



UNIVERSITATEA BABEȘ-BOLYAI
Facultatea de Chimie și Inginerie Chimică
Școala Doctorală de Inginerie Chimică



Detectarea și identificarea defectelor principalilor senzori ai stației de tratare a apelor uzate pentru îmbunătățirea performanței de funcționare

Rezumatul Tezei de Doctorat

Student doctorand: Ing. Alexandra-Veronica Luca

Îndrumător științific: Prof. Dr. Ing. Vasile-Mircea Cristea

Cuprins

Cuprins	2
INTRODUCERE.....	4
1. Motivație	4
STADIUL ACTUAL AL CUNOȘTIȚELOR	5
2. Stadiul actual al cunoștințelor privind modelarea stațiilor de tratare bazate pe tehnologia cu nămol activ	5
2.1. Introducere.....	5
2.2. Descrierea Modelului cu Nămol Activ nr. 1 (ASM1)	5
2.3. Descrierea Modelului de Simulare de Referință nr. 1 (BSM1)	6
2.4. Instrumente utilizate pentru modelarea dinamică.....	7
2.5. Evaluarea performanței operaționale a stației de tratare a apelor uzate	7
2.6. Evaluarea performanței în detectare și diagnosticare	8
2.7. Evaluarea emisiilor de gaze cu efect de seră (GES).....	8
CONTRIBUȚII PERSONALE	10
3. Modelul liniei de apă a stației municipale de tratare a apelor uzate	10
3.1. Introducere.....	10
3.2. Configurația stației de tratare și parametrii de proiectare.....	10
3.3. Modelul stației municipale de tratare a apelor uzate	10
3.4. Concluzii	11
4. Metode pentru detectarea și diagnosticarea erorilor senzorilor de oxigen dizolvat și nitrați	11
4.1. Introducere.....	11
4.2. Tipuri de erori investigate	12
4.3. Metode pentru detectarea și diagnosticarea erorilor senzorilor	12
4.4. Concluzii	13
5. Implementarea defectelor în modelul Simulink al stației municipale de tratare a apelor uzate	14
5.1. Introducere.....	14
5.2. Seturi de date pentru operare normală și anormală	14
5.3. Seturi de date pentru construirea modelului ACP de detectare a defectelor	15
5.4. Seturi de date pentru construirea modelului ADF de identificare a defectelor	15
5.5. Metode de evaluare a performanței detectării și diagnosticării defectelor	16
6. Detectarea și diagnosticarea defectelor senzorului DO și impactul asupra energiei, calității apei și emisiilor de gaze cu efect de seră.....	16
6.1. Introducere.....	16
6.2. Metodologia implementării defectelor senzorului DO	17
6.3. Variabile de proces considerate pentru detectarea și identificarea erorilor senzorului DO.....	18
6.4. Construirea modelului ACP pentru detectarea erorilor senzorului DO.....	19
6.5. Construirea modelului ADF pentru identificarea erorilor senzorului DO.....	19
6.6. Rezultate și discuții	20

6.7.	Concluzii	34
7.	Detectarea și diagnosticarea erorilor senzorului NO și impactul acestora asupra energiei, calității apei și emisiilor de gaze cu efect de seră.....	35
7.1.	Introducere.....	35
7.2.	Metodologia implementării erorilor senzorului NO.....	35
7.3.	Variabilele de proces considerate pentru detectarea și identificarea erorilor senzorului NO..	37
7.4.	Construcția modelului ACP pentru detectarea erorilor senzorului NO	37
7.5.	Construcția modelului ADF pentru identificarea erorilor senzorului NO	38
7.6.	Rezultate și discuții	38
7.7.	Concluzii	52
8.	Concluzii finale și contribuții personale.....	53
	REFERENCES.....	55

INTRODUCERE

1. Motivație

Gestionarea și tratarea apei au fost esențiale pentru sănătatea umană, protecția mediului și dezvoltarea durabilă încă din Antichitate. Primele sisteme erau axate în principal pe devierea apelor uzate, tratarea acestora apărând abia în secolul al XIX-lea, odată cu industrializarea, din cauza urbanizării accelerate, poluării și bolilor transmise prin apă. Dezvoltarea procesului cu nămol activ în 1914 a reprezentat un progres major, permițând eliminarea eficientă a poluanților organici. De-a lungul secolului XX, progresele în tratare biologică, aerare și procese chimice, combinate cu reglementările tot mai stricte, au condus la adoptarea unor stații moderne, de mari dimensiuni și cu consum energetic ridicat. În prezent, accentul nu mai este pus doar pe eliminarea poluării, ci și pe recuperarea resurselor, eficiența energetică și sustenabilitate.

Odată cu creșterea populației globale și intensificarea deficitului de apă, cererea pentru tratarea apei la standarde ridicate este în continuă expansiune. Stațiile moderne de tratare se bazează în mare măsură pe măsurători precise furnizate de senzori pentru variabile cheie, precum oxigenul dizolvat, nitrații și nitriții. Acești senzori sunt critici pentru controlul eficient al proceselor, gestionarea consumului de energie și respectarea normelor de mediu. Erorile senzorilor pot conduce la o tratare ineficientă, consum energetic crescut, scăderea calității efluentului și creșterea emisiilor de gaze cu efect de seră (GES). Având în vedere că tratarea apelor uzate contribuie cu până la 5% din emisiile globale de GES, reducerea acestora prin operare eficientă a devenit o prioritate esențială de mediu.

Complexitatea proceselor din stațiile de tratare, caracterizată prin dinamici neliniare, compoziția variabilă a influentului și reacții biologice interdependente, impune utilizarea unor strategii avansate de monitorizare și control. Modelele matematice și bazate pe date, precum Analiza Componentelor Principale (ACP) și monitorizarea statistică multivariată a proceselor, joacă un rol crucial în detectarea timpurie a erorilor, diagnosticare și optimizarea proceselor. Aceste instrumente contribuie la minimizarea impactului asupra mediului, reducerea costurilor și creșterea fiabilității. Mai mult, integrarea soluțiilor de recuperare a energiei și a surselor regenerabile deschide posibilitatea ca stațiile să avanseze către neutralitate energetică, contribuind simultan la sustenabilitate economică și ecologică.

Această cercetare este motivată de necesitatea stringentă de a îmbunătăți fiabilitatea, sustenabilitatea și eficiența stațiilor de tratare. Monitorizarea precisă a senzorilor nu doar asigură conformitatea cu reglementările în continuă evoluție, ci sprijină și optimizarea consumului de energie, reducerea emisiilor de GES și atingerea obiectivelor mai largi ale economiei circulare și ale recuperării resurselor de apă. În esență, dezvoltarea monitorizării și controlului bazate pe senzori în stațiile de tratare este vitală pentru gestionarea sigură, eficientă din punct de vedere economic și responsabilă față de mediu a sistemelor moderne de tratare a apelor uzate.

STADIUL ACTUAL AL CUNOȘTINȚELOR

2. Stadiul actual al cunoștințelor privind modelarea stațiilor de tratare bazate pe tehnologia cu nămol activ

2.1. Introducere

Monitorizarea proceselor chimice în stațiile de tratare a apelor uzate este esențială pentru asigurarea eficienței, calității efluentului și implementării unor strategii avansate de control. Aceasta se bazează pe modele mecanistice sau orientate pe date, utilizate pentru a prezice variabilele de proces și pentru a optimiza operarea (Frank, 1990; Yoon & MacGregor, 2001). Modelele dinamice sprijină optimizarea stațiilor de îndepărtare a nutrienților, gestionarea situațiilor de criză și testarea diverselor scenarii operaționale (Henze *et al.*, 2000). Asociația Internațională a Apei (International Water Association - IWA) a dezvoltat modele standardizate de tip Modele bazate pe Nămol Activ (ASM1-ASM3), care descriu procesele de îndepărtare a carbonului, azotului și fosforului, oferind suport pentru proiectarea, exploatarea și optimizarea stațiilor de tratare (Rieger *et al.*, 2012; Hauduc *et al.*, 2011; Gernaey *et al.*, 2004; Henze *et al.*, 2000).

Grupurile COST Action europene au elaborat Modele de Simulare de Referință (BSM1 și BSM2) pentru evaluarea strategiilor de control și a performanței stațiilor, incluzând scenarii de influent, consum energetic, producția de nămol și evaluarea pe termen lung a instalațiilor. Acestea permit comparații obiective între legile de control și optimizarea unor procese precum digestia anaerobă și generarea de biogaz (Alex *et al.*, 1999, 2008; Beraud *et al.*, 2009).

2.2. Descrierea Modelului cu Nămol Activ nr. 1 (ASM1)

Modelul ASM1 este probabil cel mai utilizat model pentru descrierea proceselor de tratare a apelor uzate la nivel mondial, deși, de la conceperea sa, a fost extins pentru a include mai multe fracții de cerință chimică de oxigen, pentru a integra noi rezultate experimentale (Sollfrank și Gujer, 1991), pentru a defini dinamica de creștere și populație a bacteriilor floculante și filamentoase (Gujer și Kappeler, 1992), precum și pentru a îmbunătăți descrierea procesului de îndepărtare biologică a fosforului (Henze *et al.*, 1995).

Procesele incluse în modelul ASM1 sunt definite după cum urmează (Jeppsson, 1996):

Creșterea aerobă a heterotrofilor:

$$proces1 = \mu_H \cdot \left(\frac{S_S}{K_S + S_S} \right) \cdot \left(\frac{S_O}{K_{O,H} + S_O} \right) \cdot X_{B,H} \quad (2.1)$$

Creșterea anoxică a heterotrofilor:

$$proces2 = \mu_H \cdot \left(\frac{S_S}{K_S + S_S} \right) \cdot \left(\frac{K_{O,H}}{K_{O,H} + S_O} \right) \cdot \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \cdot \eta_g \cdot X_{B,H} \quad (2.2)$$

Creșterea aerobă a autotrofilor:

$$proces3 = \mu_A \cdot \left(\frac{S_{NH}}{K_{NH} + S_{NH}} \right) \cdot \left(\frac{S_O}{K_{O,A} + S_O} \right) \cdot X_{B,A} \quad (2.3)$$

Degradarea heterotrofilor:

$$proces4 = b_H \cdot X_{B,H} \quad (2.4)$$

Degradarea autotrofilor:

$$proces5 = b_A \cdot X_{B,A} \quad (2.5)$$

Amonificarea azotului organic solubil:

$$proces6 = k_a \cdot S_{ND} \cdot X_{B,H} \quad (2.6)$$

Hidroliza compușilor organici reținuți:

$$proces7 = k_h \cdot \frac{X_S/X_{B,H}}{K_x + (X_S/X_{B,H})} \cdot \left[\left(\frac{S_O}{K_{O,H} + S_O} + \eta_h \cdot \left(\frac{K_{O,H}}{K_{O,H} + S_O} \right) \cdot \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right) \right] \cdot X_{B,H} \quad (2.7)$$

Hidroliza azotului organic reținut:

$$proces8 = k_h \cdot \frac{X_S/X_{B,H}}{K_x + (X_S/X_{B,H})} \cdot \left[\left(\frac{S_O}{K_{O,H} + S_O} + \eta_h \cdot \left(\frac{K_{O,H}}{K_{O,H} + S_O} \right) \cdot \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right) \right] \cdot X_{B,H} \cdot (X_{ND}/X_S) \quad (2.8)$$

2.3. Descrierea Modelului de Simulare de Referință nr. 1 (BSM1)

Conceptul de Model de Simulare de Referință nr. 1 (BSM1) este relativ simplu. Acesta se bazează pe o configurație modificată Ludzack-Ettinger, care permite stației de tratare să respecte reglementările stricte privind îndepărtarea cerinței chimice de oxigen (COD) și a azotului (Tchobanoglous *et al.*, 2003).

Structura de referință este alcătuită dintr-un reactor cu nămol activ împărțit în cinci compartimente. Dintre acestea, două sunt bazine anoxice, iar celelalte trei sunt bazine aerobe.

Ecuția generală pentru bilanțul de masă al primului reactor (ne-aerat) este (Alex *et al.*, 2008):

$$\frac{dZ_{as,1}}{dt} = \frac{1}{V_{as,1}} (Q_{int}Z_{int} + Q_rZ_r + Q_{po}Z_{po} + r_{Z,1}V_{as,1} - (Q_{int} + Q_r + Q_{po})Z_{as,1}) \quad (2.9)$$

unde Q_{int} este recircularea internă, Q_r reprezintă recircularea externă, iar Q_{po} este debitul deversat al decantorului primar.

Pentru restul reactoarelor, ecuația de bilanț de masă este:

$$\frac{dZ_{as,k}}{dt} = \frac{1}{V_{as,k}} (Q_{k-1}Z_{as,k-1} + r_{Z,k}V_{as,k} - Q_kZ_{as,k}) \quad (2.10)$$

unde k reprezintă numărul bioractorului (2-5).

Un decantor secundar este amplasat după reactorul cu nămol activ. Decantorul secundar este reprezentat utilizând o funcție de viteză cu dublă exponențială (Takacs *et al.*, 1991):

$$v_s(X_{sc}) = \max[0, \min\{v_0', v_0(e^{-r_h(X_{sc}-X_{min})} - e^{-r_p(X_{sc}-X_{min})})\}] \quad (2.11)$$

unde v_s reprezintă viteza de sedimentare, v_0 este viteza teoretică maximă de sedimentare (m/d), v_0' este viteza practică maximă de sedimentare Vesiling (m/d), r_h este parametrul de sedimentare din zona împiedicată (m^3/g), r_p este parametrul de sedimentare din zona floculantă (m^3/g), X_{sc} este concentrația de nămol, iar X_{min} este concentrația minimă posibilă de solide în suspensie (g/m^3).

Instalația include un flux de recirculare intern pentru a furniza nitrați în reactoarele anoxice din reactoarele aerobe și o recirculare externă pentru a transporta nămolul din decantorul secundar către reactoarele anoxice. Configurația de referință cuprinde o strategie simplă de control cu două bucle PI de reglare.

2.4. Instrumente utilizate pentru modelarea dinamică

Matlab este un limbaj de programare multifuncțional și un mediu de calcul numeric care include instrumente pentru manipularea matricelor, implementarea algoritmilor și o varietate de funcții (MathWorks, 2025a). Simulink este un mediu de programare grafică pentru diagrame bloc care funcționează împreună cu Matlab (MathWorks, 2025b). În general, este utilizat pentru modelarea și simularea sistemelor dinamice, precum și pentru testarea și verificarea continuă a sistemelor. Prin intermediul S-functions special concepute, Modelele Simulate de Referință sunt aplicate în această lucrare.

2.5. Evaluarea performanței operaționale a stației de tratare a apelor uzate

În această lucrare, au fost utilizați patru indici de performanță separați pentru a evalua impactul general al funcționării defectuoase a stației asupra performanței instalației: energia pentru aerare (AE), energia pentru pompare (PE), calitatea efluentului (EQ) și emisiile de gaze cu efect de seră, introduse recent.

Indexul energiei pentru aerare este calculat folosind coeficientul de transfer de masă al oxigenului din bioractoarele aerobe (K_{La}), care este direct legat de debitul de aer injectat, așa cum este prezentat în ecuația (2.12).

$$AE = \frac{S_{O_{sat}}}{T \cdot 1.8 \cdot 1000} \cdot \int_0^{T_{days}} \sum_{aerated\ reactors} V_{bioreactor} \cdot K_L a_i(t) dt \quad (2.12)$$

unde $S_{O_{sat}}$ reprezintă concentrația de oxigen la saturație (mg O_2/L), T_{days} este timpul de evaluare, exprimat în zile, $V_{bioreactor}$ reprezintă volumul bioractorului (m^3) iar $K_L a_i$ este coeficientul de transfer de masă în bioractorul aerat i .

Indexul energiei pentru pompare este calculat utilizând debitele de recirculare a nitrailor, recircularea nămolului activ returnat și a nămolului rezidual, așa cum este prezentat în ecuația (2.13):

$$PE = \frac{1}{T} \cdot \int_0^{T_{days}} [0.004 \cdot Q_{NR}(t) + 0.08 \cdot Q_{RAS}(t) + 0.05 \cdot Q_{waste}(t)] dt \quad (2.13)$$

unde Q_{NR} este debitul de recirculare a nitrailor (m^3/day), Q_{RAS} este debitul de recirculare a nămolului activ returnat (m^3/day), Q_{waste} este debitul de nămol rezidual provenit din decantorul secundar (m^3/day). Atât energia pentru aerare, cât și energia pentru pompare sunt exprimate în kWh/day.

