


Mirosław KWESIELEWICZ, Tomasz SŁOMIŃSKI

POLITECHNIKA GDAŃSKA, WYDZIAŁ ELEKTROTECHNIKI I AUTOMATYKI, KATEDRA AUTOMATYKI

Przegląd wybranych metod prognozowania zapotrzebowania na wodę w miejskich sieciach wodociągowych**Dr inż. Mirosław KWESIELEWICZ**

Ukończył Wydział Elektryczny Politechniki Gdańskiej w roku 1981 uzyskując tytuł magistra inżyniera elektryka o specjalności automatyka i metrologia przemysłowa. Po ukończeniu studiów został zatrudniony na Wydziale Elektrycznym, gdzie pracuje do chwili obecnej na stanowisku adiunkta. W roku 1990 na tym samym Wydziale otrzymał tytuł doktora nauk technicznych. W roku 1993 przebywał na 12 miesięcznym stażu badawczym na Uniwersytecie Delft w Niderlandach, natomiast w 1996 na 3 miesięcznym stażu TEMPUS IMG na Uniwersytecie Plymouth w Wielkiej Brytanii.



Jego prace badawcze koncentrują się głównie na zastosowaniu metod sztucznej inteligencji w sterowaniu, modelowaniu i optymalizacji. Jest autorem lub współautorem 1 rozprawy, 1 monografii oraz ponad 70 recenzowanych artykułów i referatów.

mkwies@ely.pg.gda.pl

Streszczenie

Praca dotyczy prognozowania zapotrzebowania na wodę w miejskich sieciach wodociągowych. Podaje się czynniki kształtujące zapotrzebowania na wodę oraz dokonuje się analizy porównawczej trzech wybranych metod predykcji, a mianowicie: predyktora neuronowego, predyktora neuronowo-rozmytego oraz metody opartej o uśrednianie pomiarów. Badania symulacyjne pokazały, że przy przyjętych założeniach najlepsze wyniki daje metoda uśredniania.

Abstract

The paper concerns the problem of forecasting a water demand in communal water networks. Factors influencing water demand are characterized. Next three chosen forecasting techniques are analyzed, namely: neural network based predictor, ANFIS predictor and a method based on average value of measurements. Simulation calculation showed that third method was the best one according to taken assumptions.

Słowa kluczowe: Zapotrzebowanie na wodę, predykcja, sztuczne sieci neuronowe

Keywords: Water demand, prediction, artificial neural networks


1. Wprowadzenie

Przez kilka ostatnich lat w miejskich przedsiębiorstwach wodociągowych obserwuje się znaczący spadek zużycia wody przez mieszkańców. Prowadzi to do oczywistego obniżenia dochodów tych przedsiębiorstw, a co za tym idzie do potrzeby bardziej ekonomicznego zarządzania nimi. Jednym z głównych składników ponoszonych przez nie kosztów są koszty energii elektrycznej zamawianej w zakładach energetycznych. Ilość zamawianej energii w większości przedsiębiorstw wodociągowych określana jest wyłącznie na podstawie doświadczeń pracowników zebranych podczas wieloletniej pracy z danym systemem wodociągowym. Poprawne prognozowanie zapotrzebowania na wodę może pozwolić na dokładne obliczenie niezbędnej energii elektrycznej i uniknięcie ponoszenia dodatkowych kosztów związanych z zamówionymi jej nadwyżkami. Znajomość obciążenia sieci wodociągowej pozwala na efektywne stosowanie predykcyjnego sterowania repetycyjnego taką siecią. Znajomość tego obciążenia jest szczególnie istotna dla sieci, w których pojemność zbiorników jest niewielka.

