



UNIVERSITATEA BABEȘ-BOLYAI  
BABEȘ-BOLYAI TUDOMÁNYEGYETEM  
BABEȘ-BOLYAI UNIVERSITÄT  
BABEȘ-BOLYAI UNIVERSITY  
TRADITIO ET EXCELLENTIA

UNIVERSITATEA BABEȘ-BOLYAI  
Facultatea de Chimie și Inginerie Chimică



Rezumat

# **Modelare și Optimizare Bazate pe Rețele Neuronale Artificiale pentru Îmbunătățirea Operării Stației de Epurare a Apelor Uzate**

Student doctorand: Eng. Mihály Norbert-Botond

Coordonator științific: Prof. Dr. Eng. Vasile Mircea Cristea

Cluj-Napoca, 2024



## Cuprins rezumat

Cuprins rezumat .....	1
Cuprins teză .....	2
Cuvinte cheie .....	3
1. Introducere .....	4
1.1. Motivație și context.....	4
1.2. Modele utilizate în domeniul de studiu al stațiilor de epurare a apelor uzate .....	5
1.3. Modele de rețele neuronale artificiale [14] .....	10
1.4. Goal and objectives .....	13
2. Metode de simulare a stațiilor de epurare și de evaluare a performanțelor.....	15
2.1. Simularea stației de epurare cu BSM1 .....	15
2.2. Simularea stației de epurare cu BSM2 .....	17
2.3. Matlab/Simulink .....	17
2.4. Evaluarea funcționării stației de epurare.....	18
2.5. Modelarea și evaluarea RNA .....	19
3. Cazuri investigate de îmbunătățire a funcționării stației de epurare .....	21
3.1. Optimizarea debitului de reciclare pentru conducta de apă a stației de epurare a apelor uzate ..	21
3.2. Optimizarea punctului de reglaj al buclei de control pentru conducta de apă a stației de epurare a apelor uzate .....	23
3.3. Optimizarea debitului de aer pentru reactorul aerat a stației de epurare .....	27
3.4. Optimizarea sezonieră a punctului de setare OD pentru instalația de tratare a apei uzate la scară completă.....	34
4. Detectarea și identificarea tipurilor de defecțiuni ale senzorilor OD.....	41
5. Concluzii finale.....	44
Referințe.....	48

## Cuprins teză

Summary .....	I
Rezumat .....	IV
List of publications and conferences.....	VII
Acknowledgements.....	IX
Table of contents.....	X
Nomenclature.....	XII
List of figures.....	XVII
List of tables.....	XIX
1. Introduction.....	1
1.1. Motivation and background .....	1
1.2. Goals and objectives .....	12
1.3. Models commonly used in the WWTP field of study.....	14
1.3.1. Activated Sludge Model No. 1 .....	14
1.3.2. Activated Sludge Model No. 2d.....	19
1.4. Artificial neural network models .....	27
2. WWTP simulation and performance assessment methods .....	33
2.1. WWTP simulation with BSM1 .....	33
2.2. WWTP simulation with BSM2 .....	36
2.3. Matlab/Simulink .....	38
2.4. WWTP operation evaluation.....	41
2.5. ANN modelling and evaluation .....	43
2.5.1. Studied artificial neural network types .....	43
2.5.2. ANN evaluation criteria .....	45
3. WWTP operation enhancement investigated cases.....	47
3.1. Optimization of WWTP waterline recycle flowrates.....	50
3.1.1. Model development.....	51
3.1.2. Artificial neural network type and architecture .....	52
3.1.3. Selection criteria for ANN topology .....	53
3.1.4. Optimization task .....	54
3.1.5. Results and discussion .....	54
3.1.6. Conclusions.....	59
3.2. Optimization of WWTP waterline control loop setpoints.....	59



3.2.1.	Model development.....	60
3.2.2.	Artificial neural network type and architecture .....	62
3.2.1.	Optimization task .....	67
3.2.2.	Results and discussion .....	67
3.2.3.	Conclusions.....	83
3.3.	Optimization of WWTP air flowrate distribution .....	85
3.3.1.	Model development.....	85
3.3.2.	Optimization task .....	91
3.3.3.	Results and discussion .....	93
3.3.4.	Conclusions.....	105
3.4.	Seasonal optimization of DO control loop setpoint for the water and sludge processing WWTP lines .....	106
3.4.1.	Model development.....	106
3.4.2.	Optimization task .....	112
3.4.3.	Results and discussion .....	112
3.4.4.	Conclusions.....	122
4.	Detection and identification of DO sensor fault types via ANN models .....	123
4.1.	Model development .....	124
4.1.1.	Data generation .....	124
4.1.2.	ANN architecture .....	125
4.2.	Results and discussion .....	126
4.3.	Conclusions.....	129
5.	Concluding remarks .....	131
	References.....	136

## **Cuvinte cheie**


stație de epurare a apelor uzate; modelare prin rețele neuronale artificiale; emisii de gaze cu efect de seră; calitatea efluentului; consum de energie; algoritmi genetici; optimizarea funcționării stației; detectarea și identificarea defecțiunilor.

## 1. Introducere

### 1.1. Motivație și context

Gazele cu efect de seră (GHG) sunt necesare pentru ca viața să existe pe Pământ, deoarece acestea produc efectul de seră, care ajută planeta să rețină căldura de la soare și determină încălzirea naturală a suprafeței, însă, atunci când concentrațiile de GHG cresc excesiv, căldura suplimentară este captată, ceea ce duce la creșterea temperaturii globale [1].

Cele trei principale GHG antropogene sunt dioxidul de carbon ( $\text{CO}_2$ ), metanul ( $\text{CH}_4$ ) și protoxidul de azot ( $\text{N}_2\text{O}$ ), cu niveluri diferite de contribuție la încălzirea globală. Concentrațiile atmosferice de GHG au atins maxime istorice în 2019 pentru  $\text{CO}_2$  (410 ppm),  $\text{CH}_4$  (1866 ppb), precum și pentru  $\text{N}_2\text{O}$  (332 ppb), așa cum este ilustrat în Figura 1.1. Acestea au contribuit la o creștere a temperaturii globale la suprafață de aproximativ 1,1 °C în comparație cu valorile din perioada 1850-1900 [2].



**Figura 1.1** Creșterea concentrațiilor de gaze cu efect de seră în atmosferă [2]

De asemenea, este important să se țină seama de sursele de emisii de GHG și de activitățile care contribuie la emisiile la scară globală, împreună cu tipul de gaze aferente fiecărei activități, prezentate în

Figura 1.6 pentru 2019. Sectorul energetic reprezintă aproape 76% din totalul emisiilor, producția de energie electrică și termică reprezentând cea mai mare parte, de 31,8%. Agenția Internațională a Energiei (IEA) [3] a stabilit că, în 2019, în ciuda unei scăderi de 1,3 % a emisiilor de CO<sub>2</sub> provenite din producția de energie, sectorul energetic a rămas principala sursă a acestor emisii, reprezentând 41 % din toate emisiile de CO<sub>2</sub> legate de energie [4].

Emisiile de ape uzate cuprind toate GHG majore, deoarece acumularea de materie organică și reziduuri de la plante, animale, oameni și deșeurile produse de aceștia se descompun, rezultând în emisii de dioxid de carbon, metan, precum și de protoxid de azot [5,6]. Apei reziduale i se atribuie 1,3% din emisiile globale de GHG și aproximativ 1% din consumul de energie la nivel mondial. În consecință, a crescut popularitatea investigării consumului de energie și a emisiilor de GHG ale acestora.

Tratarea apelor uzate municipale a fost adesea efectuată într-un mod nesustenabil, cu o cerere semnificativă de energie, ceea ce a avut ca rezultat un impact substanțial asupra schimbărilor climatice. Cantitatea și calitatea apelor uzate influente, precum și metoda de tratare au un impact semnificativ asupra consumului de energie a stațiilor de epurare [7]. Cantitatea de apă uzată produsă la nivel mondial este în continuă creștere datorită creșterii populației umane și ritmului accelerat al industrializării [8], urmând să se atingă o creștere de 51% până în 2050 în comparație cu nivelurile actuale [9]. În același timp, reglementările din ce în ce mai stricte privind calitatea efluenților au dus la dezvoltarea și aplicarea unor tehnologii de tratare mai avansate, însă acestea au crescut și consumul de energie a instalațiilor [10]. Deoarece majoritatea energiei provine din surse neregenerabile, peste 70% din producția mondială de energie în 2022, generarea acesteia este însoțită de emisii semnificative de GHG [11].

Cercetarea tehnologiilor de control al stațiilor de epurare a apelor uzate în vederea reducerii emisiilor de gaze cu efect de seră capătă importanță având în vedere acordurile internaționale, în special în cazul stațiilor urbane care se confruntă cu o creștere constantă a debitului de influent, în timp ce se străduiesc să îndeplinească obiectivele de reducere a emisiilor de gaze cu efect de seră. Reducerea consumului energetic și a emisiilor de GHG în stațiile de epurare a apelor uzate poate fi realizată prin optimizarea eficienței energetice în ceea ce privește structura și echipamentele, procesele de recuperare a energiei, procedurile tehnice și gestionarea costurilor. Este clar că adoptarea unei strategii mai eficiente din punct de vedere energetic poate reduce atât costurile operaționale, cât și consumul de energie [12].

## **1.2. Modele utilizate în domeniul de studiu al stațiilor de epurare a apelor uzate**

Modelarea procesului de procesare a nămolului activat este în prezent frecvent utilizată în proiectarea și exploatarea stațiilor de epurare. Este necesar să se ia în considerare numeroși factori atunci când se

simulează sisteme ce țin de nămolul activat, care cuprind procese precum oxidarea carbonului, nitrificarea și denitrificarea. Primul obiectiv a fost dezvoltarea unui model cu un nivel minim de complexitate, ceea ce a dus la modelul de nămol activ Nr. 1, cunoscut și sub numele de ASM1. Când cunoștințele privind procesele care stau la baza eliminării biologice a fosforului au crescut, grupul operativ a integrat atât transformarea biologică a azotului, cât și transformarea biologică a fosforului într-un nou model, Modelul nămolului activat nr. 2 (ASM2). Modelul ASM2 a fost extins la Modelul de nămol activat Nr. 2d (ASM2d) prin includerea organismelor acumuloare de fosfor (OAP) denitrificatoare. Cea mai recentă platformă de modelare, Modelul de nămol activat Nr. 3, a fost dezvoltată cu potențialul de a urmări compușii de stocare internă, care sunt cruciali pentru metabolismul organismelor [13].

### 1.2.1. Modelul de nămol activat Nr. 1

Grupul operativ a acceptat ideea unor funcții de comutare care să activeze și dezactiveze ecuațiile ratei de proces pe măsură ce condițiile de mediu sunt modificate. Acest lucru a fost deosebit de important pentru procesele care depind de tipul de acceptor de electroni disponibil, deoarece procesele biologice depind de bacteriile heterotrofe sau autotrofe. Acest fenomen poate fi descris prin încorporarea unui comutator de oxigen dizolvat în ecuațiile ratei procesului, așa cum este prezentat în Ecuația (1.1).

$$\frac{S_O}{K_O + S_O} \quad (1.1)$$

unde  $S_O$  reprezintă nivelul de oxigen dizolvat.

În acest mod, prin atribuirea unei valori relativ mai mici lui  $K_O$ , valoarea funcției de comutare este apropiată de unitate pentru concentrații moderate de oxigen dizolvat (DO), dar scade la zero atunci când concentrația de DO ajunge la zero. O abordare similară poate fi adoptată pentru procesele care necesită absența oxigenului dizolvat printr-o funcție de comutare în forma prezentată în ecuația (1.2).

$$\frac{K_O}{K_O + S_O} \quad (1.2)$$

Un alt aspect important al modelului este faptul că materia organică prezentă în apele reziduale a fost subdivizată în mai multe categorii, precum și faptul că atât bilanțurile de masă, cât și concentrațiile s-au bazat pe unități de consum chimic de oxigen (COD). Această unitate a fost selectată dintre cele trei măsuri utilizate în mod obișnuit, și anume, consum biologic de oxigen (BOD), carbonul organic total și COD, deoarece s-a considerat că oferă o legătură nu numai între biomasă și consumul de oxigen, ci și cu echivalentele electronice din substrat.

Prima distincție între tipurile de materie organică poate fi făcută pe baza biodegradabilității acestora. Un material nebiodegradabil trece nealterat atunci când intră într-un sistem de nămol activat, deoarece este biologic inert. O altă subdiviziune poate fi făcută ținând cont de starea fizică a materiei, care poate fi solubilă

sau sub formă de particule. Materia solubilă inertă este notată ca  $S_I$ , iar concentrația acesteia în efluent rămâne neschimbată în comparație cu concentrația din efluent. Materia în suspensie,  $X_I$ , este eliminată din sistem ca deșeu de nămol, după ce a fost încurcată în nămolul activat. În mod similar, materia organică biodegradabilă poate fi, de asemenea, împărțită în părți ușor biodegradabile și părți lent biodegradabile. Pentru a ușura procesul de modelare, partea ușor biodegradabilă, notată ca  $S_S$ , este considerată solubilă, în timp ce materia lent biodegradabilă ( $X_S$ ) este considerată particule.

Biomasa heterotrofă ( $X_{B,H}$ ) este produsă fie în condiții anoxice, fie în condiții aerobe, prin creșterea pe substrat ușor biodegradabil și se consideră că se oprește în condiții anaerobe. Pierderea de biomasă datorată descompunerii este, de asemenea, încorporată în model, luând în considerare moartea, prădarea, liza și metabolismul endogen. Se consideră că acest proces are ca rezultat un substrat lent biodegradabil și alte particule,  $X_P$ , care nu participă la procesele biologice ulterioare.

La fel ca în cazul materiei carbonatate, materia azotată din apele uzate poate fi, de asemenea, împărțită în două categorii: nebiodegradabilă și biodegradabilă, fiecare dintre acestea având subcategorii suplimentare. Partea de particule a compușilor de azot nebiodegradabili este legată de COD de particule nebiodegradabile, în timp ce categoria solubilă a fost aleasă să nu fie detaliată în model din cauza cantității sale minore. În ceea ce privește materia azotată biodegradabilă, aceasta poate fi împărțită în: amoniac ( $S_{NH}$ ), adică compusul liber, precum și sărurile sale; azot organic solubil, notat ca  $S_{ND}$ ; și azot organic sub formă de particule,  $X_{ND}$ . Bacteriile heterotrofe interacționează cu azotul organic solubil și îl transformă în azot amoniacal. Azotul amoniacal este apoi utilizat ca sursă de energie pentru bacteriile nitrificatoare autotrofe, precum și ca sursă de azot pentru sinteza biomasei heterotrofe. Din motive de simplitate, se presupune că transformarea autotrofică a azotului amoniacal în azot nitrat este un proces într-o singură etapă care necesită oxigen. Figura 1.3 ilustrează interacțiunile complexe ale componentelor sistemului, modelate ca 8 procese în ASM1.



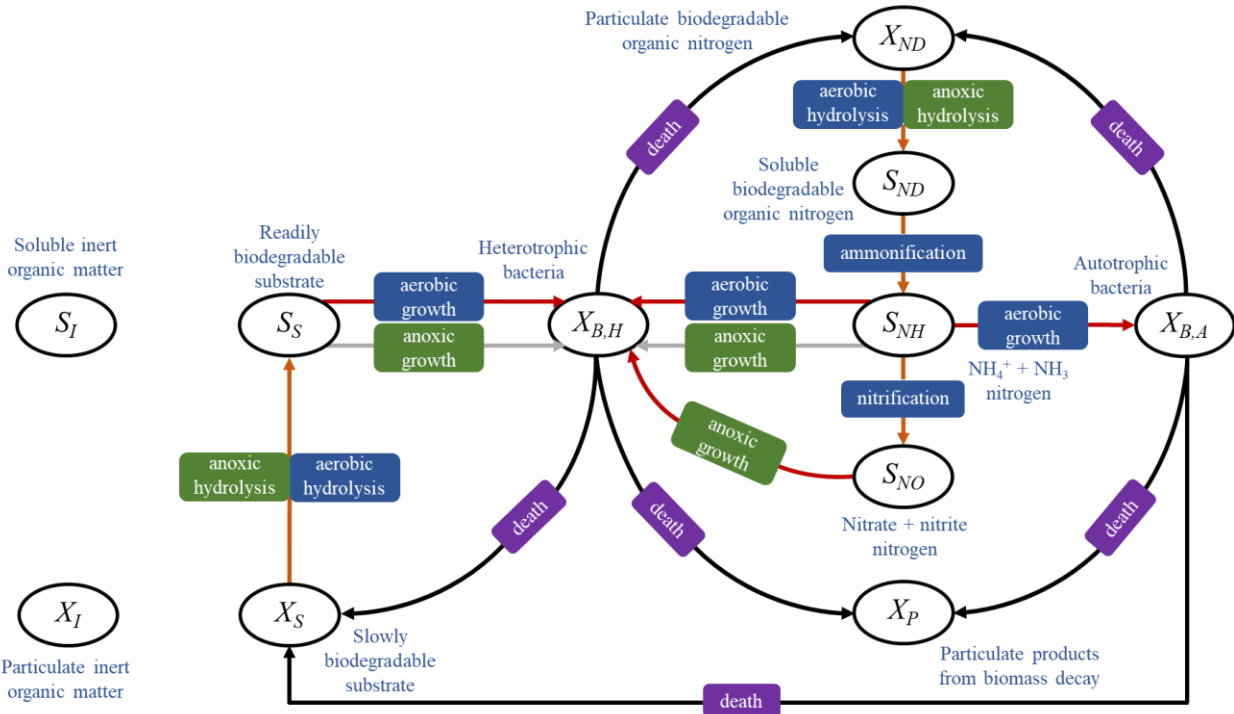


Figura 1.2 Schema generală a ASM1

### 1.2.2. Modelul de nămol activat Nr. 2d

Pentru a lua în considerare ideea că organismele acumuloare de fosfor (OAP) pot utiliza produsele de stocare organică internă a celulelor pentru denitrificare, au fost introduse încă două procese. ASM2d prezintă OAP care denitrifică, spre deosebire de ASM2, care a limitat creșterea OAP doar la condiții aerobe.

