposób, by utrzymywał równowagę. Niedoścignionym wzorem w tej dziedzinie jest mózg. Człowiek, pies, kot, mogą wyczyniać najprzeróżniejsze ewolucje nie tracąc przy tym równowagi. Aby obliczyć wielkości i kierunki sił, z jakimi balansować musi organizm podczas gwałtownego ruchu, potrzeba matematyki na dość wysokim poziomie. Mózg zaś daje sobie radę z tymi obliczeniami w ułamku sekundy wykonując w tym czasie dziesiątki innych czynności. Odpowiednio zaawansowana sieć neuronowa mogłaby czynić to samo. Właśnie SSN są wykorzystywane do sterowania robotami przeznaczonymi do pracy w najtrudniejszych warunkach.

2.4. Zalety i wady sieci neuronowej

Zalety – SSN rozwiązuje znacznie lepiej zadania, niż zwykły algorytm. Natomiast jedną z najważniejszych zalet SSN z punktu widzenia programisty jest to, że SSN nie wymagają programowania! Wystarczy stworzyć sieć, a ona uczy się sama. Rola programisty ogranicza się do zaprojektowania takiej struktury sieci, która najlepiej będzie nadawała się do rozwiązania danego problemu, a następnie do umiejętnego pokierowania procesem uczenia sieci. Z czymś się to kojarzy? Oczywiście – analogicznie jest w przypadku każdego z nas. Aby być w jakiejś dziedzinie fachowcem, trzeba po pierwsze mieć wrodzone uzdolnienia w danej dziedzinie (odpowiednią strukturę własnej sieci neuronowej, jaką jest mózg), a po drugie – mieć dobrego nauczyciela.

Inna zaleta: jak pewnie wiadomo, w zwykłym programie najmniejszy błąd może doprowadzić do wadliwego działania systemu, utraty danych, oraz do innych nieszczęść. Sieć neuronowa natomiast nawet w przypadku poważnego uszkodzenia działa nadal, jak gdyby nigdy nic! Oczywiście do pewnego stopnia. I znowu analogia: nasz mózg działa nadal po wypadku, w którym odniesie niewielki uszczerbek, działa pomimo niszczenia neuronów przez alkohol lub proces starzenia, działa długo bez „awarii”, choć jego struktura wciąż jest naruszana. Dopiero po przekroczeniu pewnego progu uszkodzeń mózg odmawia posłuszeństwa. Stąd choroba Alzheimera, dalsze stopnie np. choroby alkoholowej, psychozy po narkotykowej i podobne przypadłości.

Kolejną ważną zaletą SSN jest zdolność uogólniania zdobytej wiedzy. Znaczy to dokładnie tyle, że jeśli sieć nauczy się, powiedzmy, rozpoznawać kolory: czerwony i żółty, to rozpozna również różowy i bladeżółty, czyli kolory podobne do znanych.

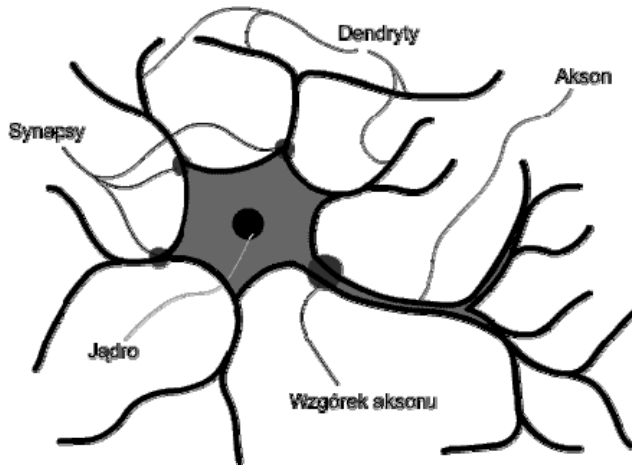
Wady – Nie ma rzeczy doskonałych. Sieci neuronowe nie przydadzą się przede wszystkim tam, gdzie potrzeba jasnych i precyzyjnych wyników – czyli przy rozmaitych skomplikowanych obliczeniach, obsłudze kont bankowych, itp. Wynika to z faktu, iż SSN jest odbiciem ludzkiego mózgu, ten zaś nie jest przystosowany do precyzyjnego operowania liczbami. Kiedy opisujemy kogoś, nie mówimy, że ma 188,34 cm wzrostu, tylko że jest wysoki. I to nie tyle dlatego, że dokładność tej informacji jest wystarczająca, lecz dlatego, że bez odpowiedniej aparatury pomiarowej nasz mózg nie jest w stanie precyzyjnie ocenić pewnych wielkości. SSN zatem operuje tzw. pojęciami rozmytymi: wysoki, niski, duży, mały, średni, jasny... Często jeśli oczekujemy od sieci odpowiedzi „tak” lub „nie”, ona odpowie: „raczej tak”, lub: „chyba nie”... Ta ostatnia skłonność sieci może być zarówno wadą, jak i zaletą – zależy, jak na to patrzeć.

