

DEZVOLTAREA UNUI MODEL DE PREDICȚIE A PRESIUNII ÎN SISTEMELE PIEZO COMMON- RAIL DISESEL BAZAT PE REȚELE NEURO-FUZZY CU MODELE DINAMICE LINEARIZATE LOCAL

Teză destinată obținerii
titlului științific de doctor inginer
la
Universitatea Politehnica Timișoara
în domeniul INGINERIA SISTEMELOR
de către

Ing. Gelu-Laurențiu Ioanaș

Conducător științific: prof.univ.dr.ing. Toma-Leonida Dragomir.
Referenți științifici: prof.univ.dr. ing. Ioan Dumitrache.
prof.univ.dr.ing. Clement Feștilă.
prof.univ.dr.ing. Ioan Silea.

Ziua susținerii tezei: 05.12.2013

Seriile Teze de doctorat ale UPT sunt:

- | | |
|---|--|
| 1. Automatică | 9. Inginerie Mecanică |
| 2. Chimie | 10. Știința Calculatoarelor |
| 3. Energetică | 11. Știința și Ingineria Materialelor |
| 4. Ingineria Chimică | 12. Ingineria sistemelor |
| 5. Inginerie Civilă | 13. Inginerie energetică |
| 6. Inginerie Electrică | 14. Calculatoare și tehnologia informației |
| 7. Inginerie Electronică și Telecomunicații | 15. Ingineria materialelor |
| 8. Inginerie Industrială | 16. Inginerie și Management |

Universitatea „Politehnica” din Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul scolii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnica – Timișoara, 2006

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității „Politehnica” din Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300159 Timișoara, Bd. Republicii 9,
tel. 0256 403823, fax. 0256 403221
e-mail: editura@edipol.upt.ro

Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității mele în cadrul Departamentului de Automatică și Informatică Aplicată al Universității Politehnica Timișoara.

Mulțumiri deosebite se cuvin conducătorului de doctorat prof.dr.ing. Toma-Leonida Dragomir care cu răbdare, pricepere și o perseverență ieșită din comun, m-a ajutat să șlefuiesc această lucrare într-o formă adecvată pentru o teză de doctorat.

De asemenea, adresez mulțumiri colectivului Continental Automotive, departamentul Powertrain Engine Systems, în special d-lui Ciprian Toma, pentru suportul financiar și tehnic oferit pe durata activităților de cercetare doctorala. Le mulțumesc colegilor dr. Hui Li și dr. Juergen Fritsch pentru suportul tehnic și discuțiile purtate în scopul înțelegerii sistemului studiat.

Mulțumesc și sunt profund recunoscător familiei, în special soției, care a fost tot timpul alături de mine, în momentele de deznădejde și entuziasm, și care mi-a oferit, pe lângă sprijinul moral, și suport în tehnoredactarea tezei.

Adresez calde mulțumiri școlii doctorale din cadrul Universității Politehnica Timișoara pentru pregătirea oferită pe durata stagiului doctoral.

Această lucrare a fost parțial finanțată prin grantul POSDRU/88/1.5/S/-50783, în cadrul proiectului „Prin burse doctorale spre cercetarea de nivel european”, ID50783 (2009), co-finanțat de fondul social european „Investing in People”, din programul sectorial operațional de dezvoltare a resurselor umane 2007-2013.

Timișoara, noiembrie, 2013

Gelu-Laurențiu Ioanaș

Pentru soția mea, Anca.

Ioanaș, Gelu-Laurențiu

Dezvoltarea unui model de predicție a presiunii în sistemele Piezo Common-Rail Diesel bazat pe rețele neuro-fuzzy cu modele dinamice linearizate local

Teze de doctorat ale UPT, Seria 12, Nr.9, Editura Politehnica, 2013, 150 pagini, 116 figuri, 17 tabele.

ISSN:2068-7990

ISBN:978-606-554-741-4

Cuvinte cheie: adaptiv, common-rail, identificare , interpolare, liniarizare locală, on-line , modelare, modele dinamice, predicție, presiune, rețele neuro-fuzzy, sistem neliniar, software, timp real.

Rezumat,

Realizarea corectă a injecției de combustibil impune calculul parametrilor de injecție pe baza valorii presiunii din momentul injecției din rampa sistemului piezo-common-rail folosind un model de predicție. Teza prezintă sinteza unui astfel de model. Procesul fiind puternic neliniar, se folosesc modele locale liniare asociate partiționării spațiului intrărilor, integrate într-o structură de tip rețea neuro-fuzzy organizată pe doua nivele, capabilă să integreze cunoștințe apriorice despre sistemul studiat. Adaptarea coeficienților modelelor locale liniare se realizează folosind un algoritm recursiv bazat pe criteriul celor mai mici pătrate ce se pretează pentru implementare pe sisteme de timp real.

Din aceleași considerente, calculul variației de presiune conceput pentru rețeaua neuro-fuzzy este restructurat și transpus într-un calcul cu blocuri de interpolare biliniară. Algoritmul a fost îmbunătățit asigurând robustețe față de zgomote de măsură și intrări cu excitație slabă.

Aplicația ce include atât modelul de predicție cât și algoritmul de adaptare, a fost inclusă în sistemul de calcul de timp real ce asigură managementul motorului diesel.

Modelul a fost dezvoltat și aplicat practic. Rezultatele aplicației sunt favorabile, cu perspective de îmbunătățire a performanțelor sistemului de injecție piezo-common-rail diesel.

CUPRINS

Notații si acronime	7
Lista de tabele	9
Lista de figuri	10
1. INTRODUCERE	15
1.1. Motivația cercetării	15
1.2. Aspecte ale modelării	16
1.3. Modelare și identificare	17
1.4. Structura tezei	19
2. MODELUL VARIAȚIEI PRESIUNII ÎN SISTEMUL DIESEL COMMON-RAIL CU PIEZO-INJECTOARE (PCR)	20
2.1. Prezentare generală	20
2.2. Problema predicției presiunii din CR	21
2.2.1. Importanța predicției presiunii din CR	21
2.2.2. Abordări actuale pentru identificarea și modelarea comportamentului presiunii în CR	21
2.3. Modelul dinamic al presiunii în CR	22
2.4. Modelul de predicție a presiunii în rampa comună	24
3. SUPTOR TEORETIC PENTRU MODELAREA ȘI IDENTIFICAREA EMPIRICĂ	28
3.1. Modele intrare-ieșire	28
3.1.1. O privire de ansamblu asupra metodelor de identificare	28
3.1.2. Semnalele de excitație	29
3.1.3. Structura generală a modelelor intrare/ieșire.....	29
3.1.4. Modelul cu răspuns la impuls în timp finit (FIR)	30
3.1.5. Structuri de sisteme de predicție și simulare	31
3.2. Metode și algoritmi pentru identificarea parametrilor	33
3.2.1. Metoda celor mai mici pătrate (CMMP)	34
3.2.2. Metoda CMMP recursivă (RLS)	35
3.3. Modele neliniare bazate pe arhitecturi de rețele neuro-fuzzy	36
3.3.1. Aspecte generale ale rețelelor neurale	36
3.3.2. Rețele Neuro – Fuzzy	37
3.3.3. Rețele neuro-fuzzy cu modele locale liniarizate	38
3.3.4. O observație privind liniarizarea modelelor matematice	38
3.3.5. Modele de predicție pentru sisteme neliniare dinamice	40
3.3.6. Modelul arborescent linear local (Local Linear Model Tree: LOLIMOT).....	42
3.3.7. Algoritmul de construcție arborescentă a modelului liniar local (LOLIMOT)....	45
4 MODELUL NEURO-FUZZY ADAPTIV DE PREDICȚIE A PRESIUNII ÎN SISTEMUL PCR.....	48
4.1. Aprofundarea modului de funcționare a CR	48
4.1.1. Funcționarea în faze	48
4.1.2. Influența vâscozității cinematice	51
4.2. Arhitectura modelului de predicție a presiunii	52
4.3. Determinarea coeficienților LLM	57
4.4. Partiționarea spațiului de funcționare S_{TP} și determinarea inițială a para- metrilor modelului.....	59
5. IMPLEMENTAREA MODELULUI NEURO-FUZZY ADAPTIV DE PREDICȚIE A PRESIUNII ÎN SISTEMUL PCR.....	65

5.1. Implementarea software a modelului adaptiv pe sistemul de timp real.....	66
5.1.1. Aspecte ale implementării software.....	66
5.1.2. Prototiparea rapidă internă (iRPT).....	66
5.1.3. Implementarea software a algoritmului de adaptare	67
5.2. Definirea cadrului de desfășurare a experimentelor	73
5.2.1. Standul experimental hidraulic	73
5.2.2. Semnale de excitație pentru LLM	74
5.2.3. Delimitarea cadrului de desfasurare a experimentelor	74
5.3. Adaptarea on-line folosind algoritmul RLS robust	74
5.3.1. Interpretarea adaptării coeficienților folosind o structură de sistem adaptiv..	75
5.3.2. Interpretarea adaptării coeficienților folosind o structură de sistem cu comutație.....	78
5.3.3. Asigurarea robusteții algoritmului de adaptare	79
5.3.4. Convergența algoritmului recursiv RLSR	82
6 REZULTATE EXPERIMENTALE	84
6.1. Determinarea modelului de predicție a presiunii în CR.....	84
6.1.1. Descompunerea inițială a spațiului $S_{T,P}$	85
6.1.2. Iterația 1 de sinteză a modelului de predicție.....	97
6.1.3. Iterația a 2-a de sinteză a modelului de predicție.....	102
6.1.4. Iterația a 3-a de sinteză a modelului de predicție.....	104
6.1.5. Iterația a 4-a de sinteză a modelului de predicție.....	107
6.1.6. Iterația a 5-a de sinteză a modelului de predicție.....	112
6.1.7. Iterația a 6-a de sinteză a modelului de predicție.....	117
6.1.8. Iterația a 7-a de sinteză a modelului de predicție.....	121
6.2. Validarea modelului de predicție a presiunii în sistemul PCR	123
6.3. Restructurarea modelului experimental.....	125
7. CONCLUZII, CONTRIBUȚII ȘI PERSPECTIVE.....	134
7.1. Concluzii.....	134
7.2. Contribuții	135
7.3. Perspective.....	136
Anexe	137
A1. SISTEMUL COMMON-RAIL CU PIEZO-INJECTOARE	137
A2. ARHITECTURA APLICAȚIEI SOFTWARE PENTRU MODELUL ADAPTIV DE PREDICȚIE A PRESIUNII ÎN CR.....	142
Bibliografie.....	144

NOTAȚII ȘI ACRONIME

ADC – (Analog to Digital Converter) - Converter analog – numeric
ARIX – Autoregressive Integral with exogenous input
ARX – Autoregressive with exogenous input
 c – viteza sunetului
CMMP – Metoda celor mai mici pătrate
CPU – (Central Processing Unit) - Unitate de procesare centrală
CR – (Common rail) - Rampă comună
CRK – Crankshaft
DAC – (Digital to Analog Converter) - Converter numeric - analogic
DoE – (Design of Experiments) – Proiectarea experimentului
 E – Modul de elasticitate
ECU – (Engine Control Unit) - Unitate de management a motorului
EFP – (Electrical Fuel Pump) – Pompa de combustibil electrică
EOI – (End of Injection) - Închiderea injectorului
EU6, EU7 – Standarde de emisii europene
FIR – Model cu răspuns la impuls finit
HPP – (High Pressure Pump) – Pompa de înaltă presiune
HPS – (High Pressure Sensor) – Senzor de presiune
INJ – Injector
IP - Interpolare
iRPT – Prototipare rapidă internă
LLM – Model local liniar
LOLIMOT – (Local Linear Model Tree) – Arhitectura arborescentă cu modele locale liniare
 mf_{inj} – Cantitatea injectată
MSE – Eroare medie pătrată
 N - viteza de rotație a arborelui cotit
NARX – Non-linear Autoregressive with exogenous input
OEM – (Original Equipment Manufacturer) – Producător din industria auto
 P – Presiunea din rampa comună
PCR – Sistem de injecție Piezo Common Rail
PCV – (Pressure Control Valve) – Electrovalvă de ajustare a presiunii în CR
PID – Proportional, integrator, derivativ
 Q_x^m – Debitul masic asociat componentei x
 Q_x^v – Debitul volumetric asociat componentei x
RAM – Memorie cu acces citire/scriere
RIP – (Rule based InterPolation) – Interpolare între baze de reguli
RLS – Metoda celor mai mici pătrate recursivă
RLSR – Metoda celor mai mici pătrate recursivă robustă
ROM – Memorie cu acces citire
SOI – (Start of Injection) - Deschiderea injectorului
SULEV – Standard de emisii SUA
 T – Temperatura combustibilului din rampa comună
TDC – Punctul mort superior

t_{EOI} – Momentul de închidere al injectorului
TFU – Fuel Temperature
 t_{INJ} – Durata evenimentului de injecție
 t_{SEG} – Momentul de calcul la evenimentul de segment
 t_{SOI} – Momentul de deschidere al injectorului
VCV – (Volumetric Control Valve) – Electrovalva ce ajustează volumul de combustibil la intrarea în pompa
 V_{rail} – volumul rampei comune
 α_{CRK} – Poziția unghiulară a arborelui cotit [$^{\circ}CRK$]
 α_{SOIi} – Poziția unghiulară la care se realizează injecția
 ΔMF_x – Masa de combustibil vehiculată într-un interval de timp prin componenta x
 $\Lambda(T,P)$ – Punct de funcționare
 T_{INJ} – Orizontul de timp dintre evenimentul de segment și evenimentul de injecție
 ρ – Densitate
 φ – Unghiul de montare al pompei
 ψ_{PCV} – Deschiderea electrovalvei de presiune [%]
 ψ_{VCV} – Deschiderea electrovalvei volumetrice [%]

LISTA DE TABELE

1. TABEL I. LIMITELE DE VARIAȚIE PENTRU INTRĂRILE ÎN MODEL.....	74
2. TABEL II. NOTAȚIILOR PUNCTELOR DE OPERARE, CENTRELOR, PUNCTELOR DE SPRIJIN ȘI LM- URILOR.....	85
3. TABEL III. COEFICIENȚII MODELULUI LM_1 ASOCIAT NEURONULUI 1.....	86
4. TABEL IV. COEFICIENȚII MODELULUI LM_2 ASOCIAT NEURONULUI 2.....	88
5. TABEL V. COEFICIENȚII MODELULUI LM_3 ASOCIAT NEURONULUI 3.....	89
6. TABEL VI. COEFICIENȚII MODELULUI LM_4 ASOCIAT NEURONULUI 4.....	91
7. TABEL VII. COEFICIENȚII MODELULUI LM_5 ASOCIAT NEURONULUI 5.....	92
8. TABEL VIII. COEFICIENȚII MODELULUI LM_6 ASOCIAT NEURONULUI 6.....	98
9. TABEL IX. COEFICIENȚII MODELULUI LM_7 ASOCIAT NEURONULUI 7.....	102
10. TABEL X. COEFICIENȚII MODELULUI LM_8 ASOCIAT NEURONULUI 8.....	104
11. TABEL XI. COEFICIENȚII MODELULUI LM_9 ASOCIAT NEURONULUI 9.....	108
12. TABEL XII. COEFICIENȚII MODELULUI LM_{10} ASOCIAT NEURONULUI 10.....	113
13. TABEL XIII. COEFICIENȚII MODELULUI LM_{11} ASOCIAT NEURONULUI 11.....	118
14. TABEL XIV. COEFICIENȚII MODELULUI LM_{12} ASOCIAT NEURONULUI 12.....	122
15. TABEL XV. BAZA DE REGULI ASOCIATĂ MODELULUI EXPERIMENTAL.....	125
16. TABEL XVI. BAZA DE REGULI ASOCIATĂ MODELULUI EXPERIMENTAL.....	126
17. TABEL XVII. BAZA DE REGULI ASOCIATĂ MODELULUI EXPERIMENTAL.....	126

LISTA DE FIGURI

1. Figura 1. Paradigmele modelării în funcție de cunoștințele despre sistemul studiat	16
2. Figura 2. Ciclul de dezvoltare și identificare a unui model	18
3. Figura 3. Sistemul hidraulic PCR de nouă generație	20
4. Figura 4. Calculul presiunii pentru un ciclu complet al PCR (720° CRK)	25
5. Figura 5. Schema bloc a modelului analitic de predicție a presiunii în rampa comună	26
6. Figura 6. Modele teoretice de variație a debitelor masice	27
7. Figura 7. Vedere de ansamblu asupra metodelor de identificare aplicabile sistemelor liniare	28
8. Figura 8. Model de predicție	31
9. Figura 9. Simulare cu un model bazat pe măsurări afectate de zgomot	32
10. Figura 10. Conceptul de predicție	33
11. Figura 11. Funcții de apartenență care formează o partiție a unității	39
12. Figura 12. Liniarizarea unei funcții neliniare	40
13. Figura 13. Modele Hammerstein și Wiener	41
14. Figura 14. Model NARX implementat cu ajutorul arhitecturii LOLIMOT	42
15. Figura 15. Structura de rețea Neuro – Fuzzy cu modele locale liniare având intrările consecințelor x și ale premiselor z	44
16. Figura 16. Faze și funcțiile de apartenență corespunzătoare	49
17. Figura 17. Variația presiunii în Common-rail vs. poziția arborelui cotit pentru un ciclu motor complet (720 °CRK)	50
18. Figura 18. Valorile variabilelor asociate debitelor masice se obțin în funcție de a_{CRK} prin interpolare	51
19. Figura 19. Variația vâscozității cinematice pentru un tip de combustibil diesel în funcție de presiune la diverse temperaturi	51
20. Figura 20. Structura de rețea Neuro-fuzzy cu modele locale dinamice. Ponderea în ieșirea finală a fiecărui model local LM este dată de funcțiile de validare Φ_i	52
21. Figura 21. Structura de rețea Neuro-fuzzy cu modele locale dinamice	53
22. Figura 22. Funcțiile de apartenență utilizate pentru calcularea funcțiilor de validare în locul celor de tip Gaussian	56
23. Figura 23. Structura mecanismului de adaptare a valorilor coeficienților modelului de predicție	58
24. Figura 24. Delimitarea spațiului S_{TP} al punctelor de operare considerate în experiment	60
25. Figura 25. Poziționarea inițială a punctelor de sprijin în spațiului intrărilor	61
26. Figura 26. Determinarea coeficienților modelelor pe baza măsurărilor experimentale	61
27. Figura 27. Evaluarea modelului asociat unui punct de sprijin în punctele de sprijin din vecinătate	63
28. Figura 28. Poziții posibile ale punctului curent $\Lambda(P,T)$ în raport cu o rețea carteziană de puncte de sprijin	68
29. Figura 29. Interpolare liniară	69
30. Figura 30. Schema de calcul a variației de presiune potrivit ultimei expresii din (75)	70
31. Figura 31. Arhitectura modelului de predicție a presiunii în CR adaptată pentru implementarea software	71

32. Figura 32. Referitoare la ritmul de prelevare a datelor și de calculare a coeficienților modelului pentru adaptarea secvențială în buclă repetitivă.....	72
33. Figura 33. Standul experimental hidraulic.....	73
34. Figura 34. Urmărirea referinței în buclă închisă pe durata adaptării.....	75
35. Figura 35. Adaptarea coeficienților modelului de predicție se realizează sub forma unui sistem cu comutație.....	78
36. Figura 36. Evoluția primului element din vectorii de stare pe durata secvenței de adaptare.....	83
37. Figura 37. Descompunerea inițială a spațiului intrărilor pe axele T și P.....	85
38. Figura 38. Evoluția coeficienților LM_1 pe durata secvenței de antrenare.....	86
39. Figura 39. Rezultatul validării pentru LM_1 în vecinătatea punctului de funcționare Λ_1	87
40. Figura 40. Evoluția coeficienților LM_2 pe durata secvenței de antrenare.....	87
41. Figura 41. Rezultatul validării pentru LM_2 în vecinătatea punctului de funcționare Λ_2	88
42. Figura 42. Evoluția coeficienților LM_3 pe durata secvenței de antrenare.....	89
43. Figura 43. Rezultatul validării pentru LM_3 în vecinătatea punctului de funcționare Λ_3	90
44. Figura 44. Evoluția coeficienților LM_4 pe durata secvenței de antrenare.....	90
45. Figura 45. Rezultatul validării pentru LM_4 în vecinătatea punctului de funcționare Λ_4	91
46. Figura 46. Evoluția coeficienților LM_5 pe durata secvenței de antrenare.....	92
47. Figura 47. Rezultatul validării pentru LM_5 în jurul punctului de funcționare Λ_5	93
48. Figura 48. Evaluarea modelelor adaptate în vederea unei noi partiționări.....	88
49. Figura 49. Indicele MSE pentru modelul LM_1 evaluat la limitele dreptunghiului asociat.....	94
50. Figura 50. Indicele MSE pentru modelul LM_2 evaluat la limitele dreptunghiului asociat.....	95
51. Figura 51. Indicele MSE pentru modelul LM_3 evaluat la limitele dreptunghiului asociat.....	95
52. Figura 52. Indicele MSE pentru modelul LM_4 evaluat la limitele dreptunghiului asociat.....	96
53. Figura 53. Indicele MSE pentru modelul LM_5 evaluat la limitele dreptunghiului asociat.....	96
54. Figura 54. Descompunerea spațiului intrărilor pe axele T și P pentru prima iterație.....	97
55. Figura 55. Evoluția coeficienților LM_6 pe durata secvenței de antrenare.....	98
56. Figura 56. Rezultatul validării pentru LM_6 în jurul punctului de funcționare Λ_6	99
57. Figura 57. Evaluarea modelului adaptat în vederea unei noi partiționări.....	99
58. Figura 58. Indicele MSE pentru modelul LM_6 evaluat la limitele dreptunghiului asociat.....	100
59. Figura 59. Evaluarea modelelor deja adaptate LM_1, LM_2 în vecinătatea punctului Λ_6	100
60. Figura 60. Indicele MSE pentru modelele LM_1 și LM_2 evaluate la limita dreptunghiului asociat LM_6	101
61. Figura 61. Descompunerea spațiului intrărilor pe axele T și P pentru a doua iterație.....	101
62. Figura 62. Evoluția coeficienților LM_7 pe durata secvenței de antrenare.....	102
63. Figura 63. Rezultatul validării pentru LM_7 în jurul punctului de funcționare Λ_7	103

64. Figura 64. Evaluarea modelului adaptat în vederea unei noi partiționări.....	103
65. Figura 65. Indicele MSE pentru modelul LM ₇ evaluat la limitele dreptunghiului asociat.....	104
66. Figura 66. Descompunerea spațiului intrărilor pe axele T și P pentru a treia iterație.....	104
67. Figura 67. Evoluția coeficienților LM ₈ pe durata secvenței de antrenare.....	105
68. Figura 68. Rezultatul validării pentru LM ₈ în jurul punctului de funcționare Λ_8	106
69. Figura 69. Evaluarea modelului adaptat în vederea unei noi partiționări.....	106
70. Figura 70. Indicele MSE pentru modelul LM ₈ evaluat la limitele dreptunghiului asociat.....	107
71. Figura 71. Descompunerea spațiului intrărilor pe axele T și P pentru a patra iterație.....	107
72. Figura 72. Evoluția coeficienților LM ₉ pe durata secvenței de antrenare.....	107
73. Figura 73. Rezultatul validării pentru LM ₉ în jurul punctului de funcționare Λ_9	109
74. Figura 74. Evaluarea LM ₉ adaptat în vederea unei noi partiționări.....	109
75. Figura 75. Indicele MSE pentru modelul LM ₉ evaluat la limitele dreptunghiului asociat.....	110
76. Figura 76. Evaluarea modelelor deja adaptate LM ₃ , LM ₆ și LM ₇ în vecinătatea punctului Λ_9	110
77. Figura 77. Indicele MSE pentru LM ₃ , LM ₆ și LM ₇ evaluate la limita dreptunghiului asociat cu LM ₉	111
78. Figura 78. Descompunerea spațiului intrărilor pe cele doua axe T și P pentru a cincea iterație.....	112
79. Figura 79. Evoluția coeficienților LM ₁₀ pe durata secvenței de antrenare.....	113
80. Figura 80. Rezultatul validării pentru LM ₁₂ în jurul punctului de funcționare Λ_{10}	114
81. Figura 81. Evaluarea modelului adaptat LM ₁₀ în vederea unei noi partiționări.....	114
82. Figura 82. Evaluarea modelului adaptat LM ₁₀ în vederea unei noi partiționări.....	115
83. Figura 83. Evaluarea modelelor deja adaptate LM ₃ , LM ₆ și LM ₈ în vecinătatea punctului Λ_{10}	115
84. Figura 84. Indicele MSE pentru LM ₃ , LM ₆ și LM ₈ evaluate la limita dreptunghiului asociat cu LM ₁₀	116
85. Figura 85. Descompunerea spațiului intrărilor pe axele T și P pentru a șasea iterație.....	117
86. Figura 86. Evoluția coeficienților LM ₁₁ pe durata secvenței de antrenare.....	118
87. Figura 87. Rezultatul validării pentru LM ₁₁ în jurul punctului de funcționare Λ_{11}	119
88. Figura 88. Evaluarea modelului LM ₁₁ adaptat în vederea unei noi partiționări.....	120
89. Figura 89. Indicele MSE pentru modelul LM ₁₁ evaluat la limitele dreptunghiului asociat.....	120
90. Figura 90. Evaluarea modelelor deja adaptate LM ₃ și LM ₄ în vecinătatea punctului Λ_{11}	120
91. Figura 91. Indicele MSE pentru LM ₃ , LM ₄ evaluate la limita dreptunghiului asociat LM ₁₁	120
92. Figura 92. Descompunerea spațiului intrărilor pe axele T și P pentru a șaptea iterație.....	121

93. Figura 93. Evoluția coeficienților LM_{12} pe durata secvenței de antrenare.....	122
94. Figura 94. Rezultatul validării pentru LM_{12} în jurul punctului de funcționare Λ_{12}	123
95. Figura 95. Reprezentarea grafică a presiunii măsurate (1 ms), media pe segmentul anterior și a predicției de presiune pentru o treaptă ascendentă de presiune.....	124
96. Figura 96. Reprezentarea grafică a presiunii măsurate (1 ms), media pe segmentul anterior și a predicției de presiune pentru o treaptă descendentă de presiune.....	124
97. Variația coeficientului $w_{i,4,1}^1$ pe domeniul de intrare S_{TP}	127
98. Figura 98. Variația coeficientului $w_{i,5,1}^1$ pe domeniul de intrare S_{TP}	127
99. Figura 99. Variația coeficientului $w_{i,0,2}^1$ pe domeniul de intrare S_{TP}	128
100. Figura 100. Variația coeficientului $w_{i,1,2}^1$ pe domeniul de intrare S_{TP}	128
101. Figura 101. Variația coeficientului $w_{i,2,2}^1$ pe domeniul de intrare S_{TP}	129
102. Figura 102. Variația coeficientului $w_{i,3,2}^1$ pe domeniul de intrare S_{TP}	129
103. Figura 103. Caracteristicile coeficientului $w_{i,4,1}^1(P), T = const.$	130
104. Figura 104. Caracteristicile coeficientului $w_{i,5,1}^1(P), T = const.$	131
105. Figura 105. Caracteristicile coeficientului $w_{i,0,2}^1(P), T = const.$	131
106. Figura 106. Caracteristicile coeficientului $w_{i,1,2}^1(P), T = const.$	132
107. Figura 107. Caracteristicile coeficientului $w_{i,2,2}^1(P), T = const.$	132
108. Figura 108. Caracteristicile coeficientului $w_{i,3,2}^1(P), T = const.$	133
109. Figura A1-1. Sistemul hidraulic PCR de nouă generație (NG).....	137
110. Figura A1-2. Injector PCR NG cu „direct drive”.....	137
111. Figura A1-3. Pompa de înaltă presiune radială cu două pistoane.....	138
112. Figura A1-4. Reprezentarea schematică a VCV	139
113. Figura A1-5. Reprezentarea schematică a PCV	139
114. Figura A1-6. Senzorul de presiune (HPS)	140
115. Figura A1-7. Diagrama fish-bone pentru factorii de influența a variației presiunii în CR	141
116. Figura A2-1. Arhitectura software a aplicației adaptive de predicție a presiunii în rampa comună (CR)	142

Motto:
„Visează, caută și cucerește!
Doar așa vei fi fericit în viață.”

1 INTRODUCERE

Modelarea în detaliu a proceselor tehnologice folosind metode teoretice și implementarea numerică a modelelor analitice rezultate pe sisteme de calcul de timp real, presupune o muncă elaborată ce consumă timp și resurse. Pentru industria automotive, aceste aspecte devin critice odată cu creșterea complexității sistemelor și a interacțiunii dintre procesele mecanice, electrice și termodinamice. În acest context, metodele de indentificare și modelele empirice rezultate vin ca o alternativă la abordările analitice clasice. Astfel, în numeroase aplicații, rețelele Neuro – Fuzzy și-au demonstrat capacitatea de a furniza, pe bază de suporturi teoretice adecvate, modele numerice obținute direct din măsurători, fără o cunoaștere în detaliu a procesului neliniar [1],[2],[3],[4].

1.1. Motivația cercetării

În ultimul deceniu, industria auto a înregistrat un progres considerabil, iar principalii producători de automobile (OEM) împreună cu furnizorii de soluții tehnice au conlucrat pentru implementarea de soluții inovatoare cu scopul de a satisface cerințele pieței, pe de o parte, iar pe de altă parte, iar pe de altă parte cu scopul de a îndeplini cerințele restrictive impuse de legislația în materie de emisii poluante (EU6, EU7, SULEV etc.) [5][6][7].

Sistemele Common-Rail diesel cu piezo-injectoare (PCR) (Anexa 1) nu fac excepție de la regulă, și echipele de ingineri sunt nevoite să găsească soluții pentru îndeplinirea obiectivelor legate de emisii și performanță, în paralel cu reducerea timpilor de implementare a soluțiilor tehnice și a costurilor. În „războiul” cu normele de emisii poluante, în prima linie se găsesc inginerii de sistem, responsabili de realizarea injectiei în parametri impuși de OEM. Ca exemplu, pentru întreg spațiul punctelor de funcționare ale motorului, deviația medie acceptată față de cantitățile ce trebuie injectate este de 0.4 mg per injectie. Problema se complică atunci când acest criteriu de performanță trebuie atins pe parcursul tuturor punctelor de funcționare și cu configurații multiple de injectie.

Printre numeroșii factori ce influențează cantitatea de combustibil injectată se numără și presiunea din Common-Rail (CR) [8],[9]. În timpul funcționării motorului, presiunea din CR este în continuă schimbare, pe de o parte, datorită referinței cerută de managerul de combustie, pe de altă parte, datorită elementelor mecanice și hidraulice din sistem. Valoarea presiunii din CR la momentele la care se realizează fiecare injectie este determinantă în calculul timpului de injectie (intervalul de timp cât injectorul este deschis) pentru cantitatea de combustibil ce trebuie injectată. Datorită restricțiilor impuse de sistemele de calcul în timp real, calculul timpilor de injectie se realizează cu un interval de timp în avans față de evenimentul de injectie, iar acest lucru impune cunoașterea în avans a evoluției presiunii în CR, de la momentul măsurării acesteia până la momentul realizării evenimentelor de injectie. În consecință, un model numeric al procesului, care să furnizeze în timp real predicția presiunii la diferite momente de timp, este absolut necesar.