ASM2 include polifosfați, o parte a nămolului activat care este crucială pentru funcționarea sistemului de nămol activat, dar care nu exercită COD, spre deosebire de ASM1, care se bazează exclusiv pe COD pentru toate materialele organice sub formă de particule și pe concentrația totală a nămolului activat. Acest lucru conduce la potențialul de includere a totalului de solide în suspensie (TSS) în model. În plus, TSS permite încorporarea particulelor solide minerale în suspensie în apele de intrare în instalațiile de tratare, precum și crearea unor astfel de particule în contextul precipitării fosforului.

Comparativ cu cele 8 procese care au fost luate în considerare pentru dezvoltarea ASM1, ASM2d încorporează un total de 21 de procese, care sunt descrise pe scurt mai jos.

Reacțiile de hidroliză depind, de fapt, de acceptorul de electroni prezent și, ca atare, au fost diferențiate trei procese pentru a descrie complet procesul de hidroliză:

1. Hidroliza aerobă a substratului lent biodegradabil, care are loc în condiții aerobe.
2. Hidroliza anoxică a substratului lent biodegradabil, care are loc în condiții anoxice.

3. Hidroliza anaerobă a substratului biodegradabil lent, care descrie procesul de hidroliză în mediu anaerob.

Hidroliza substratului lent biodegradabil, degradarea aerobă a produselor de fermentație și a substraturilor (creștere aerobă), oxidarea anoxică a substanțelor organice fermentabile ( $S_F$ ) și a produselor de fermentație ( $S_A$ ), reducerea nitratului  $S_{NO_3}$  (denitrificare) și fermentarea anaerobă a substanțelor organice fermentabile în produse de fermentație sunt toate efectuate de organismele heterotrofe. Aceste organisme sunt, de asemenea, susceptibile la liză și degradare.

4. și 5. Organismele heterotrofe se dezvoltă aerob pe substraturi fermentescibile și produse de fermentație. Cele două substraturi organice degradabile  $S_F$  și  $S_A$  sunt consumate în aceste două procese, care au fost considerate procese paralele.

6. și 7. Organismele heterotrofe se dezvoltă în anoxie pe substraturi fermentescibile și pe produse de fermentație, însoțite de denitrificare. Acestea sunt comparabile cu cele două procese de creștere aerobă, însă este nevoie de nitrat,  $S_{NO_3}$ , ca acceptor de electroni, spre deosebire de oxigen.

8. Fermentația organismelor heterotrofe care se presupune că se desfășoară în condiții anaerobe, în care produsele de fermentație  $S_A$  sunt obținute din substratul ușor biodegradabil  $S_F$ .

9. Liza organismelor heterotrofe, în care se iau în considerare toate procesele de descompunere și pierdere care se referă la organismele heterotrofe.

Se știe că organismele care acumulează fosfor ( $X_{PAO}$ ) au capacitatea de a stoca fosforul sub formă de polifosfat  $X_{PP}$ . Capacitatea anumitor OAP de a se denitrifica a fost demonstrată, contrar presupunerilor anterioare conform cărora acestea nu ar putea. Această obiecție majoră, conform căreia OAP contribuie în mod considerabil la denitrificare, care nu este specificată în ASM2, a fost abordată odată cu apariția ASM2d. În acest model (ASM2d) se consideră că procesele care implică OAP au loc atât în condiții aerobe, cât și anoxice. Cu toate acestea, creșterea lor este limitată la materialele organice interne ale celulei ( $X_{PHA}$ ).

10. Pentru a stoca produsele de fermentație externă ale celulelor  $S_A$  sub formă de material organic intern al celulelor  $X_{PHA}$ , se presupune că OAP pot elibera fosfat,  $S_{PO_4}$ , din polifosfat,  $X_{PP}$ , și pot utiliza energia care devine disponibilă din hidroliza  $X_{PP}$ .

11. și 12. Polifosfatul se stochează atât în condiții aerobe, cât și anoxice. Energia pentru OAP poate fi obținută din respirația aerobă sau anoxică a  $X_{PHA}$  pentru a stoca ortofosfatul,  $S_{PO_4}$ , sub formă de polifosfați interni celulelor,  $X_{PP}$ .

13. și 14. Creșterea organismelor care acumulează fosfor în condiții anoxice și aerobe. Se consideră că aceste organisme cresc numai prin utilizarea produselor de stocare organică internă a celulelor ( $X_{PHA}$ ). Este rezonabil să presupunem că organismele utilizează ortofosfatul,  $S_{PO_4}$ , ca nutrient pentru sinteza biomasei, deoarece fosforul este produs în mod continuu prin liza  $X_{PP}$ .

15., 16. și 17. Toate fracțiunile OAP se pierd sau se descompun ca urmare a morții, a respirației endogene sau a întreținerii.

În ceea ce privește procesul de nitrificare, se consideră că transformarea amoniului în nitrat are loc direct, într-un proces într-o singură etapă, în timp ce nitritul, ca și compus intermediar, nu este luat în considerare ca și componentă pentru model.

18. Organismele nitrificatoare se dezvoltă în mediu aerob, consumând amoniu ca nutrient și substrat, ceea ce duce la producerea de nitrați. Acest proces de nitrificare reduce, de asemenea, alcalinitatea.

19. Liza nitrifcătorilor este modelată în mod analog cu liza organismelor heterotrofe și cu ASM1.

20. Ultimele două procese integrate în ASM2d descriu precipitarea chimică a fosfaților. În sistemele biologice de eliminare a nutrienților, metalele prezente în mod natural în apele reziduale, de exemplu, cum ar fi  $Ca^{2+}$ , și concentrația ridicată de ortofosfat solubil eliberat,  $S_{PO4}$ , pot determina precipitarea chimică a fosforului (de exemplu, sub formă de apatită sau fosfat de calciu). O altă metodă utilizată pe scară largă pentru eliminarea fosforului este precipitarea simultană a fosforului cu adăugarea de săruri de fier sau de aluminiu. Îndepărtarea biologică a fosforului poate fi combinată cu precipitarea simultană în cazul în care raportul dintre carbon și fosfor este nefavorabil de scăzut.

20. Și 21. La baza modelului de precipitare stă presupunerea că precipitarea și redisoluția sunt procese opuse care, în stare de echilibru, se află în echilibru unul cu celălalt, așa cum este descris în reacția de echilibru Ecuația (1.1).



Următoarele viteze de reacție pot fi aplicate pentru a modela procesele de precipitare și de redoluție:

$$rate_{20} = k_{PRE} \cdot S_{PO4} \cdot X_{MeOH} \quad (1.2)$$

$$rate_{21} = k_{RED} \cdot X_{MeP} \quad (1.3)$$

În cazul în care procesele sunt în echilibru, constanta de echilibru poate fi scrisă sub forma:


$$K_{eq} = \frac{S_{PO4} \cdot X_{MeOH}}{X_{MeP}} \quad (1.4)$$

### 1.3. Modele de rețele neuronale artificiale [14]

Rețelele neuronale artificiale sunt procesoare paralele distribuite, alcătuite din unități de procesare de bază numite neuroni, care sunt modelate după sistemele neuronale naturale. RNA se încadrează în categoria modelelor de învățare automată care au capacități ridicate de generalizare și de învățare pentru o serie de sarcini de clasificare, predicție și modelare [15].

Blocul de bază al unei rețele neuronale artificiale, și anume neuronii, este ilustrat într-o formă generală în figura 1.4. Datele de intrare ( $p$ ) sunt vehiculate printr-o conexiune care le multiplică cu o greutate ( $w$ ). Înclinația ( $b$ ), care are o valoare constantă de 1, este apoi adăugată la produsul multiplicării anterioare

pentru a forma intrarea netă ( $n$ ). Intrarea netă este transmisă în continuare pentru a deveni argumentul unei funcții de transfer ( $f$ ), care este de obicei o funcție în trepte sau un fel de funcție sigmoidă, care produce ieșirea neuronului ( $a$ ).




**Figure 1.3** Schema unui neuron cu bias

Neuronul poate avea mai multe intrări în același timp sau un vector de date de intrare. În acest caz, fiecare dintre intrări este transmisă printr-o conexiune separată, cu propria sa greutate distinctă, așa cum este ilustrat în figura 1.4. Ca atare, intrarea netă va fi calculată ca produsul punctat al ponderilor și intrărilor, prezentat, de asemenea, în Ecuația (1.5).

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,N}p_N + b \quad (1.5)$$

unde  $N$  este numărul de elemente din vectorul de intrare.



**Figura 1.4** Reprezentarea unui neuron cu intrări multiple

Se pot utiliza mai mulți neuroni pentru a crea un strat de neuroni. O rețea neuronală artificială este alcătuită din unul sau mai multe straturi, precum cel ilustrat în figura 1.5. Numărul de neuroni din strat este notat cu  $L$  și se poate observa că, în cazul mai multor straturi, informația de intrare este transmisă printr-o matrice de ponderi cu  $L$  rânduri și  $N$  coloane. Indicii din matrice indică sursa și destinația informației, adică de la elementul  $N$  la neuronul  $L$ . În acest caz, se poate observa că stratul de neuroni va furniza un vector de ieșiri format din  $L$  elemente.




Figura 1.5 Ilustrație a unui strat de neuroni

După cum s-a menționat anterior, o RNA poate fi creată prin conectarea mai multor astfel de straturi de neuroni, de exemplu, rețeaua cu trei straturi prezentată în figura 1.6. În acest caz, se va adăuga o notație la toate elementele de arhitectură pentru a ține evidența stratului din care fac parte. Acest lucru permite ca fiecare strat să fie tratat ca o rețea separată cu un singur strat. Straturile finale în care se calculează ieșirile RNA sunt denumite de obicei strat de ieșire, în timp ce celelalte sunt cunoscute ca straturi ascunse. Primele două straturi (stratul 1 și stratul 2) ale RNA ilustrate sunt straturi ascunse, în timp ce ultimul strat (stratul 3) este stratul de ieșire.




Figura 1.6 Arhitectura unei RNA cu trei straturi

#### 1.4. Scopul și obiectivele

Scopul acestei teze este evaluarea și optimizarea performanțelor diferitelor tehnologii și strategii de tratare a apelor uzate aplicate la procesele de tratare a apelor uzate urbane cu consum mare de energie prin utilizarea tehnicilor de inteligență artificială (AI), cu scopul de a obține potențiale îmbunătățiri ale eficienței energetice, reducerea costurilor și a emisiilor de gaze cu efect de seră. În cele ce urmează este prezentată o listă a obiectivelor care trebuie îndeplinite pentru a atinge scopurile propuse:

1. O analiză aprofundată a literaturii de specialitate pentru a înțelege stadiul actual al cercetării și tehnologiile de ultimă oră.
2. Dezvoltarea de modele de inteligență artificială pentru diferite configurații de stații de epurare a apelor uzate și strategii de control pentru a obține un model de operare rapidă care poate fi utilizat ulterior în optimizarea procesului de epurare a apelor uzate în ceea ce privește îmbunătățirile de mediu și economice.
3. Optimizarea fidelității modelului AI prin studiul arhitecturii modelului, în cazul rețelelor neuronale artificiale (RNA), prin căutarea celor mai bune valori ale hiperparametrilor prin intermediul proceselor de optimizare atât factorială completă, cât și prin algoritmi genetici.
4. Simularea și optimizarea strategiilor de control existente și propuse în legătură cu eficiența energetică, emisiile de GHG, calitatea efluenților și costul total, luând în considerare mai multe configurații ale sistemului de stații de epurare, prin utilizarea modelelor AI dezvoltate.
5. Elaborarea unor modele RNA pentru detectarea și identificarea tipurilor de defecte ale senzorilor care vizează senzorul de oxigen dizolvat (DO) în vederea asigurării unei funcționări corecte a stației de epurare prin evitarea degradării calității efluentului sau a creșterii consumului de energie datorită detectării și identificării rapide a defectelor.

Stațiile de epurare a apelor uzate reprezintă 1-2% din totalul emisiilor de gaze cu efect de seră, cu o traiectorie ascendentă [16], ceea ce a dus la o creștere a atenției asupra subiectului încălzirii globale [17]. Dintre cele trei gaze principale, tratarea biologică este responsabilă pentru majoritatea emisiilor de CH<sub>4</sub> și N<sub>2</sub>O, în timp ce emisiile de CO<sub>2</sub> non-biogene sunt legate de consumul de energie al stației și de utilizarea substanțelor chimice [18]. În ceea ce privește emisiile biogene de CO<sub>2</sub>, acestea nu trebuie luate în considerare pentru inventarele de emisii de GHG [19], deși acest lucru ar putea duce la o subestimare a emisiilor de GHG de la stațiile de epurare [20]. De asemenea, tratarea biologică poate atinge un consum de energie de 50% până la 70% din cererea de energie a stațiilor de epurare, în cazul instalațiilor din China [5]. În același timp, cea mai mare parte a amprentei de carbon a instalației, adică până la 78,4%, poate fi atribuită emisiilor de N<sub>2</sub>O [21]. Ca atare, procesul de denitrificare, și anume procesul de aerare, joacă un

rol esențial în funcționarea optimă a stației de epurare, iar studiile privind influența DO asupra funcționării instalațiilor au crescut în popularitate [22].

Un alt aspect important în menținerea unei funcționări durabile este reprezentat de defecțiunile senzorilor, deoarece acestea aduc perturbări enorme în controlul procesului și în eficiența energetică [23]. Aceste defecțiuni ale senzorilor pot apărea ca urmare a condițiilor dificile de mediu, a defecțiunilor electrice sau chiar a calibrării incorecte [24], iar detectarea lor în timp util este esențială pentru atenuarea impactului potențial al acestor defecțiuni și pentru menținerea integrității procesului [25].

Se preconizează că volumul de ape uzate va crește odată cu populația și economia, în timp ce standardele pentru apele efluate vor deveni mai stricte, ceea ce va duce, de asemenea, la o creștere a emisiilor de GHG [26]. Luând în considerare toate cele de mai sus, au fost selectate următoarele studii de caz:

1. Optimizarea debitului de reciclare pentru conducta de apă a stației de epurare a apelor uzate
2. Optimizarea punctului de reglaj al buclei de control pentru conducta de apă a stației de epurare a apelor uzate
3. Optimizarea debitului de aer pentru reactorul aerat a stației de epurare
4. Optimizarea sezonieră a punctului de setare DO pentru instalația de tratare a apei uzate la scară completă
5. Detectarea și identificarea tipurilor de defecțiuni ale senzorilor DO

## 2. Metode de simulare a stațiilor de epurare și de evaluare a performanțelor

A fost necesar să se definească un mediu de simulare de referință pentru evaluarea bazată pe simulare a strategiilor propuse pentru stațiile de epurare. În elaborarea criteriilor de referință s-a urmărit combinarea simplității cu realitatea și standardele convenționale. Scopul acestor modele de simulare a fost ca, odată validată, strategia de control propusă să poată fi utilizată și evaluată în funcție de un set de criterii bine definite. De-a lungul anilor au fost elaborate mai multe astfel de modele de simulare de referință (BSM).

### 2.1. Simularea stației de epurare cu BSM1

Primul simulator de referință ia în considerare o configurație relativ simplă a instalației, axată în întregime pe linia de apă a stației de epurare (Figura 2.1). Sistemul este format dintr-un bioreactor cu cinci compartimente cu configurație anoxică-oxică care utilizează ASM1 pentru modelarea variabilelor de proces, cunoscut și sub numele de AO, urmat de un decantor secundar (clarificator) modelat utilizând funcția de viteză de decantare dublu-exponențială propusă de Takács et al. [59]. Dintre cele cinci reactoare, primele două sunt considerate reactor anoxic, în timp ce ultimele trei reactoare sunt aerisite prin aer comprimat. Aceasta este una dintre abordările comune pentru eliminarea biologică a nutrienților care combină procesele de nitrificare și predenitrificare, care este, de asemenea, frecvent utilizată în stațiile de epurare la scară reală. Pentru descrierea proceselor biologice care au loc în reactoare s-a adoptat ASM1.