Indexul calității efluentului este calculat utilizând concentrațiile de solide în suspensie totală (TSS), cerința chimică de oxigen (COD), cerința biochimică de oxigen (BOD), azotul Kjeldahl total (TKN) și concentrațiile de nitrați și nitriți din fluxul de efluent, așa cum este prezentat în ecuația (2.14). Aceste valori sunt înmulțite cu debitul fluxului de efluent. Indexul este exprimat în kilograme

de poluanți pe zi.

$$EQ = \frac{1}{T \cdot 1000} \cdot \int_0^{Tdays} [PU_{TSS}(t) + PU_{COD}(t) + PU_{BOD}(t) + PU_{TKN}(t) + PU_{NO}(t)] \cdot Q_{effluent}(t) dt \quad (2.14)$$

unde PU_{TSS} reprezintă solidele în suspensie totală, PU_{COD} se referă la cerința chimică de oxigen, iar PU_{BOD} la cerința biochimică de oxigen, PU_{TKN} reprezintă azotul Kjeldahl total, PU_{NO} include nitrații și nitriții, iar $Q_{effluent}$ este debitul fluxului de efluent.

2.6. Evaluarea performanței în detectare și diagnosticare

Matricea sau graficul de confuzie reprezintă un instrument utilizat pe scară largă în analiza clasificării, oferind o reprezentare vizuală a performanței unui model prin compararea rezultatelor reale cu cele prezise. Matricele de confuzie au fost construite pentru fiecare dintre cazurile analizate, fiecare matrice afișând numărul de adevărate pozitive, fals pozitive, adevărate negative și fals negative. Această reprezentare tabelară servește drept bază pentru calcularea principalilor indicatori de performanță care evaluează capacitățile de detectare ale sistemului, așa cum sunt prezentate mai jos:

Formula pentru calcularea Valorii Predictive Pozitive este:

$$VPP = \frac{\text{Număr de pozitive adevărate}}{\text{Număr de pozitive adevărate} + \text{Număr de pozitive false}} \quad (2.15)$$

Acuratețea este un indicator utilizat pentru evaluarea performanței unui model de clasificare:

$$\text{Acuratețea} = \frac{\text{Număr de predicții corecte}}{\text{Numărul total de predicții}} \quad (2.16)$$

Rata alarmelor false (RAF) este definită după cum urmează:

$$RAF = \frac{\text{Număr de alarme false}}{\text{Numărul total de condiții fără defect}} \quad (2.17)$$

Rata alarmelor ratate (RAR) este definită astfel:

$$RAR = \frac{\text{Număr de alarme ratate}}{\text{Numărul total de defecte}} \quad (2.18)$$

Scorul F1 (F1 score) este definit astfel:

$$F1 \text{ scor} = 2 \times \frac{\text{Precizie} \times \text{Rapel}}{\text{Precizie} + \text{Rapel}} \quad (2.19)$$

2.7. Evaluarea emisiilor de gaze cu efect de seră (GES)

Emisiile totale de GES din linia de apă a stației municipale de tratare includ atât emisiile de CO_2 și N_2O generate la fața locului, cât și cele generate în afara acesteia. Pe lângă CO_2 , N_2O este considerat un contributor semnificativ la emisiile de GES datorită potențialului său de încălzire globală, de aproximativ 265-298 de ori mai mare decât cel al CO_2 (Vallero, 2019).

Emisiile de CO_2 generate în afara stației (kg CO_2 /day) includ emisiile indirecte de CO_2 provenite de la centrala electrică, asociate consumului de energie în procesul de tratare a apelor uzate. Acestea sunt definite după cum urmează:

$$P_{CO_2, off-site} = k_{PG} \cdot e_D \quad (2.20)$$

unde k_{PG} reprezintă factorul de emisie specific sitului per unitate de energie generată, considerat cu

valoarea de 0.19 kg CO_{2e}/kWh, iar e_D este cerința totală de energie, calculată ca suma energiei pentru aerare și energiei pentru pompare (Mannina *et al.*, 2016; Listowski *et al.*, 2011).

Emisiile de N₂O generate în afara stației includ N₂O produs prin degradarea biologică în efluentul stației de tratare (în aval) (Mannina *et al.*, 2016; Prendez and Lara-Gonzales, 2008):

$$P_{N_2O,off-site} = N_{effluent} \cdot EF_{effluent} \quad (2.21)$$

unde $N_{effluent}$ reprezintă sarcina de azot din efluentul deversat în mediile acvatice, iar $EF_{effluent} = 0.005 \cdot 44/28$ kg N₂O/kg N (IPCC, 2006) este factorul de emisie pentru emisiile de N₂O provenite din apa uzată deversată.

Emisiile de CO₂ generate la fața locului în linia de apă a proceselor biologice aerobe sunt determinate folosind următoarea expresie:

$$P_{CO_2,on-site} = Q_{influent} \cdot 0.99 \cdot (1 - Y_H) \cdot \eta_{ASP} \cdot bCOD + Q_{influent} \cdot 1.03 \cdot Y_H \cdot \eta_{ASP} \cdot bCOD \cdot \frac{k_{d,H} \cdot MCRT}{1 + k_{d,H} \cdot MCRT} \quad (2.22)$$

unde: $Q_{influent}$ este debitul de intrare în stație (m³/day), 0.99 kg CO_{2e}/kg COD este factorul de emisie asociat compușilor organici, Y_H reprezintă randamentul biomasei heterotrofe (masă VSS/masă COD) (Alex *et al.*, 2008), η_{ASP} este procentul de COD biodegradabil ($bCOD$) eliminat în reactoarele cu nămol activ, 1.03 kg CO_{2e}/kg COD este factorul de emisie asociat biomasei din nămolul activ, $k_{d,H}$ este rata de degradare a biomasei heterotrofe și are valoarea de 0.3 day⁻¹ (Alex *et al.*, 2008), iar MCRT este timpul mediu de retenție celulară, care în acest caz este de 15 zile (Mannina *et al.*, 2016; Gori *et al.*, 2011).

Următoarea relație poate fi utilizată pentru a determina emisiile de N₂O generate la fața locului în linia de apă.

$$P_{N_2O,on-site} = Q_{influent} \cdot (TN_{in} - TN_{out}) \cdot r_{N_2O} \quad (2.23)$$

unde TN_{in} reprezintă azotul total din influent (kg N/m³), TN_{out} este azotul total din efluent (kg N/m³) (Huang and Shen, 2019) iar r_{N_2O} este rata de emisie a N₂O (kg N₂O/kg N) (Baresel *et al.*, 2016).

CONTRIBUȚII PERSONALE

3. Modelul liniei de apă a stației municipale de tratare a apelor uzate

3.1. Introducere

Studiul de caz al acestei lucrări este stația de tratare a apelor uzate din Someseni, Cluj, care utilizează o configurație anaerob-anoxic-aerobă (A^2O). Stația tratează atât apele menajere, cât și apele pluviale urbane și este proiectată cu o linie de apă care integrează separarea fizică, tratarea biochimică, decantarea și o linie de nămol cu producție de biogaz. În cadrul procesului A^2O , etapa biologică implică trecerea secvențială a apelor uzate prin bazine anaerobe, anoxice și aerobe, facilitând eliberarea și absorbția fosforului, denitrificarea, nitrificarea și degradarea carbonului. Ulterior, are loc separarea solid-lichid în clarificatoare. Majoritatea nămolului activ este reciclat, iar surplusul este concentrat, digerat anaerob și utilizat pentru producerea de biogaz în scopul recuperării energiei.

3.2. Configurația stației de tratare și parametrii de proiectare

După intrarea în stația de tratare, apele uzate sunt supuse sedimentării primare. După clarificatorul primar, apele uzate pătrund în bazinele de biodegradare, unde eliminarea carbonului, azotului și fosforului se realizează prin procese specifice tehnologiei cu nămol activ. Cele trei zone ale bazinelor de biodegradare sunt anaerobă, anoxică și aerobă. În zona anaerobă se dezvoltă microorganismele acumuloare de fosfor. În zona anoxică are loc denitrificarea cu ajutorul bacteriilor heterotrofe, care utilizează nitrații și nitriții pentru respirația celulară în absența oxigenului molecular. Ca rezultat, nitrații și nitriții sunt transformați în oxizi de azot și gaz azot (Wanner and Grau, 1988). Ultimele trei bioractoare formează secțiunea aerată a stației. Aici, aerul este introdus în apele uzate pentru a asigura nivelul necesar de oxigen dizolvat cu ajutorul compresoarelor. În acest compartiment, materia organică este transformată în biomasă aerobă prin asimilare, iar fosforul este absorbit de microorganismele acumuloare de fosfor. Recircularea internă trimite nitrații și nitriții formați înapoi în bazinele anoxice pentru a completa etapa de denitrificare. Amestecul lichid-solid rămas este alimentat în decantoarele secundare. 99,5% din nămolul activ, bogat în microorganisme, este returnat în zona anaerobă. Nămolul de la baza decantorului este returnat în reactorul anaerob prin fluxul de recirculare internă, în timp ce apele tratate sunt deversate în râul desemnat (Simon-Varhelyi *et al.*, 2020a). În plus, stația include o secțiune pentru producerea de biogaz.

3.3. Modelul stației municipale de tratare a apelor uzate

Baza simulatorului stației de tratare dezvoltat și utilizat în această lucrare constă în modelele BSM1 și ASM1. Modelul original BSM1 a fost modificat după necesități pentru a se conforma configurației anaerob-anoxic-oxic, A^2O , a stației municipale investigate.

Stația utilizează două bucle de control feedback bazate pe controlere PI. Prima buclă controlează concentrația de oxigen dizolvat în al treilea bioractor aerat. Scopul acesteia este de a menține oxigenul dizolvat la valoarea de referință de 2 mg O_2/L , prin ajustarea debitului de aer introdus în cele trei reactoare aerate. A doua buclă reglează nivelurile de nitrați și nitriți în bioractorul anoxic.

Aceasta menține concentrația de NO la valoarea setată de 0.01 mg N/L, prin ajustarea debitului de recirculare a lichidului amestecat, pentru a asigura denitrificarea corespunzătoare. După cum este prezentat în Figura 3.1, stația municipală de tratare include, de asemenea, un clarificator primar și unul secundar. Modelul stației respectă această structură a liniei de apă.




Figura 3.1. Configurația stației municipale de tratare

Simulările în regim dinamic pentru funcționarea normală și defectuoasă a senzorilor de concentrație DO și NO au fost realizate în cadrul acestui studiu utilizând modelul Matlab al stației municipale de tratare, dezvoltat și calibrat anterior, bazat pe ASM1, BSM1 și software-ul Matlab & Simulink (Varhelyi *et al.*, 2019).

Avantajele utilizării modelelor matematice integrate în simulatoare dinamice, fie ele mecanistice sau statistice, se bazează pe capacitatea acestora de a prezice evoluția viitoare a principalelor variabile de proces în diverse condiții. Acestea oferă un instrument valoros pentru dezvoltarea proiectării și pentru soluții noi de îmbunătățire a operării.

3.4. Concluzii

Stația municipală de tratare Someșeni este o facilitate de tratare de ultimă generație, a cărei configurație A²O, împreună cu procese sofisticate de separare, tratament biochimic și gestionare a nămolului, permite recuperarea energiei prin producerea de biogaz și garantează eliminarea eficientă a materiei organice și a nutrienților. Înțelegerea dinamicii complexe a tratării apelor uzate și reprezentarea precisă a condițiilor specifice sitului, prin calibrare atentă cu date operaționale reale, a fost posibilă datorită dezvoltării unui simulator matematic. Modelul oferă un instrument de încredere pentru prognoza performanței stației, atât în scenarii de stare staționară, cât și dinamice, prin combinarea monitorizării online continue cu validarea de laborator.

4. Metode pentru detectarea și diagnosticarea erorilor senzorilor de oxigen dizolvat și nitrați

4.1. Introducere

Menținerea standardelor obligatorii privind calitatea apei și eficiența procesului de tratare a apelor uzate poate fi dificilă atunci când apar anomalii particulare în sistem. Când condițiile de operare anormale sunt identificate și corectate prompt, se poate asigura o funcționare eficientă și

sigură. Diverse cazuri de funcționare anormală care apar în stațiile de tratare pot fi cauzate de senzori defectuoși.

Metode avansate de detectare și diagnosticare a erorilor, care utilizează modelare bazată pe date, învățare automată și inteligență artificială, au fost dezvoltate pentru a diminua impactul senzorilor cu funcționare defectuoasă.

Printre cele mai importante instrumente de monitorizare din facilitățile de tratare a apelor uzate se numără senzorii de oxigen dizolvat și de nitrați, esențiali pentru menținerea eficienței proceselor biologice de tratare. Aerarea eficientă și eliminarea azotului sunt componente fundamentale ale tratării apelor uzate, iar datele precise în timp real furnizate de acești senzori sunt importante pentru maximizarea eficienței stației, reducerea costurilor de operare și garantarea respectării standardelor de mediu (Tchobanoglous *et al.*, 2014).

4.2. Tipuri de erori investigate

Având în vedere importanța critică a senzorilor de oxigen dizolvat și nitrați în funcționarea generală a stației de tratare, această teză a examinat detectarea și identificarea diferitelor tipuri de erori ale acestor senzori. Cele șase tipuri de erori ale senzorilor investigate sunt definite și descrise mai jos.

Eroarea de zero, cunoscută și ca off-set al valorilor semnalului generate de senzor, poate fi frecvent cauzată de un senzor necalibrat corect (Teh *et al.*, 2020).

Eroarea de drift apare ca o deviație variabilă în timp față de valoarea reală și se distinge printr-un semnal rampă variabil în timp (Teh *et al.*, 2020).

Eroarea de proporționalitate reprezintă o pierdere a eficienței senzorului cauzată de o eroare de calibrare, în special atunci când panta de calibrare a senzorului este afectată de un factor de amplificare nepotrivit sau definit incorect în pasul de calibrare (Rosen *et al.*, 2008).

Eroarea de liniaritate reprezintă o degradare neregulată a performanței senzorului (Teh *et al.*, 2020).

Eroarea de tip valoare fixă se caracterizează printr-un senzor care generează aceeași valoare constantă (Rosen *et al.*, 2008). Eroarea de tip Avarie totală, cu două cazuri, minim sau maxim, apare atunci când semnalul de ieșire al senzorului este egal sau depășește valoarea minimă sau maximă de calibrare a senzorului (Rosen *et al.*, 2008). Această eroare este un caz particular al erorii de tip Valoare fixă.

4.3. Metode pentru detectarea și diagnosticarea erorilor senzorilor

Mai multe studii au utilizat diverse metodologii de Control Multivariat al Proceselor Statistice (MSPC) pentru a analiza funcționarea anormală a senzorilor și strategiile de detectare a informațiilor inexacte sau a defectării senzorilor. Diagramele de control (Kazemi *et al.*, 2020), analiza componentelor independente (ICA) (Villegas *et al.*, 2010 și analiza componentelor principale (Tao *et al.*, 2013; Garcia-Alvarez *et al.*, 2009; Qin, 2009 sunt metode MSPC folosite pentru monitorizare detaliată și detectarea erorilor.

Puține studii s-au concentrat pe problema erorilor senzorilor de oxigen dizolvat. Un studiu a dezvoltat o metodă ACP pentru detectarea a trei tipuri diferite de erori (Lee *et al.*, 2006) iar un alt articol a investigat semnalul de ieșire incorect generat de senzor (Sanchez-Fernandez *et al.*, 2015).

Doar câteva studii au analizat problemele rezultate dintr-o valoare în afara intervalului senzorului de concentrație de nitrați și nitriți. Unul dintre aceste studii s-a concentrat pe deriva unui senzor amperometric de nitriți (Britschgi *et al.*, 2020), iar altul a studiat acuratețea estimării unui senzor virtual pentru concentrația de nitrați (Corona *et al.*, 2013).

Analiza Discriminantă Fisher (ADF) este o tehnică bine cunoscută de clasificare a tiparelor (Duda *et al.*, 2000), iar aplicarea sa în analiza datelor din procese chimice a crescut constant în ultimele două decenii (Fuentes *et al.*, 2008; He *et al.*, 2005). Aplicarea ADF pentru senzorii defectuoși a fost investigată pentru unități de tratare a aerului (Du and Jin, 2008).

