



POLSKA AKADEMIA NAUK
Instytut Badań Systemowych

BADANIA SYSTEMOWE

Tom 76

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

Bartosz Szeląg

Warszawa 2019

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



**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

Bartosz Szelaĝ

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

Warszawa 2019

Copyright © by Instytut Badań Systemowych PAN
Warszawa 2019

Autor:

Dr inż. Bartosz Szelaĝ
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 biogennych 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.

8. Optymalizacja i sterowanie pracy bioreaktora

Zapewnienie odpowiednich wymagań w zakresie jakości ścieków na wylocie z oczyszczalni jest złożonym zadaniem, wymagającym utrzymania w odpowiednim zakresie parametrów działania bioreaktora. Obecnie większość prac dotyczących tego problemu polega przede wszystkim na takim doborze wartości parametrów w reaktorze, aby uzyskać nie mniejszy niż założony stopień redukcji zanieczyszczeń na odpływie z oczyszczalni ścieków. Tak pojęta optymalizacja działania reaktora biologicznego ma na celu opracowanie typowych sposobów postępowania w przypadku dopływu do oczyszczalni standardowej ilości ścieków i standardowego ładunku zanieczyszczeń. Jednak, bardzo często należy się liczyć z sytuacjami nietypowymi, w czasie których ma miejsce gwałtowny wzrost ilości ścieków na dopływie oraz spadek lub wzrost wartości wskaźników jakości ścieków surowych. Zdarzenia te w istotny sposób mogą zaburzyć działanie bioreaktora, prowadząc do naruszenia równowagi między poszczególnymi grupami mikroorganizmów w osadzie czynnym. W związku z powyższym, poza wspomnianą optymalizacją, mającą istotne znaczenie na etapie projektowania reaktora, gdy ustala się warunki jego działania w trybie codziennej eksploatacji, bardzo istotne znaczenie ma sterowanie reaktorem, które zmienia jego nastawy w zależności od zmieniających się warunków zewnętrznych. Takie sterowanie jest gwarantem ciągłości procesów w bioreaktorze, mimo dopływu nietypowych ścieków do obiektu lub gwałtownego wzrostu ilości ścieków w przypadku intensywnych zdarzeń opadowych. Aby jednak móc opracować odpowiednie algorytmy sterowania, konieczna jest prognoza dopływających ścieków. Należy mieć na uwadze fakt, iż gdy w chwili t zostanie dokonana korekta jednego z parametrów działania reaktora, to rezultat będzie zauważalny dopiero po pewnym czasie z uwagi na bezwładność obiektu i kinetykę procesów zachodzących w bioreaktorze. Dlatego też, aby sterowanie istotnie wpływało na poprawę działania oczyszczalni, konieczna jest prognoza ilości i jakości dopływających ścieków z odpowiednio dużym wyprzedzeniem.

Obecnie na ogół wartości nastaw bioreaktora wyznacza się w oparciu o bieżące pomiary, co z uwagi na wymienione wyżej czynniki (kinetyka procesów, bezwładność reaktora) nie jest dobrym rozwiązaniem, gdyż powoduje duże

opóźnienia w reakcjach obiektu. Poprawniejszym podejściem byłoby prognozowanie nastaw reaktora w chwili $(t + 1)$ na podstawie pomiarów ilości i jakości ścieków surowych i oczyszczonych w chwili (t) oraz prognoz wartości tych zmiennych w chwili $(t + 1)$, co jest możliwe do wykonania za pomocą modeli parametrycznych (Studziński 2004). Problem polega na tym, że wykonywanie bieżących pomiarów jakości ścieków jest bardzo kosztowne.

Kolejny problem dotyczy wyboru parametrów reaktora, wartości których powinny być zmieniane. Obecnie większość prac koncentruje się na doborze wartości stężenia tlenu rozpuszczonego i stopnia recyrkulacji wewnętrznej i zewnętrznej tak, aby na odpływie uzyskać wartości wskaźników jakości ścieków nie większe, niż podane w odpowiednich aktach prawnych. Przy tym pomija się zupełnie sterowanie procesem sedymentacji osadu czynnego, podczas gdy jego przebieg wpływa na wartości wskaźników jakości ścieków na wylocie z oczyszczalni (Comas i in. 2008, Flores–Alsina i in. 2009). Wobec powyższego problem sterowania bioreaktorem uwzględniającym interakcję między jakością ścieków a sedymentacją osadu w układach z usuwaniem związków C, N i P pozostaje otwarty i zostanie on rozpatrzony w dalszym ciągu rozważań.

8.1. Optymalizacja i sterowanie pracy oczyszczalni w odniesieniu do sedymentacji osadu (model niezawodności)

Jednym z najczęściej stosowanych wskaźników do oceny funkcjonowania pracy oczyszczalni ścieków jest współczynnik niezawodności COR (Niku 1981), wyrażający stosunek stężenia badanego wskaźnika jakości ścieków na odpływie do wartości dopuszczalnej (Eisenberg i in. 2001, Olivera i Sperling 2008):

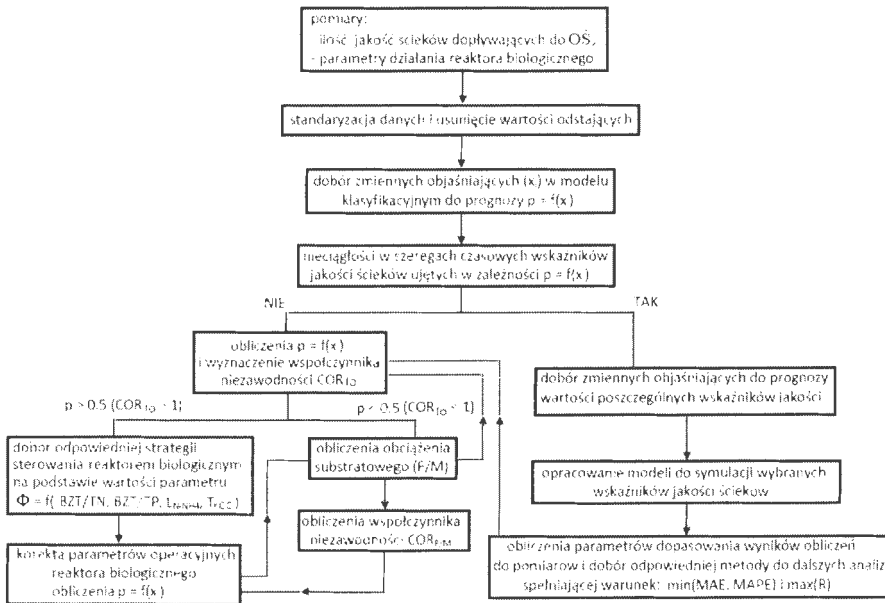
$$COR = \frac{C_{sr}}{C_{dop}} \quad (8.1)$$

gdzie: C_{sr} – średnie stężenie wybranego wskaźnika jakości ścieków na wylocie, C_{dop} – wartość dopuszczalna wskaźnika określona w Rozporządzeniu Ministra Środowiska z dnia 18 listopada 2014 r.

Na podstawie zależności (8.1) można stwierdzić, że gdy $COR < 1$, to oczyszczalnia działa poprawnie, natomiast gdy $COR > 1$, to występują w oczyszczalni problemy eksploatacyjne. Jednak współczynnik niezawodności ma istotną wadę, ponieważ stosowanie wartości średniej może prowadzić do niepoprawnych wniosków w odniesieniu do efektywności pracy oczyszczalni i uzyskanie wartości $COR < 1$ nie oznacza, że nie ma incydentalnych przekroczeń wartości wskaźników jakości ścieków oczyszczonych.

W związku z tym, w ramach prowadzonych analiz opracowano model do analizy niezawodności działania oczyszczalni, uwzględniający proces sedymentacji w osadniku wtórnym (występowanie lub brak puchnięcia osadu) oraz procesy

usuwania ze ścieków związków C, N i P (rys. 8.1). W modelu tym podstawę oceny zdolności sedymentacyjnych osadu czynnego stanowi objętościowy indeks osadu czynnego wyrażony za pomocą równania (7.4.1), oraz obciążenie substratowe osadu (Szeląg i in. 2018a, d). Obciążenie substratowe jest powszechnie stosowanym parametrem przy analizie działania oczyszczalni, pozwalającym ustalić, czy procesy usuwania zanieczyszczeń ze ścieków zachodzą poprawnie (Henze i in. 2002, Jenkins i in. 2003, Szeląg i Studziński 2017, Szeląg i in. 2018a).



Rys. 8.1. Algorytm wyznaczania modelu do symulacji i kontroli sedymentacji osadu czynnego.

W zaproponowanym modelu przyjęto, że podstawę analizy niezawodności działania oczyszczalni stanowią następujące współczynniki niezawodności:

$$COR_{I_0}(t) = \frac{p(t)}{p_{I_0,lim}} \quad (8.2)$$

$$COR_{F/M}(t) = \frac{F/M(t)}{F/M_{lim}} \quad (8.3)$$

gdzie: F/M_{lim} – wartość obciążenia substratowego, której przekroczenie prowadzi do problemów z usuwaniem związków C, N i P (w obliczeniach przyjęto $F/M_{lim} = 0,15 \cdot \text{gBZT}_5/\text{gX}_{oc} \cdot \text{d}$), $p_{I_0,lim}$ – prawdopodobieństwo przewyższenia wartości I_0 , której przekroczenie prowadzi do problemów z sedymentacją osadu;

w obliczeniach przyjęto $p_{I_0,lim} = 0,50$, co odpowiada kombinacji liniowej analizowanych zmiennych (x_i):

$$\alpha_0 + \alpha_1 \cdot T_{KOC} + \alpha_2 \cdot \frac{BZT_5}{N_{og}} + \alpha_3 \cdot \frac{BZT_5}{P_{og}} + \alpha_3 \cdot L_{N-NH_4} + \alpha_4 \cdot MLSS + \alpha_5 \cdot DO + \alpha_6 \cdot m_{PIX} = 0 \quad (8.4)$$

W celu utrzymania odpowiedniej niezawodności działania oczyszczalni kluczowe jest uzyskanie wartości $COR_{I_0,lim} \leq 1$ i $COR_{F/M} \leq 1$, co pozwala wyeliminować puchnięcie osadu i zachować prawidłowość procesu usuwania związków C, N i P. Współczynniki niezawodności (8.2) i (8.3) stanowią zmienne zależne w modelu, które wyznaczone są dla każdej chwili ($t + 1$), przy czym zmiennymi niezależnymi są ilość i jakość ścieków i nastawy reaktora biologicznego służące zmianom DO, X_{OC} i m_{PIX} , mierzone lub realizowane w chwili (t). Tym samym daje to możliwość odpowiedniego doboru wartości parametrów sterujących z dobowym wyprzedzeniem, co jest bardzo istotne z punktu widzenia technologa oczyszczalni.

W przedstawionym modelu, w celu zapewnienia ciągłości ciągów danych dotyczących jakości ścieków, przewidziano wykorzystanie metod modelowania data mining do ich prognozy. W związku z tym w dalszych analizach wartości BZT_5 , N_{og} , P_{og} i $N-NH_4$ w danej chwili będą prognozowane w oparciu o wartości dopływu ścieków do oczyszczalni mierzone w chwilach poprzednich.

