

Ewa Wąsik, Krzysztof Chmielowski, Jan Studziński, Bartosz Szelağ

Zastosowanie sztucznych sieci neuronowych do prognozowania zawartości azotu ogólnego w odpływie z oczyszczalni ścieków

W Dyrektywie Rady 91/271/EWG z 21 maja 1991 r., dotyczącej oczyszczania ścieków komunalnych, zostały określone wymagania dotyczące związków biogenych w oczyszczalniach na obszarach wrażliwych podlegających eutrofizacji [1]. Obszar Polski, który jest w 99,7% położony w zlewisku Bałtyku, uznaje się za należący do obszarów wrażliwych, co oznacza istotne ograniczenia w zawartości związków azotu i fosforu w ściekach wprowadzanych do odbiorników. Dopuszczalną zawartość związków biogenych lub minimalną skuteczność ich usuwania ze ścieków bytowych lub komunalnych wprowadzanych do wód lub do ziemi określa rozporządzenie Ministra Środowiska z 18 listopada 2014 r., przy czym wymagania te odnoszą się do średniej rocznej wartości danego wskaźnika z próbek średnich dobowych pobranych w analizowanym roku [2].

Azot ogólny jest sumą form azotu nieorganicznego (azot amonowy – NH_4^+ , azotany – NO_3^- , azotyny – NO_2^-) oraz azotu organicznego. Ścieki pochodzące ze źródeł komunalnych zawierają azot ogólny głównie w postaci jonów amonowych [3–5]. W procesach biologicznych przebiegających w komorach nitrifikacji zachodzą reakcje utleniania jonów NH_4^+ do NO_2^- (nitracja) oraz kolejno do NO_3^- (nitratacja) [6]. Produktami prawidłowo przebiegającej nitrifikacji są zatem nieznaczne ilości azotynów oraz azotany. Te ostatnie mogą być redukowane do jonów NH_4^+ na drodze asymilacji, a następnie wbudowywane w biomasę komórek bakterii. Innym sposobem usuwania azotanów jest proces biologicznej denitryfikacji (redukcji dysymilacyjnej), którego końcowymi produktami są gazowe formy azotu – tlenki azotu i azot cząsteczkowy [6].

Jednym z głównych parametrów wpływających na przebieg i skuteczność procesów nitrifikacji i denitryfikacji jest temperatura, co wykazano na przykład w pracach [7, 8]. Stwierdzono także wysokie wartości ujemnej korelacji (52÷65%) między temperaturą ścieków i różnymi postaciami azotu [5, 9]. Aby zwiększyć niezawodność eksploatacji oczyszczalni ścieków coraz częściej stosuje się system

pomiarów ciągłych, obejmujących – obok ilości – także jakość oczyszczanych ścieków. Z tego względu ważną wydaje się kontrola nie tylko ilości azotu ogólnego w ściekach odpływających z oczyszczalni, lecz również jego postaci nieorganicznych.

Wartości parametrów istotnych w procesie oczyszczania ścieków, takich jak ilość ścieków dopływających do oczyszczalni [10–13], jakość ścieków oczyszczonych odprowadzanych do odbiornika [14–18] czy właściwości sedymentacyjne osadu czynnego [19–23], mogą być prognozowane z użyciem sztucznych sieci neuronowych (artificial neural network – SSN). Liczba zastosowań sieci neuronowych w inżynierii środowiska jest coraz większa [24], chociaż wciąż pozostaje na mniejszym poziomie niż liczba ich zastosowań w medycynie czy ekonomii. Głównym powodem popularności sztucznych sieci neuronowych jest łatwość tworzenia modeli za pomocą różnego oprogramowania [25]. Zasada konstruowania modeli z użyciem sztucznych sieci neuronowych opiera się na procesie ich uczenia na podstawie danych dostarczonych w formie przykładów – wzorców uczących. Tworzą one zbiór zwany uczącym, który stanowi główne źródło wiedzy wykorzystywanej przez sztuczne sieci neuronowe. Można przyjąć, że im więcej danych zostanie wykorzystanych w procesie ich uczenia, tym model prognozy będzie dokładniejszy, przy czym należy zachować właściwe proporcje pomiędzy liczbą zmiennych na wejściu (zmiennie niezależne) i wyjściu (zmiennie zależne) oraz umiar w dążeniu do uzyskania maksymalnie dużej dokładności modelu, tak aby nie doprowadzić do „przeuczenia” sieci [26].