4.3.1. Metode de detectare a defectelor (Analiza Componentelor Principale)

ACP este o metodologie de data-mining bazată pe un model de proces construit cu datele obișnuite ale procesului. Modelele ACP sunt utilizate în principal pentru a evidenția corelația dintre variabilele de proces pe baza datelor brute. Metoda reduce setul mare de date utilizat pentru antrenarea modelului prin transformarea liniară a acestuia într-un set mai mic care păstrează informațiile critice, facilitând interpretarea datelor. Setul rezultat include o matrice de scoruri și o matrice de încărcări, care conțin informațiile extrase din setul redus de variabile. Atunci când numărul de măsurători depășește numărul de stări, ACP poate simplifica monitorizarea procesului și detectarea erorilor (Wise *et al.*, 1990).

Metoda ACP, utilizată frecvent împreună cu Hotelling's T^2 (Test Student) și Squared Prediction Error/Eroare de Predicție Pătratică (SPE), presupune o serie de proceduri pentru detectarea erorilor în subspațiul principal sau rezidual al modelului. Metode de diagnosticare a erorilor (Analiza Discriminantă Fisher)

Analiza discriminantă Fisher este o metodă de clasificare a tiparelor cu un potențial ridicat de clasificare. Scopul principal al ADF este de a determina vectorul discriminant optim Fisher, care maximizează funcția criteriu Fisher. În scopul construirii unui spațiu de caracteristici cu dimensiune mai mică, spațiul de caracteristici de dimensiune mai mare al măsurătorilor procesului poate fi proiectat în spațiul obținut al vectorilor discriminanți optimi.

Pentru a identifica defectele, ADF analizează datele măsurate colectate în condiții de diferite erori și utilizează o funcție discriminantă pentru a evalua similitudinea dintre datele curente și datele aparținând fiecărei clase. Observația este atribuită clasei i atunci când valoarea maximă a funcției discriminante, g_i , îndeplinește următoarele condiții:

$$g_i(x) > g_j(x), \forall j \neq i \quad (4.1)$$

$g_i(x)$ este funcția discriminantă pentru clasa i , definită pentru un vector măsurat $x \in R^m$, iar $g_j(x)$ este funcția discriminantă pentru clasa j , definită pentru același vector măsurat x .

4.4. Concluzii

Fiabilitatea rețelelor de senzori din stațiile de tratare a apelor uzate este esențială pentru atingerea unor standarde ridicate de calitate a apei și pentru maximizarea eficienței operaționale. Nu se poate subestima importanța senzorilor critici, precum cei pentru oxigen dizolvat (DO) și nitrați/nitriți (NO), în procesele de tratare biologică. Datele inexacte provenite de la senzorii DO pot conduce la o calitate slabă a efluentului și la ineficiențe energetice. Pe de altă parte, senzorii NO defectuoși pot provoca eutrofizare, afectând mediul înconjurător.

Pentru monitorizarea senzorilor în timp real, metode precum ACP și ADF oferă instrumente eficiente. Aceste tehnici sunt esențiale pentru reducerea timpilor de nefuncționare și pentru asigurarea respectării continue a cerințelor de calitate a apei, deoarece pot identifica erorile senzorilor, le pot clasifica și pot recomanda acțiuni corective.

Fiabilitatea și eficiența stațiilor de tratare a apelor uzate pot fi îmbunătățite semnificativ prin integrarea tehnicilor eficiente de detectare și diagnosticare a erorilor cu întreținerea și calibrarea regulată a senzorilor, sporind totodată funcționarea sustenabilă și eficiență din punct de vedere energetic a stației.

5. Implementarea defectelor în modelul Simulink al stației municipale de tratare a apelor uzate

5.1. Introducere

Detectarea și identificarea erorilor sunt cruciale pentru gestionarea sistemelor de tratare a apelor uzate, deoarece citirile inexacte ale senzorilor pot duce la dozarea incorectă a chimicalelor, aerare inefficientă sau chiar încălcarea reglementărilor. Prin utilizarea ACP și ADF, această lucrare își propune să îmbunătățească capacitatea de identificare și diagnosticare a problemelor senzorilor. Erorile senzorilor DO și NO, esențiale pentru menținerea celor mai bune proceduri de tratare a apelor uzate, sunt detectate și identificate de aceste modele.

Pentru a îmbunătăți metodele de diagnostic și a sprijini investigarea erorilor, au fost efectuate simulări controlate ale erorilor senzorilor folosind Simulink. Au fost investigate șase tipuri diferite de defecte ale senzorilor: eroare de zero, eroare de drift, eroare de proporționalitate, eroare de liniaritate, valoare fixă și avarie totală. Mai mult, implementarea defectelor senzorilor în Simulink, împreună cu operarea fără erori, reprezintă un aspect nou al acestei lucrări.

Seturile de date obținute din simulări servesc drept bază pentru instruirea și validarea modelelor ACP și ADF. În plus, o evaluare riguroasă a metodelor de detectare și diagnosticare a erorilor a fost realizată folosind matricea de confuzie. Această metrică oferă o evaluare cantitativă a performanței clasificării atât în condiții normale, cât și în condiții defectuoase.

5.2. Seturi de date pentru operare normală și anormală

Pentru a genera seturile de date necesare detectării sau diagnosticării defectelor, au fost construite treisprezece scenarii de simulare distincte pentru a examina în mod detaliat aceste condiții operaționale (operare normală și anormală) ale stației de tratare a apelor uzate, în vederea obținerii

seturilor de date necesare pentru analiza ulterioară.

Modelul calibrat al stației de tratare a fost simulat pe o perioadă de 168 de zile, pentru scenariile normale și defectuoase, rezultând un set de cincisprezece simulări diferite. Pentru a atinge starea quasi-staționară a stației, simulările au fost efectuate în condiții normale de operare pentru primele 139 de zile. Pentru scenariul de operare normală, simularea a continuat până la un total de 168 de zile, fără introducerea vreunei erori. Pentru scenariile cu erori, erorile senzorilor au fost introduse deliberat în ziua a 140-a a fiecărei simulări. În total, au fost efectuate douăsprezece simulări individuale, fiecare corespunzând unui tip diferit de defect. Datele simulate ale funcționării stației de tratare a apelor uzate au fost colectate cu un timp de eșantionare de 15 minute pentru a crea seturi de date cuprinzătoare pentru analiza ulterioară.

Seturile de date obținute au fost utilizate ulterior pentru a construi, antrena, valida și testa modelele ACP și ADF. Scopul acestor tehnici de învățare automată a fost de a îmbunătăți fiabilitatea și robustețea sistemelor de monitorizare ale stației de tratare prin evaluarea eficienței modelelor de detectare și identificare a defectelor.

5.3. Seturi de date pentru construirea modelului ACP de detectare a defectelor

Datele colectate prin procesul de simulare pe o perioadă de 40 de zile de funcționare normală, în mod specific de la ziua 100 până la ziua 139, au fost folosite pentru a construi matricea de date X a modelului ACP. Această perioadă a fost selectată pentru a asigura că modelul este antrenat în condiții de funcționare constante, fără erori, permițând captarea variabilității inerente a stației de tratare în condiții normale. Cu ajutorul acestui set de date, modelul ACP a fost capabil să detecteze tiparele normale de operare și să stabilească un prag de referință (threshold) care putea fi utilizat pentru a identifica deviațiile cauzate de defectele senzorilor.

Pentru a simula diferite tipuri de erori ale senzorilor, în sistem au fost introduse erori artificiale la începutul zilei 140.

Capacitatea modelului ACP de a detecta defectele a fost investigată utilizând date generate și înregistrate de la ziua 140 până la ziua 160 (o perioadă de 20 de zile), separat pentru fiecare dintre senzorii DO și NO în regim de funcționare defectuos. Măsurile statistice T^2 și SPE au fost folosite pentru a urmări comportamentul sistemului prin proiectarea datelor operaționale defectuoase în spațiul componentelor principale. Modelul a fost capabil să detecteze posibile anomalii folosind abateri semnificative ale acestor indici statistici ca indicatori ai erorilor senzorilor.

5.4. Seturi de date pentru construirea modelului ADF de identificare a defectelor

Modelul ADF a fost antrenat folosind date generate între zilele 141 și 145 (cinci zile) pentru funcționarea senzorilor DO și NO, fie în condiții normale, fie defectuoase. În cazul funcționării defectuoase, seturile de date utilizate pentru antrenament au inclus exemple pentru fiecare dintre tipurile de defecte. Drept urmare, matricea de antrenament pentru observarea funcționării senzorului DO este alcătuită din opt clase separate, o clasă reprezentând funcționarea normală, iar celelalte șapte reprezentând fiecare dintre diferitele tipuri de defecte. Pentru funcționarea senzorului NO, matricea

de antrenament constă în șase clase distincte, una pentru condițiile normale de funcționare și cinci pentru condițiile defectuoase.

Performanța modelului ADF antrenat în identificarea defectelor a fost evaluată folosind date de la prima zi de funcționare anormală a senzorilor (ziua 140). Această strategie de testare a fost dezvoltată pentru a investiga capacitatea metodei ADF de a identifica tipul de defect în primele ore după apariția sa. Această evaluare a oferit informații semnificative despre eficiența metodei de diagnostic și potențialul său de aplicare în scenarii de lucru în timp real.

5.5. Metode de evaluare a performanței detectării și diagnosticării defectelor

Performanța acestui studiu privind capacitățile de detectare și diagnosticare a defectelor se bazează pe metrici și metodologie de evaluare. Aceasta include construirea și interpretarea matricelor de confuzie, precum și calcularea principalilor indicatori de performanță, cum ar fi acuratețea, VPP (valoarea predictivă pozitivă), RAR (rata alarmelor ratate) și scorul F1. Matricea de confuzie a fost calculată și aplicată sistematic pentru fiecare scenariu specific, pentru a evalua precis eficacitatea tehnicilor de detectare și identificare a defectelor.

În matricea de confuzie, rândurile corespund categoriilor prezise (Clasa de ieșire), în timp ce coloanele indică categoriile reale (Clasa reală). Instanțele clasificate corect sunt plasate de-a lungul celulelor diagonale, în timp ce instanțele clasificate greșit apar în celulele off-diagonal. Fiecare celulă afișează atât numărul de instanțe, cât și procentajul corespunzător din totalul observațiilor. Coloana din dreapta matricei arată proporția cazurilor prezise pentru fiecare categorie care au fost clasificate corect sau incorect, aliniindu-se cu metrici precum precizia (sau VPP) și rata descoperirilor false. Similar, rândul de jos afișează proporția instanțelor reale ale fiecărei categorii care au fost clasificate corect sau incorect, corespunzând cu rapel (sau rata pozitivelor reale) și RAR. Acuratețea generală a clasificării este afișată în celula din colțul din dreapta-jos al matricei.

6. Detectarea și diagnosticarea defectelor senzorului DO și impactul asupra energiei, calității apei și emisiilor de gaze cu efect de seră

6.1. Introducere

În acest capitol este prezentat cadrul de simulare și metodologia concepută pentru detectarea și diagnosticarea defectelor senzorului de concentrație DO, utilizând simulatorul dinamic al unei stații de tratare municipale. Au fost dezvoltate simulări specifice pentru funcționarea normală și defectuoasă. În cazul funcționării defectuoase, au fost considerate șapte tipuri diferite de defecte ale senzorului DO: eroare de zero, eroare de drift, eroare de proporționalitate, eroare de liniaritate, valoare fixă și avarie totală - minim și maxim. Fiecare defect a fost implementat printr-o procedură individuală care a replicat fidel defectele reale ale senzorului DO. Au fost utilizate două tehnici de monitorizare statistică a proceselor, iar modele bazate pe ACP și ADF au fost dezvoltate pentru a detecta și diagnostica defectele senzorului DO considerate.

Impactul economic și de mediu al defectelor senzorului DO în stația municipală este, de

asemenea, analizat. A fost realizată o analiză detaliată, cu atenție specială asupra consumului de energie și a costurilor, calității efluentului și emisiilor de dioxid de carbon și oxid de azot. Studiul subliniază necesitatea întreținerii preventive, calibrarea periodică și a sistemelor automate de detectare a defectelor, evidențiind corelarea defectelor senzorului cu indicii de performanță ai stației.

6.2. Metodologia implementării defectelor senzorului DO

Pentru a simula comportamentul celor șapte tipuri de defecte considerate pentru senzorul de concentrație DO, au fost create module software personalizate, integrate în modelul simulatorului dinamic al stației de tratare. Pentru fiecare tip de defect, ieșirea afectată generată de defect a fost transmisă ca variabilă de proces DO măsurată către controlerul DO proporțional-integral. Planul general al stației de tratare și locația senzorului DO sunt prezentate în Figura 6.1.




Figura 6.1. Amplasarea senzorului DO în stația de tratare

Sistemul de control a oxigenului dizolvat (DO) ajustează debitul de aer pentru a aduce concentrația măsurată de DO la valoarea dorită de 2 mg O₂/L, fără niciun offset. Pentru fiecare dintre erori, scenariul de investigare a fost desfășurat astfel: timp de 139 de zile, simularea a rulat fără nicio eroare. Ulterior, începând cu ziua 140 a simulărilor, fiecare eroare a fost implementată printr-un scenariu de operare individual, pe o durată totală de 28 de zile. Variabilele de proces luate în considerare pentru identificarea erorii au fost colectate din prima zi de funcționare defectuoasă, respectiv ziua 140. Pentru colectarea datelor care descriu funcționarea normală, s-a considerat aceeași perioadă de măsurare de 28 de zile.

Eroarea de zero a fost definită ca o diferență constantă prestabilită între valorile reale și cele afectate de eroare ale senzorului. Concentrația măsurată de DO a fost considerată a avea un bias de +1.5 mg O₂/L pentru acest tip de eroare.

Eroarea de drift a fost simulată ca o deplasare în creștere, descrisă printr-un semnal rampă variabil în timp adăugat la valoarea reală a DO. Pentru a simula deriva, o valoare constantă de 0.05 mg O₂/L a fost integrată în timp și adăugată la valoarea reală a DO.

Eroarea de tip Amplificare incorectă a fost simulată prin pierderea eficienței senzorului din cauza unui factor de amplificare diferit de 1. Aceasta a constat într-un câștig de calibrare incorect de 1,4, ceea ce a dus la un factor de corelație greșit între semnalul de intrare și cel de ieșire al senzorului. Un filtru de ordinul întâi cu o constantă de timp de 0,3 zile a introdus treptat câștigul incorect în timp.

Eroarea de tip Pierdere preciziei a fost simulată folosind un generator de numere aleatoare uniforme care furniza o valoare în intervalul $[-2.5, 2.5]$ cu un timp de eşantionare de 0,1 zile. Acest semnal a fost trecut printr-un filtru de ordinul întâi cu o constantă de timp de 0,01 zile şi apoi printr-un bloc de saturaţie, care limita valoarea de ieşire la intervalul pozitiv $[0, 6]$. Acest semnal aleator a fost adăugat apoi la valoarea reală a DO pentru a genera variabila de proces măsurată afectată de eroare.

Eroarea de tip Valoare fixă a fost implementată printr-o valoare constantă a semnalului de ieşire al senzorului, indiferent de valoarea reală a variabilei de proces DO. Pentru acest studiu, s-a folosit o valoare constantă de 2,2 mg O_2/L (cu 10% mai mare decât valoarea nominală a reperului de 2 mg O_2/L).

Eroarea de tip Eroare completă a fost caracterizată, de asemenea, prin valori constante ale semnalului de ieşire al senzorului, însă aceste valori constante au corespuns valorilor minime sau maxime ale intervalului de calibrare al senzorului. Pentru variantele Eroare completă minimă şi maximă, s-au ales valorile extreme de 0,1 mg O_2/L şi 6 mg O_2/L reprezentând 5%, respectiv 300% din valoarea nominală de 2 mg O_2/L considerată pentru bucla de control a DO.

Aplicarea teoriei statistice în monitorizarea proceselor se bazează pe presupunerea că caracteristicile datelor se modifică doar atunci când apare o situaţie neaşteptată (eroare) în proces. Orice abatere semnificativă de la comportamentul normal sugerează că a avut loc un eveniment neaşteptat sau o eroare în sistem (Chiang *et al.*, 2001). De asemenea, s-a presupus că un singur senzor poate eşua o dată.