8.2. Identyfikacja strategii sterowania bioreaktorem

Z uwagi na złożony wpływ ilości i jakości ścieków na dopływie do oczyszczalni i warunków atmosferycznych na działanie obiektu celowe jest wydzielenie typowych okresów jego eksploatacji. Realizacja typowych schematów sterowania opracowanych dla typowych okresów eksploatacji oczyszczalni zapewnia uzyskanie wymaganej efektywności i niezawodności działania obiektu (eliminacja puchnięcia osadu i brak zaburzeń przy usuwaniu C, N i P ze ścieków).

W rozważaniach praktycznych do tego celu stosuje się metody klasyfikacyjne nadzorowane, w których przyjmuje się określoną liczbę klas o podobnych cechach. Jednak, może to prowadzić do niejednoznacznych rozwiązań, dlatego zastosowanie znalazły metody nienadzorowane. Jedną z najprostszych metod identyfikacji podobieństw w wielowymiarowych zbiorach cech jest hierarchiczna analiza skupień HCA (ang. Hierarchical Analysis Cluster) (Sanchez i in. 1997, Bayo I López-Castellanos 2016). Uzyskany w jej wyniku tzw. dendrogram pozwala jednoznacznie wyznaczyć zróżnicowane obiekty. Do oceny zróżnicowania obiektów najczęściej stosuje się odległość euklidesową (Rutkowski 2006). Jednak, w pracy w celu określenia odległości między obiektami zastosowano metodę Warda, w której podstawę podobieństwa zmiennych w danej klasie stanowi

wariancja. Metodę HCA wykorzystano do identyfikacji okresów eksploatacji oczyszczalni, w których obciążenie ładunkiem zanieczyszczeń i kinetyka procesów będą zbliżone. W analizie skupień ujęto zmienne niezależne uwzględnione w modelu logitowym (7.4.1), opisujące ilość (Q) i jakość ścieków (BZT_5 , N_{og} , P_{og} , $N-NH_4$) oraz kinetykę procesów biochemicznych (T_{KOC}). W obliczeniach pominięto wartości X_{OC} , DO i m_{PIX} z uwagi na to, że ich wartości przyjęte dla stanu aktualnego nie zapewniają wymaganej niezawodności działania rektora biologicznego (Szeląg i in. 2018 d).

Z uwagi na to, że wykonanie analizy skupień w aspekcie opracowania strategii sterowania reaktorem wymaga zgromadzenia znacznej ilości danych, podjęto próbę zdefiniowania uniwersalnego parametru, którego wartość pozwoliłaby ocenić, jak dobrać nastawy w reaktorze biologicznym, aby ograniczyć problemy z sedimentacją osadu czynnego w osadniku wtórnym. Wykorzystując równanie (7.4.1) i dokonując podziału analizowanych zmiennych niezależnych na zmienne niezależne losowe i sterujące, sformułowano następującą zależność:

$$X = \left(\alpha_1 \cdot \frac{BZT_5}{N_{og}} + \alpha_2 \cdot \frac{BZT_5}{P_{og}} + \alpha_3 \cdot L_{N-NH_4} + \alpha_4 \cdot T_{KOC} \right)_l + (\alpha_0 + \alpha_{1,1} \cdot MLSS + \alpha_{1,2} \cdot DO + \alpha_{1,3} \cdot m_{PIX})_s \quad (8.5)$$

gdzie $(\alpha_1 \cdot x_1 + \dots + \alpha_i \cdot x_i)_{l,s}$ – odpowiednio zmienne niezależne losowe i sterujące.

Wprowadzając odpowiednie oznaczenia na podstawie równania (8.5) zdefiniowano nowy parametr (Φ), uwzględniający interakcje między zmiennymi losowymi:

$$\Phi = \alpha_1 \cdot \frac{BZT_5}{N_{og}} + \alpha_2 \cdot \frac{BZT_5}{P_{og}} + \alpha_3 \cdot L_{N-NH_4} + \alpha_4 \cdot T_{KOC} \quad (8.6)$$

i parametr sterujący Ω , wyrażony zależnością:

$$\Omega = \alpha_0 + \alpha_{1,1} \cdot X_{OC} + \alpha_{1,2} \cdot DO + \alpha_{1,3} \cdot m_{PIX} \quad (8.7)$$

Parametry Φ i Ω opisane równaniami (8.6), (8.7) spełniają warunek postaci:

$$\Omega + \Phi = \ln\left(\frac{p}{1-p}\right) \quad (8.8)$$

co wynika z zależności w modelu logitowym.

Równania (8.6) i (8.7) stanowią ogólne zależności, w których określenie współczynników α_i wymaga odpowiednich danych pomiarowych. Podane równania są uniwersalne i ujęte w nich zmienne są typowe dla reaktorów biologicznych bazujących na technologii osadu czynnego. Wartości współczynników (α_i) zależą od jakości dopływających ścieków i przyjętych rozwiązań w komorach osadu czynnego co wykazano w rozdziale 7.4.2.1.

8.3. Sterowanie i optymalizacja działania bioreaktora

Podczas eksploatacji oczyszczalni ścieków istotne jest, aby zaprojektowany system sterowania funkcjonował w układzie dynamicznym i uwzględniał przy doborze nastaw zmieniającą się ilość i jakość dopływających ścieków oraz warunki pogodowe. W badanej oczyszczalni ścieków w Sitkówce-Nowiny występują problemy z sedimentacją osadu czynnego, co skutkuje również incydentalnie gorszą jakością ścieków na wylocie. W związku z tym, prowadzone dalej badania miały na celu poprawę niezawodności działania obiektu poprzez wyeliminowanie puchnięcia osadu, zapewnienie ciągłości procesu usuwania C, N i P ze ścieków i ograniczenie do minimum ilości dawkowanych reagentów chemicznych. Należało w związku z tym rozwiązać zadanie opisane zależnościami (Szelağ i in. 2018d):

$$\sum_{t=1}^{242} (m_{PIX}(\Phi, MLSS, DO))_{\emptyset_z}(t) \rightarrow \min \quad (8.9)$$

$$COR_{I_o}(t)(t = 1,2,3..242) \leq 1 \quad (8.10)$$

$$COR_{F/M}(t)(t = 1,2,3..242) \leq 1 \quad (8.11)$$

gdzie: $m_{PIX}(\Phi, MLSS, DO)_{\emptyset}$ – funkcja dawkowania koagulantu PIX zależna od ilości i jakości ścieków oraz warunków pogodowych, a także od sposobu korygowania DO i X_{OC} wynikającym ze sterowania \emptyset_z .

Realizację zależności (8.9)÷(8.11) osiąga się poprzez sterowanie wartościami X_{OC} i DO w odpowiednich zakresach (min – max), w zależności od ilości i jakości ścieków oraz od warunków atmosferycznych. Gdy uzyska się z obliczeń $COR_{I_o} > 1$ lub $\Phi + \Omega > 1$ dla wartości granicznych X_{OC} i DO, to dawkuje się PIX w ilości:

$$m_{PIX} = \frac{-\Phi - \alpha_{1,1} \cdot X_{OC} - \alpha_{1,2} \cdot DO}{\alpha_{1,3}} \quad (8.12)$$

W przypadku ciągłej kontroli wartości X_{OC} i DO konieczne jest spełnienie warunku, aby ze wzrostem DO odpowiednio zwiększana była wartość X_{OC} . Warunek ten można wyrazić wzorem:

$$\begin{aligned} DO(t+1) - DO(t) < 0 \rightarrow X_{OC}(t+1) = X_{OC}(t) + \\ \Delta X_{OC}(\Phi(t+1)) \end{aligned} \quad (8.13)$$

lub w przeciwnym przypadku:

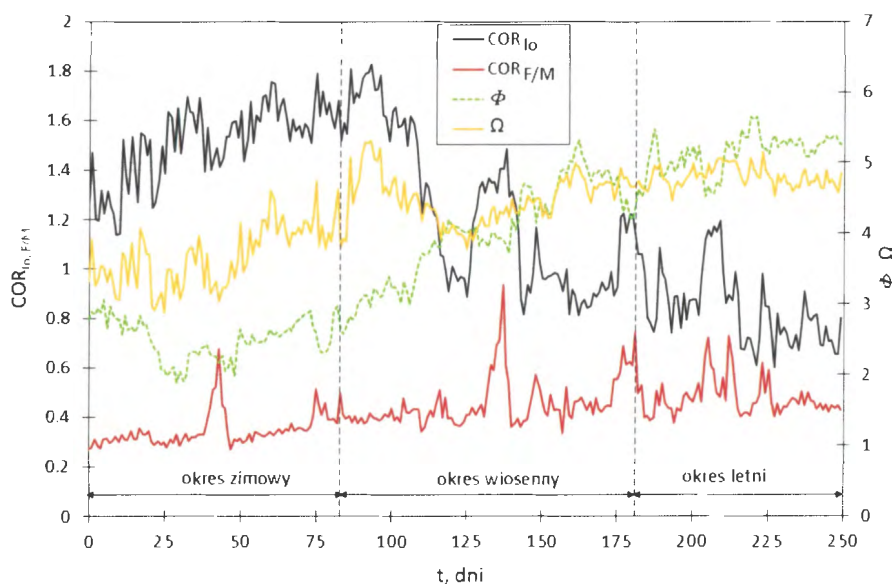
$$X_{OC}(t+1) = X_{OC}(t) - \Delta X_{OC}(\Phi(t+1)) \quad (8.14)$$

gdzie $\Delta X_{OC}(\Phi)$ – zmiana stężenia osadu czynnego między krokiem czasowym (t) i (t+1).

W celu praktycznej implementacji omówionego wyżej algorytmu obliczeniowego (rys. 8.1) przeanalizowano możliwość jego zastosowania na badanej oczyszczalni ścieków w okresie styczeń – sierpień 2016. Tym samym

ujęto sezonowy charakter pór roku (Lou i Zhao 2012). Wykorzystując wyznaczone modele matematyczne do prognozy sedimentacji osadu i wskaźników jakości ścieków na dopływie i pomiary nastaw (X_{OC} , DO, m_{PIX}) reaktora biologicznego, obliczono wartości $COR_{I_0}(t)$ i $COR_{F/M}(t)$ dla stanu rzeczywistej eksploatacji oczyszczalni. Następnie, rozwiązując zadanie opisane warunkami (8.9÷8.11), dokonano optymalizacji nastaw X_{OC} , DO i ilości dawkowanego koagulantu PIX przy zastosowaniu metody Nelder-Meada (1965).

Korzystając z pomiarów temperatury osadu i parametrów pracy bioreaktora (X_{OC} , DO, m_{PIX}) oraz opracowanych modeli do prognozy jakości ścieków (BZT_5 , N_{og} , P_{og} , $N-NH_4$), wykonano symulacje wymienionych wyżej wskaźników jakości ścieków i otrzymane wyniki podstawiono do równań (8.2), (8.3) i (8.6), wyznaczając w rezultacie wartości współczynników niezawodności $COR_{I_0}(t)$ i $COR_{F/M}(t)$ oraz Φ i Ω (rys. 8.2).




Rys. 8.2. Wyniki obliczeń $COR_{I_0,F/M}$ i współczynników Φ i Ω dla okresu 01.01 – 30.07.2015 dla oczyszczalni w Sitkówce – Nowiny.

Na podstawie zmienności krzywych na rys. 8.2 można stwierdzić, że w okresie zimowym (przy obniżonej temperaturze w komorach osadu czynnego) wartości parametru Φ są najmniejsze i wynoszą około 1,9÷3,0. Natomiast, w okresie letnim i wiosennym wartości parametru Φ są większe od 3,0, chociaż podczas opadów deszczów są mniejsze, niż w okresie bezopadowym, o około 15%. Oznacza to, że parametr Φ może stanowić istotną zmienną pozwalającą wyznaczyć

spół sposób sterowania reaktorem biologicznym w odniesieniu do sedimentacji osadu i usuwania C, N i P.