SSN nie zdaje egzaminu także wtedy, gdy specyfika problemu wymaga zastosowania wieloetapowego rozumowania. Kiedy trzeba moliźnie dochodzić do pewnych wniosków na podstawie efektów wcześniejszego rozumowania, a z tych wniosków wyciągać kolejne – sieć „odpada”. Ona „woli” rozwiązać zadanie na raz, w jednym kroku. Jeśli nawet pojawiają się jakieś wnioski pośrednie, to i tak nie ma do nich dostępu. Ta ostatnia cecha może się wydać dziwna komuś, kto oswoił się już z myślą, że SSN symuluje działanie mózgu. Przecież człowiek rozu-

muje krok po kroku, z jednych wniosków wyciągając następne. To fakt, ale rozumowanie można podzielić na pojedyncze etapy, w których działamy „na raz”. Mamy jakieś dane i wyciągamy z nich wniosek. Ten wniosek posłuży do wyciągnięcia następnego, również w takim jednorazowym procesie. Takiemu modelowi rozumowania odpowiadałby raczej cały zespół różnych sieci neuronowych, i to niekoniecznie połączonych liniowo. Dane z wyjścia pewnej sieci mogłyby trafiać na wejście to tej, to innej sieci. Każda z nich zaś, powtarzam, działa jednoetapowo.

2.5. Z czego składa się sieć neuronowa

W oryginale – komórka nerwowa. W sieci neuronowej – podstawowy jej składnik. „Oryginalny” neuron przedstawiono na rys. 1.



Rys. 1. Neuron


Fig. 1. Neuron

Opis:

- Jądro – „centrum obliczeniowe” neuronu. To tutaj zachodzą procesy kluczowe dla funkcjonowania neuronu.
- Akson – „wyjście” neuronu. Za jego pośrednictwem neuron powiadamia świat zewnętrzny o swojej reakcji na dane wejściowe. Neuron ma tylko jeden akson.
- Wzgórek aksonu – stąd wysyłany jest sygnał wyjściowy, który wędruje dalej poprzez akson.

- Dendryt – „wejście” neuronu. Tędy trafiają do jądra sygnały mające być w nim później poddane obróbce. Dendrytów może być wiele – biologiczne neurony mają ich tysiące.
- Synapsa – jeśli dendryt jest wejściem neuronu, to synapsa jest jego furtką. Może ona zmienić moc sygnału napływającego poprzez dendryt.

To nie wszystkie składowe biologicznego neuronu, lecz inne z punktu widzenia SSN nie będą nas interesować. Model neuronu składa się z dokładnie tych samych elementów, które wyżej wymieniono. Oto – nieco okrojony – schemat; kompletny jest umieszczony w dalej.



Rys. 2. Model neuronu

Fig. 2. Neuron model


Zaszły małe zmiany, ale tylko pozornie. Wejścia to dendryty, lub ściślej: sygnały przez nie nadchodzące. Wagi to cyfrowe odpowiedniki modyfikacji dokonywanych na sygnałach przez synapsy. Blok sumujący to odpowiednik jądra, blok aktywacji to wzgórek aksonu, a wyjście – to akson. Zaznaczamy, że fakt, iż na rysunku są trzy dendryty, jest czysto przypadkowy. Liczba ich jest dowolna, zaś na rysunkach wynosi trzy jedynie ze względów estetycznych.

2.6. Matematyczny model neuronu

Z oczywistych przyczyn pewne zawarte tu informacje będą powtórzeniem fragmentów pierwszej części, choć tam, gdzie nie jest to konieczne, staramy się tego unikać. Jeśli zatem nie przeczytaliśmy części

„dla ciekawskich”, to prosimy – wrócić do niej i ją przejrzeć. Na pewno to nie zaszkodzi, a być może pomoże.