Scopul acestui capitol este de a sprijini domeniul operării şi managementului staţiilor de tratare a apei prin investigarea erorilor tipice ale senzorului de concentraţie a oxigenului dizolvat (DO), detectarea şi identificarea acestor erori şi evidenţierea modului în care acestea influenţează consumul de energie, emisiile de gaze şi calitatea apei epurate. Această lucrare a fost publicată în două articole ştiinţifice (Luca *et al.*, 2023; Luca *et al.*, 2021).

6.3. Variabile de proces considerate pentru detectarea şi identificarea erorilor senzorului DO

Setul complet de douăzeci de variabile de proces ale staţiei de tratare luate în considerare pentru construirea modelului ACP a constat în variabilele debitului şi concentraţiei apei epurate din decantorul secundar (6 variabile) şi variabilele debitului nămolului şi concentraţiei la baza decantorului (14 variabile), inclusiv temperatura. Setul complet de variabile luate în considerare a fost: azot total (N_{total}), azot Kjeldahl total (TKN), cerere chimică de oxigen (COD), azot nitrat şi nitrit (S_{NO} amoniac liber şi salin (S_{NH}), solide în suspensie totală (TSS), substrat biodegradabil lent (X_S), biomasa heterotrofică ($X_{B,H}$), biomasa autotrofică ($X_{B,A}$), produse particulare inerte (X_P), azot organic particulat biodegradabil (X_{ND}), concentraţia oxigenului dizolvat (S_O), substrat uşor biodegradabil (S_S), alcalinitate (S_{alk}), debitul de deşuri (Q_W), şi temperatură (t). Primele şase variabile din setul prezentat au fost considerate pentru apa epurată a decantorului, iar ultimele

paisprezece pentru fluxul de la baza acestuia. Variabilele de concentrație ale materiei organice inerte în suspensie (X_I) și solubilă (S_I) au fost excluse, deoarece nu aduceau informații semnificative studiului (Tomita *et al.*, 2002). Aceste variabile au fost selectate pe baza valorilor deviației standard relative (RSD) obținute în perioada de simulare cu erori. RSD este o măsură a dispersiei punctelor de date într-un set de date relativ la media acestuia și a fost utilizată ca indicator pentru a determina care variabile furnizau variații semnificative. Cu cât valoarea RSD era mai mare, cu atât variabilitatea era mai ridicată, ceea ce indica o distribuție mai largă a datelor. Valorile S_{NO} , S_O și Q_w au fost excluse din seturile ADF, deoarece generau singularitate în matricea S_w (determinantul matricei era zero și matricea nu avea inversă).

6.4. Construirea modelului ACP pentru detectarea erorilor senzorului DO

Modelul ACP a fost construit folosind 3840 de observații din perioada de funcționare normală de 40 de zile. Matricea de date obținută, X , cu dimensiunile 3840x20, a reprezentat matricea de antrenament. După scalarea matricei de date, au fost obținute matricele de scoruri T și de încărcări P . Pentru CPV_k , a fost ales un prag de 98.24%. Ca urmare, numărul componentelor principale k ce contribuiau la o reprezentare consistentă a întregului set de date a fost determinat a fi opt. A fost stabilit un prag T^2 de 20,16 și un prag SPE de 1,26 pentru nivelul de încredere de 99%. Orice vector x de variabile măsurate cu o valoare T^2 sau SPE mai mare decât cele două praguri echivalente indica o funcționare anormală a senzorului.

Au fost create șapte matrice de testare folosind vectorii de variabile măsurate în regim de funcționare defectuoasă. Câte una a fost creată pentru primele cinci tipuri de erori, la care s-a adăugat tipul de eroare completă, pentru care au fost construite două matrice corespunzătoare valorilor minime și maxime ale senzorului DO. Pentru fiecare matrice de testare (1920x20), au fost utilizate în total 1920 de mostre, provenind din simulările de la ziua 140 până la ziua 160 (excluzând ziua 160). Pentru a determina funcționarea defectuoasă a senzorului, valorile T^2 și SPE au fost calculate pentru fiecare vector de mostre din matricele de testare și comparate cu pragurile determinate anterior. Valorile T^2 și SPE au fost reprezentate grafic pentru fiecare eșantion normal (de antrenament) și defectuos (de testare), în asociere cu pragurile T_{α}^2 și SPE_{α} .

6.5. Construirea modelului ADF pentru identificarea erorilor senzorului DO

Datele generate în perioada dintre ziua 141 și ziua 145, atât pentru funcționarea normală, cât și pentru cea defectuoasă a senzorului DO, au fost utilizate pentru antrenarea modelului ADF. O clasă a fost definită ca fiind setul a 480 de observații ale celor 17 variabile. Aceste variabile au constituit matricea de antrenament cu 3840 de rânduri (8 clase a câte 480 de măsurători) și 17 coloane. Performanța de diagnosticare a erorilor a modelului ADF antrenat a fost evaluată folosind datele de la ziua 140, adică prima zi de funcționare anormală. Fiecare caz de funcționare normală sau defectuoasă avea 96 de măsurători în setul de testare. Această strategie de testare a fost concepută pentru a analiza capacitatea metodei ADF de a identifica tipul de eroare în primele ore după apariția acesteia.

Valorile obținute pentru funcția discriminantă a fiecărei clase, g_i , au fost comparate pentru a

diagnostica funcționarea defectuoasă a senzorului. Valorile funcțiilor discriminante g_i au fost calculate pentru fiecare măsurătoare eșantionată la intervale de 15 minute din ziua de testare 140, afectate de diferitele tipuri de erori (7 clase), precum și pentru măsurătorile corespunzătoare funcționării normale (1 clasă). Funcția discriminantă cu cea mai mare valoare a identificat clasa senzorului defectuos și, în consecință, a diagnosticat tipul erorii.

6.6. Rezultate și discuții

6.6.1. Metrice de evaluare pentru detectarea erorilor senzorului DO

Eficiența metodelor bazate pe ACP și ADF pentru detectarea și diagnosticarea erorilor senzorului DO a fost evaluată folosind două matrice de confuzie diferite. Această abordare a permis o analiză detaliată a performanței modelelor prin examinarea sistematică a acurateței clasificării. Evaluarea cuprinzătoare asigură o analiză precisă și de încredere a funcționării senzorului, oferind o estimare cantitativă a capacităților modelelor.

Matricea de confuzie pentru detectarea senzorului DO analizează două clase distincte: anormală (cu defect) și normală (fără defect). Clasa normală este afișată în a doua coloană (reală), în timp ce clasa anormală este reprezentată în prima coloană (reală). Figura 6.2 prezintă matricea de confuzie a senzorului DO pentru detectarea erorilor.

Matricea de confuzie pentru detectarea erorilor senzorului DO

Clasa prezisă	1	13375 87.1%	0 0.0%	100% 0.0%
	2	65 0.4%	1920 12.5%	96.7% 3.3%
		99.5% 0.5%	100% 0.0%	99.6% 0.4%
		1	2	Clasă reală

Figura 6.2. Matricea de confuzie pentru detectarea erorilor senzorului DO

Cu o rată de precizie de 100% pentru clasa normală, modelul nu a prezentat fals pozitive. Pentru clasa cu erori, precizia a fost de 96,7%. În plus, acuratețea generală a modelului a fost de 99,6%, demonstrând o capacitate ridicată de clasificare corectă a observațiilor. Scorul F1 pentru clasa normală a fost de 0,983, în timp ce clasa cu erori a obținut un scor F1 remarcabil de 0,997. Aceste valori indică un echilibru excepțional între rapel și precizie, clasa cu erori performând în mod deosebit.

6.6.2. Detectarea erorilor senzorului DO

În primul rând, modelul ACP propus și dezvoltat a fost aplicat setului de date aferent funcționării normale. După cum este prezentat în Figura 6.3, toate valorile T^2 și SPE din acest set de date au fost

validate ca fiind fără erori și, prin urmare, au fost clasificate ca valori corespunzătoare funcționării normale. Mai mult, graficul T^2 arată că diferența dintre valorile din funcționarea normală și pragul asociat acestora a fost mai mare pentru T^2 decât cea indicată de graficul SPE. Aceasta înseamnă că, în modul de funcționare normal, statisticile SPE furnizează cele mai fiabile date.




Figura 6.3. Graficele T^2 și SPE pentru monitorizarea ACP a setului de date aferent funcționării normale a senzorului DO

Figurile 6.4-6.10 prezintă rezultatele detectării erorilor pentru fiecare tip de eroare investigată a senzorului DO.

Eroarea de zero a fost detectată după 1 oră folosind statisticile T^2 și după 1 oră și 15 minute folosind statisticile SPE, așa cum se poate observa în Figura 6.4.




Figura 6.4. Graficele T^2 și SPE ale ACP pentru detectarea erorii de zero a senzorului DO, cu detalii asupra perioadei imediat după apariția erorii

Figura 6.5 prezintă detectarea erorii de drift. Graficele confirmă existența erorii după 8,5 h

folosind metoda T^2 . În acest caz, metoda SPE s-a dovedit mai rapidă, detectând eroarea după 5,25 h. Eroarea de tip Derivă a fost de așteptat să necesite mai mult timp pentru a fi identificată, deoarece semnalul afectat crește lent în timp și depășește pragul statistic doar atunci când amplitudinea sa devine semnificativă.




Figura 6.5. Graficele T^2 și SPE ale ACP pentru detectarea erorii de drift a senzorului DO, cu detalii asupra perioadei imediat după apariția erorii

Pentru eroarea de proporționalitate, ambele metode statistice s-au dovedit la fel de rapide, iar defectul a fost detectat în 2 ore și 30 de minute. Rezultatele pentru detectarea acestei erori a senzorului DO sunt prezentate în Figura 6.6.




Figura 6.6. Graficele T^2 și SPE ale ACP care detectează eroare de proporționalitate a senzorului DO, cu detalii asupra perioadei imediat după apariția defectului.

Figura 6.7 prezintă rezultatele pentru eroarea de tip Pierdere preciziei a senzorului DO. În acest caz, prezența defectului a fost detectată în 3 h și 45 de minute atât de metodele T^2 și SPE . Pentru

acest tip de defect, detectarea depinde de amplitudinea aleatoare a valorii componente defectuoase.




Figura 6.7. Graficele T^2 și SPE ale ACP pentru detectarea erorii de liniaritate a senzorului DO, cu detalii asupra perioadei imediat după apariția defectului

Detectarea erorii de tip Valoare fixă a fost realizată în 1,25 ore. Pentru această eroare, ambele metode s-au dovedit la fel de eficiente. Figura 6.8 prezintă rezultatele pentru eroarea de tip Valoare fixă a senzorului DO.




Figura 6.8. Graficele T^2 și SPE ale ACP pentru detectarea valorii fixe a senzorului DO, cu detalii asupra perioadei imediat după apariția erorii

Din nou, în cazul erorii avarie totală de tip minim, statistica T^2 s-a dovedit la fel de rapidă ca și statistica SPE , iar timpul de detecție a fost de 1 h. Rezultatele pentru eroarea de tip complet minim a senzorului DO sunt prezentate în Figura 6.9.




Figura 6.9. Graficele T^2 și SPE ale ACP pentru detectarea avariei totale minime a senzorului DO, cu detalii asupra perioadei imediat după apariția erorii

Așa cum se arată în Figura 6.10, avaria totală maximă a fost detectată după 1 h, similar cu erorile de tip Eroare completă minimă și Eroarea de zero.




Figura 6.10. Graficele T^2 și SPE ale ACP pentru detectarea avariei totale maxime a senzorului DO, cu detalii asupra perioadei imediat după apariția erorii

Modelul ACP propus a detectat cu succes apariția diferitelor tipuri de erori ale senzorului DO. De regulă, metoda SPE a oferit o detectare mai rapidă decât metoda T^2 cu o promptitudine mai mare în special pentru eroarea de tip eroare de drift. Eficiența statisticilor T^2 și SPE a fost comparabilă pentru erorile de tip eroarea de zero, eroare de proporționalitate, eroare de liniaritate, valoare fixă și avarie totală. Aceste rezultate demonstrează capacitatea metodei bazate pe ACP proiectate pentru detectarea timpurie a erorilor senzorului DO, asigurând o identificare promptă a defectelor și oferind fiabilitate funcționării eficiente a stației de tratare.

Așa cum se arată în Figura 6.12, valorile g_i au indicat diagnosticul consolidat al funcționării normale (valori fără defect) după 16,5 ore (momentul identificării cu încredere). În acest caz, un set mic de 52 de observații a fost clasificată greșit ca eroare de drift, rezultând un RAR de 2,7%. În plus, scorul F1 a fost calculat la 0,973, reflectând un bun echilibru între precizie și rapel.




Figura 6.12. Diagnosticarea funcționării fără defect a senzorului DO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru fiecare dintre valorile normale și cele șapte tipuri de erori; detalii asupra perioadei de timp pentru identificarea cu încredere

Identificarea tipurilor de erori ale senzorului este prezentată în figurile 6.13-6.19.

După cum se observă în Figura 6.13, diagnosticul erorii de tip eroare de zero este confirmat după 2,5 ore, pentru un total de 5,75 ore. Drept urmare, discriminarea ADF indică clasa Eroare completă maximă pentru restul perioadei zilei. Aceasta a condus la o valoare RAR de 100% și un scor F1 de 0.




Figura 6.13. Diagnosticul erorii de zero a senzorului DO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru fiecare dintre valorile normale și cele șapte tipuri de erori; detalii asupra perioadei de identificare sigură

Așa cum se arată în Figura 6.14, diagnosticul erorii de tip eroare de drift este confirmat după 13,75 ore (momentul identificării sigure). În acest caz, RAR a fost de doar 0,6%. Acest procent redus de clasificare greșită evidențiază cât de bine poate modelul să diferențieze între condițiile cu erori și cele fără erori. În plus, scorul F1 a arătat o performanță bine echilibrată între precizie și rapel, atingând valoarea de 0,949.




Figura 6.14. Diagnosticul erorii de drift a senzorului DO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru fiecare dintre operațiunile normale și cele șapte tipuri de erori; detalii asupra perioadei de identificare sigură

La 14 ore de la momentul apariției erorii, diagnosticul erorii de tip eroare de proporționalitate a

fost confirmat. Figura 6.15 prezintă reprezentarea grafică a diagnosticului acestui tip de eroare. Eficiența generală a modelului în identificarea corectă a observațiilor a fost demonstrată prin scorul F1 de 0,985.




Figura 6.15. Diagnosticul erorii de proporționalitate a senzorului DO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru fiecare dintre starea normală și cele șapte tipuri de erori; detalii asupra perioadei de identificare sigură

Figura 6.16 arată că eroarea de liniaritate este identificată după 16,5 ore de la momentul apariției acesteia. Cu toate acestea, 62 de observații au fost clasificate greșit, dintre care 19 au fost incorect atribuite stării normale de funcționare și 43 tipului eroare de drift, rezultând un RAR de 3,2%




Figura 6.16. Diagnosticul erorii de liniaritate a senzorului DO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru fiecare dintre starea normală și cele șapte tipuri de erori; detalii asupra perioadei imediat după momentul identificării sigure

Figura 6.17 prezintă reprezentarea grafică a erorii de tip valoare fixă. Acest tip de eroare a fost diagnosticat corect după 6 ore (momentul identificării sigure). Cu al doilea cel mai mare scor F1, de 0,990, modelul a demonstrat o performanță remarcabilă în identificarea erorii de tip Valoare fixă. Acest scor ridicat evidențiază un echilibru bun între precizie și rapel, susținând astfel fiabilitatea clasificării.




Figura 6.17. Diagnosticul valorii fixe a senzorului DO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru fiecare dintre starea normală și cele șapte tipuri de erori; detalii asupra perioadei de identificare sigură

Figura 6.18 arată că avaria totală minimă este diagnosticată corect după 6,75 ore (momentul identificării sigure) de la apariția sa. Identificarea avariei totale a fost realizată cu cea mai mare acuratețe, ceea ce este indicat de cel mai ridicat scor F1 de 0,993. Rata de clasificare greșită (RAR) a fost de 1,4%.