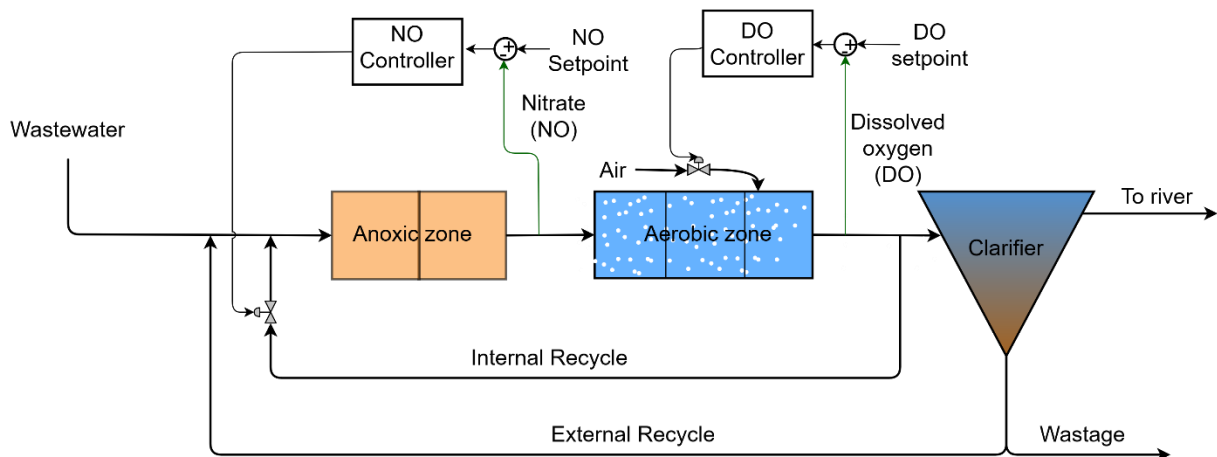
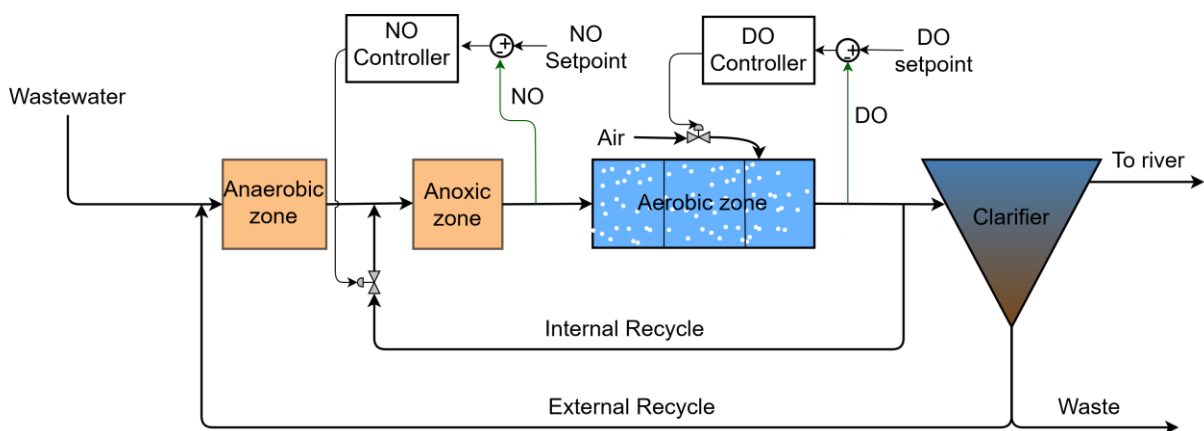


Figura 2.1 Prezentare generală a instalației BSM1

Deși BSM1 oferă o abordare adoptată în mod obișnuit pentru sistemele de tratare a apelor uzate și pune bazele unei descrieri realiste a unei stații de epurare a apelor uzate la scară largă, nu toate stațiile utilizează



metoda prezentată. Acesta este și cazul uzinei municipale locale, unde se folosește un sistem anaerob-anoxic-oxic  $A^2O$ . Metoda anoxică-aerobă utilizată în configurația BSM1 permite instalației să îndeplinească cerințele stricte de eliminare a COD și a azotului total, în timp ce strategia  $A^2O$  este concepută pentru a îndeplini nu numai limitele de reglementare a carbonului și a azotului total, ci și alte cerințe de eliminare a nutrienților care nu sunt luate în considerare în modelul clasic ASM1, cum ar fi fosforul total. În ceea ce privește amenajarea instalației, diferența dintre cele două metode constă în conectarea fluxului intern de reciclare. Se poate observa că, în configurația BSM1, ambele fluxuri de reciclare sunt conectate la apele reziduale influente, în timp ce în cazul unei metode de tratare  $A^2O$ , fluxurile de reciclare internă se conectează între primul și al doilea bioreactor (Figura 2.2).



**Figura 2.2** Prezentare generală a unei stații de epurare care utilizează metoda de tratare  $A^2O$

Atunci când se încearcă să se adapteze și să se calibreze BSM1 pe baza datelor de la stația municipală locală de epurare a apelor uzate, mai degrabă decât o ușoară modificare a configurației instalației, calibrarea parametrilor stoichiometrici și cinetici care descriu procesele biologice reprezintă o provocare mult mai mare. Munca impresionantă de calibrare a modelului BSM1 a fost realizată de o colegă de doctorat, Melinda Simon-Várhelyi, iar informații suplimentare despre acest subiect pot fi găsite în cercetarea lor [27].

Referitor la controlul utilizat în macheta BSM1, se poate observa că sunt utilizate două bucle de control PI. Prima reglează concentrația de nitrați și nitriți din efluentul celui de-al doilea reactor prin manipularea debitului fluxului de reciclare internă pe baza concentrației de nitrați și nitriți din efluentul celui de-al doilea reactor. În timp ce cea de-a doua buclă de control este responsabilă de nivelul de oxigen dizolvat din efluentul celui de-al cincilea bioreactor, acționând asupra debitului de aer care se îndreaptă spre ultimele trei reactoare pe baza nivelului de oxigen dizolvat din efluentul celui de-al cincilea bioreactor.

## 2.2. Simularea stației de epurare cu BSM2

Modelul de simulare de referință nr. 2 a fost elaborat în baza conceptului de model pe termen lung și la nivelul întregii uzine. Aceasta a fost o extindere necesară, deoarece unul dintre neajunsurile BSM1 a fost că o evaluare aprofundată pe termen lung a funcționării instalației sau a diferitelor strategii de control necesita o perioadă de evaluare mai lungă. Configurația instalației BSM1 a fost actualizată cu pretratarea apelor uzate în linia de apă și cu procesele din linia de nămol, inclusiv digestia anaerobă. Perioada de evaluare prelungită permite o evaluare mai aprofundată a funcționării instalației și a strategiilor de control, permițând luarea în considerare și a proceselor cu dinamică lentă.

BSM2 include un clarificator primar situat înaintea reactoarelor cu nămol activat, care este descris de modelul Otterpohl [28]. Pentru a modela o stație de epurare la scară completă, modelul BSM2 conține, de asemenea, un îngroșător de nămol, un digester anaerob, un sistem de deshidratare și un rezervor de stocare, după cum se poate observa în Figura 2.3.

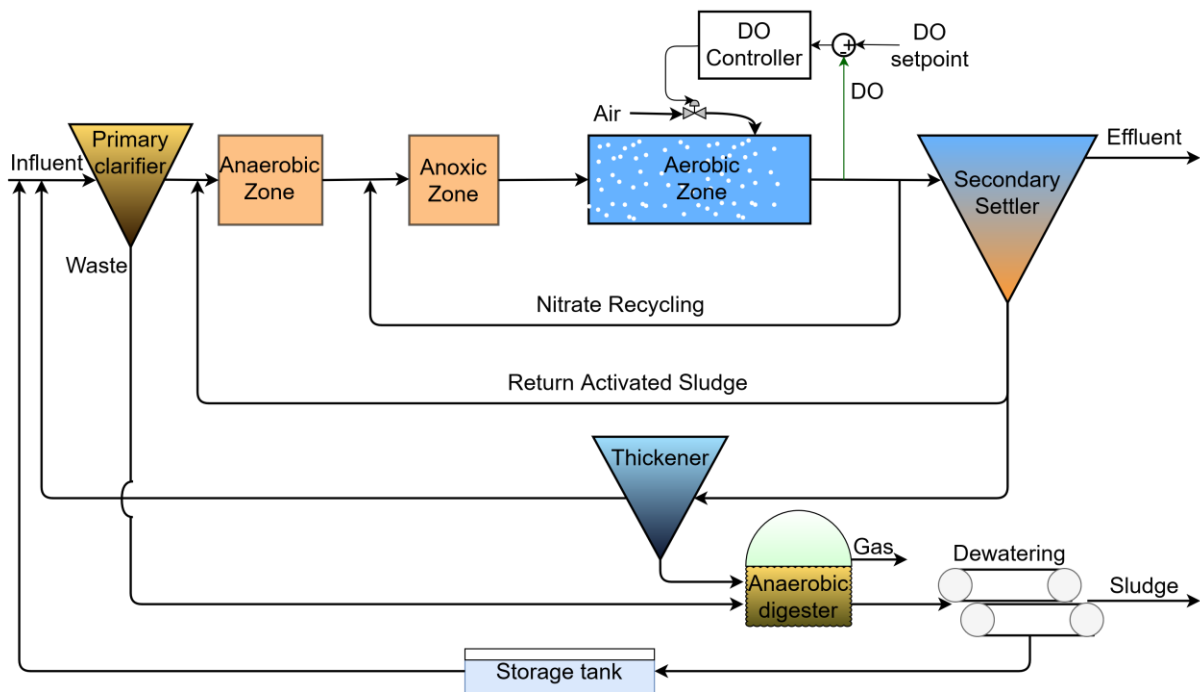



Figura 2.3 Reprezentare schematică a instalației BSM2

## 2.3. Matlab/Simulink

Matlab este atât un limbaj de programare, cât și un mediu de calcul numeric, care oferă instrumente pentru implementarea algoritmilor, manipularea matricelor și, de asemenea, diverse posibilități de

reprezentare grafică a funcțiilor și datelor. Simulink este un mediu de programare cu diagrame de blocuri integrat în Matlab, iar printre numeroasele sale aplicații, principalele sale utilizări sunt modelarea și simularea sistemelor dinamice și sistemele de testare și verificare continuă.

În cele mai multe cazuri, Matlab și Simulink sunt utilizate împreună, permițând combinarea programării pe bază de text cu cea grafică pentru dezvoltarea și simularea sistemelor preconizate. Acest lucru se realizează prin încorporarea algoritmilor creați în Matlab în blocuri de model Simulink care pot fi utilizate alături de blocurile implicite disponibile în bibliotecă, iar la sfârșitul simulării, rezultatele pot fi exportate în spațiul de lucru Matlab pentru utilizare ulterioară. Pentru a implementa un algoritm care vizează construirea unui model de proces și pentru a-l adăuga ca model Simulink, acesta trebuie structurat într-o funcție S. Funcțiile de sistem sau funcțiile S reprezintă o metodă puternică de creștere a mediului Simulink. La implementarea unui algoritm trebuie să se utilizeze un șablon pentru a obține forma generală a unei funcții S. Această formă generală a funcției S definește comportamentul blocurilor în fiecare dintre etapele de simulare, care sunt inițializarea, actualizarea, calculul derivatelor, actualizarea stărilor și a ieșirilor și terminarea. Figura 2.4 ilustrează un bloc Simulink format din seturi de variabile/seturi de intrare, de stări, de parametri și de ieșire.



**Figura 2.4** Reprezentarea unui bloc Simulink

## 2.4. Evaluarea funcționării stației de epurare

Analiza datelor este obligatorie pentru a evalua performanța și potențialul strategiilor de operare a stațiilor de epurare. Rapoartele tehnice BSM descriu metode de evaluare care au fost concepute pentru a combina cantitatea mare de date de ieșire în câțiva termeni compuși independenți din punct de vedere geografic [29]. Aceste criterii fac posibilă compararea obiectivă și simplă a impactului diferitelor strategii de operare. Termenii compuși descriși mai jos au fost utilizați pentru evaluarea funcționării în toate studiile de caz prezentate în capitolul 3, și anume indicele de calitate a efluenților, energia de aerare și energia de pompare.

Indicele de calitate a efluentului (EQI) (kg unitate de poluare/zi, kgPU/zi) evaluează masa zilnică de poluanți eliberată prin luarea în considerare a valorilor efluenților de TSS ( $PU_{TSS}$ ), COD ( $PU_{COD}$ ), BOD ( $PU_{BOD}$ ), azot Kjeldahl total (TKN) ( $PU_{TKN}$ ), concentrația de nitrați și nitriți (NO) ( $PU_{NO}$ ) și prin luarea în considerare, de asemenea, a debitului de efluent ( $Q_e$ ), după cum se arată în ecuația (2.1).

$$EQI = \frac{1}{1000 \cdot T} \cdot \int_{t_i}^{t_n} [PU_{TSS}(t) + PU_{COD}(t) + PU_{BOD}(t) + PU_{TKN}(t) + PU_{NO}(t)] \cdot Q_e(t) dt \quad (2.1)$$

Calculul indicelui energetic de aerare AE (kWh/zi) ia în considerare coeficientul de transfer al oxigenului ( $K_{La}$ ), volumele bazinelor de aerare ( $V$ ) și concentrația saturată de oxigen ( $SO_{sat}$ ).

$$AE = \frac{SO_{sat}}{1.8 \cdot 1000 \cdot T} \cdot \int_{t_i}^{t_n} \sum V \cdot K_L a(t) dt \quad (2.2)$$

În timp ce indicele de energie de pompare PE (kWh/zi) este calculat pe baza debitului de reciclare internă (reciclarea nitratilor) ( $Q_{NR}$ ), a debitului de reciclare externă (reciclarea nămolului activat de retur) ( $Q_{RAS}$ ) și a debitului de deșuri ( $Q_w$ ). Aceste valori se calculează media pe perioada de observație  $T$  (de la  $t_i$  la  $t_n$ ).

$$PE = \frac{1}{T} \cdot \int_{t_i}^{t_n} [0.004 \cdot Q_{NR}(t) + 0.008 \cdot Q_{RAS}(t) + 0.05 \cdot Q_w(t)] dt \quad (2.3)$$

## 2.5. Modelarea și evaluarea RNA

### 2.5.1. Tipuri de rețele neuronale artificiale studiate

Au fost analizate mai multe tipuri de RNA pentru a determina cea mai potrivită rețea pentru predicții. Pe parcursul studiilor de caz au fost explorate patru tipuri de RNA, care pot fi clasificate în două clase, pentru a descoperi cea mai potrivită, în ceea ce privește timpul de antrenare și criteriile de evaluare a acurateței predicției. Una dintre clase a fost rețeaua autoregresivă neliniară cu intrări exogene (NARX), în timp ce cealaltă a fost clasa bazată pe utilizarea funcțiilor de bază radială, denumită simplu rețele RBF (Radial Basis Function).

Blocul de linie de întârziere între intrările seriilor de timp ale modelului RNA și primul strat ascuns este utilizat în proiectarea rețelei neuronale de tip NARX de tip feed-forward pentru a oferi modelelor RNA o caracteristică de memorie puternică. Această linie permite precizarea valorii variabilei țintă la momentul de eșantionare apropiat în timp, utilizând date din momente anterioare, atât în cazul seturilor de date de intrare, cât și în cazul seturilor de date țintă.

Cele patru tipuri de RNA luate în considerare au fost: structura "deschisă" a clasei NARX, cunoscută și sub numele de rețea neuronală cu întârziere în timp (TDNN); structura NARX "închisă", denumită de obicei rețea neuronală recurentă (RNN); și rețeaua neuronală cu bază radială (RBNN) și rețeaua neuronală de regresie generalizată (GRNN), care fac parte din clasa RBF. Aceste patru tipuri au fost selectate ca rețele de tip NARX, care sunt bine cunoscute pentru utilizarea lor în modelarea seriilor temporale, și ca RNA de tip RBF, adică RBNN și GRNN, care au fost, de asemenea, utilizate în mod eficient în studiile de predicție a seriilor temporale [30].

Tipul TDNN cuprinde rețeaua neuronală de tip feed-forward cu un bloc de linie de întârziere între intrări și primul strat ascuns, care permite rețelelor să funcționeze cu date din momente temporale

anterioare. RNN sunt construite în mod similar cu TDNN menționate anterior. Linia de întârziere este, de asemenea, prezentă în aceste rețele. În acest caz, valorile de ieșire sunt conectate direct prin feedback de la ieșirile proprii ale rețelei calculate anterior.

RBNN-urile au fost dezvoltate cu două straturi: un strat ascuns numit strat de bază radială ca prim strat și un strat de ieșire liniară ca al doilea strat. Deoarece RBNN implicită nu conține în arhitectura sa linia de întârziere cu robinet, funcția unei astfel de linii a fost reprodusă prin adăugarea manuală a datelor din momentele de timp anterioare ca intrare în rețea. GRNN, la fel ca și RBNN, au avut două straturi în construcția lor. În cazul modelelor GRNN, întârzierea temporală a fost, de asemenea, adăugată manual. Primul strat funcționează în mod similar cu primul strat din RBNN-uri, în timp ce al doilea strat - cunoscut sub numele de strat liniar special - reprezintă diferența dintre cele două tipuri de RNA.

### 2.5.2. Criterii de evaluare RNA

Este imperativ ca modelele RNA cel mai bine concepute și instruite să fie selectate pentru utilizare ulterioară. Pentru a realiza acest lucru, trebuie să se evalueze performanța acestora. În acest scop, au fost utilizate în total trei criterii. Primul este coeficientul de determinare ( $R^2$ ), care are o valoare ideală de 1, măsoară cât de bine pot prezice rezultatele modelului prin evaluarea bonității de potrivire între valorile prezise și cele vizate. Calculul acestui criteriu este prezentat în Ecuația (2.4).

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - x_i)^2}{\sum_{i=1}^N (y_a - y_i)^2} \quad (2.4)$$

unde  $y_a$  este valoarea medie a datelor țintă,  $y_i$  este rezultatul dorit la punctul de date  $i$ ,  $x_i$  este rezultatul modelului la punctul de date  $i$  și  $N$  este numărul de observații.

Al doilea criteriu utilizat în evaluarea modelelor RNA a fost media erorilor pătratice (MSE), care calculează erorile pătratice dintre fiecare pereche de valori vizate și prezise și oferă media acestor erori pătratice. MSE se calculează după cum urmează:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2 \quad (2.5)$$

Ultimul criteriu, eroarea procentuală absolută medie (MAPE). Valoarea acestui criteriu este media erorilor procentuale absolute dintre valorile vizate și cele previzionate, împărțirea erorilor absolute la valoarea vizată fiind utilizată pentru a le converti în procente. Criteriul MAPE a fost calculat pe baza ecuației (2.6).

$$MAPE = \frac{\sum_{i=1}^N \frac{|y_i - x_i|}{y_i}}{N} 100 \quad (2.6)$$

### 3. Cazuri investigate de îmbunătățire a funcționării stației de epurare


#### 3.1. Optimizarea debitului de reciclare pentru conducta de apă a stației de epurare a apelor uzate

În primul studiu de caz a fost luat în considerare un sistem de control format din bucla de control DO pentru controlul automat al debitului de aer în bioreactoare. Fluxurile de nămol activat de retur și de reciclare a nitraților au fost controlate ca un anumit raport față de debitul de intrare (Fig. 3.1.), ceea ce reprezintă o abordare adoptată în mod obișnuit în instalațiile care nu dispun de bucla de control al NO. Studiul actual a avut ca scop dezvoltarea unor modele dinamice precise de rețele neuronale, prin explorarea a patru tipuri de arhitecturi RNA, care sunt utilizate ulterior în optimizarea debitelor de reciclare și, prin urmare, a funcționării stației de epurare. Principalele etape ale cercetării prezentate sunt:

- Generarea de date utilizând un model matematic bazat pe ASM1 și calibrat pe datele instalației.
- Dezvoltarea RNA și selectarea celor mai precise modele RNA pentru abordarea nouă de modelare directă a indicilor de performanță a stației de epurare.
- Optimizarea câștigurilor sistemului de control care manipulează reciclarea nitraților și debitele de nămol activat de retur într-un raport specificat față de debitul de intrare în stația de epurare, pe baza unei funcții obiective care ia în considerare indicii de performanță de mediu și energetică.

