

Adam Piasecki, Jakub Jurasz, Włodzimierz Marszelewski

Wykorzystanie wielowarstwowych sztucznych sieci neuronowych do średnioterminowego prognozowania poboru wody – studium przypadku

Zapewnienie ciągłości dostawy wody należy do podstawowych zadań przedsiębiorstw wodociągowych. Stąd też niezwykle istotna jest wiedza na temat zapotrzebowania na wodę zarówno w krótkich, jak i długich przedziałach czasu oraz identyfikacja czynników wpływających na wartość zapotrzebowania. Niektóre z tych czynników mają charakter uniwersalny, to znaczy wpływają na fluktuacje poboru wody we wszystkich sieciach wodociągowych. Nie oznacza to jednak, że ich siła oddziaływania jest we wszystkich przypadkach taka sama. Infrastruktura wodociągowa charakteryzuje się dużą specyfiką uzależnioną zarówno od czynników naturalnych (rzeźba terenu, deniwelacje terenu), jak i antropogenicznych (gęstość zabudowy i jej przestrzenne rozmieszczenie). Do prognozowania poboru wody z sieci wodociągowych najczęściej wykorzystywane są stochastyczne modele szeregów czasowych, dzięki którym możliwa jest [1]:

- ocena i modyfikacja modeli wykorzystywanych w modelowaniu przepływu wody w systemach wodociągowych,

- optymalizacja procesu sterowania oczyszczaniem i dystrybucją wody,

- korekta poleceń operacyjnych w procesach oczyszczania i dystrybucji wody, w celu zwiększenia ich sprawności.

W modelach tych końcowy wynik uzyskiwany jest na podstawie pomiarów wejścia i wyjścia z obiektu (obciążonych szumem) z wykorzystaniem różnych metod interpolacyjnych, aproksymacyjnych, analiz szeregów czasowych czy też modeli neuronowych [2]. Prognozowanie poboru wody, ze względu na czas, można podzielić na krótko-, średnio- i długoterminowe. Prognozy krótkoterminowe (godzinowe, dobowe) wykorzystywane są głównie w celu zapewnienia sprawnego bieżącego funkcjonowania systemu wodociągowego, w tym przede wszystkim minimalizacji czasu przebywania wody w sieci wodociągowej i zbiornikach magazynujących, zapewniając tym samym jej dobrą jakość [3]. Średnio- i długoterminowe (miesięczne i roczne) prognozy dostarczają przedsiębiorstwom wodociągowym przede wszystkim informacji na temat kształtowania się zapotrzebowania na wodę. Dzięki temu

przedsiębiorstwa wodociągowe mogą odpowiednio kształtować swoją politykę wewnętrzną i inwestycyjną dotyczącą między innymi budowy nowych ujęć wody i rozbudowy sieci wodociągowej.

Trafność prognozowanego poboru wody zależy przede wszystkim od zmiennych uwzględnionych w przyjętym modelu. W wielu pracach dowiedziono lepszej skuteczności sztucznych sieci neuronowych (SSN) w zakresie prognozowania poboru wody, w porównaniu do metod tradycyjnych, takich jak analiza szeregów czasowych i modele regresji [4–6]. Sztuczne sieci neuronowe zostały również z sukcesem zastosowane do prognozowania zapotrzebowania na wodę [7, 8].

Cel i obszar badań

Głównym celem pracy było wykorzystanie sztucznych sieci neuronowych w prognozowaniu miesięcznego poboru wody w jednej z dzielnic Torunia. Realizacja tak postawionego celu wymagała w pierwszej kolejności identyfikacji głównych czynników mających zasadniczy wpływ na prognozowany proces. Analizie poddano system wodociągowy zaopatrujący w wodę niewielką dzielnicę Torunia – Czerniewice, położoną w południowo-wschodniej części miasta. Wybór tej dzielnicy wynikał ze specyfiki miejskiego systemu wodociągowego. Toruń ma bardzo dobrze rozwiniętą sieć wodociągową, której łączna długość wynosi około 550 km.

