

Universitatea „Dunărea de Jos” din Galați
Școala doctorală de Științe Fundamentale și Inginerești



TEZĂ DE DOCTORAT

-Rezumatul tezei de doctorat -

CONTRIBUȚII PRIVIND DIAGNOZA PROCESELOR DE TRATARE A APELOR UZATE UTILIZÂND REȚELE NEURONALE

**Conducător științific,
Prof. Dr. Ing. Sergiu CARAMAN**

**Doctorand,
Ing. Mihaela MIRON**

Seria I8: Ingineria sistemelor Nr. 4

GALAȚI

2018

Universitatea „Dunărea de Jos” din Galați
Școala doctorală de Științe Fundamentale și Inginerești



TEZĂ DE DOCTORAT

-Rezumatul tezei de doctorat -

CONTRIBUȚII PRIVIND DIAGNOZA PROCESELOR DE TRATARE A APELOR UZATE UTILIZÂND REȚELE NEURONALE

**Doctorand,
Ing. Mihaela MIRON**

Președinte:	Prof. dr. ing. Eugen RUSU
Conducător științific,	Prof. dr. ing. Sergiu CARAMAN
Membri:	Prof. dr. ing. Nicolae PARASCHIV
	Prof. dr. ing. Liviu MICLEA
	Prof. dr. ing. Laurențiu FRANGU

Seria I8: Ingineria sistemelor Nr. 4

GALAȚI

2018

Seriile tezelor de doctorat susținute public în UDJG începând cu 1 octombrie 2013 sunt:

Domeniul ȘTIINȚE INGINEREȘTI

Seria I1: Biotehnologii

Seria I2: Calculatoare și tehnologia informației

Seria I3: Inginerie electrică

Seria I4: Inginerie industrială

Seria I5: Ingineria materialelor

Seria I6: Inginerie mecanică

Seria I7: Ingineria produselor alimentare

Seria I8: Ingineria sistemelor

Domeniul ȘTIINȚE ECONOMICE

Seria E1: Economie

Seria E2: Management

Domeniul ȘTIINȚE UMANISTE

Seria U1: Filologie - Engleză

Seria U2: Filologie - Română

Seria U3: Istorie

Seria U4: Filologie - Franceză

Domeniul MATEMATICĂ ȘI ȘTIINȚE ALE NATURII

Seria C: Chimie

Cuprins teză

Introducere

Lista figurilor	1
Lista tabelor	10
1. Stadiul actual în detectia și diagnoza defectelor în procesele biotehnologice	11
1.1 Generalități privind procesele biotehnologice	11
1.2 Importanța detecției și diagnozei defectelor în procesele biotehnologice	12
1.3 Terminologie și definiții în diagnoza defectelor	13
1.4 Tipuri de defecte	14
1.5 Metode de detecție a defectelor	16
1.5.1 Criterii de evaluare a eficacității algoritmilor de detecție	16
1.5.2 Metode de detecție a defectelor care nu utilizează modele matematice	16
1.5.3 Metode de detecție a defectelor bazate pe modele matematice	16
1.6 Schema de generare și evaluare a reziduurilor	18
1.7 Detecția defectelor prin estimarea parametrilor	19
1.8 Detecția defectelor prin ecuații de paritate	20
1.9 Detecția defectelor pe baza observerelor de stare	22
1.10 Detecția defectelor cu rețele neuronale	23
1.11 Metode de izolare a defectelor	24
1.12 Izolarea defectelor prin metode de clasificare	24
1.13 Izolarea defectelor prin metode de raționament	26
1.13.1 Logica fuzzy	27
1.13.2 Sisteme expert	28
1.14 Izolarea defectelor cu metode de soft – computing	29
1.14.1 Rețele neuronale artificiale	29
1.14.2 Tehnici neuro – fuzzy	30
1.14.3 Algoritmi genetici	31
1.15 Aplicații privind diagnoza defectelor în stațiile de epurare a apelor uzate	32
1.16 Concluzii	42

2.	Modelarea proceselor biotehnologice cu rețele neuronale	43
2.1	Aspecte generale privind rețelele neuronale	43
2.1.1	Funcții de activare a rețelelor neuronale	44
2.1.2	Arhitectura rețelelor neuronale	46
2.2	Antrenarea rețelelor neuronale	51
2.3	Studiu de caz: Modelarea cu rețele neuronale a procesului de tratare a apelor uzate	54
2.3.1	Prezentarea procesului de tratare a apelor uzate	54
2.3.2	Defect apărut în cursul unui experiment realizat pe stația de epurare pilot din cadrul Universității “Dunărea de Jos” din Galați	58
2.3.3	Modelul matematic al procesului de tratare biologică a apelor uzate	60
2.3.4	Modelarea cu rețele neuronale a procesului de tratare biologică a apelor uzate	62
2.3.5	Rezultatele antrenării rețelei neuronale	65
2.3.4	Rezultatele validării rețelei neuronale	68
2.4	Concluzii	71
3.	Contribuții privind detecția defectelor în procesele biotehnologice	72
3.1	Probleme curente în detecția defectelor	72
3.2	Detecția defectelor cu rețele neuronale aplicată la o stație de epurare a apelor uzate	73
3.2.1	Stabilirea condițiilor de alegere a parametrilor algoritmului de detecție a defectelor	73
3.2.2	Schema de detecție a defectelor cu rețea neuronală	86
3.2.3	Validarea metodei de detecție a defectelor cu rețea neuronală prin simulări numerice	89
3.3	Detecția defectelor cu filtrul Kalman extins aplicată la o stație de epurare a apelor uzate	107
3.3.1	Algoritmul de detecție cu filtrul Kalman extins	108
3.3.2	Implementarea filtrului Kalman extins pentru procesul de tratare a apelor uzate	108
3.3.3	Schema de detecție a defectelor cu filtrul Kalman extins	110
3.3.4	Recomandări privind alegerea parametrilor metodei de detecție	111
3.3.5	Validarea metodei de detecție cu filtrul Kalman extins prin simulări numerice	112
3.4	Concluzii	124
4.	Izolarea defectelor folosind rețele neuronale	126
4.1	Probleme curente în izolarea defectelor	126
4.2	Metoda de recunoaștere a defectelor cu rețele neuronale într-o stație de epurare a apelor uzate	126

4.2.1	Schema de diagnoză a defectelor	127
4.2.2	Proiectarea rețelei neuronale de recunoaștere a defectelor	127
4.2.3	Rezultatele instruirii, testării și validării rețelei neuronale	130
4.3	Concluzii	140
5	Concluzii	141
	Contribuții originale ale tezei de doctorat	142
	Direcții viitoare de cercetare	143
	Diseminarea rezultatelor	143
	Anexa 1	144
	Bibliografie	170

Cuprins rezumat

Introducere

1. Stadiul actual în detectia și diagnoza defectelor în procesele biotehnologice	1
1.1 Generalități privind procesele biotehnologice	1
1.2 Importanța detecției și diagnozei defectelor în procesele biotehnologice	2
2. Modelarea proceselor biotehnologice cu rețele neuronale	4
2.1 Aspecte generale privind rețelele neuronale	4
2.3 Studiu de caz: Modelarea cu rețele neuronale a procesului de tratare a apelor uzate	5
2.3.2 Defect apărut în cursul unui experiment realizat pe stația de epurare pilot din cadrul Universității “Dunărea de Jos” din Galați	5
2.3.3 Modelul matematic al procesului de tratare biologică a apelor uzate	7
2.3.4 Modelarea cu rețele neuronale a procesului de tratare biologică a apelor uzate	8
2.3.5 Rezultatele antrenării rețelei neuronale	9
2.3.4 Rezultatele validării rețelei neuronale	11
3. Contribuții privind detecția defectelor în procesele biotehnologice	14
3.1 Probleme curente în detecția defectelor	14
3.2 Detecția defectelor cu rețele neuronale aplicată la o stație de epurare a apelor uzate	14
3.2.1 Stabilirea condițiilor de alegere a parametrilor algoritmului de detecție a defectelor	14
3.2.2 Schema de detecție a defectelor cu rețea neuronală	15
3.2.3 Validarea metodei de detecție a defectelor cu rețea neuronală prin simulări numerice	16
3.3 Detecția defectelor cu filtrul Kalman extins aplicată la o stație de epurare a apelor uzate	22
3.3.3 Schema de detecție a defectelor cu filtrul Kalman extins	22
3.3.5 Validarea metodei de detecție cu filtrul Kalman extins prin simulări numerice	23
4. Izolarea defectelor folosind rețele neuronale	28
4.1 Probleme curente în izolarea defectelor	28
4.2 Metoda de recunoaștere a defectelor cu rețele neuronale într-o stație de epurare a apelor uzate	28

4.2.1	Schema de diagnoză a defectelor	28
4.2.2	Proiectarea rețelei neuronale de recunoaștere a defectelor	29
4.2.3	Rezultatele instruirii, testării și validării rețelei neuronale	30
5	Concluzii	34
	Contribuții originale ale tezei de doctorat	35
	Direcții viitoare de cercetare	36
	Diseminarea rezultatelor	36
	Bibliografie	37

Introducere

În ultimul secol, creșterea populației și dezvoltarea societății moderne pe diferite segmente reprezintă principala cauză a contaminării mediului înconjurător și a surselor de apă. Având în vedere că rezervele de apă curată sunt reduse, este important să se adopte măsuri de protecție și prevenire a poluării surselor de apă și deteriorării mediului înconjurător care asigură condițiile de trai și dezvoltare pentru toate formele de viață. În zilele de astăzi, există o conștientizare sporită a importanței privind prevenirea poluării și minimizarea deșeurilor în activitățile industriale, urbane și agricole, precum și a procesului de reciclare. Un rol important în confruntarea cu aceste provocări contemporane majore, o are biotehnologia care este într-o continuă dezvoltare, și în prezent, cea mai bună tehnologie disponibilă pentru a asigura durabilitatea și protecția mediului înconjurător. Tehnologiile din domeniul biotehnologiei sunt multiple, dar unele din cele mai des întâlnite sunt procesele de tratare a apelor uzate provenite din procesele industriale, gospodăriile oamenilor etc.

Stațiile de tratare a apelor uzate sunt instalații proiectate pentru a reduce cantitățile de materie organică și materii solide în suspensie din apă, prin tratamente adecvate pentru a purifica apa înainte de a fi deversată în orice emisar (mare, râu, lac etc.). Aceste procese sunt în mod inerent dinamice datorită variațiilor mari ale debitului de admisie a apei reziduale, concentrației și compoziției acesteia. Din acest motiv, modelele matematice și simulările pe calculator sunt esențiale pentru a modela, prezice și controla aceste procese complexe. Funcționarea proceselor de tratare a apelor reziduale este foarte complexă. În unele instalații performanțele slabe, costurile ridicate și deteriorarea mediului s-au datorat unor probleme operaționale. Îmbunătățirea performanței stațiilor de tratare a apelor reziduale depinde, în principal, și de modulul de detectare, izolare și identificare a defecțiunilor (FDI Fault Detection and Isolation), pentru a crește siguranța și fiabilitatea echipamentelor. Prin urmare, au fost propuse mai multe abordări privind diagnoza în stațiile de epurare: abordări bazate pe cunoaștere euristică, cum ar fi inteligența artificială (rețelele neuronale), analiza statistică și abordări bazate pe modele matematice.

În cercetarea realizată în cadrul prezentei teze de doctorat s-au avut în vedere următoarele direcții de cercetare: primul obiectiv a constat în modelarea proceselor biotehnologice, în particular, a stațiilor de tratare a apelor uzate folosind tehnici de inteligență artificială, și anume, rețele neuronale. Se urmărește implementarea unui model neuronal care realizează predicția ieșirilor unei stații de tratare a apelor uzate în care se face îndepărtarea pe cale biologică a substratului organic. Avantajul rețelei neuronale, folosită ca model al sistemului, este că învață direct din datele experimentale, fără să fie necesar un model analitic. În general, pentru antrenarea rețelei este necesar să se utilizeze un set de date foarte mare și reprezentativ, pentru domeniile de funcționare în care va fi folosit modelul. Rețeaua care realizează predicția ieșirilor va putea fi folosită pentru scopuri de reglare sau diagnoză a sistemului biotehnologic.

A doua direcție de cercetare vizează diagnoza defectelor în procesele biotehnologice. Având în vedere că diagnoza presupune două etape, și anume, detecția și apoi izolarea defectelor, se dorește implementarea unor tehnici de detecție și recunoaștere a defectelor folosind rețele neuronale într-un proces de epurare a apelor uzate cu nămol activ. În cazul detecției se vor analiza două situații: 1. mărimile de ieșire ale procesului sunt considerate măsurabile și 2. unele dintre mărimile de ieșire ale procesului sunt nemăsurabile direct, prin senzori dedicați. În cazul în care unele mărimi de ieșire ale procesului sunt nemăsurabile, se pot folosi estimatori de stare și parametri, și anume, observare de stare și parametri, însă principalul dezavantaj al acestei metode constă în determinarea unui model matematic cât mai precis al procesului. Pentru recunoașterea defectelor se urmărește proiectarea unei rețele neuronale cu rol de clasificator. Performanțele algoritmului de detecție, cât și cele ale metodei de recunoaștere vor fi testate în cazul apariției de defecte nete și defecte parțiale ale elementelor de execuție sau ale traductoarelor specifice proceselor de tratare a apelor uzate.

Structura tezei de doctorat cuprinde: o introducere, patru capitole și concluzii. În **introducere** sunt prezentate principalele direcții de cercetare propuse și motivația care a stat la baza abordării temei de studiu din această lucrare de doctorat.

În **capitolul 1** se prezintă un overview care se constituie într-un stadiu actual în ceea ce privește detecția și diagnoza defectelor în cazul proceselor de tratare a apelor reziduale. Sunt prezentate argumente privind importanța diagnozei defectelor, sunt analizate principalele tipuri de defecte, diverse metode de detecție a defectelor precum și o serie de tehnici de izolare a acestora. De asemenea, sunt menționate și analizate câteva rezultate recente din domeniul detecției și izolării defectelor în procesele biotehnologice, cu aplicații, în special, pe stațiile de epurare a apelor uzate.

În **capitolul 2** sunt menționate câteva aspecte generale privind rețelele neuronale (arhitecturi, funcții de activare, reguli de învățare etc.) evidențind domeniul lor de aplicabilitate. Sunt prezentate, de asemenea, principalele caracteristici de funcționare a sistemelor biotehnologice, și anume, ale stațiilor de tratare a apelor uzate cu nămol activ. Este prezentată stația de epurare din laboratorul de bioprocese din Universitatea "Dunărea de Jos" din Galați, împreună cu echipamentele de monitorizare și control aferente. Este descris în detaliu un defect real, apărut în cadrul unui experiment realizat pe stația de epurare menționată, în care s-a defectat traductorul de debit de aer, împreună cu simptomele observate. În ultima parte, accentul cade pe contribuții care constau în modelarea cu rețele neuronale a unei instalații de tratare a apelor uzate în care se face îndepărtarea pe cale biologică a substratului organic. Rezultatele simulării și validării modelului neuronal arată că procesul biotehnologic poate fi modelat, cu succes, printr-o rețea neuronală feedforward. Eroarea de modelare obținută este mai mult decât acceptabilă pentru domeniul uzual de operare a procesului.

În **capitolul 3** sunt prezentate contribuții privind detecția defectelor în stațiile de tratare a apelor uzate. Se propun două metode de detecție a defectelor bazate pe model pentru un proces de epurare a apelor uzate cu nămol activ. În prima situație, când ieșirile procesului sunt considerate măsurabile, se realizează detecția cu ajutorul modelului neuronal al procesului analizat, determinat în capitolul 2. În cea de-a doua situație, când unele mărimi de ieșire ale procesului sunt nemăsurabile, se propune o metodă de detecție bazată pe modelul analitic al procesului folosind un filtrul Kalman extins. Condițiile de care se ține cont în proiectarea ambelor metode sunt: viteza de reacție a semnalului de alarmare în prezența defectului, sensibilitatea la defect (detecția defectelor parțiale care au efecte reduse asupra procesului), robustețea (funcționarea în prezența zgomotului, perturbațiilor exterioare și a erorilor de modelare) și numărul redus de alarme false. În ambele situații, se testează performanța metodelor prin simularea de defecte nete și parțiale a elementelor de execuție și a traductoarelor întâlnite în stațiile de tratare a apelor uzate. O contribuție importantă, în acest capitol, este investigarea a două metode privind alegerea principalilor parametri ai metodei de detecție a defectelor (pragul de sensibilitate, ϵ , și orizontul de calcul al reziduurilor, N). Prima metodă constă într-o analiză teoretică în care se consideră trei ipoteze, după cum urmează: Ip. 1 nu există erori de modelare ($er(k)=0$, adică modelul reproduce fidel evoluția procesului supravegheat), dacă există defect, se presupune că devierea produsă de acesta a ajuns în regim staționar în timp foarte scurt (câteva perioade de eșantionare), decizia trebuie luată rapid, numai pe baza eșantionului curent, deci $N=1$, ceea ce este echivalent cu a spune că reziduul a fost calculat doar pentru eșantionul curent; Ip. 2 nu există erori de modelare (adică modelul reproduce fidel evoluția procesului supravegheat), devierea produsă de defect evoluează lent, cu timp de creștere cunoscut și decizia se poate lua pe baza mai multor eșantioane succesive, adică reziduul se calculează pe orizontul de timp $N>1$; Ip. 3 există eroare de modelare, cu densitate de probabilitate cunoscută, devierea produsă de defect evoluează lent, cu timp de creștere cunoscut, eroarea de modelare variază mai lent decât devierea produsă de defect și decizia se poate lua pe baza mai multor eșantioane succesive ($N>1$). Cea de a doua metodă constă în determinarea euristică a parametrilor ϵ și N . S-a concluzionat că analiza teoretică privind

modalitățile de alegere a celor doi parametri ai metodei de detecție este confirmată de rezultatele obținute prin tehnici euristice, din secțiunea 3.2.

În **capitolul 4** este proiectată o rețea neuronală de clasificare astfel încât să poată fi recunoscute defecte nete și defecte parțiale care pot apărea într-un proces de tratare a apelor uzate. Setul de date experimental este suficient de mare și conține date reprezentative pentru toate cazurile de defecte analizate. În urma antrenării, validării și testării rețelei neuronale se constată că se obțin rezultate bune ale ratelor de recunoaștere pentru toate tipurile de defecte analizate.

În ultimul capitol, numit **concluzii finale**, sunt menționate contribuțiile originale ale tezei și sunt stabilite următoarele direcții de cercetare.

Capitolul 1

Stadiul actual în detecția și diagnoza defectelor în procesele biotehnologice

1.1 Generalități privind procesele biotehnologice

Biotehnologia este știința care studiază procesele “vii” care conțin microorganisme, celule sau componente celulare cu scopul de a dezvolta noi tehnologii și produse pentru a îmbunătăți semnificativ viața oamenilor și a contribui semnificativ la protecția mediului înconjurător. Legat de protecția mediului, procesele de tratare a apelor reziduale, care sunt în esență procese biotehnologice, dispun de tehnologii inovatoare cu ajutorul cărora se reduce consumul de energie și cantitatea de reziduuri din apele uzate, se protejează și regenerează mediul înconjurător, iar procesele industriale devin mai “curate” și mai eficiente.

