



Modelowanie zmian parametrów ścieków oczyszczonych z wykorzystaniem sztucznych sieci neuronowych

Iwona Skoczko, Joanna Struk-Sokołowska, Piotr Ofman
Politechnika Białostocka

1. Wprowadzenie

Modelowanie matematyczne coraz częściej wykorzystywane jest w niemal każdej gałęzi przemysłu. Możliwość przewidywania efektów pracy obiektów technologicznych w dzisiejszych czasach jest bardzo pożądana, szczególnie gdy możliwa jest aproksymacja zmian zachodzących w układach biologicznych, takich jak oczyszczalnie ścieków (Baczyński 2010, Sochacki i in. 2010). Czasochłonne, a niejednokrotnie kłopotliwe, badania technologiczne wypierane są wynikami modelowania matematycznego prowadzonego na bazie symulacji komputerowych (Çinar 2005, Ráduly i in. 2007, Piekarski 2011). Tego typu podejście pozwala na znaczne zaoszczędzenie czasu, potrzebnego w innym wypadku na analizy laboratoryjne (Tomenko i in. 2007, Dymaczewski 2008, Sadecka i in. 2011, Haimi i in. 2013), a także umożliwia dobre odzwierciedlenie zmian, jakie zachodzą w trakcie całego procesu (Szetela & Dymaczewski 2002, Dymaczewski 2008, Ou i in. 2015). Ponadto, podejście modelowe w oczyszczaniu ścieków może wskazać momenty, w których występują nieprawidłowości w ciągu technologicznym obiektu lub okresy, gdy parametry ścieków oczyszczonych ulegną pogorszeniu (Mjalli i in. 2007). Zgodnie z pozwoleniami wodno-prawnymi ścieki oczyszczone odprowadzane do środowiska wodnego powinny spełniać określone normy (Hong i in. 2007, Eriksson i in. 2008, Andraka & Dzienis 2013). Dlatego też, możliwość wcześniejszego wykrycia potencjalnej awarii lub

nieprawidłowości w pracy oczyszczalni ścieków jest uzasadniona i pożądana z punktu ekonomicznego i środowiskowego.

Powszechnie wykorzystywane modele ASM w układach oczyszczania ścieków znajdują zastosowanie podczas planowania koncepcji technologicznych. Algorytmy te są rozbudowane do takiego stopnia, że na etapie projektowania pozwalają na stosunkowo dokładny opis zmian zachodzących w ściekach podczas ich oczyszczania (Moral i in. 2008, Benintendi 2015). Ze względu na stopień dokładności modeli ASM przed stworzeniem ciągu technologicznego oczyszczalni ścieków należy przeprowadzić szereg badań laboratoryjnych, uwzględniających między innymi frakcje ChZT czy alkaliczność ścieków. Oprócz tego modele ASM wymagają uwzględnienia parametrów technologicznych osadu czynnego (Gernaey i in. 2004, Lee i in. 2011, Herandez i in. 2013), a zaawansowanie modelowania wymaga od użytkownika znajomości stopnia kinetyki rozkładu danego związku w trakcie jego usuwania ze ścieków (Pomiès i in. 2013). Z tych powodów opis pracy oczyszczalni ścieków z wykorzystaniem gotowego oprogramowania jest trudny i czasochłonny.

Przez wzgląd na dokładność i ilość parametrów, które należy uwzględnić w modelu ASM ich wykorzystanie ogranicza się do wąskiego grona specjalistów z zakresu technologii oczyszczania ścieków. Stąd wynika potrzeba prostszego i niemniej skutecznego odwzorowania zmian zachodzących podczas oczyszczania ścieków (Gontarski i in. 2000, Skoczko i in. 2016). W literaturze tematu coraz częściej spotykane jest wykorzystanie sztucznych sieci neuronowych, które umożliwiają odzwierciedlenie pracy oczyszczalni ścieków na zasadzie tak zwanego modelu czarnej skrzynki (Moreno-Alfonso i Redondo 2001, Tomenko i in. 2007, Lee i in. 2011, Ou i in. 2015). W odróżnieniu od modeli ASM sztuczne sieci neuronowe, pozwalają na dowolność w przyjmowaniu zmiennych do prognozy jakości ścieków oczyszczonych (Dellana & West 2009, Gawdzik i in. 2016). Poprzez poszukiwanie najprostszej relacji pomiędzy zmiennymi wejściowymi i wyjściowymi, sieci neuronowe mogą uwzględniać jedynie parametry opisujące skład chemiczny ścieków surowych i oczyszczonych (Moreno-Alfonso i Redondo 2001, Czapczuk i in. 2015). Swobodny dobór zmiennych uwzględnianych w modelu teoretycznie pozwala na dokładniejsze odzwierciedlenie procesu oczyszczania ścieków. Ta własność jest szczególnie istotna w przypadku oczyszczalni przemysłowych lub oczyszczalni komunalnych przyjmujących

ścieki przemysłowe. Stwierdzenie te uzasadnione jest możliwością uwzględnienia w modelu parametrów potencjalnie toksycznych dla mikroorganizmów bytujących w osadzie czynnym (Sánchez-Avila i in. 2009, Sponza & Gök, 2010, Badawy i in. 2010, Deblonde i in. 2011).