Woda ujmowana jest z trzech ujęć – Drwęca-Jedwabno (ujęcie infiltracyjno-powierzchniowe), Mała Nieszawka (ujęcie głębinowe) i Czerniewice (ujęcie głębinowe). Woda z pierwszych dwóch ujęć tłoczona jest do sieci tworzącej jeden zintegrowany system wodociągowy, natomiast dzielnica Czerniewice, oddalona o około 7 km od centrum miasta, ma osobny system wodociągowy, który jest zaopatrywany w wodę z niewielkiego ujęcia głębinowego zlokalizowanego na obszarze tej dzielnicy. Jakość ujmowanej wody podziemnej jest tak dobra, że nie wymaga ona oczyszczania [9]. Brak połączenia z systemem wodociągowym miasta zdecydował o wyborze systemu wodociągowego dzielnicy Czerniewice do szczegółowych analiz. Na wybranym obszarze nie ma zakładów przemysłowych, dzięki czemu możliwa była trafniejsza identyfikacja czynników wpływających na pobór wody przez gospodarstwa domowe i zakłady usługowe. W rezultacie umożliwiło to dobranie odpowiednich zmiennych do modelu prognozującego pobór wody.

Mgr A. Piasecki, dr hab. W. Marszelewski: Uniwersytet Mikołaja Kopernika w Toruniu, Wydział Nauk o Ziemi, Katedra Hydrologii i Gospodarki Wodnej, ul. Lwowska 1, 87-100 Toruń, marszel@umk.pl

Mgr inż. J. Jurasz: AGH Akademia Górniczo-Hutnicza, Wydział Zarządzania, Katedra Inżynierii Zarządzania, aleja Adama Mickiewicza 30, 30-059 Kraków

Materiały i metody

W pracy wykorzystano dane udostępnione przez przedsiębiorstwo Toruńskie Wodociągi Sp. z o.o. Zawierały one informacje dotyczące eksploatacji systemu wodociągowego w dzielnicy Czerniewice z lat 2000–2012, w tym między innymi:

- miesięczny pobór wody (P_w),
- liczba osób korzystających z wodociągu (L_o),

Ponadto uwzględniono następujące dane meteorologiczne:

- maksymalna miesięczna temperatura powietrza (T_{maks}),
- minimalna miesięczna temperatura powietrza (T_{min}),
- średnia miesięczna temperatura powietrza (T_s),
- wysokość sumy opadów atmosferycznych (H_s),
- wilgotność powietrza (W_p),
- parowanie (ewapotranspiracja wskaźnikowa) (E_w),

obliczone metodą Penmana-Monteitha.

Wykorzystano również dane uzyskane z Urzędu Miasta w Toruniu, dotyczące kształtowania się cen wody w mieście (C_w), a także dane GUS o wysokości średniego rocznego wynagrodzenia w Toruniu (Z_s), które przeliczono na średnie miesięczne. Podstawowe charakterystyki statystyczne wykorzystanych parametrów zamieszczono w tabeli 1.

Tabela 1. Charakterystyka statystyczna zmiennych objaśniających i zmiennej objaśnianej w latach 2000–2012

Table 1. Statistical characteristics of explanatory variables and a dependent variable in the period of 2000–2012

Zmienna	X_{maks}	X_{min}	X_{sr}	S_x
P_w , m ³	21380	2377	8772	3349
Z_s , zł	39917	19355	28380	6772
L_o	2183	720	1466	461
H_s , mmH ₂ O	227,0	1,0	47,6	37,6
T_s , °C	23,0	-8,1	8,9	7,6
W_p , %	93,5	50,0	76,0	10,2
C_w , zł/m ³	3,33	1,13	2,05	0,69
T_{min} , °C	15,7	-12,2	4,0	6,6
T_{maks} , °C	30,0	-5,1	13,4	8,0
E_w , mmH ₂ O	5,20	0,20	1,98	1,41

Poprawne wykorzystanie sieci neuronowych wymaga przeprowadzanie wielu czynności mających na celu zagwarantowanie uzyskania właściwych wyników. Pracę z użyciem SSN można podzielić na następujące etapy:

- pozyskanie oraz statystyczna obróbka danych, które reprezentują analizowane zjawisko,
- dobór odpowiedniej architektury SSN,
- wybór metody uczenia SSN,
- krytyczna analiza uzyskanej prognozy.