Jak wspomniano obecnie często dokonuje się prognozowania zapotrzebowania na wodę wyłączając kierując się praktyką i doświadczeniem. Stosuje się także analizę statystyczną opartą na danych o wcześniejszych obciążeniach sieci. W podejściu tym zapotrzebowanie na wodę traktuje się jako proces fizyczny o składnikach zarówno deterministycznych jak i probabilistycznych [7]. Proces ten modeluje się jako proces stochastyczny, który na skutek występowania w nim określonego trendu

Mgr inż. Tomasz SŁOMIŃSKI

Ukończył studia na Wydziale Elektrotechniki i Automatyki Politechniki Gdańskiej w roku 1997 i uzyskał dyplom magistra inżyniera automatyka o specjalności Automatyka i Robotyka. W roku 1998 ukończył na Studium Doktoranckim Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej podyplomowe studium specjalistyczne w zakresie elektrotechniki.



i składników o charakterze okresowym jest niestacjonarny. W niniejszej pracy porównuje się trzy metody prognozowania zapotrzebowania na wodę oparte o: (i) sztuczne sieci neuronowe (ii), rozmyty system ekspertowy z metodą wnioskowania Takagi-Sugeno (iii) obliczenie średniej arytmetycznej.

2. Czynniki kształtujące wielkość zapotrzebowania na wodę w sieci wodociągowej

Na wielkość zapotrzebowania na wodę w sieci wodociągowej mają wpływ czynniki często o bardzo różnym charakterze. Można je podzielić na kilka grup:

- Czynniki związane z czasem. Są to: pora roku, dzień tygodnia, godzina, ale także np. dni świąteczne. Czynniki te są zdeterminowane, a ich wpływ na zapotrzebowanie na wodę można określić korzystając z danych archiwalnych dotyczących produkcji wody zbieranych przez sieci wodociągowe.
- Czynniki związane z pogodą. Są to: temperatura aktualna, temperatury ostatnich dni (wykorzystane w celu określenia trendu zmian temperatury), opady aktualne, opady ostatnich dni (również wykorzystywane w celu określenia trendu zmian). Czynniki te mają charakter losowy, ale poprzez powiązanie ich z wynikami pomiarów tych czynników w poprzednich okresach można przewidywać ich wartość, a zatem także i wpływ na wielkość zapotrzebowania na wodę.
- Czynniki związane z wielkością i charakterem rozpatrywanego obszaru. Są to: charakter obszaru (dzielnice mieszkaniowe, obszar przemysłowy, tereny rekreacyjne, itp.), wielkość obszaru (ilość mieszkańców, wielkość zakładów przemysłowych, itp.). Czynniki te są niemal zawsze zdeterminowane i ich wpływ na wielkość zapotrzebowania jest znana.
- Czynniki o charakterze czysto losowym. Na przykład: uszkodzenia sieci powiązane ze znaczną utratą wody. Są to czynniki trudno przewidywalne, a ich wpływ na zapotrzebowanie na wodę, szczególnie w przypadku skumulowania efektów kilku z nich może być znaczący.

Określenie wpływu wszystkich wymienionych czynników na zapotrzebowanie na wodę w sieci wodociągowej jest zadaniem trudnym, a szczególną trudność sprawia określenie istotności każdego z wymienionych czynników. W celu uzyskania jak najlepszej prognozy należy uwzględnić je wszystkie, co niestety prowadzi do znacznego wydłużenia czasu obliczeń. Odrzucenie niektórych z nich lub ograniczenie ich istotności prowadzi do skrócenia czasu obliczeń, ale niestety także zwiększenia prawdopodobieństwa powstania znaczących błędów w prognozowaniu. Należy zatem dokonać doboru kompromisowego umożliwiającego uzyskanie zadowalających wyników w rozsądnym czasie. Najbardziej istotnymi czynnikami są te związane z czasem oraz charakterem i wielkością rozważanego obszaru. Nie można jednak całkowicie zignorować innych czynników, takich jak temperatura czy opady, które, szczególnie w połączeniu z czynnikami o charakterze czysto losowym, mogą znacznie wpływać na obciążenia sieci. Trzeba także zauważyć, iż

w celu wykorzystania wyżej wymienionych czynników do prognozowania należy je dokładnie zmierzyć oraz przedstawić w sposób umożliwiający komputerowe ich przetworzenie.