Totuși, problematica nu se reduce doar la a modela și identifica procesul. Cum majoritatea sistemelor tehnice au parametri variabili în timp, un model realizat off-line ar avea o valabilitate limitată în timp, reducându-și acuratețea odată cu „îmbătrânirea” componentelor din sistemul CR. Drept urmare, adaptarea sistematică, *on-line*, a parametrilor modelului în timpul funcționării este o necesitate pentru păstrarea performanțelor modelului pe toată durata de exploatare a sistemului.

1.2. Aspecte ale modelării

În general, în știință și inginerie, când vine vorba de modelare, există două abordări bazate pe fundamente („filozofia” abordării) diferite: modelarea analitică și empirică. Un model analitic al unui proces poate fi realizat pe baza aplicării legilor fizice ce guvernează comportamentul sistemului. Modelul empiric, pe de altă parte, poate fi determinat pe baza observațiilor făcute asupra comportamentului real al sistemului. Structura unui astfel de model este de tip „cutie neagră” [10] și relațiile între mărimile de intrare și ieșire nu pot fi direct interpretate în sens fizic. Adesea, niciuna din cele două abordări nu este atractivă pentru ingineri. Datorită complexității sistemelor studiate, relațiile fizice dintre componentele din sistem sunt doar parțial cunoscute și dezvoltarea unui model analitic complet nu este fezabilă. Același lucru se poate spune și despre un model empiric local a cărui utilitate nu poate fi extinsă tocmai datorită dificultății întâmpinate în integrarea într-un astfel de model, a cunoștințelor despre sistem deja disponibile. În consecință, o abordare hibridă între cele două concepte este de dorit, cu ponderi diferite în funcție de etapele cercetării [11].

În Figura 1 este simbolizată dependența abordărilor, în ceea ce privește modelarea, de informațiile disponibile despre procesul studiat. Astfel, modelarea analitică se pretează atunci când cunoștințele teoretice despre sistem sunt bune, în timp ce modelarea empirică este recomandată atunci când există cunoștințe empirice suficiente despre procesul studiat. În cazul în care se dispune doar de cunoștințe și date empirice parțiale despre sistem se recomandă modelarea hibridă. În fine, se disting și situații în care se pot folosi foarte bine atât modelarea analitică cât și modelarea hibridă.

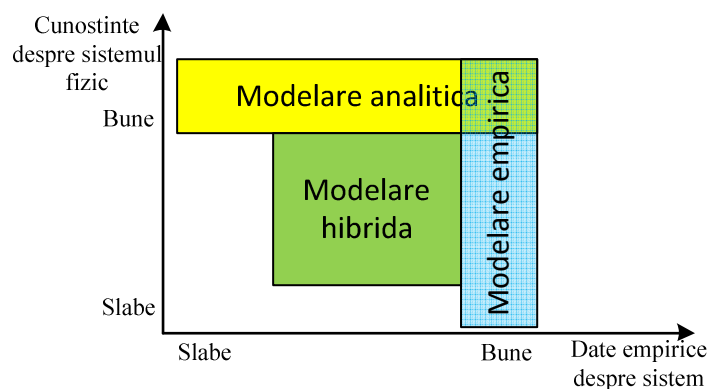


Figura 1. Paradigmele modelării în funcție de cunoștințele despre sistemul studiat

Deseori criticate de mediul academic datorită caracterului local¹, modelele empirice satisfac necesitățile ingineresti atunci când se dorește modelarea doar în vecinătatea unor puncte specifice din spațiul de operare al sistemului. Spre deosebire de modelele analitice, costurile (cu resurse umane, resurse materiale etc) pe care le implică realizarea de modele empirice sunt mult reduse, iar acuratețea calculului este mai ridicată pe întreg spațiul de operare (cu ajutorul sistemelor de calcul numeric, pot fi realizate interpolări între modele asociate unor puncte de operare diferite, acoperind astfel o arie mai largă din spațiul de operare). Un model hibrid sau de tip „cutie gri”, bazat pe sinergia dintre cele două concepte de modelare, poate deveni robust și precis în același timp, cu costuri de implementare moderate.

În general, este de dorit ca reprezentarea modelului să se facă transparent într-o formă compatibilă cu înțelegerea sistemului de către ingineri, simplificând în acest fel interpretarea și implementarea pe un sistem numeric, încorporând totodată și cunoștințele anterioare despre sistemul studiat [12],[13]. „Mixajul” între datele măsurate și cunoștințele expertului, combinat cu simplificări „ad-hoc” ale problemelor pentru a le face rezolvabile, reprezintă, de fapt, esența activității de cercetare în inginerie.

1.3. Modelare și identificare

Într-o formulare simplistă, modelarea și identificarea presupun o asociere a cunoștințelor anterioare și a datelor experimentale cu un model. Conform [11], problematica se poate formula astfel:

Problema modelării: Având un set de date experimentale și cunoștințe despre sistem, să se determine un set de modele ce pot descrie, de o manieră acceptabilă, aspectele dorite ale comportării sistemului.

Problema identificării: Având un set de modele, un set de date experimentale și o funcție obiectiv ce evaluează deviațiile dintre estimarea unui model dat și ieșirea măsurată a sistemului, să se determine, din setul dat, modelul ce minimizează funcția obiectiv. În mod uzual, problema se descompune la rândul ei în identificarea structurii modelului și identificarea parametrilor.

Din punctul de vedere al unei aplicații concrete este necesară rezolvarea ambelor probleme. Procesul de obținere a unui model este de regulă iterativ, iar în cazul unor modele adaptive este ciclic. Dintre numeroasele maniere de a reda acest lucru se consideră schema ciclului de modelare din Figura 2 [14], în care se poate observa interacțiunea dintre cunoștințele apriorice, proiectarea experimentelor, achiziția și procesarea de date urmată de modelarea numerică și validarea experimentală:

¹ Aici, termenul „local” se referă la punctul de funcționare.

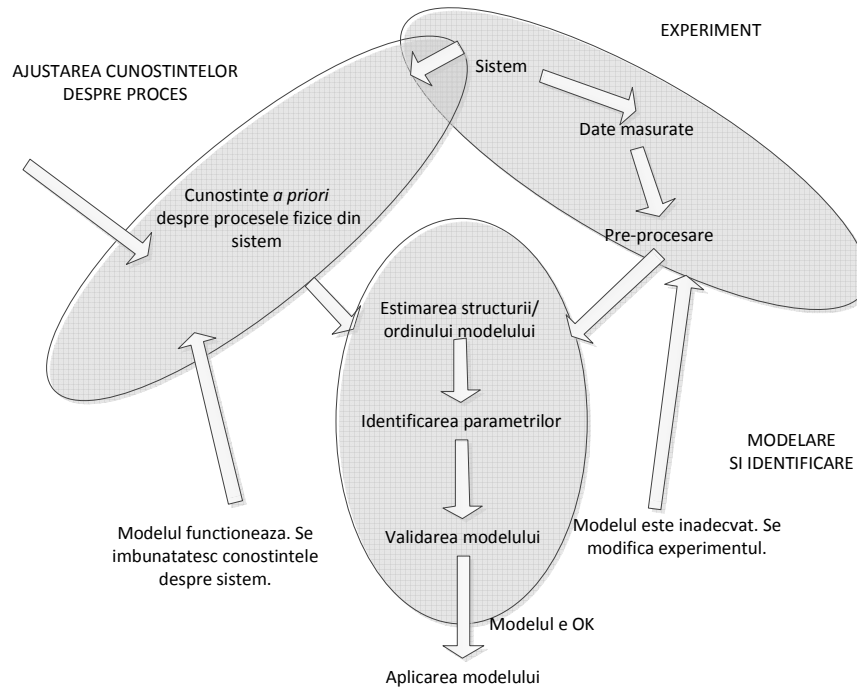


Figura 2. Ciclul de dezvoltare și identificare a unui model

Lucrarea de față are ca scop tratarea sistematică a celor două probleme cu scopul de a determina un model numeric de predicție în timp real a presiunii în sistemul PCR, cu aplicabilitate pe o zonă largă de operare și cu capacitatea de adaptare on-line a parametrilor săi.

1.4. Structura tezei

În capitolul 2 se face, prin intermediul Anexei 1, o prezentare detaliată a sistemului PCR cu toate aspectele ce țin de dinamica presiunii în rampa comună (CR). Un scurt studiu bibliografic are rolul de a prezenta abordările actuale vis-a-vis de problematica studiată și de a încadra și argumenta abordarea din teză. Se prezintă un model matematic de predicție a valorii presiunii la momentele de injecție bazat pe variația debitelor masice asociate componentelor hidraulice interconectate cu rampa comună în circuitul hidraulic și se stabilesc principalele mărimi de intrare ce vor intra în componența modelului numeric.

Capitolul 3 furnizează instrumentele de modelare și identificare folosite pe parcursul tezei. Accentul este pus pe modele intrare-ieșire, în timp discret, care, în principiu, operează cu serii de timp, cu referire directă la modelele neuro-fuzzy în care se încadrează modelele cunoscute sub denumirea de LOLIMOT. Se face o trecere în revistă a modelelor liniare dinamice de tip intrare/ieșire, apoi se realizează o scurtă prezentare a principalelor arhitecturi de rețele neuronale, cu o detaliere asupra rețelei neuro – fuzzy cu modele liniarizate local. În final se prezintă algoritmul de partiționare arborescentă a spațiului intrărilor în sub-regiuni pentru

care, simultan cu partiționarea, se sintetizează modelele liniare locale care alcătuiesc LOLIMOT.

Capitolul 4 este dedicat dezvoltării modelului neuro-fuzzy adaptiv de predicție a presiunii în CR. Dezvoltarea cuprinde două aspecte: pe de o parte, rafinarea modelului neuro-fuzzy cu modele locale adoptat în capitolul al treilea și, pe de alta parte, transformarea, într-o manieră inginerescă, a acestuia într-un model interpolativ cu puncte de sprijin, apt pentru implementare în timp real. În acest scop se aprofundează modul de funcționare a PCR și dinamica presiunii în rampa comună (CR), rezultatul final constând în introducerea, în cadrul fiecărui neuron, a unei structuri dependente de fazele sistemului, și, în înlocuirea funcțiilor de apartenență gaussiene cu funcții triunghiulare ce realizează o interpolare biliniară între regiuni alăturate din spațiul de operare. Modificările introduse sunt urmate, în mod firesc, de adecvarea strategiei de partiționare a spațiului mărimilor de intrare și de proiectare a modelului.

Capitolul 5 tratează problema restructurării succesiunii operațiilor pentru calculul variației de presiune din rampa comună de o manieră care conduce la înlocuirea structurii neuro-fuzzy inițiale cu o structură bazată pe blocuri interpolative, care însă operează tot cu coeficienții structurii inițiale. Se prezintă aspecte asociate aplicației software ce implementează pe un sistem de calcul în timp real atât arhitectura modelului cât și algoritmul de adaptare a coeficienților modelelor liniare, respectiv standul hidraulic PCR pe care se va lucra. În ultima parte a capitolului este analizat algoritmul de adaptare a coeficienților din perspectiva inspecției lui ca sistem adaptiv.

În capitolul 6 se prezintă aplicarea modelului de predicție pentru un sistem real descris în Anexa 2. Pentru cele două operații de bază ale modelului de predicție: adaptarea parametrilor și predicția variației de presiune este folosită aplicația referită în capitolul 5 și etapele de dezvoltare a modelului prezentate în capitolul 4. Întreaga dezvoltare recurge la operații efectuate în timp real, pe stand. Rezultatele finale validează modelul de predicție. Discuția finală atenționează asupra varianței coeficienților modelului în funcție de punctul de funcționare și asupra posibilității de restructurare inclusiv a variantei interpolative folosite.

Capitolul 7 sintetizează contribuțiile personale ale autorului, punând accent pe utilitatea cercetării și aplicabilitatea imediată a rezultatelor acesteia. În final, sunt formulate câteva idei referitoare la perspective aplicative și de cercetare în tematica lucrării de față.

Nota: În cadrul tezei s-au preluat o serie de figuri din lucrările publicate de autor, menționate în bibliografie. De asemenea, s-au folosit înregistrări obținute pe standul experimental folosite în dezvoltarea modelului de predicție. În cazul acestor figuri, s-a păstrat textul original în limba engleză.

2 MODELUL VARIAȚIEI PRESIUNII ÎN SISTEMUL DIESEL COMMON-RAIL CU PIEZO-INJECTOARE (PCR)

2.1. Prezentare generală

Generațiile noi de sisteme PCR sunt caracterizate de capacitatea de a opera la presiuni înalte (până la 240 MPa) cu o varietate de configurații de injecție (până la 7 injecții pe segment).

Figura 3 conține o reprezentare schematică a sistemului PCR cu patru injectoare [15], [16]. Principalele componente sunt: circuitul de joasă presiune (albastru) ce conține pompa electrică (EFP) cu scop de transfer al combustibilului din rezervor și circuitul de înaltă presiune (rosu), cu pompa de înalta presiune (HPP), electrovalvele de comandă volumetrică (VCV) și de presiune (PCV), rampa comună (CR), piezo-injectoarele (INJ_i) și senzorul de presiune (HPS). Tot de circuitul de joasă presiune aparține și conducta de retur în rezervor pe care este instalat senzorul de temperatură (TFU). Electrovalvele sunt comandate de unitatea electronică de control (ECU) ce procesează informațiile provenite de la senzorul de poziție a arborelui cotit (CRK), HPS și TFU.

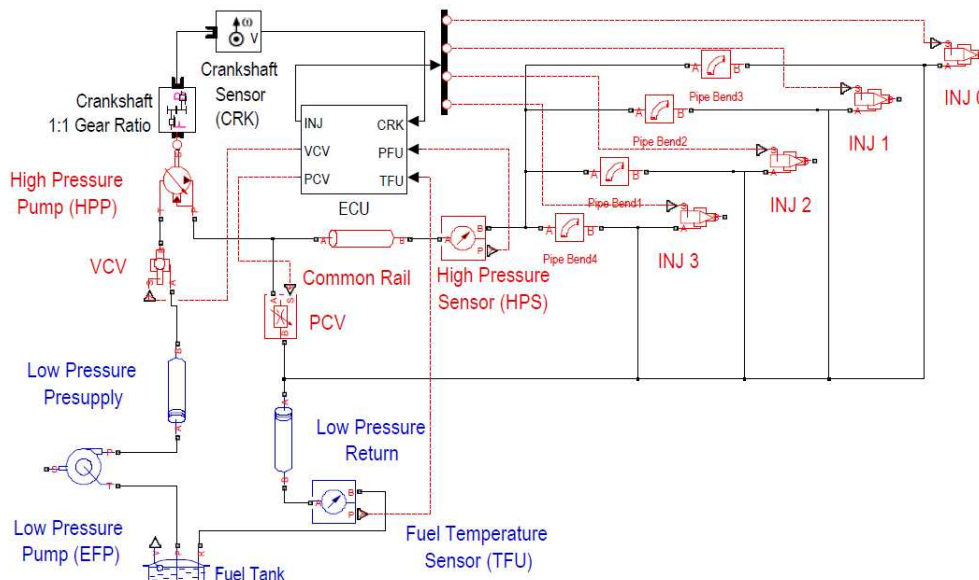


Figura 3. Sistemul hidraulic PCR de nouă generație [24]

În realizarea actuală, structura de control în buclă închisă a presiunii conține două regulatoare PID cu parametri dependenți de punctele de funcționare ale

motorului, unul desemnat să controleze electrovalva volumetrică (VCV) și celalalt pentru electrovalva de presiune (PCV). La un moment dat e funcțională doar o singura buclă de reglare care comandă o singură valvă, cealaltă valvă fiind comandată în buclă deschisă astfel că, după caz, reglarea presiunii se realizează doar cu VCV sau doar cu PCV. Selecția buclei de reglare (PCV sau VCV) este realizată pe baza debitului estimat de un model de curgere a fluidului [15].

O descriere detaliată cu specificațiile tehnice ale componentelor sistemului PCR studiat se găsește în *Anexa 1*.

2.2. Problema predicției presiunii din CR

2.2.1. Importanța predicției presiunii din CR

Literatura de specialitate conține o serie de lucrări în care sistemul de injecție Common-Rail este studiat în detaliu [17],[18],[19],[20],[21],[22],[23]. Un interes deosebit este alocat realizării combustiei și a injecției propriu-zise. Un management bun al emisiilor poluante este strâns legat de managementul combustiei, iar combustia, la rândul ei, este dependentă de realizarea injecției cu combustibil [8]. Cum intervalul de timp pe care se realizează injecția, t_{INJ} , și care determină cantitatea injectată, este direct influențat de valoarea presiunii de la momentul realizării injecției, legătura dintre valoarea presiunii din CR, cantitatea de combustibil folosit și emisiile poluante este evidentă. Concret, pentru timpi mari de injecție² (~1.5 ms) o variație de +/- 5 MPa poate induce o deviație de +/- 1 mg în cantitatea injectată [33].

Datorită caracterului inerțial al proceselor de măsurare, calcul și comandă desfășurate pe ECU, valoarea presiunii din CR (P) folosită în prezent pentru calculul t_{INJ} diferă de valoarea reală a presiunii de la momentul realizării injecției. Diferențe dintre cele două valori sunt considerate relativ mari, astfel că devine evidentă necesitatea unui model de predicție pentru comportamentul dinamic al presiunii în timpul funcționării motorului [22].

2.2.2. Abordări actuale pentru identificarea și modelarea comportamentului presiunii în CR

În literatură se pot evidenția numeroase publicații în care comportamentul presiunii în sistemul de injecție cu rampă comună, sau pe unele porțiuni ale acesteia, este modelat și identificat folosind metode analitice.

În [25], Lino et. al. propun un model în spațiul stărilor al sistemului de injecție cu rampa comună. Pe baza lui realizează o structură de reglare de tip „sliding mode” a presiunii. Modelul este validat experimental iar performanțele structurii de conducere sunt evaluate cu ajutorul uneltelor software AMESim și Matlab. Aceiași autori propun în [26] o metodă parametrică de identificare (ARIX), pentru dinamica presiunii gazului într-un sistem de injecție cu rampa comună adaptat pentru un motor pe gaz. Rezultatul identificării este concretizat într-un model ce aproximează global comportamentul sistemului și este folosit în controlul

² Sintagma „timp de injecție” se referă la durata intervalului de timp pe care se realizează injecția.

predictiv al presiunii gazului în sistemul de injecție. Validarea modelului, efectuată pe un stand experimental, demonstrează potențialul structurii de control predictiv față de o structura de conducere convențională.

În câteva publicații și lucrări se analizează în detaliu componente ale sistemului de înaltă presiune precum și factorii ce influențează dinamica presiunii. Astfel, în [27], Zeliang Li face o analiză a pompei de înaltă presiune cu scopul de a obține un model teoretic, validat experimental, ce aproximează forma de undă a presiunii furnizată de pompă. Unul dintre factorii determinanți pentru modelul de curgere al fluidului și implicit pentru dinamica presiunii, este modulul de elasticitate (E) al combustibilului folosit.

Seykens [28] și Boudy [28] formulează, pe bază de experimente, concluzii legate de influența proprietăților combustibililor biodiesel asupra comportamentului presiunii în sistemele de injecție cu rampă comună. Coeficientul de amortizare cu care se reduce amplitudinea oscilațiilor de presiune este direct dependent de modulul de elasticitate. În lucrarea [30], Kiiarvi furnizează modele analitice detaliate ale debitelor volumetric și presiunii pentru toate componentele sistemului Common-Rail. Zhang și Sun investighează în [31] posibilitatea sincronizării evenimentelor mecanico-hidraulice cu poziția arborelui cotit și concep pentru studiul pulsațiilor în presiune introduse de HPP un model bazat pe variația unghiulară a arborelui cotit. O analiză mai recentă asupra combustibililor diesel, [32], relevă dependența vâscozității cinematice de presiunea (P) și temperatura (T) a combustibilului.

Din cele mai sus prezentate se desprind următoarele concluzii:

- Problematika modelării variației presiunii în sistemul de injecție cu rampă comună este de actualitate.
- Datorită complexității problemei, studiile întreprinse se restrâng la studiul unor subsisteme.
- Studiile întreprinse nu au condus la concluzii general valabile. Studiile au, în primul rând, o valoare metodologică.

În consecință, rezultă ca rațională și necesară o abordare metodologică generală a modulului rampă comună, care să conducă la un tip de model care să poată fi personalizat pentru diferite tipuri de aplicații.

Astfel, în lucrările [24], [33], [34], [35], autorul tratează subiectul în detaliu, concentrându-se pe particularitățile sistemului PCR cu scopul de a realiza un model matematic al dinamicii presiunii în rampa comună în funcție de debitele masice vehiculate în sistem. În cele ce urmează, acest model matematic este prezentat pe larg.

2.3. Modelul dinamic al presiunii în CR

Combustibilul folosit în alimentarea sistemelor PCR este de mai multe tipuri și poate avea proprietăți diferite. Conform studiului efectuat de Kiiarvi [30], în cadrul modelului matematic al presiunii din CR ar trebui incluse, ca funcții de temperatură (T) și presiune (P), următoarele caracteristici ale fluidului: viteza undei de presiune, densitatea, modulul de elasticitate, vâscozitatea cinematică și densitatea vaporilor.

Pentru o temperatură constantă viteza c a impulsului hidraulic (viteza sunetului) depinde de presiunea P din rampa comună potrivit relației [30]:

$$c(P, T) = a_{c0} + a_{c1}P + a_{c2}P^2, \quad (1)$$

în care a_{c0} , a_{c1} , a_{c2} sunt coeficienți polinomiali dependenți de T .

Tot în condiții de temperatură constantă densitatea ρ a fluidului depinde de presiunea P și viteza c conform relației [30]:

$$\rho = \rho_0 + \int_{P_0}^P \frac{1}{c^2} dP, \quad (2)$$

unde ρ_0 este densitatea la presiunea inițială P_0 .

Modulul de elasticitate al fluidului este definit ca [30]:

$$E = \rho c^2 \quad (3)$$

Conceptul „Common-Rail” se distinge prin includerea în circuitul hidraulic a unei incinte (rampa comună) cu rol de acumulare intermediară a fluidului pompat și de filtrare a variațiilor de presiune cauzate de perturbații. În interiorul acestei incinte cu volumul V_{rail} constant nu există cavitație a fluidului. Ecuația de dinamică a presiunii se poate scrie simplu în funcție de debit și modul de elasticitate:

$$\frac{dP}{dt} = \frac{E(P, T)}{V_{rail}} \left(\sum_{i=1}^{n_{in}} Q_{in} - \sum_{i=1}^{n_{out}} Q_{out} \right), \quad (4)$$

unde:

$Q_{in/out}$ – debitul volumetric care intră/iese din incintă; semnul „+” indică aportul, iar semnul „-” evacuarea masei de combustibil din incintă;

$n_{in/out}$ – numărul de componente ale debitelor de intrare/ieșire din incintă.

Particularizând ecuația (4) pentru sistemul PCR de nouă generație, obținem ecuația ce descrie variația presiunii fluidului în rampa comună:

$$\frac{dP}{dt} = \frac{E(P, T)}{V_{rail}} \cdot (Q_{HPP}^V(t) - Q_{Leak}^V(t) - Q_{INJ}^V(t) - Q_{PCV}^V(t)), \quad (5)$$

unde:

Q_{HPP}^V - debitul volumetric asociat HPP,

Q_{INJ}^V - debitul volumetric asociat injectoarelor,

Q_{PCV}^V - debitul volumetric asociat electrovalvei de presiune,

Q_{Leak}^V - debitul volumetric asociat curgerii continue prin injectoare.

Împărțind și înmulțind în membrul drept al ecuației (5) cu densitatea ρ , putem exprima dinamica presiunii cu ajutorul debitelor masice asociate sistemului:

$$\frac{dP}{dt} = \frac{E(P,T)}{V_{rail} \cdot \rho} \cdot (Q_{HPP}^m(t) - Q_{Leak}^m(t) - Q_{INJ}^m(t) - Q_{PCV}^m(t)). \quad (6)$$

Pe baza relației (3) putem înlocui în ecuația (6) raportul E/ρ cu c^2 :

$$\frac{dP}{dt} = \frac{c^2(P,T)}{V_{rail}} \cdot (Q_{HPP}^m(t) - Q_{Leak}^m(t) - Q_{INJ}^m(t) - Q_{PCV}^m(t)). \quad (7)$$

Relația (7) reprezintă un model matematic neliniar cu parametri concentrați capabil de a genera variația presiunii P în funcție de schimbările de combustibil în care este implicată rampa comună. Se observă că dinamica valului de presiune generat de variația debitelor masice de combustibil depinde de viteza de propagare a sunetului prin fluid. În [24], [33] autorul tezei realizează o analiză corelativă a mărimilor măsurabile ce determină variația debitelor masice din (7). Potrivit acestei analize putem exprima debitele masice ca funcții de următoarele variabile măsurabile:

$Q_{HPP}^m = f(a_{CRK}(t), \varphi, \psi_{VCV}(t), N(t)) - (Q_{HPP}^m - \text{debitul masic de combustibil furnizat de pompă, } \varphi - \text{unghiul de montare al pompei, } a_{CRK} - \text{poziția unghiulară a arborelui cotit, } \psi_{VCV} - \text{deschiderea electrovalvei volumetrică } [\%], N - \text{viteza de rotație a arborelui cotit);$

$Q_{INJ}^m = f(a_{CRK}(t), a_{SOI}, t_{INJ}, mf_{inj}) - (Q_{INJ}^m - \text{debitul masic injectat, } a_{SOI} - \text{poziția unghiulară la care se realizează injectia, } mf_{inj} - \text{cantitatea injectată);$

$Q_{PCV}^m = f(\psi_{PCV}(t), P(t), T(t)) - (Q_{PCV}^m - \text{debitul masic prin PCV, } \psi_{PCV} - \text{deschiderea electrovalvei de presiune } [\%]);$

$Q_{Leak}^m = f(P(t), T(t)) - (Q_{Leak}^m - \text{debitul masic dat de curgerea continuă a injectoarelor}).$

Aspectul este important prin faptul că pentru implementarea modelului de predicție debitele masice nu se măsoară nemijlocit ci se estimează din mărimile de care depind.

2.4. Modelul de predicție a presiunii în rampa comună

După cum am menționat în paragraful 2.1., datorită inerției de calcul a sistemului de timp real, apare necesitatea predicției presiunii pentru intervalul de timp τ_{INJ} dintre momentele la care se realizează calculul (t_{SEG}) pentru t_{INJ} și momentele la care se realizează injectia.

Figura 4 prezintă, pentru un ciclu complet de combustie a sistemului PCR cu 4 INJ și HPP cu 2 pistoane, variația presiunii cauzată de evenimentele mecanico-hidraulice (punctul mort superior – TDC al HPP, momentele de deschidere (SOI) și închidere (EOI) a injectoarelor: t_{SOI} și t_{EOI}) ca funcție de a_{CRK} [33].

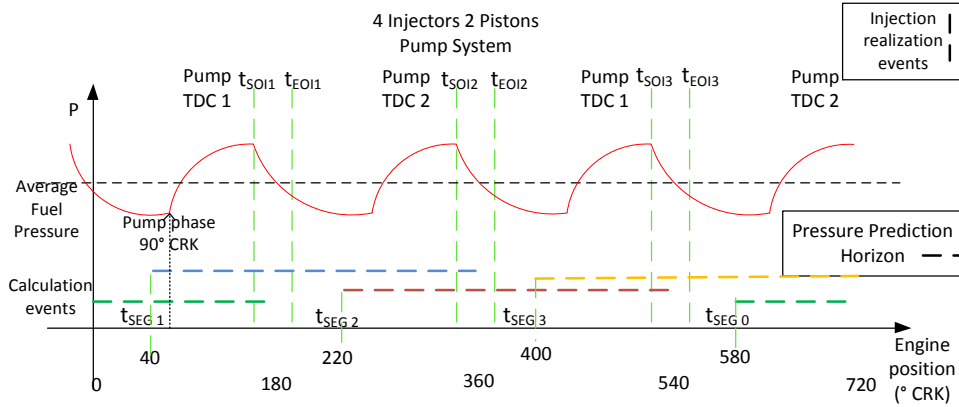


Figura 4. Calculul presiunii pentru un ciclu complet al PCR (720° CRK). Partea de sus – variația P raportată la TDC și t_{SOI} , t_{EOI} , partea de jos – orizontul de predicție în funcție de evenimentul de calcul t_{SEG} [34].

Scopul principal al modelului predictiv este de a crește acuratețea cu care presiunea din CR este folosită în calcule, în speță în calculul timpului de injecție pentru fiecare injector. Pentru aceasta modelul trebuie să genereze la momentele t_{SEGi} , o estimare a variației valorii presiunii de la momentul în care se va realiza injecția pentru injectorul următor. Orizontul de timp de predicție a presiunii pentru care se face estimarea este intervalul $[t_{SEGi}, 0.5(t_{SOIj+1} + t_{EOIj+1})]$ de lungime

$$\tau_{INJi} = 0.5(t_{SOIj+1} + t_{EOIj+1}) - t_{SEGi}$$

Integrând egalitatea (7) pe intervalul $[t_{SEGi}, t_{SEGi} + \tau_{INJi}]$ rezultă:

$$\int_{t_{SEGi}}^{t_{SEGi} + \tau_{INJi}} \frac{dP}{dt} dt = \frac{c^2(P, T)}{V_{rail}} \cdot \int_{t_{SEGi}}^{t_{SEGi} + \tau_{INJi}} [Q_{HPP}^m(t) - Q_{Leak}^m(t) - Q_{INJ}^m(t) - Q_{PCV}^m(t)] dt \quad (8)$$

Deoarece

$$\begin{aligned} \Delta MF_{TOT}(t_{SEGi} + \tau_{INJi} | t_{SEGi}) &= \int_{t_{SEGi}}^{t_{SEGi} + \tau_{INJi}} (Q_{HPP}^m(t) + Q_{Leak}^m(t) + Q_{INJ}^m(t) + Q_{PCV}^m(t)) dt = \\ &= \Delta MF_{HPP}(t_{SEGi} + \tau_{INJi} | t_{SEGi}) + \Delta MF_{Leak}(t_{SEGi} + \tau_{INJi} | t_{SEGi}) + \Delta MF_{INJ}(t_{SEGi} + \tau_{INJi} | t_{SEGi}) + \\ &+ \Delta MF_{PCV}(t_{SEGi} + \tau_{INJi} | t_{SEGi}) \end{aligned} \quad (9)$$

reprezintă cantitatea totală de combustibil care parcurge secțiunea CR pe intervalul de timp $[t_{SEGi}, t_{SEGi} + \tau_{INJi}]$ (ΔMF_{HPP} reprezintă cantitatea de combustibil furnizată de HPP, ΔMF_{INJ} cantitatea de combustibil injectată, ΔMF_{Leak} cantitatea de combustibil scursă, iar ΔMF_{PCV} cantitatea de combustibil evacuată prin PCV), egalitatea (8) se poate rescrie sub forma:

$$\Delta P(t_{SEGi} + \tau_{INJi} | t_{SEGi}) = [c^2(P, T) / V_{rail}] \cdot \Delta MF_{TOT}(t_{SEGi} + \tau_{INJi} | t_{SEGi}) \quad (10)$$

Întrucât V_{rail} este constant, iar în vecinătatea unui punct de funcționare cvasi-staționar $\Lambda(T, P)$ viteza sunetului rămâne, de asemenea, constantă, rezultă că variația presiunii este dependentă de variația masei în CR.