Klasyfikacyjny model perceptronu, na którym oparty jest najbardziej popularny typ sztucznej sieci neuronowej, składa się z warstwy wejściowej (zawierającej pewną liczbę neuronów o progowej funkcji aktywacji) oraz jednego neuronu w warstwie wyjściowej [27, 28]. Perceptron wielowarstwowy (multi-layer perceptron – MLP) jest powszechnie stosowaną strukturą nieliniowej sieci neuronowej. Oprócz warstwy wejściowej i warstwy wyjściowej ma on co najmniej jedną warstwę ukrytą. Sygnały wejściowe są najpierw przemnażane przez wartości wag, a następnie kolejno przekazywane do neuronów warstwy ukrytej. W poszczególnych neuronach tej warstwy odbywa się ich sumowanie, a uzyskane sumy są poddawane transformacji za pomocą liniowej lub nieliniowej funkcji aktywacji i przekazywane do neuronów wyjściowych. Optymalny dobór wartości wag przy poszczególnych neuronach odbywa się na drodze uczenia i poddawany jest procesowi testowania oraz walidacji [29].

Dr inż. E. Wąsik, dr hab. inż. K. Chmielowski: Uniwersytet Rolniczy w Krakowie, Wydział Inżynierii Środowiska i Geodezji, Katedra Inżynierii Sanitarnej i Gospodarki Wodnej, al. Adama Mickiewicza 24/28, 30-059 Kraków
ewa.wasik@urk.edu.pl, krzysztof.chmielowski@urk.edu.pl

Dr hab. inż. J. Studziński: Instytut Badań Systemowych Polskiej Akademii Nauk, Centrum Zastosowań Informatyki w Inżynierii Środowiska, ul. Newelska 6, 01-447 Warszawa, jan.studzinski@ibspan.waw.pl

Dr inż. B. Szelağ: Politechnika Świętokrzyska w Kielcach, Wydział Inżynierii Środowiska, Geomatyki i Energetyki, Katedra Geotechniki, Geomatyki i Gospodarki Odpadami, al. Tysiąclecia Państwa Polskiego 7, 25-314 Kielce, bszelag@tu.kielce.pl

W pracy podjęto próbę oceny możliwości zastosowania sztucznych sieci neuronowych do prognozowania ilości azotu ogólnego w ściekach w funkcji jego wybranych postaci zawartych w odpływie z oczyszczalni ścieków.

Obiekt badań

Obiektem badań była mechaniczno-biologiczna oczyszczalnia ścieków komunalnych, zlokalizowana w województwie podkarpackim, obsługująca aglomerację o równoważnej liczbie mieszkańców powyżej 100000. Jej projektowana przepustowość wynosiła ponad 35 tys. m³/d. Technologia oczyszczania ścieków oparta jest na metodzie osadu czynnego z chemicznym strącaniem fosforu za pomocą koagulantu PIX-113. Reaktory biologiczne oczyszczalni składają się z wydzielonych komór predenitryfikacji, defosfatacji, denitryfikacji i nityfikacji, w których są usuwane zanieczyszczenia organiczne oraz związki azotu i fosforu. Odbiornikiem ścieków oczyszczonych są wody powierzchniowe. Monitoring związków azotu prowadzony w analizowanej oczyszczalni ścieków obejmuje następujące jego postaci: azot ogólny (N_{og}), azot amonowy (NH₄⁺), azotyny (NO₂⁻), azotany (NO₃⁻) oraz azot Kjeldahla (N_{Kj}) (suma azotu amonowego i organicznego).

Metody

W celu przeanalizowania możliwości prognozowania zawartości azotu ogólnego w ściekach w funkcji jego różnych postaci, w pierwszej kolejności dokonano wstępnej klasyfikacji wyników analiz ścieków. Dane obejmujące 134 pomiary zawartości azotu w dobowych próbkach ścieków odpływających z oczyszczalni w latach 2010–2016, podzielone na sezon letni (od kwietnia do września) i zimowy (od października do marca), poddano grupowaniu statystycznemu. W obliczeniach zastosowano analizę skupień metodą minimalnej wariancji Warda, a miarą podobieństwa była odległość euklidesowa. Wyodrębnione w ten sposób grupy wyników stanowiły zmienne wejściowe wykorzystane w kilku wariantach modelu prognozy utworzonego za pomocą sztucznych sieci neuronowych.