Wyniki te znajdują potwierdzenie w rezultatach analizy skupień wykonanej za pomocą metody HCA w oparciu o dane dotyczące ilości i jakości ścieków (BZT_5/N_{og} , BZT_5/P_{og} , L_{N-NH_4} , T_{KOC}) oraz temperatury w komorach osadu czynnego, co zobrazowano na dendrogramie na rys. 8.3. Analizując uzyskany dendrogram można stwierdzić, że w obrębie analizowanych danych występują trzy skupienia. Wielowymiarowe dane $[x_1, x_2, x_3, x_4, x_5]$ obejmujące skupienie C1 charakteryzują się niższą temperaturą T_{KOC} , niż dane w skupieniach C2 i C3 (tab. 8.1). Z powyższego wynika, że C1 obejmuje zdarzenia, gdy kinetyka procesów w reaktorze biologicznym była niższa, niż dla skupień C2 i C3, co jest typowe dla okresu o obniżonej temperaturze osadu, występującej zwykle w okresie zimowym. W C3 średnia wartość L_{N-NH_4} (2550 kgN-NH₄/d) jest większa, niż w C1 (1948 kgN-NH₄/d) i w C2 (2150 kgN-NH₄/d).



Rys. 8.3. Dendrogram uzyskany z analizy skupień dla oczyszczalni w Sitkówce–Nowiny; C_1, C_2, C_p –liczba zmierzonych zdarzeń opisanych przez $x = [x_1, x_2, x_3, \dots, x_i]$, $k = 1, 2, 3, \dots p$.

Tab. 8.1. Zestawienie wartości średnich analizowanych zmiennych niezależnych (BZT_5/N_{og} , BZT_5/P_{og} , L_{N-NH_4} , T_{KOC}) w uzyskanych skupieniach dla oczyszczalni w Sitkówce–Nowiny.

Skupienie	T_{KOC}	L_{N-NH_4}	BZT_5/P_{og}	BZT_5/N_{og}
C1	13,7	1948	37,51	3,85
C2	17,9	2150	43,80	4,07
C3	16,0	2550	32,15	3,51

W C3 obniżona wartość T_{KOC} w odniesieniu do C2 i zwiększony ładunek $N-NH_4$ mogą wskazywać na przeciążenie obiektu, co jest typowe dla działania oczyszczalni w okresie pogody deszczowej. Fakt ten znajduje również potwierdzenie w wartościach BZT_5/N_{og} i BZT_5/P_{og} , które w C3 są mniejsze, niż w C1 i C2. Mając na uwadze powyższe rozważania i uwzględniając wyniki obliczeń uzyskane dla skupień 1 i 3 można stwierdzić, że skupienie 2 obejmuje przypadki działania oczyszczalni dla pogody bezdeszczowej. Rezultaty analizy otrzymane za pomocą metody HCA potwierdzają, że na etapie eksploatacji obiektu można wyróżnić 3 typowe okresy, na co wskazuje również zmienność współczynnika Φ w poszczególnych okresach zobrazowanych na rys. 8.2.

Uzyskane wyniki analiz (rys. 8.2 i 8.4) są tym bardziej interesujące, iż można stwierdzić skorelowanie wartości Φ i $COR_{I_0}(t)$. Na podstawie wyznaczonych krzywych można zauważyć, że podczas obniżonej temperatury osadu, co przypada na okres zimowy, występowały problemy z eksploatacją oczyszczalni – miało wówczas miejsce puchnięcie osadu. Potwierdzają to wartości $COR_{I_0}(t) > 1$ i zmienność wyznaczonej wartości Φ . W okresie wiosennym i letnim epizody te miały miejsce w przypadku pogody deszczowej, co było wynikiem zwiększonego obciążenia substratowego. Z otrzymanych krzywych wynika także, że w okresie zimowym wartości COR_{I_0} zmieniały się w zakresie $1,90 \div 3,00$, a w okresie wiosny i lata w czasie pojedynczych epizodów (opady deszczu) przekraczały wartość $COR_{I_0}(t) > 1,00$. W czasie dni bezdeszczowych w okresie wiosna – lato, gdy nie było problemów z eksploatacją oczyszczalni w odniesieniu do sedymentacji osadu ($COR_{I_0}(t) = 0,60 \div 1,00$), obiekt charakteryzował się wysoką niezawodnością działania. Wydaje się możliwe ograniczenie ilości dawkowanych koagulantów i korekta X_{OC} i DO w okresach bezdeszczowych, na co wskazują wartości $COR_{I_0}(t) < 1,0$ (rys. 8.2, rys. 8.4).

Kolejny problem stanowiły wartości X_{OC} znacznie przekraczające wartości maksymalne ($5,0 \text{ kg/m}^3$) zalecane przy eksploatacji układów z osadem czynnym w systemie przepływowym. Wykonane badania (Barbusiński i Kościelniak 1995) wykazały, że utrzymywanie wysokich wartości X_{OC} przez dłuższy okres i znaczne

zmiany obciążenia substratowego, w krótkim odstępie czasu mogą prowadzić do problemów z eksploatacją reaktora biologicznego. Ponadto, analiza dynamiki zmienności danych na rys. 8.2 potwierdza, że obliczone wartości $COR_{F/M}(t)$ były mniejsze od 1,0 (maksymalna wartość wynosi 0,81). Wynik ten wskazuje na to, że w rozważanym okresie miało miejsce pogorszenie się jakości ścieków oczyszczonych w okresie zimy i podczas opadów deszczów, co potwierdzają również pomiary wybranych wskaźników jakości ścieków na wylocie z oczyszczalni (tab. 5.1).

Analizując wyniki obliczeń wykonanych metodą HCA i uzyskany przebieg zmienności parametru Φ (rys. 8.2, 8.4), wydzielono trzy okresy działania oczyszczalni: bezdeszczowy, przypadający na okres wiosenno-letni, opadowy i okres obniżonej temperatury osadu, co można utożsamiać z porą zimową. Dla tych okresów opracowano sterowania parametrami operacyjnymi komór osadu czynnego (X_{OC} , DO i m_{PIX}) w odniesieniu do sedymentacji osadu i przebiegu usuwania C, N i P.

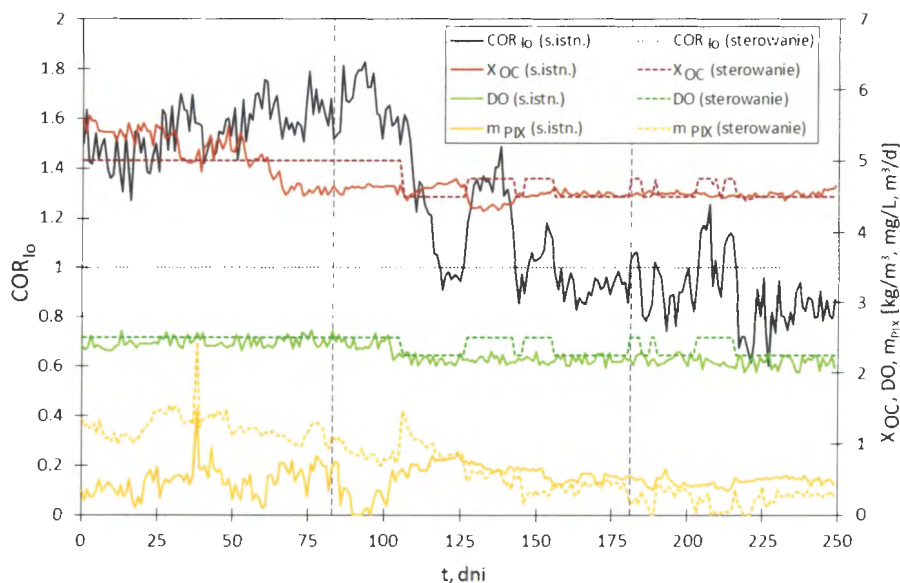
Biorąc pod uwagę zalecenia dotyczące eksploatacji oczyszczalni ścieków w systemie komór osadu czynnego (Henze i in. 2002), wyniki obliczeń innych autorów (Lou i Zhao 2012, i Flores–Alsina i in. 2009), a także analizując zmienność wartości $COR_{I_o}(t) = f(X_{OC}, DO \text{ i } m_{PIX})$, przyjęto następujący układ równań opisujący ograniczenia na etapie sterowania reaktorem biologicznym:

$$\Phi_z = \begin{cases} X_{OC,bz(max)} \geq X_{OC,bz} \geq X_{OC,bz(min)} \\ DO_{bz(max)} \geq DO_{bz} \geq DO_{bz(min)} \\ X_{OC,op(max)} \geq X_{OC,op} \geq X_{OC,op(min)} \\ DO_{op(max)} \geq DO_{op} \geq DO_{op(min)} \\ X_{OC,T(max)} \geq X_{OC,T} \geq X_{OC,T(min)} \\ DO_{T(max)} \geq DO_T \geq DO_{T(min)} \\ m_{PIX} = f(\Phi(X_{OC}, DO)) \end{cases} \quad (8.15)$$

gdzie: $X_{OC,min,max}$ – minimalne lub maksymalne zakresy zmienności stężenia osadu czynnego dla poszczególnych okresów działania obiektu, ustalone indywidualnie w zależności od obiektu, $DO_{min,max}$ – minimalne lub maksymalne zakresy zmienności stężenia osadu czynnego dla poszczególnych okresów działania obiektu, ustalone indywidualnie w zależności od obiektu, $m_{PIX} = f(\Phi(X_{OC}, DO))$ – funkcja opisująca dawkę dozowanego PIX w zależności od przyjętych wartości X_{OC} i DO .

Bazując na układzie zależności (8.15) i równaniach (8.9÷8.14) zastosowano metodę Nadlera i Meada do optymalizacji nastaw bioreaktora. Uzyskane wyniki obliczeń nastaw (DO, X_{OC}, m_{PIX}) zamieszczono na rys. 8.4. Na podstawie

otrzymanych krzywych można stwierdzić, iż w celu ograniczenia puchnięcia osadu w okresie obniżonej temperatury w komorach osadu czynnego zachodzi potrzeba utrzymania stężenia osadu nie mniejszego, niż $X_{OC} = 5,0 \text{ kg/m}^3$, stężenia tlenu rozpuszczonego nie mniejszego, niż $DO = 2,5 \text{ mg/l}$, oraz dawkowania koagulantu chemicznego (PIX). W okresie wiosennym i letnim (poza okresami opadowymi), aby zapewnić wartość $COR_{I_0}(t)$ na poziomie 1,0, celowe było utrzymanie wartości $X_{OC} \leq 4,5 \text{ kg/m}^3$ i $DO \leq 2,25 \text{ mg/l}$ oraz, podobnie jak w okresie obniżonej temperatury, potrzebne było wspomaganie procesu związkami chemicznymi (rys. 8.4). W przypadku okresów opadowych, kiedy następował wzrost obciążenia substratowego, jakość ścieków na wylocie ulegała pogorszeniu i miały miejsce problemy z puchnięciem osadu. W celu ich usunięcia zachodziła potrzeba utrzymania stężenia osadu czynnego na poziomie $X_{OC} = 4,75 \text{ kg/m}^3$ i stężenia tlenu rozpuszczonego na poziomie $DO = 2,5 \text{ mg/l}$.