W pracy przedstawiono i oceniono opracowany model sztucznej sieci neuronowej stworzonej na podstawie wyników badań prowadzonych w oczyszczalni ścieków, do której dopływają ścieki komunalne z udziałem ścieków mleczarskich pochodzących z zakładu zlokalizowanego w Bystrym koło Giżycka.

2. Metodyka


Model sztucznej sieci neuronowej aproksymujący stężenia i wartości wybranych parametrów ścieków oczyszczonych stworzono na podstawie wyników badań udostępnionych przez Przedsiębiorstwo Wodociągów i Kanalizacji w Giżycku. Analizy laboratoryjne prowadzone były w odstępach 7 dniowych w latach 2014 i 2015. Zakres badań obejmował BZT₅ i ChZT_{Cr}, azot ogólny, fosfor ogólny, zawiesiny ogólne w ściekach surowych i oczyszczonych. Dodatkowo w ściekach surowych badano odczyn i temperaturę. Analizy wykonywano zgodnie z następującymi normami:

- Odczyn – PN-EN ISO 10523:2012
- BZT₅ – PN-EN 1899-1:2002
- ChZT_{Cr} – PN- ISO 6060:2006
- Azot ogólny – PB-13/2006/PG wyd. 3 z 02.01.2013
- Fosfor ogólny – PN-EN ISO 6878:2006+Ap1. 2010+Ap2.:2010 p.7
- Zawiesiny ogólne – PN-EN 872:2007+Ap1:2007

Ścieki surowe dopływają do oczyszczalni systemem kanalizacji grawitacyjnej i tłocznej. Wstępne mechaniczne oczyszczanie ścieków (rys. 1) następuje w budynku krat. Kolejnym etapem oczyszczania mechanicznego jest piaskownik, w którym wskutek zwolnienia przepływu ścieków następuje wytrącenie i sedymentacja zawiesiny mineralnej. Dodatkowo piaskownik jest napowietrzany sprężonym powietrzem w celu lepszego flotowania części pływających. Po oczyszczeniu mechanicznym ścieki przepływają do układu komór biologicznych, pełniących podstawową funkcję oczyszczania biologicznego. W pierwszym etapie ścieki dopływają do komory defosfatacji (beztlenowej), następnie do komór

denitryfikacji (niedotlenionych), do której recykulowany jest strumień azotanów z komór nityfikacji (recyrkulacja wewnętrzna). Ścieki z komory denitryfikacji przepływają do komór nityfikacji (tlenowych). Po oczyszczeniu w reaktorach biologicznych mieszanina osadu czynnego i ścieków dopływa poprzez przelewy do komór rozdziału i dalej do dwóch osadników wtórnych. W osadnikach następuje rozdział osadu czynnego od ścieków oczyszczonych w warunkach zwolnionego przepływu. Badana oczyszczalnia ścieków charakteryzowała się RLM na poziomie 98615. Fragment schematu technologicznego oczyszczalni ścieków w Bystrym koło Giżycka, istotny z punktu przeprowadzonych badań, przedstawiono na rysunku 1.

Wyniki przeprowadzonych badań poddano analizie statystycznej, która obejmowała wyznaczenie średniej arytmetycznej, mediany, odchylenia standardowego, minimum, maksimum oraz opracowanie modelu sztucznej sieci neuronowej. Obliczenia wykonano przy użyciu licencjonowanego oprogramowania Statistica 12.5 w polskiej wersji językowej pracującej na platformie Windows 10. Do analiz statystycznych wykorzystano łącznie około 2200 wyników pomiarów.



Rys. 1. Fragment schematu technologicznego oczyszczalni ścieków w Bystrym koło Giżycka

Fig. 1. Fragment of Bystre wastewater treatment plant technological scheme

Do budowy sztucznej sieci neuronowej zastosowano próbkowanie w ilości 6000 sieci, do którego wykorzystano sieci z wielowarstwowym perceptronem. W etapie próbkowania pominięto funkcję liniową do aktywacji perceptronu. Po wyborze spośród 6000 sieci, najlepszą z nich, poddano ponownemu uczeniu, które przebiegało w dwóch etapach. W pierwszej fazie jako algorytm uczący wykorzystano wsteczną propagację błędu, natomiast w drugiej fazie gradienty sprzężone. W pierwszym etapie ponownego uczenia zadano 5000 epok, a w drugim 1000. Prędkość uczenia sztucznej sieci neuronowej w obu fazach przyjęto za równą 0,001, natomiast za funkcje aktywujące warstwę ukrytą i wyjściową neuronów przyjęto odpowiednio logistyczną i wykładniczą.