Wśród danych wejściowych dla sieci powinny znaleźć się wszystkie istotne czynniki kształtujące zapotrzebowanie na wodę, które zostały wymienione wcześniej. Wszystkie wartości tych czynników należy przedstawić w postaci liczbowej, takiej jaką można podać obróbce obliczeniowej (np. przez sieci neuronowe czy predyktor typu ANFIS). Poniżej przedstawiono propozycję takiego przedstawienia:

- Czynniki związane z czasem:
 - Pora roku (oznaczana liczbą od 1 do 365 - numerem dnia w roku)
 - Dzień tygodnia (liczba od 1 do 7)
 - Godzina (liczba od 1 do 24)
 - Dni świąteczne (0 - dzień zwykły, 1 - dzień świąteczny)
- Czynniki związane z pogodą:
 - Temperatura aktualna (liczba oznaczająca temperaturę w °C)
 - Temperatury ostatnich dni (np. suma temperatur maksymalnych dla ostatnich dni)
 - Opady aktualne (np. 0 - brak opadów, 1 - niewielki opad, 2 - średni opad, 3 - obfity opad)
 - Opady ostatnich dni (np. suma opadów (w mm) ostatnich dni)
- Czynniki związane z wielkością i charakterem rozpatrywanego obszaru:
 - Charakter obszaru (dzielnice mieszkaniowe, obszar przemysłowy, tereny rekreacyjne, itp. - każdemu rodzajowi terenu można przyporządkować liczbę: 1, 2, 3,...)
 - Wielkość obszaru (ilość mieszkańców, wielkość zakładów przemysłowych, itp.)

Od ilości uwzględnionych czynników zależeć będzie złożoność struktury predyktora, a co za tym idzie wydłużenie lub skrócenie czasu obliczeń. Część z wymienionych wyżej czynników może okazać się nadmiarowa (prognozy będą dokładne mimo ich pominięcia), ale należy najpierw to sprawdzić, czyli porównać ze sobą prognozy z uwzględnieniem i bez uwzględnienia poszczególnych czynników. Zmniejszenie ilości niezbędnych do prognozowania czynników pozwoli zmniejszyć strukturę predyktora i skrócić czas obliczeń. Z reguły przy sporządzaniu prognoz dla różnych horyzontów czasowych (np. godziny, doby czy roku) wykorzystywane będą różne czynniki. W prognozie dla całego roku nieistotna jest informacja o aktualnych opadach, a istotne są średnie roczne czy miesięczne poboru wody za ostatnie kilka lat. Z kolei przy sporządzaniu prognozy dla kolejnej godziny powinno się wykorzystywać jak najbardziej aktualne informacje i tutaj wiedza o np. bieżących opadach jest bardzo przydatna.

W przypadku, gdy wymienione wyżej dane są niedostępne jedyną drogą wyznaczenia poprawnej prognozy pozostaje posłużenie się danymi o przeszłych obciążeniach sieci wodociągowej.

3. Przegląd wybranych predyktorów do prognozowania obciążenia sieci wodociągowej


Należy zaznaczyć, że wszystkie przedstawione dalej obliczenia związane z rozważanymi metodami oparte są na tym samym zestawie informacji o rzeczywistych obciążeniach systemu wodociągowego jednego ze średnich miast Polski w ciągu roku kalendarzowego 1998, a zatem wyniki poszczególnych metod mogą być porównywane.

Dane te niosą informację o sumarycznym rozbiórce wody każdego dnia w roku, bez rozbicia jej na zużycie własne, straty, produkcję właściwą itp. [5]. Dostępność większej ilości danych do obliczeń mogłoby znacznie poprawić efektywność niektórych metod. Rozbiór wody w poszczególnych dniach (od 1 do 365) przedstawiono na rys. 1.