În ceea ce privește procesele de tratare a apelor uzate, acestea au rolul de a elimina sau reduce cantitatea de reziduuri de natură chimică sau organică din apele uzate. Epurarea apelor uzate se poate realiza prin mai multe tipuri de tratament: mecanic, biologic și chimic. Numeroși cercetători se axează pe dezvoltarea de tehnologii noi de tratare a apelor uzate, precum și de a crește eficiența, siguranța și mentenabilitatea celor existente prin tehnici de detecție și diagnoză, aplicate în special în treapta biologică. Astfel, în zilele noastre, detecția și diagnoza defectelor în stațiile de epurare a apelor uzate a devenit o provocare datorită complexității acestor sisteme. Celulele, care alcătuiesc populații de microorganisme vii, se dezvoltă imprevizibil, pot suferi mutații care pot afecta dezvoltarea lor și, în special, dinamicile de creștere, transport și propagare care sunt greu de înțeles, neliniare și variabile în timp. Nu în ultimul rând, aceste procese sunt afectate de zgomote de măsură și de proces, precum și de incertitudini parametrice și de model care creează dificultăți majore în modelarea matematică și controlul acestora, incluzând și problematica diagnozei. Lipsa unor senzori dedicați care pot să ofere informații precise în timp real, fiabilitatea scăzută a celor existenți și, în special, costurile prohibitive pentru utilizarea lor în aplicații industriale contribuie la dificultățile menționate anterior în tratarea sistemică a acestui tip de procese. În general, măsurătorile în bioprocese se fac prin analize de laborator, realizate off-line, ceea ce creează un handicap major în implementarea legilor de control automat. Astfel, problemele privind măsurarea on-line a concentrațiilor variabilelor de interes din bioprocese s-a încercat a fi surmontate prin proiectarea și utilizarea de observere de stare și parametri, care constituie o alternativă viabilă pentru măsurarea principalelor variabile din bioprocese. Principalul dezavantaj al acestei metode constă în determinarea unui model matematic cât mai precis al procesului.

Literatura de specialitate recomandă o serie de modele ale proceselor de tratare a apelor uzate. Cele mai cunoscute sunt modelele matematice elaborate de o echipă condusă de profesorul Henze în cadrul IWA (Asociația Internațională a Apelor). Astfel se poate menționa modelul ASM1 („Activated Sludge Model 1”) [1] creat pentru îndepărtarea reziduurilor care conțin carbon organic și azot. Un al doilea model matematic elaborat în cadrul IWA este ASM2, care realizează suplimentar și îndepărtarea fosforului [2]. În ASM2, partea nerezolvată a fost denitrificarea PAO (organisme care acumulează fosfor). Acest lucru a dus la necesitatea extinderii modelului ASM2 la versiunea ASM2d. Modelul este o extensie a celor două modele ASM2 și ASM1, și folosește conceptele incluse în aceste modele matematice. ASM2d include două procese suplimentare care iau în considerare faptul că organismele care acumulează fosfor pot utiliza produse biologice stocate în interiorul celulelor pentru denitrificare. Așa cum ASM2 implică faptul că PAO va crește doar în condiții aerobe, ASM2d include, de asemenea, și denitrificarea PAO [3]. ASM2d constituie un model îmbunătățit al proceselor de tratare a apelor uzate, în special în ceea ce privește dinamica concentrațiilor de nitrat și fosfat. Modelul ASM3 poate estima consumul de oxigen, producția de nămol, nitrificarea și denitrificarea sistemelor de nămol activ.

În continuare, în acest capitol se prezintă un overview care se constituie într-un stadiu actual în ceea ce privește detecția și diagnoza defectelor în cazul proceselor de tratare a apelor reziduale. Sunt prezentate argumente privind importanța diagnozei defectelor, sunt analizate principalele tipuri de defecte, diverse metode de detecție a defectelor precum și o serie de tehnici de izolare a acestora. În ultima parte sunt menționate câteva rezultate recente din domeniul detecției și izolării defectelor în procesele biotehnologice, cu aplicație, în special, pe stațiile de epurare a apelor uzate. Ultima secțiune este rezervată concluziilor.

1.2 Importanța detecției și diagnozei defectelor în procesele biotehnologice

Diagnoza defectelor este o problemă importantă în controlul proceselor biotehnologice și continuă să fie un domeniu activ de cercetare în automatica modernă.

În cazul bioprocесelor, tehnicile de diagnoză a defectelor pot fi folosite pentru a îmbunătăți eficiența, mentenanța și fiabilitatea acestor procese. Sesizarea timpurie a apariției unui defect poate să ajute la evitarea colapsului unui întreg sistem sau eventuale catastrofe prin măsuri de corecție, în funcție de severitatea sursei care a produs defectul. Etapele urmărite în cazul diagnozei defectelor sunt: 1. determinarea prezenței unui defect și 2. determinarea tipului și mărimii defectului [4]. Aceste etape se aplică în funcție de instalație, echipamente și tehnologiile folosite.

Conform comitetului tehnic IFAC SAFE – PROCESS [5] și [6], un defect este o deviație nepermisă a cel puțin unei proprietăți caracteristice sau a unui parametru al sistemului de la condițiile normale, acceptabile, uzuale ale sistemului. Defecțiunile pot să apară în anumite subsisteme, de exemplu senzori și elemente de execuție.

În general, metodele de diagnoză folosesc conceptul de redundanță, care poate fi de două tipuri [7] (Fig. 1.1): redundanța hardware și redundanța software.

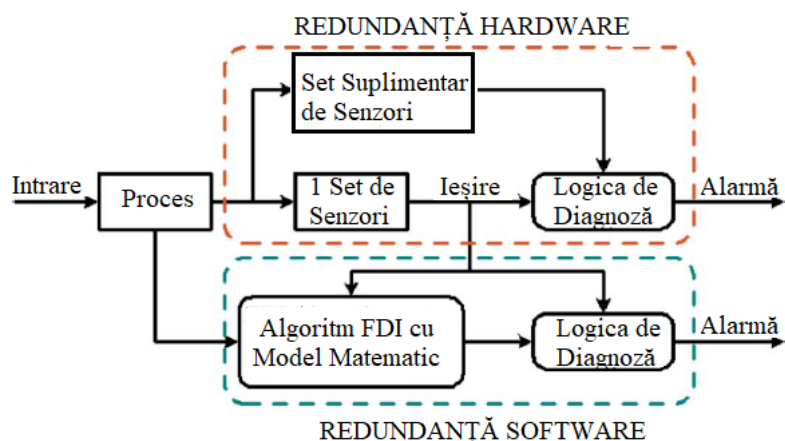


Fig. 1.1 - Redundanța hardware și redundanța software (analitică) aplicate pentru detectarea și izolarea defectelor [7] (Fault Detection and Isolation - FDI)

Redundanța hardware se referă la posibilitatea de a compara semnale duplicate, generate de diverse surse hardware, cum ar fi rezultatul măsurătorilor aceluiași semnă obținut de la doi sau mai mulți senzori. Tehnicile folosite în cazul acestei abordări sunt: metode de procesare a semnalelor (de ex. transformata Wavelet), testarea limitelor (măsuratori comparate cu diverse praguri care indică prezența unei anomalii), folosirea unor senzori speciali (de limitare, proiectați pentru a măsura numai anumiți parametri), senzori amplasați în paralel pentru măsurarea aceluiași parametru sau utilizarea sistemelor expert (pe baza unor reguli de tipul "DACĂ ... ATUNCI" pentru sesizarea unei anomalii) etc.

Redundanța software (analitică) folosește un model matematic al sistemului împreună cu alte tehnici de estimare [8], [9]. În general această abordare, nu necesită resurse hardware suplimentare și este, de obicei, mai eficientă din punct de vedere al costului în comparație cu redundanța hardware. Pe de altă parte, redundanța analitică este mai dificilă de implementat, deoarece trebuie să asigure un anumit grad de robustețe în prezența zgomotului, perturbațiilor sau erorilor de aproximare introduse de modelul matematic. Dacă nu se iau în considerare aceste condiții, se pot semnala alarme false în prezența variațiilor mărimilor de intrare sau a zgomotului. Comparând valorile estimate ale modelului analitic cu cele ale măsurătorilor obținute de la senzori, se pot detecta și izola defectele care apar în proces. Scopul este de a observa diferența dintre model și sistemul real defectat. Diferența dintre ieșirea reală măsurată a procesului și ieșirea estimată a modelului analitic se numește reziduu. Valoarea reziduuului se compară cu un prag care poate fi fix sau variabil (de ex. prag adaptiv) în urma căruia se stabilește dacă în proces a intervenit sau nu un defect.

În Fig. 1.2 se observă că redundanța analitică se împarte, la rândul ei, în metode de diagnoză care folosesc modele cantitative și calitative [4], [10] și [11]. Toate aceste metode de diagnoză folosesc estimatori de parametri, observare de stare, tehnici de inteligență artificială (rețele neuronale, algoritmi evolutivi etc.), metode hibride (modele neuro-fuzzy), ecuații de paritate sau clasificatori statistici pentru a detecta și izola discrepanțele dintre comportamentul observat al procesului și cel predictat de model. În plus, metodele de diagnoză care se bazează pe modele calitative (logica fuzzy, grafuri, arbori, metode de căutare, sisteme expert) folosesc relații de calitate între intrările și ieșirile procesului. Aceste relații oferă informații declarative privind starea parametrilor din proces (în general tendințele de variație a valorilor parametrilor). Motivația utilizării acestor modele calitative, este întărită de faptul că nu toate procesele și defectele pot fi descrise prin modele analitice, iar cunoștințele pot fi ușor încorporate în schemele de diagnoză [13], [14] și [15].

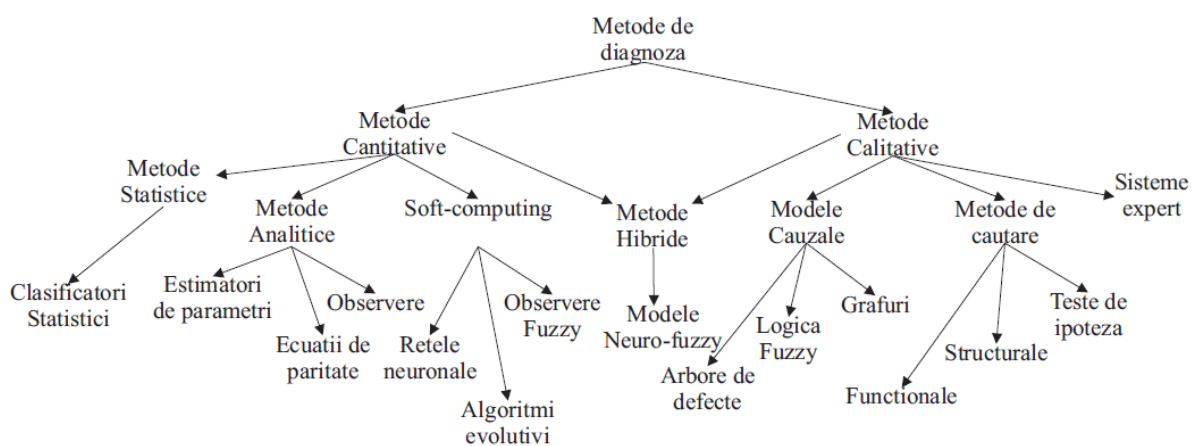


Fig. 1.2 - Metode de diagnoză bazate pe model [12]

Capitolul 2

Modelarea proceselor biotehnologice cu rețele neuronale

Procesele biotehnologice sunt sisteme complexe, puternic neliniare și influențate de incertitudini parametrice și de model (dinamici ascunse – nemodelate). Aceste procese conțin microorganisme vii care pot suferi mutații afectând, în special, dinamicile de creștere, transport și propagare care sunt greu de înțeles, neliniare și variabile în timp. Sunt puțini senzori care pot să ofere informații precise, în timp real, despre dezvoltarea unei culturi de celule. În general, concentrațiile variabilelor biologice pot fi determinate doar prin analize de laborator, realizate off-line, ceea ce creează un handicap major în modelarea matematică a acestor procese, implementarea unor legi de control sau a unor tehnici de diagnoză. În acest sens, este important să fie disponibil un model cât mai precis care să aproximeze cât mai bine comportamentul procesului biotehnologic și cu ajutorul căruia să fie generate seturile de reziduuri, evaluate ulterior pentru diagnoza defectelor. În categoria bioproceselor se încadrează și procesele de tratare a apelor uzate, care vor face subiectul dezvoltării în această lucrare de doctorat a unor metode de diagnoză.

Rețele neuronale (RNA) sunt tehnici de inteligență artificială care oferă modele de predicție eficiente pentru procese complexe și, de asemenea, pot fi aplicate în situații în care nu sunt disponibile cunoștințe suficiente despre proces. Avantajele rețelelor neuronale constau în faptul că:

- nu este necesară descrierea matematică a fenomenelor implicate în proces;
- este necesar mai puțin timp pentru construirea modelelor față de modelele matematice tradiționale;
- au o capacitatea de predicție foarte bună, cu un număr limitat de experimente [107] – [110].

S-a demonstrat, prin diverse aplicații, că rețele neuronale aproximează foarte bine dacă setul de date de antrenare conține exemple suficiente și numărul de neuroni din stratul ascuns este suficient. De asemenea, trebuie precizat faptul că modelele neuronale cu arhitectură feedforward sunt cel mai des utilizate în studiile recente privind modelarea proceselor biotehnologice [111], [112] și [113].

2.1 Aspecte generale privind rețele neuronale

De-a lungul timpului s-au înregistrat numeroase progrese în direcția dezvoltării sistemelor inteligente folosind rețele neuronale. Rețelele neuronale au fost studiate de către cercetători pentru a rezolva probleme din diverse domenii științifice cum ar fi: recunoașterea formelor, predicție, optimizare, memorare asociativă, control etc. Deși în literatura de specialitate se întâlnesc diverși algoritmi care utilizează rețele neuronale, aceștia nu sunt destul de flexibili pentru a putea funcționa în afara domeniului de aplicabilitate.

Rețelele neuronale artificiale sunt inspirate din modelul neuronilor biologici. Caracteristicile pe care încearcă să le imite rețele neuronale artificiale sunt:

- paralelismul;
- calculul și reprezentarea distribuită;
- capacitatea de învățare;
- îmbunătățirea performanțelor;
- abilitatea de a generaliza;
- adaptabilitatea;
- posibilitatea de a prelucra informații și a lua decizii;

- toleranța la erori.

O rețea neuronală artificială este o structură de procesare a informației, formată dintr-un număr de noduri (neuroni) interconectați prin legături. Fiecare legătură este caracterizată de o pondere numerică. Prin pondere se reține informația învățată de rețea iar prin ajustarea valorii ponderilor se instruieste rețeaua neuronală.

Caracteristicile principale ale unei rețele neuronale sunt:

- funcționarea (modul de calcul al ieșirii în funcție de intrare);
- arhitectura (modul de interconectare al neuronilor);
- antrenarea (determinarea parametrilor rețelei neuronale).

2.3. Studiu de caz: Modelarea cu rețele neuronale a procesului de tratare a apelor uzate

Demersul științific din această teză de doctorat constă în dezvoltarea unor metode de diagnoză a proceselor de tratare a apelor reziduale. În acest scop, s-a pornit de la un model matematic al unei stații de tratare pilot proiectată în universitatea noastră, în cadrul proiectului CEEX – MENER, Nr. 717/25.07.2006, *Îmbunătățirea indicatorilor calitativi la tratarea biologică a apelor reziduale din industria alimentară pe baza unor sisteme de conducere avansată* – acronim APEPUR [128], prezentată în Fig 2.22. Modelul matematic este cunoscut în literatura de specialitate sub numele de modelul Nejjari. Stația de tratare pilot a fost dimensionată pentru un debit de influent de 1 litru/h și a fost proiectată astfel încât rezultatele obținute în cadrul proiectului să poată fi extrapolate la o stație de dimensiuni mari. În faza de tratare aerobă a apei uzate, bioreactorul a fost proiectat pentru a putea prelua încărcări în CBO_5 de până la 1700 mg/l, la raporturi ale $CCO/CBO_5 \leq 2.2$ și raporturi $CBO_5:N:P$ de 100:5:1, acești parametri fiind asociați cu apele puternic încărcate în substanțe organice provenite, în cea mai mare parte, din industria alimentară.

2.3.2 Defect apărut în cursul unui experiment realizat pe stația de epurare pilot din cadrul Universității “Dunărea de Jos” din Galați

În continuare, se prezintă un defect real apărut în cursul experimentelor realizate cu stația de tratare pilot din Universitatea “Dunărea de Jos” din Galați. Experimentul s-a desfășurat pe durata a mai multor zile, o parte dintre rezultatele relevante pentru demersul din prezenta teză de doctorat fiind arătate în Fig. 2.24 – 2.26. Astfel, în Fig. 2.24 este trasată evoluția debitului de aer, în Fig. 2.25 – concentrația de oxigen dizolvat, iar în Fig. 2.26 – turbiditatea, mărime prin intermediul căreia se măsoară concentrația de biomasă. În figurile menționate se poate observa că procesul de epurare a avut o evoluție normală până la eșantionul 15700, după care debitul de aer măsurat cade în zero, concentrația de oxigen dizolvat crește excesiv iar după 750 – 800 de eșantioane are loc și o scădere substanțială a concentrației de biomasă. Explicația este următoarea: la momentul precizat, traductorul de debit de aer nu a mai furnizat valoarea măsurată (practic acesta s-a defectat). Regulatorul de O_2 dizolvat a comandat deschiderea valvei de aer la maxim ceea ce a avut ca efect creșterea puternică a concentrației de oxigen dizolvat și, mai târziu, o scădere a concentrației de nămol. În final, s-a dovedit că, la originea defectului, a fost defectarea sursei de alimentare a traductorului de debit de aer. După înlocuirea acesteia, procesul a revenit la o evoluție normală.