Pe baza ecuației (10), predicția pentru presiunea din CR la sfârșitul intervalului $[t_{SEGj}, t_{SEGj} + \tau_{INJj}]$ poate fi exprimată sub forma:

$$\hat{P}(t_{SEGj} + \tau_{INJj}) = P(t_{SEGj}) + \Delta\hat{P}(t_{SEGj} + \tau_{INJj}) = P(t_{SEGj}) + \Delta P(t_{SEGj} + \tau_{INJj}) \quad (11)$$

Făcând abstracție de funcțiile de calcul a debitelor masice, modelul de predicție al presiunii pe un orizont de timp $[t_{SEGj}, t_{SEGj} + \tau_{INJj}]$ poate fi simbolizat grafic sub forma din fig. 5:




Figura 5. Schema bloc a modelului analitic de predicție a presiunii în rampa comună

O reprezentare aproximativă a curbelor de variație în timp a debitelor masice din PCR, pe intervalul dintre două evenimente de segment $(t_{SEG})^3$ la care ECU realizează calculele, este prezentată în fig. 6 [33]:

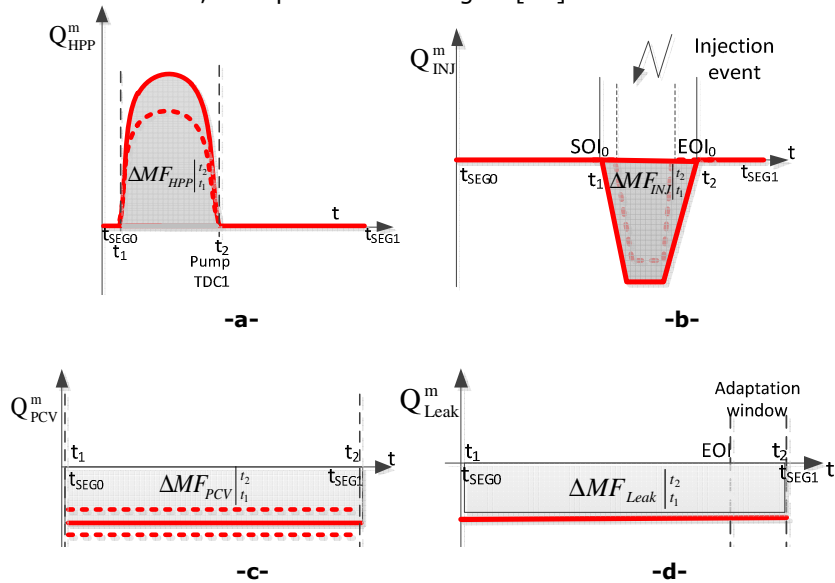


Figura 6. Modele teoretice de variație a debitelor masice pentru: a) Pistonul HPP, b) Injecție, c) PCV, d) Curgere continuă. Liniile continue și punctate sugerează variația în timp a formelor de variație a debitelor [34].

Figurile sugerează diverse forme ale curbelor de debit între momentele de început și de sfârșit a evenimentelor hidraulice notate, generic cu t_1 și t_2 .

³ S-au considerat momentele t_{SEGO} și t_{SEG1} .

După cum am menționat anterior, aceste debite masice sunt funcții de diferite variabile de proces. Curbele de variație nu pot fi determinate cu acuratețe decât experimental. Prin urmare modelul de predicție a variației presiunii determinat analitic, necesită la aplicare forme de undă determinate experimental, memorate în blocuri de interpolare care operează cu mărimi de intrare măsurabile.

Totodată, prin intermediul modelului putem avea o imagine mai clară asupra fenomenelor ce au loc în interiorul CR, aspect deosebit de important pentru inginerii de sistem.

Dat fiind faptul că procesul studiat este unul hidraulic cu mai multe mărimi de intrare și cu un caracter puternic neliniar, este necesară separarea hidraulică a evenimentelor ce se succed în sistem pentru a putea folosi mai departe metode numerice de determinare a coeficienților unui viitor model numeric. Practic, acest lucru înseamnă că, pentru a putea realiza o corelare directă între variația de presiune și variația unui singur debit masic, asociat unei componente sau alta a sistemului, este necesar ca la un moment dat un singur eveniment hidraulic să fie activ. Acest mod de desfășurare secvențială a evenimentelor corespunde realității și este esențial pentru cercetarea prezentată în această teză.

3 SUPOORT TEORETIC PENTRU MODELAREA ȘI IDENTIFICAREA EMPIRICĂ

Scopul principal al identificării sistemelor tehnologice este de a obține o reprezentare a acestora într-o formă, sau folosind un limbaj de descriere, acceptate de comunitatea științifică. Obiectivul activității de identificare este cel de a obține un model al sistemului studiat utilizabil pentru studii și diferite aplicații. Identificarea sistemelor poate conduce la obținerea de modele analitice atunci când se analizează fenomenele fizico-chimice ce se petrec în cadrul sistemului sau poate conduce la modele empirice intrare/ieșire atunci când identificarea se realizează pe baza datelor experimentale. Având la dispoziție sisteme performante de calcul în timp real, este de interes identificarea experimentală cu scopul obținerii unor modele empirice de tip intrare/ieșire ale căror parametri pot fi determinați și actualizați în permanență, cum este cazul modelelor cu adaptarea permanentă a valorilor parametrilor (cazul care prezintă interes pentru teză), folosind secvențe de date măsurate direct de la procesul modelat.

3.1. Modele intrare-ieșire

3.1.1. O privire de ansamblu asupra metodelor de identificare

Figura 7 [36] prezintă o imagine de ansamblu a metodelor de identificare aplicabile sistemelor liniare. Ele pot fi împărțite în două categorii: *parametrice* și *neparametrice* care conduc la modele cu denumiri corespondente.

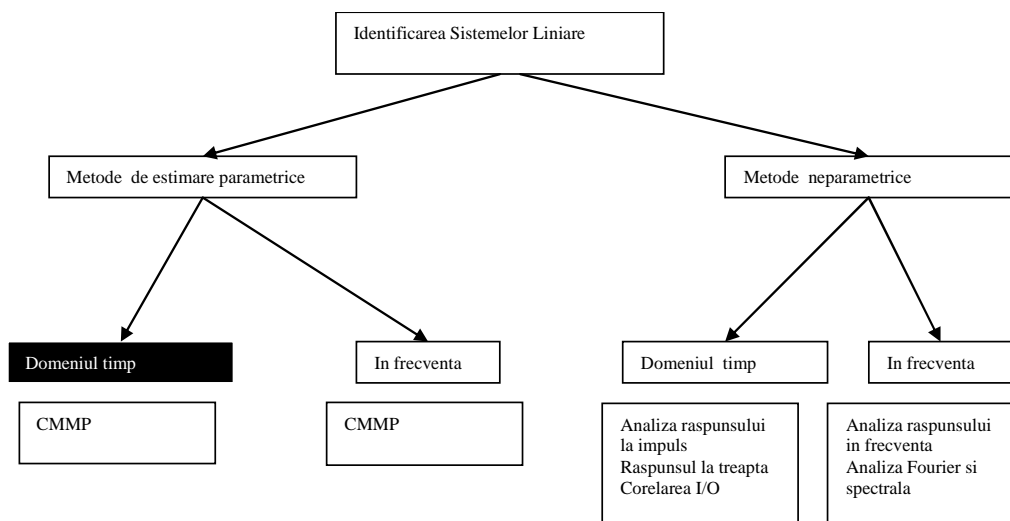


Figura 7. Vedere de ansamblu asupra metodelor de identificare aplicabile sistemelor liniare. Clasificarea se face în funcție de tipul metodei și modul de identificare (CMMP)

Deoarece obiectivul acestui studiu este acela de a obține modele liniare cu parametri adaptabili care descriu dinamica presiunii din CR și pot fi implementate cu ușurință pe un sistem de calcul numeric, în continuare vor fi tratate aspecte ce țin de modele și metodele de estimare parametrice pe bază de serii de timp.

3.1.2. Semnalele de excitație

În procesul de identificare a sistemelor, una din întrebările fundamentale care se pune cu privire la mărimile de intrare este: cum trebuie ales semnalul de excitație?

În majoritatea aplicațiilor industriale există restricții asupra semnalelor de excitație. Scopul acestor restricții este de a proteja sistemele și de a nu permite depășirea limitelor impuse. Din această perspectivă și în contextul tezei principalele noțiuni care ne interesează cu privire la semnalele de excitație sunt [36]:

Amplitudinea semnalului este esențială atunci când măsurarea răspunsului sistemelor identificate este afectată de *zgomot*. Deoarece evenimentul „zgomot” nu poate fi influențat, singurul grad de libertate pe care-l avem este amplitudinea semnalului de excitație. Pentru a obține un raport *semnal/zgomot* cât mai bun, amplitudinea semnalului de excitație trebuie să fie mult mai mare decât cea a zgomotului de măsură.

Spectrul semnalului de intrare determină *frecvențele* la care puterea introdusă în sistem de semnalul de excitație este maximă. De exemplu, folosind un semnal de tip sinusoidal vom obține informații despre răspunsul sistemului pentru o singură frecvență, iar calitatea modelului va fi excelentă doar în jurul acestei frecvențe de excitație. Astfel, este necesar să cunoaștem caracteristicile de pulsație, respectiv spectrul de frecvențe în care operează sistemul pentru a ne forma o imagine completă asupra modurilor sistemului și a formei semnalului care trebuie folosit pentru identificare.

Frecvența de eșantionare joacă un rol important în identificarea sistemelor. Uzual, valorile pentru timpii de eșantionare ai semnalelor sunt de 10-20 de ori mai mici decât cea mai mică constantă de timp. În lucrarea de față, s-a ales un pas de eșantionare $h = 1$ ms din considerente prezentate în finalul *anexei 1*.

3.1.3. Structura generală a modelelor intrare/ieşire

Se consideră un sistem liniar în timp discret având ca mărime de intrare un semnal determinist $\{u(k)\}$, transferul acestuia la ieșirea $\{y(k)\}$ fiind afectat de un zgomot alb $\{v(k)\}$ care induce la ieșire o componentă stocastică. Modelul sistemului se dezvoltă potrivit destinației sistemului și poate servi în diferite scopuri, cum sunt: predicție, simulare, optimizare, analiză, conducere sau detectarea defectelor.

Ieșirea $\{y(k)\}$ a sistemului liniar determinist la momentul k se consideră ca rezultând prin filtrarea intrării $\{u(k)\}$ prin intermediul unui *filtru liniar* $G(q^{-1})$ care reprezintă modelul sistemului. Cu q^{-1} s-a notat operatorul de întârziere cu un tact, adică $q^{-1}u(k) = u(k-1)$. El este omologul operatorului $z^{-1} = e^{-j\omega}$ din domeniul frecvențial. Transferul, neafectat de zgomot, este descris cu relația:

$$y(k) = G(q^{-1})u(k) = \frac{B(q^{-1})}{\tilde{A}(q^{-1})} u(k) \quad (12)$$

Expresia $G(q^{-1})$ se numește funcție de transfer a intrării de la $u(k)$ la ieșirea $y(k)$.

Componenta stocastică a semnalului de ieșire poate fi modelată ca ieșire a unui filtru liniar având la intrare un zgomot alb $v(k)$, potrivit relației:

$$n(k) = H(q^{-1})v(k) = \frac{C(q^{-1})}{\tilde{D}(q^{-1})} v(k), \quad (13)$$

în care $H(q^{-1})$ este funcția de transfer a zgomotului alb la ieșirea $y(k)$.

Modelul liniar care descrie atât influențele deterministe cât și cele stocastice se obține combinând cele două formule:

$$y(k) = G(q^{-1})u(k) + H(q^{-1})v(k) \quad (14)$$

Plecând de la relația (14), Ljung introduce în [10] o detaliere general acceptată a modelului în care cele două filtre $G(q^{-1})$ și $H(q^{-1})$ au unele elemente dinamice comune redate printr-un divizor comun $A(q^{-1})$. Astfel, $\tilde{A}(q^{-1}) = F(q^{-1})A(q^{-1})$ și $\tilde{D}(q^{-1}) = D(q^{-1})A(q^{-1})$, iar ecuația de mai sus se transformă în:

$$y(k) = \frac{B(q^{-1})}{F(q^{-1})A(q^{-1})} u(k) + \frac{C(q^{-1})}{D(q^{-1})A(q^{-1})} v(k) \quad (15)$$

3.1.4. Modelul cu răspuns la impuls în timp finit (FIR)

Modelul FIR este cel mai simplu model liniar intrare/ieșire. El realizează o simplă filtrare cu o medie alunecătoare a mărimii de intrare. Altfel spus, ieșirea modelului reprezintă o sumă ponderată a valorilor anterioare ale intrării afectată de zgomot:

$$y(k) = b_1 u(k-1) + \dots + b_m u(k-m) + v(k) \quad \text{sau} \quad (16)$$

$$y(k) = B(q^{-1})u(k) + v(k) \quad \text{cu} \quad B(q^{-1}) = b_1 q^{-1} + \dots + b_m q^{-m}$$

Se observă că modelul poate fi dedus ca un caz particular din (14) pentru situația când zgomotul acționează chiar la ieșire ($H(q^{-1})=1$) iar partea deterministă nu conține reacții: $\tilde{A}(q^{-1}) = 1$.

Motivația pentru utilizarea modelului FIR provine din faptul că ieșirea oricărui sistem liniar propriu fi exprimată sub forma unei sume de convoluție:

$$y(k) = \sum_{i=1}^{\infty} g_i u(k-i) = g_1 u(k-1) + g_2 u(k-2) + \dots, \quad (17)$$

unde $g_i = g_i(k)$ reprezintă valorile funcției pondere $\{g_i(k)\}$. Pentru sisteme stabile, g_i tinde la 0 atunci când i tinde la infinit. Ieșirea unui sistem FIR rezultă formal prin trunchierea sumei din (17) sub forma $B(q^{-1})u(k)$. Determinarea modelului revine astfel la determinarea polinomului $B(q^{-1})$.

3.1.5. Structuri de sisteme de predicție și simulare

Cea mai întâlnită utilizare a modelelor o reprezintă estimarea evoluției unor procese în scopuri de *simulare* și *predicție* [36].

Simularea constă în calcularea răspunsului modelului la un set de stimuli de intrare și condiții inițiale ale ieșirii sistemului, fără a introduce apoi în calcul alte valori ale acesteia. În ceea ce privește *predicția*, în fiecare pas de calcul k se consideră cunoscute atât ieșirea cât și intrarea procesului pe un interval de timp, până la un moment $k-1$, și se calculează valoarea ieșirii sistemului pentru momentul k (numită valoare estimată sau predicată și notată cu $\hat{y}(k)$) în cazul predicției pe un orizont de timp de un pas (Fig. 8). Predicția poate fi cerută și pentru un orizont de timp de l pași, adică pentru momentul $k+l-1$ ar în acest caz intrarea sistemului trebuie cunoscută până la momentul $k+l-2$. În continuare ne referim la *simulare* și la *predicție* pentru un singur pas $l=1$.




Figura 8. Model de predicție

În continuare ne referim la *simulare* și la *predicție* pentru un singur pas $l=1$.

Simularea este un proces deterministic. În Figura 9 operația de simulare este redată în paralel cu ceea ce se întâmplă în procesul real afectat de zgomot la ieșire. Modelul folosit în simulare este de forma:

$$\hat{y}(k) = G(q^{-1})u(k) \quad (18)$$

Cu toate că zgomotul (de exemplu: zgomot de măsură) nu apare explicit în modelul (18), el influențează valorile parametrilor lui $G(q^{-1})$ (funcția sau operatorul de transfer al procesului) întrucât a intervenit implicit în determinarea valorilor ieșirii pe baza cărora s-a făcut estimarea valorilor parametrilor lui G .

În unele situații, modelul (18) se completează cu un termen stocastic, similar cu cel dat de (13) însă generat de un zgomot alb $\{w(k)\}$, diferit de $\{v(k)\}$ care nu poate fi estimat:

$$\hat{y}(k) = G(q^{-1})u(k) + H(q^{-1})w(k) \quad (18')$$

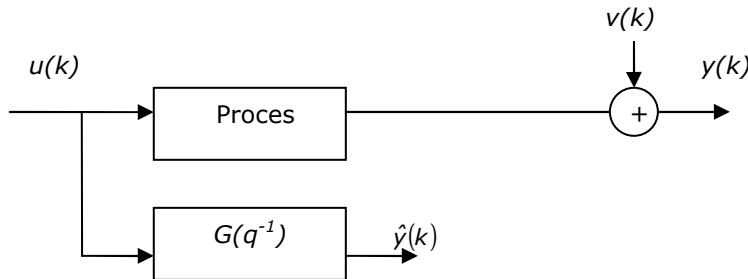


Figura 9. Simulare cu un model bazat pe măsurări afectate de zgomot

Predicția ieșirii pentru un singur pas se bazează, după cum s-a precizat, pe utilizarea informației provenită din valori anterioare ale ieșirii și intrării procesului. În cazul „timp discret”, care interesează în continuare, aceasta înseamnă serii de timp asociate mărimii de ieșire și mărimii de intrare. Ca urmare, în cazul liniar, un *predictor structural optimal* destinat predicției valorii ieșirii la momentul k va avea forma (19) care combină valorile anterioare ale intrării și ieșirii procesului:

$$\hat{y}(k | k-1) = s_0 u(k) + s_1 u(k-1) + \dots + s_{n_s} u(k-n_s) + t_1 y(k-1) + \dots + t_{n_t} y(k-n_t) \text{ sau,} \quad (19)$$

$$\text{concentrat, } \hat{y}(k | k-1) = S(q^{-1})u(k) + T(q^{-1})y(k) \quad (20)$$

Notăția $\hat{y}(k | k-1)$ are rolul de a sublinia că valoarea calculată este o estimare a valorii lui $y(k)$ pe bază de informații cunoscute până la momentul $k-1$ inclusiv. Relației (20) îi corespunde schema din Figura 10a.

Termenul $S(q^{-1})u(k)$ conține partea deterministică a predictorului în timp ce termenul $T(q^{-1})y(k)$ conține și o parte stocastică determinată de zgomotul care influențează ieșirea $\{y(k)\}$ și care, pentru a fi utilizată în (19) este măsurată la momentul anterior al lui k . Filtrul $T(q^{-1})$ nu conține termenul de coeficient t_0 deoarece valoarea ieșirii y la momentul de timp k pentru care se face predicția nu este disponibilă. De asemenea, polinomul $S(q^{-1})$ nu conține în mod obișnuit termenul de coeficient s_0 deoarece valoarea $\hat{y}(k | k-1)$ trebuie utilizată strict la momentul k când se generează $u(k)$ iar calculul din (19) nu se poate face instantaneu. Ca urmare, modelele proceselor reale sunt strict proprii (sisteme la care intrarea nu influențează instantaneu ieșirea). Termenul în s_0 se admite doar în situația în care durata de calcul a valorii date de (19) este insignifiantă în raport cu intervalul de timp absolut dintre momentele discrete k și $k+1$.

Se observă că atât partea deterministă cât și partea stocastică ale predictorului structural optimal sunt reprezentate de câte un filtru FIR. Simplitatea, caracterul liniar și stabilitatea inerentă îl recomandă pentru implementarea pe un sistem de timp real.

Modelul de predicție dezvoltat în cadrul tezei reprezintă un caz particular al modelului (20), corespunzător lui $T(q^{-1})=0$ și $S(q^{-1})$ polinom de ordinul I. Lui îi corespunde schema bloc din Figura 10b.

Eroarea de predicție, evidențiată în fig. 10b, este definită ca diferența dintre ieșirea dorită a modelului (ieșirea procesului real) și predicția realizată de model:

$$e(k) = y(k) - \hat{y}(k|k-1) \quad (21)$$

Eroarea este evidențiată în Figura 10b care conține suplimentar ideea algoritmului CMMP recursiv dezvoltată în paragraful 3.3.2.




Figura 10. Conceptul de predicție

Se demonstrează că predictorul (20) devine unul optimal atunci când $S(q^{-1}) = G(q^{-1})/H(q^{-1})$ iar $T(q^{-1}) = 1 - 1/H(q^{-1})$, unde $G(q^{-1})$ și $H(q^{-1})$ sunt cele din (18') [36].

3.2. Metode și algoritmi pentru identificarea parametrilor

Pentru modelarea variației de presiune în rampa comună în cadru tezei, se vor folosi modele de tip FIR, alegerea fiind dată de ușurința și rapiditatea cu care parametrii sunt calculați.

Ecuția predictorului optimal FIR este:

$$\hat{y}(k|k-1) = B(q^{-1})u(k), \quad (22)$$

respectiv

$$\hat{y}(k | k-1) = b_1 u(k-1) + \dots + b_m u(k-m), \quad (23)$$

iar predicția este caracterizată de eroarea

$$e(k) = y(k) - B(q^{-1})u(k). \quad (24)$$

Predictorul de tip FIR este un model de tip ARX (autoregresiv cu intrare exogenă) fără reacții interne care aparține clasei modelelor cu eroare la ieșire. Întrucât predictorul de tip FIR folosește doar date de intrare, comportarea lui este similară cu a unui model de simulare astfel că putem scrie

$$\hat{y}(k | k-1) = \hat{y}(k). \quad (25)$$

Având în vedere că eroarea de predicție este liniară în raport cu parametrii modelului, aceștia pot fi estimați cu metoda celor mai mici pătrate. Pentru varianta *on-line*, se aplică metoda celor mai mici pătrate recursivă.

3.2.1. Metoda celor mai mici pătrate (CMMP)

Folosind modelul (23) al predictorului, consecutiv, pentru $k=m+1, m+2, \dots, N$, pentru de predictor rezultatul poate fi concentrat în ecuația matriceală :

$$\underline{\hat{y}} = \underline{X} \underline{w} \quad (26)$$

unde:

$$\underline{\hat{y}} = \begin{bmatrix} \hat{y}(m+1) \\ \hat{y}(m+2) \\ \vdots \\ \hat{y}(N) \end{bmatrix}, \quad \underline{w} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix}, \quad \underline{X} = \begin{bmatrix} u(m) & u(m-1) & \dots & u(1) \\ u(m+1) & u(m) & \dots & u(2) \\ \vdots & \vdots & & \vdots \\ u(N-1) & u(N-2) & \dots & u(N-m) \end{bmatrix} \quad (27)$$

\underline{X} se numește matricea regresorilor sau a valorilor măsurate, iar coloanele ei, \underline{x}_i , vectori de regresie. Se observă că sunt utilizate $N-1$ valori consecutive ale intrării.

Eroarea de predicție are expresia:

$$\underline{e} = \underline{y} - \underline{\hat{y}} = \underline{y} - \underline{X} \underline{w} \quad (28)$$

unde $\underline{y} = \begin{bmatrix} y(m+1) \\ y(m+2) \\ \vdots \\ y(N) \end{bmatrix}$. Se constată că sunt manipulate valori ale mărimilor de intrare

și de ieșire de la N momente consecutive.

Determinarea celor m parametri grupați în vectorul \underline{w} se poate face prin rezolvarea unei probleme de minimizare a unei funcții obiectiv $I(\underline{w})$ bazată pe eroarea \underline{e} . În particular se poate considera minimizarea în raport cu \underline{w} a funcției obiectiv:

$$I(\underline{w}) = \frac{1}{2} \underline{e}^T \underline{e} \rightarrow \min_{\underline{w}} \quad (29)$$

Dezvoltând expresia (26) se observă că este o funcție parabolică de vectorul \underline{w} :

$$I(\underline{w}) = \frac{1}{2} \underline{w}^T \underline{H} \underline{w} + \underline{h}^T \underline{w} + h_0 \quad (30)$$

unde: $\underline{H} = \underline{X}^T \underline{X}$, $\underline{h} = -\underline{X}^T \underline{y}$, $h_0 = \underline{y}^T \underline{y}$.

Minimumul se obține atunci când gradientul lui $I(\underline{w})$, funcție de parametrul \underline{w} , este egal cu 0:

$$\frac{\partial I(\underline{w})}{\partial \underline{w}} = -\underline{X}^T \underline{e} = -\underline{X}^T (\underline{y} - \underline{X} \underline{w}) = 0 \quad (31)$$

Din (31) rezultă soluția (valorile optime ale vectorului parametrilor \underline{w} pentru care modelul prezice cel mai bine ieșirea y a procesului):

$$\hat{\underline{w}} = \left(\underline{X}^T \underline{X} \right)^{-1} \underline{X}^T \underline{y} \quad (32)$$

Calculul soluției se poate efectua doar dacă matricea $\underline{X}^T \underline{X}$ este nesingulară. Problema prezentă este cunoscută sub denumirea de metoda CMMP.

Problema *consistenței* rezultatului obținut se pune atunci când comparăm ieșirea modelului estimat cu ieșirea procesului real. Chiar dacă numărul de eșantioane N tinde la infinit, parametri deviază în mod sistematic de la valorile lor optime. Acest comportament este cauzat de faptul că metoda CMMP presupune ca matricea regresorilor \underline{X} să fie obținută într-un mod determinist [36].

3.2.2. Metoda CMMP recursivă (RLS)

Atunci când metoda CMMP este folosită pentru identificarea *on-line* în timp real folosind noi vectori de regresie, este necesar un nou algoritm cărui să îi corespundă un efort computațional constant, fără a folosi simultan toți regresorii constituiți în timp. Un astfel de algoritm este algoritmul CMMP recursiv.

Ideea de bază pentru acest algoritm o constituie calculul parametrilor modelului estimat $\hat{\underline{w}}(k)$ la momentul k adăugând o corecție valorilor $\hat{\underline{w}}(k-1)$ estimate la momentul de timp anterior, $k-1$. Apare astfel o recurență. Vectorul de corecție depinde de noile intrări măsurate ale regresorilor $\underline{x}(k) = [u(k-1) \dots u(k-m)]^T$ și de ieșirea procesului $y(k)$ care intră în componența erorii $\underline{e}(k)$.

Calculul parametrilor $\hat{\underline{w}}(k)$ se poate face cu formula recursivă [36]:

$$\hat{\underline{w}}(k) = \hat{\underline{w}}(k-1) + \underline{R}(k) \underline{x}(k) \underline{e}(k), \quad (33)$$

având

$$\underline{R}^{-1}(k) = \underline{R}^{-1}(k-1) + \underline{x}(k)\underline{x}^T(k)$$

Vectorul $\underline{x}(k)$ reprezintă noua informație măsurată pentru toți regresorii, iar $e(k) = y(k) - \underline{x}^T(k)\hat{\underline{w}}(k-1)$ reprezintă eroarea de predicție cu un pas.

În cazul proceselor dinamice, atunci când orizontul de timp folosit în calcul tinde la infinit, \underline{R} tinde la zero. Acest lucru nu este de dorit deoarece va încetini rata convergenței algoritmului. O soluție o reprezintă introducerea factorului de uitare $\lambda \leq 1$, astfel încât datele obținute cu j pași anteriori să fie ponderate cu un factor exponențial λ^j . Astfel, algoritmul CMMP recursiv pentru identificarea modelului FIR devine:

$$\hat{\underline{w}}(k) = \hat{\underline{w}}(k-1) + \gamma(k)e(k), \quad e(k) = y(k) - \underline{x}^T(k)\hat{\underline{w}}(k-1) \quad (34)$$

$$\gamma(k) = \frac{1}{\underline{x}^T(k)\underline{R}(k-1)\underline{x}(k) + \lambda}$$

$$\underline{R}(k) = \frac{1}{\lambda} \left(I - \gamma(k)\underline{x}(k)\underline{x}^T(k) \right) \underline{R}(k-1)$$

Parametri rezultați sunt:

$$\hat{\underline{w}}(k) = \left[\hat{b}_1(k) \quad \hat{b}_2(k) \quad \dots \quad \hat{b}_m(k) \right]^T \quad (35)$$

3.3. Modele neliniare bazate pe arhitecturi de rețele neuro-fuzzy

3.3.1. Aspecte generale ale rețelelor neurale

Originile conceptului de rețele neurale artificiale se află în structurile biologice prezente în creier, capabile să proceseze și să clasifice informația. Principalele caracteristici ale rețelelor neurale sunt:

- numărul mare de unități simple
- paralelismul între unități
- unitățile sunt puternic interconectate
- robustețea împotriva erorilor cauzate de o unitate singulară
- învățarea din datele introduse

Aceste caracteristici fac din rețelele neurale candidați perfecți pentru implementări hardware și software.

La baza transpunerii în formă matematică a filozofiei rețelelor neurale stă următoarea teoremă a lui Kolmogorov (1957):

Orice funcție continuă cu valori reale $f(u_1, \dots, u_n)$ definită pe I^n ($I = [0, 1]$), $n \geq 2$, poate fi reprezentată sub forma

$$f(u_1, \dots, u_n) = \sum_{q=1}^{2n+1} g_q \left(\sum_{p=1}^n h_{pq}(u_p) \right) \quad (36)$$

unde g_q sunt funcții continue univariabile adecvate, iar $h_{pq}(u)$ sunt funcții continue, monoton crescătoare definite pe intervalul I .

Teorema enunțată de Kolmogorov afirmă că fiecare funcție continuă multi-variabilă poate fi reprezentată prin superpoziția unui număr redus de funcții univariabile continue. Raportându-ne la rețele neurale, rezultatul „afirmă că” fiecare funcție continuă cu mai multe variabile poate fi calculată de o rețea cu două straturi în care unitățile calculează funcțiile continue h_{pq} și g_q [37],[38],[39].

Mai recent, următoarea teoremă a lui Cybenko (1989) definește noțiunea de *aproximator universal* :

Fie $\zeta(\bullet)$ o funcție mărginită, continuă, monoton crescătoare. Fie I_p hiper-cubul unitate p -dimensional $[0,1]^p$ iar $C(I_p)$ spațiul funcțiilor continue în I_p . Atunci, pentru orice funcție f , $C(I_p)$ și $\varepsilon > 0$ date, există un număr întreg M și mulțimile de constante reale α_m , θ_m și w_{mk} cu $m = 1, \dots, M$, $k = 1, \dots, p$, astfel încât să se poată defini

$$F(u_1, \dots, u_p) = \sum_{m=1}^M a_m \cdot \zeta \left(\sum_{k=1}^p w_{mk} u_k - \theta_m \right) \quad (37)$$

ca realizare de aproximare a funcției $f(\bullet)$, f fiind independentă de ζ , adică,

$$|F(u_1, \dots, u_p) - f(u_1, \dots, u_p)| < \varepsilon, \quad \forall \{u_1, \dots, u_p\} \in I_p. \quad (38)$$

În terminologia rețelelor neurale, fiecare nod aflat la ieșire poartă denumirea de *neuron de ieșire* iar mulțimea lor formează *stratul de ieșire*. Fiecare nod din centrul rețelei poartă numele de *neuron ascuns (de procesare)* iar mulțimea lor formează *stratul ascuns*. În sfârșit, nodurile amplasate la intrările rețelei poartă denumirea de *neuroni de intrare (senzoriali)* ce formează *stratul de intrare*.