Do obliczeń wykorzystano funkcję Automatycznego Projektanta programu Statistica 12. W ramach prowadzonych analiz wygenerowano 50 sztucznych sieci neuronowych uwzględniających różne kombinacje danych wejściowych i określano parametry dopasowania wyników obliczeń do danych rzeczywistych. W modelowaniu zastosowano metodę perceptronu wielowarstwowego (MLP) zbudowanego z trzech warstw – wejściowej, ukrytej i wyjściowej. W analizach założono, że liczba neuronów w warstwie ukrytej będzie się zmieniała w zakresie $k \pm 2k + 1$, gdzie k stanowiło liczbę wejść [21, 30]. Dodatkowo rozpatrzono również mniejszą liczbę neuronów, mając na uwadze możliwe uproszczenie struktury modelu. W warstwie neuronów ukrytych i w warstwie wyjściowej rozpatrzono kilka funkcji aktywacji, a mianowicie funkcję tangensa hiperbolicznego, logistyczną, sinusoidalną, wykładniczą oraz liniową [26]. Z uwagi na ograniczoną liczbę danych opisujących badany proces, w analizach przyjęto losowy dobór danych do zbioru uczącego i zbioru testowego, przy czym zbiór uczący stanowił 80% danych, a zbiór testowy i jednocześnie walidacyjny 20% danych. Proces uczenia sztucznych sieci neuronowych przeprowadzono z zastosowaniem metody ze wsteczną propagacją błędów Broydena-Flechera-Goldfarba-Shanno (BFGS) [27,30].

Wybór sztucznych sieci neuronowych został dokonany na podstawie interpretacji standardowych funkcji błędów. W tym celu zastosowano sumę kwadratów różnic między wartościami zadanymi i otrzymanymi na wyjściach każdego neuronu wyjściowego (SOS) oraz współczynnik korelacji określający jakość procesów uczenia i testowania [26]. Do ostatecznej oceny zdolności modeli do prognozowania zawartości azotu ogólnego w ściekach odprowadzanych z oczyszczalni do rzeki zastosowano powszechnie wykorzystywane miary, takie jak błąd średni (ME), średni błąd procentowy (MPE), średni błąd bezwzględny (MAE), średni bezwzględny błąd procentowy (MAPE), a także pierwiastek błędów średniokwadratowych (RMSE) oraz pierwiastek procentowego błędów średniokwadratowych (RMSPE), opisane następującymi wzorami:

$$ME = \frac{1}{n} \sum_{i=1}^n (y_{i,obs} - y_{i,progn}) \quad (1)$$

$$MPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_{i,obs} - y_{i,progn}}{y_{i,obs}} \right) 100 \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{i,obs} - y_{i,progn}| \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{i,obs} - y_{i,progn}}{y_{i,obs}} \right| 100 \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{i,obs} - y_{i,progn})^2} \quad (5)$$

$$RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_{i,obs} - y_{i,progn}}{y_{i,obs}} \right)^2} 100 \quad (6)$$

w których:

$y_{i,obs/i,progn}$ – wartość obserwowana/prognozowana
 n – liczebność analizowanego zbioru