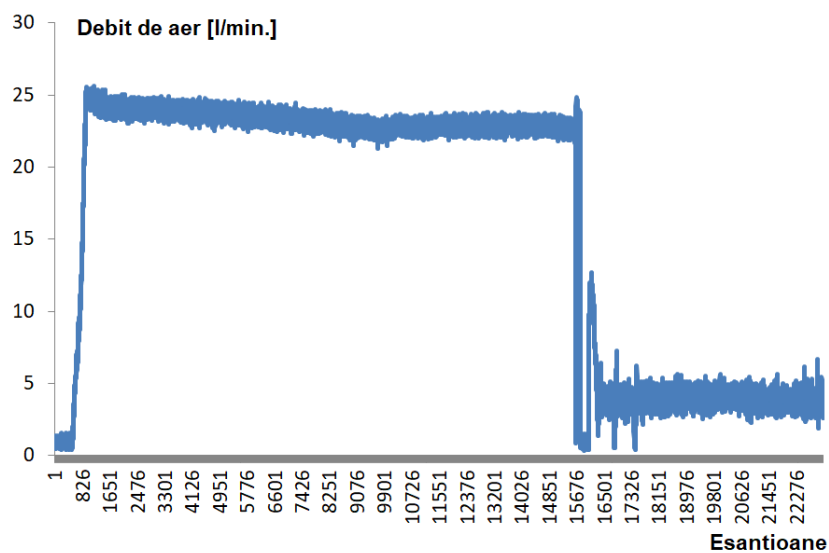


Fig. 2.24 – Evoluția debitului de aer

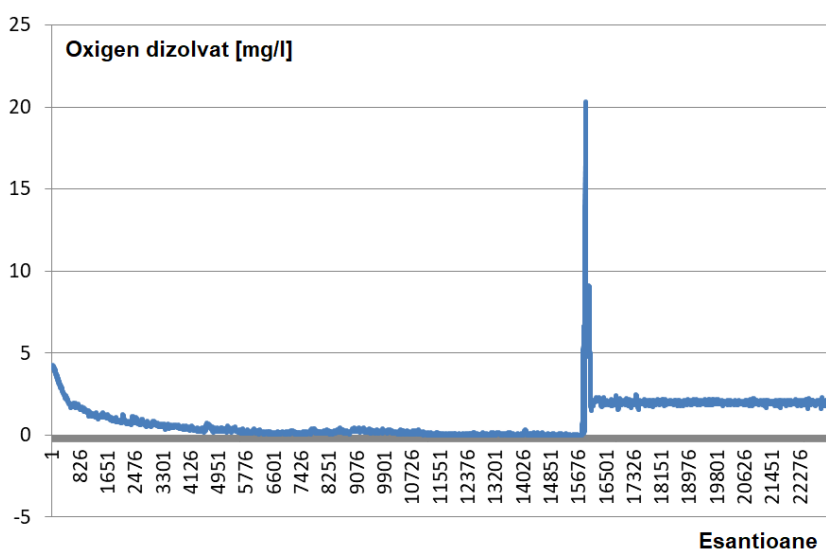


Fig. 2.25 – Evoluția concentrației de oxigen dizolvat

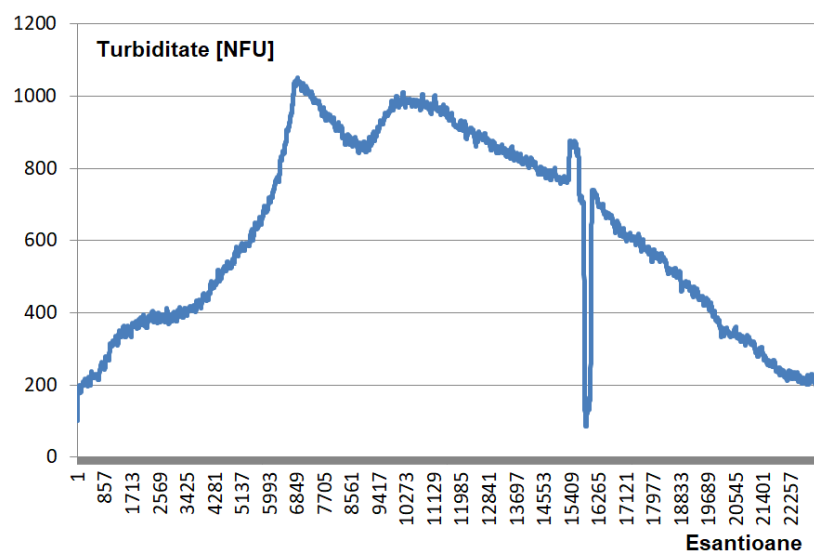


Fig. 2.26 – Evoluția turbidității

2.3.3 Modelul matematic al procesului de tratare biologică a apelor uzate

În studiul de caz analizat în această secțiune se consideră o instalație de tratare a apelor uzate în care se face îndepărtarea biologică a substratului organic de tipul celei prezentate în secțiunea anterioară. Modelul procesului are patru mărimi de stare: biomasa, $X(t)$ [mg/l], concentrația substratului organic, $S(t)$ [mg/l], concentrația oxigenului dizolvat, $DO(t)$ [mg/l] și biomasa recirculată, $X_r(t)$ [mg/l]. Modelul analizat este neliniar și are ca mărimi de comandă; viteza de aerare, W [m^3/h], viteza de diluție ($D =$ raportul dintre debitul de intrare al bazinului aerat și volumul acestuia [$1/h$]) și viteza de recirculare a nămolului, r . În Fig. 2.27, F_{in} este debitul de influent care intră în bioreactorul aerat, iar F_{out} este debitul efluentului.

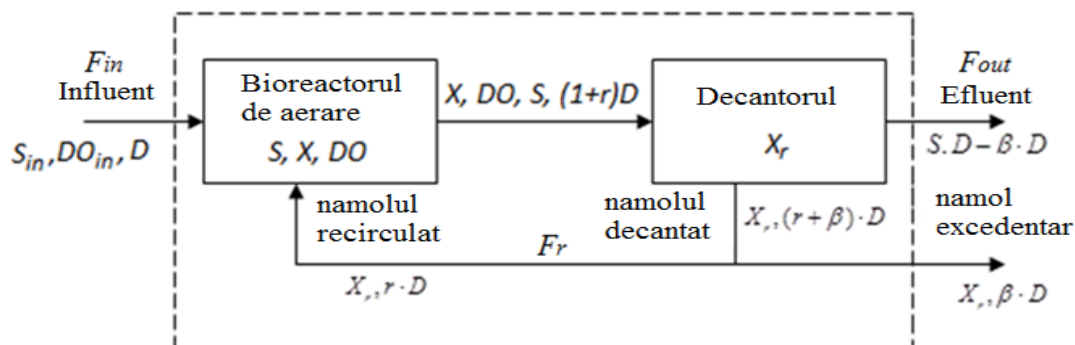


Fig. 2.27 - Reprezentarea sistemică a instalației care reduce materia organică în procesele de tratare a apelor reziduale cu nămolului activ [111]

Se consideră următoarele ipoteze pentru modelul matematic al procesului analizat [129]:

- regimul în care funcționează bioreactorul are $V = ct$ ($F_{in} = F_{out} = F$);
- fluxul de recirculare al nămolului activ este proporțional cu fluxul F : $F_r = r \cdot F$;
- fluxul de nămol în exces din bioreactor este proporțional cu fluxul de intrare al procesului (F): $F_\beta = \beta \cdot F$;
- nu există substrat sau oxigen dizolvat în fluxul recirculat de nămol activ;
- fluxul de ieșire al bioreactorului aerat este egal cu suma dintre fluxul de intrare al bioreactorului și fluxul recirculat de nămol activ.

Ținând cont de Fig. 2.27 și de cele 5 ipoteze formulate mai sus, rezultă următoarele ecuații diferențiale care descriu modelul matematic al procesului:

$$\frac{dX}{dt} = \mu(t)X(t) - D(t)(1+r)X(t) + rD(t)X_r(t) \quad (2.15)$$

$$\frac{dS}{dt} = -\frac{\mu(t)}{Y}X(t) - D(t)(1+r)S(t) + D(t)S_{in} \quad (2.16)$$

$$\frac{dDO}{dt} = -\frac{(1-Y)\mu(t)X(t)}{Y} \cdot 10^3 - D(t)(1+r)DO(t) + 60\alpha W(t)(DO_{sat} - DO(t)) + D(t)DO_{in} \quad (2.17)$$

$$\frac{dX_r}{dt} = D_s(t)(1+r)X(t) - D_s(t)(\beta+r)X_r(t) - 0.5D_s(1+\beta)X_r(t) \quad (2.18)$$

$$\mu(t) = \mu_{max} \frac{S(t)}{K_s + S(t)} \cdot \frac{DO(t)}{K_{DO} + DO(t)} \quad (2.19)$$

$$D = \frac{F_{in}}{V}; D_s = \frac{D \cdot V}{V_s} \quad (2.20)$$

unde $X(t)$ – concentrația biomasei, $S(t)$ – concentrația substratului, $DO(t)$ – concentrația oxigenului dizolvat, $X_r(t)$ – concentrația biomasei recirculate, $\mu(t)$ – viteza specifică de creștere a biomasei, μ_{max} – viteza maximă specifică de creștere a biomasei, $D(t)$ – viteza de diluție, $W(t)$ – viteza de aerare, r – viteza de recirculare, S_{in} – concentrația substratului influent, DO_{in} – concentrația oxigenului dizolvat influent, DO_{sat} – valoarea de saturație a oxigenului dizolvat, Y – coeficientul de randament, K_s – constanta de saturație a substratului, K_{DO} – constanta de saturație a oxigenului dizolvat, α – viteza de transfer a oxigenului, β – rata nămolului în exces, F_{in} – fluxul influent, V – volumul bioreactorului, D_s – viteza de diluție a nămolului, V_s – volumul nămolului.




Fig. 2.28 - Rezultatele simulării unui proces de tratare a apelor uzate în buclă deschisă [111]

Fig. 2.28, prezintă rezultatele simulării modelului matematic descris de ecuațiile (2.15) – (2.19) în buclă deschisă, pe durata răspunsului tranzitoriu, atunci când se aplică o treaptă pe intrarea $D(t)$. Rezultatele simulării modelului matematic s-au obținut luând în considerare următoarele valori ale parametrilor de intrare: $\mu_{max} = 0.11[\text{h}^{-1}]$, $K_s = 0.18[\text{g}\cdot\text{L}^{-1}]$, $K_{DO} = 0.2[\text{g}\cdot\text{L}^{-1}]$, $Y = 0.67$, $DO_{sat} = 8[\text{mg}\cdot\text{L}^{-1}]$, $\alpha = 0.0033[\text{L}^{-1}]$, $r = 1$; $\beta = 0.2$, $V = 35[\text{L}]$, $V_s = 6[\text{L}]$, $D = 0.025[\text{h}^{-1}]$, $W = 5[\text{L}\cdot\text{min}^{-1}]$, $S_{in} = 0.8[\text{g}\cdot\text{L}^{-1}]$, $DO_{in} = 2[\text{mg}\cdot\text{L}^{-1}]$ și a condițiilor inițiale: $X(0) = 0.5[\text{mg}\cdot\text{L}^{-1}]$, $S(0) = 0.8[\text{mg}\cdot\text{L}^{-1}]$, $DO(0) = 2[\text{mg}\cdot\text{L}^{-1}]$, $X_r(0) = 0[\text{mg}\cdot\text{L}^{-1}]$.

2.3.4 Modelarea cu rețele neuronale a procesului de tratare biologică a apelor uzate

Rețelele neuronale reprezintă un instrument foarte puternic pentru predicție, control și modelarea proceselor și, în particular, al proceselor de tratare a apelor reziduale biologice [130, 131]. Obiectivul principal al acestui capitol este de a dezvolta un model neuronal care să poată fi utilizat pentru diagnoza unui proces biologic de tratare a apelor uzate în care se înlătură reziduurile de carbon organic.

În Fig. 2.33 este prezentată structura rețelei neuronale proiectată cu ajutorul programului Matlab. Se pot observa cele 8 variabile de intrare, (intrările D , W , r , S_{in} și ieșirile întârziate cu un pas de eșantionare, X , S , DO , X_r). Valoarea concentrației de oxigen dizolvat din influent este considerată constantă ($DO_{in} = ct$). De asemenea, sunt suficienți 4 neuroni în stratul ascuns, ținând cont de performanța antrenării și abilitatea de generalizare a rețelei (testată pe parcursul etapei de validare).




Fig. 2.33 - Structura rețelei neuronale artificiale de aproximare a modelului nelinier de tratare a apelor uzate

Pentru antrenare, s-a utilizat algoritmul de învățare, Levenberg – Marquardt (*trainlm* – funcția de transfer neuronală din Matlab), de asemenea cunoscut și sub denumirea de “damped least-squares method” [135]. Această metodă este, conform cu [133], mult mai eficientă în cazul sistemelor neliniare chiar dacă consumă mai multă memorie a calculatorului. Pasul final validează rețeaua neuronală folosind seturi independente de date obținute prin simularea modelului procesului cu intrări de date reprezentative.

2.3.5 Rezultatele antrenării rețelei neuronale

Pentru instruire, s-au pregătit două seturi de date. Setul de date de intrare este o matrice P [8x10000] care conține valorile curente ale ieșirilor (X, S, DO, X_r), ale variabilelor de comandă (D, W, r) și perturbației S_{in} . Setul de date “țintă” este o matrice T [4x10000] care conține valorile ieșirilor, înainte cu un pas de eșantionare, față de cele din matricea P .

Comenzile Matlab folosite în proiectarea algoritmului de modelare cu rețele neuronale artificiale sunt: *newff*, *train* și *sim*.




Fig. 2.36 – Concentrația de biomasă, X (roșu – ieșirea obținută din simularea modelului analitic și albastru – ieșirea din aproximarea cu rețeaua neuronală)




Fig. 2.37 – Concentrația de substrat organic, S (roșu – ieșirea obținută din simularea modelului analitic și albastru – ieșirea din aproximarea cu rețeaua neuronală)




Fig. 2.38 – Concentrația de oxigen dizolvat, DO (roșu – ieșirea obținută din simularea modelului analitic și albastru – ieșirea din aproximarea cu rețeaua neuronală)




Fig. 2.39 – Concentrația de biomasă recirculată, X_r (roșu – ieșirea obținută din simularea modelului analitic și albastru – ieșirea din aproximarea cu rețeaua neuronală)




Fig. 2.40 - Eroarea medie patrată obținută în urma instruirii rețelei neuronale

2.3.6 Rezultatele validării rețelei neuronale

Pentru etapa de validare a fost pregătit un set de date distinct. Rezultatele validării sunt prezentate în Fig. 2.43 – 2.46. Acestea indică o capacitate bună de generalizare a rețelei neuronale, întrucât ieșirile acesteia urmăresc îndeaproape ieșirile modelului original.




Fig. 2.43 - Rezultatul validării pentru concentrația de biomasă, X (albastru – rezultatul din simularea modelului analitic, roșu – rezultatul din aproximarea cu rețeaua neuronală)

Erorile de modelare nu sunt relevante pentru proces deoarece sunt în vecinătatea valorii 0 (starea de “washout” a bioreactorului), care nu ar trebui să apară în timpul exploatarei normale. Deviația rețelei în această zonă este produsă de lipsa de date suficiente de instruire în intervalul respectiv.




Fig. 2.44 - Rezultatul validării pentru concentrația de substrat, S (albastru – rezultatul din simularea modelului analitic, roșu – rezultatul din aproximarea cu rețeaua neuronală)




Fig. 2.45 - Rezultatul validării pentru concentrația de oxigen dizolvat, DO (albastru – rezultatul din simularea modelului analitic, roșu – rezultatul din aproximarea cu rețeaua neuronală) [111]




Fig. 2.46 - Rezultatul validării pentru concentrația de biomasă recirculată, X_r (albastru – rezultatul din simularea modelului analitic, roșu – rezultatul din aproximarea cu rețeaua neuronală) [111]

Capitolul 3

Contribuții privind detecția defectelor în procesele biotehnologice

3.1 Probleme curente privind detecția defectelor

Actualmente, detectarea defectelor în stațiile de epurare a apelor uzate a devenit o provocare pentru specialiști datorită complexității acestor procese. În acest context, numeroși cercetători au contribuit la dezvoltarea diferitelor metode de detectare a defectelor, dar și la îmbunătățirea celor existente [136], [137], [138], [139], [140] și [141].

Modelele bazate pe date, cum ar fi rețelele neuronale sau tehnicile fuzzy, oferă un instrument puternic și rapid de calcul pentru tratarea problemelor de detecție. Tehnicile de prelucrare a semnalelor pentru detectarea defectelor pot fi folosite pentru observarea schimbărilor în semnale provenite fie direct din măsurători, fie din reziduuri rezultate în urma altor tehnici de detectare a defectelor [147].

Procesele de epurare a apelor uzate sunt sisteme foarte complexe care pot fi afectate de diverse perturbații și zgomote în timpul funcționării normale, fiind susceptibile la apariția a diferite defecte care compromit funcționarea corectă a acestora. Defectele care pot afecta funcționarea unui WWTP (WasteWater Treatment Process) pot fi: mecanice/electrice (defecte ale echipamentului din cauza unor probleme mecanice sau electrice), de natură fizico-chimică (pH-ul, oxigenul dizolvat sau concentrațiile altor substanțe chimice necunoscute modificate), biologice (biomasa a fost afectată – de ex. prin contaminare) sau operaționale (datorită lipsei de personal instruit).

3.2 Detecția defectelor cu rețele neuronale aplicată la o stație de epurare a apelor uzate

În această secțiune se propune o metodă de detecție a defectelor bazată pe modelul neuronal al unui proces de tratare a apelor reziduale descris în capitolul 2. În esență, fiecare mărime de ieșire, măsurabilă, este supravegheată de un automat, care trebuie să decidă dacă a apărut un defect. În acest scop, este folosit un model fidel al procesului supravegheat, în cazul acesta un model neuronal, despre care se presupune că furnizează aceeași evoluție a mărimilor de ieșire, ca și ieșirile din proces, dacă i se aplică aceleași valori ale mărimilor de intrare (aspectele privitoare la faptul că nu toate mărimile de intrare sunt măsurabile nu este discutat aici).

3.2.1 Stabilirea condițiilor de alegere a parametrilor algoritmului de detecție a defectelor

Parametrii algoritmului de decizie a automatului sunt: valoarea pragului de decizie și numărul de eșantioane pe care se calculează reziduul, respectiv ε și N . În cele ce urmează, sunt calculate probabilitățile menționate și întârzierea deciziei, astfel încât, pe baza lor, să fie aleasă o funcție obiectiv eficace. Funcția obiectiv și procedura de alegere a parametrilor (respectiv ε și N) se bazează pe teoria deciziei statistice.

Asadar se realizează o analiză teoretică în care se consideră trei ipoteze, după cum urmează: Ip. 1 nu există erori de modelare ($er(k)=0$, adică modelul reproduce fidel evoluția procesului supravegheat), dacă există defect, se presupune că devierea produsă de acesta a ajuns în regim staționar în timp foarte scurt (cîteva perioade de eșantionare), decizia trebuie luată rapid, numai pe baza eșantionului curent, deci $N=1$, ceea ce este echivalent cu a spune că reziduul a fost calculat doar pentru eșantionul curent; Ip. 2 nu există erori de modelare (adică modelul reproduce fidel evoluția procesului supravegheat), devierea produsă de defect evoluează lent, cu timp de creștere cunoscut și decizia se poate lua pe baza mai multor eșantioane succesive, adică reziduul se calculează pe orizontul de timp

$N > 1$; Ip. 3 există eroare de modelare, cu densitate de probabilitate cunoscută, devierea produsă de defect evoluează lent, cu timp de creștere cunoscut, eroarea de modelare variază mai lent decât devierea produsă de defect și decizia se poate lua pe baza mai multor eșantioane succesive ($N > 1$).

Comentariu asupra alegerii funcției reziduu, folosite în algoritmul de decizie

Referitor la definirea funcției reziduu, folosite pentru detecția defectelor, în această secțiune am studiat trei variante, prezentate în (3.24), (3.25), (3.26).

$$R_1(k) = \frac{1}{N} \sum_{i=k-N+1}^k ab(i) \quad (3.24)$$

$$R_2(k) = \frac{1}{N} \sum_{i=k-N+1}^k |ab(i)| \quad (3.25)$$

$$R_3(k) = \frac{1}{N} \sum_{i=k-N+1}^k (ab(i))^2 \quad (3.26)$$

Pentru a pune în evidență diferența dintre cele trei variante de calcul al reziduuului, Fig. (3.12) conține trei grafice, pentru cele trei variante de reziduu, calculat pe $N = 20$ eșantioane. Acesta este motivul pentru care, dacă valorile așteptate ale devierii și erorii de modelare sunt mari, comparativ cu nivelul zgomotului, cele trei variante ale reziduuului vor determina rezultate similare, deci **se poate afirma că sunt echivalente**. Dacă, dimpotrivă, devierea așteptată este mică, față de nivelul zgomotului, reziduuul cel mai avantajos este R_1 .

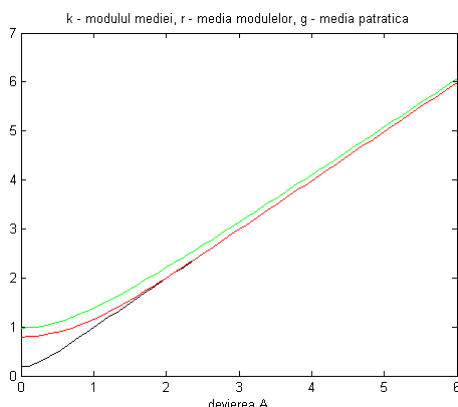


Fig. 3.12 - Variația celor trei variante de reziduu, cu valoarea devierii A

În continuare, ținând cont de analiza de mai sus, **s-a optat pentru varianta 3 de calcul al reziduurilor** în cazul procesului de tratare biologică a apelor uzate, varianta în care reziduurile sunt calculate ca medie a pătratelor abaterilor.