Schema stației municipale de epurare utilizată ca studiu de caz este prezentată în figura 3.1. Aceasta are o configurație anaerobă-anoxică-oxică ( $A^2O$ ) și utilizează o buclă de control cu reacție pentru aerarea instalației, în timp ce cele două debite de recirculare sunt determinate prin înmulțirea debitului de intrare cu factori de câștig separați [31]. Bucla de control cu reacție este responsabilă pentru procesul de nitrificare prin controlul nivelului DO în reactoarele aerate și manipularea debitului de aer [32]. A fost selectată o perioadă de 7 zile care a fost reprezentativă pentru întregul set de date și a fost utilizată pentru diferite scenarii de simulare a câștigului de recirculare.

Toate cele patru tipuri de rețele prezentate în secțiunea 2.5.1 au fost investigate cu scopul de a găsi cea mai potrivită rețea care să fie utilizată pentru predicții. Intrările RNA studiate constau în valorile trecute și prezente ale următoarelor variabile de influent: COD, concentrația de azot ( $NH_4^+ + NH_3$ ), debitul volumetric ( $Q$ ), temperatura și cei doi factori de câștig ( $K_1$  și  $K_2$ ). În plus, în funcție de tipul de rețea (cu o singură ieșire - MISO sau cu ieșiri multiple - MIMO), intrarea RNA conține, de asemenea, valorile anterioare ale creșterilor (de la un moment de eșantionare la următorul) ale unuia sau mai multor indici de performanță. Indicii de performanță au fost calculați după cum este descris în ecuațiile (2.1), (2.2) și (2.3).



**Figura 3.1** Reprezentarea schematică a stației de epurare studiate și a sistemului de control al acesteia

Variabilele de decizie pentru problema actuală au fost cei doi factori de câștig care controlează debitele de reciclare externă și internă. Ambele structuri de model MISO și MIMO au fost utilizate în continuare pentru optimizarea unui scenariu pentru o perioadă de 7 zile cu următoarea funcție obiectiv:

$$f_{min} = AE + 8 \cdot EQ + PE \quad (3.1)$$

Cele mai bune rețele ale fiecărei topologii obținute în urma procesului de încercare și eroare au fost utilizate pentru a prezice o perioadă de 7 zile, luând în considerare un scenariu încă nevăzut al intrărilor RNA. Valorile MAPE și alte rezultate ale performanțelor RNA, obținute cu cele mai bune rețele selectate, sunt prezentate în Tabelul 3.1.

Tabel 3.1 Rezultatele testelor și predicțiilor pentru cele mai bune rețele MISO și MIMO

ANN type	Transfer functions		Output	Testing		Prediction			Avg. training time (s)
	Hidden layer 1	Hidden layer 2		R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	MAPE	
TDNN	logsig	tansig	ΔAE/MISO	1	2.27E+04	0.99	1.05E+05	1.19	5.7
RNN	logsig	-	ΔEQ/MISO	1	2.52E+04	0.89	1.41E+06	3.50	600
RNN	logsig	-	ΔPE/MISO	1	3.66E+02	0.99	5.00E+02	0.85	30
RNN	logsig	logsig	All/MIMO	1	5.31E+04	0.99	5.11E+05	2.39	52

Cele mai bune rețele dezvoltate prezentate anterior au fost utilizate în continuare pentru optimizarea scenariului standard care se întinde pe o perioadă de 7 zile. Rezultatele optimizării sunt prezentate în . Toate

structurile modelului au redus câștigul de nitrați de la valoarea de 0,8 din practica operațională reală (cazul de referință) la o valoare de aproximativ 0,62.

Tabel 3.2 Rezultatele optimizării

	Nitrates gain (K <sub>2</sub> )	Activated sludge gain (K <sub>1</sub> )	AE (kWh/zi)	EQ (kgPU/zi)	PE (kWh/zi)	Optimization time (s)
Reference case	0.80	1.00	1.76E+04	1.67E+04	1.26E+03	-
Analytical	0.65	0.80	1.71E+04	1.66E+04	1.03E+03	16724
MIMO	0.62	1.07	1.71E+04	1.68E+04	1.12E+03	0.97
MISO	0.60	0.99	1.70E+04	1.68E+04	1.07E+03	2.24

Analizând acuratețea predicției și rezultatele optimizării modelelor RNA dezvoltate pentru îmbunătățirea funcționării stației de epurare a apelor uzate prin optimizarea debitului de reciclare internă și externă, se poate concluziona:

- Optimizările efectuate pentru o perioadă de timp de 7 zile au arătat că indicii de performanță AE și PE au fost precise cu succes cu valori mici ale MAPE de aproximativ 1%.
- Soluțiile optime găsite de ambele structuri ale modelului RNA au dus la reducerea celor doi indici de performanță în comparație cu cazul de referință.
- Un avantaj important a fost observat la nivelul timpului de calcul pentru sarcina de optimizare, între utilizarea RNA (0,97 și 2,24 secunde) față de modelul analitic (16724 secunde) pentru optimizare.

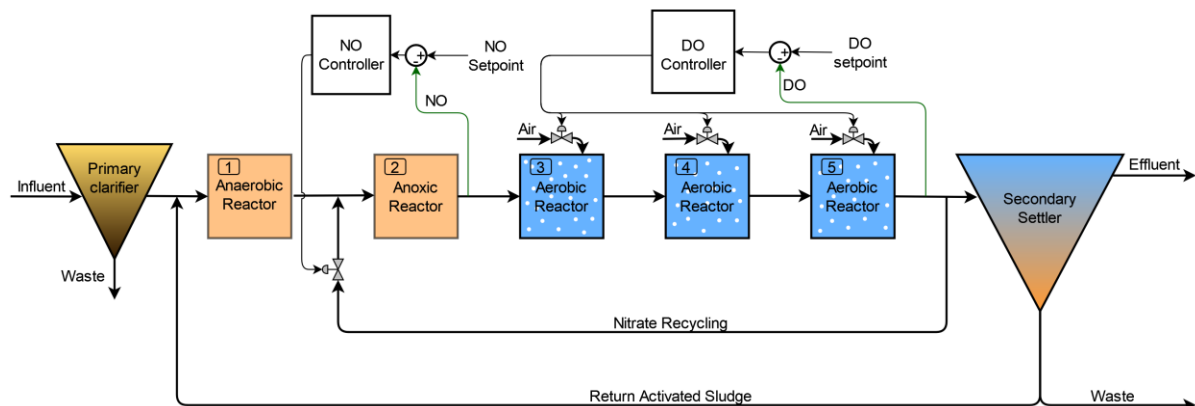
### 3.2. Optimizarea punctului de reglaj al buclei de control pentru conducta de apă a stației de epurare a apelor uzate

Cel de-al doilea studiu de caz a investigat optimizarea sistemului de control care avea atât sistemul de control automat DO, cât și NO. Această lucrare actuală a constat într-o dezvoltare completă a RNA care prevede direct indicii de performanță ai stației de epurare și a avut ca scop găsirea celui mai potrivit tip, design și metodologie de antrenare a RNA pentru construirea unor modele dinamice de mare precizie. Acestea au fost utilizate ulterior în optimizarea funcționării stației de epurare pentru a găsi cele mai bune valori de referință ale principalelor bucle de control responsabile pentru sub-procesele esențiale de oxidare a carbonului, nitrificare și denitrificare din stația de epurare (Figura 3.2). Principalele etape ale lucrării prezentate sunt:



- Generarea a două seturi de date reprezentative, unul mai mic (screening) și unul mai mare, utilizând modelul analitic calibrat și algoritmi de proiectare a experimentelor, cu scopul de a colecta un set de date minim, dar suficient de bogat, pentru a realiza o procedură de antrenare eficientă și eficientă.
- Pe baza setului mic de date de screening, s-a selectat structura și tipul de RNA cel mai performant, prin evaluarea preciziei predicției și a timpului necesar pentru antrenarea a patru tipuri de modele RNA menite să descrie comportamentul dinamic al variabilelor de calitate a efluenților din stațiile de epurare.
- Pe baza rezultatelor etapei de screening și utilizând un set de date mai mare, s-a efectuat o nouă antrenare și o nouă selecție a tipului și arhitecturii RNA cu cea mai bună performanță pentru a construi noi modele RNA, capabile să descrie cu precizie indicii de performanță ai stației de epurare, și pentru a lua în considerare utilizarea lor ulterioară în etapa de optimizare.
- Optimizarea funcționării stației de epurare pe baza celor mai performante modele RNA care prezic energia stației de epurare și indicii de calitate a efluentului, pentru a găsi cele mai favorabile valori de referință pentru buclele de control al oxigenului dizolvat și al concentrației de nitrați și nitriți.

Datele instalației au fost colectate din măsurătorile variabilelor de intrare și de proces ale stației de epurare, luând în considerare o perioadă de eșantionare de 30 de minute și pentru o perioadă de 22 de zile.



**Figura 3.2** Schema de amenajare a stației de epurare studiate și a sistemului de control al acesteia

Studiul actual a utilizat toate tipurile de RNA prezentate, menționate în secțiunea 2.5, iar hiperparametrii rețelei luate în considerare au fost aproape identice cu cele studiate în studiul de caz anterior. Pentru noul lot de rețele, s-a investigat, de asemenea, influența lungimii orizontului de timp al liniei de întârziere cu robinet asupra preciziei de predicție a RNA și a duratei de antrenare. Pentru acest parametru al modelului RNA au fost luate în considerare valori cuprinse între 12 și 100.

Pentru procesul de optimizare a fost selectată o perioadă de 7 zile. Au fost selectate cele mai eficiente RNA pentru precizarea indicilor stației de epurare, atât pentru structurile MISO, cât și pentru cele MIMO, pentru a găsi punctele de setare optime pentru buclele de control ( $NO_{ref}$  și  $DO_{ref}$ ), având în vedere intervalele prezentate în Tabelul 3.3 și funcția obiectiv prezentată în ecuația (3.2).

$$f_{min} = AE + 4 \cdot EQ + PE \quad (3.2)$$

Tabel 3.3 Gama de valori pentru punctele de setare ale buclelor de control

Variable	min	max
$NO_{ref}$ (mg N/L)	0.005	0.02
$DO_{ref}$ (mg $O_2$ /L)	1	3

Cele mai bune modele pentru fiecare caracteristică de ieșire la etapa de screening sunt prezentate în Tabelul 3.4. Aceste tipuri de modele au fost luate în considerare în continuare în etapa finală de selecție, în cadrul căreia a fost utilizat setul de date mai mare pentru dezvoltarea lor și s-a luat în considerare compromisul dintre precizia predicției și timpul de antrenare prin creșterea orizontului de timp al liniei de întârziere cu atingeri. Rezultatele obținute sunt prezentate în Tabelul 3.5.

Tabel 3.4 Rezultatele testării și predicției celor mai bune rețele pentru fiecare caracteristică de ieșire la etapa de screening

ANN type	Transfer functions		Output	Testing		Prediction (Second testing)		Avg. training time (s)
	Hidden layer 1	Hidden layer 2		$R^2$	MSE	$R^2$	MSE	
GRNN	radbas	-	TSS	0.89	1.81E-02	0.54	2.90E-01	0.074
TDNN	tansig	-	COD	1.00	7.92E-04	0.77	2.42E-01	0.56
RNN	logsig	tansig	BOD	0.88	2.97E-04	0.72	1.82E-02	202
TDNN	tansig	logsig	TKN	1.00	6.31E-05	0.87	1.14E-02	0.48
GRNN	radbas	-	NO	0.96	1.13E-02	0.77	1.07E-01	0.071
RBNN	radbas	-	All	0.99	2.43E+07	0.98	2.82E+07	4.8
RBNN	radbas	-	EQ	1.00	4.53E+04	0.76	1.84E+07	2.3

Rezultatele optimizării efectuate cu modelele RNA evidențiate în Tabelul 3.5 pentru punctele de reglare a buclei de control, timpul de calcul și valorile indicilor de performanță obținute cu punctele de reglare optime sunt prezentate în Tabelul 3.6.

Următoarele concluzii au fost trase prin evaluarea rezultatelor dezvoltării modelului RNA în două etape și a optimizării:

- Etapa de selecție a arătat că rețelele antrenate direct cu EQ ca unică variabilă de ieșire au prezentat un potențial mai mare de a face predicții eficiente, iar rețelele RNN cu două straturi ascunse au fost cele mai puțin promițătoare.
- Creșterea lungimii liniei de întârziere cu derivație a prezentat o influență pozitivă asupra preciziei RBNN, în timp ce TDNN au prezentat un răspuns neuniform.
- Optimizarea punctelor de reglare a buclei de control a condus la îmbunătățirea funcționării stației de epurare prin scăderea cu 1303 kWh/zi a consumului de energie și cu 324 kgPU/zi a indicelui de calitate a efluenților.
- Modelul MIMO ANN a realizat sarcina de optimizare de aproximativ 180 de ori mai rapid în comparație cu optimizarea bazată pe modelul analitic.

Tabel 3.5 Influența variației lungimii orizontului liniei de întârziere cu robinet asupra acurateței predicției și a timpului de antrenare la etapa de selecție finală a RNA

ANN type	Output	Delay horizon	R <sup>2</sup>	MSE	MAPE (%)	Training time (s)
RBNN	AE	12	0.95	2.06E+05	1.79	100
RBNN	AE	25	0.95	1.62E+05	1.54	190
<b>RBNN</b>	<b>AE</b>	<b>50</b>	<b>0.97</b>	<b>9.37E+04</b>	<b>1.27</b>	<b>700</b>
RBNN	AE	100	0.96	1.16E+05	1.33	2300
TDNN	EQ	12	0.97	3.92E+05	3.09	130
TDNN	EQ	25	0.94	1.38E+06	5.36	170
TDNN	EQ	50	0.92	8.40E+05	4.20	180
<b>TDNN</b>	<b>EQ</b>	<b>100</b>	<b>0.98</b>	<b>3.73E+05</b>	<b>2.57</b>	<b>550</b>
<b>TDNN</b>	<b>PE</b>	<b>12</b>	<b>0.98</b>	<b>8.66E+02</b>	<b>1.51</b>	<b>31</b>
TDNN	PE	25	0.84	5.95E+03	4.04	34
TDNN	PE	50	0.98	7.21E+02	1.58	56
TDNN	PE	100	0.98	1.10E+03	1.76	330
RBNN	All	12	0.99	3.48E+05	2.91	71
RBNN	All	25	1.00	3.42E+05	2.99	150
<b>RBNN</b>	<b>All</b>	<b>50</b>	<b>1.00</b>	<b>2.28E+05</b>	<b>2.37</b>	<b>500</b>
RBNN	All	100	1.00	2.62E+05	2.64	2600

Tabel 3.6 Rezultatele optimizării cu cele mai bune RNA și FPM utilizate pentru calculul AE, EQ și PE

Model	NO setpoint (mg N/L)	DO setpoint (mg O <sub>2</sub> /L)	AE (kWh/ziay)	EQ (kg <sub>PU</sub> /ziay)	PE (kWh/ziay)	Optimization time (min)
Base case	1.00E-02	2.000	17646	16575	1381	-
FPM	5.00E-03	1.422	16218	16243	1351	423
3 MISO ANN	5.00E-03	1.251	15899	16357	1427	2.04
MIMO ANN	5.50E-03	1.487	16366	16251	1358	2.34

### 3.3. Optimizarea debitului de aer pentru reactorul aerat a stației de epurare

Cel de-al treilea studiu de caz a investigat optimizarea distribuției fluxului de aer către reactoarele aerate. Acest studiu are ca scop găsirea parametrilor optimi de aerare (adică trei factori de creștere care să orienteze distribuția debitului de aer) pentru o strategie de funcționare a unității de aerare care să conducă la o distribuție optimizată a debitului de aer către bioreactorul aerat și să o evalueze din punct de vedere al consumului de energie, al calității efluenților și al emisiilor de GHG. În studiul actual, emisiile de GHG au fost luate în considerare pentru reactoarele biologice și decantoarele asociate din linia de apă, deoarece acestea reprezintă cea mai importantă sursă de GHG. Calculul parametrilor optimi de funcționare pentru strategia de aerare propusă s-a bazat pe predicțiile indicilor de performanță energetică a stației de epurare, a calității efluenților și a emisiilor de GHG, utilizând modele inteligente hibride dinamice dezvoltate pe baza unor seturi de date simulate. Aceste modele dinamice de rețele neuronale NARX, pentru care topologia optimă a fost căutată prin intermediul GA, vor fi denumite în continuare GA-NARX. Din cunoștințele autorilor, nu există studii asociate cu modelarea inteligentă hibridă bazată pe modele NARX optimizate prin GA, care să vizeze simularea proceselor din cadrul stațiilor de epurare. În plus, modelarea dinamică a emisiilor de GHG în stațiile de epurare a apelor uzate prin intermediul modelelor RNA reprezintă, de asemenea, o noutate a prezentei lucrări. Etapele principale ale studiului actual au fost următoarele:

- Generarea setului de date reprezentative prin utilizarea modelului analitic calibrat al stației municipale de epurare a apelor uzate considerate ca studiu de caz și prin luarea în considerare a scenariilor specifice și multiple ale parametrilor operaționali.
- Elaborarea metodologiei GA-NARX pentru căutarea topologiei RNA optime în ceea ce privește structura rețelei NARX la antrenare, numărul de straturi ascunse (NHL), numărul de neuroni din fiecare strat ascuns (NNeHL) și funcțiile de transfer (TF).
- Utilizarea modelelor dezvoltate de RNA într-o etapă de optimizare multi-obiectiv pentru găsirea parametrilor operaționali optimi de aerare.