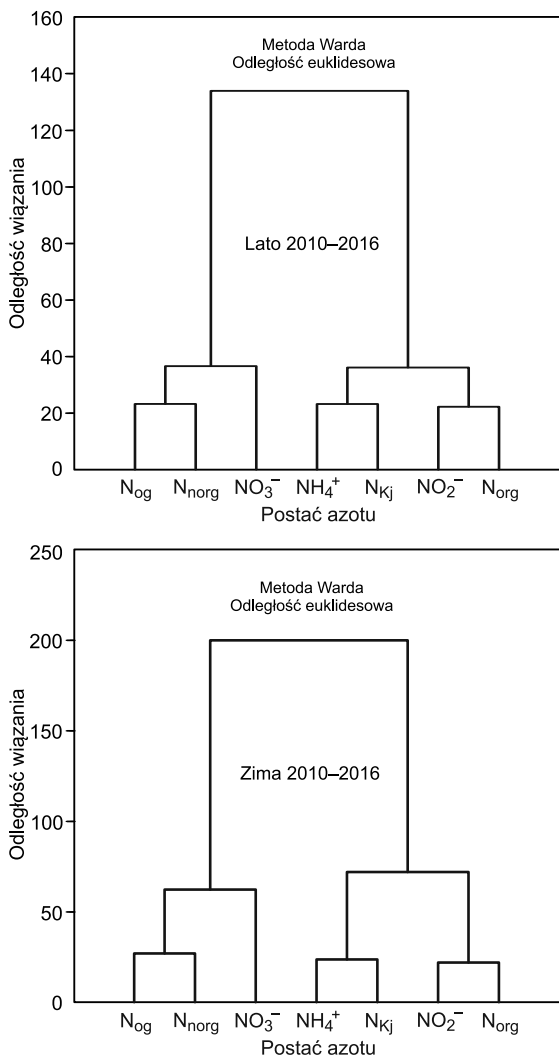
Dyskusja wyników

Analiza skupień

Analiza skupień pozwoliła na wyodrębnienie dwóch głównych skupisk zmiennych (rys. 1). Zarówno w sezonie letnim, jak i zimowym do pierwszej grupy zaliczono N_{og}, N_{norg} oraz NO₃⁻. W drugiej grupie znalazły się cztery wskaźniki – NH₄⁺, N_{Kj}, NO₂⁻ oraz N_{org}.

Model neuronowy

W celu znalezienia najlepszej struktury sztucznej sieci neuronowej testowano działanie sieci zbudowanych z różnej liczby neuronów wchodzących w skład warstwy ukrytej. Symulacje zawartości azotu ogólnego w odpływie z oczyszczalni ścieków wykonano w trzech wariantach. W pierwszym wykorzystano wszystkie oznaczone formy azotu (azot amonowy, azotany, azotyny, azot Kjeldahla, azot organiczny oraz azot nieorganiczny). W kolejnych wariantach wykorzystano dane wejściowe pochodzące z dwóch grup wyodrębnionych w analizie składowych głównych. Architektury wytypowanych sieci (MLP) oraz wyniki uzyskanych prognoz modelu neuronowego w trzech wariantach danych wejściowych zestawiono w tabelach 1 i 2.



Rys. 1. Analiza skupień poszczególnych postaci azotu w ściekach oczyszczonych z wykorzystaniem metody Warda
 Fig. 1. Cluster analysis of particular nitrogen forms in secondary effluent by Ward's method

Wykonane obliczenia wykazały, że na 50 wygenerowanych struktur sieci neuronowych najlepsze wyniki prognozowania zawartości azotu ogólnego w ściekach uzyskano w funkcji wszystkich analizowanych postaci azotu. Wytypowana sieć miała 10 neuronów w warstwie ukrytej, funkcję aktywacji tangens hiperboliczny w warstwie ukrytej i funkcję liniową w warstwie wyjściowej (tab. 1). Nieznacznie gorszymi zdolnościami prognozowania ilości azotu ogólnego, jak wykazały wartości współczynnika korelacji procesów uczenia i testowania (tab. 2), charakteryzował się podobny pod względem funkcji aktywacji model ilości azotu ogólnego w funkcji jego postaci nieorganicznych i azotanów. Zawierał on cztery neurony w warstwie wejściowej i osiem neuronów w warstwie ukrytej. W tabeli 2 zamieszczono statystyczne miary dopasowania wyników obliczeń do pomiarów w postaci błędu sumy kwadratów (SOS) oraz wartości współczynnika korelacji, dotyczące procesów uczenia i testowania. Sieci MLP 8-10-1 oraz MLP 4-8-1 charakteryzowały się bardzo wysokimi wartościami współczynnika korelacji (97÷99%).

Na podstawie wartości średniego błędu bezwzględnego (MAE) oraz średniego bezwzględnego błędu procentowego (MAPE) można stwierdzić, że najlepszymi modelami do prognozowania ilości azotu ogólnego w ściekach oczyszczonych były dwie sieci – MLP 8-10-1 oraz MLP 4-8-1 (tab. 3). Podczas procesu uczenia i testowania wartości błędów mieściły się w zakresie 0,29÷0,95 gN/m³ (MAE) oraz 2,22÷6,89% (MAPE), natomiast wartość pierwiastka procentowego błędu średniokwadratowego (RMSPE) nie przekroczyła 10%. Równość (zbliżona wartość) bezwzględnych wartości błędu średniego (ME) oraz średniego błędu bezwzględnego (MAE) wskazuje zwykle, że prognozy są systematycznie zawyżane lub zaniżane. Z tabeli 3 wynika, że w przypadku sieci MLP 4-8-1 oraz MLP 6-4-1 błąd ME był bliski zeru, a błąd MAE był wyraźnie większy. Wskazuje to na tendencję do znoszenia się błędów o znakach przeciwnych w miarach średnich i może wynikać na przykład ze zbyt uproszczonej struktury sieci. Wpływ struktury modelu na jego wrażliwość będzie przedmiotem dalszych prac.