Strukturę biologicznego neuronu pamiętamy z pierwszej części wykładów. Sztuczny neuron można zaś rozpatrywać jako specyficzny przetwornik sygnałów działający według następującej zasady. Na wejście przetwornika podawane są sygnały wejściowe, które następnie są mnożone przez odpowiednie współczynniki wag (odpowiadające „sile” połączeń synaptycznych w biologicznym neuronie). „Ważone” sygnały wejściowe są następnie sumowane i na tej podstawie wyznacza się aktywność neuronu. Oto schemat sztucznego neuronu:



Rys. 3. Schemat sztucznego neuronu

Fig. 3. Diagram of artificial neuron

Jak widać na rysunku, model sztucznego neuronu składa się z dwóch bloków: bloku sumowania Σ i bloku aktywacji F . W pewnym przybliżeniu blok sumowania odpowiada biologicznemu ciału komórki, w której realizowane jest algebraiczne sumowanie ważonych sygnałów wejściowych, oraz generowany jest sygnał wyjściowy φ , który może być traktowany jako potencjał membranowy komórki.

Potencjał membranowy można wyliczyć ze wzoru:

$$\varphi = \sum_{i=1}^m w_i u_i = \mathbf{w}^T \mathbf{u} \quad (1)$$

We wzorze tym \mathbf{w} jest wektorem współczynników wag, \mathbf{u} – wektorem sygnałów wejściowych, T – operatorem transponowania wektora lub macierzy, m – liczbą wejść neuronu.

Sygnał φ poddawany jest przetwarzaniu przez blok aktywacji F , który w zależności od potrzeb może być opisany różnymi funkcjami.

Może to być np. prosta funkcja liniowa – wówczas sygnał wyjściowy y ma postać:

$$y = k\varphi \quad (2)$$

k – jest zadany współczynnikiem.

Sieci budowane z wykorzystaniem neuronów o wyjściach opisanych tą zależnością nazywa się sieciami liniowymi. W literaturze [21] sieci takie nazywane są także sieciami Madaline, a tworzące je neurony nazywa się odpowiednio Adaline. Są to najprostsze ze znanych sieci, które znalazły praktyczne zastosowanie.

Innym typem funkcji opisującej blok aktywacji może być funkcja skoku jednostkowego. W tym przypadku sygnał wyjściowy jest równy:

$$y = \begin{cases} 1, & \varphi > \varphi_h \\ 0, & \varphi \leq \varphi_h \end{cases} \quad (3)$$

φ_h – jest zadaną stałą wartością progową.

Funkcjami, które w dokładniejszy sposób opisują nieliniową charakterystykę przejścia neuronu biologicznego, są funkcje sigmoidalne, opisane wzorem:

$$y = \frac{1}{1 + e^{(-\beta\varphi)}} \quad (4)$$

gdzie β jest zadany parametrem, oraz funkcje tangensoidalne:

$$y = \tanh\left(\frac{\alpha\varphi}{2}\right) \frac{1 - e^{(-\alpha\varphi)}}{1 + e^{(-\alpha\varphi)}} \quad (5)$$

gdzie α jest zadany parametrem, a $\tanh()$ – funkcją tangens hiperboliczny.

Należy zwrócić uwagę na następujące zależności dla funkcji sigmoidalnej:

$$\begin{aligned} \beta\varphi \rightarrow \infty &\Rightarrow y \rightarrow 1 \\ \beta\varphi \rightarrow -\infty &\Rightarrow y \rightarrow 0 \\ \beta \rightarrow \infty &\Rightarrow \frac{1}{1 + e^{-\beta\varphi}} \rightarrow \mathbf{1}(\varphi) \end{aligned} \quad (6)$$

gdzie $\mathbb{1}(\varphi)$ jest funkcją [21] Heaviside'a:

$$\mathbb{1}(\varphi) = \begin{cases} 1, & \varphi > 0 \\ 0, & \varphi \leq 0 \end{cases} \quad (7)$$

Dla funkcji tangensoidalnej odpowiednio:

$$\begin{aligned} \alpha\varphi \rightarrow \infty &\Rightarrow y \rightarrow 1 \\ \alpha\varphi \rightarrow -\infty &\Rightarrow y \rightarrow -1 \\ \alpha \rightarrow \infty &\Rightarrow \tanh\left(\frac{\alpha\varphi}{2}\right) \rightarrow \operatorname{sgn}(\varphi) \end{aligned} \quad (8)$$

przy czym $\operatorname{sgn}(>)$ oznacza funkcję signum, czyli:

$$\operatorname{sgn}(\varphi) = \begin{cases} +1, & \varphi > 0 \\ -1, & \varphi \leq 0 \end{cases} \quad (9)$$

Wykresy funkcji sigmoidalnych i tangensoidalnych mają kształt zbliżony do litery *S*, a funkcja tangensoidalna jest ponadto symetryczna względem początku układu współrzędnych. Szereg zalet wynikających ze stosowania nieliniowych funkcji tego typu będzie przedstawiony przy okazji omawiania algorytmów uczenia sieci opartych na gradientowych metodach optymalizacji.