3.2.2 Schema de detecție a defectelor cu rețea neuronală

În această secțiune se propune implementarea metodei de detecție a defectelor pe baza calculului reziduurilor. Pentru a testa sistemul de detecție a defectelor, sunt simulate diverse defecte folosind modelul analitic al procesului. Se consideră următoarele situații posibile:

1. defecte nete ale echipamentelor de câmp din proces (elemente de execuție și traductoare);
2. defecte parțiale ale echipamentelor menționate la punctul 1;

3. defecte care apar ca urmare a unor stări nefavorabile ale culturii de micro-organismе (de ex.: șoc toxic sau contaminare), care conduc nămolul la o stare neviabilă.

Schema generală de detecție a defectelor este prezentată în figura de mai jos:




Fig. 3.13 - Schema generală de detecție a defectelor

3.2.3 Validarea metodei de detecție a defectelor cu rețea neuronală prin simulări numerice

În această secțiune se prezintă o serie de simulări numerice pentru a analiza efectul parametrilor N și ε asupra performanței metodei (defecte nesemnalate sau alarme false) și vitezei de detecție (durata de alarmare privind prezența unui defect). Trebuie menționat faptul că **perioada de eșantionare s-a ales astfel: $T_e = 6 \text{ min}$** , procesul fiind foarte lent.

1. Prezența unor defecte nete ale echipamentelor de câmp

a) Defect al pompei de recirculare

Pentru simularea unui defect net al pompei de recirculare se consideră că valoarea parametrului $r = 0$ pe intervalul $N_f \in [4300, 5400]$. În Fig. 3.15 se observă abaterile de pe fiecare ieșire a procesului în momentul apariției defectului.




Fig. 3.15 - Abaterile ieșirilor X, S, X_r, DO datorate defectării pompei de recirculare ($r = 0$) pe intervalul $[4300, 5400]$ eșantioane

În continuare, se obțin reziduurile pentru fiecare mărime de ieșire a procesului, pentru următoarele valori ale lui N [eșantioane]: $N = 10$, $N = 20$, $N = 40$, $N = 80$. În Fig. 3.17 se arată obține valoarea reziduuului atunci când $N = 20$.

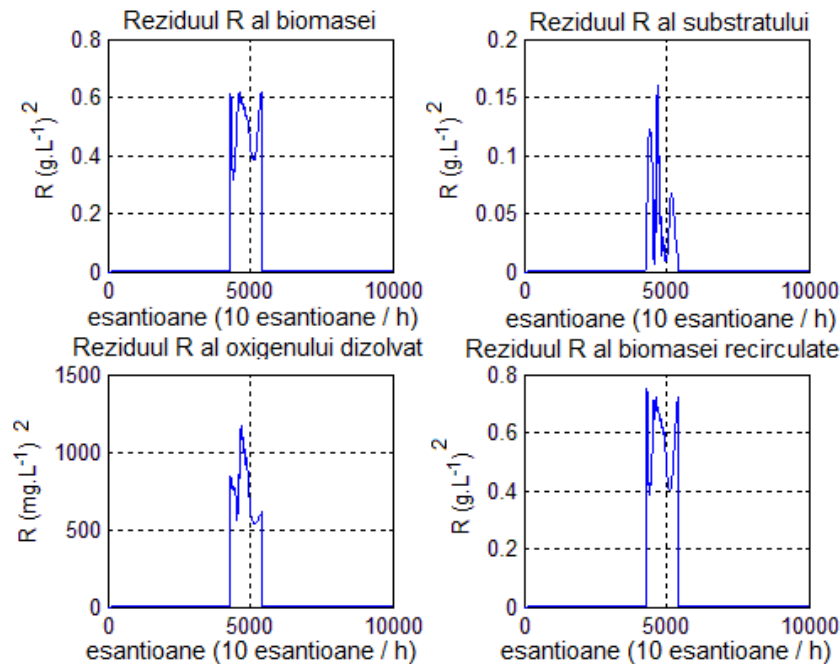


Fig. 3.17 - Reziduuul, R , obținut în cazul defectării pompei de recirculare pentru $N = 20$

b) Defect net al traductorului de măsură a concentrației de biomasă

Un defect net a traductorului de biomasă poate fi simulat prin faptul că biomasă măsurată a procesului $X = 0$ (instalația de tratare a intrat în starea de "washout"). În Fig. 3.20 se prezintă abaterile obținute pentru simularea acestui tip de defect, care se consideră că apare în proces pe o anumită perioadă de timp, și anume, între eșantioanele 4300 și 5400.

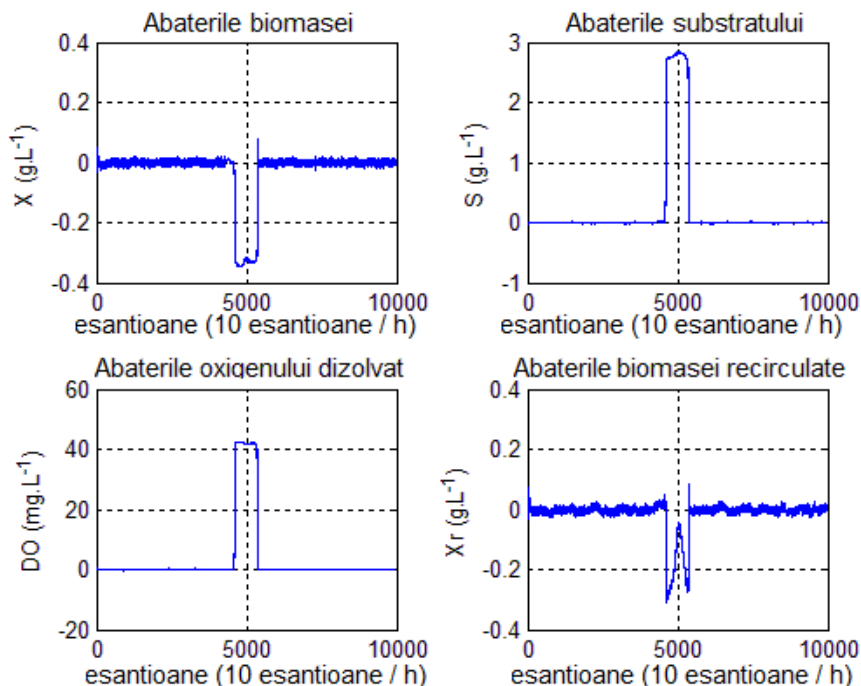


Fig. 3.20 - Abaterile ieșirilor X, S, X_r, DO datorate defectării traductorului de biomasă ($X = 0$) pe intervalul [4300, 5400] eșantioane

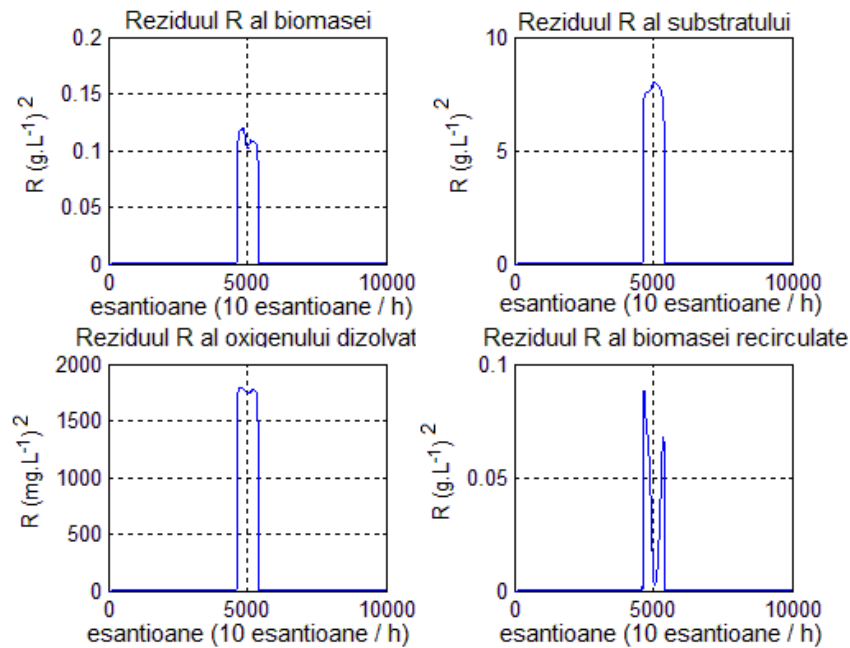


Fig. 3.22 - Reziduul, R , obținut în cazul defectării traductorului de biomasă pentru $N = 20$

Calculul reziduului este realizat și pentru celelalte valori ale lui N [eșantioane]: $N = 10$, $N = 40$, $N = 80$.

2. Prezența unor defecte parțiale (25%) ale echipamentelor de câmp

a) Defect parțial a pompei de alimentare cu influent (25% din capacitatea totală)

În continuare, se analizează un defect parțial al pompei de alimentare atunci când aceasta funcționează la 25% din capacitatea totală pe intervalul $N_f \in [4300, 5400]$. În Fig. 3.25 se obțin abaterile produse de funcționarea la capacitatea de 25% a acestui echipament.

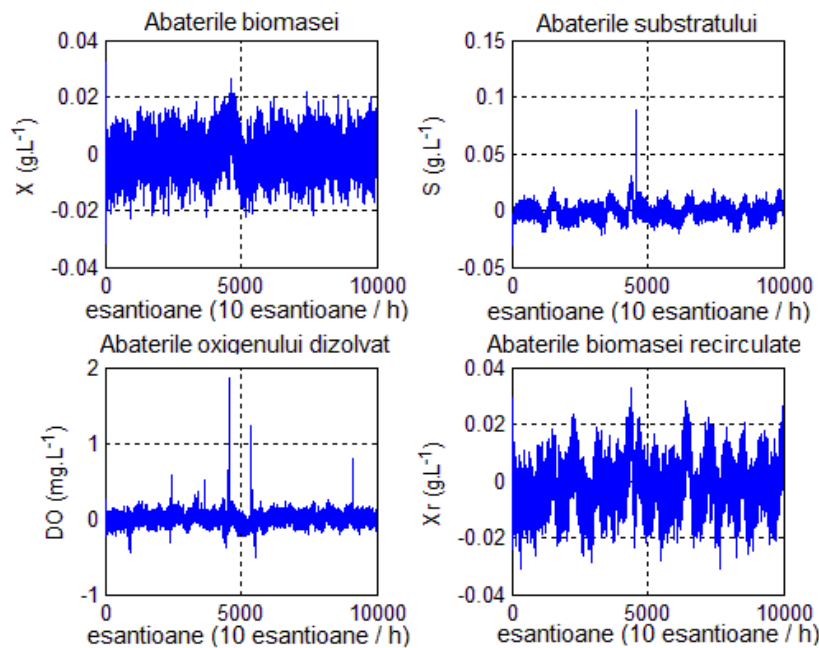


Fig. 3.25 - Abaterile ieșirilor X, S, X_r, DO datorate defectării parțiale a pompei de alimentare (funcționare la 25% din capacitatea totală) pe intervalul $[4300, 5400]$ eșantioane

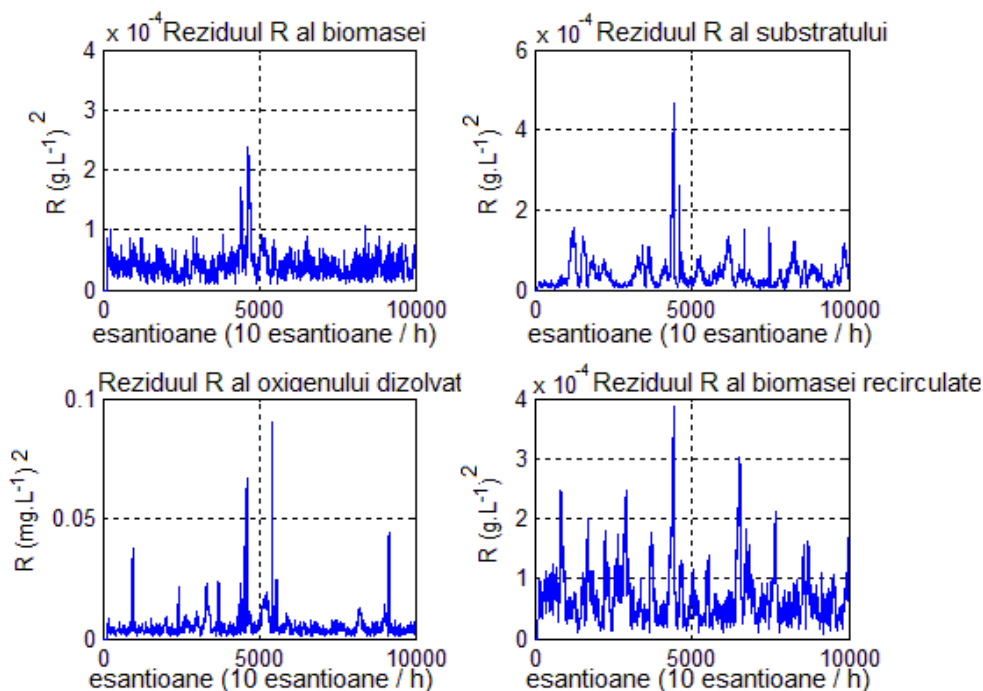


Fig. 3.27 - Reziuul, R , obținut în cazul defectării parțiale a pompei de alimentare (funcționare la 25% din capacitatea totală) pentru $N = 20$

Mai departe se obține reziuul și pentru celelalte valori ale lui N [eșantioane]: $N = 10$, $N = 40$, $N = 80$.

3. Prezența unui defect datorat unui șoc toxic suferit de cultura de micro-organisme

Defectul datorat unui șoc toxic suferit de cultura de microorganisme a fost simulat prin scăderea la jumătate a valorii vitezei de creștere a biomasei, μ_{max} , pe intervalul $N_f \in [4300, 5400]$.

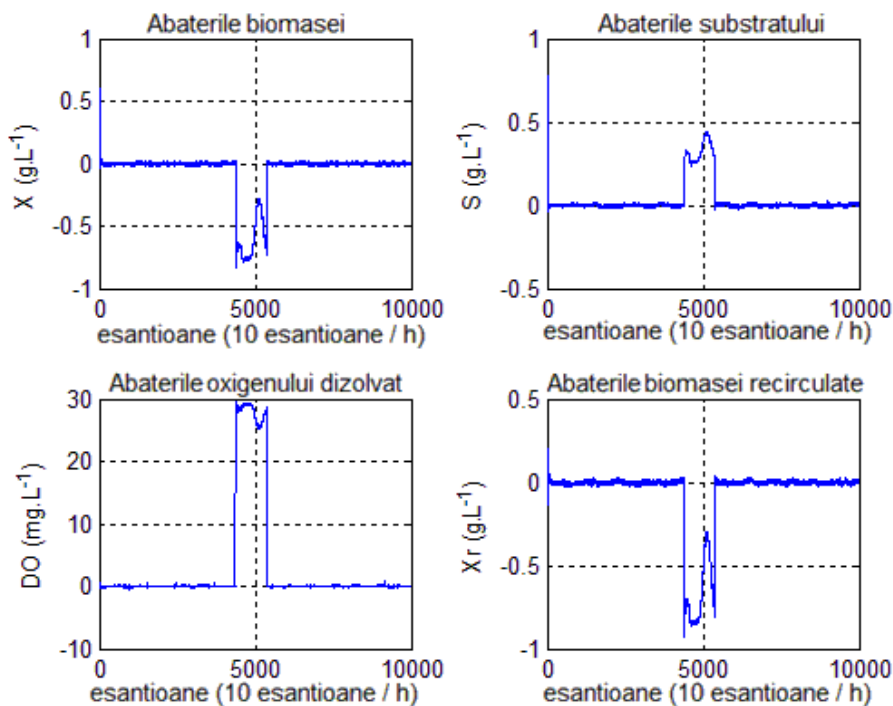


Fig. 3.30 - Abaterile ieșirilor X, S, X_r, DO datorate defectului de toxicitate ($\mu_{max}/2$ pe intervalul [4300, 5400] eșantioane)

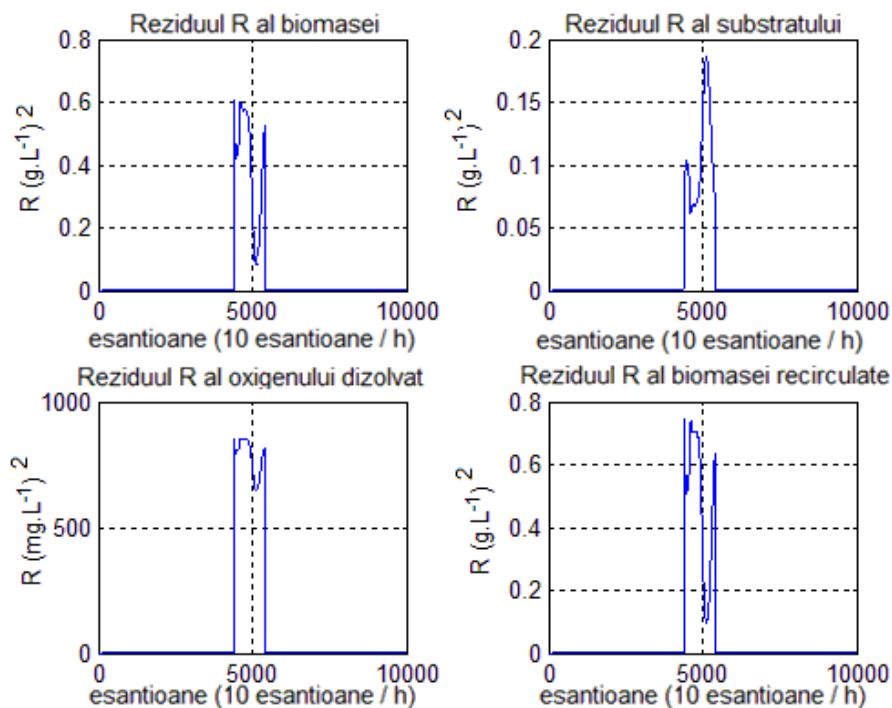


Fig. 3.32 - Reziduul, R , obținut în cazul defectului de toxicitate pentru $N = 20$

În toate cazurile de defecte analizate anterior, se alege pentru parametrul N valoarea $N = 20$, ceea ce corespunde cu analiza criteriile de alegere a parametrilor metodei de detecție din secțiunea 3.2.1.

Pragul de sensibilitate, ε , este ales pentru fiecare ieșire în parte: $\varepsilon_X = 2.2 \cdot 10^{-4}$, $\varepsilon_S = 2.6 \cdot 10^{-4}$, $\varepsilon_{DO} = 0.05$, $\varepsilon_{X_r} = 4 \cdot 10^{-4}$.

a). Detecție defect net al pompei de recirculare




Fig. 3.35 - Defect simulat pe perioada [4300,5400] eşantioane




Fig. 3.36 - Generare alarmă pe ieșirea X , în cazul defectării pompei de recirculare (detecție defect pe perioada [4300,5419] eşantioane)

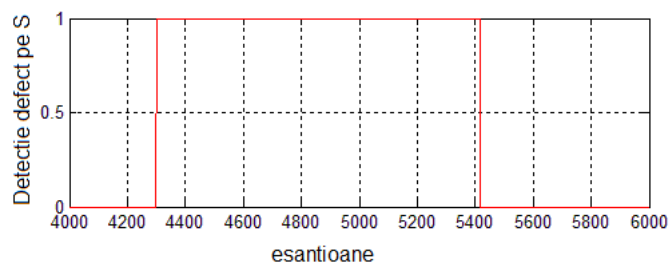


Fig. 3.37 - Generare alarmă pe ieșirea S , în cazul defectării pompei de recirculare (dectecție defect pe perioada [4300, 5419] eşantioane)




Fig. 3.38 - Generare alarmă pe ieșirea DO , în cazul defectării pompei de recirculare (dectecție defect pe perioada [4300, 5420] eşantioane)




Fig. 3.39 - Generare alarmă pe ieșirea X_r , în cazul defectării pompei de recirculare (dectecție defect pe perioada [4300, 5419] eşantioane)




Fig. 3.40 - Generare alarmă cu funcția SAU în cazul defectării pompei de recirculare (dectecție defect pe perioada [4300, 5420] eşantioane, după $\sim 0h$, dectecție practic instantanee a defectului)

Dectecția este realizată pentru toate tipurile de defecte analizate anterior. În simulările realizate s-a reușit dectecția corectă a fiecărui defect care a intervenit în proces, cu o întârziere de cel mult $12h$. Cel mai bun rezultat al algoritmului de dectecție a fost obținut în cazul defectării pompei de recirculare, dectecția defectului fiind practic instantanee.

