



POLSKA AKADEMIA NAUK
Instytut Badań Systemowych

BADANIA SYSTEMOWE

Tom 76

**MODELOWANIE MATEMATYCZNE,
OPTYMALIZACJA I STEROWANIE
PRACĄ PRZEPLYWOWYCH
OCZYSZCZALNI ŚCIEKÓW**

Bartosz Szelaĝ

Warszawa 2019

MODELOWANIE MATEMATYCZNE, OPTYMALIZACJA I STEROWANIE PRACĄ
PRZEPLYWOWYCH OCZYSZCZALNI ŚCIEKÓW, Bartosz Szelaĝ



**POLSKA AKADEMIA NAUK
INSTYTUT BADAŃ SYSTEMOWYCH**

**Seria: BADANIA SYSTEMOWE
Tom 76**

**Redaktor naukowy:
Prof. dr hab. inż. Olgierd Hryniewicz**

Warszawa 2019

Rada redakcyjna serii: BADANIA SYSTEMOWE

Prof. Janusz Kacprzyk – przewodniczący

Prof. Olgierd Hryniewicz

Prof. Tadeusz Kaczorek

Prof. Jerzy Klamka

Prof. Józef Korbicz

Prof. Zbigniew Nahorski

Prof. Ngoc Thanh Nguyen

Prof. Marek Niezgódka

Prof. Ewaryst Rafajłowicz

Prof. Leszek Rutkowski

Prof. Roman Słowiński

Prof. Jan Studziński

Prof. Tomasz Szapiro

iBS PAN

**POLSKA AKADEMIA NAUK
INSTYTUT BADAŃ SYSTEMOWYCH**

Bartosz Szelağ

**MODELOWANIE MATEMATYCZNE,
OPTYMALIZACJA I STEROWANIE
PRACĄ PRZEPIYWOWYCH
OCZYSZCZALNI ŚCIEKÓW**

Warszawa 2019

**Copyright © by Instytut Badań Systemowych PAN
Warszawa 2019**

Autor:

Dr inż. Bartosz Szela
Wydział Inżynierii Środowiska, Geomatyki i Energetyki
Politechnika Świętokrzyska
bszelag@tu.kielce.pl

Recenzenci:

Dr hab. inż. Ewa Burszta-Adamiak, prof. nadzwyczajny
Uniwersytet Przyrodniczy we Wrocławiu

Dr hab. inż. Izabela Rojek, prof. nadzwyczajny
Uniwersytet Kazimierza Wielkiego w Bydgoszczy

Skład: Anna Gostyńska / Aneta M. Pielak

Wydawca:

Instytut Badań Systemowych
Polska Akademia Nauk
Newelska 6, 01-447 Warszawa
www.ibspan.waw.pl

*Publikacja sfinansowana ze środków projektu RID
Ministerstwa Nauki i Szkolnictwa Wyższego nr 025/RID/2018/19*

ISSN 0208-8029

ISBN 978-83-89475-62-6

1. Wprowadzenie

Poprawa jakości wód odbiorników i ograniczenie niekorzystnego wpływu na środowisko stanowi obecnie jeden z najaktualniejszych tematów zarówno w kraju, jak i zagranicą (Thunberg i in. 2009, Minsoo i in. 2016). W celu poprawy jakości wód powierzchniowych wprowadzono w ustawodawstwie unijnym i krajowym szereg wymagań formalno-prawnych, narzucających wielkości dopuszczalnych stężeń wskaźników jakości ścieków oczyszczonych, które nie mogą zostać przekroczone. Potwierdzeniem tego w skali europejskiej jest to dyrektywa unijna 91/271/EWG odnosząca się do kwestii oczyszczania ścieków komunalnych. Natomiast, w kraju jest to Rozporządzenie Ministra Środowiska z dnia 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. Zgodnie z obowiązującymi aktami prawnymi podstawą projektowania oczyszczalni jest równoważna liczba mieszkańców (RLM), która stanowi podstawę doboru technologii oczyszczania ścieków. Zaprojektowany układ technologiczny ma zapewniać odpowiednie usunięcie związków organicznych (BZT_5 , $ChZT_{(Cn)}$), azotu ogólnego (N_{og}) i fosforu ogólnego (P_{og}) (tab.1.1).

W warunkach rzeczywistych wartości wskaźników jakości przyjęte do obliczeń oczyszczalni ścieków nie przyjmują wartości stałych, ale zmieniają się w szerokim zakresie. Równocześnie, zmienia się ilość dopływających ścieków i temperatura powietrza, co ma istotny wpływ na przebieg procesów oczyszczania przebiegających w reaktorze biologicznym. Podczas intensywnych opadów znacznie zwiększa się ilość dopływających ścieków, co prowadzi zwykle do hydraulicznego przeciążenia całego obiektu i wpływa na skrócenie czasu zatrzymania ścieków w reaktorze biologicznym. Równocześnie, zwiększony dopływ ścieków może prowadzić do przeciążenia hydraulicznego wydzielonych obiektów oczyszczalni, na przykład osadnika wtórnego, co niekorzystanie wpływa na proces klarowania oczyszczonych ścieków. Jednocześnie, z uwagi na rozcieńczenie dopływających ścieków, mogą wystąpić problemy związane z niedostateczną ilością związków biogennych niezbędnych do prawidłowego

przebiegu procesu oczyszczania (usuwania związków organicznych, azotu i fosforu).

Tab. 1.1. Wpływ wielkości oczyszczalni ścieków (RLM) na wymagany stopień redukcji zanieczyszczeń na odpływie z oczyszczalni ścieków; BZT₅ – pięciodniowe biochemiczne zapotrzebowanie na tlen, ChZT_(Cr) – chemiczne zapotrzebowanie na tlen wykonane metodą dwuchromianową, Z_{og} – zawiesiny ogólne, N_{og} – azot ogólny, P_{og} – fosfor ogólny, x^a – wartości wymagane wyłącznie w ściekach wprowadzanych do jezior i ich dopływów oraz bezpośrednio do sztucznych zbiorników wodnych usytuowanych na wodach płynących, x^b – minimalny procent redukcji nie ma zastosowania do ścieków wprowadzanych do jezior i ich dopływów, bezpośrednio do sztucznych zbiorników wodnych usytuowanych na wodach płynących oraz do ziemi (Dz. U. poz. 1800, 2014).

Wskaźniki	RLM				
	<2000	2000÷9999	10000÷14999	15000÷99999	>100000
BZT ₅ , mgO ₂ /l	40	25	25	15	15
BZT ₅ , min %		70-90	70-90	90	90
ChZT _(Cr) , mgO ₂ /l	150	125	125	125	125
ChZT _(Cr) , min %		75	75	75	75
Z _{og} , mg/l	50	35	35	35	35
Z _{og} , min %		90	90	90	90
N _{og} , mg/l	30 ^a	15 ^a	15	15	10
N _{og} , min %		-	70-80 ^b	70-80	70-80
P _{og}	5 ^a	2 ^a	2	2	1
P _{og} , min %		-	70-80 ^b	80	80

Eksploatując oczyszczalnię ścieków należy mieć na uwadze fakt, że w okresie zimowym na skutek obniżenia temperatury powietrza ma miejsce obniżenie kinetyki procesów zachodzących w reaktorach biologicznych, co także może prowadzić do pogorszenia jakości ścieków na odpływie. Należy także liczyć się z faktem, że mimo stabilnych warunków pracy reaktora (tj. brak opadów atmosferycznych, okres lata lub wiosny wpływające pozytywnie na stabilność procesu oczyszczania) mogą wystąpić niekontrolowane zrzuty ładunków zanieczyszczeń do systemu kanalizacyjnego, co może mieć niekorzystny wpływ na działanie obiektów technologicznych oczyszczalni i powodować konieczność zmiany nastaw w regulatorach reaktora. Wymienione czynniki mogą prowadzić do zakłóceń ciągłości przebiegu procesu oczyszczania ścieków. Dlatego też, w celu

uzyskania na odpływie wymaganych wartości wskaźników jakości ścieków, zachowania ciągłości procesów zachodzących w reaktorze biologicznym i utrzymania wysokiej niezawodności działania oczyszczalni, konieczne jest aktywne sterowanie i bieżąca kontrola nastaw reaktora biologicznego. W praktyce jest to zadanie bardzo skomplikowane, wymagające ciągłych zmian wielu nastaw regulatorów w taki sposób, aby zapewnić wymaganą jakość ścieków oczyszczonych i aby sterując jednym procesem, nie zakłócić innych procesów przebiegających w bioreaktorze.

Z uwagi na to, że eksploatacja oczyszczalni ścieków wymaga równoczesnej kontroli wielu procesów, stosuje się szereg urządzeń pomiarowych zamontowanych na jej obiektach technologicznych. Pożądaną sytuacją byłoby prowadzenie pomiarów ilości i jakości ścieków na dopływie, nastaw reaktora oraz jakości ścieków na odpływie z oczyszczalni. Obecnie większość obiektów krajowych posiada monitoring on-line nastaw reaktora biologicznego i jakości ścieków na odpływie. Natomiast, rzadko występują przypadki, gdy prowadzone są ciągłe pomiary jakości ścieków na dopływie do obiektu. Stan ten wynika z faktu, iż zgodnie z obowiązującymi aktami prawnymi nie ma takich wymagań i zachodzi jedynie potrzeba okresowej oceny efektywności działania oczyszczalni ścieków w zależności od wielkości obiektu wyrażonej za pomocą równoważnej liczby mieszkańców – RLM (tab. 1.2).

Tab. 1.2. Wpływ wielkości oczyszczalni ścieków (RLM) na roczną liczbę próbek poboru jakości ścieków (Dz. U. poz. 1800, 2014)

RLM	Liczba próbek	
	Pierwszy rok	Kolejny rok po spełnieniu wymagań
<2000	4	2
2000 ÷ 9999	12	4
10000 ÷ 49999	12	12
>50000	24	24

Standardowo, w przypadku obiektów RLM < 2000 pomiary efektywności pracy oczyszczalni należy kontrolować pobierając 4 próbki w ciągu roku; jeżeli pobrane próbki spełnią wymagane warunki, to w kolejnym roku pobierane mogą być 2 próbki (tab. 1.2). Dla obiektów, gdzie $9999 > \text{RLM} > 2000$, w przypadku uzyskiwania wysokiej efektywności możliwe jest także ograniczenie w kolejnym roku liczby próbek. Z kolei, dla oczyszczalni RLM > 10000 nie jest możliwa redukcja ilości analizowanych próbek na dopływie.

Pomiar jakości ścieków na dopływie nie stanowi obecnie dużego problemu technicznego z uwagi na to, że istnieje szereg analizatorów (np. firmy Endress–Hausser, HahLange itp.) umożliwiających pomiar odpowiednich wskaźników jakości, jednak koszt ich zakupu i eksploatacji jest wysoki. Równocześnie do stosowania ich zniechęca fakt, że urządzenia te należy okresowo kalibrować w celu uzyskania wiarygodnych wyników pomiarów, co generuje dodatkowe koszty i wymaga uciążliwego ciągłego nadzoru.

Należy przy tym zauważyć, że w oczyszczalniach ścieków zarówno o wysokim stopniu zautomatyzowania i rozbudowanym systemie monitoringu, jak i w obiektach, gdzie pomiary wykonywane są głównie na drodze oznaczeń laboratoryjnych, gromadzone są ogromne ilości danych mogących służyć do opracowania modeli procesowych. Fakt ten wzbudza szerokie zainteresowanie, na co wskazuje znaczna liczba publikacji zagranicznych. W publikacjach tych na podstawie zgromadzonych danych pomiarowych opracowuje się modele matematyczne do prognozowania jakości ścieków na odpływie oraz kontroli przebiegu procesów nityfikacji, denityfikacji i defosfatacji. Jednak z punktu widzenia eksploatatora oczyszczalni ścieków interesujące jest nie tylko prognozowanie przebiegu procesu i jego symulacja. Istotne znaczenie ma także sterowanie procesem, to znaczy wyznaczanie takich nastaw bioreaktora, aby zapewnić przebieg procesu warunkujący zadane wartości ścieków na odpływie i zminimalizowanie kosztów eksploatacyjnych obiektu. Takie postawienie zadania cieszy się ostatnio coraz większym zainteresowaniem, co potwierdza zwiększająca się liczba odnośnych prac w kraju i zagranicą, choć publikacji krajowych na ten temat jest zdecydowanie mniej.

Parametry działania reaktora biologicznego można ustalać w taki sposób, że bez względu na ilość i jakość ścieków dopływających oraz na porę roku, na odpływie uzyska się wartości wskaźników jakości ścieków poniżej wartości dopuszczalnych. Jednak problem polega na tym, że realizując takie nastawy zwykle nie uwzględnia się kosztów eksploatacyjnych obiektu, które mogą być wysokie. Wobec powyższego nasuwa się pytanie, czy nie można byłoby nastaw w bioreaktorze skorygować w taki sposób, aby uzyskać zbliżony efekt oczyszczania ścieków, ale niższym kosztem. Aby odpowiedzieć na to pytanie i uniknąć ewentualnych problemów eksploatacyjnych związanych z możliwym zakłóceniem pewnych procesów technologicznych przy sterowaniu innym procesem, jest konieczna optymalizacja pracy oczyszczalni i zdefiniowanie w tym celu odpowiednich kryteriów optymalizacyjnych. Podstawowym kryterium oceny efektywności pracy oczyszczalni jest kryterium ekonomiczne: proces oczyszczania powinien być realizowany w taki sposób, aby uzyskać najniższe koszty eksploatacji przy zapewnieniu wymaganej jakości ścieków oczyszczonych. Kolejne kryteria mogą mieć charakter techniczny i odnosić się do utrzymania na odpowiednim poziomie przebiegu poszczególnych procesów w reaktorze

biologicznym, do minimalizacji zużycia dawkowanych środków chemicznych lub minimalizacji zużycia tlenu na napowietrzanie ścieków. Kryteriów technicznych może być wiele, ponieważ jest to uzależnione od tego, co technolog chce przede wszystkim uzyskać. Kryteriami stanowiącymi kombinacje kryterium ekonomicznego i kryteriów technicznych są kryteria niezawodnościowe. W takim przypadku można skoncentrować się na analizie niezawodności działania obiektu w odniesieniu do jednego procesu najistotniejszego dla technologa lub do kilku procesów równocześnie. W ostatnich latach przedstawiono szereg interesujących prac z zakresu zastosowania modelowania matematycznego w optymalizacji i sterowaniu oczyszczalniami ścieków (np. Mulas i in. 2015, Corominas i in. 2013, Asadi i in. 2016), jednak mimo licznych analiz o charakterze teoretycznym, jedynie w jednym z 40 badanych obiektów wdrożono opracowany model matematyczny (Haimi i in. 2013). W obszarze sterowania do rozwiązania pozostaje cały szereg zagadnień dotychczas nie badanych, które dotyczą m.in. sterowania reaktorem w przypadku, gdy nie są prowadzone ciągle pomiary wskaźników jakości ścieków na dopływie a jedynie pomiary okresowe, co ma miejsce w większości krajowych oczyszczalni ścieków. Mimo potwierzonego wpływu procesu sedymentacji na jakość ścieków na odpływie w dalszym ciągu fakt ten jest uwzględniany w ograniczonym stopniu przy doborze strategii sterowania reaktorem biologicznym. Jednocześnie, mimo wielu analiz dotyczących procesu sedymentacji osadu czynnego, nie opracowano dotychczas uniwersalnej zależności pozwalającej ocenić podatność osadu na puchnięcie, która byłaby pomocna na etapie sterowania reaktorem biologicznym.

O skali poruszanego problemu i zapotrzebowania na odpowiednie algorytmy obliczeniowe może świadczyć fakt, że na terenie Polski wg danych GUS (BDL, 2017) znajduje się 3258 komunalnych oczyszczalni ścieków, z czego 11 obiektów oczyszcza ścieki mechanicznie, 2439 biologicznie i 808 obiektów realizuje podwyższony stopień redukcji zanieczyszczeń. Całkowita liczba oczyszczalni nie odzwierciedla bezpośrednio skali problemu, bowiem trzeba na to popatrzeć szerzej, biorąc pod uwagę ilość gmin w kraju tj. 2478 oraz liczbę miast na prawach powiatu tj. 66. Mianowicie dla „dużych jednostek osadniczych” zaprojektowany układ oczyszczania ścieków musi warunkować usuwanie związków organicznych, w tym azotu i fosforu. W tych przypadkach, ze względu na przepustowość obiektów przekroczenie dopuszczalnych wartości wskaźników prowadziłoby do wprowadzenia do odbiornika ścieków znacznych ilości zanieczyszczeń, które mogłyby prowadzić do naruszenia równowagi ekosystemu i mieć daleko idące następstwa ekologiczne. W związku z tym, na tych obiektach instaluje się systemy do kontroli i sterowania reaktorem, co istotnie wpływa na efektywność ich pracy. Rozwiązanie to nie jest tak powszechne w mniejszych oczyszczalniach ścieków, które są bardziej wrażliwe na zmiany ilości i jakości dopływających ścieków, co ma wpływ na ilość zanieczyszczeń trafiającą do odbiorników. Dlatego też, szczególnie w przypadku mniejszych oczyszczalni zachodzi potrzeba ciągłego

monitoringu i aktywnego sterowania bioreaktorem w celu uzyskania wymaganej jakości ścieków na odpływie. W przypadku dużych obiektów, z uwagi na wielkość zamontowanych energochłonnych urządzeń i ilość dopływających ścieków, bardziej wskazana jest optymalizacja procesu oczyszczania mająca na celu obniżenie kosztów eksploatacyjnych.

W pracy przedstawiono koncepcję systemu do kontroli, sterowania i optymalizacji działania reaktora biologicznego w przepływowej oczyszczalni ścieków. W systemie tym przewidziano zastąpienie pomiarów wskaźników jakości ścieków na dopływie wynikami obliczeń uzyskanymi w oparciu o pomiary natężenia przepływu. Do symulacji wartości wskaźników jakości ścieków zaproponowano zastosowanie metod eksploracji danych (ang. data mining). Po wykonaniu wstępnych obliczeń modelowania przedstawiono koncepcję modeli hybrydowych, w których wartości pomiarów wskaźników jakości ścieków dopływających do oczyszczalni zastąpiono wynikami ich symulacji. Modele te zastosowano do prognozy: sedymentacji osadu czynnego, zmieniających się wartości kluczowych parametrów technologicznych reaktora biologicznego wskaźników jakości ścieków na odpływie z oczyszczalni.

Opracowano także modele matematyczne do analizy niezawodności działania reaktora biologicznego w oparciu o tzw. współczynniki niezawodności w odniesieniu do procesu sedymentacji osadu czynnego i poprawności procesu usuwania związków biogennych.

Ponadto, zaproponowano nowatorski parametr uwzględniający interakcje między zmiennymi procesowymi o charakterze stochastycznym. Zmienne te dotyczą ilości i jakości ścieków na dopływie, warunków atmosferycznych i ich wpływu na podatność osadu czynnego na puchnięcie oraz doboru strategii sterowania reaktorem biologicznym.

Przedstawiono także model probabilistyczny niezawodności działania reaktora biologicznego w odniesieniu do sedymentacji osadu czynnego, w którym uwzględniono występowanie awarii systemu pomiarów wskaźników jakości ścieków na dopływie do oczyszczalni.

Przyjęto następujący układ pracy:

W rozdziale 2 omówiono metody biologicznego oczyszczania ścieków i scharakteryzowano rolę poszczególnych obiektów zlokalizowanych w ciągu technologicznym oczyszczalni. Omówiono w nim także rozwiązania technologiczne eksploatowanych systemów oczyszczania ścieków, przy czym skoncentrowano się na parametrach operacyjnych reaktorów i ich wpływie na efektywność działania obiektu.

W rozdziale 3 omówiono obecny stan wiedzy z zakresu modelowania pracy reaktorów biologicznych, ich sterowania i optymalizacji. W rozdziale opisano

także opracowane dotychczas modele do analizy i oceny niezawodności działania oczyszczalni ścieków.

W rozdziale 4 scharakteryzowano obiekty badań uwzględnione w pracy, to znaczy oczyszczalnie ścieków w Sitkówce–Nowiny i Trepczy (dalej również: oczyszczalnia Sitkówka–Nowiny i oczyszczalnia Trepcza).

W rozdziale 5 przedstawiono stosowane w badanych oczyszczalniach metody pomiarów ilości i jakości ścieków oraz parametrów działania reaktorów biologicznych. Przeanalizowano także wiarygodność i jakość danych pomiarowych pozyskiwanych w badanych oczyszczalniach ścieków. Na podstawie zgromadzonych danych wyznaczano podstawowe miary statystyczne opisujące zmienność ilości i jakości ścieków oraz parametrów działania reaktorów w tych oczyszczalniach.

W rozdziale 6 badano możliwość zastosowania wyznaczanych modeli matematycznych do symulacji reaktora biologicznego oczyszczalni i oceny niezawodności jego funkcjonowania. Metody obliczeniowe zastosowane do wyznaczania modeli porównano pod kątem ich złożoności i jej wpływu na szybkość i dokładność wykonywanych obliczeń.

W rozdziale 7 przedstawiono i oceniono wyniki obliczeń dotyczące ilości i jakości ścieków na dopływie i odpływie z oczyszczalni oraz parametrów technologicznych reaktora biologicznego. W rozdziale zaprezentowano także nowatorskie zastosowanie modelu regresji logistycznej do oceny wpływu wrażliwości poszczególnych zmiennych wejściowych modelu na prognozę dopływu ścieków do oczyszczalni. Podejście to jest innowacyjne z uwagi na to, że taki model nie był dotychczas stosowany w tego typu zadaniach, a jedynie wykorzystywany w typowych zagadnieniach klasyfikacji. Wykonane obliczenia pozwalają na uogólnienie uzyskanych wyników z uwagi na to, że symulacje komputerowe przeprowadzono dla dwóch istotnie różnych obiektów (w oczyszczalniach Sitkówka–Nowiny i w Rzeszowie), a otrzymane wyniki okazały się w obu przypadkach zbliżone.

Na przykładzie danych z zakresu natężenia przepływu ścieków przeanalizowano wpływ długości szeregów czasowych, sposobu gromadzenia danych (ciągły, nieciągły) w zależności od dobranej metody eksploracji danych na zdolności predykcyjne modelu. Wykonane analizy pozwoliły ustalić minimalną długość okresu prowadzenia pomiarów warunkującą otrzymanie zadowalających wyników symulacji w zależności od sposobu zapisywania danych i dobranej metody.

W rozdziale 7 przedstawiono także koncepcję modelowania wskaźników jakości ścieków na podstawie wartości parametrów mierzonych w każdej oczyszczalni, to znaczy natężenia przepływu dopływających ścieków. Podejście to

można potraktować jako innowacyjne z uwagi na to, że analizy wykonywane przez innych autorów wykazywały wprawdzie podobną zależność, jednak nie była ona szczegółowo badana. Należy przy tym podkreślić, że wykonane w pracy badania dotyczyły nie tylko jednego obiektu, ale dwóch różnych oczyszczalni ścieków (Sitkówka–Nowiny i w Rzeszowie), co pozwala na uogólnienie wyników. Fakt, że możliwe jest modelowanie jakości ścieków w oparciu o pomiary przepływu ścieków dopływających wykorzystano przy prognozowaniu działania reaktora biologicznego w odniesieniu do jakości ścieków na odpływie (stężenia $N - NH_4$, P_{og} i N_{og}) i sedymentacji osadu czynnego (objętościowego indeksu osadu). Przedstawione w pracy podejście do prognozy działania bioreaktora stanowi również pewną innowację w porównaniu z pracami innych autorów z uwagi na to, że w wyznaczanych obecnie modelach trudno uzyskiwane wartości pomiarów wskaźników jakości ścieków zostają wyeliminowane i zastąpione wartościami obliczeń. W praktyce pozwala to na symulację działania reaktora biologicznego również w przypadku braku ciągłych pomiarów wskaźników jakości ścieków, co do tej pory w pracach innych autorów było pomijane.

W rozdziale 7 omówiono także porównanie wyników symulacji wyznaczonych za pomocą różnych modeli klasyfikacyjnych, zaczynając od najprostszych modeli w postaci regresji logistycznej, modelu liniowego dyskryminacyjnego (LDA), a kończąc na bardziej skomplikowanych modelach uzyskanych metodami data mining. Otrzymane wyniki analiz wykazały, że możliwe jest modelowanie zjawiska sedymentacji osadu czynnego z zadowalającą dokładnością za pomocą jawnych zależności regresyjnych, co w odniesieniu do prac innych autorów (Han Qiao i in. 2012, 2013, 2016, Boztoprak in. 2016, Bagherii i in. 2016) stanowi znaczne uproszczenie symulacji rozpatrywanego zjawiska.