Tabela 1. Struktura modeli sieci neuronowych (MLP) do prognozowania ilości azotu ogólnego w ściekach oczyszczonych
 Table 1. MLP network structure for forecasting TNC in secondary effluent

Dane*	Liczba neuronów		Algorytm uczenia	Funkcja aktywacji	
	warstwa wejściowa	warstwa ukryta		warstwa ukryta	warstwa wyjściowa
$[N_{og}] = f([NH_4^+], [NO_3^-], [NO_2^-], [N_{org}], [N_{Kj}])$	8	10	BFGS 41	tanh	liniowa
$[N_{og}] = f([NO_3^-], [N_{norg}])$	4	8	BFGS 43	tanh	liniowa
$[N_{og}] = f([NH_4^+], [NO_2^-], [N_{Kj}], [N_{org}])$	6	4	BFGS 17	wykładnicza	tanh

*N_{og} – azot ogólny, NH₄⁺ – azot amonowy, NO₃⁻ – azotany, NO₂⁻ – azotyiny, N_{org} – azot organiczny, N_{Kj} – azot Kjeldahla, N_{norg} – azot nieorganiczny

Tabela 2. Jakość prognoz z użyciem sztucznych sieci neuronowych w procesie uczenia i testowania modeli zawartości azotu ogólnego w ściekach oczyszczonych
 Table 2. Quality of ANN forecasting in the process of learning and testing models of TNC in secondary effluent

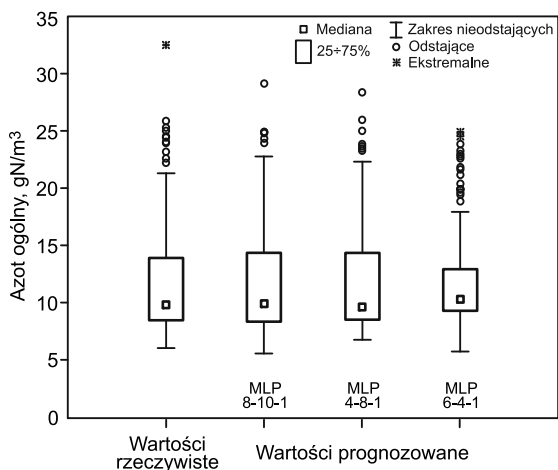
Architektura sztucznej sieci neuronowej	Funkcja błędu (SOS)		Współczynnik korelacji	
	uczenie	testowanie/walidacja	uczenie	testowanie/walidacja
MLP 8-10-1	0,240218	0,800268	0,898	0,982
MLP 4-8-1	0,564148	1,397407	0,975	0,970
MLP 6-4-1	4,547538	4,086201	0,775	0,880

Tabela 3. Wartości parametrów dopasowania modeli matematycznych do prognozowania zawartości azotu ogólnego w ściekach oczyszczonych
 Table 3. Values of fitting parameters of mathematical models to total nitrogen content forecasting in secondary effluent

SSN*	Błąd podczas uczenia						Błąd podczas testowania/walidacji					
	ME, gN/m ³	MPE, %	MAE, gN/m ³	MAPE, %	RMSE, gN/m ³	RMSPE, %	ME, gN/m ³	MPE, %	MAE, gN/m ³	MAPE, %	RMSE, gN/m ³	RMSPE, %
MLP 8-10-1	0,005	-0,053	0,287	2,22	0,69	4,99	0,241	0,988	0,481	2,85	1,26	5,45
MLP 4-8-1	0,066	-0,158	0,725	6,42	1,06	8,80	0,195	-0,813	0,951	6,89	1,67	9,26
MLP 6-4-1	-0,167	-7,208	2,266	19,60	3,02	24,30	-0,019	-5,187	2,199	18,58	2,86	22,67