Dobór odpowiednich zmiennych wejściowych jest problemem złożonym i bardzo istotnym z punktu widzenia jakości prognozy. Krytyczną ocenę metod doboru zmiennych zaproponowano w pracy [10], wyróżniając w obszarze modelowania zasobów wodnych następujące sposoby określania zbioru danych wejściowych:

- opierające się na wykorzystaniu wiedzy na temat funkcjonowania systemu, który będzie modelowany,
- wykorzystujące analizę współzmienności zmiennych na podstawie współczynnika korelacji,

- heurystyczne, polegające na przykład na uczeniu różnych modeli SSN w oparciu o krokowe dodawanie kolejnych zmiennych,

- pozyskujące wiedzę z uczonej SSN w oparciu o analizę wrażliwości,

- będące kombinacją narzędzi wykorzystywanych w różnych metodach.

W niniejszej pracy przyjęto podejście hybrydowe, łączące zalety poszczególnych metod. Dobór zmiennych objaśniających podzielono na dwa etapy – w pierwszym dokonano analizy wykresów poszczególnych zmiennych w celu identyfikacji nieregularności, braków lub zbieżności, natomiast drugi etap polegał na zbudowaniu macierzy reprezentującej wzajemną korelację między zmiennymi wejściowymi i zmienną wyjściową, czyli poborem wody. Kolejnym krokiem było stworzenie modeli z użyciem wielu zmiennych wejściowych na podstawie metody przedstawionej w pracy [11]. Sam proces uczenia sieci neuronowych przeprowadzono w programie Statistica, przyjmując następujące założenia dotyczące liczebności zbiorów:

- uczącego: 110 przypadków,
- testowego: 23 przypadki,
- walidacyjnego: 23 przypadki.

Zaszeregowanie do poszczególnych przypadków oparto na narzędziu automatycznym dostępnym w oprogramowaniu Statistica, którego działanie polega na losowym podziale zbioru na podstawie wartości losowej generatora na podzbiór uczący 70% próbek oraz podzbiory testowy i walidacyjny po 15%. W celu poprawnego zaszeregowania i uniknięcia błędów trzeciego rodzaju [12] oraz właściwej oceny modelu predykcyjnego, dokonano sprawdzenia krzyżowego w postaci k-krotnej walidacji ($k=10$), co oznaczało, że procedurę podziału zbioru na odpowiednie podzbiory powtórzono 10-krotnie, a następnie obliczono wartość średnią z uzyskanych wyników zbioru testowego.


Sieci były budowane na podstawie „Automatycznego poszukiwania sieci”, przy czym przyjęto, że powstanie 200 wielowarstwowych sieci neuronowych (multi layer perceptron – MLP), w których minimalna liczba ukrytych neuronów wyniesie 3, natomiast maksymalna – 10. Należy zauważyć, że problematyka ustalania liczby neuronów w warstwie ukrytej jest zagadnieniem budzącym wiele wątpliwości [13]. Jak wynika z pracy [14], duże sieci (z wieloma neuronami w warstwie ukrytej) mogą uczyć się rozwiązywać problemy szybciej, lecz niekoniecznie lepiej. Ponadto dokładność prognozowania nie rośnie proporcjonalnie wraz z liczbą neuronów w warstwie ukrytej. Procedurę budowy sieci rozpoczyna się z małą liczbą neuronów w warstwie ukrytej, stopniowo ją zwiększając i obserwując jakość wyników. Dążąc do jednoznaczności w określeniu liczby neuronów w warstwie ukrytej posłużono się opracowanym w pracy [15] założeniem, że minimalna liczba neuronów ukrytych to pierwiastek z iloczynu liczby neuronów w warstwie ukrytej i wyjściowej, natomiast maksymalna to 3-krotna wartość minimalnej liczby neuronów plus jeden. W każdym z analizowanych przypadków przeanalizowano 200 wariantów różnych architektur sieci typu MLP. Wartość ta wynikała z liczby możliwych kombinacji architektur, przy uwzględnieniu 8 różnych liczb neuronów w warstwie ukrytej oraz 5 różnych funkcji aktywacji, odpowiednio w warstwie ukrytej i wyjściowej ($8 \cdot 5 = 200$). Ocenę sieci wykonano na podstawie błędów prognozy w odniesieniu do zbiorów przypadków uczących, testowych oraz walidacyjnych.