3.1. Predyktor oparty o sztuczne sieci neuronowe

Do pierwotnych przyczyn preferowania sieci neuronowych ponad metodami tradycyjnymi predykcji szeregów czasowych zaliczamy [8]:

- Wszechstronność: nie wymagają one wyboru określonego modelu (np.: autoregresji, średniej ruchomej, wygładzania wykładniczego,



Rys. 1. Przykładowy rozbiór roczny wody służący do prognozowania zapotrzebowania na wodę.

Fig. 1. Exemplary annual water intake used to water demand forecasting

rozkładu widmowego, itd.). Wystarczy podać na wejście sieci odpowiednio dużą ilość informacji i pozwolić jej je przetworzyć. Sieć sama dokona wyboru odpowiedniego modelu.

- Wysoka tolerancja na dziwne, zaszumione wzorce wraz ze składowymi chaotycznymi, które przez inne metody nie są dobrze tolerowane. Wiele szeregów czasowych zawiera składowe chaotyczne (np. szeregi czasowe odwzorowujące obciążenia sieci energetycznych czy wahania kursów giełdowych).


Niestety sieci neuronowe mają też swoje wady. Można do nich zaliczyć długotrwały proces uczenia sieci, wymagający znacznych mocy obliczeniowych oraz odpowiedniego doboru parametrów uczenia (co wymaga odpowiedniej wiedzy) [10]. Niekiedy też dokładność predykcji przy pomocy sieci neuronowych może być niewystarczająca do rozwiązania danego problemu [4].

Do prognozowania wielkości obciążenia systemu wodociągowego można też zaproponować predyktor liniowy [3]. Ten nowy predyktor składa się z pojedynczego neuronu, na którego wejścia podawane są (z opóźnieniem o 1 krok) wielkości zapotrzebowania na wodę w poprzednich okresach (np. godzinach lub dobach). Neuron adaptuje swoje wagi do uzyskiwanych danych i w ten sposób pozwala na obliczenie kolejnej prognozy. Prognozowanie odbywa się „na bieżąco”, tj. sieć wykorzystuje jedynie informacje o kilku ostatnich pomiarach. Może także wykorzystywać informacje o nieco innym charakterze: np. zamiast ostatnich obciążenia - różnice pomiędzy nimi, itp. Jest ona zatem szybka, niedroga i łatwa w zastosowaniu praktycznym.

Ocena skuteczności prognozowania przy pomocy predyktora neuronowego

Na podstawie danych o obciążeniu sieci wodociągowej uzyskanych z przedsiębiorstwa wodociągów i kanalizacji w jednym z miast Polski dokonano symulacji działania predyktora neuronowego. Sieć neuronowa została symulowana w programie Matlab przy użyciu biblioteki Neural Networks [2]. Zastosowano predyktor w postaci pojedynczego neuronu, na którego wejścia podawane są z opóźnieniem dane o obciążeniu systemu wodociągowego w ostatnich dniach (rys. 2). Na podstawie tych danych sieć przewiduje obciążenie dla kolejnej doby.

Struktura predyktora jest bardzo prosta, składa się on bowiem tylko z jednej warstwy zawierającej tylko jeden neuron. Neuron ten w sposób adaptacyjny uczy się przewidywania kolejnych wartości obciążenia dobowego sieci. Wielkościami wejściowymi są wartości poprzednich obciążenia systemu wodociągowego przedstawiane przy pomocy linii opóźniającej. Wyjście neuronu, czyli predykcja obciążenia w następnym kroku porównywana jest z rzeczywistym obciążeniem sieci wodociągowej i na tej podstawie obliczany jest uchyb predykcji.



Rys. 2. Struktura predyktora neuronowego liniowego z przesuwającą linią opóźniającą [3]: P(t) - sygnał poddawany predykcji, A(t) - predykcja sygnału, E(t) - uchyb predykcji, D - bloki opóźniające sygnał wejściowy o 1 krok, N - ilość sygnałów, na podstawie których dokonywana jest predykcja

Fig. 2. Neural linear predictor structure with a delay: P(t) - signal under prediction, A(t) - predicted signal, E(t) - prediction error, D - delay blocks for input signal, N - number of signals used in prediction

Podczas początkowych iteracji błąd predykcji jest dość znaczny (wynika to z potrzeby adaptacji wag neuronu do danych wejściowych), ale po około 20 iteracjach maleje i utrzymuje się na stałym poziomie.