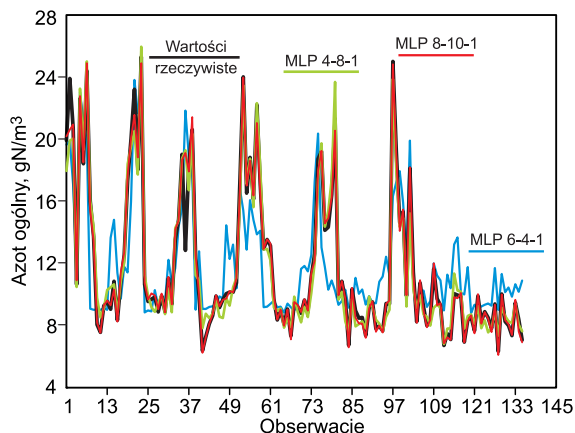
*architektura sztucznej sieci neuronowej

Na rysunku 2, który obrazuje wartości mediany oraz zakresy percentyli (25÷75%) i wartości minimum-maksimum, widać wyraźne podobieństwo rozkładu zmiennych rzeczywistych oraz zmiennych uzyskanych w modelu do prognozowania zawartości azotu ogólnego w funkcji jego wszystkich postaci (MLP 8-10-1) oraz w funkcji azotu nieorganicznego i azotanów (MLP 4-8-1).



Rys. 2. Charakterystyczne wartości azotu ogólnego obserwowane w ściekach oczyszczonych oraz prognozowane za pomocą sztucznych sieci neuronowych

Fig. 2. Characteristic values of total nitrogen content observed in secondary effluent and the ones forecasted using artificial neural networks



Rys. 3. Porównanie rzeczywistej zawartości azotu ogólnego w ściekach oczyszczonych oraz wartości prognozowanych za pomocą sztucznych sieci neuronowych

Fig. 3. Comparison of actual total nitrogen content in secondary effluent to the values forecasted using artificial neural networks

W celu wizualizacji otrzymanych obliczeń na rysunku 3 zamieszczono porównanie wyników pomiarów i obliczeń ilości azotu ogólnego w ściekach odpływających z analizowanej oczyszczalni, otrzymanych za pomocą wytypowanych sztucznych sieci neuronowych. Widać wyraźnie, że przebieg wartości prognozowanych za pomocą sieci MLP 8-10-1 oraz MLP 4-8-1 był bardzo zbliżony do rzeczywistego szeregu czasowego azotu ogólnego.

Podsumowanie

Na podstawie wykonanych symulacji można stwierdzić, że najmniejsze wartości błędów prognozowania zawartości azotu ogólnego w ściekach oczyszczonych otrzymano w wariancie, gdy prognozowana ilość azotu ogólnego była funkcją wszystkich postaci azotu występujących w ściekach. W przypadku modeli obliczeniowych w funkcji azotu nieorganicznego i azotanów uzyskane wyniki symulacji zawartości azotu ogólnego nieznacznie różniły się od danych rzeczywistych, na co wskazywały wartości współczynnika korelacji (>97%) oraz średniego bezwzględnego błędu procentowego (MAPE). W przypadku modelu uwzględniającego wszystkie postaci azotu wartości tego błędu w procesie uczenia oraz testowania/walidacji wynosiły odpowiednio 2,22% i 2,85%, natomiast w drugim przypadku były większe o około 4 punkty procentowe.

Zaproponowana metoda wykorzystania sztucznych sieci neuronowych wydaje się być skutecznym narzędziem do prognozowania zawartości azotu ogólnego w odpływie z oczyszczalni ścieków. Model wykorzystujący jedynie dane obrazujące zawartość azotu amonowego oraz azotanów i azotanów pokazuje, że ciągła analiza wartości tych wskaźników w odpływie z oczyszczalni ścieków (za pomocą sond) może się okazać bardzo użytecznym narzędziem w eksploatacji oczyszczalni ścieków.