3. Wyniki badań i dyskusja

Badane parametry ścieków dopływających do oczyszczalni wykazywały dużą zmienność w ciągu okresu badawczego. Wartości minimalne i maksymalne, jakie zaobserwowano w trakcie badań dla BZT_5 równe były odpowiednio 370,00 i 1450,00 $\text{mg O}_2 \cdot \text{dm}^{-3}$. Mimo dużej rozpiętości pomiędzy wartościami ekstremalnymi, zmienność BZT_5 w ciągu okresu badawczego zrównoważona, o czym świadczą zbliżone wartości średniej arytmetycznej (655,38 $\text{mg O}_2 \cdot \text{dm}^{-3}$) i mediany (620,00 $\text{mg O}_2 \cdot \text{dm}^{-3}$) oraz odchylenie standardowe, stanowiące około 26% średniej arytmetycznej (171,38 $\text{mg O}_2 \cdot \text{dm}^{-3}$). Wartości ChZT_{Cr} zmieniały się w zakresie od 640,00 do 1840,00 $\text{mg O}_2 \cdot \text{dm}^{-3}$. Podobnie jak w przypadku BZT_5 nie obserwowano nagłych zmian wartości ChZT_{Cr} w ściekach surowych. Zmiany w stężeniu azotu ogólnego w ściekach surowych wahały się od 58,00 do 126 $\text{mg N} \cdot \text{dm}^{-3}$. Na podstawie średniego stężenia tego parametru w okresie badawczym (88,85 $\text{mg N} \cdot \text{dm}^{-3}$) i mediany (89,00 $\text{mg N} \cdot \text{dm}^{-3}$) oraz odchylenia standardowego na poziomie 11,47 $\text{mg N} \cdot \text{dm}^{-3}$ stwierdzono, że zmiany w stężeniu azotu ogólnego były stopniowe i wynikały z wielkości produkcji w Zakładzie Przetwórstwa Mleka. Podobną prawidłowość obserwowano w przypadku fosforu ogólnego. Średnia arytmetyczna na poziomie 12,94 $\text{mg P} \cdot \text{dm}^{-3}$ i mediana równa 12,55 $\text{mg P} \cdot \text{dm}^{-3}$, przy zakresie od 8,40 do 24,40 $\text{mg P} \cdot \text{dm}^{-3}$ świadczą o stopniowych zmianach tego parametru w trakcie badań.

Tabela 1. Statystyki podstawowe wyników badań
Table 1. Basic statistics of studies results

Zmienna	Jednostka	Średnia arytmetyczna	Mediana	Odchylenie standardowe	Minimum	Maksimum
Q	$\text{m}^3 \cdot \text{d}^{-1}$	6469,54	6286,50	$\pm 676,11$	4803,00	8438,00
BZT ₅ – ŚS	$\text{mg O}_2 \cdot \text{dm}^{-3}$	655,38	620,00	$\pm 171,38$	370,00	1450,00
ChZT _{Cr} – ŚS	$\text{mg O}_2 \cdot \text{dm}^{-3}$	1246,33	1215,00	$\pm 252,11$	640,00	1840,00
N _{og} – ŚS	$\text{mg N} \cdot \text{dm}^{-3}$	88,85	89,00	$\pm 11,47$	58,00	126,00
P _{og} – ŚS	$\text{mg P} \cdot \text{dm}^{-3}$	12,94	12,55	$\pm 2,25$	8,40	24,40
Z _{og} – ŚS	$\text{mg} \cdot \text{dm}^{-3}$	651,27	585,00	$\pm 220,86$	330,00	1450,00
T – ŚS	$^{\circ}\text{C}$	16,94	16,30	$\pm 2,65$	11,60	21,30
pH – ŚS	–	–	–	–	7,00	7,90
BZT ₅ – ŚO	$\text{mg O}_2 \cdot \text{dm}^{-3}$	4,61	4,50	$\pm 1,46$	2,00	11,00
ChZT _{Cr} – ŚO	$\text{mg O}_2 \cdot \text{dm}^{-3}$	61,44	60,00	$\pm 7,90$	45,00	86,00
N _{og} – ŚO	$\text{mg N} \cdot \text{dm}^{-3}$	6,77	6,55	$\pm 2,17$	2,70	15,20
P _{og} – ŚO	$\text{mg P} \cdot \text{dm}^{-3}$	0,52	0,47	$\pm 0,18$	0,29	1,82
Z _{og} – ŚO	$\text{mg} \cdot \text{dm}^{-3}$	6,97	6,75	$\pm 2,11$	3,30	16,00

Q – ilość ścieków dopływająca z zakładu na oczyszczalnię,

ŚS – wartości i stężenia w ściekach surowych,


ŚO – wartości i stężenia w ściekach oczyszczonych.

Spośród wszystkich badanych parametrów największą zmiennością charakteryzowały się zawiesiny ogólne. Mimo zbliżonych wartości średniej arytmetycznej ($651,27 \text{ mg}\cdot\text{dm}^{-3}$) i mediany ($585,00 \text{ mg}\cdot\text{dm}^{-3}$) odchylenie standardowe równe było $220,86 \text{ mg}\cdot\text{dm}^{-3}$ i stanowiło około 34% średniej arytmetycznej tego parametru.