Jak widać na rys. 1 sygnał, który predyktor musi przewidywać ma naturę w wysokim stopniu „chaotyczną”. Obserwowany przebieg sugeruje losowy charakter danych. Ponieważ zdarza się to tylko na początku obliczeń, gdy neuron nie jest jeszcze nauczone można, te 20 pierwszych pomiarów pominąć podczas analizy błędów. Dla użytkownika sieci wodociągowej ważnym jest, aby błędy predykcji były jak najmniejsze.

Błąd prognozy szeregu czasowego przy pomocy sieci neuronowych

Rezultaty prognozy w danym okresie wybranym przez użytkownika mogą być ocenione dopiero wtedy, gdy znane już są wartości rzeczywiste, czyli pomierzone [9]. Oceny błędów prognozy dokonuje się zawsze poprzez porównanie obliczonej w prognozie wartości dla danej chwili z wielkością rzeczywistą, jaka w danej chwili wystąpiła. Znane są różne miary błędów, takie jak: średni kwadrat błędów (MSE - mean square error), błąd średniokwadratowy (RMS - root mean square), średni błąd względny (MRE - mean relative error), stosunek sygnału do szumu i inne [8]. Rozpatrywać można także błędy absolutne i względne. Większość algorytmów uczenia sieci neuronowych wykorzystuje zasadę minimalizacji błędów średniokwadratowego na wyjściu. Uczenie sieci odbywa się z reguły przy pomocy danych odpowiednio przeskalowanych na potrzeby danej sieci. Do oceny wielkości popełnionych błędów przydatne są też metody graficzne, np. odwzorowanie na jednym wykresie krzywych reprezentujących takie wielkości jak:

- obserwowane zapotrzebowanie
- przewidywane zapotrzebowanie
- błędy predykcji
- histogram błędów predykcji

Błąd predykcji obliczany jest według zależności (1):

$$e(t) = f\left(\sum_{i=1}^{N+1} p_i(t)w_i - b\right) - p(t) \quad (1)$$


3.2. Predyktor neuronowo-rozmyty typu ANFIS

W celu poprawienia dokładności prognoz uzyskiwanych przy pomocy predyktora neuronowego omawianego poprzednio postanowiono zastosować do prognozowania układ neuronowo-rozmyty, o strukturze przedstawionej na rys. 3 [1].


Rozważany predyktor typu ANFIS opiera się o metodę wnioskowania Takagi-Sugeno [6], która przykładowo dla dwóch wejść x i y oraz dwóch reguł przyjmie następującą postać (rys. 4):

- Rule1: if x is A₁ and y is B₁,
then f₁ = p₁x + q₁y + r₁,
- Rule2: if x is A₂ and y is B₂,
then f₂ = p₂x + q₂y + r₂.

Podobnie jak w przypadku predyktora neuronowego układ typu ANFIS (ang. *Artificial Neuro-Fuzzy Inference System*) nie pozwala osiągnąć zadowalającej dokładności w przypadku zbyt dużego udziału czynników losowych w zestawie danych uczących. Do osiągnięcia zadowalających wyników potrzeba większej liczby danych.