LITERATURA

1. Dyrektywa Rady z 21 maja 1991 r. dotycząca oczyszczania ścieków komunalnych (91/271/EWG). *Dziennik Urzędowy Wspólnot Europejskich* 1991, L 135/40, wraz ze zmianami.
2. Rozporządzenie Ministra Środowiska z 18 listopada 2014 r. w sprawie warunków, jakie należy spełnić przy wprowadzaniu ścieków do wód lub do ziemi, oraz w sprawie substancji szczególnie szkodliwych dla środowiska wodnego. *Dziennik Ustaw* 2014, poz. 1800.
3. K. IGNATOWICZ, Ł. NOWICKI, M. PUCHLIK: Profil zmian stężenia związków węgla, azotu i fosforu w oczyszczalni ścieków komunalnych w Nowej Wsi Elckiej. *Inżynieria Ekologiczna* 2011, nr 24, ss. 52–63.

4. J. JORDANOWSKA, M. JAKUBUS: Ładunki zanieczyszczeń oraz efektywność oczyszczania ścieków komunalnych z rejonu Wrześni na przestrzeni lat. *Nauka Przyroda Technologia* 2013, vol. 7, nr 3, #32, ss. 1–14.
5. E. WAŚIK, E. JURIK, K. CHMIEŁOWSKI, A. OPERACZ, P. BUGAJSKI: Statistical process control of removal of nitrogen compounds in the wastewater treatment plant in Krosno. *Infrastructure and Ecology of Rural Areas* 2017, No. IV/2, pp. 1699–1711.
6. Z. SADECKA: Podstawy biologicznego oczyszczania ścieków. Wydawnictwo Seidel-Przywecki, Warszawa 2010.
7. Z. DYMACZEWSKI [red.]: Poradnik eksploatatora oczyszczalni ścieków. Polskie Zrzeszenie Inżynierów i Techników Sanitarnych Oddział Wielkopolski, Poznań 2011.
8. G. KACZOR: Wpływ temperatury powietrza na temperaturę ścieków w kanalizacji i reaktorze biologicznym. *Infrastruktura i Ekologia Terenów Wiejskich* 2008, vol. 3, ss. 129–137.
9. P. BUGAJSKI: Wpływ temperatury ścieków na wielkość wybranych wskaźników zanieczyszczeń z oczyszczalni działającej w układzie sekwencyjnym SBR. *Infrastruktura i Ekologia Terenów Wiejskich* 2011, nr 2, ss. 7–15.
10. L. BARTKIEWICZ, B. SZELAĞ, J. STUDZIŃSKI: Ocena wpływu zmiennych wejściowych oraz struktury modelu sztucznej sieci neuronowej na prognozowanie dopływu ścieków komunalnych do oczyszczalni (Impact assessment of input variables and ANN model structure on forecasting wastewater inflow into sewage treatment plants). *Ochrona Środowiska* 2016, vol. 38, nr 2, ss. 29–36.
11. M. CHUCHRO, A. PIÓRKOWSKI: Wykorzystanie metod i narzędzi eksploracji danych do analizy zmienności natężenia dopływu do komunalnych oczyszczalni ścieków. *Studia Informatica* 2010, vol. 31 nr 2B, ss. 347–358.
12. J. STUDZIŃSKI, L. BARTKIEWICZ, M. STACHURA: Development of mathematical models for forecasting hydraulic loads of water and wastewater networks. In: *EnviroInfo'2013 – Environmental Informatics and Renewable Energies*, Shaker Verlag, Aachen 2013.
13. B. SZELAĞ, L. BARTKIEWICZ, J. STUDZIŃSKI, K. BARBUSIŃSKI: Evaluation of the impact of explanatory variables on the accuracy of prediction of daily inflow to the sewage treatment plant by selected models nonlinear. *Archives of Environmental Protection* 2017, Vol. 43, No. 3. pp. 74–81.
14. M. ELNEKAVE, S. O. CELIK, M. TATLIER, N. TUFEKCI: Artificial neural network predictions of up-flow anaerobic sludge blanket (UASB) reactor performance in the treatment of citrus juice wastewater. *Polish Journal of Environment Study* 2012, Vol. 21, No. 1, p. 49–56.
15. D. GÜÇLÜ, Ş. DURSUN: Artificial neural network modeling of a large-scale wastewater treatment plant operation. *Bioprocess and Biosystems Engineering* 2010, Vol. 33, No. 9, pp. 1051–1058.
16. X. WEI, A. KUSIAK, H. R. SADAT: Prediction of influent flow rate: Data-mining approach. *Journal of Energy Engineering* 2012, Vol. 19, No. 2, pp. 118–123.
17. X. WEI, A. KUSIAK: Short-term prediction of influent flow in wastewater treatment plant. *Stochastic Environmental Research and Risk Assessment* 2015, Vol. 29, No. 1, pp. 241–249.
18. R. ZHANG, X. HU: Effluent quality prediction of wastewater treatment system based on small-world. *Journal of Computers* 2012, Vol. 7, No. 9, pp. 2136–2143.
19. H. G. HAN, J. F. QIAO: Prediction of activated sludge bulking based on a self-organizing RBF neural network. *Journal of Process Control* 2012, Vol. 22, No. 6, pp. 1103–1112.
20. H. G. HAN, J. F. QIAO: Hierarchical neural network modeling approach to predict sludge volume index of wastewater treatment process. *IEEE Transactions on Control Systems Technology* 2013, Vol. 21, pp. 2423–2431.
21. I. LOU, Y. ZHAO: Sludge bulking prediction using principle component regression and artificial neural network. *Mathematical Problems in Engineering* 2012, Article ID 237693, pp. 1–17.
22. H. POUTIAINEN, H. NISKA, H. HEINONEN-TANSKI, M. KOLEHMAINEN: Use of sewer on-line total solids data in wastewater treatment plant modelling. *Water Science and Technology* 2010, Vol. 62, No. 4, pp. 743–75.
23. B. SZELAĞ, J. GAWDZIK: Application of selected methods of artificial intelligence to activated sludge settle ability predictions. *Polish Journal of Environmental Studies* 2016, Vol. 25, No. 4, pp. 1709–1714.
24. R. TADEUSIEWICZ, J. KORBICZ, L. RUTKOWSKI, W. DUCH [red.]: Sieci neuronowe w inżynierii biomedycznej, tom 9 monografii: Inżynieria biomedyczna – podstawy i zastosowania, Wydawnictwo Exit, Warszawa 2013.
25. R. TADEUSIEWICZ: Zastosowania sieci neuronowych w ochronie środowiska. Materiały XVIII Konferencji Automatyków, Wydawnictwo AGH, Kraków 2014, ss. 1–9.
26. www.statsoft.pl/textbook/stathome_stat.html?http%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html.
27. L. RUTKOWSKI: Metody i techniki sztucznej inteligencji. PWN, Warszawa 2006.
28. V. VAPNIK: Statistical Learning Theory. John Wiley and Sons, New York 1998.
29. S. HAYKIN: Neural Networks: A Comprehensive Foundation. Prentice Hall Inc., Upper Saddle River (NJ) 1999.
30. R. HECHT-NIELSEN: Kolmogorov's mapping neural network existence theorem. Proceedings of the International Joint Conference on Neural Networks, New York 1987, Vol. 3, pp. 11–14.
31. Y. BECERIKLI, A. F. KONAR, T. SAMAD: Intelligent optimal control with dynamic neural networks. *Neural Networks* 2003, Vol. 16, No. 2, pp. 251–259.