3.3 Detecția defectelor cu filtrul Kalman extins aplicată la o stație de epurare a apelor uzate

În această secțiune, se propune, față de metoda de detecție cu rețea neuronală, când toate mărimile de ieșire ale procesului au fost considerate măsurabile, o metodă de detecție a defectelor bazată pe modelul matematic analitic al procesului de tratare la care se adaugă un filtru Kalman pentru determinarea unor variabile de stare nemăsurabile direct.

În Fig. 3.59 sunt prezentate rezultatele estimării stării procesului utilizând filtrul Kalman extins.

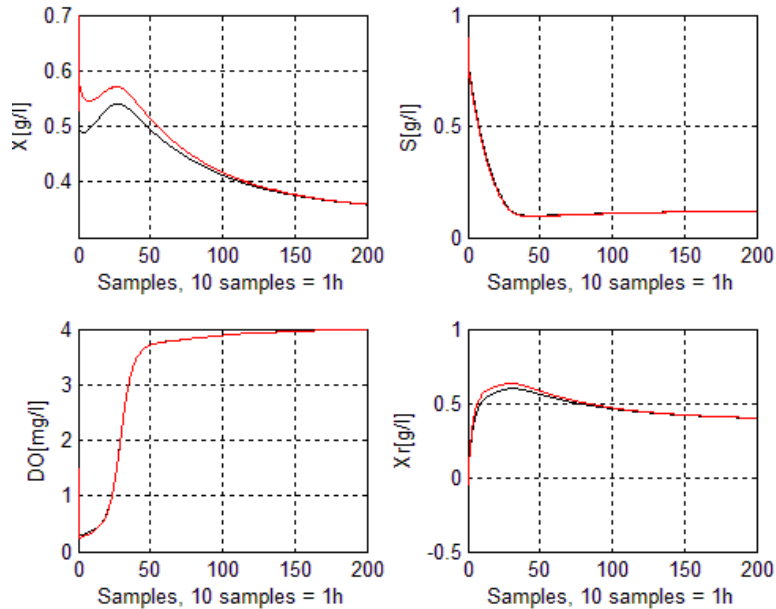


Fig. 3.59 - Estimarea stării utilizând filtrul Kalman extins (roșu – ieșirile procesului, negru – estimarea acestora)

3.3.3 Schema de detecție a defectelor cu filtrul Kalman extins

În Fig. 3.60 este prezentată schema de detecție a defectelor folosită pentru generarea reziduurilor. Mărimea de intrare DO_{in} este considerată constantă.

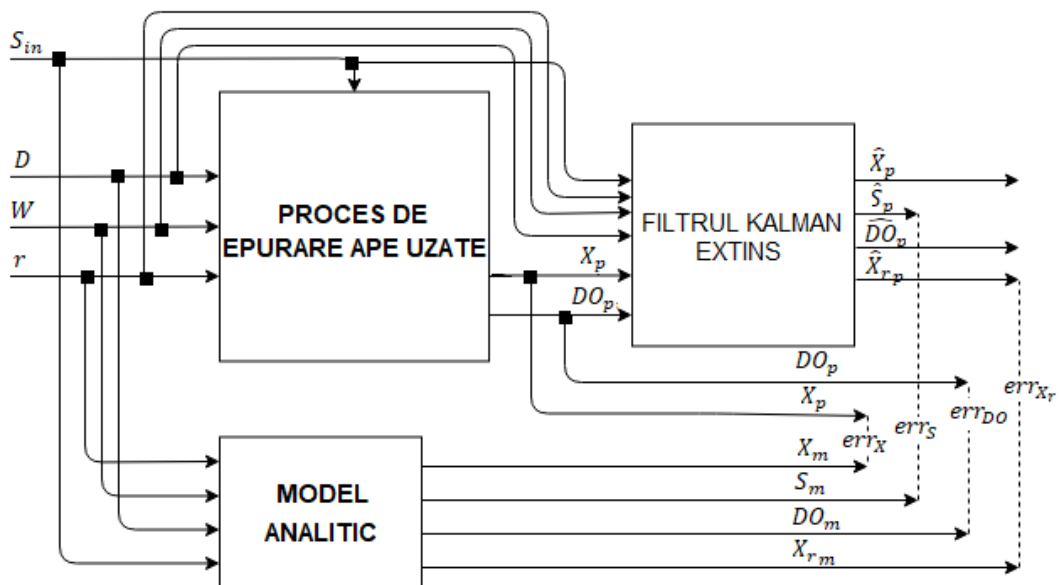


Fig. 3.60 - Schema de detecție cu filtrul Kalman extins

3.3.5 Validarea metodei de detecție cu filtrul Kalman extins prin simulări numerice

În această etapă se reiau anumite tipuri de defecte simulate în secțiunea 3.2.3 și se testează noua metodă de detecție propusă pentru situația în care se utilizează un filtru Kalman.

1. Prezența unor defecte nete ale echipamentelor de camp

a) Defect net al pompei de recirculare

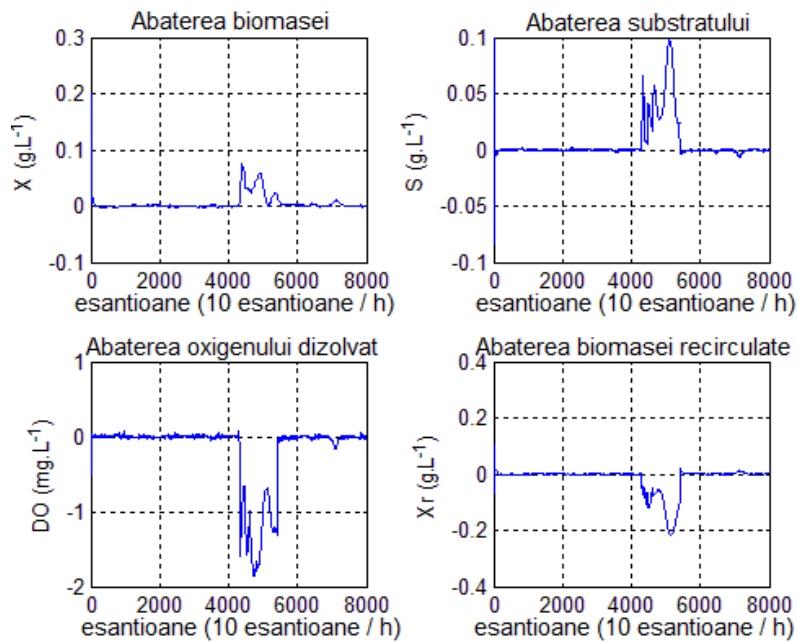


Fig. 3.62 - Abaterile ieșirilor X, S, DO, X_r , datorate defectării pompei de recirculare ($r = 0$) pe intervalul [4300, 5400] esantioane

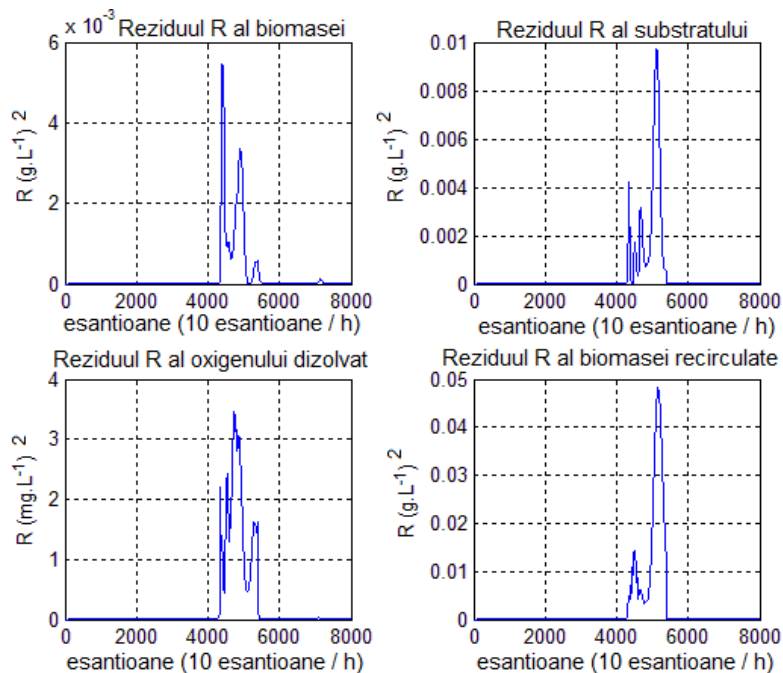


Fig. 3.63 - Reziduul, R , obținut în cazul defectării pompei de recirculare atunci când parametrul $N = 10$

Aceși procedură de calcul a reziduiului este realizată și pentru $N = 20, N = 40$.

b) Defect net al traductorului de măsură a concentrației de biomasă

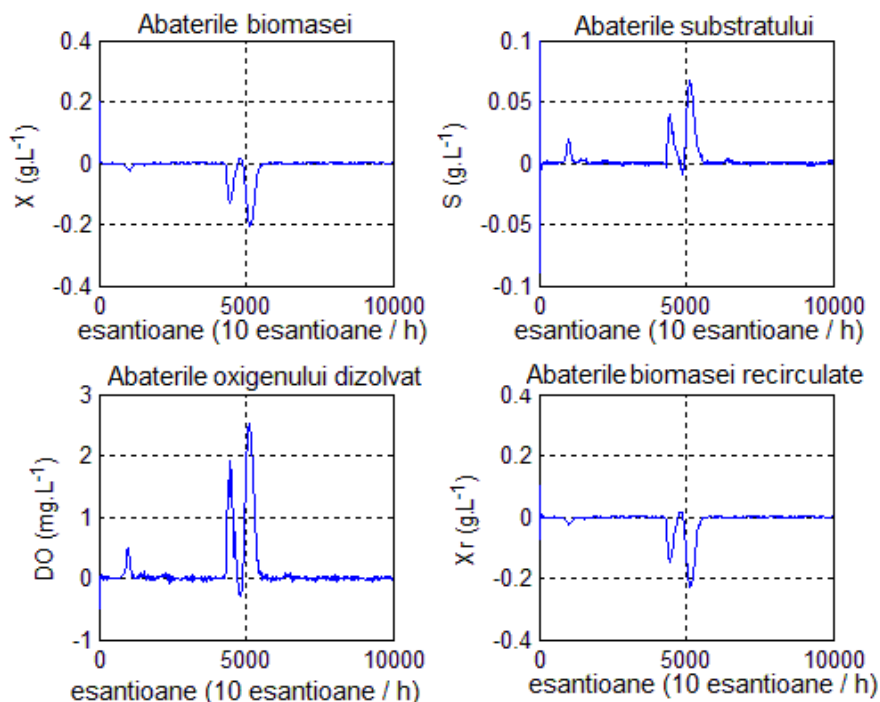


Fig. 3.66 - Abaterile ieșirilor X, S, DO, X_r , datorate defectării traductorului de biomasă ($X = 0$ – defect net) pe intervalul [4300, 5400] eşantioane

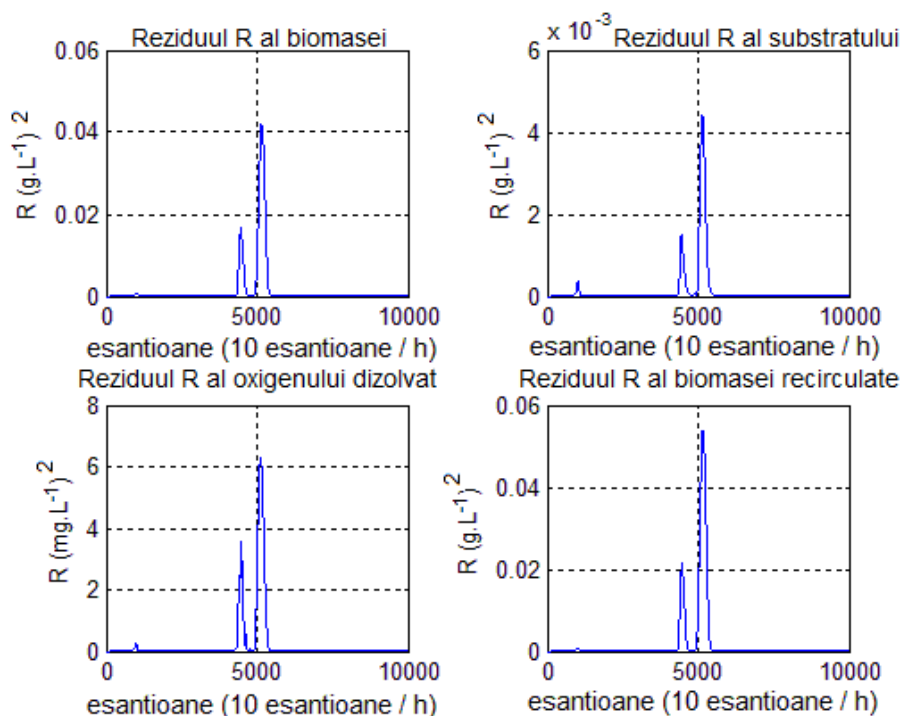


Fig. 3.67 - Reziduuul, R , obținut în cazul defectării traductorului de biomasă atunci când parametrul $N = 10$

Se reia calculul reziduiului și pentru cazul în care $N = 20, N = 40$.

2. Prezența unor defecte parțiale (25%) ale echipamentelor de câmp

a) Defect parțial al pompei de alimentare (25% din capacitatea totală)

Se consideră cazul când pompa de alimentare funcționează la o capacitate de maxim de 25% din capacitatea totală pe perioada $N_t \in [4300, 5400]$. În Fig. 3.70 se obțin abaterile ieșirilor X, S, DO, X_r .

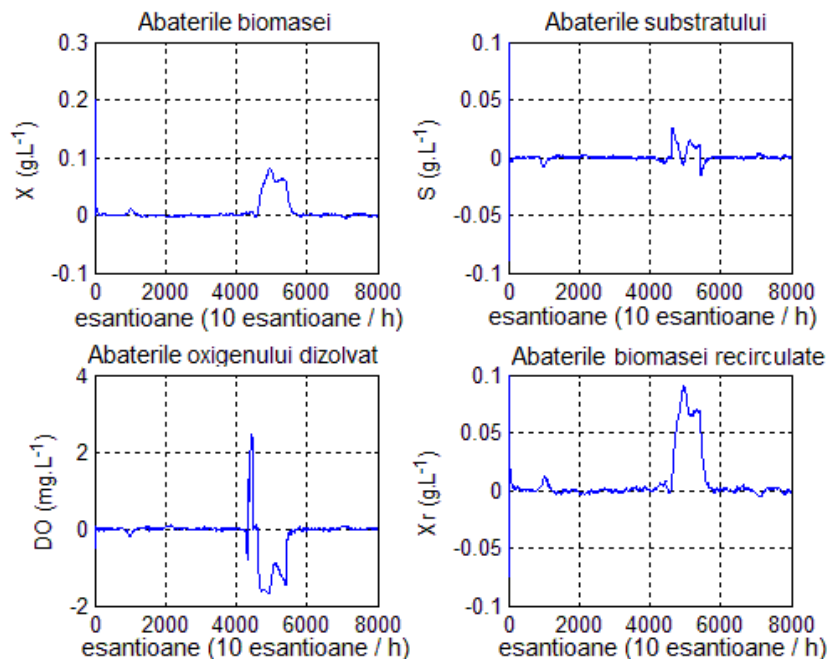


Fig. 3.70 - Abaterile ieșirilor X, S, DO, X_r , datorate defectării parțiale a pompei de alimentare (funcționare la 25% din capacitatea totală) pe intervalul $[4300, 5400]$ eşantioane

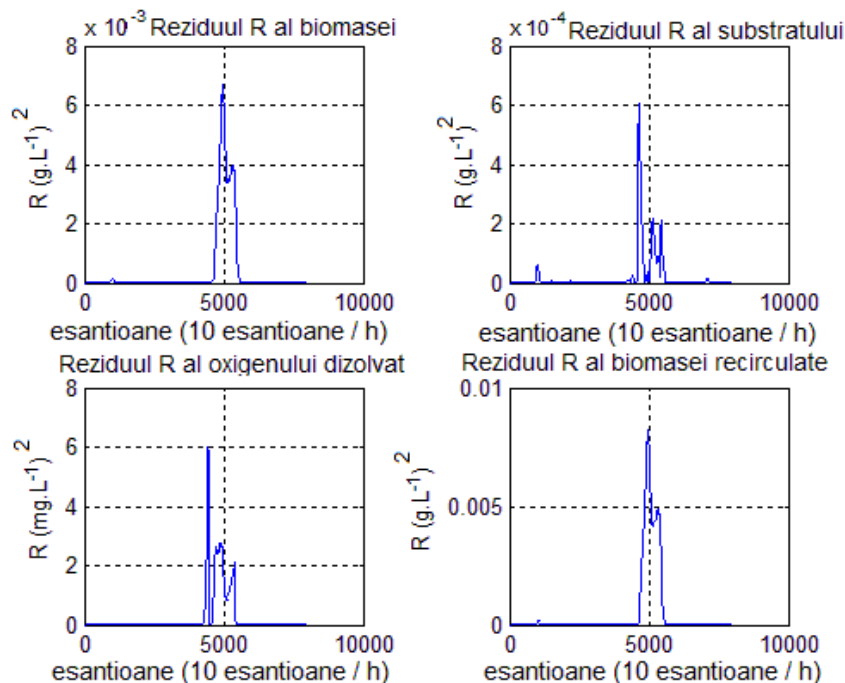


Fig. 3.71 - Reziuul, R , obținut în cazul defectării parțiale a pompei de alimentare atunci când parametrul $N = 10$

Pe baza rezultatelor simulărilor obținute în toate cazurile de defecte considerate mai sus (metoda de detecție care utilizează filtrul Kalman), se recomandă alegerea următoarelor valori pentru parametrii metodei de detecție:

a) $N = 10$ eşantioane;

b) Pragul de sensibilitate, ε , pentru fiecare ieşire este dat de valorile: $\varepsilon_X = 0.5 \cdot 10^{-3}$, $\varepsilon_S = 0.2 \cdot 10^{-3}$, $\varepsilon_{DO} = 0.2$, $\varepsilon_{X_r} = 3 \cdot 10^{-3}$.