În literatura de specialitate cele mai cunoscute arhitecturi de rețele neurale feed-forward sunt: *Rețeaua cu perceptroni multistrat (Multilayer Perceptron Network)* și *Rețeaua cu funcții de bază radiale (Radial Basis Functions Network)*.

3.3.2. Rețelele Neuro – Fuzzy

Asocierea rețelelor neurale cu modelele fuzzy are la bază compatibilitățile dintre cele două structuri. Inițial, modelele fuzzy erau introduse în cadrul rețelelor neurale și metodele de învățare, deja stabilite în contextul rețelelor, erau aplicate structurii nou formate. În ultimii ani, optica s-a flexibilizat, în sensul că modelele fuzzy pot fi direct optimizate fără a fi introduse în rețeaua neurală. Dacă pentru neuronul standard suma ponderată modela funcția *sinaptică* a neuronului biologic iar funcția de activare neliniară o modela pe cea *somatică*, la neuronul fuzzy funcția sinaptică determină gradul de apartenență al fiecărei intrări la o mulțime fuzzy dată. Funcția somatică este, de regulă, implementată sub forma unuia din operatorii norma-T sau conorma-T.

Avantajele majore pe care modelele neuro-fuzzy le oferă sunt *încorporarea cunoștințelor anterioare și interpretabilitatea* [40]:

- *Încorporarea cunoștințelor anterioare* permite utilizarea ca punct de plecare pentru modelul neuro-fuzzy, a unor modele deja validate sau a unor

informații despre regiunile din spațiul intrărilor pentru care utilizatorul nu are acces prin măsuratori directe.

- *Interpretabilitatea* permite utilizatorului să extragă informații despre proces în vederea optimizării și, de asemenea, oferă o încredere ridicată atunci când vine vorba de procese tehnologice cu grad sporit de risc.

Diferența majoră dintre sistemele fuzzy și alte modele care aproximează funcții neliniare este posibilitatea interpretării termenilor care definesc regulile. Gradul de interpretabilitate cu care sistemele fuzzy sunt înzestrate este influențat de câțiva factori importanți [36]:

- *Numărul de reguli*: odată cu creșterea numărului de reguli scade interpretabilitatea. În special când avem sisteme cu mai multe intrări și toate combinațiile lingvistice pot fi realizate, utilizatorul nu mai poate înțelege și interpreta modul de funcționare. În consecință, complexitatea modelelor fuzzy trebuie restrânsă. Acest lucru se realizează partiționând spațiul multidimensional al intrărilor în topologii tip grilă folosind premise ale regulilor care nu conțin toate combinațiile lingvistice posibile.
- *Numărul condițiilor semantice din premisă*: Regulile în care premisele conțin mai multe condiții (peste 4) sunt greu de interpretat. În limbajul uzual, pentru a enunța un raționament oamenii folosesc doar câteva condiții cu toate că numărul factorilor care ar putea influența raționamentul este mult mai mare. În acest sens se folosesc funcțiile de apartenență de tip „indiferent” pentru a defini efectul produs de intrările nerelevante asupra regulii.
- *Dimensionalitatea seturilor fuzzy*: Odată cu creșterea dimensiunii spațiului intrărilor crește și numărul de reguli, de aceea o soluție pentru simplificarea raționamentului o reprezintă folosirea directă a mulțimilor fuzzy multidimensionale. Astfel, comportamentul sistemelor fuzzy este echivalent cu cel al rețelelor cu *funcții de bază normalizate* (NRBF).
- *Ordonarea mulțimilor fuzzy*: Este necesar ca mulțimile fuzzy cu care operează un model să fie ordonate, în sensul unui criteriu de monotonie, de ex. de la mic la mare, pentru ca interpretarea rezultatului inferențelor să fie intuitivă. În lipsa unei abordări metodice, în urma optimizărilor, monotonia poate fi pierdută și astfel se pierde o calitate importantă a sistemelor fuzzy: *interpretabilitatea*.
- *Normalizarea funcțiilor de apartenență*: Deseori funcțiile de apartenență se aleg în așa fel încât pentru fiecare intrare suma lor să fie egală cu 1 (partiție a unității) (fig. 11). Atunci când se adăugă sau se renunță la reguli, fiecare funcție de apartenență trebuie normalizată în noul context pentru a-și păstra capacitatea de acțiune. Normalizarea se poate realiza fie prin alegerea unor funcții de apartenență, care în mod natural posedă această proprietate (ex. funcții de apartenență triangulare), fie prin normalizarea arbitrară a lor, transformându-le în funcții de apartenență de tip Gaussian. Datorită normalizării, funcțiile de apartenență își pot extinde influența în afara domeniului local, fapt ce poate cauza efecte nedorite, în special atunci când funcțiile de apartenență unimodale sunt compuse prin produsul tensorilor și formează funcții de apartenență multimodale.




Figura 11. Funcții de apartenență care realizează o partiție a unității

3.3.3. Rețele neuro-fuzzy cu modele locale liniarizate

În literatura de specialitate sunt întâlnite diverse structuri sau arhitecturi de rețele neuro-fuzzy ce conțin modele locale liniare⁴ de mai multe tipuri [42] - [52]:

- modele cu serii de timp (sau cronologice)
- modele polinomiale cu polinoame de diverse grade
- rețele neuronale cu diverse arhitecturi
- sisteme bazate pe reguli fuzzy
- ecuații algebrice diferențiale

Destinația acestor modele este să reproducă cât mai precis regimul de operare al sistemelor studiate în jurul unui punct de funcționare sau altul. Avantajul major al rețelelor neuro-fuzzy este acela că pot îngloba într-o manieră directă astfel modele, incluzând prin aceasta cunoștințele anterioare despre sistem și introducând restricții și limitări.

Sinteza (cvasi-optimală) a structurilor neuro-fuzzy cu modele locale liniarizate se bazează pe principiul „divide et impera”, adică o problemă complexă este divizată în mai multe sub-probleme care sunt rezolvate aproape independent prin găsirea unor modele simple, liniare, cu valabilizate locală [36]. În acest fel, fiecare regim de operare poate fi tratat individual de către un model liniar, sau un număr restrâns de modele liniare, cu parametri optimizați folosind tehnicile de optimizare cunoscute (back-propagation, Gauss-Newton, Orthogonal Least Squares etc.).

3.3.4. O observație privind liniarizarea modelelor matematice

Pentru a favoriza implementările de expresii matematice pe sisteme de calcul în timp real, care impun restricții atât din punctul de vedere al timpului de execuție (CPU load) cât și al spațiului de memorie (ROM size), este necesar ca modelele implementate să utilizeze combinații liniare între parametri. Dependențele neliniare, dar care îndeplinesc anumite condiții de derivabilitate, pot fi liniarizate, după caz, în vecinătatea unui punct de funcționare sau a unei caracteristici de referință, prin liniarizare rezultând expresii liniare atât în raport cu variațiile variabilelor, cât și în raport cu coeficienții. Ne referim doar la primul caz.

Fie $y = g(u)$ o caracteristică statică neliniară, în care $g(\cdot)$ este o funcție derivabilă. Se admite că variabilele u și y au mici variații, Δu și Δy , în jurul unui

⁴ Liniaritatea se consideră în raport cu coeficienții modelelor.

punct nominal de funcționare $M(\bar{u}, \bar{y})$ (fig. 11). Relația care leagă aceste variații este se obține plecând de la identitatea:




Figura 12. Referire la liniarizarea unei funcții neliniare

$$dy = \frac{dy}{du} du \quad (39)$$

sau trecând la diferențe finite:

$$\Delta y = k \cdot \Delta u \quad (40)$$

în care

$$k = \operatorname{tga} = \left(\frac{dy}{du} \right)_{\substack{u=\bar{u} \\ y=\bar{y}}} \quad (41)$$

Prin liniarizare, caracteristica neliniară $y = g(u)$ este înlocuită prin modelul (40), care are următoarele particularități:

- leagă printr-o relație liniară *variațiile* variabilelor ($\Delta y, \Delta u$) față de punctul nominal M ;
- leagă printr-o relație liniară coeficientul k de variația Δy (proprietate deosebit de importantă când u este un vector).

Modelul (40) este valabil în *vecinătatea punctului nominal* M . Dacă se schimbă punctul nominal de funcționare, se modifică parametrul k .

Dacă se are în vedere că $\Delta y = y - \bar{y}$ și $\Delta u = u - \bar{u}$, pentru a calcula valoarea absolută a lui y se folosește dependența afină:

$$y = \bar{y} + k(u - \bar{u}) \quad (42)$$

3.3.5. Modele de predicție pentru sisteme neliniare dinamice

În literatura de specialitate există două modele consacrate pentru modelarea proceselor dinamice neliniare, cel de tip Hammerstein și cel de tip Wiener (Fig. 13). Ele se caracterizează prin folosirea a doi operatori, unul liniar și unul neliniar, în succesiuni diferite. Întrucât operațiile de compunere a operatorilor nu sunt comutative, $y(k)$ din cele două cazuri nu este același.




Figura 13. Modele Hammerstein (stanga) și Wiener (dreapta)

Din analiza proprietăților de predicție într-un singur pas rezultă că modelele de predicție de tip Hammerstein sunt mai ușor de manipulat și au caracteristici doar ușor neliniare, iar acest lucru le recomandă pentru a fi utilizate prin scheme local liniare [36].

În cazul în care cele două structuri sunt folosite pentru predicție și în ipoteza că ele realizează un predictor recursiv de ordinul I dependențele corespunzătoare modelelor sunt de forma:

$$y(k) = f(u(k-1), y(k-1)). \quad (43)$$

Prin liniarizarea acestei dependențe în vecinătatea unui punct de operare (u_0, y_0) rezultă un model linearizat de forma:

$$\Delta y(k) = b_1 \Delta u(k-1) - a_1 \Delta y(k-1), \quad (44)$$

în care $\Delta u(k) = u(k) - u_0$ și $\Delta y(k) = y(k) - y_0$ iar

$$b_1 = \left. \frac{\partial f(u(k-1), y(k-1))}{\partial u(k-1)} \right|_{u(k-1)=u_0, y(k-1)=y_0},$$

$$a_1 = - \left. \frac{\partial f(u(k-1), y(k-1))}{\partial y(k-1)} \right|_{u(k-1)=u_0, y(k-1)=y_0}.$$

Pentru diferite poziții ale punctului de operare (u_0, y_0) valorile coeficienților a_1 și b_1 se modifică. În spațiul de coordonate $u(k-1), y(k-1), y(k)$ relația (44) descrie un plan de aproximare al suprafeței (43). Considerăm doar o porțiune a acestui plan amplasată în vecinătatea unui punct de operare (u_0, y_0) . Presupunem că domeniul de variație a perechii de valori $(u(k-1), y(k-1))$ se descrie printr-o rețea carteziană de puncte de operare (u_0, y_0) . Unui ochi de rețea definit de punctele situate în vârfurile unui dreptunghi îi corespunde un dreptunghi în planul de aproximare. Considerând mai multe puncte de operare în vecinătatea cărora se dezvoltă modele liniare și arundând diferitele ochiuri în mod unic diferitelor modele, suprafața de aproximare va fi formată din mai multe suprafețe dreptunghiulare prezentând în general, în lungul muchiilor, discontinuități. Ca urmare, predictorul (44) care aproximează predictorul (43) nu poate opera pe un domeniu larg de funcționare, din considerente de continuitate, nici cu un singur model liniarizat și nici cu mai multe modele obținute prin liniarizare în vecinătatea mai multor puncte de operare. Soluția o reprezintă modelele biliniare implementate prin interpolatoare biliniare (v. capitolele 4, 5 și 6). Ele păstrează local predictorul (44), estimând valoarea lui y la momentul k pe bază de valori de la momentul $k-1$. El este un predictor într-un singur pas, iar suprafața de predicție se obține prin reuniune de „petice” de suprafețe neplane.

3.3.6. Modelul arborescent linear local (Local Linear Model Tree: LOLIMOT)

Introdus de Nelles [52], modelul LOLIMOT face parte din categoria observatoarelor funcționale fuzzy care au proprietatea de a aproxima un proces dinamic nelinier folosind pe porțiuni modele liniare. Rețelele LOLIMOT reprezintă o soluție practică pentru un model de arhitectură neuro – fuzzy folosită în identificare, utilizată apoi în diferite maniere.

Cu ajutorul structurii LOLIMOT pot fi create relativ ușor modele dinamice cu intrări și ieșiri reprezentate de structura NARX (Non-linear Auto Regressive with eXogenous inputs):

$$\hat{y} = \underline{f} \left(\begin{matrix} u_1(k-1), \dots, u_1(k-n_{u_1}), \dots, u_p(k-1), \dots, u_p(k-n_{u_p}), \\ y_1(k-1), \dots, y_1(k-n_{y_1}), \dots, y_M(k-1), \dots, y_M(k-n_{y_M}) \end{matrix} \right) \quad (45)$$

Structura unui model LOLIMOT (Fig. 14) conține M unități de procesare, în particular M neuroni. Fiecare neuron implementează un model linear local de forma:

$$\hat{y}_i = f_i \left(\begin{matrix} u_1(k-1), \dots, u_1(k-n_{u_1}), \dots, u_p(k-1), \dots, u_p(k-n_{u_p}), \\ y_1(k-1), \dots, y_i(k-n_{y_i}) \end{matrix} \right), \quad i = 1, \dots, M \quad (46)$$

care participă de o manieră aditivă la obținerea ieșirii y . Utilizarea mărimii \hat{y}_i este controlată prin funcția de validare Φ_i cu rol de funcție de activare.

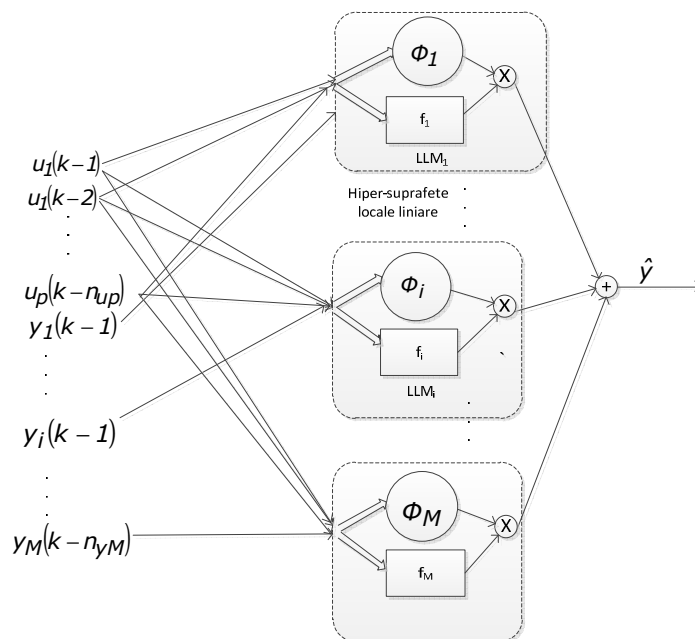


Figura 14. Model NARX implementat cu ajutorul arhitecturii LOLIMOT

Prin funcțiile de validare se asigură contribuția fiecărui neuron la obținerea mărimii de intrare sub forma sumei ponderate:

$$\hat{y} = \sum_{i=1}^M \hat{y}_i = \sum_{i=1}^M f_i(\cdot, \cdot, \dots, \cdot) \cdot \Phi_i(\cdot, \cdot, \dots, \cdot) \quad (47)$$

în care argumentele din paranteze sunt cele din (46), adică coordonatele unui punct de operare. Este foarte important faptul că prin definirea adecvată a funcțiilor de validare se poate face distincție între diferitele puncte de operare ale ansamblului determinate de valorile mărimilor de intrare. Ca urmare, printr-un model LOLIMOT se poate acoperi un întreg domeniu de lucru în care ia valori punctul de operare (spațiul intrărilor).

Funcțiile de validare pentru fiecare model sunt normalizate, adică îndeplinesc condiția:

$$\sum_{i=1}^M \Phi_i(\underline{z}) = 1. \quad (48)$$

Abordarea poate fi reformulată admitând că

- \hat{y}_i poate fi considerat ca funcție de argumente x_i , $i = 1, \dots, n_x$, derivate din cele inițiale, adică

$$\hat{y}_i = f_i(\cdot, \cdot, \dots, \cdot) = \tilde{f}_i(x_1, x_2, \dots, x_{n_x}), \quad i = 1, \dots, M.$$

unde x_1, x_2, \dots, x_{n_x} se obțin prin diferite operații, inclusiv ca funcții neliniare, în particular fuzzy, din mărimile care alcătuiesc argumentele lui f_i . Într-o abordare de tip Hammerstein se poate scrie că

$$\hat{y}_i = w_{i,0} + w_{i,1}x_1 + \dots + w_{i,n_x}x_{n_x}, \quad i = 1, \dots, M. \quad (49)$$

În (49) $w_{i,0}, w_{i,1}, \dots, w_{i,n_x}$ sunt parametri neuronului i al modelului LOLIMOT. Se observă că expresia este liniară în raport cu acești parametri.

- Funcțiile de validare pot, la rândul lor, să fie exprimate ca funcții de alte argumente, z_1, \dots, z_{n_z} , derivate, de asemenea din cele inițiale

$$\Phi_i(\cdot, \cdot, \dots, \cdot) = \tilde{\Phi}_i(z_1, z_2, \dots, z_{n_z}), \quad i = 1, \dots, M. \quad (50)$$

unde z_1, z_2, \dots, z_{n_z} se obțin, de asemenea, prin diferite operații din mărimile care alcătuiesc argumentele lui Φ_i .

- În acest caz, relația (47) devine

$$\hat{y} = \sum_{i=1}^M (w_{i,0} + w_{i,1}x_1 + \dots + w_{i,n_x}x_{n_x}) \tilde{\Phi}_i(\underline{z}) \quad (51)$$

unde $\underline{z} = [z_1 \ z_2 \ \dots \ z_{n_z}]^T$. Pentru a nu diversifica excesiv notațiile

convenim ca în loc de $\tilde{\Phi}_i(\underline{z})$ să notăm $\Phi_i(\underline{z})$, astfel că relația anterioară devine:

$$\hat{y} = \sum_{i=1}^M (w_{i,0} + w_{i,1}x_1 + \dots + w_{i,n_x}x_{n_x}) \Phi_i(\underline{z}) \quad (52)$$

Situației reformulate îi corespunde Fig. 15.

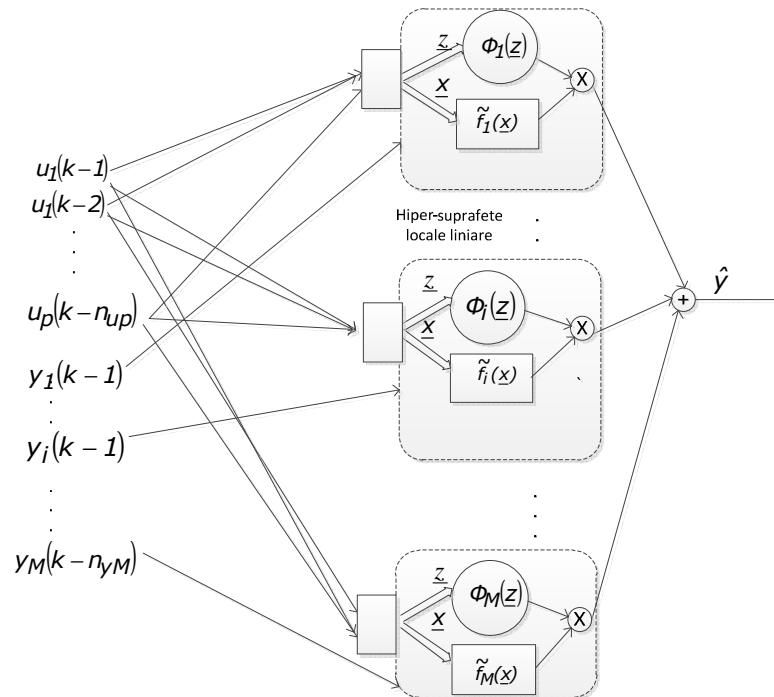


Figura 15. Structura de rețea Neuro - Fuzzy cu modele locale liniare având intrările consecințelor \underline{x} și ale premiselor \underline{z}

Funcțiile de validare sunt, de obicei, alese ca funcții Gaussiene normalizate. Dacă ele sunt și ortogonale, avem:

$$\Phi_i(\underline{z}) = \frac{\mu_i(\underline{z})}{\sum_{j=1}^M \mu_j(\underline{z})} \quad (53)$$

cu

$$\mu_i(\underline{z}) = e^{-\frac{1}{2} \left(\frac{(z_1 - c_{i,1})^2}{\sigma_{i,1}^2} + \dots + \frac{(z_{n_z} - c_{i,n_z})^2}{\sigma_{i,n_z}^2} \right)} \quad (54)$$

Coordonatele centrului $c_{i,j}$, care corespunde punctului de operare al sistemului în vecinătatea căruia este valabil modelul purtat de un neuron, și deviațiile standard $\sigma_{i,j}$ reprezintă parametrii neliniari ascunși ai rețelei neurale

asociați variabilelor derivate $\underline{z} = [z_1 \ z_2 \ \dots \ z_{n_z}]^T$. În cazul unidimensional funcția de apartenență Gaussiană unidimensională are aspectul:

$$\mu_i(z) = e^{-\frac{1}{2} \frac{(z-c_i)^2}{\sigma_i^2}} \quad (55)$$

Caracterul de rețea neuro-fuzzy al structurii LOLIMOT poate fi subliniat în mai multe moduri. De exemplu, funcțiile de validare pot fi considerate ca aparținând premisei unei reguli de producție de tip IF-THEN folosite în logica fuzzy, iar o expresie de tipul (46) sau (49) ca aparținând concluziei aceleiași reguli. Dacă agregăm toate variabilele de intrare într-un singur vector atunci (49) se poate asimila concluziei dintr-un model Takagi-Sugeno.

În acest context, subliniem că modelele neuro-fuzzy de tip LOLIMOT dezvoltate în continuare plecând de la structurile figurile 14 și 15 din paragraful anterior sunt, la un prim nivel de abordare, modele de tip Takagi-Sugeno, fiecare neuron i corespunzând unei reguli a cărei premisă apare prin funcția de validare Φ_i și a cărei concluzie corespunde operației realizate de modelul liniar local LLM _{i} .

3.3.7. Algoritmul de construcție arborescentă a modelului liniar local (LOLIMOT)

Algoritmul de construcție a modelului LOLIMOT aparține clasei de algoritmi incrementalii deoarece la fiecare iterație modelul este augmentat cu două noi reguli și diminuat cu o regulă, deci cu noi funcții de validare și un noi LLM-uri. Structura algoritmului de generare a LOLIMOT [52] este constituită din două bucle de calcul: una *externă*, în care se elaborează premisele noii perechi de reguli și se adaptează premisele celorlalte reguli și una *internă* în care se calculează parametrii concluziilor noii perechi de reguli ca soluții ale unor probleme de optimizare. Diferitele LLM-uri corespund împărțirii spațiului intrărilor după direcțiile axelor ortogonale asociate variabilelor de intrare. În final, corespunzător partiționării axelor, spațiul intrărilor este descompus în hipercuburi, în cazul bidimensional, în dreptunghiuri, ale căror centre furnizează coordonatele $c_{i,j}$ care reprezintă parametrii funcțiilor de apartenență Gaussiene $\mu_i(\underline{z})$, $i = 1, \dots, M$.

Pașii algoritmului:

1) Pornirea algoritmului

- Algoritmul pornește cu un model inițial care corespunde unei partiționări prealabile a spațiului intrărilor în M' hipercuburi. În particular, în lipsa unor cunoștințe apriorice se pornește cu $M' = 1$.
- Pentru fiecare hipercub se consemnează centrul, respectiv coordonatele $c_{i,j}$ ale acestuia, se calculează deviația standard considerând

$$\sigma_{i,j} = L_{i,j} / 3$$

unde $L_{i,j}$ este extensia hipercubului i după direcția j (lungimea laturii respective), se calculează funcția de validare Φ_i și se determină parametrii $w_{i,0}, w_{i,1}, \dots, w_{i,n_x}$ din concluzie, de exemplu prin metoda CMMP, valoarea lui n_x fiind adoptată în prealabil.

- Dacă nu există o împărțire inițială a spațiului intrărilor ($M'=1$), se adoptă $\Phi_1(z) = 1$.

2) *Stabilirea celui mai slab LLM din cele M' modele locale liniare rezultate în pasul anterior:*

- Se calculează valoarea unui indice de performanță I_i pentru fiecare LLM i . Se notează cu l indicele pentru care a rezultat cea mai neperformantă valoare (de regulă cea mai mare). LLM cu indicele l este cel mai slab din cele M modele.
- Ca indice de performanță se pot alege diferite expresii care să țină seama de erorile de predicție corespunzătoare punctelor de măsurare μ din spațiul intrărilor și de gradul de validare al modelului în punctul μ . În particular, se poate considera:

$$I_i = \sum_{\mu=1}^N e^2(\mu) \Phi_i(\underline{u}(\mu)), \quad (56)$$

unde N este numărul punctelor de măsurare.

3) *Divizarea hipercubului l :*

- LLM cu indicele l este supus mai departe rafinării prin divizare. Hipercubul l este împărțit în câte două hipercuburi prin divizarea ortogonală a axei corespunzătoare fiecărei direcții j (segmentele de lungime $L_{i,j}$ se împart pe rând în două jumătăți egale). Apoi, pentru fiecare diviziune în parte se parcurg următorii pași:
 - (1) Construirea *tuturor* funcțiilor de validare corespunzătoare luării în considerare a noii diviziuni.
 - (2) Estimarea locală a parametrilor concluziilor pentru cele două noi reguli asociate hipercuburilor rezultate în urma diviziunii.
 - (3) Calcularea indicelui de performanță pentru întreg modelul.

4) *Stabilirea unui nou LOLIMOT:*

- Noul LOLIMOT este dat de varianta de la pasul 3) pentru care la subpasul (3) se obține valoarea cea mai mică a indicelui de performanță (diviziunea selectată). El se compune din cele $M'-1$ LLM-uri din pasul anterior, dar cu funcții de validare modificate (expresiile din concluzie nu se modifică) și din cele două LLM-uri corespunzătoare diviziunii selectate.
- Dacă valoarea indicelui obținută cu diviziunea selectată satisface un criteriu de validare sau dacă $M'+1$ ajunge egal cu o valoare impusă M^{\max} modelarea se încheie și se consideră $M = M'+1$. Altfel, se consideră pentru M' valoarea augmentată $M'+1$ și calculul se reia cu pasul 2.

După cum se observă, criteriile de determinare a modelului, sunt variate și țin de complexitatea modelului, de numărul maxim de LLM, de informația disponibilă etc. Practic, avem de-a face atât cu o *optimizare de parametri* cât și cu o *optimizare de structură*. Posibilitatea de a combina diferite obiective reprezintă unul dintre marile avantaje ale LOLIMOT.

În pasul 2, pentru a compara LLM-urile, este folosită suma pătratelor erorilor locale și nu media lor. În consecință, cu LOLIMOT este de preferat să se divizeze hipercuburile care conțin cele mai multe secvențe de date, mai multă informație permițând estimarea mai multor parametri.

În particular, LOLIMOT poate fi utilizat pentru strategii de optimizare cu un pas înainte, calculele furnizând îmbunătățirile de la o iterație la alta [36]. Generalizând, acest algoritm de optimizare se poate extinde și la strategii de optimizare pe k pași. În acest caz, spațiul intrărilor se divizează și se alege cel mai bun model după k iterații. Un dezavantaj îl prezintă creșterea exponențială a efortului computațional odată cu creșterea orizontului k .

Complexitatea computațională pentru algoritmul LOLIMOT se poate evalua cu formula:

$$O(2p(p+1)^3) \approx O(2p^4) \quad (57)$$

unde p reprezintă numărul de dimensiuni ale spațiului intrărilor. La fiecare iterație trebuie estimate $2p$ LLM-uri. Pentru un număr de M neuroni, formula devine:

$$O(2Mp(p+1)^3) \approx O(2Mp^4) \quad (58)$$

Având la îndemână uneltele teoretice necesare, în următoarele capitole va fi analizată problematica modelării și identificării empirice a sistemului PCR folosind rețele neuro-fuzzy, în scopul predicției variației presiunii din rampa comună.

Aplicația software rezultată va implementa o variantă optimizată din punct de vedere computațional a arhitecturii modelului împreună cu algoritmul adaptiv bazat pe metoda CMMP recursivă.

4 MODELUL NEURO-FUZZY ADAPTIV DE PREDICȚIE A PRESIUNII ÎN SISTEMUL PCR

Având la dispoziție modelul teoretic de principiu al procesului (Fig. 5) și ideea implementării lui folosind modele de prelucrare de tip LOLIMOT, următoarea provocare o reprezintă determinarea parametrilor modelului de tip LOLIMOT, inclusiv a funcțiilor de validare, pentru un spațiu de lucru predefinit. Acest lucru presupune încorporarea *cunoștințelor apriorice* într-o structură capabilă să opereze cu datele măsurate de o manieră *salvat tempore*, deopotrivă flexibilă și robustă. Ca regulă generală, în elaborarea structurii modelului se folosește principiul *parcimoneii* [10], în baza căruia se consideră drept cea mai bună structura cea mai simplă, cu cele mai puține grade de libertate, și care modelează adecvat procesul, adică răspunde la toate necesitățile identificate.

Astfel, inspectarea proceselor din rampa comună (paragraful 4.1) conduce la observația că acestea se desfășoară secvențial și cvasi-periodic. Secvențele unei perioade, denumite *faze*, pot fi considerate într-o primă abordare, așa cum se prezintă în paragraful 4.1.1., ca fiind reprezentate de operații disjuncte dependente de poziția arborelui cotit, respectiv de valoarea unghiului σ_{CRK} . Constatarea este foarte importantă întrucât permite un al doilea nivel de structurare a prelucrării informației, așa cum se arată în paragraful 4.2. Pe de altă parte, diferitele faze sunt asociate cu forme de undă ale debitelor masice, de tipul celor din fig. 6, specifice proceselor de transfer de combustibil la care participă rampa comună. Din această perspectivă în paragraful 4.1.2. se subliniază influența vâscozității cinematice asupra acestor debite.

Implementarea modelelor de tip LOLIMOT pentru operare în timp real, cum este cazul rampei comune, trebuie să asigure două tipuri de operații: pe de-o parte adaptarea permanentă a parametrilor modelului, iar pe de altă parte utilizarea modelului pentru operații de predicție. În acest scop, în paragraful 4.3. se prezintă schema bloc prin care se asigură cele două operații.