Należy dodać, że opisane tu wzory nie uwzględniają wielu charakterystyk biologicznych neuronów. Przede wszystkim są to modele statyczne, w których pominięto czasy opóźnień będące efektem działania dynamiki systemu. Nie uwzględnia się tu również efektów synchronizacji lub funkcji modulacji częstotliwości neuronu biologicznego. Pomimo wymienionych ograniczeń sieci budowane z wykorzystaniem takich uproszczonych modeli matematycznych wykazują wiele cech, które są charakterystyczne dla systemów biologicznych.

3. Podsumowanie i wnioski końcowe

W wyniku przeprowadzonych rozważań wykazano możliwość zastosowania modeli hybrydowych w procesie programowania rozległych systemów zaopatrzenia w wodę. Model hybrydowy ma charakter strukturalny, jest powtarzalny, dyskretny w stanie. Model hybrydowy systemu zaopatrzenia w wodę pozwala na projektowanie nowych systemów, oce-

nę pracy i analizę działania całego i poszczególnych elementów istniejących systemów wodociągowych.

Niniejsza praca ma charakter wstępny, studialny, a w dalszych jej częściach podjęta zostanie próba implementacji hybrydowego modelu systemu zaopatrzenia w wodę.

Literatura

1. **Bartkiewicz B.:** *Ścieki przemysłowe*. Oficyna Wydawnicza PW, Warszawa, 2000.
2. **Biedugnis S., Miłaszewski R.:** *Metody optymalizacyjne w wodociągach i kanalizacji*. PWN, Warszawa, 1993.
3. **Biedugnis S., Podwójci P.:** *Studium na temat danych wejściowych modeli optymalizacyjnych regionalnej gospodarki odpadami komunalnymi*. VI Sem. Inst. ZWiBW PW, Oficyna Wyd. PW, Warszawa, 177-189, 1999.
4. **Biedugnis S., Podwójci P., Smolarkiewicz M.:** *Regional optimizing Model for Systems of Municipal Waste Disposal and Utilization Model for Systems of Municipal Waste Disposal and Utilization in dynamic Contest (Weryfikacja oraz ocena współzależności wybranych parametrów wejściowych i wyjściowych modelu regionalnej gospodarki odpadami w wersji dynamicznej)*. XXII Międzynarodowe Sympozjum im. Bolesława Krzysztofika AQUA' 2001, Materiały Konferencyjne, tekst referatu na CD-ROM s. 44, Płock, 2001.
5. **Gomółka B.:** *Podstawy ochrony środowiska*. Wyd. Politechniki Wrocławskiej, 1980.
6. **Harrison E., Angell R.:** *Waste Prevention Tool Kit for Local Governments*. Cornell Waste Management Institute, 1992
7. **Hicman H.:** *Collection of Residential Solid Waste*. In: *The Solid Waste Handbook: A Practical Guide* ed. by Robinson W., John Wiley & Sons, NY, 1986.
8. **Józwiak J.:** *Statystyka od podstaw*. Polskie Wyd. Ekonomiczne, Warszawa, 1997.
9. **Koniński R.A.:** *Sztuczne sieci neuronowe*. WNT, Warszawa, 2002.
10. **Kellinson S.:** *Theory of Interest*. Irwin, 1971.
11. **Krajewski K.:** *Metody optymalizacji w inżynierii środowiska*. Oficyna Wydawnicza PW, Warszawa, 1993.
12. **Marks D.H., Liebman J.C.:** *Mathematical analysis of solid waste collection*. Bureau of Solid Waste Management, 1970.
13. **McCutcheon J., Scott W.:** *An Introduction to the Mathematics of Finance*. Butterworth-Heinemann, 1991.