În continuare, se realizează detecţia pentru toate tipurile de defecte analizate. Pentru exemplificare se va arăta rezultatul detecţiei doar pentru defectul net al pompei de recirculare. Aceasta reprezintă cazul în care se obţine cel mai bun rezultat al detecţiei, şi anume, după aproximativ $0.7h$.

a). Detecţie defect net al pompei de recirculare




Fig. 3.74 - Defect simulat pe perioada de [4300, 5400] eşantioane




Fig. 3.75 - Generare alarmă pe ieşirea X , în cazul defectării pompei de recirculare (detecţie defect pe perioadele [4345, 5047], [5366, 5406] eşantioane)




Fig. 3.76 - Generare alarmă pe ieşirea S , în cazul defectării pompei de recirculare (detecţie defect pe perioadele [4307, 4402], [4461, 5410] eşantioane)




Fig. 3.77 - Generare alarmă pe ieşirea DO , în cazul defectării pompei de recirculare (detecţie defect pe perioada [4324, 5414] eşantioane)




Fig. 3.78 - Generare alarmă pe ieșirea X_r , în cazul defectării pompei de recirculare (detectie defect pe perioada [4312, 5409] eşantioane)




Fig. 3.79 - Generare alarmă cu funcția SAU în cazul defectării pompei de recirculare (detectie defect pe perioada [4307, 5414] eşantioane, după $\sim 0.7h$)

Capitolul 4

Izolarea defectelor folosind rețele neuronale

4.1 Probleme curente în izolarea defectelor

Izolarea defectelor reprezintă o etapă importantă în proiectarea sistemelor de diagnoză a defectelor (FDI – Fault Detection and Isolation). Prin izolare se înțelege determinarea tipului de defect, stabilirea locului producerii și a momentului detecției acestuia în procesul analizat. Astfel, componentele defectate trebuie să fie înlocuite sau "izolate" cât mai curând posibil, pentru a evita propagarea defectului în întregul proces biotehnologic. Cu toate acestea, metodele clasice de diagnoză utilizate în stațiile de epurare a apelor uzate nu s-au dovedit a fi foarte eficiente pentru a controla funcționarea și dinamica internă a proceselor. Prin urmare, nu este surprinzător faptul că există o creștere a numărului de lucrări în care sunt prezentate diverse tehnici avansate de izolare a defectelor.

Acestea pot fi împărțite în trei categorii principale: metode bazate pe cunoștințe, metode bazate pe modele analitice și metode de recunoaștere a formelor. Fiecare dintre ele reprezintă o combinație a unui anumit tip de cunoaștere a priori și prezintă diverse avantaje și limitări pentru o aplicație particulară sau a unui anumit proces studiat [152], [153].

Metodele de recunoaștere a formelor pot fi statistice [154], [155] (clasificatori parametrici sau neparametrici) sau deterministe (rețele neuronale de clasificare). Acestea folosesc informații privind istoricul proceselor, iar avantajul lor principal îl constituie performanțele lor în timp real, facilitatea achiziției de cunoștințe și aplicabilitatea acestora într-o varietate mare de sisteme. Pe de altă parte, acestea prezintă limitări în ceea ce privește capacitatea de generalizare în afara domeniului de antrenare și întâmpină dificultăți în identificarea defectelor multiple.

Una dintre aceste metodologii, și anume aceea care utilizează rețele neuronale artificiale, și-a demonstrat capabilitățile în ceea ce privește modelarea, controlul și diagnoza sistemelor complexe prin prelucrarea de date incomplete sau incerte [111], [134], [157] – [160]. Cu toate acestea, s-a acordat mai puțină atenție aplicării lor în scopul detecției, izolării și supravegherii defectelor din sistemele biotehnologice.

4.2 Metodă de recunoaștere a defectelor cu rețele neuronale într-o stație de epurare a apelor uzate

În această secțiune se descrie o metodă de recunoaștere cu rețele neuronale pentru a clasifica defectele care pot să apară într-o stație de epurare a apelor uzate. Procesul de tratare a apelor uzate este prezentat în detaliu în secțiunea 2.3.3 din capitolul 2. Conform cu [161], tratarea apelor uzate este un proces complex, în care senzorii și echipamentele funcționează în condiții dure, și, adesea, există întâzieri destul de mari privind răspunsul variabilelor la perturbații. Trebuie menționat faptul că izolarea defectelor s-a făcut numai pentru defectele echipamentelor de câmp (traductoare și elemente de execuție, defecte nete și parțiale), nu și pentru defecte care țin de natura procesului de tratare (proces biotehnologic foarte complex), așa cum s-a arătat în capitolul 3 – defect datorat unui șoc toxic în cultura de microorganisme.

4.2.1 Schema de diagnoză a defectelor

După cum se observă în schema de diagnoză (Fig. 4.1) a defectelor propusă în această secțiune, intrările rețelei neuronale artificiale de recunoaștere a patternurilor defectelor sunt: variabilele de intrare (D, W, r, b, S_{in}), variabilele de ieșire (X, S, DO, X_r) și istoricul pe ultimele 10 eșantioane al acestora. La ieșire se obține rezultatul recunoașterii fiecărui caz de defect considerat.

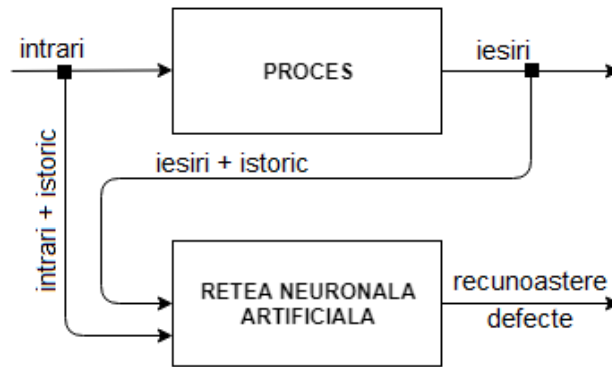


Fig. 4.1 - Schema de diagnoză a defectelor

4.2.2 Proiectarea rețelei neuronale de recunoaștere a defectelor

Pentru izolarea defectelor se proiectează o rețea neuronală artificială feedforward cu rol de clasificator. Etapele de proiectare ale rețelei neuronale artificiale pentru recunoașterea defectelor sunt similare cu cele din secțiunea 2.3.4, din capitolul 2.

Funcția de activare este *sigmoid (logsig)* pentru stratul ascuns și stratul de ieșire (cu valorile la ieșire de 0 și 1). Pentru antrenarea rețelei se utilizează un algoritm de antrenare de tip Backpropagation, bazat pe o metodă de minimizare de tip gradient conjugat (funcția din Matlab - *trainscg*), de asemenea cunoscută și sub denumirea de "Scaled conjugate gradient backpropagation". Funcția de performanță aleasă pentru procesul de antrenare este eroarea medie patrică (MSE – Mean Square Error).




Fig. 4.2 - Structura rețelei neuronale artificiale de recunoaștere a defectelor din procesul de tratare a apelor uzate

Pentru instruirea rețelei neuronale, setul de date de intrare este o matrice P de dimensiuni 90×10889 . Fiecare coloană reprezintă un exemplu care conține 90 de valori: variabilele de intrare (D, W, r, b, S_{in}), variabilele de ieșire (X, S, DO, X_r) și istoricul pe ultimele 10 eșantioane al acestora. Pentru instruire, sunt considerate în total 7623 de exemple, adică 70% din numărul total de exemple din setul de intrare. Datele sunt obținute prin simularea numerică a modelului analitic.

Setul de date de la ieșire este o matrice T de dimensiuni 7×10889 (7 clase distincte). Fiecare coloană este un vector coloană de 7 elemente care conține valori de 0 și 1, astfel:

- $[1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0]^T$ - Vectorul aparține clasei 1 (funcționare normală);
- $[0 \ 1 \ 0 \ 0 \ 0 \ 0 \ 0]^T$ - Vectorul aparține clasei 2 (defect al pompei de recirculare);
- $[0 \ 0 \ 1 \ 0 \ 0 \ 0 \ 0]^T$ - Vectorul aparține clasei 3 (defect al pompei de alimentare);
- $[0 \ 0 \ 0 \ 1 \ 0 \ 0 \ 0]^T$ - Vectorul aparține clasei 4 (defect al pompei de exces de nămol);
- $[0 \ 0 \ 0 \ 0 \ 1 \ 0 \ 0]^T$ - Vectorul aparține clasei 5 (defect al traductorului de biomasă);
- $[0 \ 0 \ 0 \ 0 \ 0 \ 1 \ 0]^T$ - Vectorul aparține clasei 6 (defect al traductorului de oxigen dizolvat);
- $[0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 1]^T$ - Vectorul aparține clasei 7 (defect parțial al pompei de alimentare).

Tabelul 4.1 - Distribuția pe clase a numărului de exemple din setul de date de instruire, validare și testare

Seturi de date	Clasa 1	Clasa 2	Clasa 3	Clasa 4	Clasa 5	Clasa 6	Clasa 7	Total
Set de intrare	4289	1091	1100	1100	1100	1100	1109	10889 (100%)
Instruire	3019	753	760	763	771	779	778	7623 (70%)
Validare	637	165	170	163	161	154	183	1633 (15%)
Testare	633	173	170	174	168	167	148	1633 (15%)




Fig. 4.4 - Evoluția erorii MSE pe durata instruirii

4.2.3 Rezultatele instruirii, testării și validării rețelei neuronale

În urma instruirii rețelei neuronale se obține *matricea de confuzie* din Fig. 4.5:

Training Confusion Matrix

	1	2	3	4	5	6	7	
1	3019 39.6%	37 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	98.8% 1.2%
2	0 0.0%	572 7.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	760 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	82 1.1%	0 0.0%	731 9.6%	0 0.0%	0 0.0%	0 0.0%	89.9% 10.1%
5	0 0.0%	7 0.1%	0 0.0%	29 0.4%	770 10.1%	0 0.0%	0 0.0%	95.5% 4.5%
6	0 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	778 10.2%	0 0.0%	99.9% 0.1%
7	0 0.0%	54 0.7%	0 0.0%	3 0.0%	1 0.0%	1 0.0%	777 10.2%	92.9% 7.1%
	100% 0.0%	76.0% 24.0%	100% 0.0%	95.8% 4.2%	99.9% 0.1%	99.9% 0.1%	99.9% 0.1%	97.2% 2.8%
	1	2	3	4	5	6	7	

Target Class

Fig. 4.5 - Matricea de confuzie pentru setul de antrenare a rețelei neuronale

Procentul de recunoaștere corectă a celor 7 clase este de 97.2% iar procentul de recunoaștere incorectă este de 2.8%.

Tabelul 4.2 - Procentele de recunoaștere pentru antrenarea rețelei neuronale

Clasa	Nr. de exemple	TP [%]	FP [%]	TN [%]	FN [%]
1	3019	98.75	1.25	100	0
2	753	100	0	97.43	2.57
3	760	100	0	100	0
4	763	89.91	10.09	99.53	0.47
5	771	95.53	4.47	99.98	0.02
6	779	99.87	0.13	99.98	0.02
7	778	92.94	7.06	99.98	0.02

Din tabelul 4.2 rezultă că s-au obținut cele mai bune procente de recunoaștere pentru clasa 3 și clasa 6, având procente foarte bune de recunoaștere *true* (clasa 3: $TP = 100\%$, $TN = 100\%$; clasa 6: $TP = 99.87\%$, $TN = 99.98\%$) și valori mici pentru procentele de recunoaștere *false* (clasa 3: $FP = 0.13\%$, $FN = 0.02\%$; clasa 6: $FP = 0\%$, $FN = 0.05\%$).

Validarea rețelei neuronale - matricea de confuzie din Fig. 4.6:




Fig. 4.6 - Matricea de confuzie pentru setul de validare a rețelei neuronale

Procentul de recunoaștere corectă a celor 7 clase este de 97.4% iar procentul de recunoaștere incorectă este de 2.6%.

Tabelul 4.3 - Procentele de recunoaștere pentru validarea rețelei neuronale

Clasa	Nr. de exemple	TP [%]	FP [%]	TN [%]	FN [%]
1	637	98.91	1.09	100	0
2	165	98.49	1.51	97.73	2.27
3	170	100	0	100	0
4	163	92.81	7.19	99.45	0.55
5	161	95.26	4.74	100	0
6	154	98.71	1.29	100	0
7	183	94.32	5.68	100	0

Din tabelul 4.3 rezultă că s-au obținut cele mai bune procente de recunoaștere pentru clasa 1 și clasa 3.

Testarea rețelei neuronale - matricea de confuzie din Fig. 4.7:

Test Confusion Matrix

Output Class	1	632 38.7%	2 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 0.2%	99.2% 0.8%
	2	0 0.0%	139 8.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	170 10.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	21 1.3%	0 0.0%	169 10.3%	0 0.0%	0 0.0%	0 0.0%	88.9% 11.1%
	5	0 0.0%	1 0.1%	0 0.0%	5 0.3%	168 10.3%	0 0.0%	0 0.0%	96.6% 3.4%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	167 10.2%	0 0.0%	100% 0.0%
	7	1 0.1%	10 0.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	145 8.9%	92.9% 7.1%
			99.8% 0.2%	80.3% 19.7%	100% 0.0%	97.1% 2.9%	100% 0.0%	100% 0.0%	98.0% 2.0%
		1	2	3	4	5	6	7	
		Target Class							

Fig. 4.7 - Matricea de confuzie pentru setul de testare a rețelei neuronale

Din tabelul 4.4 rezultă că s-au obținut cele mai bune procente de recunoaștere pentru clasa 3 și clasa 6.

Tabelul 4.4 - Procentele de recunoaștere pentru testarea rețelei neuronale

Clasa	Nr. de exemple	TP [%]	FP [%]	TN [%]	FN [%]
1	633	99.21	0.79	99.89	0.01
2	173	100	0	97.72	2.28
3	170	100	0	100	0
4	174	88.94	11.06	99.65	0.35
5	168	96.55	3.45	100	0
6	167	100	0	100	0
7	148	92.94	7.06	99.79	0.21

Analiza globală pe întreg setul de date de intrare:

Din matricea de confuzie din Fig. 4.8 reiese ca rețeaua neuronală clasifică corect datele în cele 7 clase, în proporție de 97.2%.

Overall Confusion Matrix

Output Class	1	4288 39.4%	46 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 0.0%	98.8% 1.2%
	2	0 0.0%	842 7.7%	0 0.0%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	99.8% 0.2%
	3	0 0.0%	0 0.0%	1100 10.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	115 1.1%	0 0.0%	1055 9.7%	0 0.0%	0 0.0%	0 0.0%	90.2% 9.8%
	5	0 0.0%	10 0.1%	0 0.0%	40 0.4%	1099 10.1%	0 0.0%	0 0.0%	95.6% 4.4%
	6	0 0.0%	3 0.0%	0 0.0%	0 0.0%	0 0.0%	1099 10.1%	0 0.0%	99.7% 0.3%
	7	1 0.0%	75 0.7%	0 0.0%	3 0.0%	1 0.0%	1 0.0%	1105 10.1%	93.2% 6.8%
			100.0% 0.0%	77.2% 22.8%	100% 0.0%	95.9% 4.1%	99.9% 0.1%	99.9% 0.1%	99.6% 0.4%
		1	2	3	4	5	6	7	
		Target Class							

Fig. 4.8 - Matricea de confuzie pentru întregul set de intrare

Analiza pe baza curbelor ROC ("Receiver Operating Characteristic" – caracteristica de funcționare a receptorului)




Fig. 4.9 - Curba ROC pentru setul de 7623 date de antrenare




Fig. 4.10 - Curba ROC pentru setul de 1633 date de validare




Fig. 4.11 - Curba ROC pentru setul de 1633 date de test

Din curbele ROC reiese că rata de recunoaștere cea mai scăzută se înregistrează pentru clasa 2 și clasa 4. În rest, se observă că pentru celelalte clase se obține o precizie de recunoaștere foarte bună, mai ales pentru clasele 1, 3 și 6.

Concluzii finale

Odată cu creșterea gradului de poluare și dezvoltarea societății moderne din ultimii ani, folosirea proceselor biotehnologice a devenit vitală pentru durabilitatea și protecția mediului înconjurător. În zilele de astăzi, prevenirea poluării, minimizarea deșeurilor în activitățile industriale, urbane și agricole, precum și încurajarea procesului de reciclare, au devenit prioritare. Tehnologiile folosite în domeniul biotehnologiei sunt multiple dar unele din cele mai des întâlnite sunt procesele de tratare a apelor uzate care au un rol determinant în reducerea cantităților de materii organice și solide aflate în suspensie în apă, prin tratamente adecvate pentru a purifica apa înainte de a fi deversată în orice receptor (mare, râu, lac etc.).

Așadar, pe lângă metodele de monitorizare și control, diagnoza defectelor a devenit din ce în ce mai importantă pentru a realiza o funcționare robustă și eficientă din punct de vedere al utilizării resurselor instalațiilor de tratare a apelor uzate. Procesele de epurare a apelor uzate sunt sisteme foarte complexe care pot fi afectate de diverse perturbații și zgomote în timpul funcționării normale, fiind susceptibile la apariția diferitelor defecte care pot compromite funcționarea corectă a acestora. Defectele care se pot produce într-o stație de tratare a apelor uzate sunt: mecanice/electrice (defecte ale echipamentului din cauza unor probleme mecanice sau electrice), chimice (pH-ul, oxigenul dizolvat sau concentrațiile altor substanțe chimice necunoscute modificate), biologice (biomasa a fost afectată – de ex. contaminată) sau operaționale (datorită lipsei de personal instruit). Funcționarea corectă a senzorilor și a elementelor de execuție este importantă pentru controlul eficient al acestor procese din punct de vedere al performanțelor de tratare și al utilizării resurselor energetice. O funcționare robustă și performantă necesită un control automat care, la rândul său, are nevoie de o funcționare fiabilă și precisă a senzorilor care transmit informații corecte din proces. Dacă sistemul de automatizare folosește traductoare sau elemente de execuție defecte, se ajunge rapid la pierdere de resurse (materie primă și energie) sau la devierea procesului, pînă la ieșirea din funcțiune.

În prezenta teză de doctorat, se propune, în primul rând, o metodă de modelare cu rețele neuronale a unui proces de tratare a apelor uzate cu nămol activ. Modelul neuronal este util pentru predicția ieșirilor procesului. Avantajul folosirii acestei metode constă în faptul că, pentru a obține o capacitate de predicție foarte bună, nu sunt necesare cunoștințe anterioare, cu privire la modelul matematic al procesului, ci se folosesc doar datele înregistrate în proces. Dezavantajul este că volumul de date necesar este foarte mare. Ele trebuie să caracterizeze procesul în toate regimurile de funcționare în care va fi exploatat modelul.

De asemenea, s-au implementat două metode de detecție a defectelor bazate pe model, pentru un proces de epurare a apelor uzate cu nămol activ. Sunt analizate două situații: 1. mărimile de ieșire ale procesului sunt considerate măsurabile și 2. unele dintre mărimile de ieșire ale procesului sunt nemăsurabile. Prima metodă folosește o rețea neuronală ca model, pentru predicția ieșirilor procesului, în condiții de funcționare normală. Detecția se realizează pe baza reziduurilor, calculate ca mediile pătratelor abaterilor între ieșirile procesului și cele ale rețelei neuronale. Cea de a doua metodă de detecție folosește un filtru Kalman extins pentru estimarea ieșirilor care nu sunt măsurabile. În funcție de valorile reziduurilor se stabilește dacă a apărut un defect în proces. În cazul fiecărei metode se fac recomandări specifice privind procedura de configurare a parametrilor metodelor de detecție, în așa fel încât să se reducă numărul de alarme false, să se îmbunătățească timpul de detecție și să funcționeze chiar și în situația în care procesul este puternic afectat de zgomot. Alegerea parametrilor de detecție (pragul de sensibilitate la defect și orizontul pe care se calculează reziduurile) s-a realizat prin două abordări: una teroretică, bazată pe teoria deciziei statistice, fiind analizate trei ipoteze, și a doua, bazată pe metode euristice. Validarea metodelor de detecție s-a realizat prin simulări numerice, analizând diferite tipuri de defecte nete și parțiale ale elementelor de execuție sau ale traductoarelor, inclusiv

defecte care se datorează unor evoluții nefavorabile, din punct de vedere metabolic sau biochimic, pentru procesul de tratare. În simulările realizate s-a reușit detectarea corectă a fiecărui defect care a intervenit în proces, obținându-se rezultate foarte bune, comparativ cu alte studii.