Badane parametry jakościowe ścieków były zbliżone do tych, które prezentowali Demirel i inni (2007) w pracy poświęconej przeglądowi parametrów ścieków mleczarskich na terenie Holandii. Podobne wielkości poszczególnych parametrów w ściekach surowych zaobserwowała Bartkowska i inni (2011) w badaniach poświęconym jakości ścieków w oczyszczalni ścieków w Hajnówce, która oczyszcza zmieszane ścieki komunalne i mleczarskie. Nieznacznie mniejsze wartości i stężenie poszczególnych parametrów, w porównaniu z obserwowanymi w Giżycku, uzyskała Zielińska i inni (2013). Znacznie mniejsze wartości BZT₅ i ChZT w mieszaninie ścieków komunalnych i mleczarskich obserwowała Krzemińska i inni (2013) oraz Struk-Sokołowska na oczyszczalni w Olecku (2011) i Hajnówce (2013).

Proces mechaniczno-biologicznego oczyszczania ścieków w badanym obiekcie przebiegał stabilnie w ciągu okresu badawczego. Świadczą o tym niewielkie zmiany wartości i stężenia poszczególnych parametrów podlegających kontroli. Wartości średnich arytmetycznych i median wszystkich analizowanych składników były zbliżone do siebie. Największe zróżnicowanie w wartościach badanych parametrów zaobserwowano dla azotu ogólnego i zawiesin ogólnych. Odchylenia standardowe tych wskaźników równe były odpowiednio 2,17 i 2,11 przy zakresie zmienności dla azotu $-2,7-15,2 \text{ mg N}\cdot\text{dm}^{-3}$ i zawiesin ogólnych $-3,3-16,0 \text{ mg}\cdot\text{dm}^{-3}$.

Najlepsza z uzyskanych sieci neuronowych charakteryzowała się topologią 8-13-8-5. Oznacza to, że w warstwie wejściowej, w trakcie toku obliczeniowego, nie odrzucono żadnej ze zmiennych badanych w ściekach surowych. Następnie model uwzględniał dwie warstwy ukryte, które składały się kolejno z 13 i 8 neuronów. Warstwę wyjściową stanowiły neurony opisujące wartości poszczególnych wskaźników jakościowych, badanych w ściekach oczyszczonych. Topologię uzyskanego modelu przedstawiono na rysunku 2.



Rys. 2. Struktura modelu sztucznej sieci neuronowej
Fig. 2. Structure of artificial neural network model

Opracowany model sztucznej sieci neuronowej pozwolił na uzyskanie dobrego dopasowania wartości aproksymowanych do rzeczywistych. Wartości średnich arytmetycznych i odchyłeń standardowych estymowanych wielkości zbliżone były do tych, które obserwowano w ściekach surowych w trakcie badań. Średnia wartość BZT_5 uzyskana w modelu równa była $4,51 \text{ mg O}_2 \cdot \text{dm}^{-3}$ i była mniejsza o około 2% w stosunku do średniej wartości tego parametru obserwowanej w ściekach. W przypadku $ChZT_{Cr}$ średnia wartość równa była $61,81 \text{ mg O}_2 \cdot \text{dm}^{-3}$. Wynik ten różnił się o około 1% w odniesieniu do wartości rzeczywistej. Średnie stężenie azotu ogólnego jakie było aproksymowane przez model wynosiło $7,07 \text{ mg N} \cdot \text{dm}^{-3}$ i było większe o około 4% od wartości średniej uzyskanej w ściekach oczyszczonych w ciągu okresu badawczego. Fosfor ogólny, zgodnie z aproksymacją modelu, średnią wartość przyjmował na poziomie $0,52 \text{ mg P} \cdot \text{dm}^{-3}$. Uzyskany wynik nie różnił się od wartości średniej arytmetycznej tego parametru obserwowanej w ściekach. W przy-


padku zawiesin ogólnych różnica pomiędzy średnią wartością tego parametru obserwowanego w ściekach i wartościach, jakie były aproksymowane przez model wynosiła około 2%.

Tabela 2. Statystyki opisowe zmiennych aproksymowanych przez model sztucznej sieci neuronowej

Table 2. Basic statistics of approximated variables in artificial neural network model

Parametr statystyczny	Zmienne wyjściowe, aproksymowane przez model				
	BZT ₅ [mg O ₂ ·dm ⁻³]	ChZT _{Cr} [mg O ₂ ·dm ⁻³]	N _{og} [mg N·dm ⁻³]	P _{og} [mg P·dm ⁻³]	Z _{og} [mg·dm ⁻³]
Średnia	4,51	61,81	7,07	0,52	6,87
Odchylenie standardowe	1,35	8,15	2,36	0,14	2,04
Średni błąd bezwzględny	0,86	5,80	1,49	0,08	1,09
Korelacja	0,47	0,46	0,66	0,68	0,73
R ²	0,46	0,58	0,70	0,70	0,75

Średni błąd bezwzględny z jakim estymowano parametry jakościowe ścieków surowych dla wartości BZT₅ przyjmował wartość 0,86, w przypadku ChZT_{Cr} równy był 5,80, dla azotu i fosforu ogólnego, odpowiednio, 1,49 i 0,08, a dla zawiesin ogólnych 1,09. Średnie błędy szacowania nie przekraczały 22% wartości średniej arytmetycznej poszczególnych wskaźników obserwowanych w ściekach oczyszczonych.