Rys. 3. Struktura neuronowo-rozmytego predyktora typu ANFIS
Fig. 3. Structure of a neuro-fuzzy (ANFIS) predictor



Rys. 4. Metoda wnioskowania Takagi-Sugeno dla dwóch reguł
Fig. 4. The two rule first order Takagi-Sugeno fuzzy model

3.3. Metoda uśredniania wyników poprzednich pomiarów

Metoda uśredniania jest bardzo prostą metodą pozwalającą osiągnąć najlepsze wyniki prognozowania w przypadku posiadania danych wejściowych o znacznym udziale czynników losowych. Polega ona po prostu na obliczeniu średniej arytmetycznej (AA - ang. *Arithmetical Average*) z kilku ostatnich pomiarów rzeczywistych i przyjęcie tej liczby za prognozę na okres następny. Metoda ta daje nieco lepsze rezultaty od




Rys. 5. Wyniki predykcji obciążeń sieci wodociągowej przy pomocy metody uśredniania
Fig. 5. Results of water demand prediction with use of an arithmetical average (AA) method

sieci neuronowych i predyktora ANFIS, ponieważ uwzględnia wszelkie trendy zmian wielkości prognozowanej. W zależności od przyjętej liczby pomiarów użytych wstecz do prognozowania następnej wartości obciążenia, metoda ta osiąga różną dokładność. W przypadku danych wejściowych o dużym udziale czynników losowych najlepsze wyniki osiągnięto dla prognozowania na podstawie dwóch wcześniejszych pomiarów. Wyniki takiej symulacji przedstawiono na rys. 5. Jak widać w porównaniu z omówionymi wcześniej metodami predykcji wyniki uzyskane w przypadku uśredniania dają rezultaty obciążone dużo mniejszymi błędami, przez co można polecić stosowanie tej metody w przypadku posiadania bardzo ubożego zasobu danych obliczeniowych dla predyktora.

4. Dyskusja wyników

Efektywność działania trzech omówionych metod prognozowania w przypadku, w którym dostępne są jedynie dane dotyczące rocznej produkcji wody w miejskim przedsiębiorstwie wodociagowym zestawiono na rys. 6. Jak łatwo zauważyć najlepsze wyniki osiąga się przy użyciu prostej metody uśredniania pomiarów. Inne metody, pomimo iż można uznać je za efektywne, dają nieco gorsze rezultaty.



Rys. 6. Rozkład błędów prognozowania wybranych metod w poszczególnych przedziałach wartości procentowych

Fig. 6. Distribution of a prediction error

Z przeprowadzonych badań symulacyjnych wynika, że prognoz obciążonych błędem niższym niż 10% jest:

- 92% dla metody uśredniania pomiarów,
- 82% dla metody z użyciem sieci neuronowych,
- 75% dla metody ANFIS.

Dla metody uśredniania występuje oczywiście najwięcej odpowiedzi obciążonych najmniejszymi błędami. Prognozy z błędem 0-6% stanowią aż 77%. Niestety prognozy obciążone najmniejszymi błędami (0-2%) nie stanowią większości na tyle dużej, aby można było mówić o marginalnym występowaniu prognoz obciążonych większym błędem. Niemniej jednak dokonana predykcję sygnału można uznać za skuteczną. Biorąc pod uwagę bardzo szybkozmenny przebieg wartości docelowej (z takimi przebiegami sieci neuronowe radzą sobie niestety nieco gorzej od przebiegów o wolnozmiennych parametrach) trudno obecnie znaleźć metodę gwarantującą znacząco lepsze rezultaty, jednak należałoby również sprawdzić pod względem możliwości praktycznego zastosowania także inne sposoby prognozowania szeregów czasowych, np. sterowanie predykcyjne. Rozbicie danych wejściowych na poszczególne składowe (produkcję właściwą, zużycie własne, straty, itp.) pozwoliłoby z pewnością na dokładniejszą ich predykcję, a co za tym idzie także na dokładniejszą predykcję obciążenia całej sieci. Można by wówczas zastosować różne sposoby predykcji do poszczególnych składowych. Dla przykładu wiadomym jest, iż wielkość produkcji właściwej w sieci wodociagowej dla poszczególnych dni tygodnia wykazuje charakter okresowy z pewnymi nieznacznymi odchyleniami, np. w dni świąteczne. W takim przypadku z pewnością doskonałe rezultaty można by