14. **Morrison D.:** *Wielowymiarowa analiza statystyczna*. PWN, Warszawa, 1990.
15. **Osowski S.:** *Sieci neuronowe do przetwarzania informacji*. WFUJ, Kraków, 2002.
16. **Podwójci P., Biedugnis S.:** *Studium na temat danych wejściowych modeli optymalizacyjnych regionalnej gospodarki odpadami komunalnymi*. Grant KBN nr 3 T09C 052 15, Warszawa, 2000.
17. **Rogalska D.:** *Programowanie liniowe*. Wyd. Uniwersytetu Łódzkiego, Łódź, 1998.
18. **Scharper L.:** *Transfer of Municipal Solid Waste*. The Solid Waste Handbook, John Wiley & Sons, NY, 1986.
19. **Shuster K.A.:** *A Five-Stage Improvement Process for Solid Waste Collection Systems*. US EPA, Washington D.C., 1974.
20. **Siudak M.:** *Badania operacyjne*. Oficyna Wydawnicza PW, Warszawa, 1997.
21. **Staniszewski R.:** *Teoria systemów*. Wszechnica Polskiej Akademii Nauk, Ossolineum, Wrocław, 1988.
22. **StatSoft Polska:** *Statistica Pl dla Windows*. Kraków, 1997.
23. **Stevens J.:** *Applied multivariate statistics for the social sciences*. Hillsdale, NJ Erlbaum, 1986.
24. **Szajna J.:** *Turbo Prolog. Programowanie w języku logiki*. WNT, Warszawa 1991.
25. **Tadeusiewicz R.:** *Sieci Neuronowe*. Wydawnictwa Internetowe AGH, (<http://winntbg.bg.agh.edu.pl/skrypty/1/>).
26. **Tadeusiewicz R.:** *Wprowadzenie do sieci neuronowych*. Kraków, 2001.
27. **Wagner H.:** *Badania operacyjne*. PWN, Warszawa, 1980.
28. *Waste Age*. Composting and waste management Plan, 1990.
29. **Witkowska D.:** *Sztuczne sieci neuronowe i metody statystyczne*. C.H.Beck, Warszawa, 2002.
30. **Wiśniewski M.:** *Elementy matematyki finansowej*. maszynopis, Wydział Nauk Ekonomicznych, Uniwersytet Warszawski, Warszawa, 1999.
31. **Zeigler B.:** *Teoria modelowania i symulacji*. PWN, Warszawa, 1984.
32. <http://www.lpa.co.uk> – strona firmy LPA,
33. <http://www.hallogram.com/science/lpaprolog/index.html> – strona firmy Hallogram,
34. <http://www.ccl.umist.ac.uk/teaching/material/5003/lpa/> – krótki opis programu LPA WinProlog,
35. <http://www.ozemail.com.au/~prosoft/casd16b.htm> – opis możliwości programu LPA Prolog.
36. <http://kti.mff.cuni.cz/~bartak/prolog.old/> – interaktywny kurs nauki Prolog.

Mathematical Modelling of Water Supply Networks

Abstract

Many existing water supply systems in Poland is not in the satisfactory condition. In such conditions, it becomes problematic to prepare a properly functioning water and wastewater management system in the area. Computer systems equipped with applications that allow for the proper, efficient design of water supply and sewage systems, and analysis of running of existing ones using various types of mathematical models, including hybrid models, can be helpful in solving mentioned problems.

Therefore, it is advisable to undertake the work and research on models of water supply systems in order to know more deeply their structure and to rationalize designing, use and operation of those systems. As a result, the final results of the work in this area should contribute to improving knowledge of water systems, the relationship between individual basic elements of those systems, facilitating designing and operation of water supply systems and increase their level of reliability, which in turn will improve water supply to users .

To date, no computer studies have been conducted on models of networks using a hybrid neuro-mathematical models. Most of the research and dissertations were based on existing mathematical models of water supply networks.

Formulae described in this paper do not include many characteristics of biological neurons. First of all, these are static models, in which delay times which result from the dynamics of the system were excluded. Effects of synchronization or frequency modulation function of the biological neuron are not also included. Despite these limitations networks built using such simplified mathematical models show many features that are characteristic to biological systems.

As a result of considerations, the possibility of hybrid models application in the programming process of extensive water supply systems was proved. Hybrid model is structural in nature, is repetitive, discrete in state. Hybrid model of water supply system allows to design new systems, evaluation of the work and analysis of running of the whole and individual elements of existing water supply systems.

This work is preliminary, studial, and its further parts will be concerned on the attempt of implementation of a hybrid model of water supply system.