Rys. 3. Dopasowanie modelu sztucznej sieci neuronowej do rzeczywistych parametrów ścieków

Fig. 3. Artificial neural network model fit to observed wastewater parameters

Odnosząc się do miar dokładności dopasowania modelu do wartości obserwowanych, zaobserwowano, że model sztucznej sieci neuronowej najlepiej odzwierciedlił zmiany w wartościach zawiesin ogólnych. Wskaźnik ten, charakteryzował się współczynnikiem korelacji na poziomie 0,73 i współczynnikiem R^2 równym 0,75. Nieco mniejsze dopasowanie uzyskano w stosunku do azotu i fosforu ogólnego. Uzyskane wartości korelacji wynosiły, odpowiednio dla azotu i fosforu, 0,66 i 0,68. Natomiast współczynniki determinacji dla obu parametrów przyjęły tożsamą wartość równą 0,70. Mniejsze dopasowanie, w odniesieniu do pozostałych parametrów, uzyskano dla $ChZT_{Cr}$. Wartości współczynników korelacji i R^2 tego parametru równe były, odpowiednio, 0,46 i 0,58. Opracowany model w najmniejszym stopniu odwzorował zmiany, jakie zachodziły, w wartościach BZT_5 . Współczynnika korelacji w tym przypadku równy był 0,47, a współczynnik R^2 0,46.

Model sztucznej sieci neuronowej aproksymujący zmiany w wartości zawiesin ogólnych, prezentowany przez Hanaby i współautorów (2008) dobrze odzwierciedlał trend zmian jakim podlegał ten parametr, jednakże wyniki uzyskane na drodze obliczeń były o około 20% większe w stosunku do wartości obserwowanych. Podobną relację wykazywał model prezentowany w tej pracy. Verma i inni (2013) uzyskali zbliżone do przedstawionego dopasowanie modelu sieci neuronowej w predykcji $ChZT_{Cr}$. Dokładność aproksymacji uzyskana przez autorkę wynosiła od 73,00 do 79,00%. Podobne dopasowanie wartości $ChZT_{Cr}$ i zawiesin ogólnych otrzymali Gieru i współautorzy (2006) w modelach aproksymujących wartości tych parametrów w ściekach. Prezentowane modele charakteryzowały się błędami estymacji z zakresu od 9,70 do 13,70% w stosunku do $ChZT_{Cr}$ i od 10,20 do 14,20% w stosunku do zawiesin ogólnych. Mniejsze, w porównaniu z prezentowanym modelem, dopasowanie aproksymowanych wartości $ChZT_{Cr}$ uzyskali Fang i inni (2010) oraz Kriger i Tzoneva (2007). Model prezentowany przez Fanga i współautorów charakteryzował się współczynnikiem determinacji na poziomie 0,01, natomiast Kriger uzyskał korelację równą 0,36. Kriger i Tzoneva (2007) oraz Akrotos i inni (2009) przedstawili w pracach wyniki aproksymacji stężenia azotu ogólnego. Kriger i Tzoneva uzyskali mniejszy niż prezentowany współczynnik korelacji (0,52), natomiast dopasowanie modelu Akrotosa było zbliżone ze względu na współczynnik determinacji ($R^2=0,69$). Nieco lepsze dopasowanie w przypadku aproksy-

macji wartości BZT_5 uzyskali Akratos i współautorzy (2008), gdzie współczynnik R^2 wynosił 0,52. Nieznacznie lepsze dopasowanie w stosunku do predykcji fosforu ogólnego uzyskali Akratos i inni (2009a). Współczynnik determinacji dla tego wskaźnika wynosił 0,83.

Wskaźniki, które zgodnie z miarami dopasowania modelu (korelacje i R^2), cechowały się najmniejszym dopasowaniem nie były aproksymowane z największym błędem. Mniejsze, w porównaniu z pozostałymi wskaźnikami, dopasowanie BZT_5 i $ChZT_{Cr}$ powodowane było brakiem odwzorowania w modelu wartości skrajnych występujących epizodycznie w trakcie okresu badawczego. W przypadku pozostałych zmiennych model umożliwił dobre odwzorowanie wartości ekstremalnych. Szczegółowy przebieg zmian badanych parametrów w ściekach oczyszczonych zestawiono na rysunku 3.

Tabela 3. Analiza wrażliwości modelu

Table 3. Model sensitivity analysis

Miara istotności i ranga	Zmienna wejściowa w modelu							
	Q	BZT_5	$ChZT_{Cr}$	N_{og}	P_{og}	Z_{og}	T	pH
Iloraz	1,12	1,09	1,07	1,01	1,01	1,17	1,07	1,04
Ranga	2,00	3,00	4,00	8,00	7,00	1,00	5,00	6,00

Odnosząc się do analizy wrażliwości modelu sztucznej sieci neuronowej przedstawionej w tabeli 4, zaobserwowano, że największy wpływ na predykcję poszczególnych wskaźników w ściekach oczyszczonych miało stężenie azotu ogólnego, które odznaczało się największą rangą. Kolejnymi ze względu na istotność predykcji zmiennymi było stężenie fosforu ogólnego, stężenie fosforu ogólnego, odczyn ścieków dopływających do oczyszczalni, temperatura ścieków surowych, stężenie związków organicznych charakteryzowanych parametrami $ChZT_{Cr}$ i BZT_5 . Ilość zawiesin ogólnych w ściekach surowych oraz ich ilość trafiająca na oczyszczalnię miały najmniejszy wpływ na aproksymację zmiennych wyjściowych. Ze względu na ilorazy stężenie azotu i fosforu ogólnego miały prawie równoważny wpływ na proces oczyszczania ścieków. Podobna relacja występowała pomiędzy wartością $ChZT_{Cr}$ i temperaturą ścieków surowych.