Testarea parametrilor operaționali optimi pe modelul analitic și compararea consumului de energie, a calității efluenților și a performanței emisiilor de gaze cu efect de seră cu funcționarea standard a stației de epurare.

Pentru generarea setului de date necesar pentru dezvoltarea modelelor GA-NARX a fost utilizat un model analitic bazat pe ASM1. Pentru fiecare dintre reactoarele aerate, debitul de aer poate fi distribuit neuniform folosind trei factori de câștig (G1-G3), după cum se poate observa în Figura 3.3.

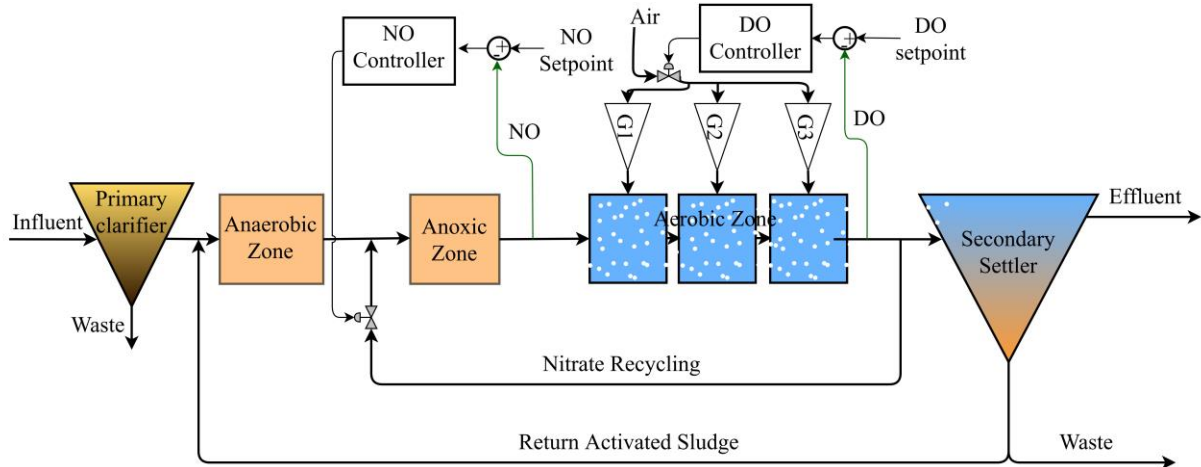


Figura 3.3 Reprezentarea schematică a stației de epurare studiate

Algoritmii pe bază de populație, cum ar fi AG, oferă mijloace adecvate pentru găsirea optimului global în optimizarea arhitecturii RNA [33]. Au fost luate în considerare modele de RNA cu 1 sau 2 straturi ascunse, cu NNeHL între 2 și 15. TF-urile de la fiecare strat ascuns au fost alese ca o funcție logsig sau tansig.

Evaluarea emisiilor de GHG a fost realizată la nivelul liniei de apă a stației de epurare, luând în considerare atât emisiile de CO<sub>2</sub> și N<sub>2</sub>O de pe amplasament, cât și cele din afara acestuia, așa cum sunt descrise în ecuațiile (3.3)-(3.7). Evaluarea emisiilor de CO<sub>2</sub> la fața locului a fost calculată în (kg CO<sub>2</sub>/m<sup>3</sup> WW), pe baza relației descrise în ecuația (3.3) [34].

$$P_{CO_2, on-site} = \left( 0.99 \cdot (1 - Y_H) \cdot \eta_{ASP} \cdot bCOD + 1.03 \cdot Y_H \cdot \eta_{ASP} \cdot bCOD \cdot \frac{k_{d,H} \cdot MCRT}{1 + k_{d,H} \cdot MCRT} \right) \quad (3.3)$$

aici, 0,99 (kg CO<sub>2</sub> eq./kg COD) este factorul de emisie corespunzător compușilor organici, Y<sub>H</sub> este randamentul biomasei heterotrofe în (masă VSS/masă COD), η<sub>ASP</sub> se referă la eliminarea COD biodegradabilă (bCOD) în reactoarele cu nămol activat, 1,03 (kg CO<sub>2</sub> eq./kg COD) este un factor de emisie în raport cu biomasa de nămol activat, k<sub>d,H</sub> este rata de descompunere pentru biomasa heterotrofă cu o valoare de 0,3 (d<sup>-1</sup>) [35], iar MCRT este timpul mediu de retenție a celulelor, considerat ca fiind de 15 zile pentru cazul actual al stației municipale de epurare.

Emisiile de  $N_2O$  la fața locului ( $kg N_2O/m^3 WW$ ) au fost estimate cu ajutorul următoarei formule:

$$P_{N_2O,on-site} = EF_{N_2O} \cdot \Delta TN \quad (3.4)$$

unde  $EF_{N_2O}$  este factorul de emisie ( $kg N_2O/kg N$ ) cu o valoare de 0,005, legat de producția de  $N_2O$  pe baza încărcăturii de N din afluent [36], iar  $\Delta TN$  este diferența specifică a masei de TN între afluentul și efluentul stației de epurare ( $kg N/m^3 WW$ ).

În ceea ce privește emisiile de  $CO_2$  în afara amplasamentului ( $kg CO_2/m^3 WW$ ), a fost utilizată următoarea relație, bazată pe [37]:

$$P_{CO_2,off-site} = \frac{(k_{PG} \cdot e_D)}{Q_i} \quad (3.5)$$

unde  $k_{PG}$  este factorul de emisie pe unitate de energie generată care urmează să fie consumată în stația de epurare, valoarea sa a fost luată ca fiind de 0,323 ( $kg CO_2 eq./kWh$ ), care este intensitatea emisiilor de GHG raportată pentru România în 2021 [38],  $e_D$  ( $kWh/zi$ ) este cererea de energie care a fost calculată ca sumă a energiilor de aerare și de pompare (AE+PE), iar  $Q_i$  este debitul de influent. Indicii AE și PE au fost calculați pe baza metodelor discutate în capitolul 2 [35].

Au fost luate în considerare emisiile de  $N_2O$  în afara amplasamentului datorită degradării biologice în sistemele din aval de stația de epurare, ceea ce duce la eliberarea suplimentară de  $N_2O$ . Următoarea ecuație descrie aceste emisii:

$$P_{N_2O,off-site} = N_e \cdot EF_e \quad (3.6)$$

unde  $N_e$  este încărcătura de N evacuată în corpul de apă receptor, iar  $EF_e$  este factorul de emisie de  $N_2O$  din apele uzate evacuate, cu o valoare de  $7,857 \cdot 10^{-3}$  ( $kg N_2O/kg N$ ) [39].

Emisiile totale de GHG au fost calculate ca emisii echivalente de  $CO_2$ , pe baza ecuației (3.7).

$$GHG = P_{CO_2,on-site} + P_{CO_2,off-site} + GWP_{N_2O} \cdot (P_{N_2O,on-site} + P_{N_2O,off-site}) \quad (3.7)$$

Valoarea pentru  $GWP_{N_2O}$  a fost luată ca 298 [40] pentru a converti emisiile în unitatea de măsură ( $kg CO_2 eq./m^3 WW$ ).

Valorile optime ale factorilor de câștig care determină distribuția aerului în cele trei bioreactoare aerate au fost căutate luând în considerare un scenariu cu o durată de 7 zile. Primele două dintre cele trei funcții obiectiv ( $f_{min,i}$ ,  $i=1-3$ ) au luat în considerare consumul de energie și emisiile de GHG ale stației de epurare, așa cum se arată în ecuațiile (3.10)-(3.11).

$$f_{min,1} = e_D \quad (3.8)$$

$$f_{min,2} = GHG \quad (3.9)$$

Pentru funcția obiectiv referitoare la calitatea efluenților au fost luate în considerare două cazuri distincte.

În cazul 1, cea de-a treia funcție obiectiv a fost considerată egală cu EQ prezis de RNA:

$$f_{min,3} = EQ \quad (3.10)$$

În cazul 2, EQ a fost calculat pe baza ecuației (2.4), ceea ce înseamnă că au fost dezvoltate 6 modele GA-NARX distincte pentru a prezice concentrațiile individuale ale celor 5 indicatori chimici diferiți și debitul efluentului. Cea de-a treia funcție obiectiv în cazul 2 a luat în considerare aceste concentrații individuale și s-a aplicat o penalizare în cazul în care nu au fost respectate limitele considerate (Ecuația (3.11)).

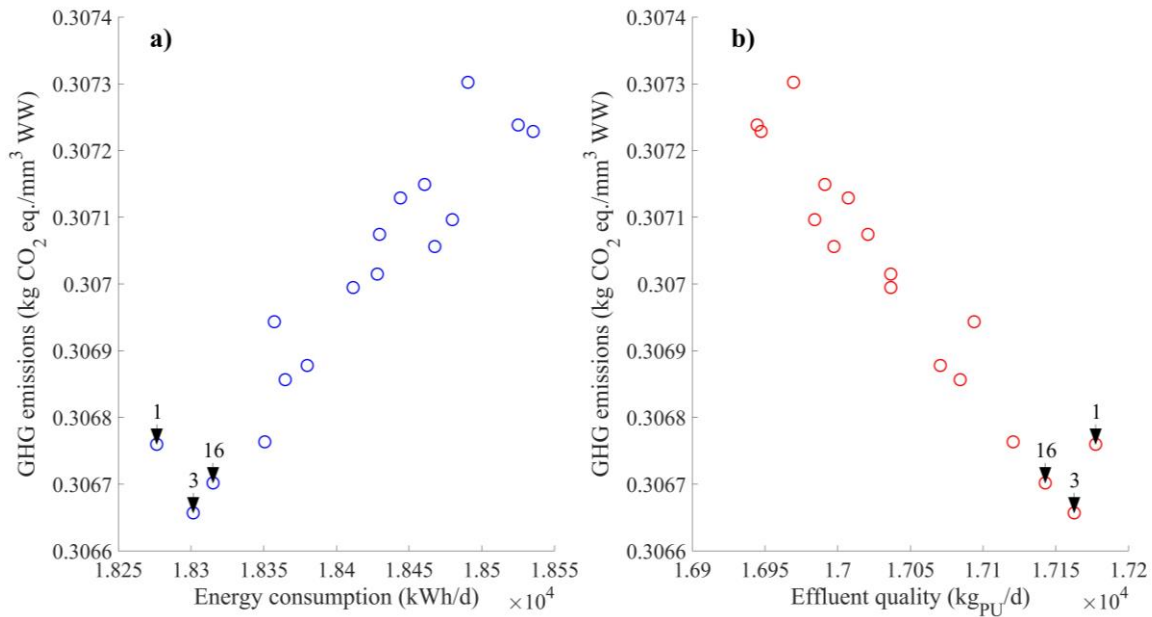
$$f_{min,3} = \begin{cases} EQ & \text{if } COD \leq 125 \ \& \ TN \leq 10 \ \& \ BOD \leq 25 \\ EQ \cdot \left(1.1 + 0.9 \cdot \frac{t_p}{T}\right) & \text{if } COD > 125 \ \text{or } TN > 10 \ \text{or } BOD > 25 \end{cases} \quad (3.11)$$

Hiperparametrii optimi ai rețelei și rezultatele MAPE pentru scenariul de predicție sunt prezentate în tabelul 3.7.

Table 3.7 Hiperparametrii modelului GA-NARX și rezultatele predicției

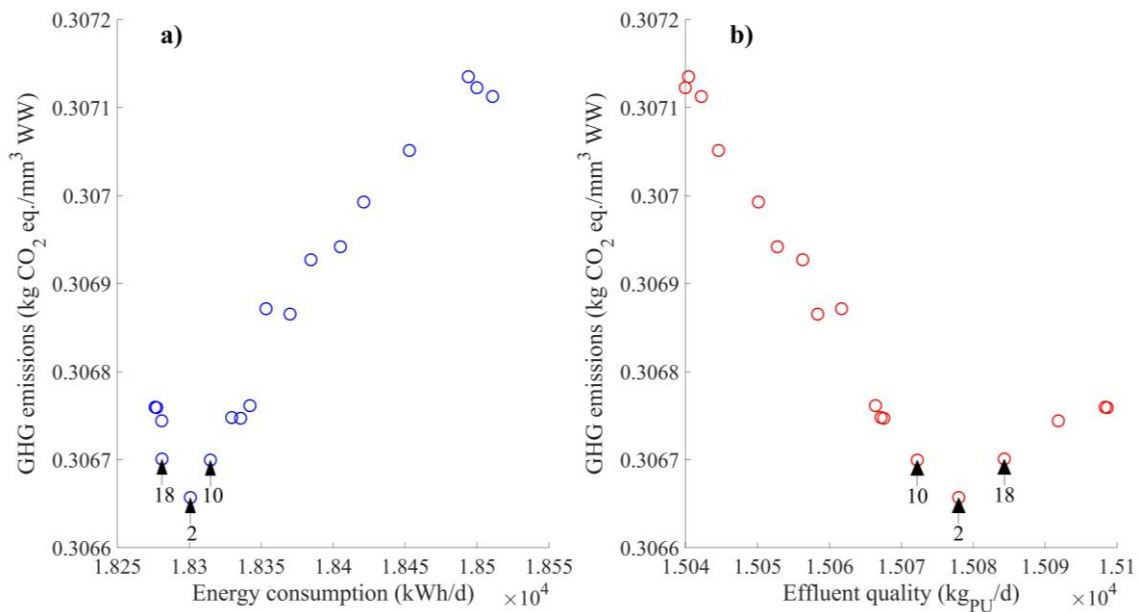
Output	Structure	Architecture	Transfer function(s)	MAPE <sub>prediction</sub> (%)
AE	open	in-15-out	logsig	1.23
BOD <sub>e</sub>	open	in-12-13-out	tansig-tansig	1.14
COD <sub>e</sub>	closed	in-11-11-out	tansig-tansig	11.1
EQ	closed	in-13-11-out	tansig-logsig	21.5
GHG	open	in-14-10-out	tansig-logsig	1.24
NO <sub>e</sub>	closed	in-14-11-out	tansig-logsig	10.8
PE	open	in-15-15-out	tansig-logsig	4.81
TKN <sub>e</sub>	open	in-13-15-out	tansig-tansig	6.27
TSS <sub>e</sub>	open	in-15-12-out	logsig-tansig	16.2
Q <sub>e</sub>	closed	in-6-13-out	tansig-logsig	0.0457

Rezultatul optimizării, un front Pareto, din primul caz de optimizare este prezentat în două grafice 2D în loc de o singură ilustrație 3D, așa cum se arată în Figura 3.4. Locația celor mai bune trei soluții a fost, de asemenea, localizată cu ajutorul unor săgeți pe grafice.



**Figura 3.4** Frontul Pareto în cazul de optimizare 1, prezentat sub forma: a) emisiilor de GHG în raport cu indicii de consum de energie și b) emisiilor de GHG în raport cu indicii de calitate a efluenților.

Rezultatele frontului Pareto obținute în cazul de optimizare 2 sunt prezentate în Figura 3.5, la fel ca în primul caz de optimizare.



**Figura 3.5** Frontul Pareto în cazul de optimizare 2, prezentat sub forma: a) emisiilor de GHG în raport cu indicii de consum de energie și b) emisiilor de GHG în raport cu indicii de calitate a efluenților.