Pe partea de izolare a defectelor, s-a realizat un algoritm de recunoaștere a unor defecte care pot apărea într-un proces de tratare a apelor uzate, folosind o rețea neuronală cu rol de clasificator. Primul pas a constat în colectarea datelor prin simulări numerice pentru construirea seturilor de date necesare antrenării, testării și validării algoritmului de recunoaștere. A fost necesar un set de date experimentale suficient de mare care să conțină date reprezentative pentru toate cazurile de defecte analizate, astfel încât rețeaua neuronală să aibă o rată de recunoaștere corectă foarte bună. Pentru izolarea defectelor s-a constatat că este suficient să se proiecteze o rețea neuronală artificială feedforward. Din rezultatele obținute, a rezultat că rețeaua neuronală are o rată a clasificării corecte, mediată pe toate cazurile considerate, de 97,2%.

Contribuții originale ale tezei de doctorat

În cadrul tezei de doctorat s-au realizat următoarele contribuții originale:

1. Determinarea unui model neuronal de tip feedforward care aproximează funcționarea unui proces de tratare a apelor uzate.
2. Analiza unei stații de epurare biologică a apelor uzate de laborator și a posibilelor defecte hardware caracteristice proceselor de tratare a apelor uzate.
3. Realizarea unei analize teoretice privind alegerea parametrilor algoritmilor de detecție (pragul de sensibilitate, ϵ , și orizontul de calcul al reziduurilor, N), analiză bazată pe teoria deciziei statistice.
4. Implementarea unei metode de detecție a defectelor într-o stație de tratare a apelor uzate, folosind o rețea neuronală ca model, pentru predicția ieșirilor procesului, în condiții de funcționare normală (fără defecte). În acest caz, se consideră că toate mărimile de ieșire ale procesului sunt măsurabile. Reziduurile se generează pe baza comparației dintre ieșirile măsurate și ieșirile predictorului. Procedura de alegere a parametrilor automatului de detecție urmărește maximizarea performanței (sensibilitate mare la defect, timp de detecție mic, evitarea alarmelor false).
5. Validarea metodei de detecție cu rețea neuronală prin simulări numerice pentru diferite tipuri de defecte nete și parțiale ale elementelor de execuție sau traductoarelor, precum și pentru un defect care se datorează evoluției procesului de tratare, din punct de vedere al metabolismului nămolului din stația de tratare.
6. Implementarea unui algoritm de detecție a defectelor cu filtrul Kalman extins, aplicat la o stație de epurare a apelor uzate. Se presupune că sunt măsurabile doar două mărimi de stare (concentrația de biomasă și cea de oxigen dizolvat), celelalte două fiind estimate folosind filtrul Kalman extins. Se aplică principiul generării reziduurilor pentru detecția defectelor din proces.
7. Determinarea, pe cale euristică, a parametrilor algoritmului de detecție, astfel încât să se obțină rezultate bune ale detecției.
8. Validarea metodei de detecție cu filtru Kalman extins, prin simulări numerice, pentru diferite cazuri de defecte nete și parțiale, care pot apărea în procesul studiat.
9. Realizarea unui algoritm de recunoaștere (izolare) a defectelor nete și parțiale ale elementelor de execuție și ale traductoarelor, într-un proces de tratare a apelor uzate, folosind rețele neuronale de clasificare.
10. Configurarea parametrilor, instruirea, testarea și validarea rețelei neuronale cu rol de clasificator, astfel încât să se obțină performanțe foarte bune de recunoaștere a defectelor, pentru toate cazurile de defecte (nete și parțiale) considerate.

11. Analiza performanțelor unui clasificator de defecte în cazul particular al stației de tratare a apelor uzate pentru îndepărtarea substanțelor organice pe baza matricilor de confuzie.

Direcții viitoare de cercetare

Având în vedere rezultatele obținute în cadrul acestei teze de doctorat, cercetările se pot extinde în următoarele direcții:

- Îmbunătățirea erorii de predicție a modelului neuronal care descrie funcționarea unei stații de tratare a apelor uzate.
- Extinderea metodei de detecție cu filtru Kalman extins și a metodei de detecție cu rețea neuronală și pentru alte tipuri de defecte.
- Îmbunătățirea rezultatelor obținute în cazul metodei de recunoaștere a defectelor cu rețea neuronală într-o stație de epurare a apelor uzate, prin mărirea setului de antrenare, și astfel, extinderea domeniului de aplicabilitate.
- Reluarea cercetărilor din teza de doctorat pentru procese de tratare mult mai complexe, care îndepărtează azotul și compuși ai acestuia, precum și fosforul din apa uzată.
- Aplicarea metodelor de detecție și recunoaștere în cadrul altor procese biotehnologice.

Diseminarea rezultatelor

Rezultatele cercetărilor din cadrul studiilor doctorale au fost prezentate în următoarele articole publicate:

1. **Mihaela Miron**, Laurentiu Frangu, George Ifrim, Sergiu Caraman, "Modeling of a Wastewater Treatment Process Using Neural Networks", 20th International Conference on System Theory, Control and Computing - ICSTCC 2016, October 13-15 2016, Sinaia, Romania, pp. 210 – 215, **ISI Proceedings - IEEE**;
2. **Mihaela Miron**, Laurențiu Frangu, Sergiu Caraman, „Actuator fault detection using extended Kalman filter for a wastewater treatment process”, 21st International Conference on System Theory, Control and Computing, October 19 - 21, 2017, Sinaia, Romania, pp. 583-588, **ISI Proceedings - IEEE**;
3. **Mihaela Miron**, Laurentiu Frangu, Sergiu Caraman, "Fault detection method for a wastewater treatment process based on a neural model," *2017 5th International Symposium on Electrical and Electronics Engineering (ISEEE)*, October 20 – 22, 2017, Galati, Romania, pp. 1-6, Galati Romania, **BDI – IEEE**.
4. Laurentiu Baicu, Sergiu Caraman, Laurentiu Frangu, **Mihaela Miron**, "Measurement of the biomass concentration from a bioprocess by image processing techniques", The 5th International Symposium On Electrical And Electronics Engineering (ISEEE), October 20 – 22, 2017, Galati Romania, **BDI – IEEE**.
5. **Mihaela Miron**, Laurențiu Frangu, Sergiu Caraman, "Artificial neural network approach for fault recognition in a wastewater treatment process", 22nd International Conference on System Theory, Control and Computing, October 10 - 12, 2018, Sinaia, Romania, **ISI Proceedings – IEEE**, lucrare acceptată.
6. Laurențiu Luca, Marian Barbu, George Ifrim, Emil Ceanga, **Mihaela Miron**, Sergiu Caraman, "Fuzzy control of a microalgae process in photobioreactors", 22nd International Conference on System Theory, Control and Computing, October 10 - 12, 2018, Sinaia, Romania, **ISI Proceedings – IEEE**, lucrare acceptată.

Toate lucrările menționate sunt indexate ISI Proceedings și IEEE-Xplore.

Bibliografie

- [1] Henze M., Grady Jr. C.P.L., Gujer W., Marais G.v.R., Matsuo T., "Activated Sludge Model No. 1", IAWQ Scientific and Technical Report No.1, IAWQ, London, UK, 1987.
- [2] Henze, M., Gujer, W., Mino, T., Matsuo, T., Wentzel, M.C.and Marais, G.v.R., "Activated Sludge Model No. 2.", IAWQ Scientific and Technical Report No. 3, London, 1995.
- [3] Henze M., Gujer W., Mino T. and van Loosdrecht M., "Activated sludge models AMS1, ASM2, ASM2d and ASM3", IWA STR No. 9, IWA Publishing, London, UK, 2000.
- [4] Patton R. J., Frank P. M., Clark R. N., "Issues of Fault Diagnosis for Dynamic Systems", Springer Verlag, London, 2000.
- [5] R. Isermann, "Trends in the application of model-based fault detection and diagnosis of technical processes," *Control Eng. Practice*, vol. 5, no. 5, 1997, pp. 709–719.
- [6] D. V. Schrick, "Remarks on terminology in the field of supervision, fault detection and diagnosis," in *Proc. IFAC Symp. Fault Detection, Supervision Safety for Techn. Process. (SAFEPROCESS)*, 1997, pp. 959–964.
- [7] Inseok Hwang, Sungwan Kim, *Senior Member, IEEE*, Youdan Kim, *Member, IEEE*, and Chze Eng Seah, "A Survey of Fault Detection, Isolation, and Reconfiguration Methods", *IEEE Transactions on control systems technology*, VOL. 18, NO. 3, MAY 2010, pp. 636 – 653.
- [8] F. Nejjari, V. Puig, L. Giancristofaro S. Koehler," Extended Luenberger Observer-Based Fault Detection for an Activated Sludge Process" Proceedings of the 17th World Congress the International Federation of Automatic Control Seoul, Korea, July 6-11, 2008, pp. 9725 – 9730.
- [9] Chen J. and Patton R.J., "Robust Model-Based Fault Diagnosis for Dynamic Systems", Kluwer Academic Publisher, London, 1999.
- [10] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W., "Fault Diagnosis. Models, Artificial Intelligence, Applications", Heidelberg: Springer-Verlag, Berlin, 2004.
- [11] Korbicz J., "Advances in fault diagnosis systems", *Proc. 10th Int. IEEE Conf. Methods and Models in Automation and Robotics, MMAR*, Międzyzdroje, Poland, Vol. 2, 2004, pp. 725–734.
- [12] Arinton E., Teză de doctorat – "Utilizarea rețelelor neuronale în diagnoza defectelor pentru procese dinamice neliniare", Universitatea "Dunărea de Jos", Facultatea de Inginerie Electrică și Electronică, Școala doctorală "Inginerie electrică și Electronică", Galați, 2010.
- [13] Calado J.M.F., Louro R., Mendes M.J.G.C., Sá da Costa J.M.G., Kowal M., "Fault isolation based on HSFNN applied to DAMADICS benchmark problem", *Proc. 15th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes, SAFEPROCESS*, Washington, D.C., USA, June 9–11 2003, pp. 1053–1058.
- [14] Kowal M. and Korbicz J., "Neuro-fuzzy detector for industrial process. – Fuzzy control : theory and practice", Heidelberg: Physica-Verlag, *Advances in Soft Computing*, 2000, pp. 294–301.

- [15] Kowal M., Korbicz J., Mendes M.J.G.C., Calado J.M.F., "Fault detection using neuro-fuzzy networks", *Systems Science*, Vol. 28, No. 1, 2002, pp. 45–57.
- [16] Isermann, R. and Ballé, P. Trends in the application of model-based fault detection and diagnosis in technical processes. *Control Engineering Practice – CEP*, 5(5):638–652, 1997.
- [17] Isermann, R. *Fault-diagnosis systems – An introduction from fault detection to fault tolerance*. Springer, Heidelberg, 2006.
- [18] Denis Dochain, "Automatic Control of Bioprocesses", John Wiley & Sons, 2008, Science - 288 pages, ISBN: 978-1-84821-025-7, pp. 214.
- [19] F. Baggiani and S. Marsili-Libelli, "Real time fault detection and isolation in biological wastewater treatment plants", *Water Science & Technology—WST*, 60.11.2009, pp. 2949 – 2961.
- [20] Antoine Genovesi, Jérôme Harmand and Jean – Philippe Steyer, "Integrated Fault Detection and Isolation: Application to a Winery's Wastewater Treatment Plant", *Applied Intelligence* 13, 2000, pp. 59–76.
- [21] Mihaela Miron, Laurențiu Frangu, Sergiu Caraman, "Actuator Fault Detection using Extended Kalman Filter for a Wastewater Treatment Process", accepted to 21st International Conference on System Theory, Control and Computing, October 19 – 21, 2017, Sinaia, Romania.
- [22] T. Escobet, V. Puig, J. Quevedo, D. Garcia, "A methodology for incipient fault detection", *Control Applications (CCA)*, 2014 IEEE Conference, Juan Les Antibes, France, 8-10 Oct. 2014.
- [23] I. Roychoudhury, G. Biswas and X. Koutsoukos, "A Bayesian Approach to Efficient Diagnosis of Incipient Faults", *Prod. 17th international Workshop on Principles of Diagnosis Penãranda de Duero Spain*, 2006.
- [24] Y. Zhang and J. Jiang, "Bibliographical review on reconfigurable fault-tolerant control systems ", *Annual Reviews in Control* vol. 32 no.2, 2008, pp. 229-252.
- [25] V. Hölttä and H. Koivo, "Quality index framework for plant-wide performance evaluation", *Journal of Process Control* vol. 19 no. 7, 2009, pp. 1143-1148.
- [26] R. Patton, P. Frank, and R. Clark, *Fault diagnosis in dynamic systems: theory and application*, New York, 1989.
- [27] W. Ge and Z. Fang, "Detection of faulty components via robust observation", *International journal of control*, vol. 47, 1988, pp. 581-599.
- [28] J. Chen, R. Patton and H. Zhang, "Design of unknown input observers and robust fault detection filters," *International journal of control*, vol. 63, 1996, pp. 85-105.
- [29] X. Ding, L. Guo and P. Frank, "Parametrization of linear observers and its application to observer design," *IEEE Transactions on Auto-matic Control*, vol. 39, 1994, pp. 1648-1652.
- [30] J. Gertler, "Analytical redundancy methods in fault detection and isolation," *in Proc. IFAC/IMACS Symposium, Safeprocess '91*, Ba-den-Baden, 1991, pp. 9-21.
- [31] Teodorescu H.N., Mlynek D., Kandel A. and Zimmermann H.J., "Intelligent Systems and Interfaces Series", Kluwer Academic Publishers, London, 2000.

- [32] MJ. Fuente, P. Vega, M. Zarrop, M. Poch, "Fault detection in a real wastewater plant using parameter – estimation techniques", *Control Eng. Practice*, Vol. 4, No. 8, 1996, pp. 1089-1098.
- [33] R. Isermann, "Supervision, fault detection and fault diagnosis methods: an introduction," *Control Engineering Practice*, vol. 5, no. 5, 1997, pp. 639 - 652.
- [34] A. Pouliezos, G. Stavrakakis and C. Leafas, "Fault Detection using parameter estimation", *Quality and Reliability Engineering International*, VOL. 5, 1989.
- [35] Venkat Venkatasubramanian, Raghunathan Rengaswamy, Kewen Yin, Surya N. Kavuri, "A review of process fault detection and diagnosis Part I: Quantitative model-based methods", *Computers and Chemical Engineering* 27, 2003, pp. 293-311.
- [36] Isermann R., "Process fault detection based on modelling and estimation methods – A survey.", *Automatica*, Vol. 29, 1984, pp. 387 – 404.
- [37] Teresa Escobet, Loise Travé – Massuyés, "Parameter estimation methods for fault detection and isolation".
- [38] J. Gertler, "Fault detection and isolation using parity relations," *Control Eng. Practice*, vol. 5, no. 5, 1997, pp. 653–661.
- [39] R. J. Patton and J. Chen, "Robust fault detection using eigenstructure assignment: A tutorial consideration and some new results," in *Proc., 39th Conf. Dec. Control*, Brighton, U.K., Dec. 1991, pp. 2242–2247.
- [40] R. J. Patton and J. Chen, "A review of parity space approaches to fault diagnosis for aerospace systems," *J. Guid., Control, Dyn.*, vol. 17, no. 2, 1994, pp. 278–285.
- [41] Gertler J., "Fault detection and Diagnosis in Engineering Systems", Marcel Dekker Inc., New York, 1998.
- [42] Chow E. Y. and Willsky A. S., "Analytical redundancy and the design of robust failure detection systems", *IEEE Trans. Automatic Control*, Vol. 29, 1984, pp. 603 – 614.
- [43] R. Isermann, "Fault-Diagnosis Systems", Springer, Berlin, 2006, pp. 231 – 252.
- [44] R. Isermann, "Model-Based Fault Detection And Diagnosis-Status And Applications", *Annual Reviews in Control*, Vol. 29, Is.1, 2005.
- [45] P. M. Frank, "Fault diagnosis in dynamic systems using analytical and knowledge based redundancy – A survey and some new results", *Automatica*, Vol. 26, 1990, pp. 459 – 474.
- [46] D. N. Wilbers and J. L. Speyer, "Detection filters for aircraft sensor and actuator faults", *Proc. ICCON' 89 Int. Conf. on Control and Applications*, Jerusalem, April 1989.
- [47] Dubravko Miljković, "Fault Detection Methods: A Literature Survey", *The 35th International Convention on Information and Communication Technology, Electronics and Microelectronics MIPRO 2011*, CTS, 21 – 25th May 2011, Croatia, pp. 111.
- [48] Afef Fekih, Hao Xu, Fahmida N. Chowdhury, "Two Neural Net – Learning methods for model-based fault detection", *IFAC Fault Detection, Supervision and Safety of Technical Processes*, Beijing 2006, pp. 72 – 77.
- [49] Rögnvaldsson T., "Learning Self-Organizing Systems Course Notes", Halmstad University, Sweden, 2001.

- [50] Isermann R. and Ballé P., "Trends in the applications of model-based fault detection and diagnosis of technical processes.", *Control Eng. Practice*, Vol. 5, No. 5, 1997, pp. 709–719.
- [51] Kościelny J.M., Syfert M., Bartys M., "Fuzzy-Logic Fault Diagnosis of Industrial Process Actuators.", *International Journal of Applied Mathematics and Computer Science – Zielona Góra : Technical University Press*, Vol. 9, No. 3, 1999.
- [52] Kościelny J.M. and Ostasz A., "Application of causal graph for description of diagnosed process.", *15th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Process — SAFEPROCESS' 2003*, USA, Washington, June 9-11, 2003, pp. 879–884.
- [53] Nyberg M., "Model based diagnosis using structured hypothesis tests.", *IFAC Fault Detection, Supervision and Safety for Technical Processes*, Budapest, Hungary, 2000, pp. 1026–1031.
- [54] Bishop C.M. "Neural Networks for Pattern Recognition", Oxford University Press, Oxford, 1995.
- [55] Dasarthy B., "Nearest Neighbor (NN) Norms: NN Pattern Classification Techniques", IEEE Computer Society Press, Los Alamitos, 1991.
- [56] Guoqiang Peter Zhang, "Neural Networks for Classification: A survey.", *IEEE Transactions on Systems, Man, and Cybernetics - PART C: APPLICATIONS AND REVIEWS*, VOL. 30, NO. 4, NOVEMBER 2000, pp. 451 – 462.
- [57] W. Y. Huang and R. P. Lippmann, "Comparisons between neural net and conventional classifiers," in *IEEE 1st Int. Conf. Neural Networks*, San Diego, CA, 1987, pp. 485–493.
- [58] D. Michie, D. J. Spiegelhalter, and C. C. Taylor, Eds., *Machine Learning, Neural, and Statistical Classification*, London, U.K.: Ellis Horwood, 1994.
- [59] V. Subramanian, M. S. Hung, and M. Y. Hu, "An experimental evaluation of neural networks for classification," *Comput. Oper. Res.*, vol. 20, 1993, pp. 769–782.
- [60] M. D. Richard and R. Lippmann, "Neural network classifiers estimate Bayesian a posteriori probability," *Neural Comput.*, vol. 3, 1991, pp. 461–483.
- [61] R. P. Lippmann, "Pattern classification using neural networks," *IEEE Commun. Mag.*, Nov. 1989, pp. 47–64.
- [62] Frank P.M. and Köppen-Seliger B., "Fuzzy logic and neural network applications to fault diagnosis", *International Journal of Approximate Reasoning*, Vol. 16, No. 1, January 1997, pp. 67–88.
- [63] Marciniak A. and Korbicz J., "Diagnosis system based on multiple neural classifiers", *Bulletin of the Polish Academy of Sciences : Technical Sciences*, Vol. 49, No. 4, 2001, pp. 681–7001.
- [64] Lee, W.S.; D.L. Grosh; F.A. Tillmann and C.H. Lie, "Fault tree analysis, methods and applications - a review", *IEEE Transactions on Reliability*, Vol. R-34, No. 3, 1985, pp. 194-202.
- [65] Torasso, P. and L. Console, "Diagnostic Problem Solving", North Oxford Academic, U.K, 1989.