Rys. 8.4. Wyniki obliczeń zmienności parametrów operacyjnych bioreaktora (X_{OC} , DO , m_{PIX}) po optymalizacji dla oczyszczalni w Sitkówce – Nowiny.

Tym samym stwierdzono, że optymalizacja parametrów działania reaktora biologicznego istotnie wpłynęła na niezawodność działania oczyszczalni ścieków. Potwierdzają to wyznaczone wartości COR_{I_0} , które nie przekraczają 1,0 co oznacza, że zastosowanie opisanej wyżej metody modelowania wartości I_0 eliminuje problemy z puchnięciem osadu czynnego. W oparciu o sporządzone krzywe (rys. 8.4÷8.5) stwierdzono, że w okresie zimowym w celu uzyskania odpowiedniej niezawodności działania oczyszczalni (redukcja $COR_{I_0}(t)$ z poziomu

1,57 dla stanu istniejącego do $COR_{1_0}(t) = 1,0$ konieczne było zwiększenie ilości dawkowanych reagentów chemicznych (z poziomu $46,16 \text{ m}^3$ w czasie 106 dni do poziomu $119,3 \text{ m}^3$).

Poprawa efektywności działania oczyszczalni w odniesieniu do sedymentacji osadu prowadziła do zwiększenia średniej dobowej dawki PIX z $0,44 \text{ m}^3/\text{d}$ do $1,12 \text{ m}^3/\text{d}$, co z punktu widzenia ekonomicznego nie jest korzystane, jednakże biorąc pod uwagę względy technologiczne jest konieczne. Otrzymane z obliczeń wartości X_{OC} nie przekraczają maksymalnych wielkości ($5,0 \text{ kg}/\text{m}^3$) zalecanych przy eksploatacji oczyszczalni. Równocześnie, wartości DO powyżej $2,5 \text{ mg}/\text{l}$ zostały wyeliminowane w celu uniknięcia potencjalnego przetlenienia osadu czynnego, co mogłoby być przyczyną pogorszenia się jego zdolności sedymentacyjnych. W okresie bezdeszczowym (123 dni) optymalizacja parametrów komór osadu czynnego przyczyniła się do redukcji wartości X_{OC} i wzrostu DO w odniesieniu do stanu istniejącego, co przełożyło się na zmniejszenie ilości dawkanego PIX z $54,24 \text{ m}^3$ do $42,35 \text{ m}^3$ (rys. 8.5). Średnia dobową dawką PIX zredukowana została z $0,55 \text{ m}^3/\text{d}$ do $0,46 \text{ m}^3/\text{d}$ a średnia wartość X_{OC} zmniejszyła się z $4,57 \text{ kg}/\text{m}^3$ do $4,50 \text{ kg}/\text{m}^3$.



Rys. 8.5. Porównanie zmienności parametrów operacyjnych reaktora (X_{OC} , DO, m_{PIX}) dla stanu istniejącego i po optymalizacji dla oczyszczalni w Sitkówce-Nowiny.

W okresie opadowym zastosowanie modelu i optymalizacja parametrów działania reaktora poprawiła niezawodność działania oczyszczalni, ponieważ wartość średnia COR_{I_0} dla stanu istniejącego zmniejszyła się z 1,20 do 1,0. Efekt ten uzyskano zwiększając średnie wartości $X_{OC} = 4,6 \text{ kg/m}^3$ i $DO = 2,3 \text{ mg/l}$, w odniesieniu do stanu istniejącego, o 3,3 % i 15,2 %, co pozwoliło na redukcję ilości dawkowanych reagentów chemicznych (z poziomu $24,86 \text{ m}^3$ do $14,68 \text{ m}^3$).

Na podstawie otrzymanych wyników obliczeń można stwierdzić, że zaproponowany model do analizy niezawodności działania oczyszczalni ścieków w odniesieniu do procesów sedimentacji osadu i usuwania ze ścieków związków C, N i P daje możliwość poprawy efektywności pracy bioreaktora nawet w przypadku braku ciągłości pomiarów wskaźników jakości ścieków. Stanowi to istotną zaletę modelu w porównaniu z pracami innych autorów (tab. 3.4 ÷ 3.5), ponieważ aspekt ten do tej pory był pomijany mimo tego, że ma on istotne znaczenie podczas eksploatacji oczyszczalni. W zaproponowanym modelu niezawodność działania bioreaktora jest określana w oparciu o zmodyfikowane współczynniki niezawodności COR, które wyznacza się w układzie dynamicznym dla każdej chwili t w zależności od ilości i jakości ścieków na dopływie do oczyszczalni oraz od wartości parametrów operacyjnych reaktora (DO , X_{OC} , m_{PIX}); stanowi to istotną modyfikację klasycznej definicji współczynnika niezawodności. W modelu do analizy niezawodności oczyszczalni ścieków zaproponowano współczynnik Φ pozwalający ocenić podatność osadu czynnego na puchnięcie oraz dobrać wartości parametrów operacyjnych w taki sposób, aby ograniczyć problemy z sedimentacją osadu.

8.4. Wpływ sterowania i optymalizacji na niezawodność pracy osadnika wtórnego w aspekcie sedimentacji osadu – model probabilistyczny

Z punktu widzenia eksploatacji oczyszczalni ścieków kluczowe jest utrzymanie w odpowiednim zakresie wartości nastaw bioreaktora (stopnie recyrkulacji, stężenie osadu czynnego, stężenie tlenu rozpuszczonego w komorach osadu czynnego, ilość dawkowanego koagulantu itp.) w celu uzyskania wymaganego efektu ekologicznego. Jedną z miar efektywności działania oczyszczalni ścieków jest niezawodność obiektu, pozwalająca ustalić, czy obiekt pracuje poprawnie przez określony czas i przy zróżnicowanych warunkach eksploatacyjnych (Rak 2008).

Niezawodność obiektu wyraża prawdopodobieństwo wystąpienia zdarzenia opisanego relacją (Rak i Tchórzewska – Cieślak 2009):

$$R(t) = p(t > \tau) \quad (8.16)$$

w której: $R(t)$ – niezawodność, t – czas pracy obiektu bez wystąpienia awarii, τ – wymagany czas pracy bez awarii.

Zależność (8.16) można odnieść do działania oczyszczalni ścieków. Przyjmując za czas pracy bez awarii odpowiednio epizody, gdy uzyskana na odpływie jakość ścieków spełnia wymagania z Rozporządzeniu Ministra Środowiska z dnia 18 listopada 2014 r., istnieje możliwość analizy pracy bioreaktora w dowolnych okresach czasu. Niezawodność działania oczyszczalni w danym przedziale czasowym można zatem opisać równaniem:

$$R(t) = \frac{\sum r(x_1, x_2, \dots, x_j)}{T} \quad (8.17)$$

gdzie: T – liczba zdarzeń w okresie czasu, w którym analizowany jest dowolny parametr działania oczyszczalni, stanowiący podstawę oceny jej niezawodności, $r(x_1, x_2, \dots, x_j)$ – funkcja o charakterze lingwistycznym opisana przez zmienne niezależne x_1, x_2, \dots, x_j , przyjmująca wartości 0 dla przypadków, gdy przyjęta graniczna wartość liczbowa x_g w ocenie niezawodności działania obiektu zostaje przekroczona, co odpowiada problemom z eksploatacją oczyszczalni ścieków, i wartości 1, gdy dla przyjętych zmiennych niezależnych, w tym m.in. nastaw bioreaktora, nie zostaje przekroczona wartość x_g i nie stwierdzono problemów w eksploatacji obiektu.

Biorąc pod uwagę ogólny charakter zależności (8.17) można stwierdzić, że istnieje możliwość przyjmowania innych kryteriów oceny działania oczyszczalni, niż wartości wybranych wskaźników jakości ścieków na odpływie. Jednym z kryteriów, które są stosowane przy analizie niezawodności działania oczyszczalni ścieków, jest obciążenie substratowe osadu, którego wartość istotnie determinuje jakość ścieków oczyszczonych. Jednak, opracowany przez Zhou i in. (2018) model do prognozy wartości F/M charakteryzował się niskim dopasowaniem wyników obliczeń do pomiarów, przez co jego zastosowanie było ograniczone. Poza tym model ten, jak i większość modeli opracowanych przez innych autorów (Niku 1981, Eisenberge i in. 2001, Messaoud i in. 2013), miał ograniczone możliwości oceny wpływu zmian w przyjętych strategiach sterowania bioreaktorem na niezawodność działania obiektu.

Mając na uwadze powyższe uwagi opracowuje się modele probabilistyczne do prognozy niezawodności działania oczyszczalni ścieków. W modelach tych do prognozy ilości i jakości ścieków oraz temperatury ścieków w bioreaktorze stosuje się generatory, pozwalające na symulację warunków na dopływie do oczyszczalni i warunków meteorologicznych przy użyciu rozkładów teoretycznych poszczególnych zmiennych wyznaczanych na podstawie pomiarów wykonanych w okresie wieloletnim. Otrzymane wyniki prognoz stanowią następnie wejścia do odpowiednich modeli procesowych, co pozwala w rezultacie na optymalny dobór parametrów operacyjnych bioreaktora (Rousseau i in. 2001, Bixo i in. 2002).

Model probabilistyczny przedstawiony przez Bixo i in. (2002) okazał się pomocny przy symulacji działania oczyszczalni ścieków, jednak symulacje wykonane za jego pomocą odnosiły się wyłącznie dla konkretnego pojedynczego okresu roku (zima, wiosna, lato) i dlatego ograniczone były możliwości badania wpływu przyjętej strategii sterowania na działanie obiektu w dłuższym okresie czasu (np. rok). W Polsce model probabilistyczny do prognozy funkcjonowania oczyszczalni ścieków opracowali Andraka i Dzieńis (2013), jednak w swoich analizach pominieli oni model procesowy, co ograniczyło możliwość oceny wpływu przyjętych nastaw na działanie obiektu.