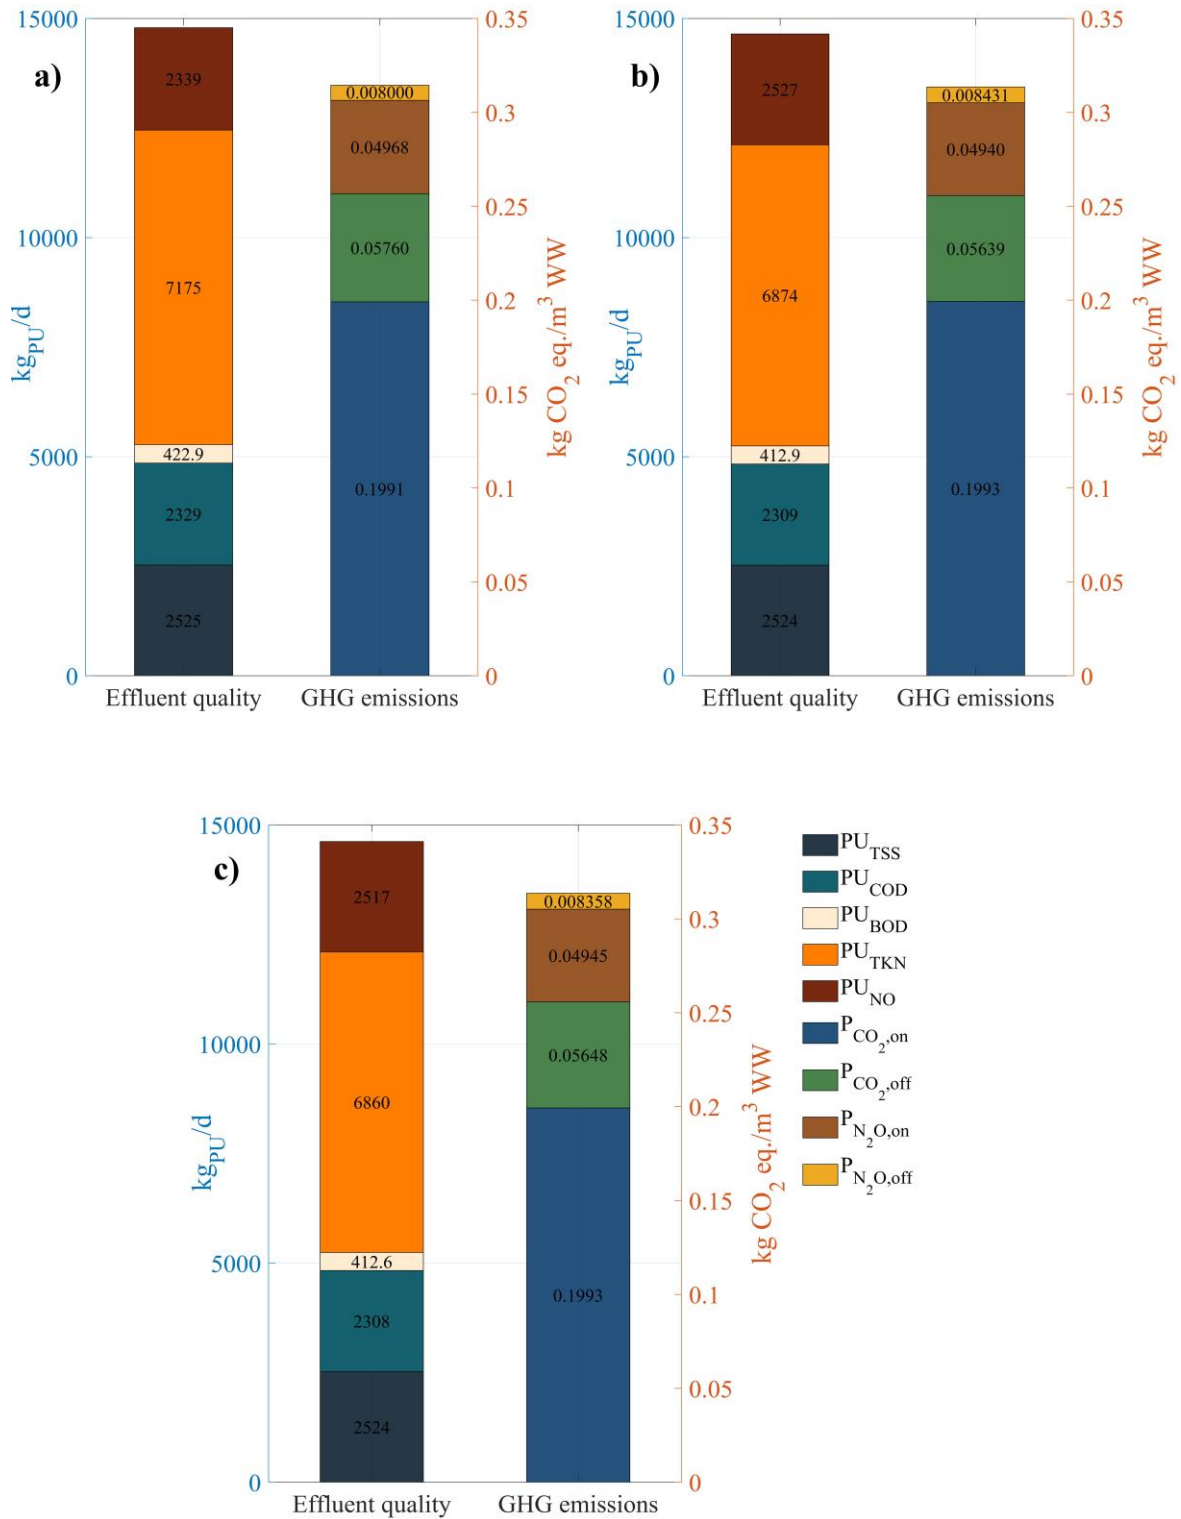


Cele mai promițătoare trei setări de distribuție a fluxului de aer, obținute din ambele cazuri de optimizare, au fost evaluate prin implementarea lor WWTP primul model extins de principiu, aceste rezultate fiind rezumate în Tabelul 3.8.

Table 3.8 Rezultatele performanței de funcționare optimizată a stației de epurare

Case	Point number	G1	G2	G3	Energy consumption (kWh/zi)	GHG emissions (kg CO <sub>2</sub> eq./m <sup>3</sup> WW)	Effluent quality (kg <sub>PU</sub> /zi)
Base Case		1.000	1.000	1.000	2.025E+04	0.31437	1.479E+04
Optimization Case 1	No. 1	0.8000	0.6000	0.4000	1.984E+04	0.31350	1.465E+04
	No. 3	0.8000	0.6000	0.4304	1.992E+04	0.31366	1.463E+04
	No. 16	0.9092	0.6086	0.4311	1.987E+04	0.31357	1.462E+04
Optimization Case 2	No. 2	0.8000	0.6000	0.4299	1.992E+04	0.31366	1.463E+04
	No. 10	0.8142	0.6001	0.4286	1.991E+04	0.31364	1.463E+04
	No. 18	0.8000	0.6000	0.4105	1.987E+04	0.31355	1.464E+04

Cele mai bune două cazuri optimizate (Cazul de optimizare 1 numărul 1 și numărul 16) au fost analizate și comparate cu Cazul de bază mai detaliat, prezentat în figura 3.6.



**Figura 3.6** Contribuții la calitatea efluenților și la emisiile de GHG pentru: a) Cazul de bază, b) Cazul de optimizare 1 numărul 1 și c) Cazul de optimizare 1 numărul 16

### **3.4. Optimizarea sezonieră a punctului de setare DO pentru instalația de tratare a apei uzate la scară completă**

În acest al patrulea studiu de caz a fost evaluată întreaga stație de epurare, nu numai procesele de tratare a apei, ci și cele de tratare a nămolului, în comparație cu studiile de caz anterioare. În plus, a fost adoptată o abordare de modelare sezonieră, deoarece procesele sunt influențate de condițiile sezoniere, astfel încât este necesar un model separat pentru fiecare perioadă a anului pentru a obține modele precise. La fel ca în cazul studiului de caz anterior, au fost utilizate GA în căutarea arhitecturilor optime pentru modelele RNA.


Scopul studiului actual a fost acela de a aborda optimizarea funcționării sezoniere a stației de epurare a apelor uzate, luând în considerare majoritatea proceselor biologice intrinseci prin luarea în considerare a complexului ASM2d și prin utilizarea modelării sale dinamice bazate pe RNA.

Prima noutate a lucrării de față constă în evaluarea calității efluenților și a emisiilor de GHG ale instalației cu ajutorul modelelor RNA, corelând în mod direct variabilele legate de influentul și controlul aerării cu indicii de performanță ai stației de epurare. Cea de-a doua vizează optimizarea bazată pe algoritmi genetici a rețelelor neuronale artificiale dinamice, cu scopul final de a optimiza funcționarea sezonieră a stației de epurare. Metoda propusă pentru dezvoltarea modelelor RNA constă în utilizarea GA pentru a găsi hiperparametrii optimi ai NARX, modele denumite GA-NARX. Etapele principale ale studiului au fost următoarele:

- Generarea, selectarea și preprocesarea datelor sezoniere pentru antrenarea modelului RNA.
- Optimizarea hiperparametrilor NARX cu ajutorul GA și găsirea unor modele GA-NARX precise pentru predicția indicilor de performanță a plantelor.
- Utilizați modelele antrenate de RNA pentru a optimiza cu frontul Pareto performanța sezonieră de funcționare a stației de epurare prin calcularea punctului de setare a oxigenului dizolvat al buclei de control esențiale responsabile de aerare.
- Evaluarea performanței stației de epurare cu puncte de reglaj optimizate pentru îmbunătățirea calității efluenților și reducerea emisiilor de GHG.

Construirea modelelor RNA se bazează în mod substanțial pe baza de date utilizată și afectează în mare măsură rezultatul și eficiența procesului de antrenare. Studiul actual a fost realizat cu seturi de date simulate, care au fost obținute prin utilizarea modelului de simulare de referință nr. 2 (BSM2) și în conformitate cu caracteristicile generale definite în raportul tehnic asociat [29]. Modelul utilizat a fost o versiune extinsă a BSM2 care descrie, de asemenea, transformările P, S și Fe, ale căror detalii pot fi găsite în [41,42]. Din cele 609 zile de intrări dinamice ale BSM2, a fost aleasă o perioadă de un an, începând cu ziua 45 și cuprinzând un total de 364 de zile. Datele de antrenare au fost colectate din simulările efectuate cu aceste 364 de zile, folosind un timp de eșantionare de 15 minute a dinamicii influenței. Toate anotimpurile au fost considerate

ca având o durată de 91 de zile, iar cele 364 de zile de date au fost împărțite în mod egal în 4 părți, după cum se arată în Figura 3.7.



**Figura 3.7** Modificarea temperaturii de intrare în timpul setului de date BSM2 de 609 zile și selectarea datelor sezoniere

Pentru a lua în considerare și poluarea datorată P eliberat în corpurile de apă receptoare, a fost adoptată o versiune extinsă a criteriilor EQ, așa cum este descrisă de ecuația (3.12) [42].

$$EQ = \frac{1}{1000 \cdot ts} \cdot \int_{t_i}^{t_{i+1}} \left[ PU_{TSS}(t) + PU_{COD}(t) + PU_{BOD_5}(t) + PU_{TKN}(t) + PU_{NO}(t) + PU_{P_{inorg}}(t) + PU_{P_{org}}(t) \right] \cdot Q_e(t) dt \quad (3.12)$$

Indicele de calitate a efluentului evaluează masa de poluanți evacuată zilnic prin luarea în considerare a valorilor efluenților de solide totale în suspensie ( $PU_{TSS}$ ), consum chimic de oxigen ( $PU_{COD}$ ), BOD ( $PU_{BOD}$ ), azotul Kjeldahl total ( $PU_{TKN}$ ), azotul nitrat și nitrit ( $PU_{NO}$ ), P anorganic ( $PU_{P_{inorg}}$ ), P organic ( $PU_{P_{org}}$ ) și luând în considerare debitul de efluent ( $Q_e$ ). Calculul EQ și al componentelor sale a fost efectuat conform descrierii din [42].

Emisiile (kg  $CO_2$  eq./zi) eliberate ca urmare a proceselor biologice aerobe, au fost evaluate pe baza relației descrise în ecuația (3.13) [34].

$$P_{CO_2,ABP} = \left( 0.99 \cdot (1 - Y_H) \cdot \eta_{ASP} \cdot bCOD + 1.03 \cdot Y_H \cdot \eta_{ASP} \cdot bCOD \cdot \frac{k_{d,H} \cdot MCRT}{1 + k_{d,H} \cdot MCRT} \right) \cdot Q_i \quad (3.13)$$

aici, 0,99 (kg CO<sub>2</sub> eq./kg COD) este factorul de emisie corespunzător compușilor organici, Y<sub>H</sub> este randamentul biomasei heterotrofe în (masă VSS/masă COD) cu o valoare de 0,625, η<sub>ASP</sub> se referă la eliminarea bCOD în reactoarele cu nămol activat, 1,03 (kg CO<sub>2</sub> eq. /kg COD) este un factor de emisie în raport cu biomasa de nămol activat, k<sub>d,H</sub> este rata de descompunere pentru biomasa heterotrofă cu o valoare de 0,28 (d<sup>-1</sup>), MCRT este timpul mediu de rezidență celulară, egal cu 15 zile, iar Q<sub>i</sub> este debitul de influență al instalației (m<sup>3</sup>/zi).

Echivalentul de CO<sub>2</sub> (kg CO<sub>2</sub> eq./zi) al N<sub>2</sub>O produs în procesele biologice aerobe (nitrificare și denitrificare) a fost calculat conform ecuației (3.14), considerând o producție de N<sub>2</sub>O egală cu 0,5% din încărcătura de N din afluent [36,39].

$$P_{N_2O,ABP} = Q_i \cdot N_{total,i} \cdot 0.005 \cdot GWP_{N_2O} \quad (3.14)$$

Producția de CO<sub>2</sub> rezultată din utilizarea metanului produs a fost calculată pornind de la ipoteza că 99% din acesta este ars într-un motor pe gaz, în timp ce restul de 1% se scurge în atmosferă [36]. Producția de metan a fost calculată pe baza [43], în timp ce CO<sub>2</sub> produs a fost calculat pe baza stoichiometriei reacției de oxidare, așa cum este descrisă în ecuația (3.15).

$$P_{CO_2,CH_4} = 0.99 \cdot MP \cdot \frac{44}{16} \quad (3.15)$$

aici, MP este debitul masic al metanului produs (kg CH<sub>4</sub>/zi).

Echivalentul de CO<sub>2</sub> al metanului scurs a fost calculat după cum urmează:

$$P_{CH_4} = 0.01 \cdot MP \cdot GWP_{CH_4} \quad (3.16)$$

unde GWP<sub>CH<sub>4</sub></sub> este potențialul de încălzire globală în raport cu CO<sub>2</sub> pentru CH<sub>4</sub>, cu o valoare de 28 [19].

Consumul net de energie (kWh/zi) pentru stația de epurare a fost calculat ca diferență între cererea zilnică de energie și recuperarea energiei. Ecuațiile (3.17)-(3.19) prezintă metoda de calcul pentru emisiile de GHG datorate consumului de energie, cererii de energie și, respectiv, recuperării de energie.

$$P_{CO_2,energy} = (e_D - e_R) \cdot EF_{energy} \quad (3.17)$$

$$e_D = AE + PE + ME + HE_{net} \quad (3.18)$$

$$e_R = 0.99 \cdot 6 \cdot MP \quad (3.19)$$

aici, EF<sub>energy</sub> este intensitatea emisiilor de GHG a producției de energie electrică la nivelul UE în anul 2021, cu o valoare de 0,275 kg CO<sub>2</sub> eq./kWh [147], 0,99 este factorul legat de ipoteza de scurgere a metanului produs. Calculul componentelor AE, PE, ME, HE<sub>net</sub>, MP a fost efectuat așa cum este descris în [43], cu o mică diferență în calculul HE<sub>net</sub>, unde factorul 0,99 a fost luat în considerare și pentru căldura produsă.

Emisiile de GHG datorate eliminării nămolului în depozitele de deșeuri au fost calculate ca fiind CO<sub>2</sub> (kg CO<sub>2</sub>/zi) generat de arderea biogazului în depozitele de deșeuri, așa cum se arată în ecuația (3.20) [36,44].

$$P_{CO_2,landf} = \frac{110}{113} \cdot W_{S,landf} + \frac{40}{113} \cdot \frac{44}{16} \cdot W_{S,landf} \quad (3.20)$$

unde W<sub>S,landf</sub> este cantitatea de nămol eliminat la depozitele de deșeuri (kg VS/zi).

Echivalentul de CO<sub>2</sub> (kg CO<sub>2</sub> eq./zi) al N<sub>2</sub>O produs de degradarea biologică în sistemul din aval al staţiei de epurare a fost calculat cu ajutorul ecuaţiei (3.21) [39].

$$P_{N_2O,downs} = \frac{44}{28} \cdot 0.005 \cdot N_{total,e} \cdot GWP_{N_2O} \quad (3.21)$$

aici, 44/28·0,005 este factorul de emisie pentru emisiile de N<sub>2</sub>O din apele uzate tratate (kg N<sub>2</sub>O/kg N), iar N<sub>total,e</sub> este debitul masic total de N din efluent (kg N/zi).

Cele mai performante modele GA-NARX au fost utilizate într-o sarcină de optimizare pentru a determina valoarea optimă a punctului de setare a buclei de control DO pentru oxigenul dizolvat în efluentul celui de-al doilea bioreactor aerat, luând în considerare perioada de timp de bază de 30 de zile în cazul fiecăruia dintre cele patru anotimpuri. Predicţiile privind emisiile de EQ și de GHG ale modelelor GA-NARX au fost utilizate ca două părţi ale funcţiei obiectiv într-o sarcină de optimizare multi-obiectiv bazată pe GA.

Soluţiile cele mai favorabile rezultate în urma sarcinii de optimizare a punctului de referinţă DO au fost testate prin simulare dinamică pe modelul matematic. Pentru o evaluare amănunţită a funcţionării optimizate a staţiei de epurare, s-a calculat, de asemenea, indicele costurilor operaţionale (OCI) atât pentru cazul optimizat, cât și pentru cazul de bază. OCI descrie funcţionarea procesului de tratare a apelor uzate prin raportarea acestuia la factorii de cost. Acesta este calculat ca o sumă ponderată a costurilor din cadrul staţiei de epurare și este descris în ecuaţia (3.23).

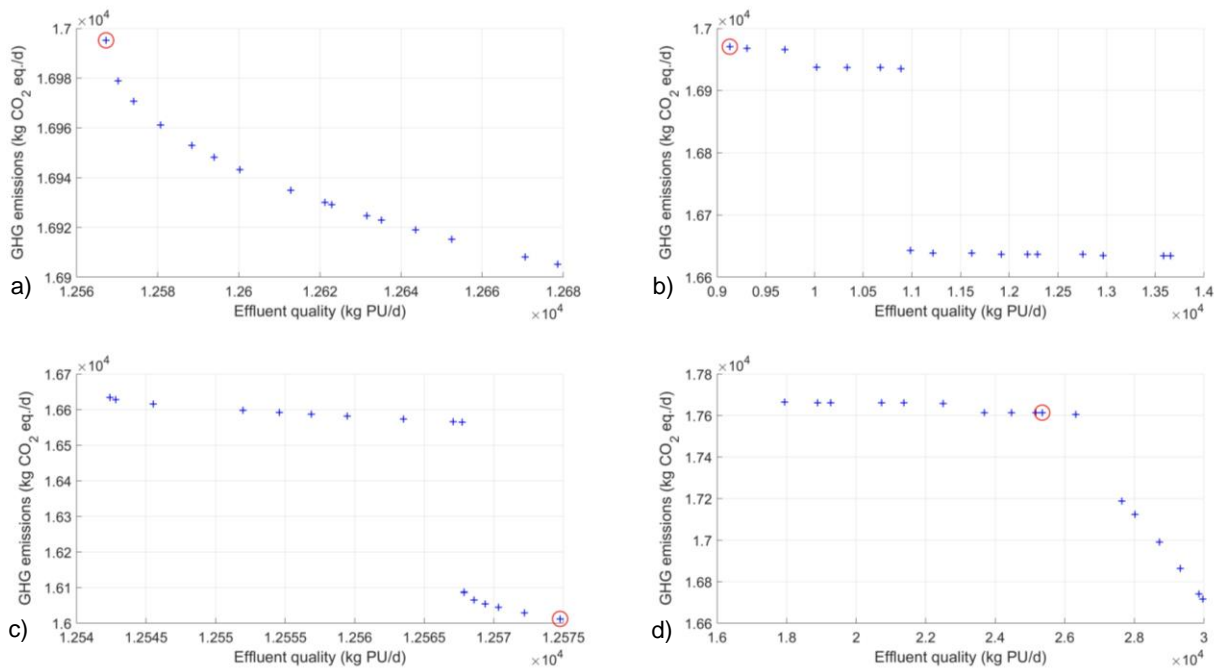
$$OCI = 3 \cdot SP + 3 \cdot EC + e_D - e_R \quad (3.23)$$

Parametrii luaţi în considerare la selectarea celui mai precis model RNA pentru utilizarea ulterioară au fost MSE, MAPE și R<sup>2</sup>. Au fost analizate două scenarii distincte în ceea ce priveşte definirea celui mai precis model. În primul caz (Cazul 1), modelul a fost salvat dacă toţi cei trei parametri de evaluare au depăşit cele mai bune rezultate obţinute anterior. În cel de-al doilea caz (Cazul 2), reţeaua a fost salvată atunci când oricare dintre cele trei metrici a prezentat rezultate mai bune decât cel mai bun rezultat anterior al acelei metrici.