W rozdziale 8 zaproponowano algorytm obliczeniowy modelu do doboru sterowania oczyszczalnią ścieków, wykorzystując wprowadzone wcześniej współczynniki niezawodności w odniesieniu do sedymentacji osadu i poprawności przebiegu procesu usuwania związków biogenych w przypadku, gdy w ciągach pomiarów dotyczących wskaźników jakości ścieków występują nieciągłości. W rozdziale zaproponowano także nowy parametr uwzględniający interakcje między zmiennymi operacyjnymi reaktora o charakterze losowym (ilość i jakość ścieków oraz warunki atmosferyczne), na podstawie którego można ocenić, czy wystąpi puchnięcie osadu i będzie można ustalić odpowiednią strategię sterowania bioreaktorem. W porównaniu z pracami innych autorów zaproponowane podejście jest nowatorskie, bowiem daje możliwość kontroli i sterowania reaktorem biologicznym w przypadku ograniczonego dostępu do pomiarów jakości ścieków opisujących analizowane zjawisko. Nowy parametr, zdefiniowany dla przypadku oczyszczalni Sitkówka–Nowiny, przetestowano także na przykładzie oczyszczalni

Trepcza, badając jego przydatność do oceny podatności osadu czynnego na puchnięcie.

W rozdziale 8 opracowano także model probabilistyczny do oceny niezawodności działania osadnika wtórnego przy wykorzystaniu generatorów liczb losowych (Monte Carlo), w którym ujęto możliwość wystąpienia awarii. Należy podkreślić, że dotychczas potencjalne awarie nie były ujmowane w modelach probabilistycznych do symulacji pracy oczyszczalni.

W rozdziale 9 zaproponowano rozwiązanie kilku zadań optymalizacji pracy reaktora biologicznego na przykładzie oczyszczalni w Sitkówce–Nowiny. W tym przypadku dysponowano kompletem danych dotyczących ilości dopływających ścieków, ich jakości na dopływie i odpływie z oczyszczalni oraz parametrów operacyjnych bioreaktora.

3. Stan badań w zakresie modelowania, optymalizacji i sterowania oczyszczalni ścieków

Historia modelowania procesów zachodzących w osadzie czynnym, realizowanego w różnych działach inżynierii środowiska, jak hydrologia, hydraulika itp., jest stosunkowo krótka, bowiem pierwszy uproszczony model matematyczny opisujący procesy w bioreaktorze podali Lawrence i McCarthy w 1970 r. Opracowany przez nich model fizyczny opisywał trzy typy reaktorów (z idealnym mieszaniem bez recyrkulacji, z idealnym mieszaniem i recyrkulacją oraz z przepływem tłokowym i recyrkulacją). Kolejne etapy tworzenia modeli fizycznych procesu oczyszczania ścieków polegały na ich uszczegółowianiu i ich modyfikacjach wynikających z rosnących wymagań dotyczących jakości ścieków oczyszczonych wprowadzanych do odbiornika. Jednak, z uwagi na znaczną złożoność takich modeli i potrzebę estymowania licznych występujących w nich parametrów stwierdzono, że kalibracja modeli fizycznych jest nadmiernie skomplikowana, a uzyskany wynik nie zawsze jest zadowalający. Dlatego też, podjęto poszukiwania alternatywnych narzędzi pozwalających na symulację procesu oczyszczania ścieków za pomocą prostszych w opisie modeli parametrycznych. Z teoretycznego punktu widzenia za przełom w rozwoju modeli parametrycznych można uznać 1958 rok, kiedy Rosenblatt stworzył model sztucznej sieci neuronowej. W latach 1960-tych nastąpił gwałtowny rozwój technik komputerowych i języków programowania. Skutkowało to szybkim rozwojem badań w obszarze modelowania osadu czynnego za pomocą modeli parametrycznych, tzw. czarnej skrzynki (ang. Black Box Models) i równolegle modeli fizycznych, co było spowodowane wzrostem szybkości obliczeń i pojemności pamięci nowych komputerów.

Reasumując, modele stosowane do symulacji pracy oczyszczalni ścieków można w ogólności podzielić na modele fizyczne i parametryczne. Przy tym modele fizyczne, bazujące na układach równań różniczkowych opisujących procesy biochemiczne przemian związków węgla, azotu i fosforu, jakie mają miejsce w reaktorze biologicznym, są bardziej dokładne, bo starają się odwzorować opisywaną rzeczywistość, i jednocześnie są bardziej złożone. Powszechnie do fizycznego opisu procesów oczyszczania ścieków stosuje się modele ASM (ang. Activated Sludge Models), opracowane przez ekspertów

organizacji IWA (International Water Association). Wśród tych modeli najczęściej stosuje się model ASM1, uwzględniający procesy utleniania związków węgla i azotu w procesach nityfikacji i denityfikacji, oraz model ASM2 i jego zmodyfikowaną wersję ASM2d, pozwalające na symulację usuwania węgla, azotu i fosforu metodą biologiczną oraz dodatkowo za pomocą chemicznego strącania. Ponadto, opracowano także model ASM3, w którym ujęto wymienione wyżej procesy i dodano możliwość rozbudowy modelu o dodatkowe moduły obliczeniowe.

Modele ASM, mimo ich dążenia do wiernego odzwierciedlenia rzeczywistości, mają jednak również pewne niedokładności. Na przykład, przyjmowana w nich charakterystyka jakości ścieków istotnie odbiega od stosowanej codziennie na oczyszczalni. W modelach tych przyjęto podział zanieczyszczeń na frakcje rozpuszczalne (składniki cieczy przepływającej przez obiekty oczyszczalni i opuszczającej ją w postaci ścieków oczyszczonych biologicznie) i nierozpuszczalne (składniki zawiesiny sedymentującej w osadnikach wstępnych i wtórnych). Ponadto, istnieje podział na frakcje organiczne, uczestniczące w procesach redukcji związków organicznych, oraz frakcje azotu i fosforu uczestniczące w procesach nityfikacji, denityfikacji oraz defosfatacji (Alex i in. 2010). Podział azotu całkowitego i fosforu całkowitego na frakcje jest dokładniejszy, niż w codziennej praktyce eksploatacyjnej oczyszczalni. Ponadto, obliczenia modelu ASM2d wykonane na przykład dla oczyszczalni w Poznaniu wykazały konieczność jego modyfikacji w odniesieniu do opisu przemian związków fosforu przy dużej zawartości LKT (Lotne Kwasy Tłuszczowe) w ściekach surowych, z uwagi na niezadowalającą zgodność pomiarów z wynikami obliczeń (Brdjanovic 1998, Henze i in. 1999, Szetela i Dymaczewski 2002). Modyfikacji modelu ASM2d dokonali również Mąkinia i in. (2010), którzy uwzględnili w swoich obliczeniach, że hydroliza związków nierozpuszczalnych zachodzi w dwóch etapach, co oddaje stan faktyczny, a nie ma przebiegu jednostopniowego, przyjętego w modelu oryginalnym. Wykonane przez licznych autorów analizy teoretyczne i badania laboratoryjne wykazały, że opracowane w IWA modele ASM2, ASM2d i ASM3 mają jednak ograniczone zastosowanie i konieczne są ich modyfikacje (Lee 2002, Wintgens i in. 2003, Iacopozzi i in. 2007, Sathyamoorthy i in. 2013, Janus 2014).

Głównym zadaniem modeli oczyszczalni ścieków jest prognoza dynamiki procesów biochemicznych w reaktorze biologicznym w czasie rzeczywistym, dlatego zastosowanie modeli fizykalnych do tego celu jest ograniczone z uwagi na stochastyczny charakter wielu zmiennych procesowych i długi czas obliczeń. W związku z powyższym, modele fizykalne stosowane są głównie do obliczeń w układzie off-line optymalizacji procesu oczyszczania ścieków. Aby obliczenia te były użyteczne dla technologów oczyszczalni, konieczne jest odtworzenie takich warunków na dopływie do obiektu, jakie panują w rzeczywistości (zmieniający się

dopływ ścieków, temperatura powietrza i ścieków, jakość ścieków itp.). Symulacja tych warunków jest możliwa przy zastosowaniu generatorów ilości i jakości ścieków na dopływie, w tym również poszczególnych frakcji zanieczyszczeń występujących w modelach ASM (Gearney i in. 2011, Snip i in. 2014), lub za pomocą modeli hydrodynamicznych systemów kanalizacji deszczowej, sanitarnej lub ogólnospławnej, wyznaczanych w oparciu o wieloletnie szeregi opadów deszczów (Cartensen i Nielsen 1998, Voijnovic i in. 2003, Szelağ i in. 2016). Z uwagi na to, że modele matematyczne, w szczególności modele hydrodynamiczne, stanowią jedynie przybliżony opis zjawiska odpływu ścieków z sieci kanalizacyjnej, ich zastosowanie jest ograniczone. Mimo tego, są prowadzone liczne badania dotyczące optymalizacji pracy oczyszczalni z wykorzystaniem modeli fizykalnych, dla których wyznacza się długookresowe szeregi czasowe będące podstawą modelowania ilości i jakości ścieków dopływających do badanego obiektu (tab. 3.1). Jednym z częstszych zadań rozwiązywanych za pomocą modeli fizykalnych jest symulacja jakości ścieków odpływających z reaktora, w celu kontroli uzyskania wymaganych wartości wskaźników jakości w ściekach oczyszczonych, określonych w Rozporządzeniu Ministra Środowiska z dnia 18 listopada 2014 roku. W rozważaniach praktycznych w wielu przypadkach do oceny działania oczyszczalni, poza wartościami standardowych wskaźników, stosuje się wskaźnik jakości EQI (ang. Effluent Quality Index), wyrażający całkowity ładunek zanieczyszczeń odpływający z oczyszczalni w analizowanym okresie. Kolejnym kryterium stanowiącym podstawę oceny pracy reaktorów biologicznych są koszty energii, które ujmuje się za pomocą wskaźnika kosztów eksploatacyjnych OCI (ang. Operational Cost Index), uwzględniającego koszty energii elektrycznej zużytej na pompowanie ścieków, ich napowietrzanie itp. Ponadto, w okresie ostatnich 10 lat zainteresowano się wpływem działania oczyszczalni na ilość gazów cieplarnianych emitowanych podczas przebiegu poszczególnych procesów technologicznych, definiując wskaźnik GHI (ang. Greenhouse Gas Index). Kolejny etap w rozwoju modeli fizykalnych stanowi z pewnością uwzględnienie problemu odorów i ich ograniczenie, co wymaga integracji opracowanych do tej pory modeli z narzędziami do prognozy jakości powietrza.

Przykład zastosowania modelu oczyszczalni ścieków Flemish w Belgii (model ASM1) do oceny wpływu doboru nastaw reaktora na przebieg procesu przedstawili Devisscher i in. (2006), którzy dla rocznych danych dotyczących zmienności dopływu i jakości ścieków wykonali symulację kosztów eksploatacyjnych obiektu z uwzględnieniem kosztów energii elektrycznej. W obliczeniach badano stopnie redukcji azotu i fosforu w ściekach oczyszczonych, przy czym w przypadku fosforu uwzględniano stosowanie koagulantu żelazowego. Wykonane symulacje wykazały, że sterowanie on-line reaktorem w porównaniu ze stosowaną w praktyce regulacją manualną nastaw prowadzi do obniżenia kosztów napowietrzania o ok. 10%, obniżenia zużycia odczynników chemicznych o ok.

3. Stan badań w zakresie modelowania, optymalizacji i sterowania oczyszczalni ścieków

30% i poprawy jakości ścieków o ok. 5%. Ponadto, wprowadzenie systemu on-line sterowania w warunkach przeciążenia ładunkiem zanieczyszczeń prowadzi do obniżenia zużycia odczynników chemicznych o ok. 4% i poprawy jakości ścieków na odpływie o ok. 5%. W przypadku niedociążenia obiektu, zastosowanie systemu sterowania on-line skutkuje obniżeniem kosztów napowietrzania o ok. 5%, zużycia środków chemicznych o ok. 12% i poprawą jakości ścieków na odpływie o ok. 3%.

Tab. 3.1. Zestawienie przykładowych prac z zakresu optymalizacji działania reaktora przy użyciu modeli fizykalnych.

Źródło	Oczyszczalnia ścieków	Prognoza	Zmienne sterujące	Metoda	Kryteria
Gearney i in. (2006), (2014)	K (ASP)	ChZT, N – NH ₄ , N _{og}	kLA, M _{nadm}	BSM2	ChZT, N – NH ₄ , TN
Xie i in. (2011)	K (Carousel)	ChZT, N – NO ₃ , N – NH ₄	HT, WO, Q _{wewn}	ASM +SVR/GA	ChZT, N – NO ₃ , N – NH ₄
Sotomayor i in. (2002), Vrecko i in. (2006)	K (ASP)	N – NH ₄ , N – NO ₃ , Z _{og}	Q _{pow} , Q _{wewn} , N-NO ₃ , REC	ASM	N – NH ₄ , N – NO ₃
Puchongkawar in i in. (2015)	K (ASP)	N – NO ₃ , N – NH ₄	kLA, M _{nadm} , REC, Q _{wewn}	BSM2	N – NO ₃ , N – NH ₄
Ingildsen i in. (2007)	K (Biodenitro)	N – NO ₃ , P – PO ₄	długość cykli (tlenowy, beztlenowy)	ASM2d	N – NO ₃ , P – PO ₄
Gearney i in. (2002)	K (ASP)	P – PO ₄	Fe(OH) ₃ /FePO ₄	ASM2d	Z _{og} , N _{og}
Seggeleke i in. (2005)	K (ASP)	N – NH ₄	kLA, Q _{wewn}	SIMBA	N – NH ₄
Ayesa i in. (2006)	K (ASP)	N – NH ₄	kLA, M _{nadm} , Q _{wewn}	ASM1	N – NH ₄
Alex i in. (2009)	K (ASP)	N – NH ₄	opt. rozdziału ścieków i procesu napowietrzania	ASM3	N – NH ₄
Błaszkiwicz i in. (2014)	K (SBR)	N – NH ₄	DO	ASM2d	N – NH ₄

Tab. 3.1. cd.

Źródło	Oczyszczalnia ścieków	Prognoza	Zmienne sterujące	Metoda	Kryteria
Zhu i in. (2017)	K (ASP)	$N - NH_4$	kLA ($N - NH_4, L_{N-NH_4}$)	ASM	$N - NH_4$
Drewnowski, Zmarzły (2017)	K (ASP)	$N - NH_4$	Q_{wewn}, DO, m_{met}	ASM	$N - NH_4$
Pijakova, Derco (2013)	K (ASP)	ChZT, $N - NH_4,$ $N - NO_3$	WO, X_{OC}	ASM1	EQI
Devisscher i in. (2006)	K (ASP)	BZT ₅ , ChZT, $Z_{og}, N_{og},$ $N - NH_4$	$M_{nadm}, Fe_xZ_y,$ kLA	ASM2d	EnEI, t_z
Beraud i Steyer (2007)	K (ASP)	BZT ₅ , ChZT, $Z_{og}, N_{og},$ $N - NH_4$	kLA, Q_{wewn}	BSM1+ GA	EnEI, EQI
Balku i Berber (2006)	K (ASP)	ChZT, Z_{og}, TN	kLA	ASM1	EnEI
Nguyen i in. (2013)	K (ASP)	BZT ₅ , ChZT, Z_{og}, N_{og}	kLA	BSM1	EnEI
Zhang i in. (2014)	K (A2O)	ChZT, $N - NH_4,$ $N - NO_3$	WO, HT, Q_{wewn}	ASM+ SVM	EnEI, t_z
Mulas i in. (2015)	K (ASP)	$N - NH_4,$ $N - NO_3$	DO, M_{nadm}	GSP-X	EnEI, t_z
Liu i in. (2010)	K (Carousel)	ChZT, TN, $N - NO_3$	X_{OC}, DO, v	ASM+ FLUENT	EnEI, t_z
Wang i in. (2017)	ASP (MBBR)	ChZT, $P_{og},$ $N - NH_4,$ N_{og}	HT, DO, $Fe_xZ_y,$ REC	PCA+ MLR +ASM1	EQI, OCI

Tab. 3.1. cd.

Źródło	Oczyszczalnia ścieków	Prognoza	Zmienne sterujące	Metoda	Kryteria
Sweetapple, Fu, Butler (2014)	K(ASP)	BZT ₅ , ChZT, TKN, N – NO ₃ , Z _{og}	kLA, M _{nadm}	BSM2	OCI, EQI, GHI
Barbu i Vilanovce (2017)	K(ASP)	BZT ₅ , ChZT, TKN, N – NO ₃ , Z _{og} , N – NH ₄	X _{OC} , N-NH ₄ , Q _{wewn} , M _{nadm}	BSM2	OCI, EQI, GHI
Flores-Alsina i in. (2014)	K(ASP)	OCI, EQI, GHI	kLA, % Z _{og} , WKF, REC	BSM2	OCI, EQI, GHI
Cominas i in. (2013)	K(ASP)	N _{og} , Z _{og}	Q _{wewn} , M _{nadm} , DO	ASM	GHI, EnEI
Kim i in. (2015)	K(ASP)	ChZT, BZT ₅ , N _{og} , TKN, Z _{og}	DO, Q _{wewn} , M _{nadm} , REC, WKF	ASM+AD M	GHI, EQI, OCI
Carrera-Chapela i in. (2014)	K(ASP)	Odory	parametry reaktora	ASM+ CALPUFF	Odory

Podobne obliczenia (symulacje długookresowe dla 1 roku) prowadzili również Vrecko i in. (2006), którzy rozpatrywali dwa systemy sterowania nastawami reaktora. W pierwszym z nich przyjęto stałe wartości współczynników transferu tlenu (kLA), recyrkulacji zewnętrznej, recyrkulacji wewnętrznej i ilości dawkowanego zewnętrznego źródła węgla. W drugim przypadku rozważano sterowanie wartością N – NO₃ na odpływie w zależności od stopnia recyrkulacji wewnętrznej, wartością N – NH₄ w komorze nityfikacji za pomocą współczynnika transferu tlenu, oraz stężeniem zawiesin mineralnych w komorze nityfikacji w funkcji strumienia osadów nadmiernych. Ilość dawkowanego zewnętrznego źródła węgla określano w zależności od ilości dopływających ścieków. Zastosowanie drugiego systemu sterowania prowadziło do poprawy jakości ścieków o 10%, redukcji zużycia energii elektrycznej o 1% i zmniejszenia prawdopodobieństwa przekroczenia dopuszczalnych wartości wskaźników jakości

ścieków oczyszczonych dla N_{og} z 23,9% do 19,0% oraz dla $N - NH_4$ z 40,9% do 33,0%.

Badania dotyczące doboru strategii sterowania nastawami reaktora w czasie rzeczywistym w oparciu o skalibrowany model oczyszczalni ścieków prowadzili również Mulas i in. (2015). Badania obejmowały dwa warianty sterowania nastawami recyrkulacji wewnętrznej, ilości odprowadzanych osadów nadmiernych i stężenia tlenu w komorach nityfikacji, przy przyjmowaniu różnych liczb tych komór. Obliczenia wykazały, że sterowanie stężeniem tlenu w 5 komorach tlenowych (I wariant) prowadziło do nieznacznie wyższych kosztów oczyszczania ścieków (nie więcej, niż 0,5%), niż w przypadku, gdy sterowano stężeniem tlenu w dwóch komorach (II wariant), w pozostałych przyjmując stałą wartość stężenia. Ponadto, wartość średnia $N - NH_4$ wyznaczona w I wariacie modelowania była niższa o ok. 10%, niż w wariacie II.

Kolejne badania dotyczące sterowania nastawami reaktora biologicznego przedstawiono w pracy (Ayes i in. 2006). W zaprezentowanym modelu sterowano procesami nityfikacji i denityfikacji poprzez dobór stężenia tlenu w komorach nityfikacji z wykorzystaniem 24-godzinne mobilnego okna uśredniającego zmiany jakości ścieków na dopływie do oczyszczalni. Wykonane obliczenia wykazały, że zastosowanie mobilnego okna prowadzi do redukcji $N - NH_4$ na odpływie o ok. 10% i redukcji napowietrzania o ok. 10–15%.

Inne podejście do sterowania nastawami w reaktorze biologicznym przedstawili Seggelke i in. (2005), którzy zastosowali model KOLSIM, (KOntinuierliches LangzeitSIMulations Modell), służący do symulacji odpływu ścieków z systemów kanalizacyjnych. W ramach prowadzonych obliczeń (model fizyczny ASM2d) wyznaczyli oni stężenia $N - NH_4$ na odpływie z oczyszczalni w czasie intensywnego zdarzenia opadowego. Wykonane symulacje wykazały, że możliwe jest ograniczenie wzrostu ładunku azotu amonowego odprowadzanego do odbiornika poprzez odpowiedni dobór nastaw reaktora, pod warunkiem wyznaczenia odpowiednio wczesnych prognoz ilości ścieków dopływających do oczyszczalni.

Przykład zastosowania modelu ASM2 do prognozy stężenia fosforanów i fosforu ogólnego w ściekach oczyszczonych omówili Gearney i in. (2002). Modelowali oni działanie oczyszczalni, w której fosfor był strącany chemicznie za pomocą związków żelaza. Wykonane symulacje, przy założeniu stałej ilości dawkowanego koagulantu oraz zmiany jego ilości w zależności od zawartości fosforanów na odpływie, pokazały, że można ponad 10-krotnie obniżyć ilości związków fosforu w ściekach oczyszczonych w tym drugim przypadku. Z kolei interesujący przykład zastosowania modelu fizycznego do optymalizacji procesu usuwania fosforu w reaktorze biologicznym typu Biotenitro (proces polega na sekwencyjnym napowietrzaniu i mieszaniu ścieków) przedstawili Ingildsen i in.

(2006). W pracy tej badano z powodzeniem możliwość wyeliminowania dawkowania związków żelaza poprzez odpowiedni dobór czasów trwania fazy tlenowej i mieszania.

W omówionych powyżej pracach stosowano modele fizyczne do oceny wpływu nastaw reaktora na uzyskiwane wskaźniki jakości ścieków oczyszczonych lub koszty eksploatacyjne oczyszczalni, wykonując jedynie obliczenia symulacyjne modeli. Jednak te same zadania można rozwiązywać jak klasyczne zadania optymalizacji, definiując odpowiednie kryteria jakości w postaci funkcji kosztów eksploatacji lub funkcji jakości ścieków. Na przykład, zastosowanie algorytmu genetycznego do optymalizacji jakości ścieków i kosztów energii elektrycznej przedstawił Beraud i in. (2007). Otrzymali oni, że sterując stężeniem tlenu w jednej komorze nityfikacji reaktora posiadającego trzy takie komory, możliwe jest ograniczenie kosztów eksploatacji o 28%, przy jednoczesnym pogorszeniu jakości ścieków zdefiniowanej za pomocą wskaźnika EQI o 17%. Z kolei sterowanie nastawami reaktora w oczyszczalni pracującej w technologii A2O badali Zhang i in. (2014). W ich obliczeniach funkcję celu stanowiła jakość ścieków oczyszczonych definiowana przez wskaźniki ChZT, $N - NH_4$ i $N - NO_3$. W obliczeniach, podobnie jak Beraud i in. (2006), zastosowali oni model ASM1. W zadaniu optymalizacji zmiennymi sterującymi były recyrkulacja wewnętrzna, czas zatrzymania ścieków i wiek osadu. Z optymalizacji wykonanej za pomocą zmodyfikowanego algorytmu genetycznego otrzymano, że najmniejsze wartości wskaźników jakości ścieków uzyskiwano dla funkcji celu definiującej jakość ścieków ze względu na redukcję azotu amonowego. Z kolei, największe wartości wskaźników uzyskano dla funkcji celu definiującej jakość ścieków biorąc pod uwagę ChZT.

Rozwinięcie zastosowań modeli fizycznych do optymalizacji działania oczyszczalni ścieków stanowią prace (Nopens i in. 2010, Sweetapple 2014). Stosując model BSM2 reaktora biologicznego zbudowanego z dwóch komór beztlenowych i trzech tlenowych ($DO = \text{const}$, $M_{\text{nadm}} = \text{const}$), analizowano wpływ sterowania napowietrzaniem na koszty eksploatacji, jakość ścieków oczyszczonych i emisję gazów cieplarnianych. W jednym wariantcie badań rozważano jeden wspólny system sterowania ilością powietrza dostarczanego do komór tlenowych, a w drugim wariantcie zastosowano 3 systemy napowietrzania działające niezależnie. Z otrzymanych rezultatów badań wynika, że stosując wariant drugi sterowania można zachować równoważną jakość ścieków, jak w wariantcie pierwszym, i jednocześnie zredukować emisję gazów cieplarnianych o 6,3% i obniżyć koszty eksploatacyjne oczyszczalni o 2,0%.