otrzymać przy użyciu predyktora neuronowego. Inne składowe (np. zużycie własne) są wielkościami łatwo przewidywalnymi (płukania filtrów czy zbiorników zużywają ściśle określoną ilość wody). Straty w przypadku awarii sieci są najtrudniejszym do predykcji składnikiem i to właśnie one mogą wprowadzać największy błąd do prognozy całkowitej produkcji wody w sieci. Wyniki prognoz w niniejszym artykule dotyczą jednodobowego horyzontu sterowania, który to horyzont jest najbardziej istotny ze względu na sterowanie całą siecią wodociagową (utrzymywanie odpowiednich poziomów w zbiornikach, włączanie i wyłączanie ujęć i stacji pomp). Prognozy dotyczące dłuższych horyzontów czasowych, takich jak tydzień, miesiąc czy rok, niezbędne są jedynie przy planowaniu takich zadań jak remonty i modernizacja sieci czy prognoz finansowych w dłuższym okresie i nie zostały one uwzględnione w niniejszym artykule.

5. Uwagi i wnioski

W pracy dokonano analizy porównawczej trzech wybranych metod prognozowania zapotrzebowania na wodę w miejskich sieciach wodociagowych w oparciu o dane dotyczące rozbioru wody za okres jednego roku z rzeczywistego obiektu. Porównano efektywność predyktora neuronowego, neuronowo-rozmytego oraz metody uśredniania. Na podstawie uzyskanych badań symulacyjnych stwierdzono, że przy przyjętych założeniach najlepsze efekty osiąga się przy użyciu metody uśredniania.

Warto podkreślić, że uzyskanie dodatkowych informacji (np. o czynnikach meteorologicznych czy związanych z wielkością i charakterem rozpatrywanego obszaru) z pewnością pozwoliłoby na poprawienie dokładności metod opartych na koncepcji sieci neuronowych. Autorzy nie dysponują tego typu danymi.

Literatura

- [1] Chin-Teng L., Lee G.C.S., Neural Fuzzy Systems - A Neuro-Fuzzy Synergism to Intelligent Systems. Prentice Hall PTR, 1995.
- [2] Demuth H., Beale M.: Neural Network Toolbox - for use with Matlab. Math Works Inc., 1998.
- [3] Duzinkiewicz K., Wołoszyn M. Neuronowy predyktor anomalii magnetycznych na Morzu Bałtyckim. Metrologia Wspomagana Komputerowo MWK, 1999.
- [4] Herz J., Krogh A., Palmer R.G.: Wstęp do teorii obliczeń neuronowych. WNT, Warszawa 1995.
- [5] Słomiński T., Duzinkiewicz K., Kwiesielewicz M., Trawicki D.: Analiza możliwości zastosowania sztucznych sieci neuronowych do prognozowania zapotrzebowania na wodę w miejskich sieciach wodociagowych. TIASWiK, Stawiska 1999.
- [6] Takagai T., Sugeno M.: Fuzzy identification of systems and its application to modeling and control. IEEE Trans. On SMC 15, 1985.
- [7] Brdyś, M.A., Ulanicki, B., 1994. Operational Control of Water Systems - Structures, Algorithms and Applications. Prentice Hall International (UK).
- [8] Masters, T., 1996. Sieci neuronowe w praktyce: programowanie w języku C++. Wydawnictwo Naukowo-Techniczne, Warszawa.
- [9] Quevedo, J., Cembrano, G., Valls, A., Serra, J., 1998. Time Series Modeling of Water Demand - A Study on Short-Term and Long-Term Predictions, in: Computer Applications in Water Supply, vol. 1: System Analysis and Simulation, eds. B. Coulbeck and Chun-Hou Orr, Research Studies Press Ltd., John Wiley & Sons Inc. Ss. 268-288
- [10] Tadeusiewicz, R., 1993. Sieci Neuronowe. Akademicka Oficyna Wydawnicza, Warszawa.

Title: Review of chosen methods of water demand forecasting in municipal water networks