Cele mai performante reţele de modelare a EQ au prezentat valori R<sup>2</sup> cuprinse între 0,9930 și 0,9950. În timp ce în cazul valorilor MAPE, acestea s-au situat între 3,53% și 4,25%. În ceea ce priveşte modelarea GA-NARX a emisiilor de GHG, intervalele rezultate pentru aceste valori au fost cuprinse între 0,9867 și 0,9872 și între 2,79% și 2,88% pentru R<sup>2</sup> și, respectiv, MAPE. Precizia modelelor RNA dezvoltate a fost considerată similară cu valorile raportate în literatura de specialitate.

Setările optime ale DO selectate pentru testarea pe perioadele de 30 de zile din fiecare set de date sezoniere sunt asociate punctelor evidenţiate cu un cerc roşu în figura 3.8. Valorile obţinute din fronturile Pareto care au fost testate prin simulare dinamică pe modelul matematic au fost următoarele: 1,373 mg O<sub>2</sub>/L pentru iarnă, 1,911 mg O<sub>2</sub>/L pentru primăvară, 1,553 mg O<sub>2</sub>/L pentru vară și 1,837 mg O<sub>2</sub>/L pentru sezonul de toamnă. Fiecare dintre valorile menţionate mai sus au fost aplicate ca puncte de setare pentru regulatorul

OD pentru perioada centrală de testare de 30 de zile din fiecare sezon. EQ, emisiile de GHG și OCI obținute prin implementarea acestor puncte de setare au fost comparate cu rezultatele cazului de bază. Aceste rezultate sunt prezentate în Tabelul 3.9. Au fost calculate, de asemenea, diferențele relative (Relative diff.) între cazul de bază și cel optimizat pentru a afișa mai bine cantitatea de schimbări și stimulente pe care le-a adus cazul optimizat în raport cu cazul de bază.



**Figura 3.8** Fronturi Pareto și soluții selectate pentru testarea pe date sezoniere din: a) iarnă, b) primăvară, c) vară și d) toamnă

Valorile OCI pentru cazurile optimizate au prezentat îmbunătățiri pentru toate datele sezoniere, cu valori cuprinse între 0,25% și 0,90%. La fel ca și în cazul GHG, acest indice este influențat și prin modificarea consumului de energie adusă de valorile mai mici ale punctului de setare DO. Ca urmare a optimizării funcționării, s-a obținut o scădere simultană atât a EQ, cât și a OCI pentru toate datele sezoniere, ceea ce înseamnă că s-a obținut un proces de tratare mai performant în ceea ce privește numărul de kg PU pe unități OCI. În general, rezultatele au indicat că diferitele scenarii sezoniere necesită setări distincte pentru a obține o funcționare îmbunătățită a stației de epurare.

De asemenea, este important de remarcat faptul că timpul de procesare a calculatorului și resursele de calcul pentru sarcina de optimizare multi-obiectiv a fost mult redus datorită utilizării modelelor GA-NARX. Timpul necesar pentru a finaliza procedura de optimizare multi-obiectiv prin atingerea limitei de generații fixe considerate a fost de aproximativ 600 de secunde. Concomitent, o singură simulare a perioadei de timp



de 30 de zile utilizând modelul matematic de prim principiu a durat peste 630 de secunde, folosind aceeași putere de calcul. Presupunând că aceeași optimizare care utilizează modelul matematic de prim principiu pentru calculul funcției obiectiv ar avea nevoie de același număr de iterații pentru a se finaliza, aceasta ar obține rezultate într-un timp de procesare cu patru ordine de mărime mai mare. Cu alte cuvinte, căutarea setării optime pentru un scenariu de 30 de zile ar necesita aproape 73 de zile de calcul atunci când se utilizează modelul bazat pe primul principiu, în timp ce aceeași sarcină de optimizare este realizată de modelele GA-NARX dezvoltate în 10 minute.





Tabel 3.9 Rezultatele EQ, GHG și OCI obținute în cazul de bază și în cazul optimizat

Case	Winter			Spring			Summer			Autumn		
	EQ	GHG	OCI	EQ	GHG	OCI	EQ	GHG	OCI	EQ	GHG	OCI
	kg PU/zi	kg CO <sub>2</sub> eq./zi	-	kg PU/zi	kg CO <sub>2</sub> eq./zi	-	kg PU/zi	kg CO <sub>2</sub> eq./zi	-	kg PU/zi	kg CO <sub>2</sub> eq./zi	-
Base case	13158	16819	9256	12555	16584	9544	13034	16713	10384	12961	16950	10275
Optimized	12252	16804	9226	12355	16571	9518	11299	16646	10290	12375	16926	10249
Relative diff. (%)	-6.88	-0.09	-0.33	-1.60	-0.08	-0.26	-13.31	-0.40	-0.90	-4.52	-0.14	-0.25

#### 4. Detectarea și identificarea tipurilor de defecțiuni ale senzorilor DO

Tehnicile de inteligență artificială au avut ca scop detectarea defecțiunilor senzorilor și diagnosticarea tipului de eroare într-o varietate de domenii. Acestea s-au dovedit a fi un instrument eficient, destinat diferitelor implementări în stațiile de epurare pentru. O diagnoză a erorilor cu ajutorul RNA a fost aplicată cu succes la măsurătorile de încărcare a nămolului, cu intenția de a asigura siguranța procesului și calitatea efluenților din stațiile de epurare. Modelul dezvoltat a putut diferenția cinci tipuri de defecte de încărcare a nămolului [45]. Cu toate acestea, rețelele neuronale artificiale au fost aplicate foarte puțin la identificarea defecțiunilor senzorilor de la stațiile de epurare, dar potențialul lor este semnificativ.

Scopul studiului actual a fost de a proiecta, antrena și testa performanța unui instrument bazat pe RNA care este capabil să detecteze și să identifice șapte tipuri de defecțiuni ale senzorilor de oxigen dizolvat. Noutatea constă în aplicarea instrumentului de diagnosticare RNA propus pentru stația de epurare municipală cu configurație A<sup>2</sup>O, având implementate cele două bucle de control principale, una pentru nitrificare și alta pentru denitrificare (Figura 3.2).

Datele necesare pentru dezvoltarea instrumentului de identificare a defecțiunilor RNA au fost obținute folosind un model de nămol activat de primă instanță calibrat anterior, modelul nr.1 al stației de epurare considerat ca studiu de caz. Au fost simulate șapte tipuri de defecțiuni ale senzorului pentru senzorul de oxigen dizolvat: polarizare, cunoscută și sub denumirea de deplasare sau decalare a semnalului; defecțiune completă, care poate fi maximă sau minimă și apare atunci când valoarea măsurată este fie cea mai mare, fie cea mai mică valoare din intervalul de calibrare a senzorului; derivă, care reprezintă o abatere neregulată în timp a valorii măsurate, în comparație cu cea reală a DO; valoare fixă, atunci când valoarea semnalului DO este constantă; pierderea preciziei, ceea ce înseamnă că valoarea furnizată de senzor este afectată de imprecizie în jurul valorii reale; câștig greșit, cunoscut și ca o eroare de calibrare tipică [46].

Setul de date a fost împărțit în următoarele părți atunci când a fost utilizat algoritmul de antrenare Levenberg-Marquardt: 70% pentru antrenare, 15% pentru validare și 15% pentru testare. Rezultatele antrenamentului au arătat rezultate bune, cu excepția celei mai mari valori de confuzie obținute, de 58,7 %, datorată confuziei dintre tipurile de defecțiuni cu defecțiune maximă completă (clasa 3) și cu valoare fixă (clasa 6), caracterizate prin efecte comparabile.

În comparație cu prima abordare de antrenare, clasificarea realizată de cea de-a doua RNA instruită care a utilizat algoritmul de regularizare Bayesiană a prezentat rezultate mai bune. Rezultatele obținute pentru setul de date de testare sunt prezentate în figura 4.1. Această metodă de antrenare nu a necesitat un set de date de validare. Prin urmare, 85% din date au fost utilizate pentru antrenare, în timp ce restul de 15% au constituit setul de date de testare. În ceea ce privește antrenarea, cea mai mare valoare de confuzie

a fost de 1,1 % în cazul defectului de câștig greșit, unde din 1920 de puncte de date doar 21 au fost clasificate ca alte clase de defecte.


**Confusion Matrix**

1	600 23.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	260 10.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	99.6% 0.4%
3	0 0.0%	0 0.0%	269 10.4%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	99.6% 0.4%
4	0 0.0%	1 0.0%	0 0.0%	281 10.8%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	99.3% 0.7%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	280 10.8%	0 0.0%	3 0.1%	3 0.1%	97.9% 2.1%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	287 11.1%	0 0.0%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	1 0.0%	1 0.0%	0 0.0%	298 11.5%	1 0.0%	99.0% 1.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	304 11.7%	100% 0.0%
	100% 0.0%	99.6% 0.4%	100% 0.0%	99.6% 0.4%	99.3% 0.7%	99.7% 0.3%	98.7% 1.3%	98.7% 1.3%	99.5% 0.5%
	1	2	3	4	5	6	7	8	
	<b>Target Class</b>								

**Figura 4.1** Matricea de confuzie a setului de date de testare pentru RNA antrenat cu algoritmul de regularizare Bayesiană

Identificarea corectă a tipului de defecțiune poate dura perioade de timp diferite, în funcție de tipul de defecțiune. În mod predominant, rețeaua de clasificare a identificat rapid și corect diferitele tipuri de defecte. Aceste perioade de timp ale identificării ferm corecte sunt: 3 ore pentru părtinire, 2,5 ore în cazul defectului complet maxim, 2,5 ore la defectul complet minim, 3 ore pentru derivă, 3,5 ore pentru fix, 4 ore

la pierderea preciziei și cea mai lungă identificare de 11 ore în cazul câștigului greșit, prezentată, de asemenea, în Figura 4.2.



**Figura 4.2** Clasificarea setului de date de testare pentru tipul de eroare a senzorului DO cu pierdere de precizie

## 5. Concluzii finale

Cercetările efectuate în cadrul prezentei teze s-au concentrat pe îmbunătățirea funcționării stației de epurare a apelor uzate. Un aspect cheie al studiilor a fost dezvoltarea unor modele RNA precise pentru ca acestea să fie utilizate fie în optimizare (Capitolul 3), fie în sarcinile de detectare și identificare a defecțiunilor (Capitolul 4). Procesul de tratare a apelor uzate a fost evaluat din punct de vedere al emisiilor de GHG, al consumului de energie, al calității efluenților și al costului total.

Secțiunea 3.1 s-a axat pe optimizarea debitelor de reciclare care influențează procesele de eliminare biologică a nutrienților într-un context în care sistemul nu dispune de bucle de control. În primul rând, un model Matlab/Simulink dezvoltat anterior și calibrat pe date reale ale instalației a fost utilizat pentru a genera setul de date pentru dezvoltarea a patru tipuri de modele RNA. Acestea au fost concepute pentru a emite direct criteriile de evaluare a stației de epurare fără a fi nevoie de calcule suplimentare. Caracteristicile de intrare ale acestor modele au constat în parametrii de intrare și de funcționare a instalației. A fost utilizat un design factorial complet pentru a găsi cele mai bune arhitecturi de rețea atât pentru modelele MISO, cât și pentru cele MIMO. Modelele au fost validate pe un set de date separat, care nu a fost utilizat la formarea lor, iar performanța lor a fost comparată cu modelele găsite în literatura de specialitate. Acest proces de dezvoltare a avut ca rezultat modele RNA care au prezentat valori aproape optime în ceea ce privește valorile  $R^2$  și valori MAPE foarte satisfăcătoare, care au variat de la 0,89 la 0,99 și, respectiv, de la 0,85 la 3,50.

Aceasta a fost urmată de implementarea celor mai bune modele RNA în sarcina de optimizare în care au fost căutați doi factori de câștig care influențează debitele fluxurilor de reciclare internă și externă, luând în considerare un scenariu de 7 zile. În acest studiu de caz, suma ponderată a energiei de aerare, a energiei de pompare și a calității efluentului a reprezentat funcția obiectiv. Rezultatele au fost testate pe modelul Simulink și au fost comparate cu cazul de referință și cu optimizarea în cazul în care a fost utilizat modelul matematic. Valorile optime găsite de RNA au arătat că consumul de energie ar putea fi redus cu 4,2 %, deși calitatea efluentului s-a înrăutățit ușor. Valorile găsite cu ajutorul modelului matematic propriu-zis ar putea fi considerate superioare, deoarece cererea de energie a fost redusă cu aproape aceeași cantitate, însoțită de o îmbunătățire marginală a calității efluentului. Cu toate acestea, procesul de optimizare cu modelele RNA a fost cu patru ordine de mărime mai scurt, demonstrând un potențial promițător în aplicații în timp real.

Secțiunea 3.2 prezintă optimizarea punctelor de reglare a buclelor de control în ceea ce privește cele două bucle de control care acționează asupra debitelor fluxurilor de reciclare internă și externă. O abordare similară a fost adoptată în ceea ce privește generarea datelor și dezvoltarea modelului RNA, adică au fost luate în considerare patru tipuri de RNA care au modelat indicii de energie și de calitate a efluentului pe baza parametrilor de influent și de funcționare a instalației, atât în cazul structurilor MISO, cât și MIMO.

În plus, acest studiu a investigat influența întârzierii de intrare asupra preciziei rețelelor neuronale dezvoltate. Acest hiperparametru este esențial în modelarea dinamică și a fost rareori discutat în literatura de specialitate, în special în aplicațiile de modelare a stațiilor de epurare. Optimizarea acestui hiperparametru a condus la îmbunătățirea acurateții rețelelor de la un interval de 1,51 la 3,09 la un interval de 1,27 la 2,57 în ceea ce privește valorile MAPE și de la valori cuprinse între 0,95 și 1,00 la valori cuprinse între 0,97 și 1,00 atunci când se analizează rezultatele  $R^2$ .

Aceste modele RNA îmbunătățite au fost utilizate în optimizarea celor două bucle de control pentru un scenariu de o săptămână. Funcția obiectiv a fost din nou definită ca o sumă ponderată a celor trei indici de performanță a stației de epurare. Sarcina de optimizare a fost realizată, de asemenea, prin utilizarea modelului matematic, iar rezultatele au fost comparate cu cele obținute de modelele RNA și cu un caz de referință. Soluțiile găsite de structurile RNA și de modelul de prim principiu au fost foarte asemănătoare. Cu toate acestea, de data aceasta, rețelele neuronale au depășit abordarea clasică, cu îmbunătățiri de 8,9% și 2% în ceea ce privește consumul de energie și calitatea efluenților, fiind totodată mai rapide de aproximativ 200 de ori.

Secțiunea 3.3 discută optimizarea unei strategii noi referitoare la distribuția debitului de aer în bioreactorul aerat. Distribuția neuniformă a aerului comprimat este propusă pentru a facilita ritmul proceselor biologice la începutul bioreactorului aerat. În acest studiu, funcționarea stației de epurare a fost evaluată din punct de vedere al eficienței energetice, al calității efluenților, precum și al emisiilor de gaze cu efect de seră. Structurile MISO au fost luate în considerare pentru cele două tipuri de NARX care au fost luate în considerare, dar dezvoltarea modelelor RNA a inclus, de asemenea, o abordare nouă, și anume o sarcină de optimizare realizată prin GA în scopul găsirii celor mai potrivite arhitecturi pentru a modela nu numai indicii de performanță, ci și diverse concentrații de efluenți, precum și emisiile stației de epurare. Utilizarea rețelelor neuronale pentru a modela emisiile de GHG nu a fost încă investigată în acest domeniu de studiu. Emisiile au luat în considerare atât emisiile de la fața locului, cât și cele din afara acestuia pentru gazele  $CO_2$  și  $N_2O$ . Acuratețea modelelor GA-NARX obținute a variat de la 0,05 la 21,5 valori MAPE, atunci când au fost prezentate cu un nou set de date de intrare.

Cele mai bune modele GA-NARX au fost utilizate în două sarcini de optimizare multi-obiectiv pentru un scenariu de 7 zile, căutând cei mai buni factori de creștere a aerării atunci când funcțiile obiectiv ale optimizării multi-obiectiv au fost consumul de energie, calitatea efluentului și consumul de energie. Primul caz de optimizare a utilizat modelele pentru indicii de performanță și emisiile de GHG, în timp ce al doilea caz de optimizare a utilizat modelele pentru concentrațiile de efluenți, indicii de energie și emisiile de GHG. În același timp, al doilea caz de optimizare a ținut cont de reglementările locale privind concentrațiile de poluanți în efluenți, iar pentru soluțiile care nu le respectau au fost emise sancțiuni. Cele două sarcini de optimizare au avut ca rezultat câte un front Pareto, ambele conținând 18 scenarii posibile pentru cei trei

factori de câștig de aerare. Acestea au fost clasificate, iar cele mai bune trei din fiecare front au fost testate pe modelul matematic și comparate cu scenariul de referință. Cererea de energie și emisiile de gaze cu efect de seră au fost ambele reduse cu până la 2%, în timp ce calitatea efluenților a fost, de asemenea, îmbunătățită cu până la 1,1%. Investigarea contribuțiilor EQ și GHG ale diferitelor surse a arătat că îmbunătățirea EQ poate fi atribuită în principal scăderii nivelurilor de TKN, în timp ce reducerea emisiilor de GHG poate fi atribuită emisiilor de CO<sub>2</sub> în afara amplasamentului datorită scăderii consumului de energie, validând strategia de operare propusă.