Figura 6.18. Diagnosticul avariei totale minime pentru senzorul DO: grafice ale funcțiilor discriminante $g_i(x)$ ale ADF pentru fiecare dintre valorile normale și cele șapte tipuri de erori; detalii asupra perioadei de identificare sigură

Așa cum se arată în Figura 6.19, avaria totală maximă este diagnosticată cu succes după 9,5 ore (momentul identificării sigure). Pentru avaria totală maximă, metoda de identificare a prezentat rezultate mai puțin precise, cu o rată de clasificare greșită (RAR) de 1,9%.




Figura 6.19. Diagnosticul avariei totale maxime pentru senzorul DO: grafice ale funcțiilor discriminante $g_i(x)$ ale ADF pentru fiecare dintre valorile normale și cele șapte tipuri de erori; detalii asupra perioadei de identificare sigură

Metoda bazată pe ADF pentru erorile senzorului DO oferă un cadru de încredere pentru diagnosticarea rapidă a defectelor senzorului și monitorizarea eficientă a evoluției acestora.

6.6.5. Evaluarea performanței stației de tratare în timpul funcționării cu erori ale senzorului DO

Pentru scenariile de funcționare normală și defectuoasă ale senzorului DO, indicii de performanță AE, PE și EQ au fost determinați ca valori medii pe o perioadă de 28 de zile (începând cu ziua 140 până la ziua 168). Valorile indicilor pentru condițiile de operare normală și pentru cele șase tipuri diferite de erori sunt prezentate în Tabelul 6.1 ca indicatori de performanță AE, PE și EQ.

Regim de operare	AE (kWh/day)	PE (kWh/day)	Cererea totală de energie (kWh/day)	EQ (kg PU/day)
Funcționare normală	16,992	1,329	18,321	16,852
Eroare de zero	14,206	2,415	16,621	21,461
Eroare de drift	15,569	1,746	17,315	17,134
Eroare de proporționalitate	15,866	1,593	17,459	16,706
Eroare de liniaritate	9,150	2,403	11,553	219,189
Valoare fixă	1,968	2,415	4,383	338,737
Avarie totală - minim	23,537	1,039	24,576	19,804
Avarie totală - maximă	1,968	2,415	4,383	338,750

Tabel 6.1. Valorile indicilor de performanță pentru cazurile de operare normală și defectuoasă

Este evident că valorile indicilor PE și EQ pentru tipurile de defecte eroare de zero, eroare de liniaritate, valoare fixă și avarie totală maximă sunt semnificativ mai mari decât valorile pentru funcționarea normală, deși AE este mai mic. Valorile mari ale semnalului senzorului DO din categoriile menționate, transmise controlerului DO ca feedback, justifică valorile AE. Ca urmare a semnalului crescut de defect, controlerul DO reduce aerarea pentru a diminua valoarea semnalului DO incorect, ceea ce conduce la o scădere a consumului de energie pentru aerare. Ulterior, nitrificarea scade, ceea ce reduce concentrația de nitrați și nitriți în reactorul aerobic și, în final, în reactorul anoxic. Debitului intern de recirculare este crescut de bucla de control NO ca răspuns la această schimbare, ceea ce generează o nevoie mai mare de energie pentru pompare. În cazul erorii de tip avarie totală - minim, valoarea ridicată a AE este determinată de creșterea debitului de aer controlat de controlerul DO ca reacție la valoarea scăzută, dar incorectă, a semnalului senzorului DO.

6.6.6. Evaluarea costurilor energetice pentru funcționarea afectată de erorile senzorului DO

În general, operarea unei stații de tratare a apelor uzate implică costuri energetice semnificative și, implicit, cheltuieli economice considerabile. Prețurile energiei sunt influențate de factori de ofertă și cerere precum geopolitica, mixul energetic specific al țării, costurile rețelei de distribuție, taxe pentru protecția mediului, condiții meteorologice extreme, precum și nivelurile accizelor și impozitelor. Sursa de energie are, de asemenea, un impact asupra costului acesteia. Conform Tabelului 6.2, costurile energiei, în funcție de sursă, variază între 5,84 și 18,75 eurocenți. Aceste valori reprezintă medii calculate pe baza a două rapoarte diferite privind costurile energiei în Europa (Kost *et al.*, 2024), Statele Unite și piețele globale (Lazard, 2024) precum și pe baza unui calculator online furnizat de Agenția Internațională pentru Energie (IEA) (IEA, 2024).

Tabel 6.2. Costuri medii în funcție de sursa energetică

Sursă/Tehnologie	€/cents/kWh
Lignit	9.89
Cărbune	9.37
Gaz (CCGT ¹)	10.78
Nuclear	18.75
Eolian onshore (pe uscat)	6.75
Eolian offshore (pe RARe)	8.55
Fotovoltaic comercial	8.07
Fotovoltaic residential	12.70
Solar termic (CSP ²)	14.8
Hidro cu acumulare (rezervor)	7.95
Hidro de tip run-of-river (firul apei)	5.84
Geotermal	8.63
Biomasă	11.57

¹CCGT - turbine pe gaz cu ciclu combinat

²CSP - energie solară concentrată

Pentru stația de tratare a apelor uzate luată în considerare în cadrul acestui studiu, s-a determinat costul zilnic atât pentru regimul normal de funcționare, cât și pentru fiecare tip de regim defectuos. Costurile zilnice pentru diferite surse de energie au fost evaluate pe baza tehnologiilor de producere a energiei. Costurile diferitelor surse de energie au fost înmulțite cu valorile cererii totale de energie calculate pentru scenariile de funcționare normală și defectuoasă, pentru a genera datele prezentate în Tabelul 6.3.

Tabel 6.3. Suma costurilor de energie AE și PE, în funcție de sursă, calculată pentru funcționarea normală și afectată de defecte a liniei de apă a stației de tratare, pentru cazul senzorului de oxigen dizolvat (DO)

Sursă/Tehnologie	Costuri zilnice de operare(€)							
	Funcționare normală	Eroarea de zero	Eroare de drift	Eroare de proporționalitate	Eroare de liniaritate	Valoare fixă	Avarie totală - minim	Avarie totală - maxim
Lignit	1,812	1,644	1,712	1,727	1,143	433	2,431	433
Cărbune	1,717	1,557	1,622	1,636	1,083	411	2,303	411
Gaz (CCGT ¹)	1,975	1,792	1,867	1,882	1,245	472	2,649	472
Nuclear	3,435	3,116	3,247	3,274	2,166	822	4,608	822
Eolian onshore (pe uscat)	1,237	1,122	1,169	1,178	780	296	1,659	296
Eolian offshore (pe RARe)	1,566	1,421	1,480	1,493	988	375	2,101	375
Fotovoltaic comercial	1,479	1,341	1,397	1,409	932	354	1,983	354
Fotovoltaic residential	2,327	2,111	2,199	2,217	1,467	557	3,121	557
Solar termic (CSP)	2,712	2,460	2,563	2,584	1,710	649	3,637	649
Hidro cu acumulare (rezervor)	1,457	1,321	1,377	1,388	918	348	1,954	348
Hidro de tip run-of-river (firul apei)	1,070	971	1,011	1,020	675	256	1,435	256
Geotermal	1,581	1,434	1,494	1,507	997	378	2,121	378
Biomasă	2,120	1,923	2,003	2,020	1,337	507	2,843	507

La examinarea costurilor asociate cu energia electrică utilizată pentru diversele cazuri de defect, se poate observa că eroarea de tip completă - valoare minimă a senzorului de DO este asociată cu cele mai ridicate costuri energetice, întrucât sistemul de control este forțat să crească semnificativ debitul de aer din cauza valorii eronate scăzute furnizate de senzorul de DO. Pe de altă parte, valorile RARi ale semnalului senzorului de DO, asociate cu defectele de tip completă - valoare maximă sau valoare fixă (ridicată), determină regulatorul de DO să limiteze debitul de aer, rezultând în costuri energetice reduse. Totuși, în aceste din urmă situații, calitatea efluentului scade rapid de peste 20 de ori, ceea ce face ca aceste defecte să aibă cele mai grave efecte generale.

6.6.7. Evaluarea impactului asupra mediului al emisiilor de CO₂ și N₂O pentru funcționarea cu defecte ale senzorului de DO

Pentru fiecare caz de funcționare defectuoasă, precum și pentru funcționarea normală, au fost estimate emisiile la fața locului și cele din afara amplasamentului de CO₂ și N₂O, principalii contributori la gazele cu efect de seră produse de linia de apă a stației de tratare. Tabelul 6.4 prezintă valorile medii zilnice ale acestora.

Tabel 6.4. Emisiile de gaze cu efect de seră cauzate de diferitele tipuri de erori ale senzorului DO

Locul emisiilor	Proces	Tip de gaz emis	Tipul erorii							
			Normal	Eroare de zero	Eroare de drift	Eroare de proporționalitate	Eroare de liniaritate	Valoare fixă	Eroare completă - minim	Eroare completă - maxim
Emisii din afara amplasamentului	Producerea de energie electrică	CO ₂ , $P_{CO_2,off-site}$ (kg CO ₂ /day)	3,481	3,158	3,290	3,317	2,195	833	4,669	833
	Degradare biologică în efluentul stației de tratare	N ₂ O, $P_{N_2O,off-site}$, (kg N ₂ O/day)	3.61	2.47	2.89	2.97	14.39	21.49	6.50	21.49
Emisii la fața locului	Procese biologice aerobe din linia de apă	CO ₂ , $P_{CO_2,on-site}$ (kg CO ₂ /day)	13,689	30,459	17,851	16,178	461,439	921,028	10,604	921,168
		N ₂ O, $P_{N_2O,on-site}$ (kg N ₂ O/day)	10.35	10.81	10.64	10.05	6.07	3.27	9.20	3.27
Total emisii		CO ₂ , $P_{CO_2,total}$ (kg CO ₂ /day)	17,170	33,617	21,141	19,495	463,634	921,861	15,274	922,001
		N ₂ O, $P_{N_2O,total}$ (kg N ₂ O/day)	13.96	13.28	13.53	13.02	20.46	24.76	15.70	24.76
Total emisii generale		CO _{2e} , $P_{CO_{2e},overall}$ (kg CO _{2e} /day)	21,330	37,574	25,173	23,375	469,731	929,239	19,953	929,379

Conform rezultatelor evaluării emisiilor de gaze cu efect de seră prezentate în Tabelul 6.4, emisiile la fața locului sunt cele mai importante, reprezentând 75%-80% din emisiile totale în timpul funcționării normale, atât pentru $P_{CO_2, total}$ cât și pentru $P_{N_2O, total}$. Cu excepția avariei totale minime, toate cazurile de erori ale senzorului DO au dus la creșterea valorilor emisiilor totale de CO_2 calculate, adică suma valorilor la fața locului și în afara sitului.

Valori crescute ale emisiilor de N_2O se regăsesc de asemenea atunci când emisiile totale de N_2O sunt evaluate pentru erorile de tip valoare fixă, avarie totală maximă și eroare de liniaritate. Trebuie menționat că avaria totală minimă a condus la valori mai mari ale emisiilor de N_2O , ceea ce reprezintă opusul tendinței observate pentru emisiile totale de CO_2 . Emisiile totale de CO_2 și N_2O au fost cumulate pentru a calcula valorile generale ale emisiilor CO_2e . Toate erorile prezintă niveluri mai ridicate ale emisiilor de CO_2 comparativ cu cazul funcționării normale, conform rezultatelor emisiilor totale de CO_2 . Singura excepție de la această tendință este avaria totală minimă. Totuși, în acest caz specific, calitatea efluentului se deteriorează cu mai mult de 17,50%, iar suma energiei de aerare și pompare înregistrează cele mai mari valori dintre toate situațiile analizate.

6.7. Concluzii

Folosind senzorul DO al unei stații municipale de tratare A^2O ca studiu de caz, au fost evaluate metodele de detectare a erorilor bazate pe ACP și metodele de diagnosticare bazate pe ADF, împreună cu performanța energetică și calitatea apei. Senzorul DO este esențial pentru eficiența nitrificării, aerarea fiind principalul consumator de energie. Au fost analizate șase tipuri de erori: eroare de zero, eroare de drift, eroare de proporționalitate, eroare de liniaritate, valoare fixă și avarie totală. ACP a detectat erorile cu o acuratețe de 99,6%, de obicei în intervalul 2-9 ore, în funcție de tipul de eroare, în timp ce diagnosticarea prin ADF a atins o acuratețe de 85,8% în 2,5-16,5 ore.

Erorile au afectat calitatea efluentului și consumul de energie în mod diferit: eroare de zero și eroare de drift au redus moderat energia, dar au deteriorat calitatea apei, în timp ce erorile de tip eroare de liniaritate și valoare fixă au cauzat degradări severe ale efluentului. Erorile de tip avarie totală au arătat extreme, cu cerințe energetice mari sau cu o calitate a efluentului drastic redusă. Emisiile de CO_2 și N_2O au fost cele mai mari de la sursele locale, în special în cazul erorilor de tip avarie totală, valoare fixă și eroare de liniaritate. Costurile energetice au depins de tipul erorii, citirile scăzute ale DO crescând cerințele de aerare.

Studiul demonstrează că abordările ACP și ADF detectează și diagnostichează eficient erorile senzorului DO, susținând o funcționare sigură, eficientă și durabilă a stației de tratare. Rezultatele oferă informații utile pentru proiectarea sistemelor de control, optimizarea energiei, reducerea emisiilor de gaze cu efect de seră și dezvoltarea senzorilor inteligenți.

7. Detectarea și diagnosticarea erorilor senzorului NO și impactul acestora asupra energiei, calității apei și emisiilor de gaze cu efect de seră

7.1. Introducere

Măsurătorile fiabile ale senzorilor sunt esențiale pentru respectarea reglementărilor și pentru controlul optim al proceselor în stațiile de tratare a apelor uzate. Dintre numeroșii senzori utilizați în operarea stațiilor de tratare, senzorul de concentrație NO este esențial pentru monitorizarea dinamică a concentrațiilor de nitrat și nitrit. Compușii de azot prezenți în stațiile de tratare pot provoca probleme semnificative de mediu.

Acest studiu se concentrează pe detectarea și identificarea diferitelor erori ale senzorului NO. Tipuri specifice de erori ale senzorului de concentrație NO au fost integrate în modelul dinamic al stației de tratare, iar mai multe simulări diferite au fost dezvoltate pentru a evidenția comportamentul stației ca urmare a acestor erori. Au fost luate în considerare cinci tipuri diferite de erori: eroare de zero, eroare de drift, eroare de proporționalitate, eroare de liniaritate și valoare fixă. Pentru a detecta eficient aceste erori, a fost dezvoltat, validat și testat un model bazat pe ACP. Un alt model, bazat pe ADF, a fost implementat și utilizat pentru diagnosticarea tipului de eroare a senzorului NO.

Mai mult, matricea de confuzie a fost utilizată pentru a evalua în mod detaliat metodele de diagnosticare și detectare a erorilor, oferind o evaluare numerică a performanței clasificării atât în scenariile normale, cât și în cele cu erori.

Impactul erorilor senzorului NO asupra performanței stației de tratare este examinat în detaliu în acest capitol prin analiza costurilor energetice, calității efluentului și evaluărilor de mediu. Pentru aceasta, au fost analizați trei indici de performanță împreună cu emisiile de gaze cu efect de seră, toate cuantificate atât în condiții normale, cât și în condiții de erori ale senzorului.

7.2. Metodologia implementării erorilor senzorului NO

Au fost dezvoltate module software dedicate pentru a simula tipurile specifice de erori considerate pentru senzorul de concentrație NO. Acestea au fost integrate în simularea dinamică a stației de tratare. Pentru fiecare tip de eroare, ieșirea senzorului afectată de eroare a fost transmisă către controlerul Proportional-Integral NO ca variabilă de proces NO măsurată. Bucla de control este direct responsabilă pentru procesul de denitrificare al tehnologiei ASM. Amplasarea acestui senzor este prezentată în Figura 7.1.




Figura 7.1. Amplasarea senzorului NO în stația municipală de tratare

Sistemul de control NO ajustează debitul intern de recirculare a nitratului și nitritului pentru a atinge valoarea de referință dorită de 0.01 mg N/L, fără offset. Pentru fiecare dintre erori, scenariul de investigare a fost realizat similar cu cazul senzorului DO în ceea ce privește durata. Mai întâi, simularea a fost rulată fără nicio eroare a senzorului timp de 139 de zile. Fiecare eroare a fost apoi implementată pentru un total de 28 de zile, începând cu ziua 140 a simulărilor. Valorile variabilelor de proces utilizate în metodologia de identificare și testare a erorilor au fost colectate începând cu ziua 140, adică prima zi de funcționare cu eroare. Aceeași durată de 28 de zile pentru perioada de colectare a măsurătorilor a fost considerată și pentru datele care descriu funcționarea normală.