Un ultim aspect abordat în capitol, tratat în paragraful 4.4, are ca punct de pornire aspectul exponențial al funcțiilor de apartenență (54) și (55) care participă la calcularea gradelor de validitate ale modelelor locale. Implementarea operatorilor exponențiali pentru aplicații de timp real este consumatoare de timp și de resurse [54],[55]. Din considerente de economie de timp (*salvat tempore*) și de resurse, soluția propusă constă în utilizarea ca tip de funcții de apartenență la domeniul de funcționare a formelor trapezoidale și dreptunghiulare.

4.1. Aprofundarea modului de funcționare a CR

Obiectivul acestui paragraf este de a realiza un efect de lupă asupra aplicării principiului LOLIMOT, expus în capitolul anterior, în sensul rafinării acestuia în vederea implementării cât mai avantajoase a operației de predicție a valorii variației de presiune în rampa comună.

4.1.1. Funcționarea în faze

Sistemul PCR funcționează în regimuri cvasi-periodice în sensul că pe intervale de timp delimitate, regimul de funcționare poate fi considerat periodic. Indiferent de regim, o perioadă corespunde rotirii arborelui cotit cu un unghi de 720 °CRK (2 rotații) adică $a_{CRK} \in [0,720)$. Dezvoltarea prezentată în continuare corespunde unui regim particular de funcționare, realizabil în bune condiții și experimental, caracterizat prin faptul că electrovalva de presiune PCV este închisă. Adoptarea acestei condiții este importantă prin faptul că ea permite separarea hidraulică a evenimentelor din cursul unei perioade, adică considerarea lor ca evenimente disjuncte. Din punct de vedere matematic aceasta înseamnă că debitul corespunzător electrovalvei, Q_{PCV}^m , se consideră nul.

Pe parcursul unei perioade se petrec 7 tipuri de evenimente hidraulice: 4 cu impulsuri singulare (1 impuls), 2 cu câte 2 impulsuri, 1 cu 4 impulsuri. Evenimentele sunt ilustrate în fig. 16.

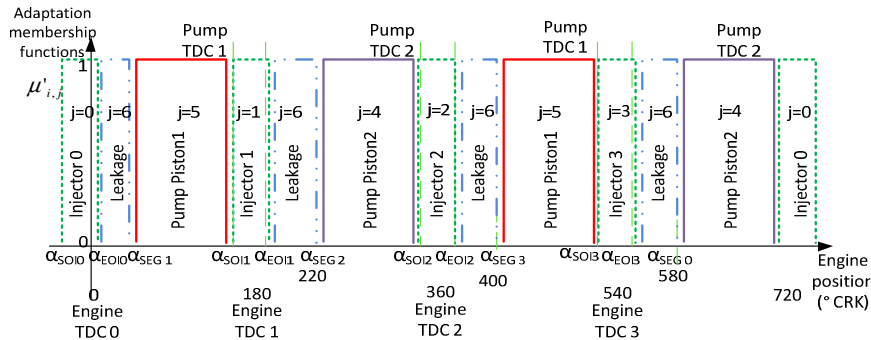


Figura 16. Faze și funcțiile de apartenență corespunzătoare [35].

Evenimentele cu impulsuri singulare corespund fazelor de injecție ($j=0, 1, 2, 3$):

- Injecția realizată de INJ_1 – pentru $a_{CRK} \in [a_{SOI1}, a_{EOI1})$ ($j=1$)
- Injecția realizată de INJ_2 – pentru $a_{CRK} \in [a_{SOI1}, a_{EOI1})$ ($j=2$)
- Injecția realizată de INJ_3 – pentru $a_{CRK} \in [a_{SOI1}, a_{EOI1})$ ($j=3$)
- Injecția realizată de INJ_0 – pentru $a_{CRK} \in [a_{SOI1}, a_{EOI1})$ ($j=0$)

Evenimentele de tip dublu impuls corespund fazelor de compresie ($j=4,5$):

- Compresiei realizată de pistonul 2 al HPP ($j=4$)
- Compresiei realizată de pistonul 1 al HPP ($j=5$)

Evenimentul de tip impuls multiplu corespunde fazei de curgeri, adică:

- Scurgerii de combustibil prin injectoare ce apare după realizarea injecției.

Cele 7 evenimente enumerate ($j=0\dots6$) sunt denumite în continuare *faze de funcționare*. După cum poate fi observat, fazele sunt mutual exclusive. Reperele

marcate în fig. 16 pe abscisă se referă la poziția de calcul (relativă la a_{CRK}) pentru evenimentele de injecție, denumite și evenimente de segment (ele au loc la fiecare $180^\circ CRK$: $a_{i,SEGS+1} = a_{i,SEGS} + 180^\circ$) și la poziția de început și sfârșit a unei injecții ($a_{i,SOIS}$, $a_{i,EOIS}$).

În paragraful 2.4 a fost redată o variație teoretică a presiunii P în CR pentru o perioadă de $720^\circ CRK$. În fig. 17 este prezentată variația lui P pentru un caz concret, în jurul punctului de operare $\Lambda(20^\circ C, 130 \text{ MPa})$. Figura a fost obținută de autor prin prelevarea valorilor de presiune din CR și ale poziției a_{CRK} , eșantionate la 1 ms , pe durata a 70 de perioade consecutive ale sistemului folosind standul din fig. 33. În cursul experimentului viteza de rotație a arborelui cotit a fost menținută constantă. Curba figurată cu linie continuă a fost obținută prin medierea valorilor instantanee pentru valori apropiate ale lui a_{CRK} . Pentru aplicația prezentată în cadrul tezei este de reținut faptul că P și a_{CRK} pot fi măsurate și utilizate sincron în operațiile de adaptare și predicție.

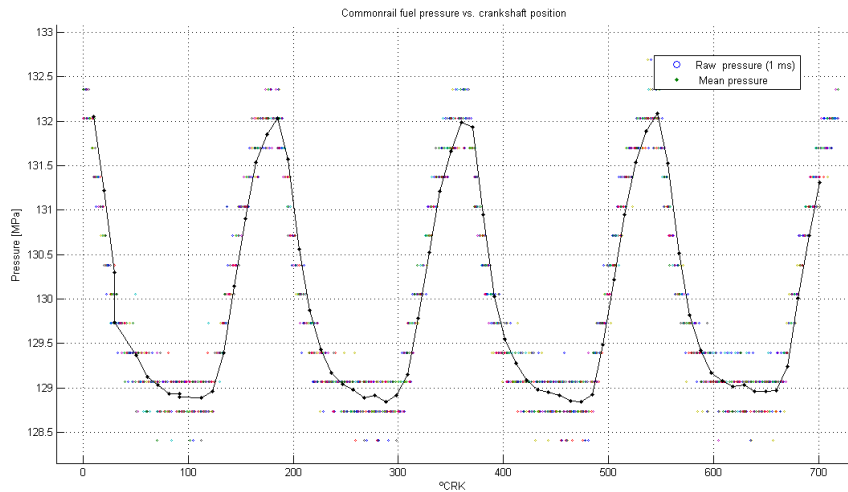


Figura 17. Variația presiunii în Common-rail vs. poziția arborelui cotit pentru un ciclu motor complet ($720^\circ CRK$).

Pe parcursul celor 7 faze se produc variații temporale ale debitelor masice de forma celor reprezentate în fig. 6. Fenomenele de variație a debitelor din fig. 6 fiind corelate cu poziția arborelui cotit, adică a_{CRK} , rezultă că în funcție de viteza de rotație, extensia lor temporală poate să fie mai mare sau mai mică. În calculele de predicție se operează cu eșantioane ale acestor debite obținute la momente echidistante pentru pasul de eșantionare $h=1 \text{ ms}$. În consecință, eșantionarea formelor de undă din fig. 6 la diferite viteze de rotație ale arborelui cotit va conduce la valori diferite ale curbelor de debit. În acest context, curbele teoretice de debit se vor implementa prin modele interpolative care vor furniza valorile eșantioanelor în funcție de valorile curente ale a_{CRK} . Conceptul este redat în fig. 18:




Figura 18. Valorile variabilelor asociate debitelor masice se obțin în funcție de a_{CRK} prin interpolare.

4.1.2. Influența vâscozității cinematice

Variația de presiune generată de debitele care apar în relația (7) depinde de vâscozitatea cinematică a combustibilului diesel. Un studiu efectuat pe mai multe sortimente de combustibili diesel [32] relevă faptul că vâscozitatea cinematică este dependentă, la fel ca și E , de punctul de operare $\Lambda(T,P)$ (fig. 19):




Figura 19. Variația vâscozității cinematice pentru un tip de combustibil diesel în funcție de presiune la diverse temperaturi: \blacklozenge 20 °C, \blacksquare 40 °C, \blacktriangle 60 °C [32].

Influența vâscozității cinematice asupra dinamicii presiunii în CR se realizează prin intermediul modului de variație în timp al debitelor și este dificil de surprins prin modele analitice. *Din acest motiv este justificată utilizarea, în continuare, în modelul de predicție a variației presiunii, a unui număr relativ mare de parametri numerici cu valori reactualizate permanent de o manieră adaptivă.*

4.2. Arhitectura modelului de predicție a presiunii

Potrivit celor prezentate în capitolul 3, un model de tip LOLIMOT este alcătuit în primă instanță din blocuri de modelare locală LM asociate diferitelor puncte de operare din spațiul intrărilor. Ideea este redată mai jos în fig. 20:




Figura 20. Structura de rețea neuro-fuzzy cu modele locale dinamice. Ponderarea în ieșirea finală a fiecărui model local LM este dată de funcțiile de validare Φ_i .

În această figură s-a notat cu \underline{u} vectorul mărimilor de intrare și cu y valoarea măsurată a presiunii din CR. În componența lui \underline{u} intră trei mărimi scalare: debitele masice Q_{HPP}^m , Q_{INJ}^m și Q_{Leak}^m .

Din aceste mărimi se sintetizează trei grupuri de mărimi notate cu

$$\underline{x} = [x_1, x_2, x_3]^T, \quad \underline{z} = [z_1, z_2]^T \text{ și } z'$$

unde:

$$x_1 = Q_{HPP}^m, \quad x_2 = Q_{INJ}^m, \quad x_3 = Q_{Leak}^m, \quad z_1 = T, \quad z_2 = P \text{ și } z' = a_{CRK}.$$

Se observă că, pe de o parte, așa cum s-a precizat în paragraful anterior, a fost omis debitul prin PCV realizându-se un model valid doar pentru PCV închis, iar, pe de altă parte, că vectorul \underline{z} conține chiar valorile coordonatelor punctului de operare $\Lambda(T, P)$.

Spre deosebire de varianta clasică a LOLIMOT referită în capitolul 3, arhitectura modelului destinat predicției variației de presiune în CR, considerat în continuare, rafinează structura din fig. 20 prin faptul că fiecare bloc LM este la rândul lui o structură ce conține 7 modele LLM (*modele sau operatori de fază*) asociate fiecăreia

din cele 7 faze. Structura este reprezentată în fig. 21. Vom considera că prin adoptarea acestei structurări se introduce un al doilea nivel de procesare în arhitectura modelului, inferior - Nivelul 2 - de fază.

Fiecărui model de fază îi corespunde o funcție de validare de fază, $\Phi'_{i,j}$, destinată discriminării fazei respective (identifică faptul că faza este în curs de execuție). Modelele LLM sunt modele de tip Hammerstein cu partea neliniară reprezentată de curba teoretică de variație a debitelor masice (Fig. 6) și partea liniară funcționând ca un filtru FIR de ordinul 2 pentru dinamica debitelor.




Figura 21. Structura de rețea neuro-fuzzy cu modele locale dinamice. Pe al 2-lea nivel sunt modele locale LM_i ce conțin modele liniare dinamice LLM_{i,j} activate de funcțiile de validare $\Phi'_{i,j}$. [24]

Cele 7 funcții de validare de fază $\Phi'_{i,j}(a_{CRK}) = \Phi'_{i,j}(z')$, considerate prin notația $j=0\dots6$, se obțin dintr-o singură funcție de apartenență de fază

$$\Phi'_{i,j}(z') = \mu'_{i,j}(z'), \quad j = 0, \dots, n-1, \quad (59)$$

în care potrivit corespund reprezentării din fig. 16, avem:

$$\mu'_{i,j}(z') = \sigma(z' - a_{SOIj}) - \sigma(z' - a_{EOIj}), \quad j = 0, \dots, 3$$

pentru cele 4 evenimente de injecție asociate celor 4 injectoare;

$$\mu'_{i,4}(z') = \sum_{s=0}^1 [\sigma(z' - a_{SEG2s}) - \sigma(z' - a_{SOI2s})]$$

pentru evenimentul de pompare distribuită asociat cu pistonul 2;

$$\mu'_{i,5}(z') = \sum_{s=0}^1 [\sigma(z' - a_{SEG2s+1}) - \sigma(z' - a_{SOI2s+1})]$$

pentru evenimentul de pompare distribuită asociat cu pistonul 1;

$$\mu'_{i,6}(z') = \sum_{s=0}^3 [\sigma(z' - a_{EOIs}) - \sigma(z' - a_{SEGS+1})]$$

pentru evenimentul de curgere distribuită⁵.

Conform arhitecturii din fig. 21, fiecare LLM_{i,j} furnizează o valoare (asociată concluziei) calculată cu formula:

$$\hat{y}_{i,j}(k) = \sum_{l=1}^{n_x} \underbrace{b_{i,j,l}(q^{-1}) x_l(k)}_{\hat{y}_{i,j,l}(k)}, \quad b_{i,j,l}(q^{-1}) = b_{i,j,l}^1 q^{-1} + b_{i,j,l}^2 q^{-2} \quad (60)$$

unde $j = 0, \dots, 6$ (corespunde fazelor hidraulice ciclice corelate cu a_{CRK}) și $l = 1, \dots, n_x$ cu $n_x = 3$ (corespunde debitelor masice). Coeficienții $b_{i,j,1}^1 \dots b_{i,j,3}^2$ ai operatorilor liniari $b_{i,j,l}(q^{-1})$ se determină prin operații de identificare de tipul celor descrise în paragraful 3.2.2. Având în vedere că pe parcursul oricărei faze se utilizează doar un singur debit masic, celelalte fiind nule, rezultă că pentru fiecare neuron i , $i = 1, \dots, M$, în fiecare dintre cele 7 expresii din (60), corespunzătoare lui $j = 0, \dots, 6$, 4 dintre cei 6 coeficienți pot să fie considerați nuli, întrucât debitele masice cu care se înmulțesc sunt întotdeauna nule. Ca urmare, pentru cele 7 faze se obțin relațiile:

$$\begin{aligned} \hat{y}_{i,0,2}(k) &= b_{i,0,2}^1 x_2(k-1) + b_{i,0,2}^2 x_2(k-2) & (61) \\ \hat{y}_{i,1,2}(k) &= b_{i,1,2}^1 x_2(k-1) + b_{i,1,2}^2 x_2(k-2) \\ \hat{y}_{i,2,2}(k) &= b_{i,2,2}^1 x_2(k-1) + b_{i,2,2}^2 x_2(k-2) \\ \hat{y}_{i,3,2}(k) &= b_{i,3,2}^1 x_2(k-1) + b_{i,3,2}^2 x_2(k-2) \\ \hat{y}_{i,4,1}(k) &= b_{i,4,1}^1 x_1(k-1) + b_{i,4,1}^2 x_1(k-2) \\ \hat{y}_{i,5,1}(k) &= b_{i,5,1}^1 x_1(k-1) + b_{i,5,1}^2 x_1(k-2) \\ \hat{y}_{i,6,3}(k) &= b_{i,6,3}^1 x_3(k-1) + b_{i,6,3}^2 x_3(k-2) \end{aligned}$$

Astfel expresia lui \hat{y}_i devine:

$$\begin{aligned} \hat{y}_i(k) &= \underbrace{(b_{i,0,2}^1 x_2(k-1) + b_{i,0,2}^2 x_2(k-2))}_{LLM_{i,0}} \phi'_{i,0}(z'(k)) + \underbrace{(b_{i,1,2}^1 x_2(k-1) + b_{i,1,2}^2 x_2(k-2))}_{LLM_{i,1}} \phi'_{i,1}(z'(k)) + & (62) \\ &+ \underbrace{(b_{i,2,2}^1 x_2(k-1) + b_{i,2,2}^2 x_2(k-2))}_{LLM_{i,2}} \phi'_{i,2}(z'(k)) + \underbrace{(b_{i,3,2}^1 x_2(k-1) + b_{i,3,2}^2 x_2(k-2))}_{LLM_{i,3}} \phi'_{i,3}(z'(k)) + \\ &+ \underbrace{(b_{i,4,1}^1 x_1(k-1) + b_{i,4,1}^2 x_1(k-2))}_{LLM_{i,4}} \phi'_{i,4}(z'(k)) + \underbrace{(b_{i,5,1}^1 x_1(k-1) + b_{i,5,1}^2 x_1(k-2))}_{LLM_{i,5}} \phi'_{i,5}(z'(k)) + \\ &+ \underbrace{(b_{i,6,3}^1 x_3(k-1) + b_{i,6,3}^2 x_3(k-2))}_{LLM_{i,6}} \phi'_{i,6}(z'(k)) \end{aligned}$$

⁵ $\sigma(x)$ reprezintă funcția treaptă unitară.

iar

$$\Delta \hat{P}(k) = \hat{y}(k) = \sum_{i=1}^M \hat{y}_i(k) \phi_i. \quad (62)$$

În calculele curente se lucrează cu valori normalizate ale mărimilor x_1, x_2, x_3 . Pentru normalizare se folosește relația (63) în care x_{lmin} și x_{lmax} reprezintă valorile minime respectiv maxime ale lui x_l .

$$\tilde{x}_l(k) = \frac{x_l(k) - x_{lmin}}{x_{lmax} - x_{lmin}}, \quad l = 1, \dots, n_x. \quad (63)$$

Relația (63) se poate rescrie sub forma:

$$\begin{aligned} \tilde{x}_l(k) &= x_{lmin} + \Delta x_l \cdot x_l(k), \quad l = 1, \dots, n_x \\ \Delta x_l &= x_{lmax} - x_{lmin} \end{aligned} \quad (64)$$

În valori normate pentru (59) obținem:

$$\hat{y}_{i,j,l}(k) = (b_{i,j,l}^1 + b_{i,j,l}^2) \cdot x_{lmin} + b_{i,j,l}^1 \cdot \Delta x_l \cdot \tilde{x}_l(k-1) + b_{i,j,l}^2 \cdot \Delta x_l \cdot \tilde{x}_l(k-2) \quad (65)$$

Întrucât $x_{lmin} = 0$ (toate debitele sunt unidirectionale), primul termen din (65) dispare.

Introducând notațiile

$$b_{i,j,l}^1 \cdot \Delta x = w_{i,j,l}^1 \quad \text{și} \quad b_{i,j,l}^2 \cdot \Delta x = w_{i,j,l}^2 \quad (66)$$

din (65) rezultă formula:

$$\hat{y}_{i,j,l}(k) = w_{i,j,l}^1 \cdot \tilde{x}_l(k-1) + w_{i,j,l}^2 \cdot \tilde{x}_l(k-2) \quad (67)$$

Utilizarea întregului model presupune calcularea în fiecare pas de discretizare a timpului atât a valorilor funcțiilor de validare $\Phi_i(\underline{z})$ din (62), bazate pe funcții de apartenență de forma (54) sau (55), cât și utilizarea formulelor (67) în asociere cu funcțiile de validare de fază. Volumul de calcule fiind considerabil există tot interesul de a-l reduce cu scopul de a servi unei implementări software de timp real pentru care timpul de calcul este un factor critic. Una dintre operațiile consumatoare de timp și de resurse de memorie este calcularea exponențialelor cu exponenți pătratici care intervin în funcțiile de apartenență folosite pentru obținerea valorilor $\Phi_i(\underline{z})$.

În acest scop, în cadrul tezei s-a adoptat o a doua modificare notabilă față de varianta clasică de modelare cu LOLIMOT considerând în locul funcțiilor de apartenență gaussiene funcții de apartenență derivate din cele de tip trapezoidal (Fig. 22)⁶.

⁶ Efectele operării cu astfel de funcții sunt discutate în lucrări de bază referitoare la modelele fuzzy sau de tip RIP [56],[57],[58],[59].




Figura 22. Funcțiile de apartenență utilizate pentru calcularea funcțiilor de validare în locul celor de tip Gaussian.

Astfel, în locul formulelor de calcul (54), (55) în continuare se operează cu funcții de apartenență de forma

$$\mu_j(\underline{z}) = \mu_{i_T}(z_1) \cdot \mu_{i_P}(z_2) \quad (68.1)$$

în care

$$\mu_{i_T}(z_1) = \begin{cases} 1, & z_1 \leq T_{iT} \text{ si } \exists(i_T - 1) \text{ sau } z_1 \geq T_{iT} \text{ si } \exists(i_T + 1) \\ \frac{z_1 - T_{iT-1}}{T_{iT} - T_{iT-1}}, & z_1 \in (T_{iT-1}, T_{iT}] \\ \frac{T_{iT+1} - z_1}{T_{iT+1} - T_{iT}}, & z_1 \in [T_{iT}, T_{iT+1}) \\ 0, & T_{iTmin} < z_1 < T_{iTmax}, z_1 \notin (T_{iT-1}, T_{iT+1}) \end{cases} \quad (68.2)$$

iar

$$\mu_{i_P}(z_2) = \begin{cases} 1, & z_2 \leq P_{iP} \text{ si } \exists(i_P - 1) \text{ sau } z_2 \geq P_{iP} \text{ si } \exists(i_P + 1) \\ \frac{z_2 - P_{iP-1}}{P_{iP} - P_{iP-1}}, & z_2 \in (P_{iP-1}, P_{iP}] \\ \frac{P_{iP+1} - z_2}{P_{iP+1} - P_{iP}}, & z_2 \in [P_{iP}, P_{iP+1}) \\ 0, & P_{iPmin} < z_2 < P_{iPmax}, z_2 \notin (P_{iP-1}, P_{iP+1}) \end{cases}, \quad (68.3)$$

respectiv cu funcții de validare calculate cu aceleași relații ca și în capitolul 3:

$$\Phi_j(\underline{z}) = \frac{\mu_j(\underline{z})}{\mu_{TOT}(\underline{z})}, \quad \mu_{TOT}(\underline{z}) = \sum_{i=1}^M \mu_i(\underline{z}) \quad (69)$$

Indecșii i_T și i_P corespund celor M_T nivele de temperatură, respectiv M_P nivele de presiune, iar punctele (T_{iT}, P_{iP}) , denumite în continuare *puncte de sprijin*, sunt asociate, în acest stadiu al discuției, fiecărui neuron pe baza algoritmului de partiționare a spațiului S_{TP} al punctelor de funcționare $\Lambda(T,P)$ delimitat de $[T_{min}, T_{max}]$, respectiv $[P_{min}, P_{max}]$. Se observă că fiecărui LM_i ii sunt asociate, de fapt, o

pereche de funcții de apartenență, una în raport cu T și cealaltă în raport cu P , conform fig. 22.

Potrivit relației (69) funcțiile de validare se comportă ca un sistem normalizat de ponderi (de sumă egală cu 1):

$$\Phi_{TOT}(\underline{z}) = \sum_{i=1}^M \Phi_i(\underline{z}) = 1. \quad (70)$$

4.3. Determinarea coeficienților LLM

Odată definitivată noua structură a modelului neuro-fuzzy de predicție, independentă de valoarea lui M (numărul de LM-uri, de neuroni de pe primul strat), se procedează la estimarea permanentă, la fiecare pas de calcul k , a coeficienților $\underline{w}_{i,j,l}$. Estimarea permanentă impune utilizarea unui procedeu adaptiv implementat în timp real. Structura se utilizează în ambele etape de dezvoltare a aplicației:

- *etapa de construcție a modelului de tip LOLIMOT* (v. paragraful următor), (etapa de implementare);
- *etapa de utilizare curentă a modelului* (pentru adaptarea coeficienților $\underline{w}_{i,j,l}$ și predicția curentă a variației de presiune ΔP).

Algoritmul de adaptare reprezintă în esență un sistem adaptiv, căruia i se poate asocia structura din fig. 23. Valorile adaptate sunt cele ale coeficienților $\underline{w}_{i,j,l}$, adaptarea realizându-se, în principiu, astfel încât eroarea $e(k)$, referitoare la variația de presiune ΔP (diferența dintre $y(k)$ măsurat și valoarea estimată \hat{y}_{pg}) să tindă spre 0. În figură notațiile au următoarea semnificație:

- partea încadrată corespunde procesului real, iar partea neîncadrată mecanismului de adaptare și predicție;
- blocul „model adaptiv” agregă, pe de-o parte algoritmul de calcul dat de formulele (71) de mai jos, iar pe de altă parte modelul LOLIMOT, respectiv varianta modificată a acestuia prezentată în paragraful anterior;
- $x(k-1)$ reprezintă intrarea ce determină atât ieșirea $y(k)$ a procesului cât și ieșirea predictată $\hat{y}_{pg}(k)$ a modelului folosită pentru calcularea momentelor de declanșare a proceselor de injecție. Conform fig. 4, $\hat{y}_{pg}(t_{SEGj})$ va intra în calculul parametrilor de injecție pentru cilindrul următor.

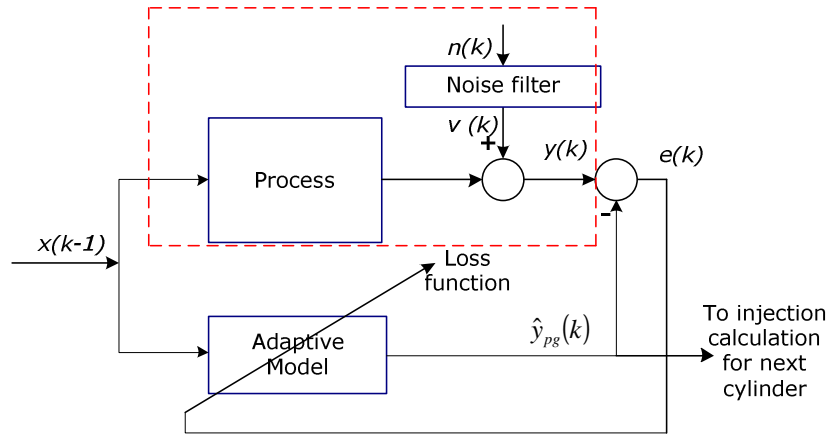


Figura 23. Structura mecanismului de adaptare a valorilor coeficienților modelului de predicție. [35]

Algoritmul de adaptare a coeficienților $\{(w_{i,j,l}^1, w_{i,j,l}^2)\}$ ai modelului de predicție a presiunii trebuie conceput pentru a funcționa *on-line* pe un sistem de calcul de timp real. Pentru adaptare este adecvată metoda RLS. Așa cum s-a precizat în capitolul anterior, ea se caracterizează prin efort computațional constant și predictibil pentru fiecare recurență de calcul [53].

Structura de adaptare utilizată de autor implementează o variantă modificată a algoritmului RLS (33), ajustată pentru structura din figura 23. Modificarea făcută față de varianta clasică a RLS constă în includerea funcțiilor de validare $\Phi_i(\underline{z})$ ale LM-urilor în structura algoritmului precum și în includerea mărimilor de intrare normate conform relațiilor (63),(66),(67).

Algoritmul de adaptare este:

$$\begin{aligned}
 e(k) &= y(k) - \underline{\tilde{X}}_l^T(k) \cdot \underline{\hat{w}}_{i,j,l}(k-1) \\
 \underline{\hat{w}}_{i,j,l}(k) &= \begin{cases} \underline{\hat{w}}_{i,j,l}(k-1) + \underline{\gamma}_{i,j,l}(k) \cdot e(k), & \text{daca } \Phi'_{i,j}(z') = 1, \\ \underline{\hat{w}}_{i,j,l}(k-1), & \text{daca } \Phi'_{i,j}(z') = 0 \end{cases} \\
 \underline{\gamma}_{i,j,l}(k) &= \frac{1}{\underline{\tilde{X}}_l^T(k) \underline{R}_{i,j,l}(k-1) \underline{\tilde{X}}_l(k) + \lambda_i} \underline{R}_{i,j,l}(k-1) \cdot \underline{\tilde{X}}_l^T(k) \cdot \Phi_i(\underline{z}(k)) \cdot \Phi'_{i,j}(z'(k)) \\
 \underline{R}_{i,j,l}(k) &= \begin{cases} \frac{1}{\lambda_i} (\underline{I} - \underline{\gamma}_{i,j,l}(k) \underline{\tilde{X}}_l^T(k)) \cdot \underline{R}_{i,j,l}(k-1), & \text{daca } \Phi'_{i,j}(z'(k)) = 1 \\ \underline{R}_{i,j,l}(k-1), & \text{daca } \Phi'_{i,j}(z'(k)) = 0 \end{cases}
 \end{aligned} \tag{71}$$

Acesta corespunde unui singur LLM și se rulează doar pe intervalele de timp asociate fazei sistemului pentru care LLM-ul este valid.

În relația (71) s-au utilizat notațiile

$$\begin{aligned}\hat{w}_{i,j,l}(k) &= [w_{i,j,l}^1(k) \ w_{i,j,l}^2(k)]^T \\ \hat{x}_l(k) &= [\hat{x}_l(k-1) \ \hat{x}_l(k-2)]^T.\end{aligned}\quad (72)$$

În (71) variabilele sau parametri fără indice se referă la mărimi caracteristice întregului sistem, cele cu indicele i la mărimi caracteristice unui LM, deci unui punct de sprijin, cele cu indicii i, j la mărimi caracteristice unui LLM, indiferent de debitul de intrare, cel cu indicele l la un anumit debit de intrare, iar cele cu indicii i, j, l la mărimi caracteristice unui LLM și unui debit de intrare ⁷. Pe de altă parte se observă că funcțiile de validare $\phi'_{i,j}(z')$ ⁸ servesc pentru modificarea structurii sistemului, acesta comutând de pe o configurație dinamică, atunci când $\phi'_{i,j}(z') > 0$, pe una statică atunci când $\phi'_{i,j}(z') = 0$.

Ca o consecință a utilizării noilor funcții de apartenență, la care ne-am referit în paragraful anterior, adaptarea se face, așa cum se arată în paragraful 5.2, doar pentru modelele corespunzătoare punctelor de sprijin care delimitează dreptunghiul din rețeaua de puncte de sprijin în care se găsește punctul de funcționare curent (max. 4 pentru spațiul bi-dimensional corespunzător variabilelor T și P). Ca urmare, pe durata adaptării, efortul computațional este păstrat constant și din acest de-al doilea punct de vedere.⁹

4.4. Partiționarea spațiului de funcționare S_{TP} și determinarea inițială a parametrilor modelului

Conceptul de bază pentru partiționarea spațiului de funcționare S_{TP} și determinarea inițială a parametrilor modelului este furnizat de algoritmul LOLIMOT și se bazează pe o partiționare iterativă a spațiului punctelor de funcționare S_{TP} și evaluarea performanțelor modelului obținut la fiecare iterație. În cadrul unei iterații se granularizează partiționarea spațiului de lucru prin crearea a două noi porțiuni dreptunghiulare. Operația se efectuează având în vedere faptul că axele T și P sunt ortogonale și folosind ca indicator de performanță o funcție de cost pătratic (v. relația (72)).