Tabela 2. Macierz korelacji zmiennych objaśniających i zmiennej objaśnianej
Table 2. Matrix of correlation coefficients among explanatory variables and a dependent variable

Zmienna	P_w	Z_s	L_o	H_s	T_s	W_p	C_w	T_{min}	T_{maks}	E_w
P_w	1	0,65	0,71	0,00	0,41	-0,43	0,60	0,42	0,37	0,47
Z_s	0,65	1	0,96	-0,02	-0,02	0,06	0,98	-0,01	-0,02	-0,06
L_o	0,71	0,96	1	-0,04	-0,02	0,04	0,92	-0,02	-0,03	-0,03
H_s	0,00	-0,02	-0,04	1	0,42	-0,01	-0,02	0,38	0,48	0,36
T_s	0,41	-0,02	-0,02	0,42	1	-0,71	-0,02	0,99	0,98	0,91
W_p	-0,43	0,06	0,04	-0,01	-0,71	1	0,06	-0,76	-0,59	-0,84
C_w	0,60	0,98	0,92	-0,02	-0,02	0,06	1	-0,02	-0,03	-0,06
T_{min}	0,42	-0,01	-0,02	0,38	0,99	-0,76	-0,02	1	0,96	0,92
T_{maks}	0,37	-0,02	-0,03	0,48	0,98	-0,59	-0,03	0,96	1	0,86
E_w	0,47	-0,06	-0,03	0,36	0,91	-0,84	-0,06	0,92	0,86	1

Wyniki

Na analizowanym obszarze Torunia w ostatnich latach stwierdzono systematyczne zwiększanie się ilości pobieranej wody (rys. 1) – w latach 2000–2012 ten łączny przyrost wyniósł ponad 67%.



Rys. 1. Miesięczna zmienność poboru wody w latach 2000–2012

Fig. 1. Monthly variability in water consumption for the period of 2000–2012

Jest to tendencja przeciwna od obserwowanej w innych miastach Polski [16]. Do najważniejszych przyczyn obserwowanego zwiększenia zapotrzebowania na wodę w analizowanej dzielnicy Torunia można zaliczyć:

- młoda i wciąż rozwijająca się, atrakcyjnie położona, dzielnica,
- brak przemysłu,
- zabudowa jednorodzinna (z ogródkami i trawnikami) stanowi znaczący odsetek istniejących i nowo powstających budynków,
- dużą część mieszkańców stanowią osoby zamożne, które nie muszą liczyć się z kosztami zużycia wody (np. na podlewanie przydomowej zieleni).

Analiza macierzy korelacji (tab. 2) wykazała brak silnego związku między zmiennymi wejściowymi i zmienną wyjściową (P_w – pobór wody). Stwierdzono natomiast silną współzależność między poszczególnymi zmiennymi, których występowanie było uzasadnione. Jedną ze zmiennych (H_s – wysokość sumy opadów) była w sposób pomijalnie mały skorelowana ze zmienną wyjściową (P_w). Przyjmując jednak, że wszystkie zgromadzone zmienne wejściowe mają istotny wpływ na zmienną wyjściową, pobór wody można zapisać w postaci funkcji:

$$P_w = f(Z_s, L_o, H_s, T_s, W_p, C_w, T_{min}, T_{maks}, E_w) \quad (1)$$

Należy zauważyć, że zgromadzone przez autorów zmienne objaśniające nie wyczerpują zbioru zmiennych wpływających na kształtowanie się poboru wody, na co wskazują małe wartości współczynnika korelacji (tab. 2). Przy dziesięciu zmiennych wejściowych liczba możliwych kombinacji wejść do sieci neuronowej wyniosła 511. Wykorzystanie metody eliminacji zaproponowanej przez autorów pracy [11] pozwoliło na ograniczenie liczby kombinacji (i tym samym modeli) do ośmiu. Strukturę wybranych sieci w przypadku poszczególnych modeli przedstawiono w tabeli 3, natomiast tabela 4 zawiera między innymi strukturę, funkcję aktywacji oraz algorytm uczenia najlepszych SSN uzyskanych w programie Statistica.