Eroarea de zero a fost caracterizată printr-o diferență constantă prestabilită între valorile reale și valorile afectate de eroare ale senzorului. Pentru implementarea erorii în simulare, o valoare constantă negativă de -0.0098 mg N/L a fost adăugată la valoarea reală a concentrației NO.

Eroarea de drift a fost simulată ca un semnal rampă variabil în timp, scăzut din valoarea reală a NO. O valoare constantă negativă de -0.0075 mg N/ a fost integrată în timp și adăugată la valoarea reală a NO (adică -75% din valoarea nominală a valorii de referință a circuitului de control NO de 0.01 mg N/L).

Eroarea de proporționalitate a fost simulată prin pierderea eficienței senzorului ca urmare a unui factor de amplificare negativ. Aceasta a avut un câștig de calibrare incorect de -0,7, ceea ce a dus la o corelație incompletă între semnalul de intrare și cel de ieșire al senzorului. Amplificarea incorectă a fost introdusă treptat în timp printr-un filtru de ordin întâi cu constanta de timp de 0,1 zile.

Pentru simularea erorii de liniaritate a fost utilizat un generator de numere aleatoare uniforme care furniza valori în intervalul [-0,06, 0,06], cu un timp de eșantionare de 0,1 zile. Acest semnal a fost procesat printr-un filtru de ordin întâi cu constanta de timp de 0,01 zile, urmat de un bloc de saturație, care limita valoarea de ieșire la intervalul pozitiv [0, 3]. Semnalul aleator astfel obținut a fost apoi scăzut din valoarea reală a NO pentru a genera variabila de proces NO măsurată inexact.

Eroarea de tip valoare fixă a fost caracterizată prin valoarea constantă a semnalului de ieșire al senzorului. Pentru acest studiu, o valoare constantă de -0.0095 mg N/L (echivalentul a 95% din valoarea nominală a valorii de referință a circuitului de control NO de 0.01 mg N/L) fost adăugată la valoarea nominală a valorii de referință de 0,01 mg N/L, rezultând o valoare constantă a senzorului

de 0.0005 mg N/L.

Fiecare tip de eroare al senzorului de concentrație NO a fost introdus individual la timpul specificat în simulările dinamice și a generat setul de date necesar descrierii situației anormale respective.

Acest capitol propune sprijinirea managementului stației de tratare prin investigarea modului în care erorile senzorului NO afectează consumul de energie, emisiile de gaze cu efect de seră și calitatea efluentului. De asemenea, evaluează eficiența detectării și identificării erorilor folosind metodele ACP și ADF și oferă recomandări pentru operarea și întreținerea pe termen lung a stației de tratare. Lucrarea prezentată a fost publicată într-un articol științific (Luca *et al.*, 2025).

7.3. Variabilele de proces considerate pentru detectarea și identificarea erorilor senzorului NO

Au fost considerate douăzeci de variabile de proces pentru modelul ACP și douăzeci și una pentru modelul ADF. Acestea includ concentrațiile din decantoarele secundare (3 variabile), concentrațiile din bioractoarele anoxice (8 variabile), concentrațiile din bioractoarele aerate (7 variabile), debitul intern de recirculare (1 variabilă), debitul de aerare (1 variabilă) și debitul efluentului de apă curată (1 variabilă). Variabilele luate în considerare au fost următoarele: azotul nitrat și nitrit (S_{NO}), amoniacul liber și salin (S_{NH}), azotul organic solubil biodegradabil (S_{ND}), azotul organic particulat biodegradabil (X_{ND}), concentrația de oxigen dizolvat (S_O), substratul ușor biodegradabil (S_S), substratul lent biodegradabil (X_S), alcalinitatea (S_{alk}), debitele reactoarelor (Q), debitul de recirculare a nitratului (Q_{NR}) și debitul de aerare (Q_{air}). Valorile măsurate ale lui Q_{NR} au fost excluse din modelul ADF.

7.4. Construcția modelului ACP pentru detectarea erorilor senzorului NO

Modelul ACP a fost dezvoltat folosind 3840 de observații din perioada de funcționare normală de 40 de zile. O matrice de 3840 de observații pentru cele 21 de variabile luate în considerare a definit matricea de antrenament X . Matricea T a scorurilor și matricea P o încărcăturilor au fost obținute după scalarea matricei de date de antrenament. A fost ales un prag de 98,98% pentru CPV_k . Ca rezultat, numărul de componente principale k considerate necesare pentru a reprezenta întregul set de date a fost determinat ca fiind 8. La un nivel de încredere de 99%, pragul T_α^2 a fost 20,16, iar pragul SPE_α a fost 0,97. O eroare a fost indicată de orice vector x de variabile măsurate cu o valoare T^2 sau SPE mai mare decât cele două praguri corespunzătoare.

Au fost constituite cinci matrice diferite de date de testare pentru fiecare tip de eroare, folosind vectorii de variabile măsurate în condiții anormale de funcționare. Fiecare matrice de testare a fost construită din 1920 de observații pentru 20 de variabile, corespunzătoare perioadei simulate de la ziua 140 până la ziua 160 (excluzând ziua 160). Pentru fiecare vector de probe din matricile de testare, a fost determinată o valoare a indicelui T^2 și una a indicelui SPE . Pentru a determina funcționarea defectuoasă a senzorului, valorile T^2 și SPE au fost calculate pentru fiecare vector de

probe din matricile de testare și comparate cu pragurile determinate anterior.

Valorile T^2 și SPE au fost reprezentate grafic pentru fiecare dintre probele normale (de antrenament) și cele cu erori (de testare), împreună cu pragurile T_α^2 și SPE_α .

7.5. Construcția modelului ADF pentru identificarea erorilor senzorului NO

Șase clase de date distincte au fost create pentru fiecare scenariu: una pentru modul de funcționare normal și cinci pentru fiecare tip de funcționare a senzorului NO în prezența unei erori. Aceste clase au fost create folosind datele din zilele 141 până în 145 (cinci zile) și au fost utilizate pentru antrenarea modelului ADF. Fiecare clasă a fost definită prin 480 de observații, rezultând o matrice de antrenament cu 2880 de linii și 20 de coloane. Datele din ziua 140, prima zi de funcționare anormală, au fost utilizate pentru evaluarea performanței modelului ADF antrenat în diagnosticarea erorilor. Setul de date de testare a inclus 96 de măsurători pentru fiecare caz, normal sau anormal. Scopul acestei strategii de testare a fost investigarea capacității metodei de diagnostic ADF de a identifica tipul erorii în primele câteva ore de la apariția acesteia.

Pentru a diagnostica funcționarea defectuoasă a senzorului, valorile g_i , obținute pentru funcția discriminantă a fiecărei clase, au fost comparate. Funcțiile discriminante g_i au fost calculate pentru fiecare măsurătoare eșantionată la 15 minute din ziua de testare 140, afectată de diferitele tipuri de erori (5 clase), precum și pentru măsurătorile corespunzătoare funcționării normale (1 clasă). Funcția discriminantă cu cea mai mare valoare a identificat clasa senzorului defect și, astfel, a diagnosticat tipul erorii.

7.6. Rezultate și discuții

7.6.1. Metrici de evaluare pentru detectarea erorilor senzorului NO

Au fost utilizate două matrice de confuzie diferite pentru a evalua eficiența metodelor bazate pe ACP și ADF, una pentru detectarea și cealaltă pentru diagnosticarea erorilor senzorului NO. Matricea de confuzie pentru detectarea erorilor senzorului NO ia în considerare două clase: normal (fără erori) și anormal (cu erori). Prima coloană (reală) afișează clasa anormală, în timp ce a doua coloană (reală) afișează clasa normală. Matricea de confuzie pentru detectarea erorilor senzorului NO este prezentată în Figura 7.2.

Matricea de confuzie pentru detectarea erorilor senzorului NO

Clasă prezisă	1	9398 81.6%	0 0.0%	100% 0.0%
	2	202 1.8%	1920 16.7%	90.5% 9.5%
		97.9% 2.1%	100% 0.0%	98.2% 1.8%
		1	2	Clasă reală

Figura 7.2. Matricea de confuzie pentru detectarea erorilor senzorului NO

Pentru clasa normală, precizia este de 100%, ceea ce înseamnă că nu există false pozitive; pentru clasa anormală, precizia este de 90,5%. Doar 202 observații, reprezentând 1,8% din totalul observațiilor, au fost clasificate incorect ca aparținând clasei anormale. Acuratețea generală a modelului, de 98,2%, arată că acesta a performat foarte bine în detectarea corectă a erorilor senzorului NO.

Valoarea F1 pentru clasa normală este 0,950, iar pentru clasa anormală este 0,989. Ambele scoruri indică un echilibru remarcabil între rapel și precizie, cu performanțe foarte bune pentru clasa normală.

7.6.2. Detectarea erorilor senzorului NO

Pe baza algoritmului ACP, prezența unei erori a senzorului NO este detectată atunci când un vector de variabile măsurate x depășește valorile prag pentru ambii indici T^2 și SPE .

Metoda de detectare a erorilor senzorului NO bazată pe ACP a demonstrat o eficiență ridicată în identificarea defectelor senzorului într-o etapă timpurie. Dintre cei doi indici statistici, abordarea bazată pe SPE a prezentat o performanță superioară în detectarea erorilor comparativ cu metoda T^2 . Totuși, utilizarea ambilor indici în combinație poate crește fiabilitatea prin oferirea unei evaluări mai cuprinzătoare a apariției și persistenței erorilor.

Modelul ACP propus a fost testat inițial pe setul de date de funcționare normală. Reprezentările grafice ale valorilor T^2 și SPE pentru probele din acest set de date, comparativ cu pragurile corespunzătoare, sunt prezentate în Figura 7.3. Acestea confirmă scenariul fără erori, cu excepția unor puncte din statisticile T^2 . Aceasta înseamnă că, pentru modul de funcționare normal, statistica SPE oferă cele mai relevante rezultate pentru detectarea erorilor, așa cum a fost raportat și în literatura de specialitate (Yoo *et al.*, 2004).




Figura 7.3. Graficele T^2 și SPE ale monitorizării ACP pentru setul de date de funcționare normală a senzorului NO

Figurile 7.4 până la 7.8 prezintă rezultatele detectării erorilor pentru fiecare dintre tipurile de erori ale senzorului NO investigate.

Figura 7.4 arată că eroarea de zero a fost detectată la 1,25 ore de la apariția sa (în ziua 140). Cu doar câteva excepții în zilele 145, 152 și 159, statistica SPE detectează corect regimul defectuos, oferind rezultate mai bune decât statistica T^2 .




Figura 7.4. Graficele T^2 și SPE ale ACP pentru detectarea erorii de zero a senzorului NO, cu detalii asupra perioadei imediat după apariția erorii

Metoda SPE a detectat eroarea de tip eroare de drift în 19 ore și 15 minute, mai rapid decât metoda T^2 a lui Hotelling. Figura 7.5 arată că detectarea erorii cu T^2 a durat 35 ore și 15 minute.




Figura 7.5. Graficele T^2 și SPE ale ACP pentru detectarea erorii de drift a senzorului NO, cu detalii asupra perioadei imediat după apariția erorii

Figura 7.6 prezintă detectarea erorii de proporționalitate. În acest caz, metoda SPE s-a dovedit din nou mai precisă. Deși metoda T^2 detectează inițial eroarea în 1,5 ore, confirmarea prezenței erorii pe întreaga perioadă apare abia după 6,5 ore, în timp ce metoda SPE recunoaște ferm eroarea de tip amplificare incorectă pe întreaga perioadă de 28 de zile după 2 ore și 45 de minute..




Figura 7.6. Graficele T^2 și SPE ale ACP pentru detectarea erorii de proporționalitate a senzorului NO, cu detalii asupra perioadei imediat după apariția erorii

Deși metoda T^2 confirmă prezența erorii de liniaritate în 1 oră și 45 de minute, iar metoda SPE recunoaște prezența acesteia după 3 ore și 45 de minute, metoda SPE o detectează mai bine în zilele următoare, respectiv în zilele 141, 143 și 144, așa cum se arată în Figura 7.7.




Figura 7.7. Graficele T^2 și SPE ale ACP pentru detectarea erorii de liniaritate a senzorului NO, cu detalii asupra perioadei imediat după apariția erorii

Detectarea valorii fixe prin ACP este prezentată în Figura 7.8. În acest caz, ambele metode au

fost la fel de eficiente și rapide, detectând eroarea de tip Valoare fixă în 1 oră și 30 de minute.




Figura 7.8. Graficele T^2 și SPE ale ACP pentru detectarea erorii de tip valoare fixă a senzorului NO, cu detalii asupra perioadei imediat după apariția erorii

Metoda de detectare a erorilor senzorului NO bazată pe ACP s-a dovedit a fi foarte eficientă și rapidă în identificarea erorilor, statistica SPE demonstrând o performanță superioară metodei T^2 .

7.6.3. Metrici de evaluare pentru diagnosticarea erorilor senzorului NO

Pentru metoda de identificare ADF a fost dezvoltată, de asemenea, o matrice de confuzie. Prima coloană a acestei matrice afișează clasa normală (funcționare fără erori, reala 1). Coloanele următoare listează clasele cu erori (reale) în ordinea: eroare de zero (reala 2), eroare de drift (reala 3), eroare de proporționalitate (reala 4), eroare de liniaritate (reala 5) și valoare fixă (reala 6). Acuratețea generală a diagnosticului a fost de 97,7%, așa cum este ilustrat în Figura 7.9.

Matricea de confuzie pentru diagnosticarea tipurilor de erori ale senzorului NO

Clasă prezisă	1	1919 16.7%	1 0.0%	30 0.3%	5 0.0%	3 0.0%	25 0.2%	96.8% 3.2%
	2	0 0.0%	1881 16.3%	7 0.1%	10 0.1%	4 0.0%	4 0.0%	98.7% 1.3%
	3	1 0.0%	31 0.3%	1873 16.3%	40 0.3%	19 0.2%	1 0.0%	95.3% 4.7%
	4	0 0.0%	0 0.0%	0 0.0%	1862 16.2%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	1 0.0%	10 0.1%	3 0.0%	1832 15.9%	7 0.1%	98.9% 1.1%
	6	0 0.0%	6 0.1%	0 0.0%	0 0.0%	62 0.5%	1883 16.3%	96.5% 3.5%
		99.9% 0.1%	98.0% 2.0%	97.6% 2.4%	97.0% 3.0%	95.4% 4.6%	98.1% 1.9%	97.7% 2.3%
		1	2	3	4	5	6	
		Clasă reală						

Figura 7.9. Matricea de confuzie pentru diagnosticarea tipurilor de erori ale senzorului NO

7.6.4. Diagnosticarea tipurilor de erori ale senzorului NO

Valorile g_i corespunzătoare curbei de funcționare normală, reprezentate cu roșu pe grafic, au identificat funcționarea normală fără erori. Începând cu momentul inițial al perioadei de observație de 24 de ore pentru diagnostic, fiecare dintre punctele g_i ale curbei roșii a arătat cele mai mari valori pe parcursul zilei de testare, indicând funcționarea normală, cu o singură excepție. Aceasta s-a manifestat pentru o valoare la 5,5 ore.

Valoarea rapel a fost în acest caz de 99,9%, iar precizia pe termen lung a fost de 96,8%. O evaluare echilibrată între precizie și rapel a fost oferită de scorul F1 calculat, de 0,983. În această situație, RAR are o valoare scăzută de 0,1%. Reprezentarea grafică a diagnosticului pentru funcționarea normală a senzorului NO este prezentată în Figura 7.10.




Figura 7.10. Diagnosticarea funcționării fără erori a senzorului NO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru funcționarea normală și cele cinci tipuri de erori; detalii privind perioada de timp pentru identificarea sigură

Așa cum este prezentat în Figura 7.11, eroarea de zero a fost diagnosticată cu succes pentru următoarele intervale de timp: 1-1,5 h, 5-5,25 h, 5,75 h, 8,75-13,75 h și apoi de la 17 h până la

sfârșitul zilei. Ultimul interval a fost considerat momentul sigur de identificare. În acest caz, RAR a fost de 2%. Scorul F1 pentru acest scenariu de clasificare a fost 0,983, reflectând o detectare bună a tipului de eroare.