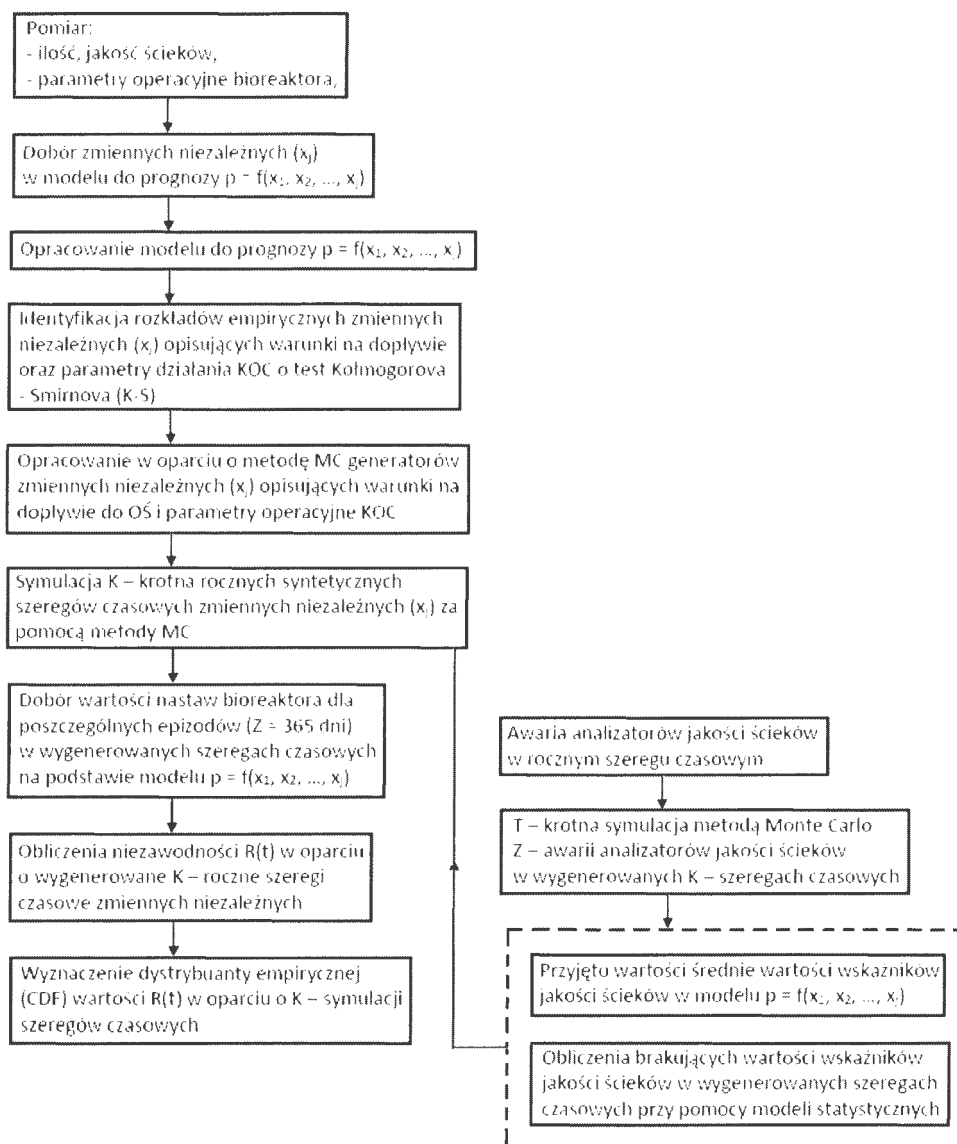
Na uwagę zasługuje również fakt, że aspektem do tej pory nie ujmowanym w modelach probabilistycznych były awarie układów pomiarowych w oczyszczalniach ścieków.

Mając na względzie powyższe uwagi i ograniczenia omówionego w punkcie 8.1 modelu do analizy niezawodności oczyszczalni ścieków, przedstawiono poniżej autorski model probabilistyczny do analizy niezawodności oczyszczalni w ujęciu długookresowym (jednego roku) w odniesieniu do sedymentacji osadu czynnego. Schemat algorytmu wyznaczania modelu zamieszczono na rys. 8.6.

Zaproponowany model składa się z dwóch niezależnych modeli. Pierwszym z nich jest model klasyfikacyjny (logitowy) do prognozy sedymentacji osadu czynnego, w którym uwzględnione zmienne niezależne dotyczą ilości i jakości ścieków oraz parametrów operacyjnych bioreaktora. Zaletą tego modelu jest prosta interpretacja wyników obliczeń, pozwalająca ocenić, na podstawie wyznaczonych współczynników empirycznych (β_j), wpływ poszczególnych zmiennych niezależnych (x_j) na modelowany proces.

Kolejny model w zaproponowanym algorytmie, a właściwie grupa modeli, to generatory zmiennych niezależnych (x_j) uwzględnionych w równaniu $p = f(x_1, x_2, x_3, \dots, x_j)$ służącym do prognozy parametrów operacyjnych reaktora i sedymentacji osadu; modele te są wyznaczane za pomocą metody Monte Carlo. Podstawą symulacji tych zmiennych za pomocą generatorów są rozkłady teoretyczne zmiennych ustalone w oparciu o ich rozkłady empiryczne wyznaczone na podstawie danych pomiarowych rejestrowanych na oczyszczalni ścieków. W przypadku modeli generatorów przyjęto, że istnieje możliwość prognozy awarii analizatorów zainstalowanych na oczyszczalni do pomiaru wskaźników jakości ścieków na dopływie ujętych w modelu $p = f(x_1, x_2, x_3, \dots, x_j)$. W dalszych analizach założono średnią liczbę T awarii analizatorów w roku, i stosując metodę Monte Carlo generowane są wartości z zakresu $1 \div 365$ (dni), odpowiadające zdarzeniom, gdy taka awaria miała miejsce. W przypadku awarii analizatorów wybranych wskaźników jakości ścieków, a co za tym idzie, braku pomiarów odnośnych zmiennych w modelu $p = f(x_1, x_2, x_3, \dots, x_j)$ w proponowanym modelu

przyjęto albo średnie wartości analizowanych wskaźników, albo mogą one być modelowane za pomocą modeli statystycznych opisanych w punkcie 7.3. Aspekt awaryjności analizatorów do tej pory nigdy nie był badany przez innych autorów.



Rys. 8.6. Schemat obliczeniowy zaproponowanego w pracy modelu probabilistycznego do prognozy niezawodności działania oczyszczalni w odniesieniu do sedymentacji osadu.

Kolejne kroki zaproponowanego algorytmu obliczeniowego z rys. 8.6 są następujące:

- a) wyznaczenie zmiennych niezależnych (x_j) i współczynników empirycznych (α_i) w modelu regresji logistycznej,
- b) ustalenie rozkładów empirycznych zmiennych niezależnych (x_j) uwzględnionych w modelu $p = f(x_1, x_2, x_3, \dots, x_j)$ i dopasowanie do nich rozkładów teoretycznych za pomocą testu Kołmogorowa–Smirnova,
- c) K -krotna symulacja metodą Monte Carlo (MC) szeregów czasowych zmiennych niezależnych opisujących warunki na dopływie do oczyszczalni ścieków i parametry operacyjne komór osadu czynnego,
- d) dobór nastaw w bioreaktorze na podstawie przyjętych strategii sterowania dla poszczególnych dni w modelowanych K -krotnie rocznych szeregach czasowych,
- e) wyznaczenie wartości p dla ustalonych wartości zmiennych niezależnych,
- f) obliczenie niezawodności $R(t)$ dla przyjętej strategii sterowania reaktorem biologicznym dla obliczonych K szeregów czasowych,
- g) ustalenie rozkładu empirycznego niezawodności $R(t)$ na podstawie wyznaczonych K wartości $R(t)$,
- h) wyznaczenie rozkładów empirycznych dla zmiennych będących parametrami operacyjnymi reaktora (CDF – skumulowane rozkłady gęstości prawdopodobieństwa) na podstawie symulacji Z dni w K rocznych szeregach czasowych,
- i) analiza wpływu awarii analizatorów wybranych wskaźników jakości ścieków na działanie bioreaktora; dla przyjętej liczby awarii Z , za pomocą generatora MC są modelowane T -krotnie dni, gdy wystąpią awarie analizatorów jakości ścieków dla wygenerowanych K szeregów czasowych,
- j) dla przyjętych założeń w odniesieniu do wskaźników jakości ścieków dobierane są odpowiednio nastawy bioreaktora i określne są rozkłady CDF wartości niezawodności oraz parametry operacyjne bioreaktora.

Bazując na opracowanym we wcześniejszych rozdziałach modelu do symulacji $p = f(x_1, x_2, x_3, \dots, x_j)$ (równanie 7.4.1) i na uwzględnionych w modelu zmiennych niezależnych zamieszczono poniżej przykład zastosowania omówionego powyżej algorytmu tworzenia modelu probabilistycznego do prognozy niezawodności działania oczyszczalni w odniesieniu do sedymentacji osadu czynnego.

W prowadzonych analizach rozważono kilka przykładowych strategii sterowania bioreaktorem:

- a) (S1) kontrola wartości X_{OC} , DO, m_{PIX} w oparciu o analizy przeprowadzone w punkcie 8.3 i wytyczne branżowe do eksploatacji obiektów z usuwaniem C, N i P (Łomotowski i Szpindor 1999, Henze i in. 2002, Flores–Alsina i in. 2009); opracowany zestaw reguł sterujących postaci:

$$\phi_{z(s1)} = \begin{cases} 4,50 \geq X_{OC,bz} \geq 2,50 \\ 2,50 \geq DO_{bz} \geq 2,00 \\ 5,00 \geq X_{OC,op} \geq 4,50 \\ 2,50 \geq DO_{op} \geq 2,00 \\ 5,00 \geq X_{OC,T} \geq 4,50 \\ 2,50 \geq DO_T \geq 2,25 \\ m_{PIX} = f(\Phi(X_{OC}, DO)) \end{cases} \quad (8.18)$$

- b) (S2–Var) Kontrola wartości X_{OC} , DO i m_{PIX} w zależności od T_{KOC} ; opracowany zestaw reguł sterujących postaci:

$$\phi_{z(s2)} = \begin{cases} T_{KOC} \leq 13,7^\circ C \\ DO = 2,5 \text{ mg/l} \\ X_{OC} = 5,00 \text{ kg/m}^3 \\ m_{PIX} = 1,14 \text{ m}^3/d \\ T_{KOC} \geq 13,7^\circ C \\ DO = 2,25 \text{ mg/l} \\ X_{OC} = 4,50 \text{ kg/m}^3 \\ m_{PIX} = 0,51 \text{ m}^3/d \end{cases} \quad (8.19)$$

- c) (S3–min, S4–max) Kontrola wartości X_{OC} , DO w zależności od T_{KOC} i $m_{PIX} = \text{const}$; opracowane zestawy reguł sterujących postaci:

$$\phi_{z(s3)} = \begin{cases} T_{KOC} \leq 13,7^\circ C \\ DO = 2,5 \text{ mg/l} \\ X_{OC} = 5,00 \text{ kg/m}^3 \\ T_{KOC} \geq 13,7^\circ C \\ DO = 2,25 \text{ mg/l} \\ X_{OC} = 4,50 \text{ kg/m}^3 \\ m_{PIX} = 0,51 \text{ m}^3/d \end{cases} \quad (8.20)$$

$$\Phi_{z(S4)} = \begin{cases} T_{KOC} \leq 13,7^{\circ}C \\ DO = 2,5 \text{ mg/l} \\ X_{OC} = 5,00 \text{ kg/m}^3 \\ T_{KOC} \geq 13,7^{\circ}C \\ DO = 2,25 \text{ mg/l} \\ X_{OC} = 4,50 \text{ kg/m}^3 \\ m_{PIX} = 1,14 \text{ m}^3/d \end{cases} \quad (8.21)$$

W przypadku strategii S1, dla losowych wartości (BZT_5/N_{og} , (BZT_5/P_{og} , L_{N-NH_4} , i T_{KOC} obliczono wartości m_{PIX} , X_{OC} i DO w taki sposób, aby $COR_{I_0} = 1,0$, co oznacza brak puchnięcia osadu w analizowanym okresie, a co za tym idzie $R(t = 365 \text{ dni}) = 1,0$. Tym samym zachodzi potrzeba analizy zmienności uzyskanych z symulacji parametrów operacyjnych komór osadu czynnego, dla wartości wskaźników jakości ścieków i temperatury w bioreaktorze otrzymanych prognozy MC.


W pozostałych strategiach sterowania ($S2 \div S4$) z uwagi na to, że wartości $MLSS$, DO i m_{PIX} są zadawane, wartości $R(t)$ mogą zmieniać się w odpowiednim zakresie zmienności. W strategiach sterowania $S2 \div S4$ koncentrowano się na analizie niezawodności działania obiektu $R(t)$ i aspektach technologicznych związanych z dawkowaniem koagulantu PIX .