Algoritmul de partiționare a spațiului de funcționare S_{TP} și determinare inițială a parametrilor modelului este conceput pentru utilizare mixtă, *off-line și on-line*. El are un caracter ingineresc și folosește date experimentale de la sistemul fizic. Chiar și în aceste condiții operațiunea este migăloasă și implică un consum de resurse important. Costurile adaptării cresc odată cu numărul de experimente efectuate. În opinia autorului, acest algoritm optimizează activitățile experimentale și aduce beneficii economice.

⁷ Este util de observat că în fiecare fază se consideră un singur debit. Indicele l asociat debitului este totuși necesar întrucât același tip de debit poate să apară în mai multe faze (v. paragraful 4.1.1).

⁸ Se va remarca și caracterul mutual exclusiv al funcțiilor de validare $\phi'_{i,j}(z')$.

⁹ Primul punct de vedere îl reprezintă utilizarea variantei recursive RLS a metodei CMMP.

Odată realizată partiționarea spațiului de funcționare și determinarea valorilor inițiale ale parametrilor modelului, algoritmul se folosește, în continuare, numai în regim de adaptare permanentă a parametrilor și de predicție a variației de presiune.

În ansamblu, distingem două etape de lucru:

- Etapa I: Crearea modelului de tip LOLIMOT. Etapa se finalizează cu determinarea modelelor LM_1, \dots, LM_M și a funcțiilor de apartenență.
- Etapa II: Utilizarea *on-line* a modelului cu adaptarea permanentă a valorilor coeficienților.

Partiționarea din prima etapă face obiectul acestui paragraf, iar adaptarea, care apare în ambele etape și căreia îi corespunde schema bloc din fig. 23, este dezvoltată în capitolul următor.

Etapa I:

- a) Se delimitează domeniul de lucru $S_{TP} = [T_{min}, T_{max}] \times [P_{min}, P_{max}]$ (spațiul variabilelor de intrare ce definesc punctele de operare) ca în fig. 24.




Figura 24. Delimitarea spațiului S_{TP} al punctelor de operare considerate în experiment

- b) Pe baza informațiilor apriorice cu privire la regimurile de funcționare ale rampei comune se stabilește o primă mulțime de puncte de sprijin în vecinătatea cărora se vor dezvolta la punctul c) LM-uri: $\{c_{i_{Tj}}, i_{Pj}\}$. Indecșii i_{Tj} și i_{Pj} corespund poziționării punctelor de sprijin (numite și centre) în planul (T,P).

Fiecărui model i se asociază o funcție de validare de forma (68). În această subetapă de dezvoltare punctele de sprijin pot avea o distribuție oarecare, așa cum se arată în fig. 25, sau o amplasare în nodurile unei minirețele carteziene care să acopere și colțurile domeniului S_{TP} .




Figura 25. Poziționarea inițială a punctelor de sprijin în spațiului intrărilor

- c) Se efectuează experimente de funcționare a rampei comune în vecinătatea fiecărui punct de sprijin (în acord cu notarea punctelor de sprijin din fig. 25 denumim experimentele: $Exp(c_{2,3}), \dots, Exp(c_{2,4})$). Folosind algoritmul (71) și relațiile (68) și (69), precum și rezultatele experimentale obținute, se construiesc modelele corespunzătoare punctelor de sprijin selectate în această fază. În cazul particular al fig. 25 este vorba despre modelele: $LM_{c_{2,3}}, \dots, LM_{c_{2,4}}$.




Figura 26. Determinarea coeficienților modelelor pe baza de experimente. Punctul roșu se referă la punctul de sprijin, punctele negre înconjurătoare sugerează puncte în care s-au făcut măsurări, iar cercul ce înconjoară punctul de sprijin sugerează obținerea unui LM.

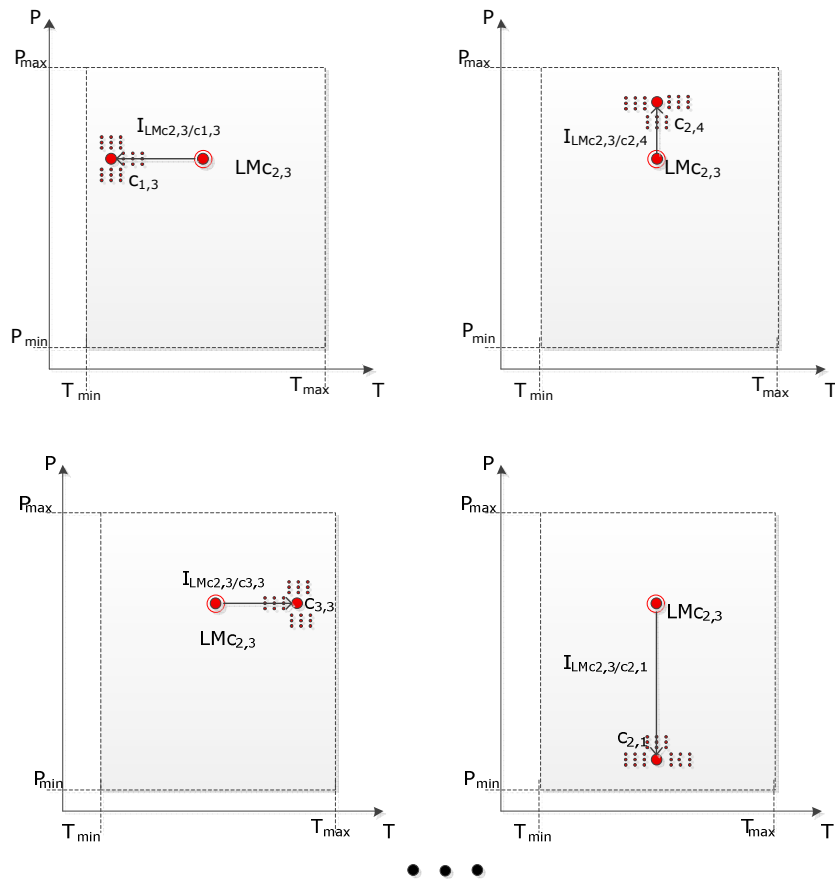
- d) Se evaluează performanța modelelor locale (LM) sintetizate pentru punctele de sprijin de la c) folosind rezultatele experimentale și funcția de cost (73):

$$I_{LM_{ci}/c_m} \left(\bigcup_{j,l} w_{i,j,l} \right) = \frac{1}{N_v} \sum_{k=1}^{N_v} e_i^2(k), \quad e_i(k) = y(k) - \hat{y}_{LM_{ci}}(k). \quad (73)$$

Formula se referă la un LM notat generic cu LM_{ci} . În formulă: N_v reprezintă numărul de puncte de măsurare reținute pentru y din experimentul $Exp(c_m)$, $\hat{y}_{LM_{ci}}$ valorile lui y obținute pentru aceleași puncte cu modelul LM_{ci} de parametri

$\bigcup_{j,l} w_{i,j,l}$, iar $I_{LMc_i,c_m} \left(\bigcup_{j,l} w_{i,j,l} \right)$ valoarea indicatorului obținută prin aplicarea

modelului LM_{c_i} în punctul de sprijin c_m . Funcția de cost (73) se calculează pentru toate modelele de la punctul c). Ca urmare, ea se calculează în toate punctele învecinate oricărui punct de sprijin c_i , amplasate atât pe direcția T (orizontală) cât și pe direcția P (verticală). De exemplu, pentru modelul $LM_{c_{2,3}}$ corespunzător punctului de sprijin $c_{2,3}$ se calculează $I_{LM_{c_{2,3}/c_{1,3}}}$, $I_{LM_{c_{2,3}/c_{3,3}}}$, $I_{LM_{c_{2,3}/c_{2,1}}}$, $I_{LM_{c_{2,3}/c_{2,4}}}$ folosind măsurătorile din $Exp(c_{1,3}), \dots, Exp(c_{2,4})$). Ideea apare în primele 4 părți ale fig. 27 (ultimele trei părți ale figurii sunt destinate modelului din punctul de sprijin $c_{2,4}$).



• • •




Figura 27. Evaluarea modelului asociat unui punct de sprijin în punctele de sprijin din vecinătate

- e) Se calculează pentru fiecare pereche de puncte de sprijin învecinate, amplasate pe orizontală sau verticală, un indicator de performanță pentru segmentul de axa dintre punctele de sprijin respective. În exemplul considerat se calculează:

$$I_{c2,3,c1,3} = 0.5 \cdot [I_{LMc2,3/c1,3} + I_{LMc1,3/c2,3}] \quad (74)$$

...

$$I_{c2,4,c2,3} = 0.5 \cdot [I_{LMc2,4/c2,3} + I_{LMc2,3/c2,4}]$$

Dacă nu există vecini într-o direcție, se consideră că media este dată de modelul marginal de pe acea direcție: ex. $I_{c2,4,c1,4} = I_{LMc2,4/c1,4}$.

- f) Dezvoltarea secvențială a modelului de tip LOLIMOT.

Se compară valorile indicatorilor de performanță de la punctul e). Se consideră ca fiind cel mai puțin performant indicatorul de performanță pentru care valoarea calculată la punctul e) este cea mai mare și pe această bază se ia decizia de introducere a unui nou punct de sprijin, c_{nou} . Dacă indicatorul cel mai puțin performant corespunde unui segment mărginit de două puncte de sprijin punctul de sprijin c_{nou} se plasează la jumătatea distanței dintre cele două puncte de sprijin. Dacă indicatorul este asociat unui punct marginal, atunci se prelungeste axa după care s-a făcut evaluarea până la limita domeniului (T_{min} , T_{max} , P_{min} sau P_{max}) și se consideră punctul de sprijin c_{nou} ca fiind punctul de pe frontieră. Operația este destinată granularizării rețelei de puncte de sprijin și este denumită „diviziune”.

Fiecare diviziune înseamnă creșterea numărului punctelor de sprijin cu o unitate și în acest context sunt necesari următorii pași:

- i. Construirea de funcții de validare pentru noul model, rezultat prin augmentarea modelului inițial cu punctul de sprijin c_{nou} .
- ii. Revenirea la punctul c) prin efectuarea unui nou experiment în vecinătatea noului punct de sprijin și estimarea locală a parametrilor noului LM.
- iii. Aplicarea criteriului de oprire a execuției algoritmului:

Se operează cu două criterii care trebuie îndeplinite: numărul maxim de LM-uri și atingerea unei valori de prag inferioară pentru toți indicatorii de performanță $I_{ca,b,cb,a}$. Algoritmul se oprește atunci când unul dintre criteriile de oprire este atins.

g) Completarea grilei carteziene.

După încheierea subetapei f), configurația punctelor de sprijin corespunde unei grile carteziene incomplete. În acest context grila se completează cu restul punctelor de sprijin (v. Fig. 28) și se continuă cu generarea de modele pentru fiecare dintre ele pentru toate cele 7 faze de lucru.

Odată încheiată subetapa f), se consideră finalizată etapa I.

Etapa II:

În etapa II se folosește modelul obținut în etapa I, adaptarea pornind cu coeficienții modelelor obținute în finalul etapei I. După ce s-a obținut configurația finală cu M LM-uri (puncte de sprijin) în spațiul de lucru al rampei comune, se trece la utilizarea efectivă a arhitecturii LOLIMOT potrivit celor prezentate în paragraful 4.3.

Modelul realizează simultan adaptare și predicție, însă cu pași de timp diferiți și într-o formă modificată. Pasul adoptat pentru discretizarea timpului este $h = 1$ ms. Calculul adaptiv al coeficienților se face din zece în zece pași, adică la intervale de $10h = 10$ ms, iar cel de predicție la fiecare h , adică din milisecundă în milisecundă folosind coeficienții calculați pe baza măsurărilor din decada anterioară.

5 IMPLEMENTAREA MODELULUI NEURO-FUZZY ADAPTIV DE PREDICȚIE A PRESIUNII ÎN SISTEMUL PCR

Problematika algoritmilor folosiți în identificarea *on-line* bazată pe algoritmi recursivi a fost îndelung studiată în literatura de specialitate, fiind asociată cu diverse aplicații din industrie [52],[53],[61],[62],[63],[64]. Necesitatea ajustării coeficienților modelelor în timpul funcționării sistemelor se datorează caracterului variant în timp al proceselor modelate. Optimizarea acestor algoritmi a fost de cele mai multe ori o consecință a restricțiilor impuse de implementarea pe sisteme de timp real.

În cazul rampei comune adaptarea coeficienților LLM pe durata funcționării sistemului este esențială datorită caracterului variant în timp al procesului precum și datorită incertitudinilor inerente, pentru asigurarea unor performanțe acceptabile ale modelului de predicție a presiunii. Operațiile de adaptare se derulează „simultan” cu cele de predicție, în sensul că cele două operații se derulează *on-line*. Capitolul de față este destinat prezentării modului în care instrumentele teoretice și metodologia din capitolele anterioare au fost utilizate în implementarea operațiilor de determinare adaptivă a coeficienților modelului de predicție și de realizarea a predicției variației de presiune.

Paragraful 5.1. tratează câteva aspecte referitoare la capabilitățile și restricțiile caracteristice suportului de implementare și dezvoltă soluția de implementare adoptată. Ca punct de plecare pentru această soluție sunt considerate câteva forme posibile de scriere a modelului adaptiv. Ele diferă prin modul de organizare a succesiunii calculelor din cadrul modelului neuro-fuzzy (i). Întrucât utilizarea de funcții de apartenență gaussiene este mare consumatoare de resurse, se folosesc funcțiile de apartenență trapezoidale (în variante particularizate) introduse în capitolul 4 (ii). Combinarea aspectelor (i) și (ii) se soldează cu posibilitatea implementării algoritmului de determinare a coeficienților LLM-urilor prin simple calcule de interpolare biliniară. Noua structură a algoritmului devine una algebrică în care structura neuro-fuzzy nu mai apare sub forma inițială. Calculul se simplifică esențial ca urmare a derulării lui secvențiale doar pentru câte o singură fază și pentru cel mult 4 puncte de sprijin.

În paragraful 5.2 se descrie contextul experimental în care s-a verificat soluția de implementare de la 5.1.: stand experimental, semnale și domenii de variație.

Paragraful 5.3. dezvoltă ideea considerării mecanismului de adaptare bazat pe RLS ca un sistem adaptiv. Studiul oferă un suport pentru înțelegerea procesului de adaptare de o manieră mai apropiată inginerului automatist. Pe de-o parte, convergența calculelor de determinare a coeficienților este transformată într-o problemă de stabilizare pentru care coeficienții devin mărimi de stare ale unui sistem în timp discret. Pe de altă parte, suportul permite adoptarea unor măsuri de asigurare a robusteții algoritmului de adaptare în raport cu zgomote de natură diversă care pot să apară în utilizarea practică. De asemenea, descrierea

algoritmului sub forma unui model intrare-stare – ieșire permite interpretarea algoritmului ca un sistem cu comutație.

5.1. Implementarea software a modelului adaptiv pe sistemul de timp real

Unul dintre obiectivele acestei cercetări îl constituie realizarea unei aplicații de timp real ce implementează modelul adaptiv de predicție a presiunii în sistemul PCR.

Fără doar și poate, chestiunea nu este una trivială și presupune luarea în calcul a mai multor aspecte: timp de execuție, memorie consumată, robustețea aplicației etc. Astfel:

- Pentru un procesor de timp real, timpul de execuție pentru fiecare task este alocat între anumite limite, aceasta constrângere fiind determinantă pentru buna funcționare a sistemului de calcul.
- Memoria, de asemenea este limitată și fiecare aplicație beneficiază de un anumit „buget” de memorie ROM/RAM în care trebuie să se încadreze.
- Robustețea aplicației poate fi evaluată în funcție de modul în care aceasta se execută pe sistemul de timp real (ECU) și în funcție de diversele regimuri de funcționare (motor oprit, regim tranzitoriu de start etc.).

5.1.1. Aspecte ale implementării software

Implementarea aplicației, ce realizează atât adaptarea coeficienților modelului cât și predicția variației presiunii, s-a realizat folosind mediul de dezvoltare Matlab/Simulink, ce oferă o viziune transparentă asupra sub-sistemelor și modulelor de calcul.

Interfața de intrare a modelului implementat a fost adaptată pentru a permite utilizarea variabilelor deja calculate în alte module ale ECU și anume: modulul de calcul al vitezei și poziției unghiulare, modulul de calcul pentru presiune și temperatură, modulul de calcul pentru reglarea presiunii etc. Modulele de calcul pentru adaptare și predicție au fost concepute să funcționeze sincron cu sistemul de operare OSEK [65] ce rulează pe ECU. Toate calculele sunt efectuate în virgulă mobilă.

5.1.2. Prototiparea rapidă internă (iRPT)

Pentru integrarea modelului în aplicația de management al motorului, ce rulează pe ECU, s-a folosit iRPT (internal Rapid Prototyping), grăbind astfel ciclul de dezvoltare software și integrare al aplicației. În faza de dezvoltare și testare a aplicației s-a folosit conceptul „ETAS eHooks” dezvoltat de ETAS [66]. Acesta presupune augmentarea fișierelor de cod mașină „.S19” cu noua secvență de cod și totodată introducerea unor întreruperi care să permită prelucrarea/suprascrierea unor variabile calculate în aplicația deja existentă.

5.1.3. Implementarea software a algoritmului de adaptare

Modelul conceptual al operației de predicție dezvoltat în capitolele anterioare a fost adaptat la sistemul de calcul de timp real ținând seama de aspectele referitoare la implementare care au fost menționate în sub-capitolul 5.1.

Pornind de la aceste considerente, a rezultat ca necesară eficientizarea calcului variației de presiune $\Delta\hat{P}(k)$ prin restructurarea formulei (62) care exprimă ieșirea modelului neuro-fuzzy. Astfel, folosind pentru sumele multiple proprietățile de asociativitate, distributivitate și comutativitate, din (62) rezultă transformarea:

$$\begin{aligned} \Delta\hat{P}(k) = \hat{y}(k) &= \sum_{i=1}^M \hat{y}_i(k) \phi_i(\underline{z}) = \\ &= \sum_{i=1}^M \left(\sum_{l=1}^{n_x} \left(\sum_{j=0}^{n-1} b_{i,j,l}^1 \phi_{i,j}(z') \right) x_l(k-1) + \left(\sum_{j=1}^{n-1} b_{i,j,l}^2 \phi_{i,j}(z') \right) x_l(k-2) \right) \phi_i(\underline{z}) = \dots \\ &= \sum_{j=0}^{n-1} \left(\sum_{l=1}^{n_x} \left(\underbrace{\sum_{i=1}^M b_{i,j,l}^1 \phi_i(\underline{z})}_{\Sigma_{1,j,l}} x_l(k-1) + \underbrace{\sum_{i=1}^M b_{i,j,l}^2 \phi_i(\underline{z})}_{\Sigma_{2,j,l}} x_l(k-2) \right) \cdot \phi_{i,j}(z') \right) \end{aligned} \quad (75)$$

Ultima expresie permite, spre deosebire de forma inițială, implementări mai avantajoase din punct de vedere al efortului computațional, gestionabile în mai multe moduri. În funcție de modul de gestionare a relațiilor (75), aplicațiile de timp real vor prezenta doar diferențe de organizare a calculelor, rezultatul fiind identic. În variantele de implementare concepute, autorul a implementat ultima expresie din (75) în mai multe variante. Cea reținută în final pornește de la particularizarea sumelor $\Sigma_{i,j,l}$ și exploatarea altor observații referite în continuare.

Într-o primă etapă a discuției, considerăm exemplul din figura 28, corespunzător unei situații în care punctele de sprijin sunt amplasate în nodurile unei rețele carteziane. Se disting trei tipuri de situații după cum punctul curent $\Lambda(P,T)$ se situează, la un moment dat, într-un punct de sprijin (⊙), pe o latură a rețelei (⊗), sau în interiorul unui careu (⊚). În cele trei cazuri sumele $\Sigma_{i,j,l}$ se reduc la 1, 2, respectiv 4 termeni. Astfel:

- dacă $\Lambda(P,T)$ se afla în poziția ⊙:

$$\Sigma_{1,j,l} = b_{1,j,l}^1 \cdot \phi_1(\underline{z}), \quad \Sigma_{2,j,l} = b_{1,j,l}^2 \cdot \phi_1(\underline{z}); \quad (76.1)$$

- dacă $\Lambda(P,T)$ se afla în poziția ⊗:

$$\Sigma_{1,j,l} = b_{1,j,l}^1 \cdot \phi_1(\underline{z}) + b_{2,j,l}^1 \cdot \phi_2(\underline{z}), \quad \Sigma_{2,j,l} = b_{1,j,l}^2 \cdot \phi_1(\underline{z}) + b_{2,j,l}^2 \cdot \phi_2(\underline{z}); \quad (76.2)$$

- dacă $\Lambda(P,T)$ se afla în poziția ⊚:

$$\begin{aligned} \Sigma_{1,j,l} &= b_{1,j,l}^1 \cdot \phi_1(\underline{z}) + b_{2,j,l}^1 \cdot \phi_2(\underline{z}) + b_{4,j,l}^1 \cdot \phi_4(\underline{z}) + b_{5,j,l}^1 \cdot \phi_5(\underline{z}), \\ \Sigma_{2,j,l} &= b_{1,j,l}^2 \cdot \phi_1(\underline{z}) + b_{2,j,l}^2 \cdot \phi_2(\underline{z}) + b_{4,j,l}^2 \cdot \phi_4(\underline{z}) + b_{5,j,l}^2 \cdot \phi_5(\underline{z}) \end{aligned} \quad (76.3)$$

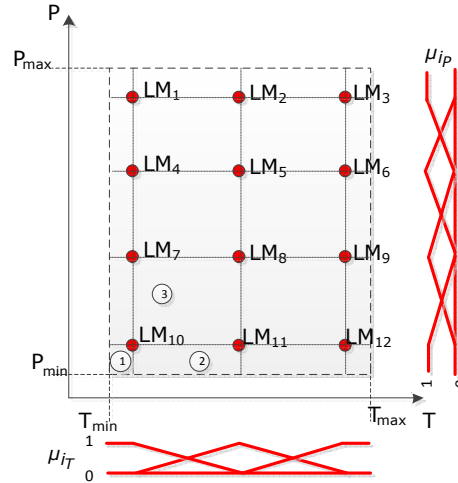


Figura 28. Poziții posibile ale punctului curent $\Lambda(P,T)$ în raport cu o rețea carteziană de puncte de sprijin. În exterior sunt reprezentate funcțiile de apartenență utilizate pentru calculul funcțiilor de validare.

În (76.1) $\Phi_1(\underline{z})$ are semnificația de valoare a funcției de validare din punctul de sprijin curent, în acest caz punctul ①, calculată pentru acest punct. Valorile funcțiilor de validare asociate tuturor celorlalte puncte de sprijin atunci când punctul curent este în ① sunt nule. Ca urmare, aplicând relațiile (68.1) și (69) rezultă:

$$\Phi_1(\underline{z}) = 1 \quad (77.1)$$

În (76.2) $\Phi_1(\underline{z})$ și $\Phi_2(\underline{z})$ sunt valorile funcțiilor de validare asociate punctelor de sprijin de la capetele segmentului pe care se găsește punctul curent, în acest caz punctul ②, calculate în punctul curent. Aplicând relațiile (68.1) și (69) rezultă că valorile funcțiilor de validare asociate tuturor celorlalte puncte de sprijin atunci când punctul curent este în ② sunt nule. Ca urmare,

$$\Phi_1(\underline{z}) + \Phi_2(\underline{z}) = 1, \quad (77.2)$$

iar atât suma $\Sigma_{1,j,l} = b_{1,j,l}^1 \cdot \Phi_1(\underline{z}) + b_{2,j,l}^1 \cdot \Phi_2(\underline{z})$ cât și suma $\Sigma_{2,j,l} = b_{1,j,l}^2 \cdot \Phi_1(\underline{z}) + b_{2,j,l}^2 \cdot \Phi_2(\underline{z})$ furnizează o valoare egală cu cea care se obține prin interpolare liniară în lungul laturii de rețea considerând ca puncte de sprijin capetele segmentului asociate cu valorile $b_{1,j,l}^1$ și $b_{2,j,l}^1$ în cazul sumei $\Sigma_{1,j,l}$, respectiv cu valorile $b_{1,j,l}^2$ și $b_{2,j,l}^2$ în cazul sumei $\Sigma_{2,j,l}$. Explicația se bazează pe reprezentarea din figura 29 în care: 1 este graficul lui $b_{1,j,l}^1 \cdot \Phi_1(\underline{z})$ (sau $b_{2,j,l}^2 \cdot \Phi_1(\underline{z})$), 2 reprezintă graficul lui $b_{2,j,l}^1 \cdot \Phi_2(\underline{z})$ (sau $b_{2,j,l}^2 \cdot \Phi_2(\underline{z})$), iar $F(x)$

este tocmai suma $\Sigma_{1,j,l}$ (sau $\Sigma_{2,j,l}$), și constă în faptul că segmentele AC și BD au aceeași lungime.




Figura 29. Atunci când punctul curent $\Lambda(P,T)$ se situează pe o latură a rețelei carteziene din fig. 28 valorile sumelor Σ_1 sau Σ_2 se pot calcula prin interpolare liniară.

În (76.3) $\Phi_1(\underline{z})$, $\Phi_2(\underline{z})$, $\Phi_4(\underline{z})$ și $\Phi_5(\underline{z})$ sunt valorile funcțiilor de validare asociate punctelor de sprijin de la colțurile careului delimitat, conform fig. 28, de LM_1 , LM_2 , LM_4 și LM_5 în interiorul căruia se găsește punctul curent, în acest caz punctul $\textcircled{3}$, calculate în punctul curent. Aplicând relațiile (68.1) și (69) rezultă că valorile funcțiilor de validare asociate tuturor celorlalte puncte de sprijin atunci când punctul curent este în $\textcircled{3}$ sunt nule. Ca urmare

$$\Phi_1(\underline{z}) + \Phi_2(\underline{z}) + \Phi_4(\underline{z}) + \Phi_5(\underline{z}) = 1, \quad (77.3)$$

iar fiecare dintre sumele $\Sigma_{1,j,l}$ și $\Sigma_{2,j,l}$ furnizează o valoare egală cu cea care se obține prin interpolare biliniară [67] în careul delimitat de cele 4 puncte de sprijin din rețea asociate cu valorile $b_{1,j,l}^1$, $b_{2,j,l}^1$, $b_{4,j,l}^1$ și $b_{5,j,l}^1$ în cazul sumei $\Sigma_{1,j,l}$, respectiv valorile $b_{1,j,l}^2$, $b_{2,j,l}^2$, $b_{4,j,l}^2$ și $b_{5,j,l}^2$ în cazul sumei $\Sigma_{2,j,l}$. Și de această dată este posibilă o interpretare grafică de factură similară cu cea din figura 29.

Este ușor de observat că prin simple particularizări, formulele (76.3) pot fi reduse la formele (76.1) și (76.2), iar ca urmare, în toate cazurile se poate folosi interpolarea biliniară.

Potrivit considerentelor de mai sus, coeficienții LLM au fost dispuși în tabele de interpolare biliniară asociate punctelor de sprijin corespunzătoare nodurilor rețelei carteziene.

Această abordare schimbă esențial utilizarea modelului conceptual, de tip neuro-fuzzy. Implementarea prin modele de tip interpolativ [68],[69],[70], nu mai conservă arhitectura de tip neural a sistemului, nici pe cea organizată pe un singur nivel și nici pe cea organizată pe două niveluri. În plus, vom mai observa că funcțiile de validare $\Phi'_{i,j}(z')$ nu depind de punctul de sprijin, adică de indicele i , ci doar de fază, adică de indicele j , iar acest lucru permite modificarea notației:

$$\Phi'_{i,j}(z') = \Phi'_j(z') \quad (78)$$

70 Implementarea modelului neuro-fuzzy adaptiv de predicție a presiunii în PCR - 5

În acord cu toate aceste observații, într-o a doua etapă, arhitectura descrisă în figurile 20 și 21 este reorganizată conform Fig. 30, pentru o implementare software eficientă. În figură, operația externă din ultima expresie din (75) este defalcată pe n blocuri, reprezentate cu linie întreruptă, potrivit rescrierii ei sub forma:

$$\Delta \hat{P}(k) = \hat{y}(k) = \sum_{j=0}^{n-1} \hat{y}'_j(k), \quad (79)$$

$$\hat{y}'_j(k) = \sum_{l=1}^{n_x} \left(\underbrace{\sum_{i=1}^M b_{i,j,l}^1 \Phi_i(z)}_{\Sigma_{1,j,l}} x_l(k-1) + \underbrace{\sum_{i=1}^M b_{i,j,l}^2 \Phi_i(z)}_{\Sigma_{2,j,l}} x_l(k-2) \right) \cdot \Phi'_j(z')$$

În interiorul fiecărui bloc reprezentat cu linie întreruptă figurează n_x perechi de blocuri interpolatoare și de înmulțire corespunzătoare operațiilor $\left(\sum_{i=1}^M b_{i,j,l}^1 \Phi_i(z) \right) x_l(k-1)$, respectiv $\left(\sum_{i=1}^M b_{i,j,l}^2 \Phi_i(z) \right) x_l(k-2)$, ale căror ieșiri se

însumează în acord cu suma $\sum_{l=1}^{n_x}$ și operatorul de adunare din (79).

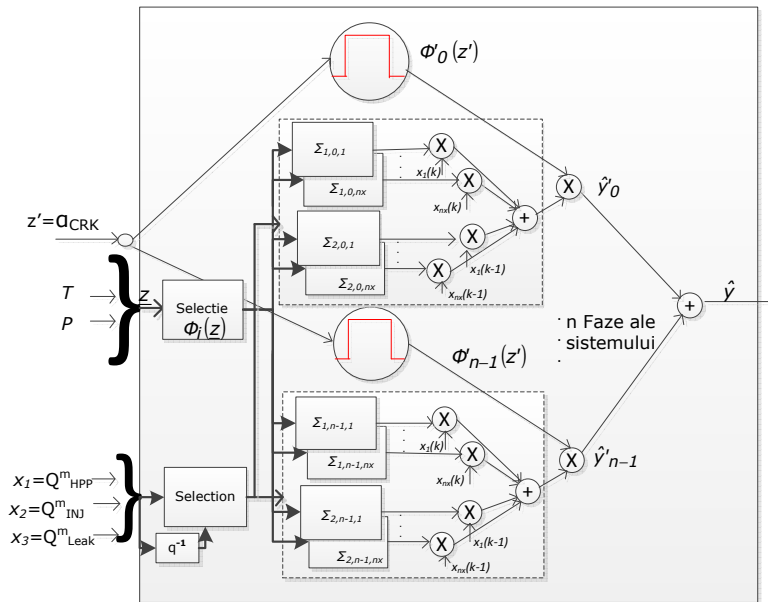


Figura 30. Schema de calcul a variației de presiune potrivit ultimei expresii din (75).

Într-o a treia etapă, vom observa că întregul calcul poate decurge și mai simplu folosind funcțiile $\Phi_j(z')$ cu rol de funcție logică de activare/dezactivare a calculelor, fapt surprins în Fig. 31.