Ocenę wpływu wyznaczonej strategii sterowania reaktorem na emisję gazów (GHI), koszty eksploatacji oczyszczalni (OCI) i jakość ścieków (EQI) wyznaczali Barbu i in. (2017). W swoich badaniach analizowali oni istniejący w oczyszczalni system sterowania polegający na utrzymaniu stałego stężenia tlenu w komorach

nitryfikacji oraz na regulacji ilości odprowadzanych osadów nadmiernych w zależności od pory roku, przy równoczesnym dawkowaniu zewnętrznego źródła węgla. Wykonane symulacje pracy oczyszczalni dla okresu roku za pomocą modelu BSM2G (zmodyfikowany model BSM2, w którym uwzględniono możliwość prognozowania gazów cieplarnianych) wykazały, że z punktu widzenia ekonomicznego (ocenianego na podstawie wskaźnika OCI) i ekologicznego (ocenianego na podstawie wskaźników EQI i GHI) wysoką efektywność działania reaktora zapewnia przede wszystkim strategia stabilizacji N – NO₃ w komorze nitryfikacji.

Podobne obliczenia za pomocą modelu BSM2 prowadzili Flores-Alsina i in. (2014), analizujący wpływ zmiany stężenia tlenu w komorach nitryfikacji, ilości usuwanych zawiesin w osadniku wstępnym i temperatury fermentacji w WKF na jakość ścieków (ocenianą na podstawie EQI), koszty eksploatacji (oceniane na podstawie OCI) i emisję gazów cieplarnianych (ocenianą na podstawie GHI). Wykonane symulacje wykazały, że zmniejszenie wartości DO z 2 mg/l na 1 mg/l lub jej zwiększenie z 2 mg/l na 3 mg/l prowadzi, odpowiednio, do zwiększenia OCI o 5% i redukcji EQI o 10%, lub do spadku OCI o 6% i wzrostu EQI o 5%. Z kolei, zmniejszenie stopnia redukcji zawiesin w osadniku wstępnym z 50% na 33% prowadzi do spadku wartości OCI i EQI o 10%, natomiast wzrost stopnia redukcji zawiesin prowadzi do zwiększenia wartości OCI i EQI. Również, kontrola strumienia azotu z WKF do bioreaktora prowadzi do poprawy jakości ścieków. Gdy w komorze tlenowej przyjęto DO=1mg/l, to kontrola strumienia azotu z WKF prowadzi do redukcji emisji gazów cieplarnianych o 15% w porównaniu z przypadkiem, gdy DO = 2 mg/l. Z wykonanych obliczeń wynika, że doboru strategii sterowania można dokonać w oparciu o kryteria ekologiczne lub ekonomiczne. Należy przy tym pamiętać, że te kryteria w pewnym stopniu wykluczają się, gdyż poprawa jakości ścieków oczyszczonych prowadzi zwykle do zwiększenia kosztów eksploatacji i zwiększenia emisji gazów cieplarnianych.

Uwzględniając problemy z jednoznacznym określeniem optymalnej strategii sterowania reaktorem Kim i in. (2015) zaproponowali parametr IPI, stanowiący średnią ważoną wartości EQI, OCI, GHI. Przedstawili oni przykład doboru takiej strategii na podstawie obliczeń symulacyjnych z wykorzystaniem modelu ASMN-G (ang. Activated Sludge Model Nitrogen for Greenhouse), w którym, podobnie jak Flores-Alsina i in. (2014), uwzględniali odzysk energii elektrycznej ze spalania biogazu. Przemiany biochemiczne w WKF prognozowano za pomocą modelu ADM (ang. Activated Digestion Model). Autorzy przeanalizowali kilka wariantów optymalizacji pracy reaktora, w których uwzględniano jakość ścieków na odpływie (wskaźnik EQI), koszty eksploatacji oczyszczalni (wskaźnik OCI) i emisję gazów cieplarnianych (wskaźnik GHI). Wykonane obliczenia wykazały, że możliwa jest optymalizacja nastaw reaktora (dotyczących stężenia tlenu, recyrkulacji zewnętrznej, recyrkulacji wewnętrznej, ilości dawkowanego zewnętrznego źródła

węgla i temperatury stabilizacji osadów w WKF) w oparciu o zastosowane wskaźniki przy założeniu, że wartości OCI, EQI i GHI mają identyczny udział wagowy w parametrze IPI. W rezultacie uzyskano obniżenie kosztów eksploatacji o 11%, poprawę jakości ścieków o 2% i zmniejszenie emisji gazów cieplarnianych o 31%.

Z powyższego przeglądu prac wynika, że analizy wykonywane za pomocą modeli fizykalnych mogą stanowić cenne wskazówki dla eksploatorów oczyszczalni ścieków przy opracowywaniu strategii sterowania oczyszczalnią. Modele fizykalne stanowią zatem efektywne narzędzie do oceny wpływu nastaw w reaktorze na funkcjonowanie oczyszczalni. Jednak, należy pamiętać przy tym o kilku zagadnieniach stanowiących o słabych stronach tych modeli. Modele fizykalne są bardzo złożone, co bardzo utrudnia ich kalibrację. Ich złożoność wpływa również na długi czas obliczeń, co powoduje, że nie są możliwe obliczenia symulacyjne modeli w czasie rzeczywistym. Długi czas obliczeń pojedynczej symulacji modelu utrudnia obliczenia optymalizacyjne, w których na ogół takich obliczeń wykonuje się bardzo dużo. Należy także pamiętać o tym, że na etapie tworzenia i kalibracji modelu fizykalnego konieczne jest wykonanie wielu eksperymentów pomiarowych, które nie są rutynowo prowadzone na oczyszczalni, w szczególności dotyczą one szczegółowego określenia zmieniającego się w czasie składu ścieków surowych.

W związku z powyższym do symulacji działania oczyszczalni ścieków stosuje się powszechnie znacznie prostsze modele statystyczne, zwane również modelami parametrycznymi lub modelami czarnej skrzynki, których parametry, w odróżnieniu od modeli fizykalnych, nie mają interpretacji fizycznej. W modelach czarnej skrzynki występuje etap uczenia, w którym na podstawie określonego zbioru danych pomiarowych generowana jest struktura modelu. Aby zweryfikować zdolności predykcyjne modelu, wykonuje się w kolejnych etapach testowanie i walidację modelu na podstawie odrębnych zbiorów danych.

3.1. Prognoza ilości i jakości ścieków na dopływie do oczyszczalni modelami statystycznymi

Z dokonanego przeglądu literatury (Osman Akan i in. 1993, Rossman i in. 1998) wynika, że jednymi z pierwszych zmiennych, których symulacją zajęto się z uwagi na potrzebę poprawy efektywności funkcjonowania oczyszczalni, jest ilość i jakość ścieków na dopływie (tab. 3.2, 3.3). Do ich prognozy opracowano modele hydrodynamiczne oparte na równaniach różniczkowych, opisujących spływ powierzchniowy z terenu zlewni, przepływ siecią kanałów i nierównomierność odpływu z obiektów typu zabudowa mieszkaniowa, przemysł, usługi itp. W celu wykonania takiego modelu konieczne jest zgromadzenie szczegółowych informacji o zlewni, co zwykle jest utrudnione z uwagi na braki w zasobach danych, które są

niezbędne do kalibracji modelu. Prowadzone obliczenia wykazały, że występują problemy z kalibracją modeli hydrodynamicznych (Flores-Alsina i in. 2009, Szelağ i in. 2016, Kiczko i in. 2018,), co istotnie ogranicza ich zastosowanie (tab. 3.2).

Tab. 3.2. Zestawienie przykładowych prac z zakresu modelowania dopływu ścieków.

Źródło	Zmienne objaśniające (niezależne)	Model
Gernaey (2011), Martin i Venrolleghem (2014) Alsina-Flores (2014)	sezonowość (Qh, Qd, Qr), Opad, H_{gr}	fenomenologiczny
Butler, Graham (1995)	prawdopodobieństwo działania urządzeń	probabilistyczny
Zhang i in. (2017)	Q	SOM
Ma i in. (2014)	$Q(t - 1)$	WANN
Cartensen, Nielsen (1998)	Opad, charakterystyka zlewni	MOUSE/AR
Szelağ i in. (2016)	Opad, charakterystyka zlewni	SWMM (GLUE+GSA)
Huo (2008)	$Q(t - 1)/Q(t - 1)$, $T(t - 1)$	ARIMA
Ayesha i in. (2013)	$Q(t - 1)$	ARIMA
Abunama i Othman (2017)	$Q(t - 1)$	AR
Sobota, Szetala (2006)	sezonowość (Qd), biały szum, Q_{dsr}	AR
Sobota, Szetela (2005)	$Q(t - 1)$	AR
Minsoo, Yejin (2015)	$Q(t - 1)$	k-NN
Wei i in. (2013)	Opad, wsp. odbicia radaru	MLP/RF/BT/SVM
El-Din, Smith (2002)	Opad (zdarzenia opadowe)	ANN
Jurasz, Piasecki (2015)	$Q(t - 1)$, $T(t - 1)$, W, Q_{woda}	ANN

Ponadto, z uwagi na uproszczony opis badanych procesów w modelach hydrodynamicznych (problem z jednoznacznym określeniem ilości wody, jaka znajduje się w zlewni, co ma kluczowy wpływ na modelowanie odpływu), nie zawsze uzyskane wyniki są wiarygodne (Szelağ i in. 2016). Dlatego też, obliczenia prowadzone za pomocą modeli hybrydowych, stanowiących połączenie modelu hydrodynamicznego i statystycznego, są znacznie dokładniejsze, niż otrzymane jedynie za pomocą modelu hydrodynamicznego. Jednak również model hybrydowy, bazujący także na fizykalnym opisie badanego zjawiska, wymaga

znacznie większej liczby danych, niż model statystyczny. Uzyskany tym sposobem wynik często nie jest satysfakcjonujący, co zadecydowało o coraz powszechniejszym stosowaniu jedynie modeli statystycznych w badaniach oczyszczalni ścieków, w tym w szczególności do modelowania dopływu ścieków surowych.

Tab. 3.3. Zestawienie przykładowych prac z zakresu modelowania jakości ścieków na dopływie do oczyszczalni.

Publikacja	Wskaźnik	Zmienne objaśniające (niezależne)	Model
Dogan, Ates, Yilmaz (2008)	BZT ₅	ChZT, N, P, Z _o , Q	MLR
Sobota, Szetela (2006)	BZT ₅ , ChZT, N – NH ₄	sezonowość dobową, biały szum, Q _{dsr} , C _{sr}	AR
Sobota, Szetela (2005)	BZT ₅ , ChZT, N – NH ₄	ChZT(t-i), BZT ₅ (t-i), N – NH ₄ (t – i)	AR
Huo (2008)	BZT ₅ , Z _o , N – NH ₄	BZT ₅ (t-i), Z _o (t-i), N – NH ₄ (t – i)	ESM
Verma, Wei, Kusiak (2012)	Z _{og}	CBZT ₅ , Q/Z _{og} (t-1)	BT+ANN
Ahnert (2016)	ChZT	Q	NLR
Bechman, Nielsen (1999)	ChZT, Z _{og}	Q, ChZT, Z _{og} (godzinowy, zmywanie podczas opadów)	analiza Fouriera
Langeberger, i in. (2008)	ChZT, TKN, P _{og}	Q, ChZT, TKN, P _{og} (typowy dopływu do OŚ w funkcji RLM)	analiza Fouriera
Rodriguez, i in. (2013)	Q, Z _{og} , BZT ₅ , ChZT	Q, Z _{og} , BZT ₅ , ChZT (przemysł, biura, osiedla mieszkaniowe, usługi komercyjne)	analiza Fouriera + error
Kusiak, Verma (2013)	CBZT	pory roku (wiosna, lato, jesien, zima), Q	MARS, RF, GP
Ebrahimi, Gerber (2017)	BZT ₅ , P _{og}	BZT ₅ , Z _{og} , N _{og} , P _{og}	NLR+PCA
Minsoo, Yejin (2015)	ChZT, Z _o , N _{og} , P _{og}	ChZT(t-i), Z _o (t-i), N _{og} (t-i), P _{og} (t-i)	k-NN
Häck, Köhne (1996)	ChZT, N – NH ₄	N-NH ₄ , Cond, mętność/COD, Cond, mętność (t)	ANN

Generatory ilości i jakości ścieków rozwijane są od około 20 lat (Rodríguez i in. 2013, Gearney i in. 2014, Martin i in. 2014, Flores-Alsina i in. 2014). W modelach tych uwzględnia się typ analizowanej jednostki osadniczej charakteryzowany przez sposób zabudowy terenu zlewni (przemysł, zabudowa mieszkaniowa itp.), sezonowość (zmiennosc godzinowa, dobowa miesięczna, roczna), stochastyczny charakter opadów deszczów, proces zmywania zanieczyszczeń z powierzchni zlewni, zmienny poziom zwierciadła wód gruntowych (H_{gr}) i wielkość jednostki odniesione do równoważnej liczby mieszkańców RLM. Symulatory ilości i jakości ścieków w cyklu nie krótszym, niż doba, opracowywali również Bechman i in. (1999), Langeberger i in. (2008) i Rodriguez i in. (2013), którzy do prognozy wartości Z_{og} , ChZT, TKN i P_{og} zastosowali analizę harmoniczną (tab. 3.2). Wyznaczone w ten sposób szeregi czasowe charakteryzowała zadowalająca zgodność z wynikami pomiarów: wartości współczynnika korelacji R były nie mniejsze, niż 0,78. Sobota i Szetela (2006) na podstawie pomiarów prowadzonych na oczyszczalniach ścieków Głogów, Rzeszów, Opole i Ciernie opracowali bezwymiarowe krzywe zmienności dopływu i jakości ścieków na dopływie do oczyszczalni, które wykorzystali do prognozy tych zmiennych (tab. 3.2, 3.3).

Do symulacji ilości ścieków dopływających do oczyszczalni z dobowym wyprzedzeniem czasowym Ayesha i in. (2013), Sobota i Szetela (2005) stosowali modele liniowe typu AR, ARIMA, uzyskując zadowalające wyniki symulacji (wartości współczynnika korelacji między wynikami obliczeń a pomiarami mieściły się w przedziale 0,70-0,95). Modele liniowe wykorzystano także przy prognozowaniu wskaźników jakości ścieków na dopływie do oczyszczalni (BZT_5 , ChZT, Z_{og} , $N - NH_4$), chociaż w wielu przypadkach modele te były niedokładne. Huo (2008) do prognozy BZT_5 oraz Z_o zastosował model autoregresyjny i wyznaczone wartości R mieściły się w przedziale 0,53-0,63. Sobota i Szetela (2005) modelując wartości wskaźników jakości ścieków wprowadzili modyfikację modelu AR podanego przez Jenkinsa i Box (1983), co wpłynęło dodatnio na poprawę zdolności predykcyjnych modelu, nie mniej jednak otrzymane przez nich wartości R nie przekraczały 0,70. Przedstawione wyniki wskazują na to, że prognozowanie jakości ścieków na dopływie jest bardziej złożone, niż symulacja samego dopływu ścieków i że modele autoregresyjne w tych zadaniach mogą mieć ograniczone zastosowanie. Wniosek ten znajduje potwierdzenie w obliczeniach Dogana i in. (2008), którzy na podstawie pomiarów ChZT, N_{og} , P , Z_{og} i Q opracowali model do prognozy BZT_5 , uzyskując zadowalające dopasowanie wyników obliczeń do pomiarów ($R = 0,96$).

Mając na względzie trudności z modelowaniem procesów w oczyszczalni ścieków za pomocą modeli fizykalnych, hydrodynamicznych, hybrydowych i z użyciem szeregów czasowych, zaczęto w zadaniach prognozowania używać sieci neuronowych (El-Din i Smith 2002, Fernandez i in. 2009, Jurasz i Pilecki

2015, Bartkiewicz i in. 2016). W obliczeniach wykorzystywano różne rodzaje sieci neuronowych: perceptron wielowarstwowy, sieci rekurencyjne, falkowe i samoorganizujące się sieci neuronowe (SOM), stosowane zwykle w zagadnieniach klasyfikacyjnych. Ciekawą pracę przedstawili Zhang i in. (2017), którzy analizując wyniki pomiarów przepływu z 50 pompowni ścieków sanitarnych wyróżnili za pomocą sieci SOM typowe zmienności odpływu ścieków z poszczególnych zlewni, analizowane w cyklu dobowym. Uzyskany wynik był zbliżony do otrzymanego za pomocą generatorów do prognozy przepływu ścieków surowych, modelowanej w pracach (Sobota i Szetela 2005, 2006, Langeberger i in. 2008, Rodriguez i in. 2013). W większości prac z zakresu prognozy ilości ścieków na dopływie do oczyszczalni za pomocą sieci neuronowych uwzględniano oprócz przepływu również wysokość opadów deszczu (El-Din i Smith 2002, Fernandez i Seco 2009, Jurasz i Pilecki 2015). Uzyskane modele charakteryzowały się zadowalającymi zdolnościami predykcyjnymi.

Inny rodzaj badań polegał na porównywaniu różnych metod modelowania ze względu na ich stopień złożoności i uzyskiwaną dokładność obliczeń. Taka analiza porównawcza znajduje się w pracy Wei i in. (2013), w której prognozowano dopływ do oczyszczalni z krokiem pomiarowym 15 minut za pomocą metod MLP, BT, RF i SVM, na podstawie pomiarów dopływu, opadów deszczu i współczynnika odbicia wiązki radarowej od kropli deszczu. Okazało się, że stosując model SVM o znacznie bardziej złożonej strukturze, niż MLP, uzyskano niewiele lepsze wyniki (o 1%). Natomiast, stosując metody BT i RF o prostszej strukturze, niż MLP, otrzymano wyniki niewiele gorsze, bo odpowiednio o 1,8% i 4,4%. Podobne wyniki otrzymali Szeląg i in. (2017), którzy również wykazali możliwość poprawnej prognozy dopływu ścieków do oczyszczalni (na podstawie danych dobowych) za pomocą metod SVM i RF. Z kolei Kirger i Tzoneva (2013), modelując również dobowy dopływ ścieków, stwierdzili, że wyniki otrzymane za pomocą sieci neuronowych typu MLP (oceniane na podstawie wartości R) są zaledwie o 2% gorsze, niż uzyskane rekurencyjnymi sieciami neuronowymi.

Prognoza dopływu ścieków do oczyszczalni z dobowym krokiem obliczeń w ograniczonym stopniu umożliwia korektę nastaw reaktora biologicznego. Problem symulacji dopływu z krokiem 15 minut badali Wei i in. (2013), którzy opracowali model statystyczny stanowiący kaskadowe połączenie dwóch sieci neuronowych. W rozwiązaniu tym błędy prognozy dopływu otrzymane z pierwszej sieci neuronowej były częściowo niwelowane za pomocą drugiej sieci, co poprawiło zdolność predykcyjną modelu o 15%.

Z kolei, Kusiak (2013) zajął się symulacją wybranych wskaźników jakości ścieków na dopływie do oczyszczalni używając pomiarów 5-ciodobowych. Wykonane obliczenia wykazały wpływ sezonowej zmienności CBZT₅ (Całkowite Biochemiczne Zapotrzebowanie na Tlen) na wyniki obliczeń. Spośród badanych metod (MLP, C&RT, MARS, RF) najmniejsze błędy prognozy CBZT₅ wyznaczono

dla okresu jesieni metodą MARS ($R=0,76$). Lepsze wyniki modelowania otrzymano dla metody RF ($R=0,89$). Ponadto, Kusiak i in. (2012) wykazali zadowalające wyniki symulacji Z_{og} za pomocą sieci MLP z przesuwym oknem. Uzyskane wyniki wykazały możliwość symulacji koncentracji zawiesiny ogólnej w ściekach z dobowym i tygodniowym krokiem pomiarowym ze średnim błędem prognozy odpowiednio 22% i 30%. Rezultaty analiz wykonane przez Minsoo i in. (2016) potwierdziły satysfakcjonujące wyniki symulacji Z_{og} , ChZT, N_{og} i P_{og} dla pogody opadowej i bezdeszczowej.

W prowadzonych badaniach dotyczących modelowania jakości ścieków na dopływie do oczyszczalni zajmowano się również prognozowaniem wskaźników jakości, których określenie jest czasochłonne i kosztowne i jednocześnie mają one kluczowy wpływ na przebieg procesów biochemicznych w reaktorze. Na przykład Ebrahimi i in. (2017) na podstawie pomiarów P, N_{og} i Z_{og} oraz BZT₅, Z_{og} i N zajmowali się symulacją wartości BZT₅ i P za pomocą metody NLR+PCA. Wyznaczone modele charakteryzowały się zadowalającymi zdolnościami predykcyjnymi wybranych wskaźników, uzyskując wartości R równe odpowiednio 0,916 i 0,937. Z kolei Häck i Köhne (1996), stosując metodę sztucznych sieci neuronowych, wykonali obliczenia $N - NH_4$ na podstawie pomiarów ChZT lub mętności, otrzymując w obu przypadkach zadowalające dopasowanie modelu do pomiarów na poziomie $R = 0,91$.

3.2. Prognoza jakości ścieków na odpływie z oczyszczalni modelami statystycznymi

Wykorzystując fakt, iż modele parametryczne, w szczególności sieci neuronowe, lepiej prognozują zależności nieliniowe, niż modele hybrydowe i tworzenie ich jest znacznie mniej skomplikowane, w szczególności w porównaniu z modelami fizykalnymi. Dlatego, metody te znalazły szerokie zastosowanie w symulacji oczyszczalni ścieków, w których zachodzą procesy biochemiczne prowadzące do usunięcia ze ścieków związków biogenych (Hong i Bhamidimarri 2007, Pai i in. 2011, Mirbagherii i in. 2015, Abba 2017). Wykazano możliwość implementacji tych metod do prognozowania procesów przebiegających w klasycznych i zmodyfikowanych układach technologicznych oczyszczania ścieków (SBR, SMBR, MBR, UASBR itp.). W tab. 3.4 zamieszczono zestawienie publikacji, w których zajmowano się modelowaniem jakości ścieków na odpływie z oczyszczalni oraz symulacją parametrów operacyjnych bioreaktora. Można dokonać podziału tych publikacji według trzech kryteriów: ze względu na zastosowaną metodę symulacji, ze względu na dobór danych zmiennych wejściowych do modelu, oraz ze względu na uzyskaną dokładność prognoz badanych procesów w przypadku występowania nieciągłości w szeregach czasowych danych pomiarowych.

Biorąc pod uwagę kryterium związane z metodami wykorzystywanymi do modelowania jakości ścieków oczyszczonych (kryterium 1) należy uwzględnić prace, w których do prognozy wartości BZT₅ (Barthoeux 1996), ChZT (Elkiran 2017) lub P_{og} (Bloom 1996), zastosowano metody MLR, PLS lub C&RT. Kolejną grupę metod powszechnie implementowanych do określania jakości ścieków na odpływie z oczyszczalni stanowią sieci neuronowe, zbudowane zwykle z 3 warstw (wejściowej, ukrytej i wyjściowej). Są one używane do symulacji zmian BZT₅, ChZT, N_{og} i P_{og} w ściekach oraz wyznaczania nastaw X_{OC}, F/M, M_{nađm}, REC w bioreaktorze. W przypadku niezadawalających wyników predykcji wskaźników jakości ścieków na odpływie wprowadza się modyfikacje sieci neuronowych, polegające na optymalizacji, za pomocą odpowiednich algorytmów numerycznych, wag przyporządkowanych do poszczególnych neuronów sieci (Qiao i in. 2011, Mirbagherii i in. 2015, Chen i in. 2017). W celu poprawy wyników obliczeń rozważa się często modyfikacje sieci neuronowej polegające na zmianie funkcji aktywacji przyporządkowanych do poszczególnych warstw sieci (Güçlü i Dürsun 2000, Kundu i in. 2014), zastąpieniu neuronów w warstwie ukrytej regulatorami rozmytymi (Yasim i in. 2017, Maachou i in. 2015), funkcjami Kernela (Manu i Thalla (2017), wprowadzeniu sprzężeń zwrotnych lub dodatkowych połączeń między warstwami sieci (Chen i in. 2003, Qiao i in. 2011, Han i in. 2016).