Bazując na przedstawionym na rys. 8.6 algorytmie obliczeniowym i wykonanych wyżej obliczeniach, wyznaczono rozkłady empiryczne zmiennych niezależnych o charakterze losowym (BZT_5/N_{og} , BZT_5/P_{og} , L_{N-NH_4} , i T_{KOC}) ujętych w równaniach (7.4.1) i (8.2), (8.3); do danych tych dopasowano następnie rozkłady teoretyczne (tab. 8.2). Przeprowadzone analizy wykazały, że w przypadku większości analizowanych zmiennych nie ma podstaw do odrzucenia hipotezy zerowej mówiącej, iż rozpatrywany empiryczny rozkład danych odbiega od rozkładu normalnego. Na podstawie opracowanych modeli do prognozy sedymentacji osadu opisanych równaniami (7.4.1) i (8.2), (8.3) i wyznaczonych rozkładów teoretycznych zmiennych (tab. 8.2) oraz dla przyjętych strategii sterowania ($S1 \div S4$) wykonano następnie obliczenia niezawodności $R(t = 365 \text{ dni})$ działania oczyszczalni, gdy mają miejsce awarie analizatorów ($Z=36$) i gdy awarie nie występują; wyniki uzyskanych symulacji zamieszczono na rys. 8.7÷8.13.


Na bazie wykonanych obliczeń dla wariantu sterowania S1 sporządzono krzywe CDF obrazujące zmienność parametrów operacyjnych (X_{OC} , DO i m_{PIX}) bioreaktora dla okresu rocznego, Analizując na rys. 8.7 i 8.8 zmienność wartości DO i X_{OC} w ciągu roku można stwierdzić, że obliczone stężenie tlenu rozpuszczonego i stężenie osadu czynnego w KOC zmieniało się, odpowiednio, w zakresie $2,0 \div 2,5 \text{ mg/l}$ i $2,5 \div 5,0 \text{ kg/m}^3$.

Tab. 8.2. Zestawienie wyników obliczeń dopasowania rozkładów teoretycznych do danych empirycznych w oparciu o test Kołmogorova–Smirnova dla oczyszczalni w Sitkówce–Nowiny.


Wskaźniki	Zima		Wiosna, lato, jesień	
	rozkład	K-S (p)	rozkład	K-S (p)
Q	N	0,342	N	0,245
T_{KOC}	N	0,524	N	0,456
BZT_5	N	0,782	N	0,569
N-NH ₄	N	0,881	N	0,752
N_{og}	N	0,732	N	0,700
P_{og}	N	0,575	N	0,521
T_{KOC}	N	0,054	N	0,068
DO	N	0,156	N	0,231
X_{OC}	N	0,135	N	0,156
I_0	LN	0,608	LN	0,520
PIX	N	0,254	N	0,315




Rys. 8.7. Rozkład empiryczny wartości DO w przeciągu roku dla wariantu sterowania S1 bez awarii i z awariami dla oczyszczalni w Sitkówce-Nowiny.



Rys. 8.8. Rozkład empiryczny wartości X_{OC} w roku dla wariantu sterowania S1 bez awarii i z awariami dla oczyszczalni w Sitkówce-Nowiny.



Rys. 8.9. Rozkład empiryczny wartości m_{PIX} w przeciągu roku dla wariantu sterowania S1 bez awarii i z awariami dla oczyszczalni w Sitkówce-Nowiny.



Rys. 8.10. Rozkład empiryczny wartości m_{PIX} w roku dla wariantu sterowania S1 bez awarii i z awariami dla oczyszczalni w Sitkówce-Nowiny.


Wyznaczone wartości DO na poziomie 2,5 mg/l i X_{OC} na poziomie ok. 5,0 kg/m³ (odpowiada to wartości percentyla $p = 0,95$) wskazują, że średnio przez około 0,25 roku temperatura w bioreaktorze spada poniżej 13,8°C. Przez okres około 0,75 roku wartość DO była na poziomie $\leq 2,25$ mg/l a wielkości $X_{OC} \leq 5,0$ kg/m³, co można utożsamiać z pracą bioreaktora w warunkach pogody bezdeszczowej, z czego przez okres 0,15 roku wartości DO i X_{OC} zmieniały się, odpowiednio, w przedziale 2,00÷2,25 mg/l i 2,5÷4,5 kg/m³. Wartości DO i X_{OC} zmieniające się w podanych wyżej zakresach mogą wskazywać na to, że podczas eksploatacji badanego obiektu zdarzały się okresy podwyższonej temperatury osadu, co można utożsamiać z okresem letnim i wiosennym; jest wówczas możliwe znaczne obniżenie stężenia tlenu oraz prawdopodobnie także wartości X_{OC} (rys. 8.8) i m_{PIX} (rys. 8.9), unikając przy tym problemów z puchnięciem osadu czynnego.

Biorąc pod uwagę losowy charakter zmiennych niezależnych, takich jak BZT_5/N_{Og} , BZT_5/P_{Og} , L_{N-NH_4} , i T_{KOC} , można stwierdzić na podstawie rys. 8.9 i rys. 8.10, iż oprócz kontroli wartości zmiennych X_{OC} i DO istotne znaczenie odgrywa także dozowanie koagulantu PIX.


Aby wyeliminować problemy z puchnięciem osadu czynnego zachodzi potrzeba dodatkowo podawania PIX w ilości 265m³/rok ($p = 0,50$). Istotnym aspektem, który uwzględniono w prowadzonych analizach, a dotychczas był on

pomijany w prognozach pracy oczyszczalni, były awarie analizatorów jakości ścieków. Wykonane symulacje działania osadnika wtórnego (rys. 8.7÷8.10) wykazały, że awarie analizatorów prowadzą do nieznacznego zwiększenia wartości zmiennych sterujących (X_{OC} , DO i m_{PIX}) w cyklu rocznym, aby zapewnić niezawodność pracy oczyszczalni ścieków na poziomie ($R(t \text{ 365 dni}) = 1,0$ w odniesieniu do sedymentacji osadu czynnego).


Przeprowadzone prognozy pracy bioreaktora (rys. 8.11÷8.15) dla kolejnych strategii sterowania (S2÷S4) wskazują, iż niezawodność $R(t)$ pracy obiektu w ujęciu rocznym zmniejsza się w porównaniu ze strategią S1, na co wskazuje przebieg poszczególnych krzywych na rys. 8.11. Spośród rozpatrywanych strategii sterowania (S2÷S4) największą niezawodność działania osadnika wtórnego stwierdzono w przypadku strategii S4 (stała dobowa dawka PIX równa $1,14 \text{ m}^3$). W tym przypadku, przyjmując losowy charakter ilości i jakości ścieków na dopływie do oczyszczalni (BZT_5/N_{og} , BZT_5/P_{og} , L_{N-NH_4}) oraz temperatury osadu (T_{KOC}) stwierdzono, że niezawodność oczyszczalni ścieków zmienia się od 0,92 ($p = 0,05$) do 0,96 ($p = 0,95$), podczas gdy średnia wartość wynosi $R(t) = 0,94$ ($p = 0,50$).




Rys. 8.11. Rozkłady empiryczne niezawodności $R(t)$ dla przyjętych strategii sterowania dla modelu z awariami i bez awarii dla oczyszczalni w Sitkówce-Nowiny




Rys. 8.12. Rozkłady empiryczne niezawodności COR_{10} dla przyjętych strategii sterowania dla modelu z awariami i bez awarii dla oczyszczalni w Sitkówce-Nowiny.



Rys. 8.13. Rozkłady empiryczne wartości η dla przyjętych strategii sterowania dla modelu z awariami i bez awarii (gdzie η – udział dni w roku, gdy dawka PIX jest za mała i następuje puchnięcie osadu) dla oczyszczalni w Sitkówce-Nowiny.



Rys. 8.14. Rozkłady empiryczne niedoboru rocznej dawki PIX (m_{PIX}), która by wyeliminowała puchnięcie osadu dla przyjętych strategii sterowania dla modelu z awariami i bez awarii dla oczyszczalni w Sitkówce-Nowiny.



Rys. 8.15. Rozkłady empiryczne nadmiaru rocznej dawki PIX (m_{PIX}) dla przyjętych strategii sterowania dla modelu z awariami i bez awarii dla oczyszczalni w Sitkówce-Nowiny.

Mniejszą niezawodność funkcjonowania oczyszczalni uzyskano dla strategii sterowania ze zmienną dawką PIX w zależności od T_{KOC} ; wartości $R(t)$ zmieniają się w zakresie 0,76÷0,84. Wykonane symulacje pracy oczyszczalni Sitkówka–Nowiny wykazały, że stosując strategię sterowania S4 w 95% zdarzeń w roku wartości COR_{I_0} nie przekraczają wartości 1,15 co wskazuje na za dużą i nieoptymalnie dobraną dawkę dobową PIX.

Wyniki te znajdują potwierdzenie w rezultatach analiz wykonanych w odniesieniu do udziału (η) dni w roku, gdy ilość dawkowanego PIX jest niewystarczająca (rys. 8.13) i gdy ilość podawanego PIX jest nadmierna (rys. 8.12 i 8.15), co prowadzi do obniżenia wartości $COR_{I_0}(t = 1 \div 365 \text{ dni}) < 1,0$. Analiza krzywych na rys. 8.14 pozwala na ocenę zastosowanych strategii sterowania w odniesieniu do ilości dawkowanego PIX, którego nadmiar prowadzi do redukcji wartości $COR_{I_0}(t = 1 \div 365 \text{ dni}) < 1,0$. W przypadku strategii sterowania S4 warunkującej największy udział dni w roku, gdy $COR_{I_0}(t) < 1,0$, stwierdzono, że roczna ilość nadmiarowo dawkowanego PIX jest największa i zmienia się od 95,2 m³/rok ($p = 0,05$) do 114,1 m³/rok ($p = 0,95$). W strategii sterowania S2 ilość PIX jest mniejsza o ponad 40 %, co znajduje również odzwierciedlenie w wartościach $COR_{I_0}(t)$ (rys. 8.12) i w rozkładach empirycznych wartości rocznej dawki PIX (m_{PIX}), która by wyeliminowała puchnięcie osadu.

Uzyskane wyniki obliczeń zobrazowane na rys. 8.11÷8.15 wskazują, że wpływ na niezawodność pracy obiektu mają awarie analizatorów jakości ścieków. Ujęcie awarii analizatorów w modelu powoduje spadek niezawodności pracy bioreaktora, co wynika z niepewnej informacji o jakości ścieków na wlocie do oczyszczalni. Obniżenie niezawodności działania reaktora $R(t)$ nie jest duże, bowiem wartość $R(t)$ dla poszczególnych percentyli obniża się o $\Delta R \sim 0,01$, ale wskazuje to na wzrost liczby potencjalnych problemów podczas eksploatacji obiektu. Na podstawie wykonanych analiz (rys. 8.11÷8.15) można stwierdzić, że w poszczególnych strategiach sterowania (S2÷S4) uwzględnienie w symulacjach awarii prowadziło do spadku ilości dawkowanego PIX (w porównaniu z przypadkami bez awarii), którego niedobór przyczynia się do spadku niezawodności działania oczyszczalni.

Podsumowując uzyskane wyniki można stwierdzić, że zaproponowany model probabilistyczny można stosować do analizy wpływu przyjętych strategii sterowania oczyszczalni na niezawodność działania obiektu. Zaproponowane rozwiązanie jest tym bardziej istotne, że daje możliwość oceny i identyfikacji niekorzystnych warunków eksploatacyjnych, na które oczyszczalnia może być narażona z uwagi na dużą zmienność ilości i jakości dopływających ścieków.