- [66] Isermann, R. and M. Ulieru, "Integrated Fault Detection and diagnosis", IEEE/SMC Conference "Systems Engineering in the Service of Humans", Le Touquet, France. Vol.1, 1993, pp. 743-748.
- [67] http://www.shiva.pub.ro/FDD/m_rationare.htm
- [68] Pearl, J., Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference. San Mateo, Calif.: Morgan Kaufmann, 1988.
- [69] Ayoubi M. and Isermann R., "Neuro-fuzzy systems for diagnosis. – Fuzzy Sets and Systems", Vol. 89, No. 3, 1997, pp. 289–307.
- [70] Kościelny J.M. and Syfert M., "Fuzzy logic application to diagnostic of industrial processes", 15th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Process – SAFEPROCESS' 2003, USA, Washington, June 9-11 2003, pp. 771–776.
- [71] Caraman S., Barbu M., Carstoiu D., "Sisteme bazate pe cunostinte in conducerea proceselor", Editura Fundatiei Universitare "Dunarea de Jos", Galati, 2005.
- [72] Pănescu D., "Sisteme bazate pe cunostinte - reprezentarea cunoasterii", Editura MATRIXROM, 2000.
- [73] Winston P.H., "Inteligența artificială", Editura tehnica, 1981.
- [74] Baeza, J. A., Ferreira, E. C., & Laufuente, J., "Knowledge-based supervision and control of wastewater treatment plant: a real-time implementation", Water Science and Technology, 41, 2000, pp. 129–137.
- [75] Agneli, Diagnostic Expert Systems: *From Expert's Knowledge to Real-Time Systems*, TMR e-Book, Advanced Knowledge Based Systems: Model, Applications & Research, Vol. 1, 2010, pp. 50–73.
- [76] P.M. Frank, "Handling modelling uncertainty in fault detection and isolation systems", Proc. 9th Int. Conf. IPMU, Annecy, France, 1729–1749 (2002).
- [77] J. Korbicz and C. Cempel (eds.), "Analytical and knowledge-based redundancy in fault detection and diagnosis", Appl. Math. and Comp. Sci., Spec. Issue 3 (3), (1993).
- [78] J.M.F. Calado, J. Korbicz, K. Patan, R.J. Patton, and J.M.G. Sáda Costa, "Soft computing approaches to fault diagnosis for dynamic systems", European Journal of Control 7 (2–3), 2001, pp. 248–286.
- [79] R.J. Patton and J. Korbicz (eds.), "Advances in computational intelligence for fault diagnosis systems", Special Issue of Int. J. Appl. Math. and Comp. Sci. 9 (3), 1999.
- [80] Nelles O., "Non-linear System Identification: From Classical Approaches to Neural Networks and Fuzzy Models", Springer Verlag, Berlin, 2000.
- [81] S. R. Naidu, E. Zafiriou, and T. J. McAvoy, "Use of neural networks for sensor failure detection in a control system," *IEEE Contr. Syst. Mag.*, vol. 10, April 1990, pp. 49-55.
- [82] T. Kohonen, "Self-Organizing Maps", 2nd.Ed., Springer, 1997.
- [83] Haykin S.S., "Neural Networks: A Comprehensive Foundation (2nd Edition)", Prentice Hall, 1998.
- [84] Kohonen T., "Self-Organization and Associative Memory", Springer-Verlag, New York, 1989.

- [85] Ivanov Virginia, Curs "Monitorizarea și diagnoza echipamentelor electrice", cap. 5 – Metode si tehnici avansate de diagnoza, 2015 – 2016, pp.7 – 8.
- [86] Muller J.A., "Self-organization of models - Present state", Proc. Eurosim, Vienna, Austria, 1995, pp. 1149–1154.
- [87] Leonhardt S. and Ayoubi M., "Methods of fault diagnosis", Control Eng. Practice, Vol. 5, No. 5, 1997, pp. 683–692.
- [88] Lopez-Toribio C., Patton R.J. and Uppal F., "Artificial intelligence approaches to fault diagnosis for dynamic systems" – Applied Mathematics Computer Science, Vol. 9, No. 3, 1999, pp. 471–518.
- [89] Uppal F.J., Patton R.J., Palade V., "Neuro-fuzzy based fault diagnosis applied to an electro-pneumatic valve", Proc. of the 15th IFAC World Congress, Barcelona, Spain, July 21-26, 2003, pp. 2483-2488.
- [90] Simani, S., Fantuzzi, C., and Patton, R.J., "Model - based fault diagnosis in dynamic systems using identification techniques", Springer - Verlag London Limited, Great Britain, 2003.
- [91] S Rahman, FAM Yusof, MZA Bakar, "The method review of neuro-fuzzy applications in fault detection and diagnosis system", International Journal of Engineering & Technology 10 (3), 2010, pp. 50-52.
- [92] Chiang, H. L., Russell, L.E., & Braatz, D.R., "Fault detection and diagnosis in industrial systems", Springer, London, Great Britain, 2001.
- [93] Tiponuş Virgil, Căleanu Cătălin - Daniel, "Rețele Neuronale. Arhitecturi si algoritmi", EDITURA POLITEHNICA. Timisoara 2002, ISBN 973-9389-66-X, pp. 121 – 122.
- [94] Dosoftei Constantin – Catalin, "Utilizarea inteligenței computaționale în conducerea proceselor", Teza de doctorat, Universitatea Tehnica "Gh. Asachi" iasi, Facultatea de Automatica si calculatoare, 2009, pp. 40 – 45.
- [95] Zaharie D., "Algoritmi genetici – Curs 4. Algoritmi genetici – mecanisme de incrucisare si mutatie", Arad, 2006, pp. 1 – 2.
- [96] M. Borairi, Wang H., "Actuator and sensor fault diagnosis of non-linear dynamic systems via genetic neural networks and adaptive parameter estimation technique", Proceedings of the 1998 IEEE, International Conference on Control Applications, Trieste, Italy 1 – 4 September 1998, pp. 278 – 282.
- [97] Obuchowicz A., "Evolutionary Algorithms for Global Optimization and Dynamic System Diagnosis", Lubusky Scientific Society, Zielona Góra, 2003.
- [98] F. Nejari, J. Quevedo. Control no lineal adaptivo de un proceso de tratamiento de aguas residuales, Jornadas de Automatica, Tenerife, 2002.
- [99] A. Sanchez-Fernández, M. J. Fuente and G. I. Sainz-Palmero, "Fault detection in wastewater treatment plants using distributed PCA methods," *2015 IEEE 20th Conference on Emerging Technologies & Factory Automation (ETFA)*, Luxembourg, 2015, pp. 1-7.
- [100] J. Alex, L. Benedetti, J. Copp, K.V. Gernay, U. Jeppsson, I. Nopens, M.N. Pons, C. Rosen, J.P. Steyer, and P. Vanrolleghem. Benchmark: Simulation model no. 2 (bsm2). Technical report, Dept. of Industrial Electrical Engineering and Automation. Lund University., 2008.

- [101] Han Honggui , Li Ying , Qiao Junfei, A fuzzy neural network approach for online fault detection in waste water treatment process, *Computers and Electrical Engineering*, v.40 n.7, pp.2216-2226, October 2014.
- [102] Brault JM, Labib RL, Perrier M, Stuart P. Prediction of activated sludge filamentous bulking using ATP data and neural networks. *Can Soc Chem Eng* 2011;89(4):901–13.
- [103] Han HG, Chen QL, Qiao JF. An efficient self-organizing RBF neural network for water quality predicting. *Neural Networks* 2011;24(7):717–25.
- [104] Han HG, Qiao JF. Prediction of activated sludge bulking based on a self-organizing RBF neural network. *J Process Control* 2012;22(6):1103–12.
- [105] Smets IY, Banadda EN, Deurinck J, Renders N, Jenne R, Impe JFV. Dynamic modeling of filamentous bulking in lab-scale activated sludge processes. *J Process Control* 2006;16(3):313–9.
- [106] Brault JM, Labib RL, Perrier M, Stuart P. Prediction of activated sludge filamentous bulking using ATP data and neural networks. *Can Soc Chem Eng* 2011;89(4):901–13.
- [107] M. J. Willis, C. Di Massimo, G. A. Montague, M. T. Tham, and A. J. Morris, “Artificial neural networks in process engineering,” *IEE Proceedings D*, vol. 138, no. 3, pp. 256–266, 1991.
- [108] G. A. Montague, A. J. Morris, and M. T. Tham, “Enhancing bioprocess operability with generic software sensors,” *Journal of Biotechnology*, vol. 25, no. 1-2, pp. 183–201, 1992.
- [109] S. Linko, J. Luopa, and Y.-H. Zhu, “Neural networks as “software sensors” in enzyme production,” *Journal of Biotechnology*, vol. 52, no. 3, pp. 257–266, 1997.
- [110] M. M. Hamed, M. G. Khalafallah, and E. A. Hassanien, “Prediction of wastewater treatment plant performance using artificial neural networks,” *Environmental Modelling and Software*, vol. 19, no. 10, pp. 919–928, 2004.
- [111] Mihaela Miron, Laurentiu Frangu, George Ifrim, Sergiu Caraman, —Modeling of a Wastewater Treatment Process Using Neural Networks, *ICSTCC 2016*, October 13-15 2016, Sinaia, Romania, *IEEE Xplore Digital Library*, ThB3.6 pp. 210.
- [112] FS Mjalli, S Al-Asheh, HE Alfadala, Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance, *Journal of Environmental Management* 83 (3), pp. 329-338, 2007.
- [113] KP Oliveira-Esquerre, M Mori, RE Bruns, “Simulation of an industrial wastewater treatment plant using artificial neural networks”, *Brazilian Journal of Chemical Engineering* 19 (4), pp. 365-370, 2002.
- [114] Haykin, Simon O., “*Neural Networks and Learning Machines*”, Prentice Hall; 3rd ed. ISBN-13 9780131471399, 28.11, 2008.
- [115] Martin Côte, Bernard P. A. Grandjean, Paul Lessard, Jules Thibault, “Dynamic modelling of the activated sludge process: Improving prediction using neural networks”, *Volume 29, Issue 4, April 1995, Pages 995-1004*.
- [116] Yoon-Seok TimothyHong, Michael R. Rosen, Rao Bhamidimarri, “Analysis of a municipal wastewater treatment plant using a neural network-based pattern analysis”, *Volume 37, Issue 7, April 2003, Pages 1608-1618*.

- [117] G. Han, J.-F. Qiao, H.-G. Han, W. Chai, "Optimal control for wastewater treatment process based on Hopfield neural network", *Kongzhi yu Juece/Control and Decision* 29(11):2085-2088 · November 2014.
- [118] Wang, C. G., and D. G. Jamieson, An objective approach to regional wastewater treatment planning, *Water Resour. Res.*, 38(3), doi:10.1029/2000WR000062, 2002.
- [119] Özer Çınar, "New tool for evaluation of performance of wastewater treatment plant: Artificial neural network", Volume 40, Issue 9, September 2005, Pages 2980-2984.
- [120] Hilario López, García, Iván Machón González, "Self-organizing map and clustering for wastewater treatment monitoring", Volume 17, Issue 3, April 2004, Pages 215-225.
- [121] Hong-Gui Han, Qi-li Chen, Jun-Fei Qiao, "An efficient self-organizing RBF neural network for water quality prediction", Volume 24, Issue 7, September 2011, Pages 717-725.
- [122] Hong-Gui Han, Jun-Fei Qiao, Qi-li Chen, "Model predictive control of dissolved oxygen concentration based on a self-organizing RBF neural network", Volume 20, Issue 4, April 2012, Pages 465-476.
- [123] Haykin, S., "Neural Networks. A Comprehensive Foundation", IEEE Press, MacMillian, 1994.
- [124] Iulian B. Ciocoiu, Curs "Adaptive Signal Processing", Facultatea de Electronica, Telecomunicatii si Tehnologia Informatiei, Universitatea Tehnica din Iasi, Romania, pp. 35.
- [125] Dumitrache I., Constantin N., Drăgoicea M., *Rețele neurale. Identificarea și conducerea proceselor*, Ed. Matrix Rom, București, 1999.
- [126] Hagan M.T., Menhaj M., "Training feed-forward networks with the Marquardt algorithm", *IEEE Transactions on Neural Networks* 5 (1994), p. 989–993.
- [127] Raport științific de etapă, director proiect: Sergiu Caraman, "Îmbunătățirea indicatorilor calitativi la tratarea biologică a apelor reziduale din industria alimentară pe baza unor sisteme de conducere avansată" – APEPUR, Grant CEEEX – MENER nr. 717/24.07.2006, pp. 7 -11.
- [128] Îmbunătățirea indicatorilor calitativi la tratarea biologică a apelor reziduale din industria alimentară pe baza unor sisteme de conducere avansată, CEEEX-MENER Nr.717/2006-2008, site: <http://www.aepur.ugal.ro/> (director proiect prof dr.ing. Sergiu Caraman).
- [129] Barbu, M., Contributions to the automatic control of biotechnological processes, PhD Thesis, "Dunarea de Jos" University, Galati, Romania, Noiembrie 2006, 178 pp.
- [130] Dogan, E., et al., Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand, *AIChE Journal – Environmental Progress & Sustainable Energy*, Vol. 27, Issue 4, Dec. 2008, pp. 439-446.
- [131] Hamed, M., et al., Prediction of wastewater treatment plant performance using artificial neural networks, *Environmental Modelling & Software*, Elsevier, Vol. 19, Issue 10, Oct. 2004, pp. 919-928.
- [132] Jack V. Tu, "Advantages and Disadvantages of using Neural Network versus Logistic Regression for Predicting Medical Outcomes", *Journal of Clinical Epidemiology*, Vol. 49, Issue 11, november 1996, pp. 1225-1231.

- [133] Heikki N. Koivo, "Neural networks: Basics using MATLAB Neural Network Toolbox", 2008, pp. 2.
- [134] Kumpati S. Narendra and Kannan Parthasarathy, "Identification and Control of Dynamical Systems using Neural Networks", IEEE Transactions of Neural Networks, Vol. 1, No. 1, march 1990, pp. 6 and pp. 13.
- [135] https://en.wikipedia.org/wiki/Levenberg%E2%80%93Marquardt_algorithm
- [136] E.A. Garcia and P.M. Frank, "Deterministic Nonlinear Observer-Based Approaches to Fault Diagnosis: A Survey", Control Engineering Practice 5(5), p. 663-760, 1997.
- [137] P. M. Frank "Analytical and Qualitative Model-based Fault Diagnosis - A Survey and Some New Results", European Journal of Control 2(1), 6-28, 1996.
- [138] Isermann. Fault diagnosis of machines via parameter estimation and knowledge processign - tutorial paper, Automatica, 29(4): 815–836, 1993.
- [139] M. Blanke, M. Kinnaert, J. Lunze and M. Staroswiecki, "Diagnosis and Fault-Tolerant Control", Springer-Verlag, Berlin Heidelberg, 2003.
- [140] J. J. Gertler. Fault detection and diagnosis in engineering systems Marcel Dekker, Inc., New York, Basel, Hong Kong, 1998.
- [141] J. Chen. and R. J. Patton, "Robust Model-based Fault Diagnosis for Dynamic Systems", Kluwer Academic Publishers, 1999.
- [142] Dubravko Miljković, "Fault Detection Methods: A Literature Survey", The 35th International Convention on Information and Communication Technology, Electronics and Microelectronics MIPRO 2011, CTS, 21 – 25th May 2011, Croatia, pp. 111.
- [143] D. García-Álvarez, "Fault detection using Principal Component Analysis (PCA) in a Wastewater Treatment Plant (WWTP)", pp. 55 – 60, January 2009, Spain.
- [144] Chen, J., Liao, C. M., "Dynamic process fault monitoring based on neural network and PCA". Jour. of Process Control, vol. 12, pp. 277–289, 2002.
- [145] Klancar, G.,D. Jurici, R. Karba., "Robust fault detection based on compensation of the modelling error", International journal of Systems Science, vol. 33, no. 2, pp. 97–105, 2002.
- [146] Dejan Dovžan, Vito Logar, Nadja Hvala, Igor škrjanc, "Monitoring and sensor fault detection in a waste-water treatment process based on a fuzzy model", ELEKTROTEHNIŠKI VESTNIK 78(3): pp. 142–146, 2011.
- [147] <http://www.shiva.pub.ro/FDD/detectie&diagnoza.htm>.
- [148] R.O. Duda, P.E. Hart: Pattern Classification and Scene Analysis, Ed. John Wiley, 1973.
- [149] Recunoașterea formelor și prelucrarea imaginilor, Ed. Academica, Galați, 2001
- [150] Mihaela Miron, Laurentiu Frangu, Sergiu Caraman, "Fault detection method for a wastewater treatment process based on a neural model," *2017 5th International Symposium on Electrical and Electronics Engineering (ISEEE)*, October 20 – 22, 2017, Galati, Romania, pp. 1-6, Galati Romania.
- [151] Salowa Methnani, Frédéric Lafont, Jean-Paul Guathier, Tarak Damak, Ahmed Toumi, "Actuator and Sensor Fault Detection, Isolation and Identification in Nonlinear Dynamic Systems, with an Application to a Waste Water Treatment Plant", Journal of Computer Engineering and Informatics, Vol. 1 Iss. 4, pp. 112-125, 2013.

- [152] V. Venkatasubramanian, "Towards integrated process supervision: Current status and future directions," in *Proceedings of the IFAC International Conference on Computer Software Structures*, Lund, Sweden, 1994, pp. 1–13.
- [153] Antoine Genovesi, Jérôme Harmand, Jean-Philippe Steyer, "Integrated Fault Detection and Isolation: Application to a Winery's Wastewater Treatment Plant", *Applied Intelligence*, 2000, Volume 13, Number 1, Page 59.
- [154] M. Basseville, "On-board component fault detection and isolation using the statistical local approach," in *Proceedings of the Eleventh IFAC/IFORS International Symposium on Identification and System Parameter Estimation, SYSID'97*, Katakayushu, Japan, 1997.
- [155] D. Garcia-Alvarez, M.J. Fuente, P. Vega and G. Sainz, "Fault Detection and Diagnosis using Multivariate Statistical Techniques in a Wastewater Treatment Plant", *Journal: IFAC Proceedings Volumes*, 2009, Volume 42, Number 11, Page 952.
- [156] G. Stephanopoulos and C. Han, "Intelligent systems in process engineering: A review," *Comp. Chem. Engng.*, vol. 20, nos. 6–7, pp. 743–791, 1996.
- [157] Boger Z., "Application of a Neural Networks to Water and Wastewater Treatment Plant Operation", *ISA Transactions*, Vol.31, Pp. 25-33, 1992.
- [158] Chiroșcă A., Dumitrașcu G, Ifrim G., Titica M., Caraman S., An analysis concerning the robust control of the biological wastewater treatment processes using fuzzy techniques, *ICSSTC 2012*.
- [159] Dogan, E., et al., Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand, *AIChE Journal – Environmental Progress & Sustainable Energy*, Vol. 27, Issue 4, Dec. 2008, pp. 439-446.
- [160] Hamed, M., et al., Prediction of wastewater treatment plant performance using artificial neural networks, *Environmental Modelling & Software*, Elsevier, Vol. 19, Issue 10, Oct. 2004, pp. 919-928.
- [161] G.M. Zeng, X.D. Li, R. Jiang, J.B. Li, and G.H. Huang, "Fault Diagnosis of WWTP Based on Improved Support Vector Machine", *Environmental Engineering Science*. November 2006, 23(6): 1044-1054.