Przy formułowaniu modelu do prognozy pracy oczyszczalni ścieków istotne znaczenie ma dobór zmiennych wejściowych (niezależnych), zwanych inaczej predyktorami. Zwykle przy doborze tych zmiennych bazuje się na fizyce badanego procesu i wiedzy technologicznej o modelowanych obiektach. Jednak, często dobór ten nie jest prosty ze względu na złożoność rozważanych zjawisk i dlatego też, stosuje się w tym celu metody umożliwiające identyfikację zmiennych mających decydujący wpływ na przebieg badanego procesu. Do tych metod należą przede wszystkim metoda drzew wzmocnianych, metoda lasów losowych (Kusiak i Zhang 2010, Verma i in. 2012) i algorytmy genetyczne (Venkadesh i in. 2013). Ponadto, do redukcji wymiarowości modelu stosuje się metody PCA (ang. Principle Component Analysis) i PLS (ang. Partial Least Square) (Lee i in. 2009, Woo i in. 2009, Yoo i in. 2004). Z kolei do badania skupień dobieranych zmiennych służą metody grupowania danych, takie jak: metoda samoorganizujących się sieci neuronowych, analiza k-średnich i analiza skupień (Rustum i in. 2007, Rustum 2009).

Biorąc pod uwagę kryterium związane z doбором zmiennych wejściowych do modelu (kryterium 2) można dokonać podziału publikacji z tab. 3.4 na trzy grupy.

Pierwszą grupę (a) stanowią publikacje przedstawiające modele statystyczne, w których zmiennymi objaśniającymi (predyktorami) są wyłącznie wskaźniki fizyko-chemiczne ścieków (pH, T, stężenia BZT₅, ChZT, N_{og}, P_{og}). W drugiej grupie (b) publikacji są prezentowane modele, w których zmiennymi wejściowymi,

poza wskaźnikami fizyko-chemicznymi, są także nastawy reaktora biologicznego (pH, DO, X_{OC} , ORP, REC, M_{nadm} , HT). Trzecią grupę (c) stanowią publikacje, w których zmiennymi objaśniającymi modeli są frakcje zanieczyszczeń ujęte w modelu ASM i dane dotyczące składu osadu czynnego (Raduly i in. 2007, Qiao i Yang 2011). Z uwagi na to, że określenie udziału frakcji zanieczyszczeń w ściekach i udziału bakterii heterotroficznych i autotroficznych w osadzie wymaga wykonania badań, które nie są rutynowo prowadzone na oczyszczalni, podejście to ma ograniczone zastosowanie, co potwierdza stosunkowo nieduża liczba prac z tego zakresu (tab. 3.4).

Tab. 3.4. Zestawienie przykładowych publikacji z zakresu symulacji jakości ścieków na odpływie za pomocą modeli parametrycznych.

Publikacja	Oczyszczalnia	Prognoza	Zmienne objaśniające	Metoda
Berthouex, Box (1996)	K(ASP) ^a	BZT ₅	BZT ₅ , Z _o , F/M, OP	MLR, EWMA
Heddam (2016)	K(ASP) ^a	BZT ₅	ChZT, SS, Cond, T, pH	GRNN/MLR
Rustum i in. (2007)	K(ASP) ^b	BZT ₅	Q, Z _o , N-NH ₄ , warstwa osadu w osadniku wstępnym	SOM+ANN
Qiao i in. (2016)	K(A2O) ^b	BZT ₅	ChZT, Z _o , DO, pH	(ANN, Elman, FNN)+Ch
Oktay, Ozgur (2009)	K(ASP) ^a	BZT ₅	ChZT, P _{og} , TM, TDS	ANN
Khademikia (2016)	K(ASP) ^b	BZT ₅ , ChZT, Z _o	BZT ₅ , ChZT, N-NO ₃ , TDS, P-PO ₄ , pH, T, DO	ANN/COA+ANN
Raduly i in.(2007)	K(ASP) ^c	BZT ₅ , ChZT, Z _{og} N _{og} , N – NH ₄	Q, T _{KOC} , X _a , Z _{og} , X _h , X _s , X, S _{nh} , S _s , Si(ASM3)	ANN
Qiao, Yang (2011)	K(ASP) ^c	BZT ₅ ChZT Z _o N – NH ₄	S _s , X _s , X _{bh} , X _{ba} S _s , S _i , X _s , X _i , X _{bh} , X _{ba} , X _p X _s , X _i , X _{bh} , X _{ba} , X _p X _i , X _{bh} , X _{ba} , X _p , S _{nh}	ANN(HRO)

Tab. 3.4. cd.

Publikacja	Oczyszczalnia	Prognoza	Zmienne objaśniające	Metoda
Mirbagherii (2015)	K(SMBR) ^b	BZT ₅ , ChZT, N – NH ₄ , P _{og}	Q, BZT ₅ , ChZT, N-NH ₄ , P _{og} , TDS, HT, pH, X _{OCV}	ANN(RBF)
Hong, Paik (2007)	K(ASP) ^b	BZT ₅ Z _o N – NH ₄	BZT ₅ , ASA, Q, T _{KOC} , M _{nadm} , I _o N – NH ₄ , T _{KOC} , BZT ₅ , Q ASA, Q, I _o , M _{nadm} , pH	GP
Abba, Elkiran (2017)	K(MBR) ^b	ChZT	pH, Cond, BZT ₅ , ChZT, N _{og} , P _{og} , Z _o , Z _o	MLR/ANN
Qiao i in. (2011)	P(ASP) ^a	ChZT	Z _o , oil, N-NH ₄ , pH	DANN
Z _o Rene, Saidutta (2008)	P(ASP) ^a	ChZT	TOC, phenol, Z _{og} , TDS	ANN
Chen i in. (2010)	P(ASP) ^b	ChZT	REC*, Z _o , F/M*, HT*	GM
Pai, Tsai, Lo	P(ASP) ^a	ChZT, Z _o	T _{KOC} , Z _o , ChZT, pH	ANN,GA+ANN
Pai i in. (2011)	P(ASP) ^a	ChZT Z _o pH	ChZT, pH Z _o , pH Z _o , pH	ANFIS/ANN
Woo i in. (2009)	P(ASP) ^b	ChZT, N _{og} , CN	pH, ORP, T _{KOC} , DO, X _{OC} , M _{nadm} , REC	PLS,ANN+PLS, k-PLS
Kundu i in. (2014)	P(SBR) ^b	% ChZT, %N – NH ₄	ChZT, N – NH ₄ , X _{OCV} , pH, DO, T _{KOC}	ANN
Yoo i in. (2004)	P(ASP) ^b	ChZT, CN I _o	Q, CN, ChZT, X _{OC} , DO, T _{dop} , T(aer), pH	TSK+PLS

Tab. 3.4. cd.

Publikacja	Oczyszczalnia	Prognoza	Zmienne objaśniające	Metoda
Cinar i in. (2006)	P(SMBR) ^b	ChZT, N – NH ₄ NO ₃ , P _{og}	ChZT, N-NH ₄ , P _{og} , ciśnienie, HT	CNN
Wan i in. (2000)	P(ASP) ^b	Z _o	Q, Z _o , BZT ₅ , ChZT, HT, F/M, X _{OC} , DO	GA+ANN
Poutiainen, Niska (2010)	P(ASP) ^a	Z _o	Z _o , P _{og} , N _{og} , N-NH ₄ , Z _{og} (t-1)	MLR/ANN
Delana i West (2002)	K(ASP) ^a	ChZT Z _o	Q, ChZT Q, Z _{og}	ARMA
Lee i in. (2006)	K(ASP)	ChZT N _{og} N – NH ₄	Z _o , P _{og} , REC, OP, X _{OC} , DO Q, ChZT, N – NH ₄ , N _{og} , OP, DO Q, ChZT, N-NH ₄ , N _{og} , X _{OC} , DO	ANN+PLS
Hongbin i in. (2014)	K(ASP) ^a	ChZT, TN, P _{og}	Q, BZT ₅ , ChZT, Z _{og} , N _{og} , P _{og}	ANFIS/GA+ANFIS
Erdirencelebi, Yalpi (2011)	L/P(UASBR) ^a	ChZT, VFA, pH	pH, ChZT, VFA	ANFIS
Tümer, Edebali (2015)	K(BN) ^a	Z _{og}	Q, pH, ChZT, BZT ₅ , Z _{og} , T _{KOC}	ANN
Luo i in. (2009)	K(ASP) ^b	N _{og}	N _{og} , OP, DO, N – NH ₄	ANN+FR
Clara (2008)	K(ASP) ^b	N _{og}	s _i , X _j , Q _{DO} , E _{PUMP} , M _{nadm}	AGF
Lee i in. (2009)	K(ASP) ^b	N _{og} , P _{og}	Q, T, pH, ChZT, N _{og} , P _{og} , X _{OC} , I _o , DO	ANN-PLS

Tab. 3.5. cd.

Publikacja	Oczyszczalnia	Prognoza	Zmienne objaśniające	Metoda
Han i in. (2016)	K(ASP) ^b	N – NH ₄	P _{og} , Z _{og} , DO, T, ORP	FL+c-NN
Jami i in. (2011)	K(SBR) ^a	N – NH ₄	pH, Q, Z _o , ChZT, BZT ₅	ANN
Manu i Thalla (2017)	K(ASP) ^a	TKN	TKN, ChZT, TS, pH, N – NH ₄ , NH ₃ ,	ANFIS/SVM
Chen i in. (2003)	K(ASP) ^b	N – NH ₄ , P _{og}	BZT ₅ , N – NH ₄ , N-NO ₃ , pH, d/dt(pH), DO, d/dt(DO), ORP d/dt(ORP), HT	RANN
Maachou i in. (2015)	K(ASP) ^a	N-NO ₃	Q, BZT ₅ , ChZT, Z _o	ANFIS
Bloom (1996)	K(ASP) ^a	P _{og}	Q, TOC, pH, Alk, Z _o , LI, P-PO ₄	PLS
Hong, Bhamidimarri (2003)	K(ASP) ^b	MLSS	REC, X _{oc} (t-1), Q, P _c	GP/ANN
Guclu, Dursun (2000)	K(ASP) ^b	MLSS	Q, ChZT, Z _{og} , TKN, L _{ChZT} , DO	ANN
Lee i in. (2005)	P(ASP) ^b	MLSS	Q, ChZT _{dop.odp} , Phenol, X _{oc} (t-1), CN _{dop.odp} , pH(t-1)	ANN+ASM
Yasmin i in. (2017)	P(ASP) ^a	MLSS	BZT ₅ , ChZT, Z _o , N – NH ₄ , O&G	ANFIS
Lee i in. (2002)	P(ASP) ^b	MLSS, CN	Q, CHZT, Phenol, ChZT, CN, pH(t-1), X _{oc}	ASM ANN ASM+ANN ASM+error(ANN)
Mirbagherii, Bagherii (2015)	L(SBR) ^b	X _{ocv}	HT, Z _{og} , ChZT, WO	ANN(RBF)

Biorąc pod uwagę kryterium podziału publikacji związane z dokładnością prognoz w przypadku nieciągłości ciągów pomiarowych (kryterium 3), można zauważyć, że publikacji zajmujących się tym zagadnieniem jest stosunkowo mało (Woo i in. 2009). Nieciągłości w pomiarach wynikają z problemów technicznych związanych z pomiarami jakości ścieków, które dotyczą konieczności częstego czyszczenia sond pomiarowych i ich recalibracji.

3.3. Prognoza sedymentacji osadu czynnego za pomocą modeli statystycznych

Sedymentacja osadu jest istotnym wskaźnikiem efektywności działania oczyszczalni ścieków i utrzymanie jej wartości w odpowiednim zakresie warunkuje optymalny przebieg procesów w reaktorze, co wpływa na jakość ścieków odpływających z obiektu. Od ponad 30 lat prowadzone są badania mające na celu opracowanie modeli matematycznych pozwalających na prognozę i eliminowanie puchnięcia osadu czynnego. W tab. 3.5 przedstawiono prace dotyczące prognozowania sedymentacji osadu czynnego. Mimo tego, że obecny rozdział dotyczy modeli statystycznych, to należy w tym miejscu wspomnieć również o pracy Martinsa i in. (2004), którzy podali model fizyczny do symulacji kinetyki przemian biochemicznych w odniesieniu do kłaczków osadu czynnego. Prace przytoczone w tab. 3.5 można podzielić na 2 grupy: zajmujące się modelami szarej skrzynki (otrzymane w modelu współczynniki mają fizyczną interpretację) i czarnej skrzynki (wyznaczone modelu współczynniki nie mają interpretacji). W obrębie modeli szarej skrzynki można wyróżnić modele liniowe i nieliniowe. Prace dotyczące modeli liniowych (Aarnio i Mikkinen 1986, Bayo i in. 2006)) koncentrują się na identyfikacji zjawiska puchnięcia osadu czynnego w reaktorze za pomocą modeli klasyfikacyjnych.

Tab. 3.5. Zestawienie prac z zakresu prognozy sedymentacji osadu czynnego.

Źródło	Oczyszczalnia	Proces	Prognoza	Zmienne objaśniające	Metoda
Aarnio i Mikkinen (1986)	K	ASP	I_o	P, SS, ChZT, T	PLS
Qiao i in. (2014)	L	SBR	I_o	DO, pH, ChZT, N_{og}	FNN
Bagheri i in. (2015)	K	A2O	I_o	ChZT, N_{og} , T, MLVSS, DO, pH, Z_{og}	ANN(RBF,MLP)+GA

Tab. 3.5. cd.

Źródło	Oczyszczalnia	Proces	Prognoza	Zmienne objaśniające	Metoda
Djedodou, Achour (2016)	K	ASP	I_o	Z_{og} , ChZT, BZT ₅ , T, pH, Cond, N-NH ₄ , N-NO ₃ , P _{og} , % BZT ₅ , % ChZT, % N-NH ₄ , % PO ₄	ANN
Rossle, Pretorius (2008)	L	ASP	I_o	X_{oc} , T _{KOC}	NLR
Comas i in. (2001)	K	ASP	stan osadu czynnego	b.nitkowe, ChZT _{dop} , Q, Cond, mikroorganizmy (ameby, orzęski wrotki, ameby, zooglea, dominujące protoza), piana, Z_{og} , (Z_{og} , ChZT, BZT ₅ , N _{og} , TKN, NO ₃) odp., liczba taksonów	C&RT, k-NN
Comas i in. (2008)	K	ASP	I_o	WO, F/M, $\Delta F/M$ ChZT, Ss, DO, BZT ₅ /P _{og} , BZT ₅ /N _{og} .	FL
Martins i in. (2004)	-	ASP	kłaczek osadu	skład mikroorganizmów, zaw.subst.pożywkowych, szybkości wzrostu, zawartość biomasy, zawartość octanów	fizyczny model
Roche (1995)	K, I	ASP	I_o	SBH, Q(REC), $X_{oc}(REC)$	NLR
Lou, Zhao (2013)	K	A2O	I_o	I_o	ANN/PCA+ANN
Han, Qiao (2013)	L	SBR	I_o	DO, pH, ChZT, N _{og}	HANN/FNN/GFNN

Tab. 3.5. cd.

Źródło	Oczyszczalnia	Proces	Prognoza	Zmienne objaśniające	Metoda
Belanche (2000)	K	ASP	Z_{og}	Q, ChZT, Z_{og} , b.nitkowate, wrotki, orzęski, zooglea	k-NN, ANN(CL)
Côté, (1995)	K	ASP	Z_{og}	Q, ChZT, BZT ₅ , b.nitkowate, mikrofauna	ANN
Capodaglio (1991)	K	ASP	I_o	BZT ₅ / N_{og} , N_{og} / P_{og} , X_{OC} , DO, F/M	ANN
Bayo i in. (2006)	K	ASP	I_o	pory roku/pH + pory roku	Logit
Han, Qiao (2012)	M	SBR	I_o	Q, pH, DO, BZT ₅ , ChZT, N_{og}	SORBF/ARX/RBF/FNN
Han, Li, Qiao (2016)	L	SBR	I_o	pH, ChZT, N_{og} , DO, X_{OC}	RANN/ARX/FFN/SVM
Liu i in. (2016)	K	Carousell	I_o	ChZT, DO, Q, WO, X_{OC} , T, OP	GPR
Boztoprak i in. (2015)	K	ASP	I_o	analiza obrazu kłaczek osadu kamerą	CNN(ABC,GA,LM)

Praca Aarnio i Mikkinena (1986) jest jedną z pierwszych prac dotyczących prognozy puchnięcia osadu. Autorzy w badaniach zastosowali model PLS, wyznaczony na podstawie pomiarów wskaźników fizyko-chemicznych ścieków (P , Z_{og} , ChZT, T) w reaktorze. Model charakteryzował się zadowalającymi zdolnościami identyfikacji zjawiska puchnięcia osadu. Przykład implementacji modelu klasyfikacyjnego do badania tego zjawiska przedstawili Bayo i in. (2006), którzy wyznaczali puchnięcie osadu czynnego za pomocą modelu regresji logistycznej na podstawie pomiarów pH w bioreaktorze i danych o porze roku (wiosna, lato, zima).

Poza liniowymi modelami klasyfikacyjnymi przy identyfikacji puchnięcia osadu znalazły również zastosowanie modele nieliniowe. Przykład takiego podejścia przedstawili Comas i in. (2001), którzy wykorzystali metodę drzew klasyfikacyjnych do identyfikacji stanu osadu czynnego (puchnięcie, obecność piany, przeciążenie lub niedociążenie osadu, denitryfikacja w osadniku wtórnym,

typowe stany działania reaktora dla warunków pogodowych lata i zimy) na podstawie pomiarów ilości i jakości ścieków surowych, nastaw reaktora oraz składu flory bakteryjnej (orzęski, wrotki, ameby) w osadzie. Opracowany model pozwalał na identyfikację składu mikrobiologicznego osadu i jakości ścieków na odpływie, jednak nie umożliwiał dokonywania korekt nastaw reaktora w celu poprawy efektywności jego funkcjonowania. Mając na uwadze ograniczenia modelu klasyfikacyjnego bazującego na drzewie decyzyjnym, Comas i in. (2008) opracowali model do prognozy puchnięcia osadu wykorzystując teorię logiki rozmytej. W modelu przyjęto kryteria lingwistyczne do oceny zdolności sedimentacyjnych osadu czynnego (puchnięcie osadu niskie, średnie i wysokie). Analiza pomiarów z istniejącego obiektu (układ Ludzack–Ettinger do usuwania związków organicznych i azotu) i danych literaturowych pozwoliła na zdefiniowanie zmiennych determinujących zjawisko puchnięcia osadu (wiek osadu, stężenie tlenu w komorach nityfikacji, obciążenie substratowe ładunkiem zanieczyszczeń organicznych, BZT_5/N_{og} , BZT_5/P , zawartość łatwo biodegradowalnych substancji Ss, usunięcie ładunku chemicznego zapotrzebowania na tlen ChZT odniesione do zawartości biomasy w reaktorze $\Delta F/M_{ChZT}$). Wartości liczbowe zmiennych ujmowanych w modelu przekształcono do postaci lingwistycznej, co polegało na wprowadzeniu kilku klas zmienności tych zmiennych w zależności od ich wartości liczbowych. Przykładowo, ilość tlenu rozpuszczonego w osadzie czynnym ustala się jako bardzo niską (<1 mg/l), niską ($0\div 2$ mg/l), normalną ($1\div 3$ mg/l), wysoką ($2\div 5$ mg/l) i bardzo wysoką ($3,5\div 8,3$ mg/l), natomiast wartość obciążenia substratowego określa się jako niskie ($<0,5$ kgChZT/kg X_{OC} .d), normalne ($0,25\div 0,75$ kgChZT/kg X_{OC} .d), wysokie ($0,50\div 1,00$ kgChZT/kg X_{OC} .d) i bardzo wysokie ($0,75\div 1,57$ kgChZT/kg X_{OC} .d). Również w pracach (Roche 1995, Rossle i Pretorius 2008) wyznaczano modele nieliniowe do prognozowania objętościowego indeksu osadu I_0 na podstawie pomiarów nastaw reaktora i wskaźników fizyko–chemicznych charakteryzujących jakość ścieków oczyszczonych.

Z przeglądu publikacji (tab. 3.5) wynika, że poza modelami szarej skrzynki (PLS, NLR, logit, FL) przy symulacji objętościowego indeksu osadu szerokie zastosowanie znalazły również modele czarnej skrzynki (głównie sieci neuronowe i ich modyfikacje), w których podstawę obliczeń objętościowego indeksu osadu (I_0) stanowią wartości wskaźników fizyko–chemicznych ścieków oczyszczonych i nastaw reaktora biologicznego. Ciekawe podejście do symulacji indeksu osadu przedstawili Boztoprak i in. (2015), którzy wykorzystali analizę obrazu kłaczek osadu czynnego uzyskanego kamerą wysokiej rozdzielczości. Wyznaczony model charakteryzował się zadowalającą dokładnością prognozy I_0 , co potwierdziły wartości $R>0,90$. Szereg modeli do prognozy objętościowego indeksu osadu przedstawili Qiao i in. (2012, 2014, 2016), którzy opracowali nowatorskie modele czarnej skrzynki w postaci hierarchicznej sieci neuronowej (HANN) i modelu

hybrydowego SOM+RBF, charakteryzujące się lepszymi zdolnościami predykcyjnymi, niż modele typu ARX, RBF i SVM. Wyniki symulacji wartości I_0 , wyznaczone przez nich w oparciu o pomiary DO, pH, ChZT i N_{og} , wskazują na możliwość prognozy złożonych zjawisk z wysoką dokładnością (około 95% wyników obliczeń zgodnych z pomiarami) w przypadku ograniczonej liczby zmiennych. W innych pracach (Capodaglio i in. 1991, Lou i Zhao 2013, Bagherii i in. 2015, Djedodu i Achour 2016, Liu i in. 2016) (por. tab. 3.4) autorzy uwzględniali znacznie większą liczbę zmiennych objaśniających, niż Qiao i Han (2012, 2014, 2016), uzyskując niewiele lepsze wyniki symulacji indeksu osadu. Badano także modele, w których zmiennymi objaśniającymi były bakterie nitkowate, orzęski, wrotki i bakterie typu *Zooglea* występujące w osadzie, natomiast miarą zmienności sedymentacji osadu była zawartość zawiesiny w odpływie (Côté 1995, Belanche i in. 2000).