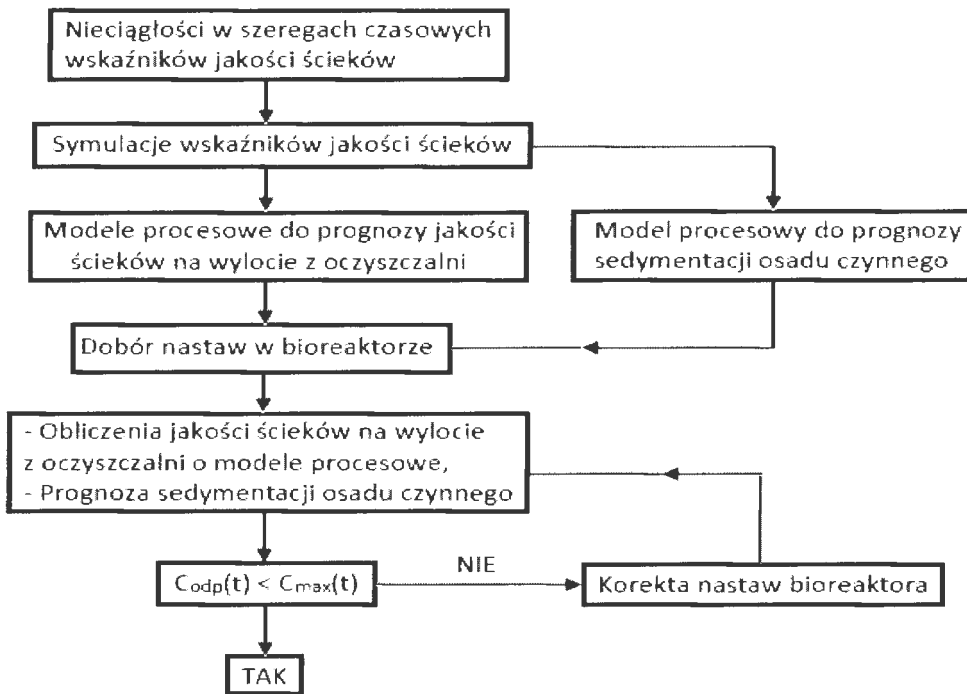
8.5. Aspekty sterowania bioreaktorem – jakość ścieków na wylocie a sedymentacja osadu

Podczas eksploatacji oczyszczalni ścieków kluczowy jest dobór i kontrola parametrów operacyjnych bioreaktora, aby na odpływie wartości wybranych wskaźników jakości ścieków ujętych w Rozporządzeniu Ministra Środowiska z dnia 14 listopada 2014 r. nie zostały przekroczone. W celu poprawy efektywności działania oczyszczalni ścieków i obniżenia kosztów jej pracy coraz częściej opracowuje się modele matematyczne (tab. 3.1÷3.4) wspomagające sterowanie systemami wykonawczymi regulującymi stopnie recyrkulacji, stężenie tlenu rozpuszczonego w komorach nitrifikacji, ilość dawkowanych związków chemicznych (metanol, PIX itp.). Jednak, w modelach tych pomija się zwykle dynamikę procesów zachodzących w bioreaktorze i mających wpływ na jakość ścieków oczyszczonych (np. sedymentacja osadu czynnego). Ponadto, zakłada się powszechnie ciągłość pomiarów wykorzystywanych w modelach (usuwanie ze ścieków związków organicznych, azotu, fosforu, puchnięcie osadu itp.), co powoduje, że opracowywane na podstawie takich modeli algorytmy sterowania mają ograniczone zastosowanie w praktyce.

Dlatego też, w pracy zaproponowano algorytm obliczeniowy (rys. 8.16) umożliwiający symulację i kontrolę jakości ścieków na wylocie z oczyszczalni ścieków oraz ocenę procesu sedymentacji osadu czynnego w przypadku nieciągłości ciągów pomiarowych dotyczących wskaźników jakości ścieków. W algorytmie przewiduje się, że w przypadku nieciągłości szeregów czasowych brakujące wartości wskaźników będą modelowane. Uzyskane tym sposobem dane wejściowe do modeli procesowych (wskaźniki jakości ścieków na dopływie, parametry sterujące reaktorem X_{OC} , DO i m_{PIX}) umożliwią wykonanie symulacji jakości ścieków na wylocie z obiektu i procesu sedymentacji osadu czynnego w bioreaktorze. W przypadku, gdy dobrane wartości nastaw reaktora zapewniają wartości wskaźników jakości ścieków oczyszczonych ($C_{odp}(t)$) niższe od wartości dopuszczalnych, to można uznać te nastawy za właściwe. W przeciwnym przypadku należy dokonać korekty przyjętych nastaw. Jako dodatkowy istotny parametr technologiczny będący podstawą oceny działania oczyszczalni przyjęto sedymentację osadu czynnego.

W badaniach skupiono się na symulacji na wylocie z oczyszczalni związków azotu (N_{og} , $N-NH_4$) i fosforu (P_{og}) ze względu na to, że podczas eksploatacji obiektu miały miejsce przekroczenia ich dopuszczalnych wartości (tab. 5.1). Do modelowania wskaźników jakości ścieków wykorzystano modele matematyczne omówione w punkcie 7.4. Do prognozy sedymentacji osadu czynnego zastosowano model regresji logitowej opisany równaniem (7.4.1). W celu praktycznej implementacji zaproponowanego algorytmu obliczeniowego (rys. 8.16) wykonano przykładowe obliczenia składające się z następujących kroków:

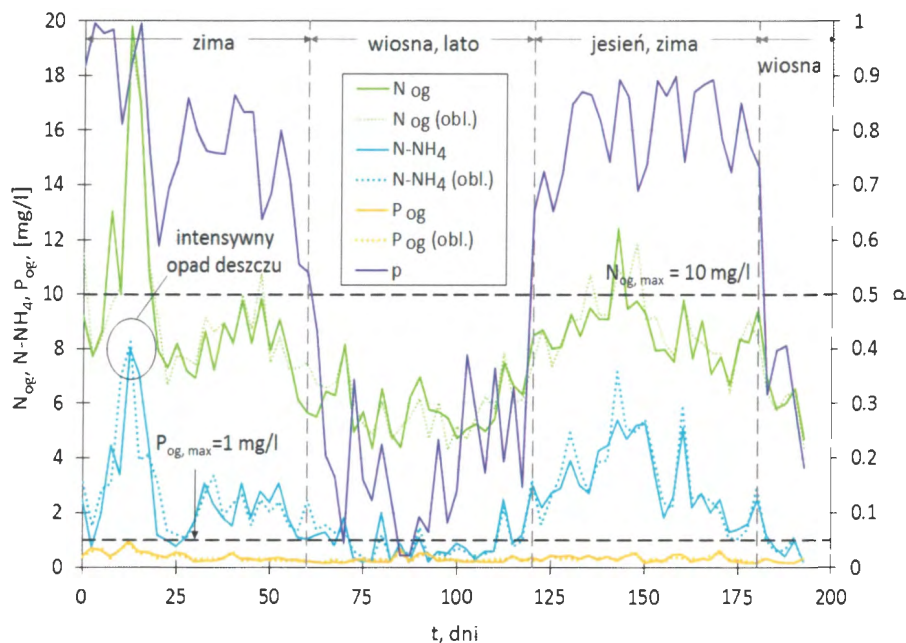
- symulacja jakości ścieków na dopływie do oczyszczalni dla wybranych zdarzeń,
- prognoza jakości ścieków na wylocie z oczyszczalni i sedymentacji osadu dla stanu istniejącego,
- interpretacja uzyskanych wyników i dobór nastaw w bioreaktorze,
- prognoza jakości ścieków na wylocie z oczyszczalni i sedymentacji osadu dla przyjętych nastaw.



Rys. 8.16. Schemat ideowy algorytmu kontroli nastaw w bioreaktorze w przypadku nieciągłości w szeregach czasowych wskaźników jakości ścieków.

Kroki obliczeniowe (a) i (b) szczegółowo omówiono w punktach 7.3 i 7.4. W obliczeniach do prognozy jakości ścieków na dopływie do oczyszczalni (BZT₅, ChZT, N_{og}, N-NH₄, P_{og}) zastosowano modele opracowane na bazie metody kaskadowych sieci neuronowych, zapewniającą najlepsze dopasowanie wyników obliczeń do pomiarów. Do obliczenia jakości ścieków na wylocie z obiektu w przypadku braku ciągłości w pomiarach wskaźników jakości ścieków na

dopływie przyjęto kombinację modeli CNN+CNN dla N_{og} oraz SVM+CNN dla P_{og} i $N-NH_4$. Pomiary oraz wyniki obliczeń wybranych wskaźników jakości ścieków i sedymentacji osadu czynnego przedstawiono na rys. 8.17.

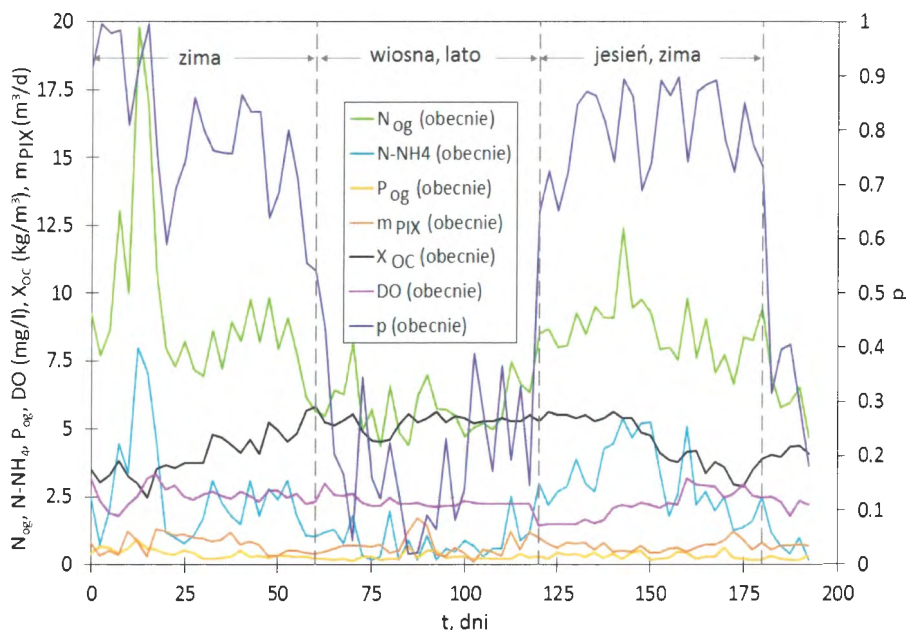


Rys. 8.17. Wyniki pomiarów i symulacji wybranych wskaźników jakości ścieków (N_{og} , $N-NH_4$, P_{og}) i obliczeń prawdopodobieństwa przekroczenia wartości $I_0 = 150 \text{ cm}^3/\text{g}$ dla oczyszczalni w Sitkówce – Nowiny.

Na podstawie wyznaczonych krzywych można stwierdzić, że w przypadku analizowanych zdarzeń w okresie zimy i wiosny wartości analizowanych wskaźników jakości ścieków były wyższe, niż w okresie wiosny i lata. Pogorszeniu jakości towarzyszyło również puchnięcie osadu, na co wskazują uzyskane wartości $p > 0,50$. Analizując wartości wskaźników jakości ścieków na wylocie z oczyszczalni stwierdzono, że w przypadku, gdy miało miejsce puchnięcie osadu, doszło również do przekroczenia dopuszczalnych wartości wskaźnika jakości dotyczącego N_{og} . Mogło to być związane ze stosunkowo niskim stężeniem osadu czynnego w okresie zimowym (rys. 8.18) i obniżoną temperaturą, co miało wpływ na kinetykę procesów biologicznego usuwania zanieczyszczeń.