Tabela 3. Struktura zmiennych wejściowych modeli
Table 3. Input variables structure for individual models

Model	Zmienne wejściowe	Zmienna wyjściowa
M1	Z_s, L_o, C_w, E_w	P_w
M2	Z_s, L_o, C_w, W_p	
M3	Z_s, L_o, C_w, T_s	
M4	Z_s, L_o, C_w, T_{min}	
M5	Z_s, L_o, C_w, T_{maks}	
M6	$Z_s, L_o, C_w, T_{maks}, W_p$	
M7	$Z_s, L_o, C_w, T_{maks}, H_s$	
M8	$Z_s, L_o, C_w, H_s, T_s, E_w, T_{min}, T_{maks}, E_w$	

Uzyskane modele oceniono na podstawie wartości współczynnika korelacji wejścia do wyjścia z modelu (CC), jakości modelu (E) [17], średniego błędu kwadratowego wartości średniej (root mean squared error – RMSE) oraz znormalizowanego średniego błędu kwadratowego wartości średniej (normalized root mean square error – NRMSE), opisanych następującymi zależnościami:

$$E = 1 - \frac{\sum_{i=1}^n (P_w^{obs} - P_w^{progn})^2}{\sum_{i=1}^n (P_w^{obs} - P_w^{sr})^2} \quad (2)$$

$$RMSE = \frac{1}{n} \sum_{i=1}^n (P_w^{obs_i} - P_w^{progn_i})^2 \quad (3)$$

$$NRMSE = \frac{RMSE}{\frac{1}{n} \sum_{i=1}^n P_w^{obs_i}} \quad (4)$$

Tabela 4. Charakterystyka sztucznych sieci neuronowych uzyskana w programie STATISTICA
Table 4. Characteristics of artificial neural networks generated by STATISTICA software

Model	Struktura	Jakość			Algorytm uczenia	Funkcja aktywacji	
		uczenia	testowania	walidacji		warstwa ukryta	warstwa wyjściowa
M1	4-8-1	0,864	0,757	0,910	BFGS 7	liniowa	wykładnicza
M2	4-3-1	0,885	0,800	0,822	BFGS 14	logarytmiczna	logarytmiczna
M3	4-4-1	0,791	0,767	0,900	BFGS 7	liniowa	wykładnicza
M4	4-5-1	0,780	0,758	0,852			
M5	4-9-1	0,798	0,773	0,894	BFGS 8	tangens hiperb.	
M6	5-3-1	0,963	0,953	0,877	BFGS 44	liniowa	
M7		0,836	0,801	0,892	BFGS 11		
M8	9-4-1	0,872	0,769	0,879	BFGS 9		

Wartości poszczególnych wskaźników wykorzystanych do oceny prognoz uzyskiwanych na podstawie poszczególnych modeli sztucznych sieci neuronowych przedstawiono w tabeli 5.

Tabela 5. Wskaźniki jakości prognoz wg poszczególnych modeli
Table 5. Performance quality indexes according to individual models

Model	Kryterium			
	E	RMSE	CC	NRMSE
M1	0,707	1812,1	0,849	0,207
M2	0,720	1772,9	0,868	0,202
M3	0,570	2195,8	0,782	0,250
M4	0,557	2227,7	0,766	0,254
M5	0,584	2160,4	0,791	0,246
M6	0,901	1052,5	0,950	0,120
M7	0,676	1906,2	0,831	0,217
M8	0,707	1812,9	0,861	0,207

W celu porównania modeli w zakresie błędów powstających w procesie uczenia, testowania oraz walidacji posłużono się wzorem na średni bezwzględny błąd procentowy (mean absolute percentage error – MAPE):