4. Podsumowanie

Ścieki surowe należą do jednych z najbardziej skomplikowanych pod względem chemicznym cieczy. W trakcie ich biologicznego oczyszczania zachodzą tysiące reakcji jednostkowych, których celem jest biodegradacja zanieczyszczeń. Dokładny opis matematyczny takich zjawisk jest niezwykle trudny, a niejednokrotnie niemożliwy. Stąd, potrzeba stosowania rozbudowanych i złożonych algorytmów, które pozwolą możliwie dokładnie oddać charakter zmian mających miejsce w reaktorach biologicznych. W takim przypadku zadaniem sztucznych sieci neuronowych jest odnalezienie najprostszej relacji, jaka występuje pomiędzy dobranymi parametrami jakościowymi w układzie ściek surowy-ściek oczyszczony.

W niniejszej pracy przedstawiono model, którego zadaniem była predykcja pięciu podstawowych parametrów ścieków oczyszczonych, podlegających okresowej kontroli. W większość prac poświęconych modelowaniu matematycznemu procesów oczyszczania ścieków prezentowane są modele aproksymujące jedną zmienną. Rzadziej spotykane są algorytmy jednocześnie estymujące więcej niż trzy zmienne. Wynika to ze stopnia złożoności i częstotliwości występowania jednostkowych zmian w trakcie procesów biologicznych. Nie mniej prezentowany model pozwolił z dość dużą dokładnością odwzorować zmiany ilościowe podstawowych wskaźników charakteryzujących ścieki oczyszczone.

Literatura

- Akratos, C. S., Papsyros, J. N. E., Tsihrintzis, V. A. (2008). An artificial neural network model and design equations for BOD and COD removal prediction in horizontal subsurface flow constructed wetland. *Chemical Engineering Journal*, 143, 96-110.
- Akratos, C. S., Papsyros, J. N. E., Tsihrintzis, V. A. (2009). Total nitrogen and ammonia removal prediction in horizontal subsurface flow constructed wetlands: Use of artificial neural networks and development of a design equation. *Biosource Technology*, 100, 586-596.
- Akratos, C. S., Papsyros, J. N. E., Tsihrintzis, V. A. (2009a). Artificial neural network use in ortho-phosphate and total phosphorus removal prediction in horizontal subsurface flow constructed wetlands. *Biosystems Engineering*, 102, 190-201.

- Andraka, D., Dzienis, L. (2013). Modelowanie ryzyka w eksploatacji oczyszczalni ścieków, *Rocznik Ochrona Środowiska*, 15, 1111-1125.
- Baczyński, T. (2010). Przegląd metod służących wyznaczaniu frakcji ChZT w ściekach. *Gaz, Woda i Technika Sanitarna*, X, 29-35.
- Badawy, M. I., El-Wahaab, R. A., Moawad, A., Ali, M. E. M. (2010). Assessment of the performance of aerated oxidation ponds in the removal of Persistent Organic Pollutants (POPs): A case study. *Desalination*, 251, 29-33.
- Bartkowska, I., Dzienis, L., Wawrentowicz, D. (2011). Efektywność pracy oczyszczalni ścieków w Hajnówce i propozycja jej modernizacji. *Inżynieria Ekologiczna*, 24, 226-235.
- Benintendi, R. (2015). Modeling and experimental investigation of activated sludge VOCs adsorption and degradation. *Process Safety and Environmental Protection*, 575, 1-9.
- Czapczuk, A., Dawidowicz, J., Piekarski, J. (2015). Metody sztucznej inteligencji w projektowaniu i eksploatacji systemów zaopatrzenia w wodę. *Rocznik Ochrona Środowiska*, 17, 1527-1544.
- Deblonde, T., Cossu-Leguille, C., Hartemann, P. (2011). Emerging pollutants in wastewater: A review of the literature. *International Journal of Hygiene and Environmental Health*, 214, 442-448.
- Dellana, S. A., West, D. (2009). Predictive modeling for wastewater applications: Linear and nonlinear approaches. *Environmental Modeling and Software*, 24, 96-106.
- Demirel, B., Yenigun, O., Onay, T. T. (2005). Anaerobic treatment of dairy wastewaters: a review. *Process Biochemistry*, 40, 2583-2595.
- Dymaczewski, Z. (2008). Charakterystyka frakcji organicznych ścieków miejskich pod kątem modelu osadu czynnego ASM2d. *Przemysł Chemiczny*, 87/5, 440-442.
- Eriksson, E., Christensen, N., Schmidt, J. E., Ledin, A. (2008). Potential priority pollutants in sewage sludge. *Desalination*, 226, 371-388.
- Fang, F., Ni, B-J., Xie, W-M., Sheng, G-P., Liu, S-G., Tong, Z-H., Yu, H-Q. (2010). An integrated dynamic model for simulating a full-scale municipal wastewater treatment plant under fluctuating conditions. *Chemical Engineering Journal*, 160, 522-529.
- Gawdzik J., Szelaż B., Bezak-Mazur E., Stoińska R. (2016). Zastosowanie wybranych modeli nieliniowych do prognozy ilości osadu nadmiernego. *Rocznik Ochrona Środowiska*, 18, 695-708
- Gernaey, K. V., van Loosdrecht, M. C. M., Henze, M., Lind, M., Jørgensen, B. (2004). Activated sludge wastewater treatment plant modeling and simulation: state of the art. *Environmental Modeling and Software*, 19, 763-783.