W okresie letnim i wiosennym stwierdzono brak problemów z puchnięciem osadu (niskie wartości p) i do oczyszczalni na poziomie $86000 \text{ m}^3/\text{d}$. Niższe wartości wskaźników jakości ścieków na wylocie z oczyszczalni, niż w okresie zimowym. Wynikało to ze zmiany kinetyki procesów usuwania związków azotu

w bioreaktorze i wysokiego stężenia osadu czynnego, osiągającego lokalnie wartości na poziomie $5,6 \text{ kg/m}^3$, co przekracza wartość zalecaną do eksploatacji bioreaktorów w technologii osadu czynnego. Rozpatrując wartości DO mierzone w okresie letnim można stwierdzić, że zmieniały się one w zakresie $2,3 \div 3,0 \text{ mg/l}$, a w okresie zimowym ich zmienność była większa ($2,0 \div 3,2 \text{ mg/l}$). Maksymalna zanotowana wartość DO odpowiadała intensywnemu zdarzeniu opadowemu, któremu towarzyszył dopływ



Rys. 8.18. Koncentracja N_{og} , $N-NH_4$, P_{og} w ściekach odpływających z oczyszczalni i prawdopodobieństwo przekroczenia wartości $l_o = 150 \text{ cm}^3/\text{g}$ w zależności od wartości nastaw reaktora (X_{OC} , DO i m_{pIX}) dla oczyszczalni w Sitkówce–Nowiny.

Analiza obecnego stanu działania obiektu wskazuje, że w okresie letnim wydawała się możliwa eksploatacja obiektu przy niższych stężeniach osadu czynnego – nie większych, niż wartość zalecana równa $5,0 \text{ kg/m}^3$. W okresie zimowym należy zapewnić wartości wskaźników jakości ścieków poniżej wartości dopuszczalnych ($N_{og} < 10 \text{ mg/l}$), co jest możliwe poprzez zwiększenie stężenia osadu czynnego i stabilizację stężenia tlenu rozpuszczonego na względnie stałym poziomie nie przekraczającego wartości $DO = 2,5 \text{ mg/l}$.

Omówione ograniczenia można zapisać w postaci warunków:


$$\Phi_{z(s)} = \begin{cases} X_{OC}(t) \leq 5,0 \text{ kg} \cdot \text{m}^{-3} \\ DO(t) \leq 2,50 \text{ mg/l} \\ m_{PIX} = f(X_{OC}(t), DO(t)) \\ N_{og} \leq 10 \text{ mg/l} \\ P_{og} \leq 1 \text{ mg/l} \end{cases} \quad (8.22)$$

Z uwagi na to, że realizacja powyższych warunków jest możliwa dla dużej liczby kombinacji wartości parametrów operacyjnych reaktora, przyjęto w obliczeniach dodatkowe założenia: w okresie wiosenno–letnim wartości X_{OC} , DO i m_{PIX} , należy ustalić w taki sposób, aby $p \leq 0,50$ i jednocześnie aby nie przekroczyć na wylocie dopuszczalnych wartości wskaźników jakości; w okresie zimowym przyjęto $X_{OC} = 5,0 \text{ kg/m}^3$ i $DO = 2,25 \text{ mg/l}$, identyczne jak w modelu przedstawionym w punkcie 8.1, a ilość dawkowanego PIX przyjmowano opcjonalnie: a) identycznie, jak w obiekcie (S_a); b) minimalna dobowa dawka PIX nie mniejsza, niż $0,51 \text{ m}^3/\text{d}$; w przypadku przekroczenia stężenia P_{og} na wylocie ilość PIX jest wyznaczana w oparciu o opracowany model matematyczny (S_b).


Bazując na powyższych założeniach wykonano wariantowe obliczenia wartości X_{OC} , DO i m_{PIX} , dla przypadku, gdy pomiary wartości wskaźników stanowiących zmienne niezależne w modelach do prognozy N_{og} , $N\text{-NH}_4$ i P_{og} są ciągłe, oraz dla przypadku, gdy występują nieciągłości w pomiarach. Wyniki symulacji przedstawiono na rys. 8.19 i rys. 8.20.

Na podstawie wykonanych obliczeń stwierdzono, że w okresie zimowym można wyeliminować zdarzenia, gdy wartości N_{og} na odpływie przekraczają wartości dopuszczalne, stosując odpowiedni dobór nastaw w bioreaktorze w przypadku występowania nieciągłości w pomiarach wskaźników jakości ścieków. W okresie zimowym korekta nastaw X_{OC} , DO pozwoliła na poprawę jakości ścieków na wylocie z oczyszczalni w przypadku N_{og} i $N\text{-NH}_4$ oraz poprawę własności sedymentacyjnych osadu, na co wskazują obliczone wartości p , jednak nie wyeliminowano puchnięcia osadu, co wynika z wartości ($p > 0,5$) (rys. 8.19). Maksymalne wartości wskaźników jakości ścieków dla stanu obecnego obniżono w przypadku N_{og} do wartości z zakresu $9,0 \div 9,8 \text{ mg/l}$ oraz w przypadku P_{og} , od wartości $0,91 \text{ mg/l}$ do $0,35 \text{ mg/l}$ (wariant S_a). W badanym wariantcie obliczeń istnieje możliwość eliminacji puchnięcia osadu jedynie na drodze dawkowania koagulantu PIX, co wpłynęłoby pozytywnie na poprawę jakości ścieków w odniesieniu do P_{og} , i BZT_5 .

a)




b)




Rys. 8.19. Porównanie wartości nastaw w bioreaktorze (X_{OC} , DO i m_{PIX}) i wskaźników jakości ścieków na wylocie (N_{og} , $N-NH_4$ i P_{og}) dla stanu istniejącego i po optymalizacji dla wariantu uwzględniającego odpowiednio ciągłość (a) i nieciągłość (b) pomiarów wskaźników jakości na dopływie (ilość PIX dawkowana w okresie zimowym identyczna) dla oczyszczalni w Sitkówce – Nowiny.

a)



b)



Rys. 8.20. Porównanie wartości nastaw w bioreaktorze (X_{OC} , DO i m_{PIX}) i wskaźników jakości ścieków na wylocie z oczyszczalni (N_{og} , $N-NH_4$ i P_{og}) dla stanu istniejącego i po optymalizacji dla wariantu uwzględniającego odpowiednio ciągłość (a) i nieciągłość (b) pomiarów wskaźników na dopływie (ilość PIX dawkowana w okresie zimowym nie mniejsza, niż $0,51 \text{ m}^3/\text{d}$) dla oczyszczalni w Sitkówce–Nowiny.

W wariacie obliczeń uwzględniającym ciągłość danych pomiarowych dotyczących wskaźników jakości ścieków i minimalną dobową dawkę PIX w okresie zimy na poziomie $0,51 \text{ m}^3/\text{d}$ (S_b) stwierdzono wzrost wartości wskaźników jakości ścieków (P_{og}) w porównaniu z wariantem S_a od wartości $0,33 \text{ mg/l}$ do $0,74 \text{ mg/l}$.

Wykonane obliczenia wykazały, że w okresie letnim jest możliwa redukcja stężenia osadu czynnego (ma to wpływ na stopień recyrkulacji i stężenie osadu recykulowanego), stężenia tlenu rozpuszczonego (prowadzi to do redukcji objętości wprowadzanego powietrza), ilości dawkowanego PIX w stosunku do stanu istniejącego oraz jest możliwe niedopuszczenie do puchnięcia osadu czynnego, co potwierdzają uzyskane z symulacji wartości $p < 0,5$ (rys. 8.20). Co prawda, wartości wskaźników jakości ścieków (N_{og} , P_{og} , $N\text{-NH}_4$) zwiększyły się, jednak nie stwierdzono przekroczeń wartości dopuszczalnych ujętych w Rozporządzeniu Ministra Środowiska z dnia 18 listopada 2014 r. W okresie letnim w pojedynczych epizodach obliczone wartości p były znacznie mniejsze, niż $0,50$, i mieściły się w zakresie $0,10 \div 0,30$. W tych przypadkach nie była możliwa redukcja ilości podawanego PIX z uwagi na potencjalne przekroczenia wartości P_{og} powyżej wielkości dopuszczalnej.

Podsumowując powyższe wyniki analiz można stwierdzić, że zaproponowany w pracy algorytm umożliwiający dobór nastaw w bioreaktorze w przypadku nieciągłości w pomiarach wskaźników jakości ścieków, można zastosować na istniejącym obiekcie. Przedstawiona w pracy metodyka ma charakter uniwersalny i może być zaimplementowana na innych obiektach pod warunkiem, że są opracowane modele procesowe tych obiektów.

Opracowany algorytm pozwala na równoległą analizę i badanie interakcji między jakością ścieków na wylocie z oczyszczalni a zmianą zdolności sedymentacyjnych osadu czynnego. Wykonane analizy wykazały, że w okresie zimowym występują problemy z sedymentacją osadu i w wielu przypadkach jedynym rozwiązaniem jest dawkowanie koagulantów.

9. Podsumowanie i wnioski końcowe

Oczyszczalnia ściek6w stanowi złoŝony obiekt technologiczny, w którym zachodzi szereg proces6w biochemicznych. Podstawą oceny działania oczyszczalni jest uzyskiwanie na wylocie załoŝonej jakości ściek6w. Z uwagi na losowy i zaleŝny od pory roku charakter ilości i jakości ściek6w na doplywie, zapewnienie wymaganej jakości ściek6w na odplywie jest trudne. Wymaga to regulacji w trybie dynamicznym nastaw bioreaktora i wybranych obiekt6w technologicznych, co pozwala na spełnienie obowiązujących wymagań prawnych. W związku z powyŝszym podejmowane są próby wspomaganie procesu usuwania związk6w biogennych przy wykorzystaniu modeli matematycznych opracowanych na podstawie pomiar6w 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 przypadk6w stosuje się modele parametryczne (szarej lub czarnej skrzynki).

W przypadku obiekt6w, na których gromadzone są pomiary w trybie ciągłym (on-line) (ilość i jakość ściek6w na doplywie i odplywie z oczyszczalni, parametry operacyjne bioreaktora), takie modele pozwalają na uzyskanie zadowalającej jakości ściek6w na wylocie i obniŝenie koszt6w eksploatacyjnych. W przypadku braku ciągłości w pomiarach jakości ściek6w na doplywie do oczyszczalni, na przykłąd na skutek wadliwej pracy urządzeń pomiarowych lub gdy wartości wskaźnik6w oznaczane są drogą analityczną, modele matematyczne zasilane danymi w trybie on-line mają ograniczone zastosowanie. Wynika to z braku wartości liczbowych zmiennych niezaleŝnych 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 wynik6w. Należy rozwaŝyć kwestię, czy tworzyć modele o prostszej strukturze wymagające mniejszych nakład6w obliczeniowych i kr6tszego czasu obliczeń, czy może stosować modele bardziej złoŝone? Sformułowane zadanie jest trudne, bowiem stanowi kompromis między dokłądnością prognoz i złoŝonością modelu i ma istotny wplyw 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 wzmocnianych.

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.
- Aysha 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., Harremoes 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., Tchobanoglous 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., Adeloye 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., Edebalı 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