3.4. Sterowanie nastawami reaktorów biologicznych przy użyciu modeli statystycznych

Ze względu na zmieniającą się na dopływie do oczyszczalni ilość i jakość ścieków oraz zróżnicowane warunki atmosferyczne, uzyskanie wymaganej efektywności usuwania zanieczyszczeń w odniesieniu do obowiązujących aktów prawnych nie jest prostym zadaniem. Na etapie eksploatacji obiektu, w celu spełnienia wymagań ujętych w Rozporządzeniu Ministra Środowiska z dnia 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, możliwe są dwa rozwiązania. Pierwsze rozwiązanie dotyczy takiego wyznaczenia stałych nastaw reaktora, które w założeniu zapewnią odpowiednią jakość ścieków na odpływie, mimo zmieniających się dynamicznie warunków na dopływie do obiektu. Jest to sterowanie w układzie regulacji automatycznej, zapewniające stabilną pracę obiektu. Jednak takie podejście, poprawne z technicznego punktu widzenia, może być nieekonomiczne i generować wysokie koszty eksploatacyjne. Wobec powyższego, można wziąć pod uwagę drugie rozwiązanie, polegające na aktywnym, czyli zmieniającym się w czasie sterowaniu nastawami bioreaktora w celu zapewnienia odpowiedniej jakości ścieków na odpływie i jednocześnie obniżenia kosztów funkcjonowania oczyszczalni. Z uwagi na złożoność obiektów, jakimi są oczyszczalnie ścieków i potrzebę definiowania licznych kryteriów jakości przy sterowaniu aktywnym (dotyczących jakości ścieków na odpływie, kosztów eksploatacji, ilości produkowanego biogazu, ilości zużywanych koagulantów itp.) liczba publikacji poświęcona sterowaniu bioreaktorami jest stosunkowo mała w porównaniu z pracami dotyczącymi modelowania oczyszczalni. W nielicznych pracach związanych z wyznaczaniem stałych nastaw regulatorów w reaktorze stosowano modele fizyczne (Minsoo i in. 2016). Jednak ze względu na to, że modele te z powodu swojej złożoności mają

długie czasy obliczeń i ich kalibracja jest bardzo uciążliwa mają ograniczone wykorzystanie przy optymalizacji pracy bioreaktora, o czym wspomniano już wcześniej. Tym bardziej jest ono ograniczone w przypadku zadania aktywnego sterowania oczyszczalnią, które musi zachodzić w trybie on-line. Dlatego też, w zadaniach sterowania nastawami reaktora biologicznego zastosowanie znajdują modele statystyczne (tab. 3.6). Z przeglądu prac zestawionych w tab. 3.6 wynika, że kluczowym kryterium sterowania nastawami reaktora jest jakość ścieków oczyszczonych i ładunek zanieczyszczeń ujęty za pomocą EQI w ściekach wprowadzanych do odbiornika. Kolejne przyjmowane kryteria dotyczą kosztów eksploatacyjnych oraz ilości produkowanego biogazu (Wei i Kusiak 2012). Przy czym ilość produkowanego biogazu jest zwykle uzupełnieniem kryteriów podstawowych związanych z jakością ścieków i kosztami eksploatacyjnymi Tomita i in. (2007). W pracy Flores-Alsiny i in. (2009) kryteria dotyczące kosztów eksploatacyjnych i ładunku zanieczyszczeń odprowadzanych do odbiornika analizowano dla przypadków, gdy występowało lub nie występowało zjawisko puchnięcia osadu czynnego. Modelami statystycznymi stosowanymi do sterowania nastawami bioreaktora dla uzyskania zadanej jakości ścieków oczyszczonych ($N-NH_4$, ChZT, Z_{og} , N_{og} , $N-NO_3$) są zwykle sztuczne sieci neuronowe. Zmiennymi objaśniającymi w tych modelach są ilość i jakość ścieków surowych oraz zmienne sterujące, takie jak: współczynnik transferu tlenu (kLA), stopień recyrkulacji zewnętrznej (REC) i wewnętrznej (Q_{wewn}), stężenie osadu czynnego (X_{OC} i ilość dawkowanych związków chemicznych (koagulanty, zewnętrzne źródło węgla). W pracy (Canete i in. 2016) przedstawiono modele statystyczne, oparte o metody SVM i ANN, do prognozy wartości Z_{og} , ChZT, N_{og} w ściekach oczyszczonych z odpowiednim wyprzedzeniem czasowym na podstawie pomiarów $N-NO_3$, $N-NO_2$, $N-NH_4$, alkaliczności i DO w komorach reaktora. Podejście to daje możliwość kontroli i korekty zmiennych niezależnych w modelu, co pozwala na poprawę efektywności pracy bioreaktora. Wartości sterowań reaktora wyznaczone na podstawie modeli statystycznych czasami były weryfikowane za pomocą modelu fizycznego.

Takie podejście jest pokazane w pracy Canete i in. (2016), co wydaje się słuszne ze względu na dużą dokładność dobrze skalibrowanego modelu fizycznego i jednocześnie możliwy do zaakceptowania nawet długi czas jego pojedynczej symulacji. Model statystyczny do kontroli wartości nastaw reaktora przedstawiono także w pracy Haimi i in. (2016), w której, wykorzystując zmodyfikowaną metodę PCA, identyfikowano na odpływie z oczyszczalni wskaźniki jakości ścieków odstające od wartości wymaganych. Na tej podstawie dokonywano korekty nastaw reaktora biologicznego (Q_{wewn} , kLA, X_{OC} , M_{nadm}), co miało wpływ na poprawę jakości ścieków oczyszczonych. Możliwość doboru nastaw reaktora w zależności od wydzielonych metodą k-najbliższych sąsiadów różnych etapów działania oczyszczalni (pogoda opadowa, typowy stan

eksploatacji, problemy z działaniem osadnika wtórnego) przedstawili Sanchez i in. (2008).

Tab. 3.6. Zestawienie wybranych publikacji z zakresu sterowania reaktorem biologicznym (x^* – zmienne sterujące).

Źródło	Oczyszczalnia	Prognoza	Zmienne objaśniające	Metoda	Kryteria
Cristea i in. (2009)	ASP	N-NO ₃	Si, Ss, Xi, Xs, Xbh, Snh, Snd, Z _{og} (Q _{wewn} , kLA)*	ANN	N-NO ₃
Fernandez de Canete (2016)	ASP	Z _{og} , ChZT, N _{og} (t+T _o)	DO(t-i), Alk(t-j), N-NO ₃ (t-k), N-NH _{4,odp} , Q(t-m)	GSP-X+ +ANN/ SVM	Z _{og} , ChZT, TN
Gyeongdong i in. (2012)	A2O (L)	DO	Q, N-NO ₂ , N-NO ₃ , P-PO ₄ , ORP (pH, X _{OC})*	cF+ANN	N-NH ₄
Lucarni i in. (2002)	ASP (SBR)	N _{og} , P _{og}	ORP, pH	ANN	N _{og} , P _{og}
Chen i in. (2006)	ASP/I	ChZT	CN, Z _o , HT, X _{OC} (Q, REC)*	ANN(GA)	OCI
Haimi i in. (2016)	ASP	N-NO ₃ , N-NH ₄ , pH, Alk	Q, Z _o , N-NO ₃ , N-NH ₄ (V(AN), Q _{wewn} REC, M _{nadm} , kLA)*	PCA (EWMA) +T ² Hotteling	N-NH ₄
Sanchez i in. (1997)	ASP	dobór sterowania	jakość ścieków, parametry reaktora	k-NN	EQI, OCI
Asadi, Verma, Yang (2016)	ASP	CBZT, Z _{og} , TSP, TDP	Q, T, pH (REC, Q _{pow} , DO)*	MARS+ PSO	jakość ścieków, koszty
Kusiak, Wei (2013)	ASP	CBZT, Z _{og}	Q, T, CBZT, Z _{og} (Q _{pow} , DO)*	ANN	jakość ścieków, koszty
Minsoo i in. (2016)	ASP	N _{og} , P _{og}	(REC, M _{nadm} , kLA, Q _{wewn})*	k-NN+ ASM+ QUALE2	N _{og} , P _{og}

Tab. 3.6. cd.

Źródło	Oczyszczalnia	Prognoza	Zmienne objaśniające	Metoda	Kryteria
Brdyś i in. (2002),(2004), (2008), (2014)	ASP	N-NH ₄ , N-NO ₃ , P-PO ₄ , ChZT	Q, ChZT, BZT ₅ , N _{og} , P _{og} (PIX, X _{OC} , DO, Q _{wewn})*	EKF	OCI, EQI, OV
Tomita i in. (2007)	ASP (UASB)	Biogaz	BZT ₅ , ChZT, ChZT(rozp), T (HT, ChZT _{odp})*	PLS+GA	Biogaz
Wei i Kusiak (2012)	ASP	Biogaz	M _{nadm} , L _{org} , t (T _{wkf} , Z _o , VS, pH)*	ANN+PS O	Biogaz
Santin (2015)	ASP	N _{og} , N-NH ₄	Q _{wewn} , DO	BSM1+A NN	EQI, OCI
Flores-Alsina i in. (2009), Comas (2008)	ASP	TKN, N _{og} , ChZT, BZT ₅ , Z _{og}	Q, WO, BZT ₅ , N _{og} , P, DO, F/M, Ss (RECM _{nadm} , kLA)*	BSM2+FL	EQI, OCI

Kryterium ekonomiczne dotyczące kosztów eksploatacji wprowadzili do zadania optymalizacji i sterowania Kusiak i Wei (2013). W rozpatrywanym przez nich przypadku podjęto próbę optymalizacji procesu oczyszczania ścieków polegającej na redukcji strumienia powietrza (I wariant), poprawie jakości ścieków (II wariant) i równoczesnym spełnieniu obu założeń (III wariant). Do tego celu autorzy wykorzystali trzy modele statystyczne do symulacji wartości wskaźników jakości ścieków (CBZT₅, Z_{og}) i ilości doprowadzanego powietrza do bioreaktora. Wartości wymienionych wyżej wskaźników prognozowano modelem opracowanym metodą MLP na podstawie wartości Q, REC, DO, (CBZT₅, Z_{og}) i stężenia tlenu w bioreaktorze (DO). Natomiast, wielkość wprowadzanego strumienia powietrza symulowano na podstawie wartości Q, REC, DO i rozważanych wskaźników jakości ścieków na dopływie i odpływie z obiektu. Wykonane symulacje wykazały, że jest możliwa redukcja strumienia powietrza w wariacie I odpowiednio o 15% w odniesieniu do stanu istniejącego, przy czym stwierdzono wzrost maksymalnych wartości wskaźników jakości ścieków na wylocie z ok. 7,5 mg/l do ok. 20,0 mg/l w odniesieniu do CBZT₅ i z ok. 20,0 mg/l do ok. 30,0 mg/l dla Z_{og}). W celu poprawy jakości ścieków na wylocie z oczyszczalni (wariant II) wymagane było zwiększenie strumienia powietrza o 5% w odniesieniu do stanu istniejącego. W wariacie III, stanowiącym kompromis między wariantem I i II, stwierdzono redukcję strumienia powietrza o 5%

i mniejsze różnice między wartościami wskaźników jakości ścieków, niż w wariancie II.

Problem optymalizacji nastaw bioreaktora sformułowany przez Kusiaka i Wei (2013) rozwinęli Asadi i in. (2016), którzy poza wartościami wskaźników jakości ścieków ($CBZT_5$, Z_{og}) i stężenia tlenu w bioreaktorze (Q_{pow}) uwzględnili w swoim modelu również wartości TSP (całkowity zawieszony fosfor) i TDP (całkowity rozpuszczony fosfor). Do symulacji tych zmiennych zastosowano 3-letnie szeregi danych pomiarowych. Przy prognozie jakości ścieków na wylocie uwzględniono ilość i jakość ścieków ($CBZT_5$, Z_{og}), TSP, TDP oraz parametry operacyjne reaktora (pH, temperatura oraz stopień recyrkulacji i strumień powietrza stanowiące zmienne sterujące). W obliczeniach ujęto metody MARS, RF, ANN i k-NN. Asadi i in. (2016) ograniczyli się do minimalizacji wartości wskaźników jakości ścieków na odpływie (wariant I) i redukcji kosztów napowietrzania, czyli minimalizacji strumienia doprowadzanego powietrza (wariant II). Wykonane rezultaty analiz wykazały, że najlepszymi zdolnościami predykcji jakości ścieków charakteryzuje się model opracowany metodą MARS. Symulacje wykonane w wariancie I dla okresu 42 dni wykazały poprawę jakości ścieków oczyszczonych w odniesieniu do wskaźników Z_{og} , $CBZT_5$, TDP odpowiednio o 9,7%, 15,7% i 21,1%, oraz wzrost kosztów napowietrzania o 33,7% i wzrost stężenia tlenu DO o 9,6%. W wariancie II uzyskano redukcję kosztów napowietrzania o 31,5%, wzrost stężenia tlenu o 5,4% oraz wzrost wartości Z_{og} , $CBZT_5$ i TDP na wylocie z oczyszczalni odpowiednio o 11,1%, 13,7% i 21,7%.

Poza kryteriami jakościowymi (wartości wskaźników jakości ścieków na odpływie z oczyszczalni) i ekonomicznymi istotną rolę przy doborze nastaw reaktora biologicznego odgrywają również kryteria ekologiczne. Związane są one z wpływem jakości ścieków oczyszczonych na zanieczyszczenie wód odbiornika. Strategie sterowania reaktorem uwzględniające również kryteria ekologiczne są złożone i w celu ich spełnienia konieczna jest integracja modeli do prognozy ilości i jakości ścieków na dopływie, modeli procesów biochemicznych przebiegających w bioreaktorze i modeli prognozowania jakości ścieków na odpływie (Grochowski i in. 2004, Brdyś i in. 2002). Przykłady sterowania nastawami bioreaktora w zależności od zmieniającej się ilości i jakości ścieków na dopływie, z uwzględnieniem kryteriów jakościowych, ekologicznych i ekonomicznych, są przedstawione w pracach Brdyś i in. (2004, 2008, 2014) oraz Minsoo i in. (2016). Dla uwzględnienia wszystkich wymienionych kryteriów Brdyś i in. (2004, 2008, 2014) opracowali hierarchiczną strukturę sterowania składającą się z trzech warstw: sterowania nadzorującego, optymalizacji i generowania trajektorii sterowań dla wybranych zmiennych sterujących i różnych horyzontów czasowych i warstwy nadążającej odpowiedzialnej za realizację sterowań wyznaczonych przez warstwę optymalizacji. Warstwa optymalizacji składa się z trzech podwarstw:

- sterowania procesami wolnozmiennymi (korekta wieku osadu, stężenia osadu czynnego, ilości usuwanych osadów nadmiernych i dozowania ścieków do reaktora z punktu zlewnego), odpowiedzialnej za stabilność biologiczną oczyszczalni i minimalizację kosztów eksploatacyjnych,
- sterowania procesami średnio szybkimi (korekta stężenia tlenu w komorach tlenowych, stopni recyrkulacji, ilości dawki chemicznego wspomagającego usuwanie fosforu), odpowiedzialnej za jakość ścieków na odpływie i również minimalizację kosztów eksploatacyjnych,
- sterowania procesami szybkozmiennymi (korekta stężenia tlenu w komorze nityfikacji i dozowania reagentów chemicznych), odpowiedzialnej za jakość ścieków na odpływie w czasie ulewnych deszczy i krótkotrwałych zdarzeń zakłócających pracę obiektu.

W każdej podwarstwie do generowania trajektorii sterowań wykorzystano metodę krzepkiego (ang. robust) sterowania predykcyjnego. W podwarstwie sterowania procesami średnio szybkimi przyjęto model „Grey Box” bazujący na metodzie rozszerzonego filtra Kalmana. Zastosowanie opracowanego systemu sterowania reaktorem biologicznym testowano na oczyszczalni ścieków w Kartuzach (Brdyś i in. 2008). Wykazano, że zaproponowany system sterowania pozwala na redukcję kosztów eksploatacyjnych, poprawę jakości ścieków na odpływie i również na ograniczenie objętości zrzutów przelewem burzowym w czasie intensywnych opadów, co ma istotne znaczenie dla równowagi biologiczno–chemicznej ekosystemu w odbiorniku.

Minsoo i in. (2016) przedstawili możliwość integracji modelu do prognozy ilości i jakości ścieków na dopływie z modelem ASM symulacji procesów w reaktorze oraz z modelem prognozy jakości ścieków w odbiorniku. Wykazali oni, że zaproponowane rozwiązanie pozwala na poprawę jakości ścieków oczyszczonych oraz redukcję wartości N_{og} , P_{og} w wodach odbiornika, co ogranicza zjawisko eutrofizacji wód powierzchniowych w ciekach wodnych. Przykład połączenia modelu fizykalnego i modelu czarnej skrzynki (ANN) przedstawili również Sant’in i in. (2015), wykazując możliwość zastosowania sztucznej sieci neuronowej do prognozy wartości maksymalnych $N-NH_4$ w ściekach oczyszczonych, co umożliwi zmianę strategii sterowania reaktorem.

W omawianych dotychczas pracach (Brdyś 2008, Kusiak i Wei 2013, Minsoo i in. 2016, Asadi i in. 2016) autorzy w większości przypadków koncentrowali się na optymalizacji i sterowaniu nastawami reaktora w oparciu o uzyskane wyniki prognoz wskaźników jakości ścieków na wylocie z oczyszczalni. Takie podejście nie uwzględnia jednak zdarzeń, jakie mogą wystąpić w reaktorze i prowadzić do pogorszenia się jakości ścieków na odpływie, na przykład zjawisko puchnięcia osadu czynnego. Problem ten został przedstawiony w pracy Comas i in. (2008) oraz Flores-Alsina i in. (2009). Flores-Alsina i in. (2009) rozważali wpływ zmiany

ilości odprowadzanych osadów nadmiernych (wariant I), stopnia recyrkulacji zewnętrznej (wariant II) i współczynnika transferu tlenu (wariant III) na jakość ścieków na odpływie w przypadku puchnięcia osadu lub jego braku. Wykonane symulacje wykazały na przykład, że w przypadku zwiększonego stopnia recyrkulacji o 50% puchnięcie osadu prowadzi do wzrostu wskaźnika EQI o 8% i wzrostu wartości wskaźników jakości ścieków oczyszczonych BZT₅, ChZT, Z_{og}, N_{og}, TKN odpowiednio o 22%, 9%, 20%, 5% i 11%. Wyniki symulacji uzyskane przez autorów wskazują, że celowe jest uwzględnianie procesu puchnięcia osadu przy modelowaniu procesów w bioreaktorze. Powinien on być uwzględniany również w zadaniach, których celem jest optymalizacja względnie sterowanie nastawami regulatorów w reaktorze oczyszczalni.

3.5. Modele niezawodności pracy oczyszczalni

Niezawodność jest istotnym wskaźnikiem oceny poprawności działania obiektów inżynierskich, w tym w szczególności oczyszczalni ścieków (Rak i Tchórzewska – Cieślak 2006, 2013). Dotychczas bardzo nieliczne prace z obszaru inżynierii środowiska zajmują się tym problemem (Rak 2004). Opracowywane modele do prognozy niezawodności działania oczyszczalni ścieków są bardzo uproszczone i w większości przypadków dotyczą wyznaczania współczynnika niezawodności COR, będącego stosunkiem średniej wartości wskaźnika jakości ścieków na odpływie do jego wartości dopuszczalnej, podanej w Rozporządzeniu Ministra Środowiska z dnia 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. Zaproponowany współczynnik pozwala ocenić niezawodność działania obiektu w sposób bardzo ogólny, dostateczny z punktu widzenia eksploatatora. Nie uwzględnia on zmienności jakości ścieków na odpływie, jaka może wystąpić w rozpatrywanym okresie czasu (np. 1 roku), co oznacza, że nie rejestruje on nawet znacznych przekroczeń dopuszczalnych wskaźników jakości ścieków. Biorąc pod uwagę prowadzone obecnie badania z zakresu optymalizacji i sterowania nastawami reaktorów biologicznych (Elis i in. 1993, Messaoud i in. 2013, Taheriyoun i Moradinejad 2015, Kudłak i in. 2016) można zauważyć, że wartość współczynnika COR w ograniczonym stopniu odzwierciedla wyznaczanie korekty strategii sterowania reaktorem. Mając na względzie powyższe uwagi, celowa wydaje się modyfikacja obecnie stosowanej formuły do wyznaczania współczynnika niezawodności. Z punktu działania oczyszczalni wskazane byłoby zastąpienie średniej wartości wskaźnika jakości ścieków wyznaczonej na podstawie rutynowych pomiarów, wynikami jego obliczeń uzyskanymi za pomocą modeli fizykalnych lub statystycznych.

3.6. Cel i zakres pracy

Przegląd publikacji dotyczących prognozowania ilości i jakości ścieków na dopływie i odpływie z oczyszczalni ścieków oraz sedymentacji osadu czynnego skłania do stwierdzenia, że w przeciągu ostatnich 40 lat nastąpił gwałtowny rozwój w obszarze modelowania, optymalizacji i sterowania reaktorami biologicznymi. Współcześnie jest to temat bardzo intensywnych badań, które mają na celu redukcję ładunku zanieczyszczeń wprowadzanych do odbiorników, obniżenie kosztów eksploatacyjnych oczyszczalni oraz zmniejszenie emisji gazów cieplarnianych w oparciu o wyniki symulacji długookresowych uzyskiwanych za pomocą modeli fizykalnych. Aby zapewnić poprawne wykonanie takich symulacji, w ostatnich 15 latach opracowano szereg generatorów dopływu ilości i jakości ścieków, a także poszczególnych frakcji zanieczyszczeń w ściekach surowych w zależności od charakteru lokalnego jednostek osadniczych. Z uwagi na to że, modele fizykalne procesów biochemicznych są opisane układami równań różniczkowych, w których trzeba wyznaczyć dużą liczbę parametrów, występują na ogół problemy z ich kalibracją i obecnie jest to główny problem ograniczający ich zastosowanie.

Wobec powyższego, do modelowania procesów i doboru nastaw w reaktorach biologicznych oraz symulacji jakości ścieków na dopływie i odpływie z oczyszczalni coraz powszechniejsze zastosowanie znajdują modele statystyczne. Jednak, modele statystyczne wyznaczone do prognozowania wskaźników jakości ścieków na dopływie do oczyszczalni są tworzone na bazie wyników ich pomiarów (Häcke i Köhne 1996, Sobota i Szetela 2005, Dogan i in. 2008, Minsoo i in. 2016, Ebrahimi i in. 2017). W efekcie wykonywanie takich pomiarów jest kosztowne i w rejestrowanych szeregach czasowych występują nieciągłości spowodowane awariami sond pomiarowych. Dlatego też, zachodzi potrzeba opracowania modeli do prognozy jakości ścieków na dopływie w oparciu o pomiary takich wskaźników, które mogą być wykonywane na każdej oczyszczalni ścieków w sposób prostszy, tańszy i bezawaryjny.

Poza tym, że modele statystyczne do symulacji procesów biochemicznych mają ograniczone wykorzystanie z powodu częstych okresów nieciągłości w ciągach pomiarowych wskaźników jakości ścieków na dopływie, to również ocena poprawności tych modeli w aspekcie ich zastosowania w zadaniach symulacji, optymalizacji i sterowania bioreaktorami budzi wątpliwości. Po pierwsze, opracowując takie modele autorzy przede wszystkim koncentrują się na implementacji wybranej metody modelowania, natomiast nie zajmują się już porównaniem uzyskanych wyników z innymi metodami (Chen i in. 2003, Cinar i in. 2006, Raduly i in. 2007, Hong, Paik 2007, Qiao, Yang 2011). Postępowanie to budzi wątpliwości, ponieważ oprócz uzyskania samych rezultatów modelowania jest również ważne, aby poszukiwać metody zapewniającej uzyskiwanie

najmniejszych błędów obliczeniowych i możliwie prostej w implementacji, co umożliwi jej zastosowanie w praktyce inżynierskiej. Analizując prace z zakresu modelowania jakości ścieków na odpływie i sedymentacji osadu czynnego można zauważyć, że autorzy na ogół nie sprawdzają użyteczności opracowanych modeli do sterowania reaktorem biologicznym (Cinar i in. (2006), Hong, Paik (2007), Pai i in. (2011), Qiao, Yang (2011), Lou, Zhao (2013), Han, Qiao (2013), Bagheri i in. (2015)). Jest to o tyle istotne, że często wyznaczone modele, nawet poprawnie prognozujące wartości wybranych wskaźników jakości ścieków, mogą mieć ograniczone zastosowanie do optymalizacji lub sterowania nastawami reaktora z powodu ich złożoności. W efekcie czyni to je bezużytecznymi z eksploatacyjnego punktu widzenia. W związku z tym, tworząc modele do symulacji pracy bioreaktora są niezbędne równoczesne analizy weryfikujące ich przydatność w zadaniach optymalizacji i sterowania.

Modele statystyczne mogą być i są stosowane w rozwiązywaniu zadań sterowania nastawami bioreaktorów. Jednak, obecnie kryteria optymalizacji stosowane w tych zadaniach dotyczą przede wszystkim zapewnienia wymaganej jakości ścieków na odpływie z oczyszczalni i ograniczenia kosztów eksploatacji obiektu. Natomiast, w ograniczonym stopniu uwzględniają zjawiska jak na przykład puchnięcie osadu. Zgodnie z dotychczasową wiedzą puchnięcie osadu prowadzi do pogorszenia jakości ścieków na odpływie i także innych problemów eksploatacyjnych (Henze i in. 2002). Znalazło to potwierdzenie również w badaniach prowadzonych przez Comasa i in. (2008), którzy zajmowali się optymalizacją działania oczyszczalni (pracującej w układzie Ludzack–Ettinger) z zastosowaniem modelu fizycznego ASM do symulacji i prognozy sedymentacji osadu.

Biorąc pod uwagę obecny stan wiedzy z zakresu modelowania niezawodności działania oczyszczalni i liczne uproszczenia przyjmowane w wyznaczanych modelach, należy zauważyć, że konieczne są badania mające na celu rozbudowę tych modeli i ich uszczegółowienie. Do tej pory opracowywane modele odnosiły się do analizy niezawodności w odniesieniu wyłącznie do jakości ścieków na odpływie, podczas gdy należy badać efektywność działania bioreaktora z uwzględnieniem możliwie wielu przebiegających w nim procesów i zjawisk (np. usuwania zindywidualizowanych związków biogennych oraz sedymentacji i puchnięcia osadu).