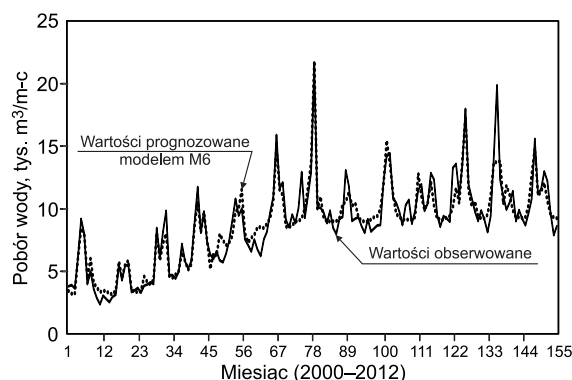
$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_w^{obs_i} - P_w^{progn_i}}{P_w^{obs_i}} \right| 100 \quad (5)$$

Wartości tego błędu zawiera tabela 6.

Tabela 6. Wartości błędu typu MAPE poszczególnych zbiorów
Table 6. MAPE error values for individual sets

Model	Średni bezwzględny błąd procentowy (MAPE), %		
	uczenia	testowania	walidacji
M1	21,44	22,91	12,95
M2	19,18	21,36	15,19
M3	24,16	21,82	14,61
M4	25,14	22,95	14,79
M5	24,87	22,68	14,87
M6	8,37	8,88	10,85
M7	22,52	22,70	13,66
M8	23,36	25,16	15,95

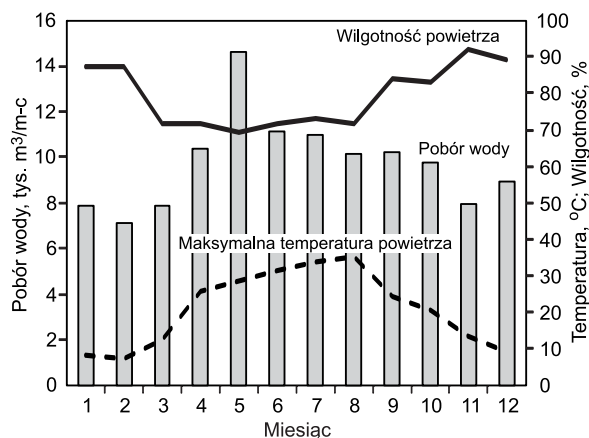
Ocenę i jakość prognozy z użyciem uzyskanych modeli sieci wykonano na podstawie wartości poszczególnych parametrów zebranych w tabelach 4–6. Model M6 (rys. 2), cechujący się najlepszą dokładnością prognozy w przypadku zbioru danych walidacyjnych, opierał się na zbiorze zmiennych wejściowych, w skład których wchodziły takie parametry, jak średnie wynagrodzenie miesięczne (Z_s), liczba osób korzystających z wodociągu (L_o), cena wody (C_w), maksymalna temperatura powietrza (T_{maks}) oraz wilgotność powietrza (W_p).



Rys. 2. Dopasowanie prognozy z użyciem modelu M6 do rzeczywistego poboru wody

Fig. 2. M6 model forecast fit to the real water consumption

W przypadku tego modelu wartość MAPE dotycząca zbiorów uczącego, testującego oraz walidacyjnego wynosiła odpowiednio 8,37%, 8,88% i 10,85%. Były to wartości od 3- do 1,5-krotnie lepsze niż w przypadku pozostałych modeli. Na trafność prognoz tej sztucznej sieci neuronowej, w porównaniu do innych, wskazuje również korzystna wartość kryteriów E oraz CC zbliżająca się do jedności. Analogiczne wnioski dotyczyły oceny błędów typu RMSE oraz NRMSE, które w przypadku wybranego modelu (M6) osiągnęły najkorzystniejsze wartości na tle pozostałych – minimalną RMSE oraz maksymalną NRMSE. Model prognostyczny M6 oceniono dodatkowo na podstawie danych niebiorących udziału w analizie. Prognozę wykonano na 2013 r., w którym uwzględnione parametry meteorologiczne oraz pobór wody kształtowały się tak, jak na rysunku 3, natomiast liczba mieszkańców oraz koszt jednostkowy wody wynosiły odpowiednio 2190 oraz 3,61 zł/m³. Przy tych danych wartość błędu typu MAPE wyniosła 10,95%, co było wartością nieznacznie gorszą (o 0,1%) od rezultatów osiąganych przez model M6 w przypadku zbioru testowego.