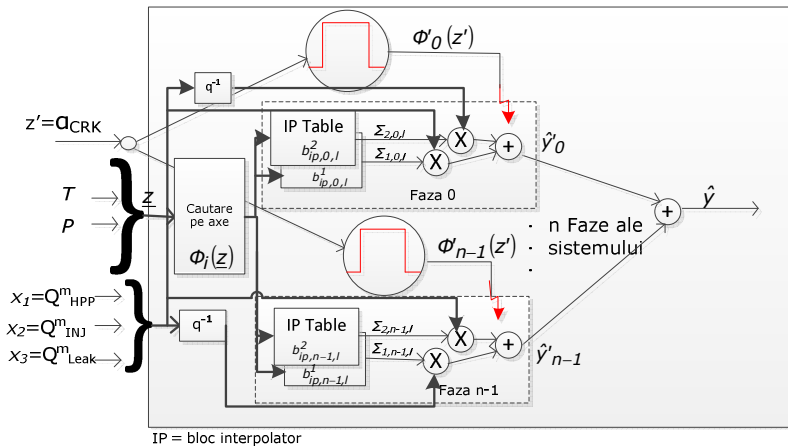


Figura 31. Arhitectura modelului de predicție a presiunii în CR adaptată pentru implementarea software.

Blocul „Axis look-up” are rolul de selecție a blocurilor de interpolatoare în funcție de punctul de operare curent $\Lambda(P,T)$. Funcțiile de validare $\Phi_j(z')$ selectează ansamblurile „System Phase j ” cu care se face la momentul curent calculul și, implicit, tabele de interpolare care vor fi active. Acest concept permite calcularea la un moment dat a ieșirii \hat{y} doar în funcție de un ansamblu „System Phase j ”. Se mai poate remarca faptul că modelele LLM sunt substituite de produsul dintre intrările $x(k-1)$ și $x(k-2)$, și sumele $\Sigma_{1,j}$ și $\Sigma_{2,j}$. Din tabelele de interpolare (IP) rezultă coeficienții $\Sigma_{1,j}$ și $\Sigma_{2,j}$ interpolați în funcție de punctul de operare curent $\Lambda(T,P)$.

Din punctul de vedere al efortului computațional, pentru a optimiza calculele în aplicația software, se realizează următoarea modificare: în funcție de gradul de activare (validare) la un moment dat (0=dezactivare, 1=activare), funcțiile de validare mutual exclusive, corespunzătoare fazelor sistemului pentru toate punctele de funcționare, notate Φ_j , generează un „trigger” de calcul pentru interpolarea între valorile coeficienților și pentru operațiile de multiplicare și adunare.

O vedere sintetică asupra implementării software a modelului adaptiv cu modele locale din figura 31, este prezentată în Anexa 2.

Sistemul de predicție este implementat într-o aplicație care rulează cu un pas de discretizare a timpului de $h = 1$ ms. Datorită volumului mare de operații de achiziție și prelucrare de date există riscul introducerii de „jitter” prin întreruperile generate la nivelul CPU și prin supraîncărcarea acestuia. Așa cum s-a precizat la finele capitolului anterior, s-a ales o soluție de compromis constând în adaptarea ciclică a coeficienților modelului, odată la 10 ms, folosind atât:

- i) date achiziționate la un interval de 1 ms: P și a_{CRK} (Fig. 32)

cât și

- ii) date achiziționate și procesate la 10 ms: temperatura T și variabilele asociate cu forma de variație a debitelor masice.

Pentru mărimile de la punctul ii) achiziția cu un pas de $10h$ reprezintă o soluție rațională care are în vedere faptul că variațiile acestor mărimi în raport cu timpul sunt caracterizate de constante de timp cu cel puțin un ordin de mărime mai mare decât $10h$, iar pe de altă parte faptul că valorile lor se modifică cu puțin de la un punct de sprijin la altul. Variabilele asociate cu forma de variație a debitelor masice ($a_{CRK}(t)$, φ , $\psi_{VCV}(t)$, $N(t)$), a_{SOI} , t_{INJ} , mf_{inj} , $\psi_{PCV}(t)$) servesc pentru calcularea debitelor masice de pe forme de undă ca și cele din Fig. 6. Calculul se bazează pe relațiile precizate în paragraful 2.3:

$$\begin{aligned} Q_{HPP}^m &= f_{Q_{HPP}^m}(a_{CRK}(t), \varphi, \psi_{VCV}(t), N(t)), \\ Q_{INJ}^m &= f_{Q_{INJ}^m}(a_{CRK}(t), a_{SOI}, t_{INJ}, mf_{inj}) \\ Q_{Leak}^m &= f_{Q_{Leak}^m}(P(t), T(t)) \end{aligned} \quad (80)$$

și se realizează folosind blocuri de interpolare în funcție de argumentele care apar în expresiile celor trei debite. Argumentele se referă la specificul combustibilului, injectoarelor și motorului și la forme de undă standard pentru variațiile debitelor masice în raport cu a_{CRK} .

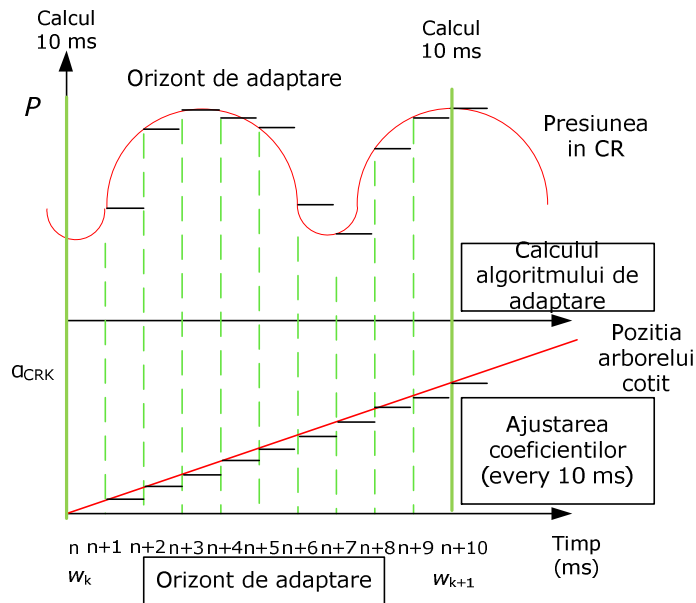


Figura 32. Referitoare la ritmul de prelevare a datelor și de calculare a coeficienților modelului pentru adaptarea secvențială în buclă repetitivă.

Pentru reducerea numărului de întreruperi la nivelul CPU, datele achiziționate pe durata a 10 pași consecutivi sunt înregistrate într-un *buffer* circular și procesate odată la 10 ms (Fig. 32). Procesarea, în speță calculul adaptiv al coeficienților unui LLM, se face în cadrul unei bucle „for” care utilizează valorile măsurate și reținute în

buffer ale variabilele P și a_{CRK} la fiecare milisecundă din cele 10 predecesoare. Bucla „for” se execută de 10 ori, iar pentru predicție pe următoarele 10 milisecunde se rețin doar valorile coeficienților calculate la ultima parcurgere a buclei. Pe decada următoare (următorii zece pași consecutivi de durată h) variația de presiune $\Delta\hat{P}(k) = \hat{y}(k)$ se calculează pas cu pas, folosind valorile coeficienților obținute la ultima parcurgere a buclei „for” și valori ale debitelor masice determinate prin interpolare bazată pe relațiile (80).

5.2. Definirea cadrului de desfășurare a experimentelor

Pentru validarea aplicației de adaptare și predicție a presiunii în CR, a fost folosit un stand hidraulic tip „Moehwald” ce a permis atât generarea controlată a variabilelor de intrare pentru procesul fizic, cât și achiziția de valori măsurate prin intermediul plăcilor de achiziție ETAS ETK și ETAS650 folosind interfața INCA 7.1 [71].

5.2.1. Standul experimental hidraulic

Standul experimental este prezentat schematic în figura 33. Viteza HPP este reglată prin intermediul unui motor electric comandat de un calculator de proces. Temperatura fluidului este controlată de un dispozitiv extern într-un rezervor cu capacitatea de 40 l ce alimentează circuitul de înaltă presiune prin „Fuel feed line”. Presiunea și pulsurile de injecție sunt comandate de ECU.

Achiziția de date și comandă se realizează prin intermediul unor convertoare analog-numeric (ADC) și numeric-analogice (DAC) pe 10 biți. Interfața cu utilizatorul permite vizualizarea și înregistrarea valorilor măsurate.

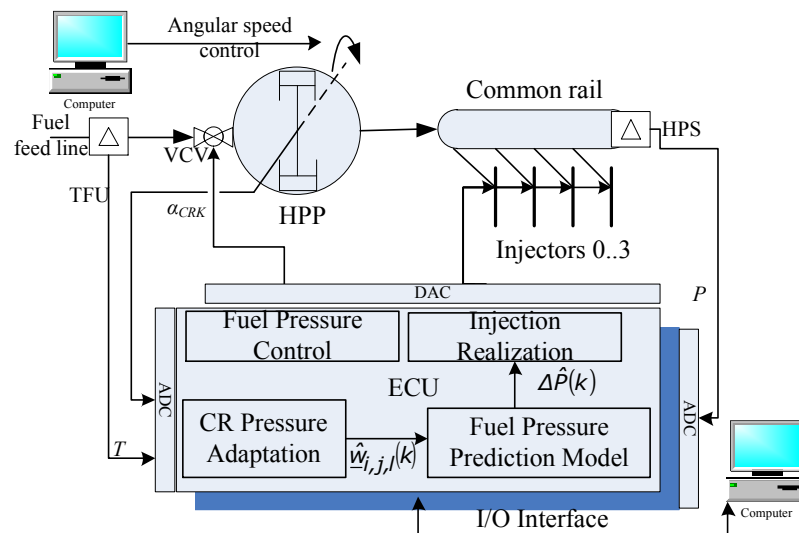


Figura 33. Standul experimental hidraulic [35].

Coeficienții obținuți în urma adaptării sunt folosiți mai departe în predicția presiunii $\hat{P}(k)$ din CR, valoare ce ulterior va intra în calculul timpilor de injecție.

5.2.2. Semnale de excitație pentru LLM

În scopul determinării coeficienților $LLM_{i,j}$, sistemul este condus în diverse puncte de funcționare $\Lambda_i(T,P)$ prin comenzi aplicate de la interfețele cu utilizatorul (ETAS). Pe parcursul operațiilor de identificare și adaptare, variabilelor ce influențează debitele masice ($\psi_{VCV}(t)$, $a_{SOI}(t)$, $t_{INJ}(t)$, $mf_{inj}(t)$) li se imprimă o evoluție de tip semnal scară pentru produce diferite amplitudini ale debitelor masice. Generarea corectă a acestor semnale este determinantă în obținerea unor valori optime ¹⁰ ale coeficienților modelelor liniare.

5.2.3. Delimitarea cadrului de desfășurare a experimentelor

În prealabil realizării experimentelor practice s-a procedat la delimitarea spațiului de variație pentru mărimile de intrare ale modelului. Acest lucru este necesar pentru normalizarea intrărilor în modelul de predicție al presiunii conform ecuațiilor (63) – (67).

Pentru antrenarea modelului, s-a ales zona de tranzit între regimul simplu aspirat și cel turbo, zonă care, în general, pune probleme în ceea ce privește dinamica presiunii în CR. În tabelul I sunt precizate limitele de variație pentru mărimile care intră în calcul:

TABEL I. LIMITELE DE VARIAȚIE PENTRU INTRĂRILE ÎN MODEL

Nr.	Variabila	Limite variație		
		Min	Max	u/m
1	T	-5	45	[°C]
2	P	65	135	[MPa]
3 ¹¹	a_{CRK}	0	720	[°CRK]
4	ψ_{VCV}	18.5	21.5	[%]
5	N	1500	2000	[rpm]
6	φ	80	80	[°CRK]
7	a_{SOI}	-2.5	1.5	[°CRK]
8	mf_{inj}	15	30	[mg/stk]
9	t_{INJ}	0.8	1.3	[ms]

5.3. Adaptarea on-line folosind algoritmul RLS robust

În literatura de specialitate, prin lucrări cum sunt [66],[73],[74],[75],[76] și [77], se tratează problema adaptării on-line evaluându-se capacitatea algoritmului

¹⁰ „Optimal” – cu înțelesul de valori ale coeficienților pentru care eroarea de predicție este minimă.

¹¹ Această mărime variază periodic între cele două limite.

RLS de a furniza, fără a supraîncărca sistemul de calcul, valori consistente. Rezultatele prezentate recomandă algoritmul RLS pentru aplicații de timp real atât din punctul de vedere al efortului de calcul cât și din punctul de vedere al convergenței algoritmului de adaptare.

În cele ce urmează se prezintă, la nivelul unui LLM, procesul de adaptare a coeficienților modelului de predicție al variației de presiune în rampa comună, pe baza algoritmului prezentat în capitolul 4, și modificarea lui pentru a asigura robustețe față de zgomote și perturbații asociate incertitudinilor de modelare și inițializare a modelului modificat.

5.3.1. Interpretarea adaptării coeficienților folosind o structură de sistem adaptiv

Așa cum s-a menționat în paragraful 5.1. coeficienții modelelor LLM, utilizate pentru predicție conform schemei din fig. 31, sunt supuși în permanență unui proces de recalculare adaptivă, care se efectuează periodic, odată la 10 ms (la capătul unui interval de lungime egală cu 10 pași de discretizare h).

Structura adaptivă de calcul recursiv a coeficienților, prezentată inițial în fig. 23, este reluată mai jos în fig. 34. Datorită utilizării în calcule a erorii de estimare

$$e_{i,j} = y - \hat{y}_{i,j},$$

care conține implicit o conexiune cu reacție, modelul structurii mecanismului de adaptare recursivă este asimilabil cu cel al unui sistem de urmărire (sistem de reglare cu referință variabilă) destinat asigurării condiției $\hat{y}_{i,j} = y$ prin modificarea valorilor parametrilor $\hat{w}_{i,j,l}$, în condițiile perturbării lui de intrările \tilde{x}_l (între \tilde{x}_l și y existând un grad de corelare [78]). Întrucât parametrii $\hat{w}_{i,j,l}$ sunt folosiți apoi în predicție, se consideră ca ieșire a structurii atât $\hat{y}_{i,j}$ cât și $\hat{w}_{i,j,l}$.




Figura 34. Urmărirea referinței în buclă închisă pe durata adaptării [35].

În esență, algoritmul de adaptare (71) este soluția unui probleme de optimizare obținută pe baza RLS, care are ca scop determinarea valorilor parametrilor $\hat{w}_{i,j,l}$ pentru fiecare punct de sprijin $\Lambda_i(T_i, P_i)$ din grila carteziană de distribuție a punctelor de sprijin. Valorile obținute sunt folosite apoi pentru a calcula prin interpolare pe $\hat{y}_{i,j}$ dat de (79). Necesitatea adaptării se explică prin faptul că în cursul funcționării formele de undă ale debitelor masice (v. rel. 80) și modulul de

76 Implementarea modelului neuro-fuzzy adaptiv de predicție a presiunii în PCR - 5

elasticitate al combustibilului se modifică în fiecare punct de sprijin în parte, iar ca urmare parametri $\hat{w}_{i,j,l}$ variază. Variabilitatea în timp a parametrilor este surprinsă în ecuațiile (71) prin recursivitatea: apar $\hat{w}_{i,j,l}(k)$ și $\hat{w}_{i,j,l}(k-1)$. În acest context, variabilele $\hat{w}_{i,j,l}$, la fel și variabilele $R_{i,j,l}$, pot fi interpretate ca variabile de stare, iar algoritmul RLS (71) și ecuația (68) ca un sistem dinamic, neliniar, cu vectorul de stare $s = \begin{bmatrix} \hat{w}_{i,j,l} \\ R_{i,j,l} \end{bmatrix}$ și cu orientarea $\{y, \tilde{x}_l\} \rightarrow \{\hat{w}_{i,j,l}\}$.

Aducerea sistemului (71)+(68) la forma canonică a unui sistem în timp discret

$$\begin{cases} x(k+1) = f(x(k), u(k)) \\ y(k) = g(x(k)) \end{cases}, \quad (81)$$

se face pe baza următoarei abordări:

- În sistemul (81) prima ecuație (ecuația de stare) are funcția de a estima tendința de evoluție temporală a sistemului prin calcularea vectorului de stare folosit în următorul pas ($k+1$), iar a doua ecuație (ecuația de ieșire) are funcția de a calcula valorile de la pasul curent (k) ale mărimilor de ieșire ale sistemului utilizate de mediul exterior sau de un alt sistem situat în aval.
- Atunci când sistemul (81) este modelul unui algoritm de calcul (un regulator numeric, un observator, etc.) în programul de aplicație succesiunea operațiilor este, de regulă, următoarea: i) se achiziționează $u(k)$; ii) se calculează $y(k)$ și se transmite la ieșire, iii) se calculează $x(k+1)$, valoarea reținându-se pentru a calcula pe $y(k)$ în următorul pas.
- În sistemul (71) $s(k) = \begin{bmatrix} \hat{w}_{i,j,l}(k) \\ R_{i,j,l}(k) \end{bmatrix}$ reprezintă valori calculate în pasul curent k pe baza valorilor cunoscute pentru pasul curentul. Valorile $s(k)$ nu se utilizează în pasul curent, ci doar în pasul următor, $k+1$, ca valori cunoscute pentru acel pas. Ca urmare, atunci când interpretăm (71) ca un sistem dinamic, cu ecuațiile 2 și 4 ca ecuații de stare, în acord cu forma canonică (81) în loc de $s(k)$ trebuie să notăm $s(k+1)$, augmentând argumentul cu o unitate. Continuând raționamentul realizăm că $s(k-1) = \begin{bmatrix} \hat{w}_{i,j,l}(k-1) \\ R_{i,j,l}(k-1) \end{bmatrix}$ trebuie notat cu $s(k)$.
- În cazul variabilelor $e(k)$, $y(k)$, $\tilde{x}_l^T(k)$ și $y_{i,j,l}(k)$ nu se impune nici o schimbare de argument întrucât ele reprezintă valori cunoscute pentru pasul curentul. Totuși, cu privire la $\tilde{x}_l^T(k) = [\tilde{x}_l(k-1) \ \tilde{x}_l(k-2)]$, variabilă cu rol de mărime perturbatoare, trebuie observat că este vorba de o

notație care exprimă ce valori ale lui $\tilde{\underline{x}}_l$ se iau în considerare la momentul k .

- Ca urmare (71) se rescrie într-o primă etapă sub forma:

$$\begin{aligned} e(k) &= y(k) - \tilde{\underline{x}}_l^T(k) \cdot \hat{\underline{w}}_{i,j,l}(k) \\ \hat{\underline{w}}_{i,j,l}(k+1) &= \begin{cases} \hat{\underline{w}}_{i,j,l}(k) + \underline{y}_{i,j,l}(k) \cdot e(k), & \text{daca } \Phi'_{i,j}(z'(k)) = 1, \\ \hat{\underline{w}}_{i,j,l}(k), & \text{daca } \Phi'_{i,j}(z'(k)) = 0 \end{cases} \\ \underline{y}_{i,j,l}(k) &= \frac{1}{\tilde{\underline{x}}_l^T(k) \underline{R}_{i,j,l}(k) \tilde{\underline{x}}_l(k) + \lambda_i} \underline{R}_{i,j,l}(k) \cdot \tilde{\underline{x}}_l^T(k) \cdot \Phi_l(z(k)) \cdot \Phi'_{i,j}(z'(k)) \\ \underline{R}_{i,j,l}(k+1) &= \begin{cases} \frac{1}{\lambda_i} \left[\underline{I} - \underline{y}_{i,j,l}(k) \tilde{\underline{x}}_l^T(k) \right] \cdot \underline{R}_{i,j,l}(k), & \text{daca } \Phi'_{i,j}(z'(k)) = 1 \\ \underline{R}_{i,j,l}(k), & \text{daca } \Phi'_{i,j}(z'(k)) = 0 \end{cases} \end{aligned} \quad (82)$$

iar într-o a doua etapă, după eliminarea erorii $e(k)$, sub forma canonică:

$$\left\{ \begin{aligned} \hat{\underline{w}}_{i,j,l}(k+1) &= \begin{cases} [\underline{I} - \underline{y}_{i,j,l}(k) \tilde{\underline{x}}_l^T(k)] \cdot \hat{\underline{w}}_{i,j,l}(k) + \underline{y}_{i,j,l}(k) \cdot y(k), & \text{daca } \Phi'_{i,j}(z'(k)) = 1 \\ \hat{\underline{w}}_{i,j,l}(k), & \text{daca } \Phi'_{i,j}(z'(k)) = 0 \end{cases} \quad \hat{\underline{w}}_{i,j,l}(0) = \hat{\underline{w}}_{i,j,l,0} \\ \underline{R}_{i,j,l}(k+1) &= \begin{cases} \frac{1}{\lambda_i} [\underline{I} - \underline{y}_{i,j,l}(k) \tilde{\underline{x}}_l^T(k)] \cdot \underline{R}_{i,j,l}(k), & \text{daca } \Phi'_{i,j}(z'(k)) = 1 \\ \underline{R}_{i,j,l}(k), & \text{daca } \Phi'_{i,j}(z'(k)) = 0 \end{cases} \quad \underline{R}_{i,j,l}(0) = \underline{R}_{i,j,l,0} \end{aligned} \right. \quad (83)$$

cu

$$\underline{y}_{i,j,l}(k) = \frac{1}{\tilde{\underline{x}}_l^T(k) \underline{R}_{i,j,l}(k) \tilde{\underline{x}}_l(k) + \lambda_i} \underline{R}_{i,j,l}(k) \cdot \tilde{\underline{x}}_l^T(k) \cdot \Phi_l(z(k)) \cdot \Phi'_{i,j}(z'(k))$$

$$\hat{\underline{w}}_{i,j,l}(k) = [\underline{I}_2 \quad 0] \cdot \begin{bmatrix} \hat{\underline{w}}_{i,j,l}(k) \\ \underline{R}_{i,j,l}(k) \end{bmatrix}$$

Ultima ecuație din (83), $\hat{\underline{w}}_{i,j,l}(k) = [\underline{I}_2 \quad 0] \cdot \begin{bmatrix} \hat{\underline{w}}_{i,j,l}(k) \\ \underline{R}_{i,j,l}(k) \end{bmatrix}$, reprezintă ecuația de

ieșire și este în fond o identitate care fixează ideea că drept ieșire se consideră vectorul coeficienților.

În [36] se prezintă o altă abordare a algoritmului de adaptare RLS, arătându-se similitudinea acestuia cu un filtrul Kalman. Punctul de plecare îl reprezintă faptul că problema adaptării, ca și problema filtrului Kalman, se poate exprima sub forma unei probleme de optimizare constând în minimizarea erorii de predicție $e_{i,j}$ pe baza unui criteriu integral de optimizare pe un orizont de timp τ ce corespunde unui număr suficient de realizări secvențiale ale ieșirii procesului ai cărui parametri de predicție sunt estimați. Aceasta este o condiție necesară pentru ca procesul modelat să poată fi considerat *ergodic*.

În teorie, timpul de stabilizare al procesului tranzitoriu de adaptare este cu aproximație [79]:

$$\tau \approx \frac{1}{2\lambda_i \omega_{i,j,l}}, \quad (84)$$

unde $\omega_{i,j,l}$ reprezintă cea mai mică valoare proprie a matricei $\underline{R}_{i,j,l}$ iar λ_i este factorul de uitare. În cazuri concrete, valoarea timpului de stabilizare depinde și de condițiile

$$\text{inițiale } \begin{cases} \hat{w}_{i,j,l}(0) = \underline{w}_{i,j,l,0} \\ \underline{R}_{i,j,l}(0) = \underline{R}_{i,j,l,0} \end{cases}.$$

Timpul necesar ca eroarea de adaptare $e_{i,j}(k)$ să atingă o valoare minimă impusă δ este strâns legat de condițiile inițiale [81]. Ca urmare, alegerea unor valori inițiale „potrivite” pentru matricea de covarianță R_{ij} este crucială pentru atingerea pragului de convergență într-un număr rezonabil de pași [82]. Acest aspect este exemplificat în paragraful 5.3.3.

5.3.2. Interpretarea adaptării coeficienților folosind o structură de sistem cu comutație

Mecanismul de adaptare este în ansamblu un mecanism hibrid, care la un prim nivel operează secvențial prin acțiuni de comutare de pe un LMM pe altul, corespunzătoare derulării celor 7 faze din cursul unui ciclu de injecție, iar la un al doilea nivel operează pentru LLM-ul selectat ca un sistem în timp discret cu rolul de a asigura adaptarea valorilor celor doi parametri ai LLM-ului. Ideea este redată în fig. 35 care detaliază structura din fig. 34.

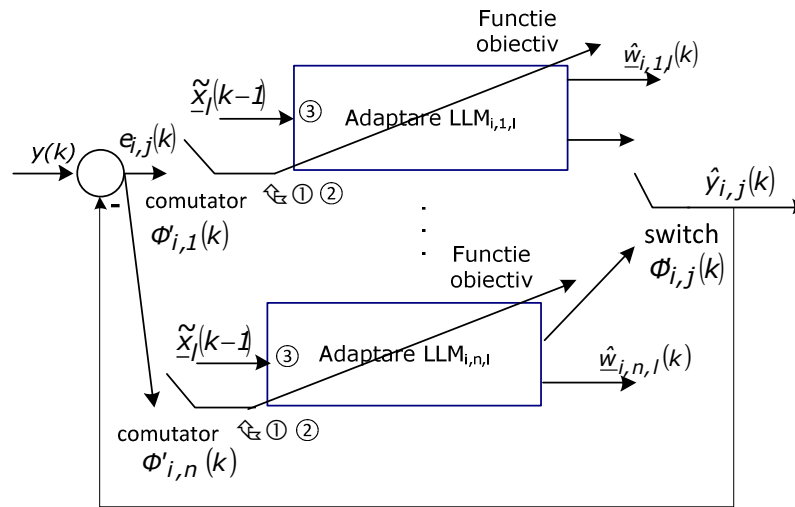


Figura 35. Adaptarea coeficienților modelului de predicție se realizează sub forma unui sistem cu comutație.

Acțiunea de adaptare a coeficienților unui LLM, derulată pe cel de-al doilea nivel ca proces în timp discret, decurge conform ecuațiilor (83). Are durata identică cu cea a fazei sistemului și se reia la fiecare ciclu ori de câte ori faza devine activă. Ca urmare, se poate vorbi de un proces de comutare și la nivelul unui singur LLM. Aprofundând cele de mai sus se ajunge la următoarele două abordări:

- o abordare corespunzătoare situației în care ne interesează doar procesul de adaptare a coeficienților,

- o abordare corespunzătoare situației în care ne interesează ansamblul sistemului de predicție în contextul funcționării rampei comune în cadrul sistemului din Fig. 3.

În primul caz punctul de plecare îl constituie observația că la un moment dat se adaptează doar coeficienții unui singur LLM. Din momentul în care încetează faza corespunzătoare LLM-ului respectiv și până în momentul în care este reactivată adaptarea parametrilor LLM-ului bucla de adaptare este în repaos (regim de suspendare la nivelul LLM), iar valorile coeficienților rămân constante. Este ușor de observat că cele precizate sunt conținute deja de forma (83) a mecanismului de adaptare întrucât acesta poate fi interpretat ca un sistem cu comutație cu orientarea $\{y(k), \tilde{x}_l(k)\} \rightarrow \{\hat{w}_{i,j,l}(k)\}$, de stare $s(k)$ și semnal de comutare $\psi(k) = \Phi'_{i,j}(z'(k))$:

$$\begin{cases}
 s(k+1) = A\Phi'_{i,j}(z'(k))\tilde{x}_l(k) \cdot s(k) + \begin{bmatrix} \underline{y}_{i,j,l}(k) \\ 0 \end{bmatrix} \cdot [y(k)] \\
 \text{cu} \\
 A\Phi'_{i,j}(z'(k))\tilde{x}_l(k) = \begin{cases} \begin{bmatrix} I - \underline{y}_{i,j,l}(k) \cdot \tilde{x}_l^T(k) & 0 \\ 0 & \frac{1}{\lambda_i} (I - \underline{y}_{i,j,l}(k) \tilde{x}_l^T(k)) \end{bmatrix}, & \Phi'_{i,j}(z'(k))=1 \\ \begin{bmatrix} \hat{w}_{i,j,l}(k) & 0 \\ 0 & R_{i,j,l}(k) \end{bmatrix}, & \Phi'_{i,j}(z'(k))=0 \end{cases} \\
 \underline{y}_{i,j,l}(k) = \frac{1}{\tilde{x}_l^T(k)R_{i,j,l}(k)\tilde{x}_l(k) + \lambda_i} R_{i,j,l}(k) \cdot \tilde{x}_l^T(k) \cdot \Phi_i(z(k)) \\
 \hat{w}_{i,j,l}(k) = [I_2 \quad 0] \cdot s(k)
 \end{cases} \quad (85)
 \end{cases}$$

Întrucât la reactivarea algoritmului de adaptare se pleacă de la stările conservate, deci de la ultimele valori ale coeficienților, se poate face abstracție de intervalele de suspendare și se poate privi LLM-ul ca un sistem independent de restul LLM-urilor. Aspectul „sistem cu comutație” nu mai este de interes. Algoritmul recursiv de adaptare fiind convergent rezultă că structura de adaptare interpretată ca sistem adaptiv este asimptotic stabilă și ca urmare și BIBO-stabilă. Deci și ansamblul LLM-urilor este BIBO stabil [80].

În al doilea caz trebuie considerate comutările între toate între fazele de funcționare ale rampei comune, deci comutările între toate LLM-urile. Întrucât această abordare ar aduce în plus doar evidențierea intervalelor de suspendare, studiul nu este oportun.

5.3.3. Asigurarea robusteții algoritmului de adaptare

Problema robusteții algoritmului de adaptare este tratată de autor în [35]. În mod similar cu abordările ce privesc sistemele de reglare, incertitudinile parametrice și nestructurate (zgomot) acționează în permanență asupra procesului de adaptare ca niște perturbații care fac ca eroarea $e_{i,j}(k)$ să fie în permanență nenulă. În felul acesta devine posibil ca valorile parametrilor $\hat{w}_{i,j,l}$ să se modifice chiar și atunci când ele ar trebui să fie păstrate constante. Pentru a asigura

robustețea sistemului adaptiv față de astfel de perturbații pe canalul erorii $e_{i,j}(k)$ din bucla de adaptare se introduce în punctul ① o neliniaritate de tip zonă de insensibilitate $D(e_{i,j})$ (v. fig. 34, 35):

$$D(e_{i,j}) = \begin{cases} 0, & \text{pentru } |e_{i,j}| < \delta \\ e_{i,j}, & \text{pentru } |e_{i,j}| \geq \delta \end{cases} \quad (86)$$

Rolul ei este de a rejecta influența erorilor de predicție foarte mici [78],[83]. Pe aceste considerente, prima ecuație de stare din sistemul (79) devine:

$$\hat{w}_{i,j,l}(k) = \hat{w}_{i,j,l}(k-1) + \underline{y}_{i,j,l}(k) \cdot D(e_{i,j}(k)), \quad \hat{w}_{i,j,l}(0) = \hat{w}_{i,j,l,0} \quad (87)$$

Pentru $e_{i,j}(k) \leq \delta$, algoritmul de adaptare lucrează cu $D(e_{i,j}) = 0$, și $\hat{w}_{i,j,l}$ rămâne constant (nu ajustează în vreun fel valorile anterioare ale coeficienților modelului).