Celem pracy było wykazanie, że możliwa jest ciągła symulacja, sterowanie, optymalizacja pracy przepływowej oczyszczalni ścieków. Zakres pracy obejmował opracowanie:

- modeli statystycznych do prognozy jakości ścieków na dopływie do oczyszczalni ścieków na bazie pomiarów natężenia przepływu,

- algorytmu obliczeniowego do tworzenia modeli procesowych (prognoza jakości ścieków na wylocie, sedymentacja osadu czynnego) w przypadku wystąpienia nieciągłości pomiarów jakości ścieków przy pomocy metod data mining,
- uniwersalnej metodyki pozwalającej optymalizować i badać wpływ struktury modelu sieci neuronowej w tym charakterystyk fizyczno–geograficznych i opadowych na zdolności predykcyjne modelu do prognozy natężenia przepływu,
- metodyki doboru metody statystycznej do symulacji pracy oczyszczalni ścieków z uwzględnieniem sposobu gromadzenia danych i długości okresu pomiarowego,
- uproszczonej metodyki symulacji niezawodności pracy przepływowej oczyszczalni ścieków (w aspekcie sedymentacji osadu i usuwania związków biogennych) z ujęciem wpływu zmiennych parametrów operacyjnych reaktora,
- modelu probabilistycznego do symulacji niezawodności pracy oczyszczalni ścieków w odniesieniu do zdolności sedymentacyjnych osadu czynnego z ujęciem: stochastycznego charakteru ilości, jakości ścieków na dopływie, warunków pogodowych i potencjalnych awarii układu pomiarowego.

9. Podsumowanie i wnioski końcowe

Oczyszczalnia ścieków stanowi złożony obiekt technologiczny, w którym zachodzi szereg procesów biochemicznych. Podstawą oceny działania oczyszczalni jest uzyskiwanie na wylocie założonej jakości ścieków. Z uwagi na losowy i zależny od pory roku charakter ilości i jakości ścieków na dopływie, zapewnienie wymaganej jakości ścieków na odpływie jest trudne. Wymaga to regulacji w trybie dynamicznym nastaw bioreaktora i wybranych obiektów technologicznych, co pozwala na spełnienie obowiązujących wymagań prawnych. W związku z powyższym podejmowane są próby wspomaganie procesu usuwania związków biogennych przy wykorzystaniu modeli matematycznych opracowanych na podstawie pomiarów gromadzonych na obiekcie. Do tego celu można stosować modele fizykalne lub parametryczne, tzw. modele czarnej skrzynki. Jednak z uwagi na znaczenie czasu przy wykonywaniu pojedynczej symulacji modelu oczyszczalni, obecnie w większości przypadków stosuje się modele parametryczne (szarej lub czarnej skrzynki).

W przypadku obiektów, na których gromadzone są pomiary w trybie ciągłym (on-line) (ilość i jakość ścieków na dopływie i odpływie z oczyszczalni, parametry operacyjne bioreaktora), takie modele pozwalają na uzyskanie zadowalającej jakości ścieków na wylocie i obniżenie kosztów eksploatacyjnych. W przypadku braku ciągłości w pomiarach jakości ścieków na dopływie do oczyszczalni, na przykład na skutek wadliwej pracy urządzeń pomiarowych lub gdy wartości wskaźników oznaczane są drogą analityczną, modele matematyczne zasilane danymi w trybie on-line mają ograniczone zastosowanie. Wynika to z braku wartości liczbowych zmiennych niezależnych uwzględnianych w modelach procesowych.

Poza problemami z dostępem do danych wejściowych w modelach matematycznych oczyszczalni pojawia się kolejna istotna kwestia dotycząca doboru metody do symulacji i interpretacji uzyskanych wyników. Należy rozważyć kwestię, czy tworzyć modele o prostszej strukturze wymagające mniejszych nakładów obliczeniowych i krótszego czasu obliczeń, czy może stosować modele bardziej złożone? Sformułowane zadanie jest trudne, bowiem stanowi kompromis między dokładnością prognoz i złożonością modelu i ma istotny wpływ na

podejmowanie decyzji przez technologa podczas eksploatacji oczyszczalni. Ponadto w przypadku modeli procesowych uzyskanych przy pomocy metod czarnej skrzynki (z uwagi na brak fizycznej interpretacji wyznaczonej struktury) mogą pojawić się problemy z jednoznacznością oceną ich przydatności. Warunkiem użyteczności tworzonych modeli do symulacji bioreaktorów jest poprawne odzwierciedlenie wpływu zmiennych niezależnych (ilość i jakość ścieków na dopływie do obiektu, parametry operacyjne reaktora) na zjawiska zachodzące w osadzie czynnym.

W pracy przedstawiono metodykę tworzenia modeli procesowych do symulacji ilości i jakości ścieków na wlocie i wylocie z oczyszczalni i osadu czynnego w bioreaktorze. Do tego celu zastosowano szereg metod data mining, zaczynając od najprostszych modeli liniowych, poprzez modele bazujące na teorii drzew regresyjnych i klasyfikacyjnych (drzewa wzmacniane, lasy losowe), a kończąc na złożonych metodach uczenia maszynowego, jak metoda wektorów nośnych, sztuczne sieci neuronowe typu perceptron wielowarstwowy (3 warstwy) oraz sieci neuronowe kaskadowe (tzw. deep learning) z co najmniej dwiema warstwami ukrytymi. W przypadku symulacji osadu czynnego obliczenia dotyczą jego sedymentacji z zastosowaniem modeli do prognozy wartości liczbowych i zmiennych lingwistycznych (osad puchnie lub nie). Wykorzystując opracowane modele statystyczne do symulacji procesów zachodzących w bioreaktorze przedstawiono metodykę optymalizacji działania oczyszczalni ścieków. Wykonane modele statystyczne wyznaczono na podstawie wieloletnich ciągów pomiarowych pochodzących z oczyszczalni ścieków Sitkówka–Nowiny, Trepcza i Rzeszów.

Ze względu na złożoną postać opracowanych modeli przedstawiono metodykę ich tworzenia pozwalającą na analizę niezawodności pracy oczyszczalni w ujęciu długo- i krótko-okresowym.

Na podstawie wykonanych w pracy obliczeń sformułowano następujące wnioski końcowe:

1. Do analizy wrażliwości struktury sieci neuronowej (funkcje aktywacji, liczby neuronów w warstwach ukrytych) i zmiennych niezależnych (wartości przepływów i opadów) w przypadku prognozy dopływu należy zastosować metodę regresji logistycznej. Opracowany model szarej skrzynki pozwala na ocenę wpływu uwzględnionych w nim zmiennych niezależnych na dokładność predykcji dopływu. W opracowanym modelu można analizować wpływ poszczególnych zmiennych i również grupy zmiennych w porównaniu z innymi rozwiązaniami, w których rozważa się jedynie wpływ pojedynczych zmiennych. Zaprezentowane w pracy podejście stanowi alternatywne rozwiązanie do obecnie stosowanych metod, gdzie zachodzi potrzeba wykonania obliczeń o dużym nakładzie czasowym lub wymaga się implementacji złożonych algorytmów numerycznych.

2. Wykazano na podstawie przeprowadzonych badań, że możliwe jest modelowanie jakości ścieków (BZT_5 , $ChZT$, Z_o , N_{og} , $N-NH_4$, P_{og}) na dopływie do oczyszczalni ścieków na podstawie pomiarów natężenia przepływu. Rezultaty te wskazują na to, że zróżnicowany stopień rozcieńczenia ścieków determinuje jakość ścieków, co wykazano na przykładzie dwóch obiektów (oczyszczalnie Sitkówka–Nowiny i Rzeszów). Spośród badanych w pracy metod najlepsze wyniki modelowania (najmniejsze wartości błędów prognozy wybranych wskaźników jakości ścieków) otrzymano stosując metodę kaskadowych sieci neuronowych (wielowarstwowych). Z kolei największe błędy prognozy otrzymano metodami lasów losowych bądź drzew wzmacnianych.

W przypadku niezadawalających zdolności predykcyjnych modeli do prognozy jakości ścieków wyznaczanych na podstawie wartości dopływów w oparciu o metody uczenia maszynowego, alternatywne rozwiązanie może stanowić opracowany klasyfikator wskaźników jakości i ładunków zanieczyszczeń. Zaproponowane narzędzie zbudowane przy użyciu metody wektorów nośnych pozwala na identyfikację stanu pracy oczyszczalni na dopływie do obiektu (przeciążenie hydrauliczne, niedobór biogenów) z dobowym wyprzedzeniem, na podstawie wartości natężenia przepływu zmierzonych w dobach poprzednich. Przedstawiony model pozwala na identyfikację typowych stanów na dopływie do oczyszczalni i umożliwia prognozowanie stanów incydentalnych niebezpiecznych dla bioreaktora. Wykonany w pracy model może stanowić użyteczne narzędzie dla technologa, który przy jego użyciu może podjąć odpowiednie decyzje eksploatacyjne dotyczące korekty parametrów operacyjnych bioreaktora (zmiana stopni recyrkulacji, stężenia tlenu rozpuszczonego w komorach osadu czynnego, dawkowania metanolu itp.).

3. Na podstawie wykonanych badań stwierdzono, że jest możliwe modelowanie sedymentacji osadu czynnego w osadniku wtórnym i jakości ścieków na wylocie z oczyszczalni ścieków w przypadku nieciągłości pomiarów jakości ścieków na dopływie do obiektu. Uzyskano to tworząc modele hybrydowe. Rozwiązanie to polega na zastąpieniu wartości zmiennych niezależnych (jakość ścieków) w modelach procesowych wynikami obliczeń. Najlepsze wyniki modelowania (najmniejsze błędy prognozy) sedymentacji osadu czynnego otrzymano za pomocą modeli hybrydowych bazujących na kombinacjach modeli kaskadowych sieci neuronowych jako modelu procesowego i modeli kaskadowych sieci neuronowych względnie wektorów nośnych lub perceptronu wielowarstwowego jako modeli wskaźników jakości ścieków. W przypadku modeli do prognozy jakości ścieków (azot amonowy, fosfor ogólny) najmniejsze wartości błędów uzyskano stosując metody wektorów nośnych i kaskadowych sieci neuronowych. Dla azotu ogólnego

zadowalające rezultaty obliczeń otrzymano modelami wykonanymi przy pomocy kaskadowych sieci neuronowych.

4. Do identyfikacji zdolności sedymentacyjnych osadu czynnego na istniejących obiektach można zastosować metodę regresji logistycznej (szara skrzynka), wykorzystując pomiary ilości i jakości ścieków na dopływie do oczyszczalni (BZT_5 , N_{og} , P_{og} , $N-NH_4$), pomiary temperatury w bioreaktorze i parametrów operacyjnych bioreaktora (stężenie osadu czynnego, stężenie tlenu rozpuszczonego, ilość dawkowanego PIX).

Należy podkreślić, że wyniki obliczeń otrzymane modelem logitowym nie odbiegają od rezultatów uzyskanych złożonymi modelami klasyfikacyjnymi opartymi na metodach sztucznych sieci neuronowych, wektorów nośnych, lasów losowych lub drzew wzmacnianych. Wykonane obliczenia (oczyszczalnie Sitkówka–Nowiny i Trepcza) wykazały, że wartości empirycznych współczynników w modelu regresji logistycznej zależą od dynamiki jakości ścieków na dopływie do oczyszczalni i rozwiązań technologicznych przyjętych na obiektach.

5. Kluczowe znaczenie na etapie tworzenia modeli procesowych (jakość ścieków na wylocie, sedymentacja osadu) przy pomocy metod czarnej skrzynki (sztuczne sieci neuronowe, metoda wektorów nośnych, lasy losowe, drzewa wzmacniane itp.) ma analiza wrażliwości modelu. Zaproponowana w pracy metoda analizy pozwala ocenić, na ile opracowany model poprawnie symuluje wpływ zmiennych niezależnych (w tym przede wszystkim zmiennych sterujących) na rozpatrywane zjawisko, co jest kluczowe z punktu widzenia wdrożenia opracowanych modeli statystycznych.
6. Opracowany model matematyczny oczyszczalni ścieków w oparciu o metody data mining (sieci neuronowe, regresja logistyczna) pozwala na badanie interakcji między procesami zachodzącymi w osadzie czynnym (sedymentacja) i jakością ścieków na wylocie (związki azotu i fosforu). Stanowi to cenne i oryginalne narzędzie, którego opracowania nie podjęto się do tej pory w kraju i zagranicą. Wykonane obliczenia wykazały, że na bazie opracowanego modelu możliwa jest optymalizacja pracy oczyszczalni ścieków (dobór odpowiednich nastaw, tj. korekta stężenia osadu czynnego, stężenia tlenu rozpuszczonego w komorach, ilości dawkowanego PIX) nawet w przypadku braku ciągłości danych pomiarowych dotyczących jakości ścieków na dopływie do obiektu.
7. Opracowany model probabilistyczny do analizy efektywności pracy bioreaktora (w odniesieniu do sedymentacji osadu czynnego) umożliwia ocenę niezawodności pracy oczyszczalni dla przyjętej strategii sterowania reaktorem w ujęciu długo-okresowym. Model ten pozwala na ocenę wpływu zmienności (prognozowanej za pomocą generatorów Monte Carlo bazujących

na wyznaczonych rozkładach teoretycznych na podstawie danych pomiarowych) ilości i jakości ścieków na dopływie i temperatury osadu czynnego (w ujęciu sezonowym wynikającym z pór roku) na dobór odpowiednich nastaw, co do tej pory w modelach o podobnym charakterze nie było uwzględniane. Jako nowe podejście w zaprezentowanym modelu należy uznać możliwość symulacji wpływu awarii analizatorów jakości ścieków na dopływie na dobór nastaw i niezawodność pracy oczyszczalni.

8. Wykazano, że długość szeregu pomiarowego, liczba danych i sposób ich gromadzenia (sposób ciągły - dane gromadzone w układzie on-line ze stałą rozdzielczością; sposób nieciągły, tj. okres między kolejnymi pomiarami (krok próbkowania) nie jest stały, są czynnikami determinującymi dobór metody do prognozowania jakości pracy oczyszczalni ścieków. Na podstawie opracowanych w pracy algorytmów można optymalizować długość okresu pomiarowego, przy uwzględnieniu którego ma być tworzony model matematyczny (o zadawalających zdolnościach predykcyjnych), przyjmując na początku eksperymentu określoną metodę data mining do symulacji zjawiska i sposób gromadzenia danych do jego opisu. W pracy wykazano, że stosując do prognozy działania oczyszczalni ścieków metody sieci neuronowych (MLP, CNN, SVM) wystarczą dane z rozdzielczością dobową obejmujące okres 6 miesięcy, tj. 180 wartości (dla zmiennej zależnej i zmiennych niezależnych) gromadzonych w układzie ciągłym lub nieciągłym, aby opracowany model charakteryzował się wysokimi zdolnościami predykcyjnymi. Przy czym modele opracowane na podstawie danych mierzonych w trybie on-line dla przyjętych długości szeregów czasowych charakteryzują się lepszymi zdolnościami predykcyjnymi, niż w przypadku danych mierzonych w trybie nieciągłym. Pośród badanych metod (MLR, GP, RF, BT, k-NN, MLP, CNN, SVM) stwierdzono, że metody MLP, CNN i SVM wykazują mniejszą wrażliwość na liczbę danych pomiarowych, niż modele opierające się na metodach lasów losowych, drzew wzmacnianych, k-najbliższych sąsiadów i programowania genetycznego. Tym samym przede wszystkim te metody powinny być dedykowane do modelowania oczyszczalni ścieków.
9. Możliwa jest ocena, symulacja i kontrola efektywności pracy oczyszczalni ścieków w trybie on-line na podstawie wartości współczynników niezawodności w odniesieniu do sedimentacji osadu czynnego (COR_{I_0} i jakości ścieków na wylocie ($COR_{F/M}$), wyrażonej w sposób uproszczony (obciążenie substratowe bioreaktora). Rozwiązanie to jest możliwe nawet w przypadku nieciągłości pomiarów wskaźników jakości ścieków na dopływie do oczyszczalni. Brakujące wartości wskaźników są modelowane na podstawie pomiarów natężenia dopływu do oczyszczalni przy zastosowaniu metod data mining. Podstawę doboru nastaw (stężenie osadu czynnego,

stężenie tlenu rozpuszczonego, ilość dawkowanego PIX) w bioreaktorze stanowi wartość współczynnika Φ będącego liniową kombinacją zmiennych dotyczących ilości i jakości ścieków (BZT_5/N_{og} , BZT_5/P_{og} , $N-NH_4$) oraz temperatury w komorach osadu czynnego. W pracy wykazano, że współczynnik Φ ma charakter sezonowy, zależy od pory roku i jest wrażliwy na przeciążenia hydrauliczne. Przyjęte rozwiązanie stanowi uproszczenie w odniesieniu do opracowywanych do tej pory modeli, gdy wartości nastaw ustalano drogą symulacji komputerowych metodami uczenia maszynowego.

Literatura

- Aarnio P., Minkkinen P. (1986): *Application of partial least – squares modelling in the optimization of a wastewater treatment plant*. Analytica Chimica Acta, 191, 457-460.
- Abba S.I., Elkiran G. (2017): *Effluent prediction of chemical oxygen demand from the wastewater treatment plant using artificial neural network application*. Procedia Computer Science, 120, 156–163.
- Abunama T., Othman F. (2017): *Time Series Analysis and Forecasting of Wastewater Inflow into Bandar Tun Razak Sewage Treatment Plant in Selangor, Malaysia*. IOP Conf. Series: Materials Science and Engineering, 210, 1-10.
- Abyaneh H.Z. (2014): *Evaluation of multivariate linear regression and artificial neural networks in prediction of water quality parameters*. Journal of Environmental Health Science and Engineering, 12, 1–8.
- Ahnert M., Marx C., Krebs P., Kuehn V. (2016): *A black-box model for generation of site-specific WWTP influent quality data based on plant routine data*. Water Science and Technology, 74, 2978–2986.
- Al-batah M.S., Alkhasawneh M.S., Tay L.T., Ngah U.K., Lateh H.H., Isa N.A.M. (2015): *Landslide occurrence prediction using trainable cascade forward network and multilayer perceptron*. Mathematical Problem in Engineering, 2015, 1–9.
- Alex J., Benedetti L., Copp J., Gernaey K.V., Jeppsson U., Nopens I., Pons M.N., Rieger L., Rosen Ch., Steyer J.P., Vanrolleghem P.A., Winkler S. (2008): *Benchmark Simulation Model no. 1 (BSM1)*. Technical Report, Department of Industrial Electrical Engineering and Automation, Lund University, LUTEDX/(TEIE7229)/1-62/(2008).
- Alsina X.F., Roda I.R., Sin G., Gernaey K.V. (2008): *Multi-criteria evaluation of wastewater treatment plant control strategies under uncertainty*. Water Research, 42, 4485–4497.
- Alsina X. F., Comas J., Roda I.R., Gernaey K.V., Rosen C. (2009): *Including the effects of filamentous bulking sludge during the simulation of wastewater treatment plants using a risk assessment model*. Water Research, 43, 4527–4538.

- Alsina X.F., Corominas L., Neumann M.B., Vanrolleghem P.A. (2012): *Assessing the use of activated sludge process design guidelines in wastewater treatment plant projects: A methodology based on global sensitivity analysis*. Environmental Modelling & Software, 38, 50-58.
- Alsina X.F., Arnell M., Amerlinck Y., Corominas L., Gernaey K.V., Guo L., Lindblom E., Nopen I., Porro J., Shaw A., Snip L., Vanrolleghem P.A., Jeppsson U. (2014): *Balancing effluent quality, economic cost and greenhouse gas emissions during the evaluation of (plant-wide) control/operational strategies in WWTPs*. Science of the Total Environment, 46, 616–624.
- Alsina X.F., Saagi R., Lindblom E., Thirsing C., Thornberg D., Gernaey K.V., Jeppsson U. (2014): *Calibration and validation of a phenomenological influent pollutant disturbance scenario generator using full-scale data*. *Water Research*, 51, 172-185.
- Andraka D., Dzienis L. (2013): *Modelowanie ryzyka w eksploatacji oczyszczalni ścieków*. Rocznik Ochrony Środowiska, 15, 1111-1125.
- Asadi A., Verma A., Yang K. (2016): *Wastewater treatment aeration process optimization: A data mining approach*. Journal of Environmental Management, 203, 1-10.
- Avella A.C., Görner T., Yvon J., Chappe P., Guinot-Thomas P., Donato P. (2011): *A combined approach for a better understanding of wastewater treatment plants operation: Statistical analysis of monitoring database and sludge physico-chemical characterization*. Water Research, 45, 981–992.
- Ayesa E., Sota A. De la, Grau P., Sagarna J.M., Salterain A., Suescun J. (2006): *Supervisory control strategies for the new WWTP of Galindo-Bilbao: the long run from the conceptual design to the full-scale experimental validation*. Water Science and Technology, 53, 193–201.
- Ayesha S., Balasubramanian S., Latha K.C. (2013): *A Time Series Analysis of Wastewater Inflow of Sewage Treatment Plant in Mysore, India*. International Journal of Current Research, 5, 248-253.
- Bagheri M., Mirbagheri S.A., Bagheri Z., Kamarkhani A.M. (2015): *Modeling and optimization of activated sludge bulking for a real wastewater treatment plant using hybrid artificial neural networks-genetic algorithm approach*. Process Safety and Environmental Protection, 95, 12-25.
- Bagley S.C., White H., Golomb B.A. (2001): *Logistic regression in the medical literature: standards for use and reporting, with particular attention to one medical domain*. Journal of Clinical Epidemiology, 54, 979–985.
- Balku S., Berber R. (2006): *Dynamics of an activated sludge process with nitrification and denitrification: Start-up simulation and optimization using evolutionary algorithm*. Computers and Chemical Engineering, 30, 490–499.
- Bannister C.A., Currie C.J., Preece A., Spasic I. (2014), *Automatic development of clinical prediction models with genetic programming: A case study in cardiovascular disease*. Health, 17, 200–201.

- Barbu M., Vilanova R., Meneses M., Santin I. (2017): *Global Evaluation of Wastewater Treatment Plants Control Strategies Including CO₂ Emissions*. IFAC PapersOnLine, 50-1, 12956–12961.
- Barbusiński K., Kościelniak H. (1995): *Influence of substrate loading intensity on floc size in activated sludge process*. Water Research, 29, 1703–1710.
- Bartkiewicz L., Studziński J. (2010): *Mathematical modeling of the hydraulic load of communal wastewater networks*. In: Modeling and Simulation 2010, G.K. Janssens, K. Ramakers, A. Caris. (eds), EUROSIS-ETI, Hasselt Belgium 2010, 156–160.
- Bartkiewicz L., Szelał B., Studziński J. (2016): *Ocena wpływu zmiennych wejściowych oraz struktury modelu sztucznej sieci neuronowej na prognozowanie dopływu ścieków komunalnych do oczyszczalni*. Ochrona Środowiska, 38, 29–36.
- Bayo J., Angosto J.M., Serrano-Aniorte J. (2006): *Evaluation of physicochemical parameters influencing bulking episodes in a municipal wastewater treatment plant*. Water Pollution VIII: Modelling, Monitoring and Management, Bologna, September 4-6, 531–541.
- Bayo J., López-Castellanos J. (2016): *Principal factor and hierarchical cluster analyses for the performance assessment of an urban wastewater treatment plant in the Southeast of Spain*. Chemosphere, 155, 152-162.
- Bechmann H., Nielsen M.K., Madsen H., Kjølstad-Poulsen N. (1999): *Grey-box modelling of pollutant loads from a sewer system*. Urban Water, 1, 71-78.
- Belanche L., Valde's J.J., Comas J., Roda I.R., Poch M. (2000): *Prediction of the bulking phenomenon in wastewater treatment plants*. Artificial Intelligence in Engineering, 14, 307-317.
- Berthouex P.M., Box G.E. (1996): *Time series models for forecasting wastewater treatment plant performance*. Water Research, 30, 1865 – 1875.
- Bezak-Mazur E., Stoińska R., Szelał B. (2016): *Ocena wpływu parametrów operacyjnych i występowania bakterii nitkowatych na objętościowy indeks osadu czynnego – studium przypadku*. Rocznik Ochrona Środowiska, 18, 487–498.
- Béraud B., Steyer J.P., Lemoine C., Latrille E., Manic G., Printemps-Vacquier C. (2007): *Towards a global multi objective optimization of wastewater treatment plant based on modeling and genetic algorithms*. Water Science and Technology, 56, 109-16.
- Bixio D., Parmentier G., Rousseau D., Verdonck F., Meirlaen J., Vanrolleghem P.A., Thoeye C. (2002): *A quantitative risk analysis tool for design/simulation of wastewater treatment plants*. Water Science and Technology, 46, 1-7.
- Bloom H.A. (1996): *Indirect measurement of key water quality parameters in sewage treatment plants*. Journal of Chemometrics, 10, 697-706.
- Bojanowska I., Downar D., Siedlecka E., Ropel E. (2000): *Ocena skuteczności miejskiej oczyszczalni ścieków w Kartuzach*. Ochrona Środowiska, 3, 21–24.
- Box G.E.P., Jenkins G.M. (1983): *Analiza szeregów czasowych. Prognozowanie i sterowanie*. PWN, Warszawa 1983.