Rys. 3. Zmienność poboru wody oraz wybranych parametrów meteorologicznych w 2013 r.

Fig. 3. Variability of water consumption and selected meteorological parameters in 2013

Wnioski

♦ Analiza prognozowania poboru wody z wykorzystaniem sieci neuronowych potwierdziła użyteczność tej metody w badanym zakresie i może być proponowana jako alternatywa dla stosowanego obecnie (w Toruńskich Wodociągach Sp. z o.o.) modelu addytywnego szeregu czasowego, w przypadku którego wartość błędu typu MAPE wynosi 16,2%.

♦ Najlepszą jakość prognozy (ocenioną na podstawie wartości błędu typu MAPE) uzyskano w przypadku modelu M6, zbudowanego na podstawie następujących zmiennych: liczba osób korzystających z wodociągu, cena wody, maksymalna temperatura powietrza, wilgotność powietrza oraz średni dochód na mieszkańca.

♦ W prognozowaniu poboru wody odrzucono niektóre ze zmiennych, które wydawałyby się w sposób naturalny wpływać na jej zużycie, w tym głównie wysokość opadów atmosferycznych. Specyfika tego parametru meteorologicznego polega na tym, że występuje on zazwyczaj z dużym nasileniem jedynie w ciągu kilku dni w miesiącu. Z tego też względu parametr ten będzie miał znaczenie w przypadku prognozowania krótkoterminowego. Dotyczy to zwłaszcza poboru wody w ujęciu dobowym [18, 19], przy czym stwierdzono brak tej zależności w krótszych przedziałach czasu (pobór godzinowy) [20].

♦ Zakres zmiennych uwzględnionych w prognozowaniu poboru wody za pomocą sieci neuronowych wymaga dostosowania do warunków lokalnych, czego potwierdzeniem jest fakt, że nie wszystkie zmienne uwzględnione w innych pracach [7, 8] dotyczących analizowanego zagadnienia okazały się istotne w rozpatrywanym przypadku.

♦ Wykorzystanie wszystkich zgromadzonych i jednocześnie korelujących z poborem wody zmiennych wejściowych w budowie modelu sztucznej sieci neuronowej nie jest jednoznaczne z uzyskaniem najlepszych jakościowo prognoz. W analizowanym przykładzie lepiej sprawdziły się sztuczne sieci neuronowe z ograniczoną liczbą zmiennych objaśniających.

LITERATURA

1. J. ŁOMOTOWSKI, Z. SIWOŃ: Metodyka analizy danych pochodzących z monitoringu systemów wodociągowo-kanalizacyjnych. *Gaz, Woda i Technika Sanitarna* 2010, nr 3, ss. 16–20.

2. Z. SIWOŃ, W. CIEŻAK, J. CIEŻAK: Modele neuronowe szeregów czasowych godzinowego poboru wody w osiedlach mieszkaniowych (Neural network models of hourly water demand time series in housing areas). *Ochrona Środowiska* 2011, vol. 33, nr 2, ss. 23–26.

3. J. ZHANG, R. SONG, N. BHASKAR, M. FRENCH: Short-term water demand forecasting: A case study. Proc. of 8th Annual Water Distribution Systems Analysis Symposium, ASCE Library, Cincinnati 2008, pp. 1–14.

4. A. JAIN, A. K. VARSHNEY, U. C. JOSHI: Short term water demand forecast modeling at IIT Kanpur using artificial neural networks. *Water Resources Management* 2001, Vol. 15, No. 5, pp. 299–321.

5. J. F. ADAMOWSKI: Peak daily water demand forecasting modeling using artificial neural networks. *Journal of Water Resources Planning and Management* 2008, Vol. 134, No. 2, pp. 119–128.

6. J. BOUGADIS, K. ADAMOWSKI, R. DIDUCH: Short term municipal water demand forecasting. *Hydrological Processes* 2005, Vol. 19, No. 1, pp. 137–148.

7. L. S. ILIADIS, F. MARIS: An artificial neural network model for mountainous water resources management: The case of Cyprus mountain watersheds. *Environmental Modeling & Software* 2007, Vol. 22, No. 7, pp. 1066–1072.