- Gieru, S., Thiery, F., Traoré, A., Nguyen, T. P., Barreau, M., Polit, M. (2006). KSOM and MLP neural networks for on-line estimating the efficiency of an activated sludge process. *Chemical Engineering Journal*, 116, 1-11.
- Gontarski, C. A., Rodrigues, P. R., Mori, M., Prenem, L. F. (2000). Simulation of an industrial wastewater treatment plant using artificial neural networks. *Computer and Chemical Engineering*, 24, 1719-1723.
- Haimi, H., Mulas, M., Corona, F., Vahala, R. (2013). Data-derived soft-sensors for biological wastewater treatment plants: An overview. *Environmental Modeling and Software*, 47, 88-107.
- Hamed, M., Khalafallah, M. G., Hassanein, E. A. (2004). Prediction of wastewater treatment plant performance using artificial neural network. *Environmental Modeling and Software*, 19, 919-928.
- Hanaby, D., Turkoglu, I., Demir, Y. (2008). Prediction of wastewater treatment plant performance based on wavelet packet decomposition and neural networks. *Expert Systems with Applications*, 34, 1038-1043.
- Hernandez, S. C., Bueno, J. A., Sanchez, E. N., Diaz-Jimenez, L. (2013). State Estimation by Artificial Neural Networks in a Continuous Bioreactor. *IFAC Proceedings Volumes*, 46, 215-220.
- Hong, S. H., Lee, M. W., Lee, D. S., Park, J. M. (2007). Monitoring of sequencing batch reactor for nitrogen and phosphorus removal using neural networks. *Biochemical Engineering Journal*, 35, 365-370.
- Kruger, C., Tzoneva, R. (2007). A neural network model for control of wastewater treatment process. *IFAC Proceedings Volumes*, 40, 981-986.
- Krzemińska, D., Neczaj, E., Parkitna, K. (2013). Zastosowanie reakcji Fentona do wspomagania biologicznego oczyszczania ścieków z przemysłu mleczarskiego. *Rocznik Ochrona Środowiska*, 15, 2381-2397.
- Lee, J-W., Suh, C., Hong, Y-S. T., Shin, H-S. (2011). Sequential modeling of full-scale wastewater treatment plant using and artificial neural network. *Bioprocesses and Biosystems Engineering*, 34, 963-973.
- Lee, J-W., Suh, C., Hong, Y-S. T., Shin, H-S., (2011). Sequential modeling of full-scale wastewater treatment plant using and artificial neural network, *Bioprocesses and Biosystems Engineering*, 34, 963-973.
- Mjalli, F. S., Al-Asheh, S., Alfadala, H. E. (2007). Use of artificial neural network black-box modeling for prediction of wastewater treatment plants performance. *Journal of Environmental Management*, 83, 329-338.
- Moral, H., Aksoy, A., Gokcay, C. F. (2008). Modeling of the activated process by using artificial neural networks with automated architecture screening. *Computers and Chemical Engineering*, 32, 2471-2478.
- Moreno-Alfonso, N., Redondo, C. F. A. (2001). Intelligent waste-water treatment with neural-networks. *Water Policy*, 3, 267- 271.