Figura 7.11. Diagnosticarea erorii de zero a senzorului NO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru funcționarea normală și cele cinci tipuri de erori; detalii privind perioada de timp pentru identificarea sigură

Diagnosticarea erorii de drift a fost raportată la punctul de 5,5 ore, apoi între 7,25-8,25 h, 9-9,5 h, 11,75-14,75 h și, în final, de la 18 h până la sfârșitul zilei. După ora 18, curba galbenă devine dominantă în comparație cu celelalte curbe, așa cum se observă în Figura 7.12. Scorul F1 este 0,964, iar RAR are valoarea de 2,4%.




Figura 7.12. Diagnosticarea erorii de drift a senzorului NO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru funcționarea normală și cele cinci tipuri de erori; detalii privind perioada de timp pentru identificarea sigură

Figura 7.13 prezintă diagnosticarea erorii de proporționalitate. Acest tip de defect a fost identificat definitiv după 17,75 ore. Totuși, el a fost de asemenea identificat corespunzător în trei intervale anterioare momentului sigur de identificare, respectiv între 9,75-11 h, 12,25-12,75 h și la momentul de 14,75 h. Aceasta conduce la o precizie pe termen lung de 100%, cu un rapel de 97,0% și un RAR de 3%. Scorul F1 este 0,985, sugerând o capacitate foarte bună de diagnosticare a erorii.




Figura 7.13. Diagnosticarea erorii de proporționalitate a senzorului NO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru funcționarea normală și cele cinci tipuri de erori; detalii privind perioada de timp pentru identificarea sigură

Eroare de liniaritate este diagnosticată corect între 12-13,75 h. În prima zi de apariție a erorii, aceasta a fost temporar identificată greșit fie ca valoare fixă, fie ca eroare de drift. Ocazional, acest defect este diagnosticat eronat ca funcționare normală sau Derivă. Figura 7.14 ilustrează diagnosticarea erorii de tip Pierdere preciziei. Precizia pe termen lung pentru această eroare a fost de 98,9%, iar valoarea rapel a fost de 95,4%. Ambii indici arată o proporție bună de identificări corecte. Scorul F1 a fost 0,971, iar RAR a avut valoarea de 4,6%, reflectând o bună capacitate de identificare a erorii de tip Pierdere preciziei.




Figura 7.14. Diagnosticarea erorii de liniaritate a senzorului NO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru funcționarea normală și cele cinci tipuri de erori; detalii privind perioada de timp pentru identificarea sigură

Așa cum este prezentat în Figura 7.15, eroarea de tip valoare fixă este diagnosticată corect între 2-5,25 h, 10,75-12,75 h, 14,75-15 h și, ulterior, este identificată persistent și corect după momentul de 15,5 h (momentul de identificare sigură). Pentru cazurile în care această eroare a fost diagnosticată greșit, RAR este de 1,9%. Scorul F1 de 0,973 și precizia pe termen lung de 96,5% reflectă o capacitate puternică de identificare corectă a erorii de tip Valoare fixă.




Figura 7.15. Diagnosticarea erorii de tip valoare fixă a senzorului NO: graficele funcțiilor discriminante $g_i(x)$ ale ADF pentru funcționarea normală și cele cinci tipuri de erori; detalii privind perioada de timp pentru identificarea sigură

Trebuie menționat că valorile semnalului senzorului NO, comparabile în scenariile cu erori, conduc la valori foarte apropiate ale variabilei de proces NO. În final, acest lucru a dus la valori similare ale funcției discriminante g_i . Prin urmare, este mai probabil ca unele erori să fie diagnosticate eronat în momentul imediat al apariției lor, precum și în perioadele ulterioare mai lungi sau mai scurte.

7.6.5. Evaluarea performanței în timpul funcționării cu erori ale senzorului NO

Similar investigațiilor privind erorile senzorului DO, indicii de performanță AE, PE și EQ au fost determinați ca valoare medie zilnică pe o perioadă de 28 de zile, atât pentru cazurile de funcționare normală, cât și pentru cele cu erori ale senzorului NO (de la ziua 140 până la ziua 168, ultima fiind exclusă). Valorile AE, PE și EQ pentru funcționarea normală și pentru funcționarea cu cele cinci tipuri de erori sunt prezentate în Tabelul 7.1.

Tabel 7.1. Valorile indicilor de performanță pentru cazurile de funcționare normală și cu erori ale

Regim de operare	AE (kWh/day)	PE (kWh/day)	Cererea totală de energie (kWh/day)	EQ (kg PU/day)
Funcționare normală	16,992	1,329	18,321	16,852
Eroare de zero	17,253	1,633	18,886	15,050
Eroare de drift	17,776	2,320	20,096	14,911
Eroare de proporționalitate	17,496	1,956	19,452	17,108
Eroare de liniaritate	17,752	2,232	19,984	17,186
Valoare fixă	17,848	2,415	20,263	17,198

senzorului NO

Toate erorile influențează negativ indicii AE, PE și cererea totală de energie, conducând la costuri mai mari de energie pentru aerare și pomparea debitului intern de recirculare. Creșterea pompării apare ca urmare a valorii mai scăzute a semnalului senzorului NO, care determină variabila manipulată a controlerului NO să crească debitul intern de recirculare (debitul de nitrați și nitriți). În plus, datorită creșterii variabilei manipulate a debitului de aer a controlerului DO, AE este de asemenea mărit. Erorile de tip Deplasare și Derivă au un efect favorabil asupra valorilor EQ, în timp ce erorile de tip Amplificare incorectă, Pierderea preciziei și Valoare fixă conduc la valori mai mici ale acestui indice de performanță.

7.6.6. Evaluarea costurilor energetice pentru funcționarea afectată de erorile senzorului NO

Costul zilnic pentru fiecare tip de funcționare defectuoasă a stației de tratare analizate în acest studiu a fost calculat similar cu cel determinat pentru investigarea erorilor senzorului DO. Fiecare tip posibil de sursă de energie sau tehnologie de producție a energiei, ce ar putea fi utilizat de AE și PE ale stației de tratare, a avut evaluate costurile zilnice. Tabelul 7.2 oferă un rezumat al acestor evaluări.

Tabel 7.2. Suma costurilor energetice AE și PE, în funcție de sursă, calculată pentru funcționarea normală și pentru funcționarea afectată de erori ale

Sursa/Tehnologie	Costuri zilnice de operare(€)					Valoare fixă
	Funcționare normală	Eroare de zero	Eroare de drift	Eroare de proporționalitate	Eroare de liniaritate	
Lignit	1,812	1,868	1,987	1,924	1,976	2,004
Cărbune	1,717	1,770	1,883	1,823	1,873	1,899
Gaz (CCGT)	1,975	2,036	2,166	2,097	2,154	2,184
Nuclear	3,435	3,541	3,768	3,647	3,747	3,799
Eolian onshore (pe uscat)	1,237	1,275	1,356	1,313	1,349	1,368
Eolian offshore (pe mare)	1,566	1,615	1,718	1,663	1,709	1,732
Fotovoltaic comercial	1,479	1,524	1,622	1,570	1,613	1,635
Fotovoltaic residential	2,327	2,399	2,552	2,471	2,538	2,573
Solar termic (CSP ²)	2,712	2,795	2,974	2,879	2,958	2,999
Hidro cu acumulare (rezervor)	1,457	1,501	1,598	1,547	1,589	1,611
Hidro de tip run-of-river (firul apei)	1,070	1,103	1,174	1,136	1,167	1,183
Geotermal	1,581	1,630	1,734	1,679	1,725	1,749
Biomasă	2,120	2,185	2,325	2,251	2,312	2,344

senzorului NO în linia de apă a stației de tratare

Eroarea de tip valoare fixă a senzorului NO este cea care conduce la cele mai mari costuri energetice, conform analizei costurilor energiei electrice consumate de stația de tratare în timpul funcționării în prezența diferitelor tipuri de erori. Pe de altă parte, eroarea de tip eroare de zero implică cel mai redus cost energetic.

Înainte de înlocuirea senzorului defect, costurile energetice implicite pot fi reduse prin trecerea la surse alternative de energie mai puțin costisitoare și prin implementarea unui plan special pentru utilizarea unei surse mixte de energie în cazul funcționării senzorului defect, în funcție de disponibilitatea soluțiilor tehnice.

7.6.7. Evaluarea impactului asupra mediului pentru emisiile de CO₂ și N₂O în timpul funcționării cu erori ale senzorului NO

Au fost estimate emisiile de CO₂ și N₂O generate pe amplasament și în afara acestuia, care reprezintă surse semnificative de gaze cu efect de seră emise de linia de apă a stației de tratare. Valorile medii zilnice au fost calculate pentru fiecare tip de eroare a senzorului NO în timpul funcționării stației. Rezultatele emisiilor de gaze cu efect de seră sunt prezentate în Tabelul 7.3.

Locul emisiilor	Proces	Tip de gaz emis	Tipul erorii					Valoare fixă
			Normal	Eroarea de zero	Eroare de drift	Eroare de proporționalitate	Eroare de liniaritate	
Emisii din afara amplasamentului	Producerea de energie electrică	CO ₂ , $P_{CO_2,off-site}$ (kg CO ₂ /day)	3,481	3,588	3,818	3,696	3,797	3,850
	Degradare biologică în efluentul stației de tratare	N ₂ O, $P_{N_2O,off-site}$, (kg N ₂ O/day)	3.61	3.65	3.50	3.63	3.51	3.47
Emisii la fața locului	Procese biologice aerobe din linia de apă	CO ₂ , $P_{CO_2,on-site}$ (kg CO ₂ /day)	13,689	13,869	14,175	14,037	14,137	14,207
		N ₂ O, $P_{N_2O,on-site}$ (kg N ₂ O/day)	10.35	10.34	10.40	10.35	10.40	10.42
Total emisii		CO ₂ , $P_{CO_2,total}$ (kg CO ₂ /day)	17,170	17,457	17,993	17,733	17,934	18,057
		N ₂ O, $P_{N_2O,total}$ (kg N ₂ O/day)	13.96	13.99	13.90	13.98	13.91	13.89
Total emisii generale		CO _{2e} , $P_{CO_{2e},overall}$ (kg CO _{2e} /day)	21,330	21,626	21,135	22,899	22,079	22,196

Tabel 7.3. Emisiile de gaze cu efect de seră cauzate de diferitele tipuri de erori ale senzorului NO

Conform valorilor emisiilor de gaze cu efect de seră prezentate în Tabelul 7.3, emisiile generate pe la fața locului sunt cele mai semnificative, reprezentând aproape 80%, respectiv 75% din totalul emisiilor în condiții normale de operare pentru $P_{CO_2, total}$ și $P_{N_2O, total}$. Pentru toate cazurile de erori investigate ale senzorului NO, emisiile totale de CO₂ calculate, adică suma valorilor pe amplasament și în afara acestuia, au prezentat valori mai ridicate. Eroarea de zero și eroarea de proporționalitate au generat niveluri mai mari ale emisiilor totale de N₂O decât celelalte erori, care au prezentat valori ușor mai mici. Este important de menționat că cele mai scăzute valori ale emisiilor de N₂O au fost produse de eroarea de tip valoare fixă, în contrast cu tendința în cazul emisiilor totale de CO₂, unde eroarea de tip eroare de zero a generat cele mai mari emisii.

Pentru a determina emisiile totale de CO₂ s-a utilizat suma emisiilor totale de CO₂ și N₂O. Conform rezultatelor, majoritatea erorilor generează emisii totale de CO₂ mai mari decât în cazul funcționării normale.

Evaluarea emisiilor de CO₂ și N₂O calculate pentru diferitele erori ale senzorului NO, oferă date cantitative utile privind amploarea și ierarhia celor mai problematice tipuri de erori ale senzorilor, care pot avea un impact semnificativ asupra funcționării pe termen lung a stației de tratare.

7.7. Concluzii

Acest studiu a evaluat metodele de detectare a erorilor bazate pe ACP și identificare a erorilor bazate pe ADF pentru senzorul NO care controlează nitriții/nitrații într-un reactor anoxic al stației de tratare. Detectarea prin ACP a fost rapidă și precisă (98,2%), cu metoda SPE în general superioară metodei T², în timp ce ADF a atins o acuratețe de diagnostic de 97,7%, cu timpi inițiali de detectare între 1 și 12 ore și diagnostic consolidat între 5,5 și 18 ore.

Erorile au influențat consumul de energie, calitatea efluentului (EQ) și emisiile de gaze cu efect de seră. Funcționarea normală a consumat 18,321 kWh/zi cu EQ 16,852 kg PU/zi; erorile au crescut consumul de energie cu 10.6-20,263 kWh/zi. Erorile de tip eroarea de zero și eroare de drift au îmbunătățit ușor EQ, dar au crescut consumul de energie, în timp ce eroarea de proporționalitate, eroare de liniaritate și valoare fixă au deteriorat EQ (>17,000 kg PU/zi). Emisiile de gaze cu efect de seră au fost în principal pe amplasament (~75%), cele mai mari creșteri fiind cauzate de erorile de tip Valoare fixă (~5%).

Rezultatele demonstrează că metodele ACP și ADF sunt eficiente pentru gestionarea erorilor senzorului NO, susținând o operare sigură, eficientă și durabilă a stației de tratare. Constatările oferă, de asemenea, îndrumări pentru proiectarea sistemelor de control, managementul energiei, reducerea impactului asupra mediului, întreținere, calibrare și dezvoltarea senzorilor inteligenți.

8. Concluzii finale și contribuții personale

Această cercetare a examinat erorile senzorilor DO și NO într-o stație municipală de tratare, concentrându-se pe detectarea și diagnosticarea timpurie, precum și asupra efectelor asupra calității efluentului, consumului de energie și emisiilor de gaze cu efect de seră. Metodele de detectare a erorilor bazate pe ACP și de identificare a erorilor bazate pe ADF s-au dovedit eficiente pentru diferite tipuri de erori. Erorile au avut un impact semnificativ asupra indicelui EQ și a consumului de energie, cele mai dăunătoare fiind Eroarea completă, Valoare fixă și Pierderea preciziei. Aerarea, ca proces cu consum energetic ridicat, a fost deosebit de afectată, iar toate erorile au crescut consumul total de energie cu până la 10,6%. Emisiile de CO₂ și N₂O au fost de asemenea puternic influențate, anumite erori înrăutățind semnificativ amprenta de mediu a stației. Rezultatele subliniază importanța senzorilor fiabili și a gestionării eficiente a erorilor pentru o operare durabilă și eficientă a stațiilor de tratare.

Cele mai importante concluzii, care rezumă atât rezultatele cantitative, cât și cele calitative obținute în această cercetare, sunt următoarele:

- Rezultatele detectării erorilor:
 - Modelul bazat pe ACP s-a dovedit a fi foarte eficient în detectarea erorilor senzorilor de concentrație DO și NO, atingând o acuratețe generală de 99,6% pentru senzorii DO și 98,2% pentru senzorii NO;
 - Comparând indicii statistici Hotelling T^2 și SPE , metoda SPE a fost mai rapidă în detectarea erorilor, identificându-le de obicei în mai puțin de două ore;
 - Timpul de detectare a erorilor senzorilor DO a variat de la mai puțin de o oră (eroare de zero, Eroare completă) până la 5 ore și 15 minute (eroare de drift);
 - Timpul de detectare a erorilor senzorilor NO a variat de la mai puțin de 1 oră și 15 minute (eroare de zero) până la 19 ore și 15 minute (eroare de drift);
- Rezultatele diagnosticării erorilor:
 - Modelul bazat pe ADF a demonstrat performanțe puternice în diagnosticare, distingând precis între funcționarea defectuoasă și cea fără erori, atingând o acuratețe generală de 85,8% pentru erorile senzorilor DO și 97,7% pentru erorile senzorilor NO;
 - Pentru erorile senzorilor DO, ADF a identificat erorile în intervalul de 2,5 până la 16,5 ore;
 - Pentru erorile senzorilor NO, ADF a identificat erorile în doar 15 minute până la 1 oră, cu momentele de identificare sigură cuprinse între 15 minute și 18 ore;
- Impactul asupra calității efluentului (indicele EQ):
 - Pentru erorile senzorilor DO, cele mai dăunătoare scenarii au fost avarie totală maxim, valoare fixă și eroare de liniaritate, în timp ce eroarea de proporționalitate

a avut un impact minim;

- Pentru erorile senzorilor NO, erorile de tip valoare fixă au avut cel mai grav efect asupra indicelui EQ, în timp ce eroare de drift, eroare de proporționalitate și eroare de liniaritate au cauzat deteriorări în grade diferite;
- Impactul asupra emisiilor de gaze cu efect de seră:
 - Pentru erorile senzorilor DO, scenariile avarie totală maximă și valoare fixă au dus la o creștere de 40 de ori a emisiilor GES comparativ cu funcționarea normală;
 - pentru erorile senzorilor NO, sursele on-site au contribuit cu 75% la emisiile totale de CO₂ și N₂O, iar erorile de tip valoare fixă au avut cel mai sever impact, crescând emisiile cu aproximativ 5%;
- Implicații asupra costurilor energetice:
 - Avaria totală a senzorului DO a dus la cele mai mari costuri energetice din cauza aerării excesive induse;
 - Pentru erorile senzorilor NO, erorile de tip valoare fixă au generat cele mai mari costuri energetice dintre toate tipurile de defecte.