- Bozorg-Haddad O, Soleimani S., Loáiciga H.A. (2017): *Modeling water-quality parameters using genetic algorithm–least squares support vector regression and genetic programming*. Journal of Environmental Engineering, 143, 145-153.
- Boztoprak H., Özbay Y., Güçlü D., Küçükhemek M. (2015): *Prediction of sludge volume index bulking using image analysis and neural network at a full-scale activated sludge plant*. Desalination and Water Treatment, 57, 1–11.
- Brdjanovic D. (1998): *Modeling biological phosphorus removal in activated sludge systems*. Ph.D, Thesis, Delft University of Technology, Delft 1998.
- Brdyś M.A., Grochowski M., Gminski T., Konarczak K., Drewa M. (2008): *Hierarchical predictive control of integrated wastewater treatment systems*. Control Engineering Practice, 16, 751–767.
- Brdyś M.A., Konarczak K. (2002): *Model predictive medium control layer for integrated sewer-wastewater treatment plant systems*. IIFAC International Conference on Technology, Automation and Control of Wastewater and Drinking Water Systems-Ti4SWiK'02, Gdansk–Sobieszewo, June 19-21, Poland.
- Brdyś M.A. (2014): *Integrated monitoring, control and security of Critical Infrastructure Systems*. Annual Reviews in Control, 38, 47–70.
- Breiman L. (2000): *Random forests*. Journal Machine Learning, 45, 5–32.
- Burges C. (1998): *A Tutorial on Support Vector Machines for Pattern Recognition*. In: U. Fayyad, Knowledge Discovery and Data Mining, Kluwer, 1–43.
- Butler D., Graham N.J.D. (1995): *Modeling Dry Weather Wastewater Flow in Sewer Networks*. Journal of Environmental Engineering, 121, 161–173.
- Canete J.F., Saz-Orozco P.D., Baratti R., Mulas M., Ruano A., Garcia-Cerezo A. (2016): *Soft-sensing estimation of plant effluent concentrations in a biological wastewater treatment plant using an optimal neural network*. Expert Systems With Applications, 63, 8–19.
- Capizzi G., Sciuto G.L., Monforte P., Napoli C. (2015): *Cascade feed forward neural network-based model for air pollutants evaluation of single monitoring stations in urban areas*. International Journal of Electronics and Telecommunications, 61, 327–332.
- Capodaglio A., Jones H., Novotny V., Feng X. (1991): *Sludge bulking analysis and forecasting: Application of system identification and artificial neural computing technologies*. Water Research, 25, 1217-1224.
- Carstensen J., Nielsen M.K., Strandbæk H. (1998): *Prediction of hydraulic load for urban storm control of a municipal WWT plant*. Water Science and Technology, 37, 363-370.
- Caruana R., Karampatziakis N., Yessenalina A. (2008): *An Empirical Evaluation of Supervised Learning in High Dimensions*. In: Proceedings of the 25. International Conference on Machine Learning, Helsinki, Finland, 2008.

- Chang T., Duzinkiewicz K., Brdys M.A. (2004): *Bounding approach to parameter estimation without priori knowledge on model structure error*. IFAC Large Scale Systems: Theory and Applications, Osaka, Japan, 2004, 221–226.
- Cheema J.J.S., Sankpal N.V., Tambe S.S., Kulkarni B.D. (2002): *Genetic programming assisted stochastic optimization strategies for optimization of glucose to gluconic acid fermentation*. Biotechnology Progress, 18, 1356–1365.
- Chen H.W., Ning S.K., Yu R.F., Hung M.S. (2006): *Optimizing the monitoring strategy of wastewater treatment plants by multiobjective neural networks approach*. Environmental Monitoring and Assessment, 125, 325–32.
- Chen H.W., Yu R.F., Ning S.K., Huang H.C. (2010): *Forecasting effluent quality of an industry wastewater treatment plant by evolutionary grey dynamic model*. Resources, Conservation and Recycling 54, 235–241.
- Chen Q., Qiao J., Zou Y.M. (2017): *A self-organizing recurrent neural network*, International Journal of Artificial Intelligence and Applications, 8, 11–23.
- Chuchro M. (2009): *Prediction of the sewage treatment plant inflow parameters*. Akademia Górniczo-Hutnicza, Wydział Geologii, Geofizyki i Ochrony Środowiska, Kraków 2009.
- Çinar Ö., Hasar H., Kinaci C. (2006): *Modeling of submerged membrane bioreactor treating cheese whey wastewater by artificial neural network*. Journal of Biotechnology, 123, 204–209.
- Clara N. (2008): *Neural networks complemented with genetic algorithms and fuzzy systems for predicting nitrogenous effluent variables in wastewater treatment plants*. WSEAS Transactions on Systems, 6, 695–705.
- Comas J., Dzeroski S., Gibert K., Roda I.R., Sánchez-Marré M. (2001), *Knowledge discovery by means of inductive methods in wastewater treatment plant data*. AI Communications, 14, 45–62.
- Comas J., Roda I.R., Gernaey K.V., Rosen C., Jeppsson U., Poch M. (2008): *Risk assessment modelling of microbiology-related solids separation problems in activated sludge systems*. Environmental Modelling & Software, 23, 1250–1261.
- Corominas L., Larsen H.F., Alsina X.F., Vanrolleghem P.A. (2013): *Including Life Cycle Assessment for decision-making in controlling wastewater nutrient removal systems*. Journal of Environmental Management, 128, 759–767.
- Corominas L., Foley J., Guest J.S., Hospido A., Larsen H.F., Morera S., Shaw A. (2013): *Life cycle assessment applied to wastewater treatment: State of the art*. Water Research, 47, 5480–5492.
- Cortés U., Martínez M., Comas J., Sánchez-Marré M., Poch M., Rodríguez-Roda I. (2003): *A conceptual model to facilitate knowledge sharing for bulking solving in wastewater treatment plants*. AI Communications, 16, 279–289.
- Côté M., Jean B.P.A.G., Lessard P., Thibault J. (1995): *Dynamic modelling of the activated sludge process: improving prediction using neural networks*. Water Research, 29, 995–1004.

- Cristea V.M., Pop C., Agachi P.S. (2009): *Artificial neural networks modelling of PID and model predictive controlled waste water treatment plant based on the Benchmark Simulation Model No.1*. 19th European Symposium on Computer Aided Process Engineering–ESCAPE19J, Jeżowski and J, Thullie (eds.), 1183–1188.
- Czekański A. (2017): *Efekty stosowania PIX-u 113 do wspomagania procesu technologicznego w rozbudowanej oczyszczalni ścieków w Trepczy*. Seminarium naukowo–techniczne Opalenica–Poznań, 20–22 wrzesień 2017, 175–211.
- Dąbek L., Szelaż B., Picheta – Oleś A. (2017): *Assessment of the possibility of using data mining methods to predict sorption isotherms of selected organic compounds on activated carbon*. E3S Web of Conferences 22, 00174 (2017).
- Dellana S.A., West D. (2009): *Predictive modeling for wastewater applications: Linear and nonlinear approaches*. Environmental Modelling & Software, 24, 96–106.
- Devisscher M., Ciacci G., Fe L., Benedetti L., Bixio D., Thoeye C., Gueldre G., Marsili-Libelli S., Vanrolleghem P.A. (2006): *Estimating costs and benefits of advanced control for wastewater treatment plants – the MAgIC methodology*. Water Science and Technology, 53, 215–223.
- Dogan E., Ates A., Yilmaz E.C., Eren B. (2008): *Application of Artificial Neural Networks to Estimate Wastewater Treatment Plant Inlet Biochemical Oxygen Demand*. Environmental Progress, 27, 439–446.
- Djeddou M., Achour B. (2015): *The use of a neural network technique for the prediction of sludge volume index in municipal wastewater treatment plant*. Larhyss Journal, 24, 351-370.
- Drewnowski J., Zmarzły M. (2017): *The use of mathematical models for diagnosis of activated sludge systems in WWTP*. E3S Web of Conferences 22, 00037 (2017).
- Ebrahimi M., Gerber E.L., Rockaway T.D. (2017): *Temporal performance assessment of wastewater treatment plants by using multivariate statistical analysis*. Journal of Environmental Management, 193, 234-246.
- Eisenberge D., Soller J., Sakaji R., Olivier A. (2001): *Methodology to evaluate water and wastewater treatment plant reliability*. Water Science and Technology, 43, 91-99.
- El-Din A.G., Smith D.W. (2002): *Modelling approach for high flow rate in wastewater treatment operation*. Journal of Environmental Engineering Science, 1, 275–291.
- Ellis G.W., Grasso D., Ge X. (1993): *ARMA Processes and Reliability-Based Design of Wastewater-Treatment Facilities*. Journal of Environmental Engineering, 119, 463-477.
- Fallah-Mehdipour E., Bozorg Haddad O., Mariño M.A. (2013): *Prediction and simulation of monthly groundwater level by Genetic Programming*. Journal of Hydro-environment Research, 7, 253–260.
- Fernandes J.A., Irigoien X., Boyra G., Lozano J.A., Inza I. (2008): *Optimizing the number of classes in automated zooplankton classification*. Journal of Plankton Research, 31, 19–29.

- Fernandez F.J., Seco A., Ferrer J., Rodrigo M.A. (2009): *Use of neurofuzzy networks to improve wastewater flow-rate forecasting*. Environmental Modelling & Software, 24, 686–693.
- Fiałkowska E., Fyda J., Pajdak-Stós A., Wiąckowski K. (2010): *Osad czynny. Biologia i analiza mikroskopowa*. Wyd. Seidel-Przywecki, Warszawa 2010.
- Friedman J.H. (2001): *Greedę function approximation: A gradient boosting machine*. The Annals of Statistics, 29, 1189–1232.
- Friedman J.H. (2002): *Stochastic gradient boosting*. Computational Statistics and Data Analysis, 38, 367–378.
- Garcia H.L., Gonzáles I.M. (2004), *Self-organizing map and clustering for wastewater treatment monitoring*. Engineering Applications of Artificial Intelligence, 17, 215–225.
- Gernaey K.V., Mussati M., Yuan Z., Nielsen M.K., Jørgensen S.B. (2002): *Control strategy evaluation for combined N and P removal using a benchmark wastewater treatment plant*. 15th Triennial World Congress, Barcelona, Spain, 1–6.
- Gernaey K.V., Alsina X.F., Rosen Ch., Benedetti L., Jeppsson U. (2011): *Dynamic influent pollutant disturbance scenario generation using a phenomenological modelling approach*. Environmental Modelling & Software, 26, 1255–1267.
- Grochowski M., Brdýs M.A., Gminski T. (2004): *Intelligent control structure for control integrated wastewater systems*. IFAC Large Scale Systems: Theory and Applications, Osaka, Japan, 2004, 245 – 250.
- Gyeongdong B., Seong-Pyo C., Sudaе K., Yejin K., Hyosoo K., Changwon K., Sungshin K. (2012): *Modular Neural Networks Prediction Model Based A2/O Process Control System*. International Journal of Precision Engineering and Manufacturing, 13, 905–913.
- Güçlü D., Dursun Ş. (2010): *Artificial neural network modelling of a large-scale wastewater treatment plant operation*. Bioprocess and Biosystems Engineering, 33, 1051–1058.
- Haimi H., Mulas M., Corona F., Marsili-Libelli S., Lindell P., Heinonen M., Vahala R. (2016): *Adaptive data-derived anomaly detection in the activated sludge process of a large-scale wastewater treatment plant*. Engineering Applications of Artificial Intelligence, 52, 65–80.
- Han H.G., Qiao J.F. (2012): *Prediction of activated sludge bulking based on a self-organizing RBF neural network*. Journal of Process Control, 22, 1103–1112.
- Han H.G., Qiao J.F. (2013): *Hierarchical Neural Network Modeling Approach to Predict Sludge Volume Index of Wastewater Treatment Process*. IEEE Transactions on Control Systems Technology, 21, 2423–2431.
- Han H., Li Y., Qiao J. (2014): *A fuzzy neural network approach for online fault detection in wastewater treatment process*. Computers & Electrical Engineering, 40, 2216–2226.

- Han H.G., Li Y., Guo Y.N., Qiao J.F. (2016): *A soft computing method to predict sludge volume index based on a recurrent self-organizing neural network*. Applied Soft Computing, 38(C), 477-486.
- Han H., Chen Z.Y., Qiao J., Zhang H. (2016): *Soft-sensor method for effluent ammonia nitrogen based on interval type-2 fuzzy neural networks*. 36th Chinese Control Conference (CCC), 26–28 lipiec 2017, 120–126.
- Häck M., Köhne M. (1996): *Estimation of wastewater process parameters using neural networks*. Water Science and Technology, 33, 101-115.
- Hecht-Nielsen R. (1987): *Kolmogorov's mapping neural network existence theorem*. In Proceedings of the 1st IEEE International Joint Conference of Neural Networks, 3, 11–14, New York, NY, USA, 1987.
- Heddad S., Lamda H., Filali S. (2016): *Predicting effluent Biochemical Oxygen Demand in a wastewater treatment plant using Generalized Regression Neural Network based approach: a comparative study*. Environmental Processes, 3, 153–165.
- Helling C., Schellen A.A.J.C., Mulder J.W., Loosdrecht M.C.M., Heijnen J.J. (1998): *The sharon process: An innovative method for nitrogen removal from ammonium-rich waste water*. Water Science and Technology, 37, 135-142.
- Henze M., Gujer W., Mino T., Matsuo T., Wentzel M.C., Marais G.V.R., Loosdrecht M.C.M. (1999): *Activated Sludge Model No 2d*. Water Science and Technology, 39, 165–182.
- Henze M., Harremoës P., Jansen J., Arvin E. (2002): *Wastewater Treatment, Biological and Chemical Processes*. Springer-Verlag Berlin Heidelberg.
- Hoef J.M., Temesgen H., Gómez S. (2013): *A Comparison of the Spatial Linear Model to Nearest Neighbor (k-NN) Methods for Forestry Applications*. PLoS ONE, 8, 1–13.
- Hong Y.S., Bhamidimarri R. (2003): *Evolutionary self-organising modelling of a municipal wastewater treatment plant*. Water Research, 37, 1199–1212.
- Hong Y.S.T., Paik B.C. (2007): *Evolutionary Multivariate Dynamic Process Model Induction for a Biological Nutrient Removal Process*. Journal of Environmental Engineering, 133, 1–10.
- Hongbin L., Mingzhi H., ChangKyoo Y. (2014): *A fuzzy neural network-based soft sensor for modeling nutrient removal mechanism in a full-scale wastewater treatment system*. Desalination and Water Treatment, 51, 6184–6193.
- Huo J.S., Seaver W.L., Robinson R.B., Cox Ch.D. (2005): *Application of Time Series Models to Analyze and Forecast the Influent Components of Wastewater Treatment Plants (WWTPs)*. World Water and Environmental Resources Congress 2005, 1–5.
- Iacopozzi I., Innocenti V., Marsili-Libelli S., Giusti E. (2007): *A modified Activated Sludge Model No. 3 (ASM3) with two-step nitrification – denitrification*. Environmental Modelling & Software, 22, 847-861.
- Ingildsen P., Rosen C., Gernaey K.V., Nielsen M.K., Guildal T., Jacobsen B.N. (2006): *Modelling and control strategy testing of biological and chemical phosphorus removal at Avedøre WWTP*. Water Science and Technology, 53, 105–113.

- Jami M.S., Mujeli M., Kabbashi N.A. (2011): *Simulation of ammoniacal nitrogen effluent using feedforward multilayer neural networks*. African Journal of Biotechnology, 10, 18755-18762.
- Janus T. (2014): *Integrated mathematical model of a MBR reactor including biopolymer kinetics and membrane fouling*. Procedia Engineering, 70, 882-891.
- Jenkins D., Richard M.G., Digger G.T. (2003): *Manual on the Caused and Control of Activated Sludge Bulking, Foaming and other Solids Separation Problems*. Lewis Publishers, New York, NY, USA.
- Jurasz J., Piasecki A. (2015): *Application of artificial neural networks in discharged wastewater volume forecasting case study Toruń*. Logistyka, 4, 9061-9066.
- Kaczor G. (2008): *Influence of air temperature on sewage temperature in sewerage system and in biological reactor*. Infrastructure and Ecology of Rural Areas, 3, 129-137.
- Khademikia S., Haghizadeh A., Godini H., Khorramabadi G.S. (2016): *Artificial Neural Network-Cuckoo Optimization Algorithm (ANN-COA) for Optimal Control of Khorramabad Wastewater Treatment Plant*. Iranian Civil Engineering Journal, 2, 555-567.
- Kiczko A., Szeląg B., Koziół A.P., Krukowski M., Kubrak E., Kubrak J., Romanowicz R.J. (2018): *Optimal Capacity of a Stormwater Reservoir for Flood Peak Reduction*. Journal of Hydrologic Engineering, 23, 1-9.
- Kim D., Bowen J.D., Ozelkan E.C. (2015): *Optimization of wastewater treatment plant operation for greenhouse gas mitigation*. Journal of Environmental Management, 163, 39-48.
- Kocev D., Dzeroski S., White M.D., Newell G.R., Griffioen P. (2009): *Using single- and multi-target regression trees and ensembles to model a compound index of vegetation condition*. Ecological Modelling, 220, 1159-1168.
- Koza J.R. (1992): *Genetic programming: on the programming of computers by natural selection*. MIT Press, Cambridge, MA, 1992.
- Kudłak B., Wiczerzak M., Yotova G., Tsakovski S., Simeonov V., Namieśnik J. (2016): *Environmental risk assessment of Polish wastewater treatment plant activity*. Chemosphere, 160, 181-188.
- Kundu P., Debsarkar A., Mukherjee S., Kumar ., (2014): *Artificial neural network modelling in biological removal of organic carbon and nitrogen for the treatment of slaughterhouse wastewater in a batch reactor*. Environmental Technology, 35, 1296-1306.
- Kusiak A., Zhang Z. (2010): *Short-horizon prediction of wind power: A Data-Driven Approach*. IEEE Transactions on Energy Conversion, 25, 1112-1122.
- Kusiak A., Verma A., Wei X. (2013): *A data-mining approach to predict influent quality*. Environmental Monitoring and Assessment, 185, 2197-2210.

- Kusiak A., Zeng Y., Zhang Z. (2013): *Modeling and analysis of pumps in a wastewater treatment plant: A data-mining approach*. Engineering Applications of Artificial Intelligence, 26, 1643–161.
- Kusiak A., Wei X. (2013): *Optimization of the Activated Sludge Process*. Journal of Energy Engineering, 139, 12–17.
- Kusiak A., Wei X. (2014): *Prediction of methane production in wastewater treatment facility: a data-mining approach*. Annals of Operations Research, 216, 71–81.
- Kuswanto H., Salamah M., Fachruddin M.I. (2017): *Random Forest Classification and Support Vector Machine for Detecting Epilepsy using Electroencephalograph Records*. American Journal of Applied Science, 14, 533–539.
- Lackner S., Gilbert E.M., Vlaeminck S.E., Joss A., Horn H., Loosdrecht M.C.M. (2014): *Full-scale partial nitrification/anammox experiences - An application survey*. Water Research, 55, 292–303.
- Langergraber G., Alex J., Weissenbacher N., Woener D., Ahnert M., Frehman T., Halft N., Hobus I., Plattes M., Spering V., Winkler S. (2008): *Generation of diurnal variation for influent data for dynamic simulation*. Water Science and Technology, 50, 131-138.
- Lawrence A.W., McCarty P.L., Fachruddin M.I. (1970): *Unified basis for biological treatment design and operation*. Journal of the Sanitary Engineering Division 96, 757–778.
- Lee D.S., Jeon C.O., Park J.M., Chang K.S. (2002): *Hybrid neural network modelling of a full - scale Industrial Wastewater Treatment Process*. Biotechnology and Bioengineering, 78, 670–682.
- Lee D.S., Vanrolleghem P.A., Park J.M. (2005): *Parallel hybrid modeling methods for a full-scale cokes wastewater treatment plant*. Journal of Biotechnology, 115, 317–328.
- Lee D.S., Lee M.W., Woo S.H., Kim Y.J., Park J.M. (2006): *Nonlinear dynamic partial least squares modeling of a full-scale biological wastewater treatment plant*. Process Biochemistry, 41, 2050–2057.
- Lee Y., Cho J., Seo Y., Lee J.W., Ahn K. (2002), *Modeling of submerged membrane bioreactor process for wastewater treatment*. Desalination, 146, 451–457.
- Lee H.W., Lee M.W., Park J.M. (2009): *Multi-scale extension of PLS algorithm for advanced on-line process monitoring*. Chemometrics and Intelligent Laboratory Systems, 98, 201-212.
- Lee S., Kim J.C., Jung H.S., Lee M.J., Lee S. (2017): *Spatial prediction of flood susceptibility using random-forest and boosted-tree models in Seoul metropolitan city, Korea*. Journal Geomatics, Natural Hazards and Risk, 8, 1185–1203.
- Li X.Z., Kong J.M. (2014): *Application of GA-SVM method with parameter optimization for landslide development prediction*. Natural Hazards and Earth System Sciences, 14, 525–533.

- Liu Y., Guo J., Wang Q., Huang D. (2016): *Prediction of Filamentous Sludge Bulking using a State-based Gaussian Processes Regression Model*. Scientific Reports, 6, 31303, 1-11.
- Lubos J., Kaletova T., Sedmakova M., Balazova P., Cervenanska A. (2017): *Comparison of service characteristics of two town's WWTP*. Journal of Ecological Engineering, 18, 61-67.
- Luccarini L., Porrá E., Spagni A., Ratini P., Grilli S., Longhi S., Bortone G. (2002): *Soft sensors for control of nitrogen and phosphorus removal from wastewaters by neural networks*. Water Science and Technology, 45, 101-107.
- Luo F., Yu R., Xu Y., Li Y. (2009): *Effluent quality prediction of wastewater treatment plant based on fuzzy-rough sets and artificial neural networks*. 6th International Conference on Fuzzy Systems and Knowledge Discovery, 47-51.
- Lou I., Zhao Y. (2012): *Sludge Bulking Prediction Using Principle Component Regression and Artificial Neural Network*. Mathematical Problem in Engineering, 2012, 1-17.
- Łapczyński M. (2010): *Drzewa klasyfikacyjne i regresyjne w badaniach marketingowych*. Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie, Kraków 2010.
- Łomotowski J., Szpindor A. (1999): *Nowoczesne systemy oczyszczania ścieków*. Wydawnictwo Arkady, Warszawa 1999.
- Ma S., Zeng S., Dong X., Chen J., Olsson G. (2013): *Short-term prediction of influent flow rate and ammonia concentration in municipal wastewater treatment plants*. Frontiers of Environmental Science & Engineering, 8, 128-136.
- Maachou R., Lefkir A., Merabtene T., Hamriche A., Bermad A. (2017): *Contribution to optimize decision parameters in activated-sludge process using ANFIS model*. MATEC Web of Conferences 120, 05001, ASCMCES-17, 1-8.
- Manu D.S., Thalla A.K. (2017): *Artificial intelligence models for predicting the performance of biological wastewater treatment plant in the removal of Kjeldahl Nitrogen from wastewater*. Applied Water Science, 7, 3783-3791.
- Martin C., Vanrolleghem P.A. (2014): *Analysing, completing, and generating influent data for WWTP modelling: A critical review*. Environmental Modelling & Software, 60, 188-201.
- Martins A.M.P., Heijnen J.J., Loosdrecht M.C.M. (2004): *Bulking sludge in biological nutrient removal systems*, Biotechnology and Bioengineering, 86, 25-135.
- Martins A.M.P., Pagilla K.R., Heijnen J.J., Loosdrecht M.C.M. (2004): *Bulking filamentous sludge - a critical review*. Water Research, 38, 793-817.
- Martins A.M.P., Picioreanu C., Heijnen J.J., Loosdrecht M.C.M. (2004): *Three-Dimensional Dual-Morphotype Species Modeling of Activated Sludge Flocs*. Environmental Science & Technology, 38, 5632-5641.
- Mąkinia J. (2010): *Mathematical Modelling and Computer Simulation of Activated Sludge Systems*. IWA Publishing, London.