Wasik, E., Chmielowski, K., Studzinski, J., Szelag, B. Application of Artificial Neural Networks to Forecasting Total Nitrogen Content in Secondary Effluent from Treatment Plants. *Ochrona Środowiska* 2018, Vol. 40, No. 1, pp. 29–33.

Abstract: Potential application of artificial neural networks (ANN) to forecast total nitrogen content (TNC) in treated wastewater was presented as a function of selected nitrogen forms present in the secondary effluent. The analyzed data from the period of 2010–2016 covered measurements of the nitrogen content in the effluent from the treatment plant servicing agglomeration with a population equivalent of more than 100,000. The input data set was initially subjected to cluster analysis and then, used to train a neural network in the form of a multilayer perceptron (MLP). The simulations demonstrated

that the smallest error values for the forecast of TNC (2–3%) were obtained for the variant, the value of which was a function of all the forms of nitrogen present in the secondary effluent. For the total nitrogen model based on inorganic nitrogen and nitrates data only, the simulation results did not differ significantly from the actual values, as indicated by a very high correlation coefficient (over 97%). In this case, the value of the mean absolute error increased only by nearly 4% to 6.2% (learning process) or 6.9% (testing/validation process), compared to the simulation based on all the nitrogen forms in the sewage.

Keywords: Sewage, secondary effluent, modeling, forecasting, artificial neural networks, total nitrogen, ammonia nitrogen, nitrites, nitrates, organic nitrogen.