Cercetările viitoare se pot concentra pe îmbunătățirea detectării și identificării defectelor multiple simultane ale senzorilor în stațiile de tratare a apei uzate. Aceasta ar putea implica dezvoltarea unor modele de diagnostic mai avansate pentru creșterea acurateței și fiabilității. Tehnicile de învățare automată, precum deep learning, ar putea automatiza detectarea defectelor și îmbunătăți timpii de reacție.

Monitorizarea în timp real ar putea fi de asemenea optimizată prin strategii de control adaptiv și algoritmi auto-corectivi care ajustează pragurile de detecție pe baza datelor sistemului. Integrarea detectării avansate a defectelor în sistemul SCADA al stației municipale de tratare ar putea eficientiza operațiunile și reduce costurile.

Explorând aceste direcții, cercetările viitoare pot contribui la realizarea unor sisteme de tratare mai eficiente, fiabile și prietenoase cu mediul, asigurând o calitate superioară a apei și un consum redus de energie.

REFERENCES

1. Alex J., Benedetti L., Copp J., Gernaey K.V., Jeppsson U., Nopens I., Pons M.N., Steyer J.P., Vanrolleghem P., Benchmark simulation model no. 1 (BSM1), 2008.
2. Alex J., Tschepetzki R., Jumor U., Obenaus F., Rosenwinkel K.H., Analysis and design of suitable model structures for activated sludge tanks with circulating flow, *Water Science and Technology*, 1999, 39(4), 55-60. DOI: [https://doi.org/10.1016/S0273-1223\(99\)00053-0](https://doi.org/10.1016/S0273-1223(99)00053-0).
3. Beraud B., Lemoine C., Steyer J.P., Computational intelligence techniques for bioprocess modelling, supervision and control, Springer, Berlin, 2009, Chapter Multiobjective Genetic Algorithms for the Optimisation of Wastewater Treatment Processes, pp. 163-195. DOI: https://doi.org/10.1007/978-3-642-01888-6_6.
4. Britschgi L., Villez K., Schrems P., Udert K.M., Electrochemical nitrite sensing for urine nitrification, *Water Research X*, 2020, 9, 100055. DOI: <https://doi.org/10.1016/j.wroa.2020.100055>.
5. Chiang L.H., Russell E.L., Braatz R.D., Fault detection and diagnosis in industrial systems, Springer Science & Business Media, London, 2001. ISBN: 1-85233-327-8.
6. Corona F., Mulas M., Haimi H., Sundell L., Heinonen M., Vahala R., Monitoring nitrate concentrations in the denitrifying post-filtration unit of a municipal wastewater treatment plant, *Journal of Process Control*, 2013, 23(2), 158-70. DOI: <https://doi.org/10.1016/j.jprocont.2012.09.011>.
7. Du Z., Jin X., Multiple faults diagnosis for sensors in air handling unit using Fisher discriminant analysis, *Energy Conversion and Management*, 2008, 49(12), 3654-3665. DOI: <https://doi.org/10.1016/j.enconman.2008.06.032>.
8. Duda R.O., Hart P.E., Stork D.G., Pattern classification, 2nd edition, Wiley, New York, 2000. ISBN: 978-0-471-05669-0.
9. Frank P., Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy: a survey and some new results, *Automatica*, 1990, 26(3), 459-474. DOI: [https://doi.org/10.1016/0005-1098\(90\)90018-D](https://doi.org/10.1016/0005-1098(90)90018-D).
10. Fuente M., Garcia G., Sainz G., Fault diagnosis in a plant using fisher discriminant analysis, in Proceedings of the 16th Mediterranean Conference on Control and Automation Congress Centre, 25th-27th of June 2008, Ajaccio, France, 53-58. DOI: <https://doi.org/10.1109/MED.2008.4602082>.
11. Garcia-Alvarez D., Fault detection using principal component analysis (PCA) in a wastewater treatment plant (WWTP), in Proceedings of the International Student's Scientific Conference, 15th of January 2009, Online Conference, 55-60.
12. Gernaey K.V., van Loosdrecht M.C.M., Henze M., Lind M., Jorgensen S.B., Activated sludge wastewater treatment plant modelling and simulation: state of the art, *Environmental Modelling & Software*, 2004, 19, 763-783. DOI: <https://doi.org/10.1016/j.envsoft.2003.03.005>.
13. Gori R., Jiang L.-M., Sobhani R., Rosso D., Effects of soluble and particulate substrate on the carbon and energy footprint of wastewater treatment processes, *Water Research*, 2011, 45, 5858-5872. DOI:

<https://doi.org/10.1016/j.watres.2011.08.036>.

14. Gujer W., Kappeler J., Modelling population dynamics in activated sludge systems, *Water Science and Technology*, 1992, 25(6), 93-104. DOI: <https://doi.org/10.2166/wst.1992.0116>.
15. Hauduc H., Rieger L., Ohtsuki T., Shaw A., Takacs I., Winkler S., Heduit A., Vanrolleghem P.A., Gillot S., Activated sludge modelling: development and potential use of a practical applications database, *Water Science and Technology*, 2011, 63, 2164-2182, DOI: <https://doi.org/10.2166/wst.2011.368>.
16. He Q., Qin S., Wang J., A new fault diagnosis method using fault directions in fisher discriminant analysis, *AIChE Journal*, 2005, 51(2), 555-571. DOI: <https://doi.org/10.1002/aic.10325>.
17. Henze M., Gujer W., Mino T., Matsuo T., Wentzel M.C., Marais G.V.R., Activated sludge model no. 2, IAWQ Scientific and Technical Report No. 3, IAWQ, London, 1995.
18. Henze M., Gujer W., Mino T., van Loosdrecht M., Activated sludge models ASM1, ASM2, ASM2d and ASM3, IWA Publishing, London, 2000, pp. 1-120. DOI: <https://doi.org/10.2166/9781780402369>.
19. Huang F., Shen W., Calculation of N₂O emissions in the wastewater treatment process of paper mill, in Proceedings of the 2nd International Conference on Sustainable Energy, Environment and Information Engineering (SEEIE 2019), 24th-25th of March 2019, Beijing, China. DOI: <https://doi.org/10.2991/seeie-19.2019.29>.
20. IEA - International Energy Agency, Levelised cost of electricity calculator, <https://www.iea.org/data-and-statistics/data-tools/levelised-cost-of-electricity-calculator>, 2024, accessed on 7th of September 2025.
21. IPCC - Intergovernmental Panel on Climate Change, Guidelines for national greenhouse gas inventories. Intergovernmental panel on climate change, 2006, Table 6.11, 5(6), <http://www.ipcc-nggip.iges.or.jp/public/2006gl/index.html>, accessed on 7th of September 2025.
22. Jeppsson U., Modelling aspects of Wastewater Treatment Processes, PhD thesis, 1996.
23. Kazemi P., Bengoa C., Steyer J.-P., Giralt J., Data-driven techniques for fault detection in anaerobic digestion process, *Process Safety and Environmental Protection*, 2020, 146, 905-915. DOI: <https://doi.org/10.1016/j.psep.2020.12.016>.
24. Kost C., Muller P., Schweiger J.S., Fluri V., Thomsen J., Levelized cost of electricity -Renewable energy technologies, *Fraunhofer ISE Report*, 2024, 1-48.
25. Lazard, Lazard's levelized cost of energy +, <https://www.lazard.com/research-insights/levelized-cost-of-energyplus>, 2024, accessed on 7th of September 2025.
26. Lee C., Choi S.W., Lee, I.B., Sensor fault diagnosis in a wastewater treatment process, *Water Science and Technology*, 2006, 53(1), 251-257. DOI: <https://doi.org/10.2166/wst.2006.027>.
27. Listowski A., Ngo H.H., Guo W.S., Vigneswaran S., Shin H.S., Moon H., Greenhouse gas (GHG) emissions from urban wastewater system: future assessment framework and methodology, *Journal of Water Sustainability*, 2011, 1(1), 113-125.

28. Luca A.-V., Simon-Varhelyi M., Mihaly N.-B., Cristea V.-M., Data driven detection of different dissolved oxygen sensor faults for improving operation of the WWTP control system, *Processes*, 2021, 9(9),1633. DOI: <https://doi.org/10.3390/pr9091633>.
29. Luca A.-V., Simon-Varhelyi M., Mihaly N.-B., Cristea V.-M., Fault detection and diagnosis of the wastewater nitrate and nitrite sensors using PCA and FDA combined with assessment of the economic and environmental impact of the faults, *Environmental Monitoring and Assessment*, 2025, 197, 121. DOI: <https://doi.org/10.1007/s10661-024-13593-z>.
30. Luca A.-V., Simon-Varhelyi M., Mihaly N.-B., Cristea V.-M., Fault type diagnosis of the WWTP dissolved oxygen sensor based on Fisher Discriminant Analysis and assessment of associated environmental and economic impact, *Applied Sciences*, 2023, 13(4), 2554. DOI: <https://doi.org/10.3390/app13042554>.
31. Mannina G., Ekama G., Caniani D., Cosenza A., Esposito E., Gori R., Garrido-Baserba M., Rosso D., Olsson G., Greenhouse gases from wastewater treatment - a review of modelling tools, *Science of The Total Environment*, 2016, 551-552, 254-270, DOI: <https://doi.org/10.1016/j.scitotenv.2016.01.163>.
32. MathWorks, Matlab, <https://www.mathworks.com/products/Matlab.html>, 2025a, accessed on 7th of September 2025.
33. MathWorks, Simulink, <https://www.mathworks.com/products/Simulink.html>, 2025b, accessed on 7th of September 2025.
34. Prendez M., Lara-Gonzalez S., Application of strategies for sanitation management in wastewater treatment plants in order to control/reduce greenhouse gas emissions, *Journal of Environmental Management*, 2008, 88(4), 658-664. DOI: <https://doi.org/10.1016/j.jenvman.2007.03.041>.
35. Qin S.J., Data-driven fault detection and diagnosis for complex industrial processes, in Proceedings of the 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes (IFAC), 30th of June - 3rd of July 2009, Barcelona, Spain, *IFAC Proceedings Volumes*, 42(8), 1115-1125. DOI: <https://doi.org/10.3182/20090630-4-es-2003.00184>.
36. Rieger L., Gillot S., Langergraber G., Ohtsuki T., Shaw A., Takacs I., Winkler, S., Guidelines for using activated sludge models, IWA Publishing, London, 2012, pp. 11-147. DOI: <https://doi.org/10.2166/9781780401164>.
37. Rosen C., Rieger L., Jeppsson U., Vanrolleghem P.A., Adding realism to simulated sensors and actuators, *Water Science and Technology*, 2008, 57(3), 337-44. DOI: <https://doi.org/10.2166/wst.2008.130>.
38. Sanchez-Fernandez A., Fuente M.J., Sainz-Palermo G.I., Fault detection in wastewater treatment plants using distributed PCA methods, in Proceedings of the 20th Conference on Emerging Technologies & Factory Automation (ETFA), 8th-11th of September 2015, Luxembourg, Luxembourg, 1-7. DOI: <https://doi.org/10.1109/ETFA.2015.7301504>.

39. Simon-Varhelyi M., Cristea V.-M., Luca A.-V., Reducing energy costs of the wastewater treatment plant by improved scheduling of the periodic influent load, *Journal of Environmental Management*, 2020a, 262, 110294, 1-10. DOI: <https://doi.org/10.1016/j.jenvman.2020.110294>.
40. Sollfrank U., Gujer W., Characterization of domestic wastewater for mathematical modelling of the activated sludge process, *Water Science and Technology*, 1991, 23, 4-6, 1057-1066.
41. Takacs I., Patryio G.G., Nolasco D., A dynamic model of the clarification-thickening process, *Water Research*, 1991, 25(10), 1263-1271. DOI: [https://doi.org/10.1016/0043-1354\(91\)90066-Y](https://doi.org/10.1016/0043-1354(91)90066-Y).
42. Tao E.P., Shen W.H., Liu T.L., Chen X.Q., Fault diagnosis based on PCA for sensors of laboratorial wastewater treatment process, *Chemometrics and Intelligent Laboratory Systems*, 2013, 128, 49-55. DOI: <https://doi.org/10.1016/j.chemolab.2013.07.012>.
43. Tchobanoglous G., Burton F.I., Stensel H.D., Wastewater engineering - treatment and reuse, Metcalf & Eddy Inc., Boston, 2003. ISBN: 7-302-05857-1.
44. Tchobanoglous G., Stensel H.D., Tsuchihashi R., Burton F.I., Wastewater engineering - treatment and reuse, Metcalf & Eddy Inc., Boston, 2014. ISBN: 0-073-40118-8.
45. Teh H.Y., Kempa-Liehr A.W., Wang K.I.K., Sensor data quality: a systematic review, *Journal of Big Data*, 2020, 7(1), 1-49. DOI: <https://doi.org/10.1186/s40537-020-0285-1>.
46. Tomita R.K., Park S.W., Sotomayor O.A., Analysis of activated sludge process using multivariate statistical tools - a PCA approach, *Chemical Engineering Journal*, 2002, 90(3), 283-290. DOI: [https://doi.org/10.1016/S1385-8947\(02\)00133-X](https://doi.org/10.1016/S1385-8947(02)00133-X).
47. Vallero D.A., Air pollution calculations, Elsevier, Amsterdam, 2019, Chapter Air pollution biogeochemistry, pp. 175-206, ISBN 978-0-12-814934-8.
48. Varhelyi M., Cristea V.-M., Brehar, M., Nemes E.-D., Nair A., WWTP model calibration based on different optimization approaches, *Environmental Engineering and Management Journal*, 2019, 18(8), 1657-1670.
49. Villegas T., Fuente M.J., Sainz-Palmero G.I., Fault diagnosis in a wastewater treatment plant using dynamic independent component analysis, in Proceedings of the 18th Mediterranean Conference on Control and Automation (MED'10), 23rd-25th of June 2010, Marrakech, Morocco, 874-879. DOI: <https://doi.org/10.1109/MED.2010.5547760>.
50. Wanner J., Grau P., Filamentous bulking in nutrient removal activated sludge systems, *Water Science and Technology*, 1988, 20(4-5), 1-8. DOI: <https://doi.org/10.2166/wst.1988.0149>.
51. Wise B.M., Ricker N.L., Veltkamp D.F., Kowalski B.R., Theoretical basis for the use of principal component models for monitoring multivariate processes, *Process Control and Quality*, 1990, 1, 41-51.
52. Yoo C.K., Lee J.M., Lee I.B., Vanrolleghem P.A., Dynamic monitoring system for full-scale wastewater treatment plants, *Water Science and Technology*, 2004, 50, 163-171. DOI: <https://doi.org/10.2166/wst.2004.0684>.
53. Yoon S., MacGregor J., Fault diagnosis with multivariate statistical models part I: using steady state fault signatures, *Journal of Process Control*, 2001, 11(4), 387-400. DOI:

[https://doi.org/10.1016/S0959-1524\(00\)00008-1](https://doi.org/10.1016/S0959-1524(00)00008-1).