- Ou, H-S., Wei, C-H., Wu, H-Z., He, B-Y. (2015). Sequential dynamic artificial neural network modeling of a full-scale coking wastewater treatment plant with fluidized bed reactors. *Environmental Science and Pollution Research*, 22, 15910-15919.
- Ou, H-S., Wei, C-H., Wu, H-Z., He, B-Y. (2015). Sequential dynamic artificial neural network modeling of a full-scale coking wastewater treatment plant with fluidized bed reactors. *Environmental Science and Pollution Research*, 22, 15910-15919.
- Piekarski, J. (2011). Zastosowanie metod numerycznych do modelowania procesu filtracji grawitacyjnej. *Rocznik Ochrona Środowiska*, 13, 315-332.
- Pomiès M., Choubert J. M., Wisniewski C., Coquery M. (2013). Modeling of micropollutant removal in biological wastewater treatments: A review. *Science of the Total Environment*, 443, 733- 748
- Ráduly, B., Gernaey, K. V., Capodaglio, A. G., Mikkelsen, P. S. (2007). Artificial neural network for rapid WWTP performance evaluation: Methodology and case study. *Environmental Modeling and Software*, 22, 1208-1216.
- Sadecka, Z., Płuciennik-Koropczuk, E., Sieciechowicz, A. (2011). Frakcje ChZT ścieków w modelach biokinetycznych. *Forum Eksploatatora*, 54, 72-77.
- Sánchez-Avila, J., Bonet, J., Velasco, G., Lacorte, S. (2009). Determination and occurrence of phthalates, alkylophenols, bisphenol A, PBDEs and PAHs in an industrial sewage grid discharging to a Municipal Wastewater Treatment Plant. *Science of The Total Environment*, 407, 4157-4167.
- Skoczko, I., Ofman, P., Szatyłowicz, E. (2016). Zastosowanie sztucznych sieci neuronowych do modelowania procesu oczyszczania ścieków w małej oczyszczalni ścieków. *Rocznik Ochrony Środowiska*, 18, 493-506.
- Sochacki, A., Płonka, L., Miksch, K. (2010). Zastosowanie modeli matematycznych w symulacji procesów oczyszczania ścieków metodą osadu czynnego. *Forum Eksploatatora*, I/II, 5-56.
- Sponza D. T., Gök O. (2010). Effect of rhamnolipid on the aerobic removal of polyaromatic hydrocarbons (PAHs) and COD components from petrochemical wastewater. *Bioresource Technology*, 101, 914- 924
- Struk-Sokołowska, J. (2011). Zmiany udziału frakcji ChZT podczas oczyszczania ścieków z dużym udziałem ścieków mleczarskich. *Rocznik Ochrona Środowiska*, 12, 2015- 2032.
- Struk-Sokołowska, J., Ignatowicz, K. (2013). Współoczyszczanie ścieków komunalnych i mleczarskich przy zastosowaniu technologii SBR. *Rocznik Ochrona Środowiska*, 15, 1881-1898.
- Szetela, R., Dymaczewski, Z. (2002). Modyfikacja obecnej postaci modelu osadu czynnego ASM2d. *Ochrona Środowiska*, 1/84, 3-8.

- Tomenko, V., Ahmed, S., Popov, S. (2007). Modelling constructed wetland treatment system performace. *Ecological Modelling*, 24, 355-364.
- Verma, A., Wei, X., Kusiak, A. (2013). Predicting the total suspended solid in wastewater: A data-mining approach. *Engineering Applications of Artificial Intelligence*, 26, 1366-1372.
- Zielińska, M., Cydzik-Kwiatkowska, A., Zieliński, M., Dębowski, M. (2013). Impact of temperature, microwave radiation and organic loading rate on methanogenic community and biogas production during fermentation of dairy wastewater. *Biosource Technology*, 129, 308-314.
- Çinar, Ö. (2005). New tool for evaluation of performance of wastewater treatment plant: Artificial neural network. *Process Biochemistry*, 40, 2980-2984.

Modelling Changes in the Parameters of Treated Sewage Using Artificial Neural Networks

Abstract

Aim of this study was to develop a model of artificial neural network for changes approximation in concentration and values of basic quality parameters of treated wastewater. Studies were carried out in years 2014 and 2015 in Bystre wastewater treatment plant, located near Giżycko. To Bystre sewage treatment plant inflows mixed domestic and dairy wastewater. In model as input variables were taken seven chemical parameters of raw wastewater and the amount of sewage inflowing to facility. Chosen chemical indicators were describing values of biological and chemical oxygen demand, concentrations of total nitrogen and phosphorus, amount of total suspended solids, pH and temperature of raw wastewater. In presented model the greatest impact on variables approximation had concentrations of total nitrogen and phosphorus. Developed model at it best reflected changes in total suspended solid in treated wastewater.

Streszczenie

Celem pracy było opracowanie modelu sztucznej sieci neuronowej aproksymującej zmiany w stężeniach i wartościach podstawowych parametrów jakościowych ścieków oczyszczonych. Badania prowadzone były w latach 2014 i 2015 w oczyszczalni ścieków w Bystrym koło Giżycka. Obiekt ten oczyszcza zmieszane ścieki komunalne i mleczarskie. W modelu jako zmienne wejściowe wybrano siedem parametrów chemicznych ścieków surowych i ilość ścieków dopływającą do oczyszczalni. Wskaźniki chemiczne uwzględniały wartości biologicznego i chemicznego zapotrzebowania na tlen, stężenia azotu i fosforu ogólnego, ilość zawiesin ogólnych, odczyn oraz temperaturę ścieków. W pre-

zowanym modelu największy wpływ na aproksymację zmiennych wyjściowych miały stężenia azotu i fosforu ogólnego. Opracowany algorytm najlepiej oddał charakter zmian zawiesin ogólnych w ściekach oczyszczonych.

Słowa kluczowe:

oczyszczanie ścieków, ścieki mleczarskie, sztuczne sieci neuronowe

Keywords:

wastewater treatment, dairy wastewater, artificial neural networks