Secțiunea 3.4 s-a axat pe o noțiune recent introdusă de modelare sezonieră a stației de epurare a apelor uzate și a cuplat-o cu optimizarea multi-obiectivă a punctului de reglare a buclei de control a oxigenului dizolvat pentru o stație de epurare la scară reală. Studiul prezentat în această secțiune a utilizat o versiune extinsă a BSM2 pentru generarea de date, în timp ce metodologia GA-NARX discutată anterior a fost aplicată pentru dezvoltarea modelului RNA, însă hiperparametrii optimizați au fost extinși cu algoritmul de antrenare pentru care au fost luați în considerare cei trei cei mai frecvent utilizați în acest domeniu de studiu. Rețelele au avut 13 caracteristici de intrare constând în parametri de influență și de operare și au prezis calitatea efluentului și emisiile de GHG ale stației de epurare. În acest caz, au fost luate în considerare și emisiile de CH<sub>4</sub>. Rezultatele testării modelului RNA au arătat un interval de performanță de la 0,987 la 0,995 în ceea ce privește R<sup>2</sup>, în timp ce valorile pentru MAPE s-au situat între 2,79 și 4,25.

Setarea optimă a DO a fost căutată pentru o perioadă de timp de 30 de zile, luând în considerare calitatea efluenților și emisiile de GHG ca fiind cele două obiective pentru sarcina de optimizare multi-obiectiv. Optimizarea a fost realizată pentru toate cele patru anotimpuri, oferind un set de 18 soluții posibile pentru fiecare anotimp, cunoscut sub numele de front Pareto. Soluția considerată ca fiind cea mai bună a fost testată pe modelul matematic și comparată cu cazul de referință. Valorile DO pentru sezoane au variat între 1,373 și 1,911 mg O<sub>2</sub>/L, implementarea acestora a îmbunătățit calitatea efluenților cu până la 13,3% și, de asemenea, a redus ușor emisiile de GHG cu mai puțin de 1%. Aceste îmbunătățiri ale funcționării stației de epurare au fost, de asemenea, însoțite de o reducere a costului total cu aproape 1%. Reducerea emisiilor a fost atribuită reducerii consumului de energie, care se datorează unor valori de referință ale DO mai mici decât valoarea de referință. Sarcina de optimizare prin utilizarea modelelor GA-NARX s-a încheiat în câteva minute, în timp ce aceeași sarcină ar fi durat mai mult de 30 de zile pentru scenariul de 30 de zile, adică o diferență de patru ordine de mărime. Modelele de rețele neuronale și-au demonstrat potențialul promițător pentru diverse aplicații, cum ar fi sprijinul pentru luarea deciziilor sau controlul bazat pe model al funcționării stațiilor de epurare.

Capitolul 4 prezintă investigarea modelelor RNA ca instrumente soft pentru detectarea și identificarea defecțiunilor senzorilor DO. Instrumente soft similare au fost investigate în literatura de specialitate, însă nu au fost încă aplicate în cazul stațiilor de tratare a apelor uzate. În cadrul studiului au fost luate în

considerare șapte tipuri de defecte, iar modelul Matlab/Simulink calibrat a fost utilizat în scopul generării de date. Rețelele au fost dezvoltate utilizând 20 de caracteristici de intrare care cuprind variabilele de intrare și concentrația mai multor specii din efluentul de fond al clarificatorului secundar, în timp ce obiectivul rețelei a fost de a clasifica funcționarea senzorului într-una dintre cele 8 categorii, și anume funcționarea normală și cele șapte tipuri de defecte. Pentru a găsi cel mai performant model de rețea neuronală, s-a utilizat un proces de încercare și eroare prin căutarea arhitecturii și a algoritmului de formare optimi. Metodele de antrenare luate în considerare au fost algoritmi Levenberg-Marquardt și de regularizare Bayesiană.

Rețeaua cea mai precisă dezvoltată cu fiecare algoritm de formare a fost testată cu un nou set de date de intrare. Ambele modele RNA au avut performanțe remarcabile în ceea ce privește detectarea tipurilor de defecte, rețeaua antrenată cu algoritmul Levenberg-Marquardt a prezentat un procent de confuzie de 0%, ceea ce indică faptul că clasificarea a fost corectă în 100% din cazuri, în mod similar, rețeaua antrenată cu regularizarea Bayesiană a avut, de asemenea, performanțe impecabile, cu 0% confuzie. Diferențele dintre rețele au fost evidențiate la identificarea tipurilor de erori, unde RNA antrenată cu algoritmul Levenberg-Marquardt a confundat grav două tipuri de erori, fiecare dintre acestea rezultând în procente de confuzie de 44,2% și 41,3% pentru cele două, în timp ce a avut o acuratețe generală de 85,7%. Pe de altă parte, rețeaua neuronală antrenată cu regularizarea Bayesiană a demonstrat un grad de acuratețe mult mai mare, cu cea mai mare valoare de confuzie de 1,3% pentru o clasă individuală și o acuratețe generală aproape ideală de 99,5%. În același timp, identificarea corectă a tipurilor de defecte a fost realizată în câteva ore de la începutul comportamentului defectuos. RNA dezvoltat se arată promițător în utilizarea pentru monitorizarea precisă a proceselor din cadrul stației de epurare, sprijinind funcționarea sigură și eficiența a acestora.

Lucrările viitoare se pot concentra pe conectarea aspectelor din mai multe studii pentru o optimizare generală a funcționării stației de epurare sau pe extinderea cercetărilor prezente pentru a include alte tipuri de modele bazate pe date, precum și alte strategii de operare.



## Referințe

- [1] Le Treut H., R. Somerville, U. Cubasch, Y. Ding, C. Mauritzen, A. Mokssit, T. Peterson and M. Prather, 2007: Historical Overview of Climate Change. In: *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change* [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
- [2] Calvin K, Dasgupta D, Krinner G, Mukherji A, Thorne PW, Trisos C, et al. IPCC, 2023: *Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland. 2023. <https://zoi.org/10.59327/IPCC/AR6-9789291691647>.
- [3] International Energy Agency (IEA). *Tracking power 2020*. Paris: 2020.
- [4] IEA. *Coal-Fired Power*. Paris: 2020.
- [5] Gu Y, Li Y, Yuan F, Yang Q. Optimization and control strategies of aeration in WWTPs: A review. *J Clean Prod* 2023;138008. <https://zoi.org/10.1016/j.jclepro.2023.138008>.
- [6] Aghabalaei V, Nayeb H, Mardani S, Tabeshnia M, Baghdadi M. Minimizing greenhouse gases emissions and energy consumption from wastewater treatment plants via rational design and engineering strategies: A case study in Mashhad, Iran. *Energy Reports* 2023;9:2310–20. <https://zoi.org/10.1016/j.egy.2023.01.017>.
- [7] Zhao Y, Wesley Awe O, Liu R. Analysis of Energy Consumption and Saving in Wastewater Treatment Plant: Case Study from Ireland. *J Water Sustain* 2016;2:63–76. <https://zoi.org/10.11912/jws.2016.6.2.63-76>.
- [8] Cardoso BJ, Rodrigues E, Gaspar AR, Gomes Á. Energy performance factors in wastewater treatment plants: A review. *J Clean Prod* 2021;322:129107. <https://zoi.org/10.1016/j.jclepro.2021.129107>.
- [9] Qadir M, Drechsel P, Jiménez Cisneros B, Kim Y, Pramanik A, Mehta P, et al. Global and regional potential of wastewater as a water, nutrient and energy source. *Nat Resour Forum* 2020;44:40–51. <https://zoi.org/10.1111/1477-8947.12187>.
- [10] Di Fraia S, Massarotti N, Vanoli L. A novel energy assessment of urban wastewater treatment plants. *Energy Convers Manag* 2018;163:304–13. <https://zoi.org/10.1016/j.enconman.2018.02.058>.
- [11] Our World in Data. Electricity production by source. <https://ourworldindata.org/grapher/electricity-prod-source-stacked?stackMode=relative> (accessed September 14, 2023).
- [12] Ranieri E, D’Onghia G, Lopopolo L, Gikas P, Ranieri F, Gika E, et al. Evaluation of greenhouse gas emissions from aerobic and anaerobic wastewater treatment plants in Southeast of Italy. *J Environ Manage* 2023;337:117767. <https://zoi.org/10.1016/j.jenvman.2023.117767>.
- [13] Henze M, Gujer W, Mino T, van Loosedrecht M. Activated Sludge Models ASM1, ASM2, ASM2d and ASM3. *Water Intell Online* 2015;5:9781780402369–9781780402369. <https://zoi.org/10.2166/9781780402369>.

- [14] Simon Haykin. *Neural Networks and Learning Machines*. Third Edition. McMaster University, Canada: Pearson; 2008.
- [15] Zounemat-Kermani M, Stephan D, Hinkelmann R. Multivariate NARX neural network in prediction gaseous emissions within the influent chamber of wastewater treatment plants. *Atmos Pollut Res* 2019;10:1812–22. <https://zoi.org/10.1016/j.apr.2019.07.013>.
- [16] Zhu L, Wang C, Huang N, Fu Y, Yan Z. Developing an Indicator System to Monitor City's Sustainability Integrated Local Governance: A Case Study in Zhangjiakou. *Sustainability* 2022;14:5047. <https://zoi.org/10.3390/su14095047>.
- [17] Du W-J, Lu J-Y, Hu Y-R, Xiao J, Yang C, Wu J, et al. Spatiotemporal pattern of greenhouse gas emissions in China's wastewater sector and pathways towards carbon neutrality. *Nat Water* 2023;1:166–75. <https://zoi.org/10.1038/s44221-022-00021-0>.
- [18] Wang D, Ye W, Wu G, Li R, Guan Y, Zhang W, et al. Greenhouse gas emissions from municipal wastewater treatment facilities in China from 2006 to 2019. *Sci Data* 2022;9:317. <https://zoi.org/10.1038/s41597-022-01439-7>.
- [19] IPCC, 2014: IPCC Fifth Assessment Report: Climate Change 2014 (AR5). <https://www.ipcc.ch/report/ar5/syr/> (accessed September 12, 2023).
- [20] Bani Shahabadi M, Yerushalmi L, Haghghat F. Estimation of greenhouse gas generation in wastewater treatment plants - Model development and application. *Chemosphere* 2010;78:1085–92. <https://zoi.org/10.1016/j.chemosphere.2009.12.044>.
- [21] Daelman MRJ, van Voorthuizen EM, van Dongen LGJM, Volcke EIP, van Loosdrecht MCM. Methane and nitrous oxide emissions from municipal wastewater treatment – results from a long-term study. *Water Sci Technol* 2013;67:2350–5. <https://zoi.org/10.2166/wst.2013.109>.
- [22] Åmand L, Olsson G, Carlsson B. Aeration control – a review. *Water Sci Technol* 2013;67:2374–98. <https://zoi.org/10.2166/wst.2013.139>.
- [23] Ba-Alawi AH, Al-masni MA, Yoo C. Simultaneous sensor fault diagnosis and reconstruction for intelligent monitoring in wastewater treatment plants: An explainable deep multi-task learning model. *J Water Process Eng* 2023;55:104119. <https://zoi.org/10.1016/j.jwpe.2023.104119>.
- [24] Ba-Alawi AH, Loy-Benitez J, Kim S, Yoo C. Missing data imputation and sensor self-validation towards a sustainable operation of wastewater treatment plants via deep variational residual autoencoders. *Chemosphere* 2022;288:132647. <https://zoi.org/10.1016/j.chemosphere.2021.132647>.
- [25] Ge Z, Song Z, Gao F. Review of Recent Research on Data-Based Process Monitoring. *Ind Eng Chem Res* 2013;52:3543–62. <https://zoi.org/10.1021/ie302069q>.
- [26] Xi J, Gong H, Zhang Y, Dai X, Chen L. The evaluation of GHG emissions from Shanghai municipal wastewater treatment plants based on IPCC and operational data integrated methods (ODIM). *Sci Total Environ* 2021;797:148967. <https://zoi.org/10.1016/j.scitotenv.2021.148967>.
- [27] Várhelyi M, Cristea VM, Brehar M, Nemeș ED, Nair A. WWTP model calibration based on different optimization approaches. *Environ Eng Manag J* 2019;18:1657–70. <https://zoi.org/10.30638/eemj.2019.156>.
- [28] Otterpohl R. *Dynamische Simulation zur Unterstützung der Planung und des Betriebes von kommunalen Kläranlagen*. PhD thesis 1995.

- [29] Alex J, Benedetti L, Copp J, Gernaey K V., Jeppsson U, Nopens I, et al. Benchmark Simulation Model no. 2 ( BSM2 ). Iwa 2018;1:99.
- [30] Gan M, Peng H, Dong XP. A hybrid algorithm to optimize RBF network architecture and parameters for nonlinear time series prediction. *Appl Math Model* 2012;36:2911–9. <https://zoi.org/10.1016/j.apm.2011.09.066>.
- [31] Simon-Várhelyi M, Cristea VM, Luca AV. Reducing energy costs of the wastewater treatment plant by improved scheduling of the periodic influent load. *J Environ Manage* 2020;262. <https://zoi.org/10.1016/j.jenvman.2020.110294>.
- [32] Ostace G.S., V.M. Cristea, P.S. Agachi, Extension of Activated Sludge Model No 1 with Two-Step Nitrification and Denitrification Processes for Operation Improvement, *Environ Eng Manag J.* 10 2011 1529–1544. <https://zoi.org/10.30638/eemj.2011.214>.
- [33] Ojha VK, Abraham A, Snášel V. Metaheuristic design of feedforward neural networks: A review of two decades of research. *Eng Appl Artif Intell* 2017;60:97–116. <https://zoi.org/10.1016/j.engappai.2017.01.013>.
- [34] Gori R, Jiang LM, Sobhani R, Rosso D. Effects of soluble and particulate substrate on the carbon and energy footprint of wastewater treatment processes. *Water Res* 2011;45:5858–72. <https://zoi.org/10.1016/j.watres.2011.08.036>.
- [35] Alex J, Benedetti L, Copp J, Gernaey K V, Jeppsson U, Nopens I, et al. Benchmark Simulation Model no. 1 ( BSM1 ). vol. 1. 2008.
- [36] Koutsou OP, Gatidou G, Stasinakis AS. Domestic wastewater management in Greece: Greenhouse gas emissions estimation at country scale. *J Clean Prod* 2018;188:851–9. <https://zoi.org/10.1016/j.jclepro.2018.04.039>.
- [37] Mannina G, Ekama G, Caniani D, Cosenza A, Esposito G, Gori R, et al. Greenhouse gases from wastewater treatment - A review of modelling tools. *Sci Total Environ* 2016;551–552:254–70. <https://zoi.org/10.1016/j.scitotenv.2016.01.163>.
- [38] EEA, 2022: Data visualization: Country level – Greenhouse gas emission intensity of electricity generation. [https://www.eea.europa.eu/ziata-and-maps/ziaviz/co2-emission-intensity-12/#tab-chart\\_2](https://www.eea.europa.eu/ziata-and-maps/ziaviz/co2-emission-intensity-12/#tab-chart_2) (accessed September 14, 2023).
- [39] IPCC, 2006: IPCC Guidelines for National Greenhouse Gas Inventories. <https://www.ipcc-nggip.ighg.or.jp/public/2006gl/vol5.html> (accessed September 14, 2023).
- [40] IPCC, 2007: Climate Change 2007: Synthesis Report. Contribution of Working Groups I, II and III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, Pachauri, R.K and Reisinger, A. (eds.)]. IPCC, Geneva, Switzerland.
- [41] Flores-Alsina X, Solon K, Kazadi Mbamba C, Tait S, Gernaey K V., Jeppsson U, et al. Modelling phosphorus (P), sulfur (S) and iron (Fe) interactions for dynamic simulations of anaerobic diGHGtion processes. *Water Res* 2016;95:370–82. <https://zoi.org/10.1016/j.watres.2016.03.012>.
- [42] Solon K, Flores-Alsina X, Kazadi Mbamba C, Ikumi D, Volcke EIP, Vaneeckhaute C, et al. Plant-wide modelling of phosphorus transformations in wastewater treatment systems: Impacts of control and operational strategies. *Water Res* 2017;113:97–110. <https://zoi.org/10.1016/j.watres.2017.02.007>.
- [43] Gernaey K V., Jeppsson U (Ulf), Vanrolleghem PA, Copp JB, International Water Association. Task Group on Benchmarking of Control Strategies for Wastewater Treatment Plants. Benchmarking of



- control strategies for wastewater treatment plants. 2014.
- [44] Mamais D, Noutsopoulos C, Dimopoulou A, Stasinakis A, Lekkas TD. Wastewater treatment process impact on energy savings and greenhouse gas emissions. *Water Sci Technol* 2015;71:303–8. <https://zoi.org/10.2166/wst.2014.521>.
- [45] Han H-G, Liu H-X, Liu Z, Qiao J-F. Fault detection of sludge bulking using a self-organizing type-2 fuzzy-neural-network. *Control Eng Pract* 2019;90:27–37. <https://zoi.org/10.1016/j.conengprac.2019.06.010>.
- [46] Luca AV, Simon-Várhelyi M, Mihály NB, Cristea VM. Data driven detection of different dissolved oxygen sensor faults for improving operation of the wwtp control system. *Processes* 2021;9. <https://zoi.org/10.3390/pr9091633>.