8. J. LIU, H. H. G. SAVENIJE, J. XU: Forecast of water demand in Weinan city in China using WDF-ANN model. *Physics and Chemistry of the Earth* 2003, Vol. 28, pp. 219–224.

9. A. PIASECKI, W. MARSZELEWSKI: Krótkookresowa dynamika zmian wody włączanej do miejskiego systemu wodociągowego na przykładzie Torunia – analiza wstępna. W: T. CIUPA, R. SULIGOWSKI [red.]: Woda w mieście. UJK w Kielcach, Kielce 2014, t. 2, ss. 205–213.

10. G. J. BOWDEN, G. C. DANDY, H. R. MAIER: Input determination for neural network models in water resources applications. Part 1 – background and methodology. *Journal of Hydrology* 2005, Vol. 301, No. 1–4, pp. 75–92.

11. M. S. BABEL, V. R. SHINDE: Identifying prominent explanatory variables for water demand prediction using artificial neural networks: A case study of Bangkok. *Water Resources Management* 2011, Vol. 25, No. 6, pp. 1653–1676.

12. F. MOSTELLER: A k-sample slippage test for an extreme population. In: Selected Papers of Frederick Mosteller, Springer, New York 2006, pp. 101–109.

13. T. KAVZOGLU: Determining optimum structure for artificial neural networks. Proc. of the 25th Annual Technical Conference and Exhibition of the Remote Sensing Society, Cardiff (UK) 1999, pp. 675–682.

14. K. G. SHEELA, S. N. DEEPA: Review on methods to fix number of hidden neurons in neural networks. *Mathematical Problems in Engineering* 2013, pp. 1–11.

15. K. SHIBATA, Y. IKEDA: Effect of number of hidden neurons on learning in large-scale layered neural networks. Proc. of the ICROS-SICE International Joint Conference, 2009, pp. 5008–5013.

16. H. HOTŁOŚ: Badania zmian poboru wody w wybranych miastach Polski w latach 1990–2008 (Variations in water consumption observed in some municipalities in the time span of 1990 to 2008). *Ochrona Środowiska* 2010, vol. 32, nr 3, ss. 39–42.

17. J. E. NASH, J. V. SUTCLIFFE: River flow forecasting through conceptual models part I – A discussion of principles. *Journal of Hydrology* 1970, Vol. 10, No. 3, pp. 282–290.

18. J. F. ADAMOWSKI: Peak daily water demand forecast modeling using artificial neural networks. *Journal of Water Resources Planning and Management* 2008, Vol. 134, No. 2, pp. 119–128.

19. H. HOTŁOŚ: Analiza wpływu czynników meteorologicznych na zmienność poboru wody w miejskim systemie wodociągowym (Analysis of influence of meteorological factors on water uptake variations in municipal water supply system). *Ochrona Środowiska* 2013, vol. 35, nr 2, ss. 57–62.

20. S. GATO: Forecasting urban residential water demand. Doctoral dissertation, RMIT University, Melbourne 2006.

Piasecki, A., Jurasz, J., Marszelewski, W. Application of Multilayer Perceptron Artificial Neural Networks to Mid-Term Water Consumption Forecasting – A Case Study. *Ochrona Srodowiska* 2016, Vol. 38, No. 2, pp. 17–22.

Abstract: Multilayer perceptron (MLP) artificial neural networks were employed to monthly water consumption forecasting. Research encompassed Czerniewice, one of the estates in Torun with a dedicated waterworks system (different from the other part of the town). Initially, nine exogenous variables describing meteorological, economic and social conditions were examined. The forecasting process revealed that implementation of all input variables correlating with water

consumption did not lead to the highest quality forecasts. In terms of quality, the best result (evaluated based on MAPE criterion) was achieved for a model built on variables such as number of residents with access to waterworks, water rate, maximum temperature and humidity, and average income per inhabitant. It was demonstrated that the selection of input variables used for water consumption forecasting should be adjusted to local conditions. In the example considered, artificial neural networks proved useful in mid-term water consumption forecasting.

Keywords: Water supply system, water consumption, forecasting, artificial neural networks, exogenous variable.