- Messaoud D., Bachir A., Maurice M. (2013): *Determination and analysis of daily reliability level of municipal wastewater treatment plant*. Courier du Savoir, 17, 39-46.
- Minsoo K., Yejin K., Hyosoo K., Wenhua P., Changwon K. (2016): *Operator decision support system for integrated wastewater management including wastewater treatment plants and receiving water bodies*. Environmental Science and Pollution Research, 23, 10785–10798.
- Minsoo K., Yejin K., Hyosoo K., Wenhua P., Changwon K. (2016): *Evaluation of the k-nearest neighbor method for forecasting the influent characteristics of wastewater treatment plant*. Frontiers of Environmental Science & Engineering, 10, 299–310.
- Mirbagheri S.A., Bagheri M., Ehteshami M., Bagheri Z., Poursaghar M. (2015): *Modeling of mixed liquor volatile suspended solids and performance evaluation for sequencing batch reactor*. Journal of Urban and Environmental Engineering, 9, 54-65.
- Mirbagheri S.A., Bagheri M., Boudaghpour S., Ehteshami M., Bagheri Z. (2015): *Performance evaluation and modeling of a submerged membrane bioreactor treating combined municipal and industrial wastewater using radial basis function artificial neural networks*. Journal of Environmental Health Science & Engineering, 13, 13–17.
- Mulas M., Tronci S., Corona F., Haimi H., Lindell P., Heinonen M., Vahala R., Baratti R. (2015): *Predictive control of an activated sludge process: An application to the Viikinmäki wastewater treatment plant*. Journal of Process Control, 35(C), 89–100.
- Mulas M., Corona F., Sirviö J., Hyvönen S., Vahala R. (2016): *Full-scale implementation of an advanced control system on a biological wastewater treatment plant*. IFAC-PapersOnLine, 49-7, 1163–1168.
- Mulder A. (2003): *The quest for sustainable nitrogen removal technologies*. Water Science and Technology, 48, 67-75.
- Nawar S., Mouazen A.M. (2017): *Comparison between Random Forests, Artificial Neural Networks and Gradient Boosted Machines Methods of On-Line Vis-NIR Spectroscopy Measurements of Soil Total Nitrogen and Total Carbon*. Sensors, 17, 2–22.
- Nguyen D.H., Latifi M.A., Lesage F., Mulholland M. (2013): *Dynamic simulation and optimization of wastewater treatment plants*. 2013 International Conference on Process Control (PC) June 18–21, 2013, Štrbské Pleso, Slovakia, 407–414.
- Nielsen P.H., Kragelund C., Seviour R.J., Nielsen J.L., *Identity and ecophysiology of filamentous bacteria in activated sludge*. FEMS Microbiology Reviews, 33, 969–998.
- Niku S., Schroeder E.D., Tchobanous G., Samaniego F.J. (1981): *Performance of activated sludge process: reliability, stability and variability*. Environmental Protection Agency, EPA Grant No, R805097-01, 124p.

- Nitze U., Schulthess U., Asche H. (2012): *Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised cro type classification*. Proceedings of the 4th GEOBIA, May 7-9, 2012, Rio de Janeiro, Brazil, 35–40.
- Noi P.T., Kappas M. (2017): *Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery*. Sensors (Basel) 2018, 18, 2–20.
- Ogutu J.O., Piepho H.P., Streeck T.S. (2011): *A comparison of random forests, boosting and support vector machines for genomic selection*. BMC Proceedings 2011, 5(Suppl 3):S11.
- Olivera S.C., Sperling M. (2008): *Reliability analysis of wastewater treatment plants*. Water Research, 42, 1182-1194.
- Ossowski S. (2013): *Neural Networks for information processing*. Publishing House of the Warsaw University of Technology, Warszawa 2013.
- Ozkan O., Ozdemir O., Azin S.T. (2009): *Prediction of Biochemical Oxygen Demand in a wastewater treatment plant by Artificial Neural Networks*. Asian Journal of Chemistry, 21, 4821-4830.
- Pai T.Y., Tsai Y.P., Lo H.M., Tsai C.H., Lin C.Y. (2005): *Grey and neural network prediction of suspended solids and chemical oxygen demand in hospital wastewater treatment plant effluent*. Computers and Chemical Engineering, 31, 1272–1281.
- Pai T.Y., Yang P.Y., Wang S.C., Lo M.H., Chiang C.F., Kuo J.L., Chu H.H., Su H.C., Yu L.F., Hu H.C., Chang Y.H. (2011), *Predicting effluent from the wastewater treatment plant of industrial park based on fuzzy network and influent quality*. Applied Mathematical Modelling, 35, 3674–3684.
- Pawlowski, C.W., Rhea, L., Shuster, W.D., Barden, G. (2014). *Some factors affecting inflow and infiltration from residential sources in a core urban area: Case study in Columbus, Ohio, neighborhood*. Journal of Hydraulic Engineering, 140, 105-114.
- Pijáková I., Derco J. (2013): *The assessment of potential operation of wastewater treatment plant by dynamic simulations*. Acta Chimica Slovaca, 6, 20—24.
- Ping Y.U. (2015): *Multi-model modeling and its application of urban sewage treatment based on clustering analysis*. 2015 Global Conference on Polymer and Composite Materials (PCM 2015), IOP Conf, Series: Materials Science and Engineering 87, 012-029.
- Poutiainen H., Niska H., Heinonen H.T., Kolehmainen M. (2010): *Use of sewer on-line total solids data in wastewater treatment plant modelling*. Water Science and Technology, 62, 743-750.
- Qiao J., Chen Q., Han H. (2011): *The Chemical Oxygen Demand Modelling Based on a Dynamic Structure Neural Network*. In: F, Sebastián, G, Einschlag (Editors), Waste Water- Evaluation and Management, 93–114.
- Qiao J., Yang W. (2011): *Recurrent High Order Neural Network Modeling for Wastewater Treatment Process*. Journal of Computers, 8, 1570–1577.

- Qiao J., Hu Z., Li W. (2016): *Soft Measurement Modeling Based on Chaos Theory for Biochemical Oxygen Demand (BOD)*. Water, 8, 581, 2–21.
- Rak J. (2004): *Istota ryzyka w funkcjonowaniu systemu zaopatrzenia w wodę*. Oficyna Wydawnicza Politechniki Rzeszowskiej, Rzeszów 2004.
- Rak J., Tchórzewska-Cieślak B. (2009): *O bezpieczeństwie zaopatrzenia w wodę*. Monografie Komitetu Inżynierii Środowiska PAN, vol. 59, tom 2, s.171-178.
- Rak J., Tchórzewska-Cieślak B. (2006): *Five – parametric matrix to estimate risk connected with water supply system operating*. Environment Protection Engineering, 2, 37-47.
- Rak J. (2008). *Methods of reliability index determination concerning municipal water quality*. Journal of KONBiN, 5(2), 157 – 173.
- Rak J., Tchórzewska-Cieślak B. (2013). *Ryzyko w eksploatacji systemów zbiorowego zaopatrzenia w wodę*. Wydawnictwo Scidel Przywecki, Warszawa 2013.
- Raduly B., Gemaey K.V., Capodaglio A.G., Mikkelsen P.S., Henze M. (2007): *Artificial neural networks for rapid WWTP performance evaluation: Methodology and case study*. Environmental Modelling & Software, 22, 1208-1216.
- Rene E.R., Saidutta M.B. (2008): *Prediction of Water Quality Indices by Regression Analysis and Artificial Neural Networks*. International Journal of Environmental Research, 2, 183-188.
- Rezania M., Javadi A. (2007): *A new genetic programming model for predicting settlement of shallow foundations*. Canadian Geotechnical Journal, 44, 1462-1473.
- Ribeiro D., Sanfins A., Belo O. (2013): *Wastewater treatment plant performance prediction with support vector machines*. In: *Industrial Conference on Data Mining*. In: P. Perner (Editor), *Proceedings of the 13th international conference on Advance in Data mining: applications and theoretical aspects*, New York 2013, 99–111.
- Roche N., Vaxelaire J., Prost C. (1995): *A simple empirical model for hindered settling in activated sludge clarifier*. Water Environment Research, 67, 775-780.
- Rodríguez J.P., McIntyre N., Díaz-Granados M., Achleitner S., Hochedlinger M., Maksimović C. (2013): *Generating time-series of dry weather loads to sewers*, Environmental Modelling & Software, 43, 133-143.
- Rogers L.L., Dowla F.U. (1994): *Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling*. Water Resources Research, 30, 457–481.
- Romanowicz R.J., Kiczko A., Napiórkowski J.J. (2010): *Stochastic transfer function model applied to combined reservoir management and flow routing*. Hydrological Sciences Journal, 55, 27–40.
- Romanowicz R.J., Osuch M. (2015): *Stochastic Flood Forecasting System: The Middle River Vistula Case Study*. Springer Verlag, New York, 2015.
- Rosen Ch., Yuan Z. (2001): *Supervisory control of wastewater treatment plants by combining principal component analysis and fuzzy c-means clustering*. Water Science and Technology, 43, 147-156.

- Rosenblatt F. (1958): *The perceptron: A probabilistic model for information storage and optimization in the brain*. Psychological Review, 65, 386 - 408.
- Rousseau D., Verdancq F., Moerman D., Carrette R., Thoeye C., Meirlaen J., Venrolleghem P.A. (2001): *Development of a risk assessment based technique for design/retrofitting WWTP*. Water Science & Technology, 43, 287–294.
- Rössle W.H., Pretorius W.A. (2008): *Batch and automated SVI measurements based on short-term temperature variations*. Water SA, 34, 237–243.
- Rustum R., Adeloje A., Simala A. (2007): *Kohonen self-organising map (KSOM) extracted features for enhancing MLP-ANN prediction models of BOD₅*. Water Quality and Sediment Behaviour of the Future: Predictions for the 21st Century (Proceedings of Symposium HS2005 at IUGG2007, Perugia, July 2007), IAHS Publ, 314.
- Rustum R. (2009): *Modelling Activated Sludge Wastewater Treatment Plants Using Artificial Intelligence Techniques (Fuzzy Logic and Neural Networks)*. PhD Thesis, Heriot, 2009.
- Salpasaranis K., Stylianakis V. (2017): *Forecasting the OECD fixed broadband penetration with genetic programming method, diffusion models and macro-economic indicators*. Image Processing & Communications, 21, 47-56.
- Sant´ın I. (2015): *Effluent predictions in wastewater treatment plants for the control strategies selection*. Actas de las XXXVI Jornadas de Automática, 2 - 4 de septiembre de 2015, Bilbao, 1009–1016.
- Sarkar M., Leong T.Y. (2000): *Application of K-nearest neighbors algorithm on breast cancer diagnosis problem*. AMIA Annual Symposium Proceedings of Archive, 759–763.
- Sathyamoorthy S., Chandran K., Ramsburg C.A. (2013): *Biodegradation and cometabolic modeling of selected beta blockers during ammonia oxidation*. Environmental Science & Technology, 47, 12835–12843.
- Sánchez M., Cortés U., Béjar J., Gracia J.De., Lafuente J., Poch M. (1997): *Concept Formation in WWTP by Means of Classification Techniques: A Compared Study*. Applied Intelligence, 7, 147–165.
- Schmidt L., Sliemers O., Schmid M., Bock E., Gijs Kuenen J., Jetten M.S.M., Strous M. (2003): *New concepts of microbiological treatment processes for nitrogen removal in wastewater*. Microbiology Review, 772, 1 – 12.
- Seggelke K., Rosenwinkel K.H., Vanrolleghem P.A., Krebs P. (2005): *Integrated operation of sewer system and WWTP by simulation-based control of the WWTP inflow*. Water Science and Technology, 5, 195–203.
- Setti S.G., Rao R.N. (2014): *Artificial neural network approach for prediction of stress-strain curve of near b titanium alloy*. Rare Metals, 33, 249–257.
- Sezgin M., Jenkins D., Parker D.S. (1978): *A unified theory of filamentous activated sludge bulking*. Journal (Water Pollution Control Federation), 50, 362–381.

- Shahin M. (2015): *Genetic programming for modelling of geotechnical engineering systems*. In: Handbook of Genetic Programming Applications, A, H, Gandomi, A, H, Alavi and C, Ryan (eds.), 37-57, Springer Verlag Heidelberg.
- Shoumy N.J., Yaakob S.N., Ehkan P., Ali M.S., Khatun S. (2016): *Cascade-forward neural network performance study for bloodstain image analysis*. 3rd International Conference on Electronic Design (ICED).
- Singh N.K., Kazmi A.A. (2018): *Performance and Cost Analysis of Decentralized Wastewater Treatment Plants in Northern India: Case Study*. Journal of Water Resources Planning and Management, 144, 1–12.
- Siwek K., Osowski S. (2016): *Data mining methods for prediction of air pollution*. International Journal of Applied Mathematics and Computer Science, 26, 467–478.
- Snip L.J.P., Alsina X.F., Gy Plósz B., Jeppsson U., Gernaey K.V. (2014): *Modelling the occurrence, transport and fate of pharmaceuticals in wastewater systems*. Environmental Modelling & Software, 62, 1-16.
- Sobota J., Szetela R. (2005): *Jednowymiarowe modele natężenia i jakości ścieków dopływających do oczyszczalni komunalnych*. Ochrona Środowiska, 27, 15-22.
- Sobota J., Szetela R. (2006): *Tworzenie szeregów czasowych natężenia dopływu i parametrów jakości ścieków na potrzeby symulacji pracy oczyszczalni komunalnych*. Ochrona Środowiska, 28, 39–46.
- Studziński J. (2004): *Identyfikacja, symulacja i sterowanie oczyszczalniami ścieków*. Badania Systemowe, Warszawa 2004, Monografia Instytutu Badań Systemowych PAN.
- Sweetapple C.G. (2014): *Developing Strategies for the Reduction of Greenhouse Gas Emissions from Wastewater Treatment*. Ph, D, Thesis, Exeter University.
- Szeląg B., Barbusiński K., Studziński J. (2018a): *Activated sludge process modelling using selected machine learning techniques*. Desalination and Water Treatment, 1–10.
- Szeląg B., Barbusiński K., Studziński J., Bartkiewicz L. (2017c): *Prediction of wastewater quality indicators at the inflow to the wastewater treatment plant using data mining methods*. E3S Web of Conferences 22, 00174 (2017).
- Szeląg B., Bartkiewicz L., Studziński J., Barbusiński K. (2017): *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, 43, 74–81.
- Szeląg B., Gawdzik J. (2017a): *Assessment of the effect of wastewater quantity and quality, and sludge parameters on predictive abilities of non-linear models for activated sludge settleability predictions*. Polish Journal of Environmental Studies, 26, 315–322.
- Szeląg B., Gawdzik J. (2017b): *Application of Selected Methods of Artificial Intelligence to Activated Sludge Settleability Predictions*. Polish Journal of Environmental Studies, 25, 1709-1714.

- Szeląg B., Gawdzik J., Studziński J. (2018b). *Sludge Volume Index (SVI) Modelling: Data Mining Approach*. Z. Wilimowska et al. (eds.), Information Systems Architecture and Technology: Proceedings of 38th International Conference on Information Systems Architecture and Technology – ISAT 2017, Advances in Intelligent Systems and Computing 657, 324 – 335.
- Szeląg B., Kiczko A., Studziński J., Dąbek L. (2018c): *Hydrodynamic and probabilistic modelling of storm overflow discharges*. Journal of Hydroinformatics, Vol. 20, No. 5, 1100 – 1110.
- Szeląg B., Kiczko A., Dąbek L. (2016): *Analiza wrażliwości i niepewności modelu hydrodynamicznego (SWMM) do prognozowania odpływu wód opadowych ze zlewni zurbanizowanej studium przypadku*. Ochrona Środowiska, 38, 15–22.
- Szeląg B., Siwicki P. (2017): *Application of the selected classification models to the analysis of the settling capacity of the activated sludge – case study*. In: B. Kaźmierczak, M. Kutylowska, K. Piekarska, A. Trusz-Zdybek, E3S Web of Conferences 17, Boduszów-Gorce 2017, 1–7.
- Szeląg B., Studziński J. (2017): *A data mining approach to the prediction of food-to-mass ratio and mixed liquor suspended solids*. Polish Journal of Environmental Studies, 26, 2231-2238.
- Szeląg B., Studziński J. (2018). *Modelling and Forecasting the Sludge Bulking in Biological Reactors of Wastewater Treatment Plants by Means of Data Mining Methods*. 296 – 305, Proceedings of the First International Conference on Intelligent Systems in Production Engineering and Maintenance ISPEM 2017, 296 – 305.
- Szeląg B., Studziński J., Barbusiński K. (2018d). *Application of the model of sludge volume index forecasting to assess reliability and improvement of wastewater treatment plant operating conditions*. Desalination and Water Treatment (w druku).
- Szetela R., Dymaczeński Z. (2002): *Modyfikacja obecnej postaci modelu osadu czynnego ASM2d*. Ochrona Środowiska, 1, 3–8.
- Taheriyoun M., Moradinejad S. (2015): *Reliability analysis of a wastewater treatment plant using fault tree analysis and Monte Carlo simulation*. Environmental Monitoring and Assessment, 187, 1-13.
- Thiery F., Grieu S., Traore A., Esteben M., Polit M. (2005): *Neural networks for estimating the efficiency of a WWTP biologic treatment*. In: Software Engineering: Evolution and Emerging Technologies.(red. K. Zieliński, T. Szmuc), IOS Press, Amsterdam, 25–33.
- Thunberg A., Sundin A.M., Carlsson B. (2009): *Energy optimization of the aeration process at Käppala wastewater treatment plant*. 10th IWA Conference on Instrumentation, Control & Automation.
- Tian Z.X., Jiang J.P., Guo L., Wang P. (2012): *Anomaly detection of Municipal Wastewater Treatment Plant operation using Support Vector Machine*. International Conference on Automatic Control and Artificial Intelligence (ACAI 2012).

- Tomczak E., Kaminski W. (2012): *Application of ANN to the Sorption Equilibrium Modelling of Heavy Metal Ions on Clinoptilolite*. Ecological Chemistry and Engineering S, 19, 227-237.
- Tran D.H., Ng A.W.M., Perera B.J.C., Burn S., Davis P. (2007): *Application of probabilistic neural networks in modelling structural deterioration of stormwater pipes*. Urban Water Journal 3, 175-184.
- Tomita R.K., Sotomayor O.A.Z., Park S.W., Tisza-Contreras J.F. (2007): *Multiobjective optimization of an upflow anaerobic sludge blanket reactor*. Revista Peruana de Química e Ingeniería Química, 10, 39-49.
- Traczewska T. (1997): *Biotyczne i abiotyczne uwarunkowania pęcznienia osadu czynnego*. Ochrona środowiska, 2, 29-32.
- Tümer A.E., Edebali S. (2015): *An Artificial Neural Network Model for Wastewater Treatment Plant of Konya*. Intelligent Systems and Applications in Engineering, 3, 131-135.
- Van Hulle S.W.H. (2005): *Modelling, simulation and optimization of autotrophic nitrogen removal processes*. PhD Thesis, University of Gent.
- Vapnik V. (1998): *Statistical Learning Theory*. John Wiley and Sons, New York, 1998.
- Venkadesh S., Hoogenboom G, Potter W., McClendon R. (2013): *A genetic algorithm to refine input data selection for air temperature prediction using artificial neural networks*. Applied Soft Computing, 13, 2253-2260.
- Verma A., Wei X., Kusiak A. (2012): *Predicting the total suspended solids in wastewater: A data-mining approach*. Engineering Applications of Artificial Intelligence, 26, 1366-1372.
- Vojinovic Z., Kecman V., Babovic V. (2003): *Hybrid approach for modeling wet weather response in wastewater systems*. Journal of Water Resources Planning and Management, 129, 511-521.
- Vrecko D., Gernaey K.V., Rosen C., Jeppsson U. (2006): *Benchmark Simulation Model No 2 in Matlab-Simulink: towards plant-wide WWTP control strategy evaluation*. Water Science and Technology, 54, 65-72.
- Wan T.J., Chen Ch.H., Chang Y.S., Chen J.C. (2000): *An application of artificial neuromolecular system for effluent quality prediction of wastewater treatment plant*. Journal of Chinese Institute of Environmental Engineering, 10, 155-162.
- Wei X., Kusiak A. (2012): *Optimization of Biogas Production Process in a Wastewater Treatment Plant*. Proceedings of the 2012 Industrial and Systems Engineering Research Conference, 1-9.
- Wei X., Kusiak A., Sadat H.R. (2013): *Prediction of Influent Flow Rate: Data-Mining Approach*. Journal of Energy Engineering, 139, 118-123
- Weiß, G., Brombach, H., Haller, B. (2002). *Infiltration and inflow in combined sewer systems: longterm analysis*. Water Science & Technology, Vol. 45, p. 227-230.

- Wett B., Podmirseg S.M., Gomez-Brand M., Hell M., Nyhuis G., Bott C., Murthy S. (2015): *Expanding DEMON Sidestream Deammonification Technology Towards Mainstream Application*. Water Environment Research, 87, 2084–2089.
- Wintgens T., Rosen J., Melin T., Brepols C., Drensla K., Engelhardt N. (2003): *Modeling of a membrane bioreactor system for municipal wastewater treatment*. Journal of Membrane Science, 216, 55-6.
- Woo S.H., Jeon C.O., Yun Y.S., Choi H., Lee C.S., Lee D.S. (2009): *On-line estimation of key process variables based on kernel partial least squares in an industrial cokes wastewater treatment plant*. Journal of Hazardous Materials, 161, 538–544.
- Xie W.M., Zhang R., Li W.W., Ni B.J., Fang F., Sheng G.P., Yu H.Q., Song J., Le D.Z., Bi X.J., Liu Ch.Q., Yang M. (2011): *Simulation and optimization of a full-scale Carrousel oxidation ditch plant for municipal wastewater treatment*. Biochemical Engineering Journal, 56, 9-16
- Yang J.H., Cheng Ch.H., Chan Ch.P. (2017): *A Time-Series Water Level Forecasting Model Based on Imputation and Variable Selection Method*. Computational Intelligence and Neuroscience, 2017, Article ID 8734214, 1-11.
- Yasmin N.S.A., Gaya M.S., Wahab N.A., Sam Y.M. (2017): *Estimation of pH and MLSS using neural network*. Telkomnika, 15, 912–918.
- Yetilmmezsoy K., Ozkaya B., Cakmakci M. (2011): *Artificial intelligence-based prediction models for environmental engineering*. Neural Network World, 3, 193-218.
- Yoo C.K., Bang Y.H., Lee B., Vanrolleghem P.A., Rosén Ch. (2004): *Application of Fuzzy Partial Least Squares (FPLS) Modeling Nonlinear Biological Processes*. Korean Journal of Chemical Engineering, 21, 1087-1097.
- Zhang R., Xie W.M., Yu H.Q., Li W.W. (2014): *Optimizing municipal wastewater treatment plants using an improved multi-objective optimization method*. Bioresource Technology, 157, 161–165.
- Zhang M., Jing H., Liu Y., Shi H. (2017): *Estimation and optimization operation in dealing with inflow and infiltration of a hybrid sewerage system in limited infrastructure facility data*. Frontiers of Environmental Science & Engineering, 11, 1–11.
- Zhao Y., Guo L., Liang J., Zhang M. (2014): *Seasonal artificial neural network model for water quality prediction via a clustering analysis method in a wastewater treatment plant of China*. Desalination and Water Treatment, 57, 3452–3465.
- Zhao G., Liu J., Jiang J., Wang W. (2017): *A deep cascade of neural networks for image inpainting, deblurring and denoising*. Multimedia Tools and Application, 1–16.
- Zhu J.J., Kang L., Anderson P.R. (2018): *Predicting influent biochemical oxygen demand: Balancing energy demand and risk management*. Water Research, 128, 304-313.

ISSN 0208-8029
ISBN 978-83-89475-62-6

**INSTYTUT BADAŃ SYSTEMOWYCH
POLSKIEJ AKADEMII NAUK**
tel.: (+48) 22 3810246 / 22 3810277 / 22 3810241 / 22 3810273
e-mail: biblioteka@ibspan.waw.pl