Neliniaritatea (82) are, pe de altă parte, și rolul de a acționa ca un „sesizor” de atingerea practică a convergenței [35].

O altă măsură aplicată în această lucrare pentru rejectarea zgomotului de măsură, este medierea progresivă a erorii de adaptare (v. ② fig. 34, 35). Astfel, în loc să se lucreze cu prima relație din (71)

$$e_{i,j}(k) = y(k) - \tilde{x}_l^T(k-1) \cdot \hat{w}_{i,j,l}(k-1), \quad (88)$$

a erorii de adaptare, se operează cu expresia

$$e_{i,j}(k) = \frac{1}{N_a} \sum_{i=k-N_a+1}^k \left(y(i) - \tilde{x}_l^T(i) \cdot \hat{w}_{i,j,l}(i-1) \right) \quad (89)$$

în care se folosește pentru un $\hat{w}_{i,j,l}$ dat o secvență de adaptare cu N_a eșantioane consecutive.

Avantajele pe care le prezintă această metodă sunt date de capacitatea de rejectare a zgomotului de măsură fără a pierde corelarea dintre intrarea \tilde{x}_l și ieșirea y (pentru $k=1$). Convergența algoritmului de adaptare pentru acest caz nu este riguros demonstrată în literatură.

O vulnerabilitate, deloc de neglijată, a algoritmului de adaptare o constituie „inflația” valorilor elementelor matricei $\underline{R}_{i,j,l}$. Acest lucru se întâmplă în condiții de excitație slabă sau inexistentă a mărimilor de intrare în model. Conform lui Widrow și Kamenetsky [79], efectul „inflaționist” poate fi redus prin introducerea unui factor de „deflație”¹². Această măsură are ca efect reducerea treptată a valorilor matricei $\underline{R}_{i,j,l}$ și implicit a riscului de divergență a coeficienților modelului adaptat.

¹² În acest context, termenii „inflație” și „deflație” se referă la expandarea sau contracția unor valori numerice.

O variantă mai robustă, propusă de autor în această lucrare, este introducerea unei zone de insensibilitate și pentru intrările modelului (v. ③ fig. 34, 35), astfel încât efectul „inflaționist” asupra valorilor matricii $R_{i,j,l}$ să fie oprit înainte de a se produce. Similar cu rejecția zgomotului pe canalul erorii $e_{i,j}(k)$, se introduce un prag de sensibilitate de valoare ε pentru norma $|\tilde{x}_l^T(k)|$ cu rolul de a „îngheța” valorile matricii $R_{i,j}$. Ca urmare, cea de a doua ecuație de stare din (83) va avea forma:

$$\underline{R}_{i,j,l}(k+1) = \begin{cases} \frac{1}{\lambda_l} [I - \underline{Y}_{i,j,l}(k) \tilde{x}_l^T(k)] \cdot \underline{R}_{i,j,l}(k), & \text{dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 1 \\ |\tilde{x}_l^T(k)| \geq \varepsilon \end{cases} \\ \underline{R}_{i,j,l}(k), & \text{dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 0 \\ |\tilde{x}_l^T(k)| < \varepsilon \end{cases} \end{cases}, \quad \underline{R}_{i,j,l}(0) = \underline{R}_{i,j,l,0} \quad (90)$$

Combinând ecuațiile (83), (87) și (90), potrivit precizărilor anterioare, modelul (83) al algoritmului RLS este modificat rezultând varianta robustă, RLSR:

$$\left\{ \begin{array}{l} \hat{\underline{w}}_{i,j,l}(k+1) = \begin{cases} [I - \underline{Y}_{i,j,l}(k) \tilde{x}_l^T(k)] \cdot \hat{\underline{w}}_{i,j,l}(k) + \underline{Y}_{i,j,l}(k) \cdot y(k), & \text{dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 1 \\ |e_{i,j}(k)| \geq \delta \end{cases} \\ \hat{\underline{w}}_{i,j,l}(k), & \text{dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 0 \\ |e_{i,j}(k)| < \delta \end{cases} \end{cases}, \quad \hat{\underline{w}}_{i,j,l}(0) = \hat{\underline{w}}_{i,j,l,0} \\ \underline{R}_{i,j,l}(k+1) = \begin{cases} \frac{1}{\lambda_l} [I - \underline{Y}_{i,j,l}(k) \tilde{x}_l^T(k)] \cdot \underline{R}_{i,j,l}(k), & \text{dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 1 \\ |\tilde{x}_l^T(k)| \geq \varepsilon \end{cases} \\ \underline{R}_{i,j,l}(k), & \text{dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 0 \\ |\tilde{x}_l^T(k)| < \varepsilon \end{cases} \end{cases}, \quad \underline{R}_{i,j,l}(0) = \underline{R}_{i,j,l,0} \\ \text{cu} \\ \begin{cases} e_{i,j}(k) = y(k) - \tilde{x}_l^T(k) \cdot \hat{\underline{w}}_{i,j,l}(k) \\ \underline{Y}_{i,j,l}(k) = \frac{1}{\tilde{x}_l^T(k) \underline{R}_{i,j,l}(k) \tilde{x}_l(k) + \lambda_l} \underline{R}_{i,j,l}(k) \cdot \tilde{x}_l^T(k) \cdot \Phi_l(z(k)) \cdot \Phi'_{i,j}(z'(k)) \end{cases} \\ \hat{\underline{w}}_{i,j,l}(k) = [I_2 \quad 0] \cdot \begin{bmatrix} \hat{\underline{w}}_{i,j,l}(k) \\ \underline{R}_{i,j,l}(k) \end{bmatrix} \end{array} \right. \quad (91)$$

Dacă, suplimentar, se introduce și relația de mediere (89), se obține:

$$\left\{ \begin{array}{l}
 \hat{W}_{i,j,l}(k+1) = \begin{cases} [I - \gamma_{i,j,l}(k) \cdot \tilde{X}_l^T(k)] \cdot \hat{W}_{i,j,l}(k) + \gamma_{i,j,l}(k) \cdot y(k), \text{ dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 1 \\ |e_{i,j}(k)| \geq \delta \end{cases} \\
 \hat{W}_{i,j,l}(k), \text{ dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 0 \\ |e_{i,j}(k)| < \delta \end{cases}
 \end{cases} \quad \hat{W}_{i,j,l}(0) = \hat{W}_{i,j,l,0} \\
 R_{i,j,l}(k+1) = \begin{cases} \frac{1}{\lambda_i} [I - \gamma_{i,j,l}(k) \tilde{X}_l^T(k)] \cdot R_{i,j,l}(k), \text{ dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 1 \\ |\tilde{X}_l^T(k)| \geq \varepsilon \end{cases} \\
 R_{i,j,l}(k), \text{ dacă } \begin{cases} \Phi'_{i,j}(z'(k)) = 0 \\ |\tilde{X}_l^T(k)| < \varepsilon \end{cases}
 \end{cases} \quad R_{i,j,l}(0) = R_{i,j,l,0} \\
 \text{cu} \\
 e_{i,j}(k) = \frac{1}{N_a} \sum_{i=k-N_a+1}^k (y(i) - \tilde{X}_l^T(i) \cdot \hat{W}_{i,j,l}(i)) \\
 \gamma_{i,j,l}(k) = \frac{1}{\tilde{X}_l^T(k) R_{i,j,l}(k) \tilde{X}_l(k) + \lambda_i} R_{i,j,l}(k) \cdot \tilde{X}_l^T(k) \cdot \Phi_i(z(k)) \cdot \Phi'_{i,j}(z'(k)) \\
 \hat{W}_{i,j,l}(k) = [I_2 \quad 0] \cdot \begin{bmatrix} \hat{W}_{i,j,l}(k) \\ R_{i,j,l}(k) \end{bmatrix}
 \end{array} \right. \quad (92)$$

5.3.4. Convergența algoritmului recursiv RLSR

În contextul celor mai sus prezentate, factorii determinanți pentru convergența algoritmului îi reprezintă valorile inițiale $\begin{cases} \hat{W}_{i,j,l}(0) = \hat{W}_{i,j,l,0} \\ R_{i,j,l}(0) = R_{i,j,l,0} \end{cases}$ și valoarea aleasă pentru factorul de uitare λ_i .

Pentru o mai rapidă convergență, vectorul coeficienților fiecărui model este inițializat cu valori diferite de zero, de preferat valori identificate în prealabil în jurul punctului de funcționare, sau $\hat{W}_{i,j,l}(0) = [0.1 \quad 0.1]^T$, iar cel al variabilelor ajutoare $R_{i,j,l}$, cu $R_{i,j,l} = 0.005 \cdot I_2 = \begin{bmatrix} 0.005 & 0 \\ 0 & 0.005 \end{bmatrix}$. Pentru factorul de uitare s-a folosit valoarea tipică $\lambda_i = 0.98$.

Un exemplu de adaptare convergentă este prezentat în Fig. 36. Ea redă grafic evoluțiile în timp ale primelor elemente din cadrul vectorilor stărilor $\hat{W}_{12,4,1}$ și $R_{12,4,1}$ pe durata adaptării în jurul punctului de operare $\Lambda(40^\circ\text{C}, 130\text{MPa})$.




Figura 36. Evoluția primului element din vectorii de stare pe durata secvenței de adaptare pentru LLM-ul corespunzător lui activității pistonului 1 al HPP în jurul punctului de operare $\Lambda(40^{\circ}\text{C}, 130\text{MPa})$.

Cu privire la coeficientul $w_{12,4,1}^1$, trebuie remarcat faptul că el tinde să se stabilizeze la o valoare de 2.82 după cca. 350 de eșantioane. Acest lucru este confirmat de faptul că eroarea de estimare tinde la zero. Mărimile de stare $R_{12,4,1}^1$ este și ea asimptotic convergentă, dar prezintă oscilații permanente.

Reprezentarea evoluției acestor variabile trebuie privită în contextul mecanismului de adaptare. A fost aleasă o reprezentare continuă, eliminând din grafic momentele de inactivitate (reprezentarea s-a făcut doar pentru porțiunile în care LLM-ul e activ). Evident, în acest mod, lucrurile pot fi privite sub forma unei adaptări continue fără intervale de suspendare. Reprezentarea este în concordanță cu utilizarea corectă a formulei (92). Cunoscând faptul că fiecare eșantion are durata de 1 ms și având în vedere că în cazul de față $\lambda_i = 0.98$, iar cea mai mică valoare a matricii $R_{12,4,1}$ la finalul adaptării este $\omega_{12,4,1}^1 \approx 0.003$ ms, rezultă că timpul de convergență, estimat conform formulei (84), este cu aproximație $\tau = 1/(0.98 \cdot 0.003) \approx 340$ ms. Se observă că rezultatul este în concordanță cu situația din Fig. 36.

6 REZULTATE EXPERIMENTALE

Capitolul prezintă modul în care se aplică precizările din capitolele 4 și 5 pentru sinteza modelului de predicție de tip LOLIMOT a valorii gradientului de presiune în rampa comună în cazul simplificat al considerării doar a debitelor masice Q_{INJ}^m și Q_{HPP}^m (paragraful 6.1), maniera în care s-a realizat validarea rezultatelor (paragraful 6.2) și reevaluarea modelului sintetizat prin prisma varianței coeficienților în raport cu temperatura T și presiunea P și a sugerării unei posibilități de restructurare a calculelor de interpolare într-o variantă RIP (paragraful 6.3).

6.1. Determinarea modelului de predicție a presiunii în CR

Modelul de predicție al presiunii din rampa comună se obține prin aplicarea algoritmului din paragraful (4.4). Modelul se dezvoltă iterativ, simultan cu partiționarea spațiului de lucru $S_{T,p}$ în subregiuni. Punctul de plecare pentru algoritmul de separare îl constituie fig. 25. Din considerente de volum de memorie (RAM și ROM), numărul maxim de subregiuni a fost ales $M=12$. Fiecare regiune are un centru notat cu $C_{a,b}$, denumit și punct de sprijin Λ_{cd} . Termenul „centru” este folosit din perspectiva inițială a modelelor neuro-fuzzy de tip LOLIMOT (paragraful 3.3.7) și subliniază asocierea cu un domeniu de validitate. Termenul „punct de sprijin” este folosit din perspectiva ulterioară a modelelor de tip interpolativ (paragraful 4.2) și vizează participarea coeficienților asociați punctului respectiv la cel puțin un domeniu de interpolare biliniară. În aplicarea algoritmului s-a folosit ca și criteriu de performanță, pe tot spațiul de lucru, condiția $I_{MSE} < 1$, I_{MSE} fiind valoarea indicelui de eroare medie pătrată (MSE) calculată cu relația (73).

Experimentele s-au realizat folosind standul experimental din fig. 33. Acesta a fost utilizat atât pentru manipularea punctelor de operare ale sistemului cât și pentru mărimile de intrare asociate debitelor masice. Cele din urmă au fost modificate în trepte, sub formă de semnale scară, în limitele precizate în tabelul I. Pe parcursul secvenței de adaptare au fost urmărite doar fazele asociate debitelor Q_{INJ}^m și Q_{HPP}^m . Datele măsurate au fost prelucrate și afișate cu ajutorul aplicației Matlab 7.1.

În cele ce urmează se prezintă parcurgerea secvențială a algoritmului și rezultatele obținute în cursul procesului de adaptare. Aplicarea se soldează cu 12 puncte de sprijin, respectiv cu un model cu 12×12 coeficienți (câte 12 coeficienți pentru fiecare punct de sprijin). Corespondența notațiilor punctelor de operare, centrelor, punctelor de sprijin și LM-urilor este dată în tabelul II:

TABEL II. NOTAȚIILOR PUNTELOR DE OPERARE, CENTRELOR, PUNTELOR DE SPRIJIN ȘI LM-URILOR

Puncte de operare	Notația ca centru	Notația ca punct de sprijin	LM-ul asociat punctului de sprijin
$\Lambda(20^{\circ}\text{C}, 110\text{MPa})$	$C_{2,3}$	Λ_1	LM_1
$\Lambda(20^{\circ}\text{C}, 70\text{MPa})$	$C_{2,1}$	Λ_2	LM_2
$\Lambda(0^{\circ}\text{C}, 110\text{MPa})$	$C_{1,3}$	Λ_3	LM_3
$\Lambda(40^{\circ}\text{C}, 110\text{MPa})$	$C_{3,3}$	Λ_4	LM_4
$\Lambda(20^{\circ}\text{C}, 130\text{MPa})$	$C_{2,4}$	Λ_5	LM_5
$\Lambda(20^{\circ}\text{C}, 90\text{MPa})$	$C_{2,2}$	Λ_6	LM_6
$\Lambda(40^{\circ}\text{C}, 70\text{MPa})$	$C_{3,1}$	Λ_7	LM_7
$\Lambda(0^{\circ}\text{C}, 70\text{MPa})$	$C_{1,1}$	Λ_8	LM_8
$\Lambda(40^{\circ}\text{C}, 90\text{MPa})$	$C_{3,2}$	Λ_9	LM_9
$\Lambda(0^{\circ}\text{C}, 90\text{MPa})$	$C_{1,2}$	Λ_{10}	LM_{10}
$\Lambda(40^{\circ}\text{C}, 130\text{MPa})$	$C_{3,4}$	Λ_{11}	LM_{11}
$\Lambda(0^{\circ}\text{C}, 130\text{MPa})$	$C_{1,4}$	Λ_{12}	LM_{12}

Notațiile folosite în figuri pentru coeficienți sunt următoarele: $w_{i,j,l}^1 = w1(i, j, l)$, $w_{i,j,l}^2 = w2(i, j, l)$, i reprezentând indicele neuronului sau LM-ului.

6.1.1. Descompunerea inițială a spațiului $S_{T,P}$

Punctele *a*) și *b*) din etapa I a algoritmului de construire a modelului de predicție (paragraful 4.4) presupun delimitarea spațiului de lucru și alegerea unor puncte de sprijin inițiale. Au fost alese 5 puncte: $\Lambda_1, \Lambda_2, \Lambda_3, \Lambda_4$ și Λ_5 dispuse ca în fig. 37. Lor li se asociază în continuare respectiv, LM-urile: $\text{LM}_1, \text{LM}_2, \text{LM}_3, \text{LM}_4$ și LM_5 . Dreptunghiurile colorate sugerează regiunile de validitate pentru fiecare LM.




Figura 37. Descompunerea inițială a spațiului intrărilor pe axele T și P

Algoritmul continuă cu punctul c) prin adaptarea coeficienților celor 5 LM-urilor. Având în vedere că în fiecare punct de sprijin sunt active doar 6 din cele 7 faze, și că LLM-ul fiecărei faze are doar 2 coeficienți, rezultă că pentru fiecare LM s-au determinat 12 coeficienți.

- **LM₁** – model adaptat în vecinătatea punctului de sprijin Λ_1




Figura 38. Evoluția coeficienților LM₁ pe durata secvenței de antrenare

Conform graficului din fig. 38, valorile adaptate ale coeficienților LLM-urilor se „stabilizează” după aprox. 20 de secunde de la inițierea procesului de adaptare la nivelurile din Tabelul III.

TABEL III. COEFICIENȚII MODELULUI LM₁ ASOCIAT NEURONULUI 1

Faza j a sistemului	Debitele masice ($Q_{i,j,l}^m$)	Coeficienții LLM _{1,i}	
		$w^1_{i,j,l}$	$w^2_{i,j,l}$
0	$Q_{INJ}^m 0$	-3.1682	-0.0067
1	$Q_{INJ}^m 1$	-2.7977	-0.0081
2	$Q_{INJ}^m 2$	-2.7722	-0.0088
3	$Q_{INJ}^m 3$	-2.6989	-0.0087
4	$Q_{HPP}^m 1$	2.3896	0.0152
5	$Q_{HPP}^m 2$	2.5681	0.0144

În fig. 39 se prezintă comparativ rezultatele simulării cu acest model, pe parcursul aceluiași experiment, pe un interval de 10 secunde. Presiunea prezintă variații într-o plajă de cca. 2,5 MPa, iar eroarea de estimare medie este mai mică decât 1 MPa. Indicele I_{MSE} are valoarea $4.83 \cdot 10^{-1}$, notată în partea inferioară a figurii.




Figura 39. ¹³Rezultatul validării pentru LM_1 în vecinătatea punctului de funcționare Λ_1

Aceiași pași ai algoritmului se desfășoară și pentru celelalte modele, cu rezultate similare.

- LM_2 – model adaptat în vecinătatea punctului de sprijin Λ_2





Figura 40. Evoluția coeficienților LM_2 pe durata secvenței de antrenare


¹³ Indicele MSE corespunde relației (73)

TABEL IV. COEFICIENȚII MODELULUI LM_2 ASOCIAT NEURONULUI 2

Faza j a sistemului	Debitele masice (Q_{INJ}^m)	Coeficienții $LLM_{2,j}$	
		$w^1_{2,j,l}$	$w^2_{2,j,l}$
0	$Q_{INJ}^m 0$	-3.3670	-0.017
1	$Q_{INJ}^m 1$	-3.3483	-0.0997
2	$Q_{INJ}^m 2$	-3.4584	-0.0098
3	$Q_{INJ}^m 3$	-3.3933	-0.0098
4	$Q_{HPP}^m 1$	1.9752	0.0454
5	$Q_{HPP}^m 2$	2.1130	0.0154

Figura 41. Rezultatul validării pentru LM_2 în vecinătatea punctului de funcționare Λ_2

- **LM_3** – model adaptat în vecinătatea punctului de sprijin Λ_3

Figura 42. Evoluția coeficienților LM_3 pe durata secvenței de antrenareTABEL V. COEFICIENȚII MODELULUI LM_3 ASOCIAT NEURONULUI 3

Faza j a sistemului	Debitele masice (Q_{INJ}^m)	Coeficienții $LLM_{3,j}$	
		$w^1_{3,j,l}$	$w^2_{3,j,l}$
0	$Q_{INJ}^m 0$	-2.8303	-0.0093
1	$Q_{INJ}^m 1$	-2.6272	-0.0027
2	$Q_{INJ}^m 2$	-2.6054	-0.0026
3	$Q_{INJ}^m 3$	-2.6129	-0.0018
4	$Q_{HPP}^m 1$	2.2183	0.073
5	$Q_{HPP}^m 2$	2.2941	0.0725




Figura 43. Rezultatul validării pentru LM_3 în vecinătatea punctului de funcționare Λ_3

- **LM_4** – model adaptat în vecinătatea punctului de sprijin Λ_4




Figura 44. Evoluția coeficienților LM_4 pe durata secvenței de antrenare

TABEL VI. COEFICIENȚII MODELULUI LM₄ ASOCIAT NEURONULUI 4

Faza j a sistemului	Debitele masice (Q_{\bullet}^m)	Coeficienții LLM _{4,j}	
		$w^1_{4,j,l}$	$w^2_{4,j,l}$
0	$Q_{INJ}^m 0$	-3.4211	-0.0097
1	$Q_{INJ}^m 1$	-3.5203	0.0095
2	$Q_{INJ}^m 2$	-3.3054	0.0081
3	$Q_{INJ}^m 3$	-3.2389	0.0099
4	$Q_{HPP}^m 1$	3.0072	0.0596
5	$Q_{HPP}^m 2$	2.9362	0.077




Figura 45. Rezultatul validării pentru LM₄ în vecinătatea punctului de funcționare Λ_4

- **LM₅** – model adaptat în vecinătatea punctului de sprijin Λ_5




Figura 46. Evoluția coeficienților LM_5 pe durata secvenței de antrenare

TABEL VII. COEFICIENȚII MODELULUI LM_5 ASOCIAT NEURONULUI 5

Faza j a sistemului	Debitele masice (Q_{INJ}^m)	Coeficienții $LLM_{5,j}$	
		$w^1_{5,j,l}$	$w^2_{5,j,l}$
0	$Q_{INJ}^m 0$	-2.9843	-0.007
1	$Q_{INJ}^m 1$	-2.8535	-0.0058
2	$Q_{INJ}^m 2$	-2.8482	-0.0064
3	$Q_{INJ}^m 3$	-2.8537	-0.0061
4	$Q_{HPP}^m 1$	2.908	0.0893
5	$Q_{HPP}^m 2$	2.963	0.0851




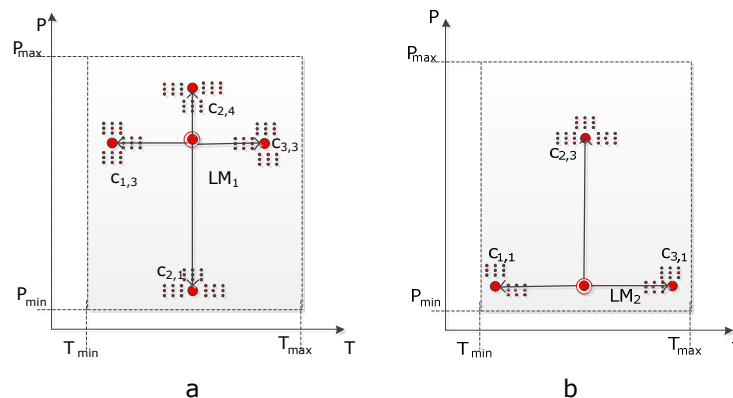
Figura 47. Rezultatul validării pentru LM_5 în jurul punctului de funcționare Λ_5

Punctul e) al algoritmului presupune evaluarea fiecărui LM determinat în punctele de sprijin învecinate sau, dacă acestea nu există, în capetele segmentelor de axă. În urma evaluării, va rezulta zona din spațiul de lucru $S_{T,P}$ cel mai slab reprezentată de modelul general, alcătuit în această etapă de cele 5 LM-uri. În figura 48 este reprezentat modul în care se realizează evaluarea LM-urilor deja sintetizate. Punctul încercuit corespunde punctului de sprijin al cărui LM se evaluează. Punctele neîncercuite reprezintă puncte de evaluare și totodată, potențiale puncte de sprijin.

Astfel, Fig. 48.a se referă la LM_1 și este în corespondență cu înregistrările din Fig. 49. LM_1 este evaluat în patru puncte adiacente: centrele $C_{2,1}$, $C_{2,4}$, $C_{1,3}$ și $C_{3,3}$. Din Fig. 49 se observă că rezultatul cel mai bun, comparabil cu cel din Fig. 39, corespunde centrului $C_{2,1}$, iar cel mai slab centrului $C_{2,4}$.

Fig. 48.b împreună cu fig. 50 se referă la LM_3 . Rezultatul cel mai slab corespunde punctului $\Lambda(20^\circ\text{C}, 110\text{MPa})$.

În mod similar, perechilor de figuri 48.c și 51, 48.d și Fig. 52, respectiv 48.e și Fig. 53 se referă, respectiv la LM_3 , LM_4 și LM_5 .






Figura 48. Evaluarea modelelor adaptate în vederea unei noi partiționări: a. LM₁, b. LM₂, c. LM₃, d. LM₄ și e. LM₅

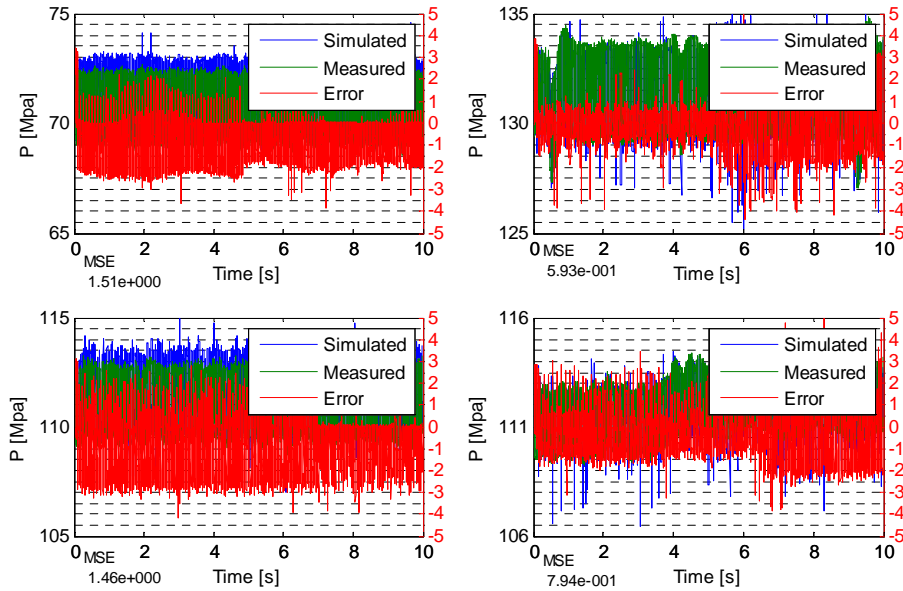


Figura 49. Indicele MSE pentru modelul LM₁ evaluat la limitele dreptunghiului asociat (sus: $\Lambda(20^{\circ}\text{C}, 70\text{MPa})$, $\Lambda(20^{\circ}\text{C}, 130\text{MPa})$, jos: $\Lambda(0^{\circ}\text{C}, 110\text{MPa})$, $\Lambda(40^{\circ}\text{C}, 110\text{MPa})$)

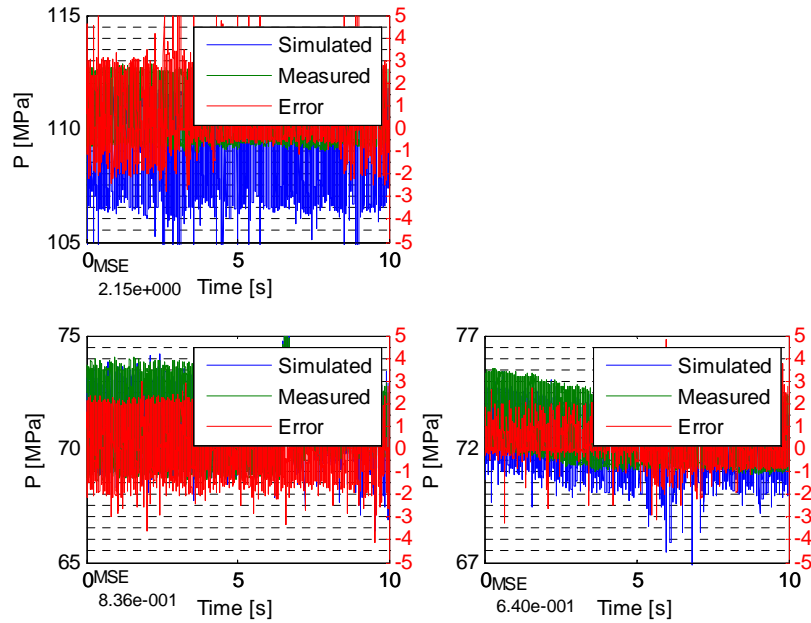


Figura 50. Indicele MSE pentru modelul LM_2 evaluat la limitele dreptunghiului asociat (sus: $\Lambda(20^\circ\text{C}, 110\text{MPa})$, jos: $\Lambda(0^\circ\text{C}, 70\text{MPa})$, $\Lambda(40^\circ\text{C}, 70\text{MPa})$)

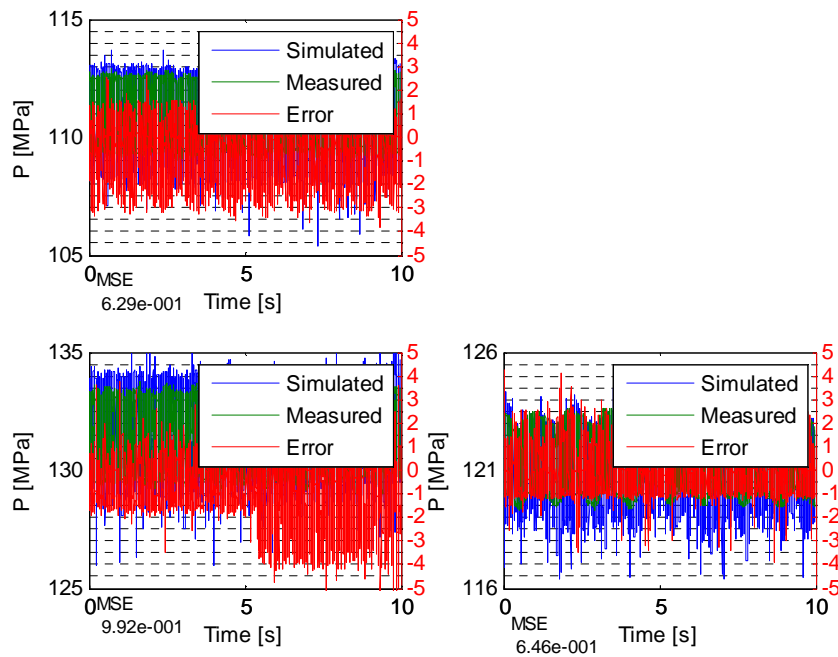


Figura 51. Indicele MSE pentru modelul LM_3 evaluat la limitele dreptunghiului asociat (sus: $\Lambda(20^\circ\text{C}, 110\text{MPa})$, jos: $\Lambda(0^\circ\text{C}, 130\text{MPa})$, $\Lambda(40^\circ\text{C}, 120\text{MPa})$)

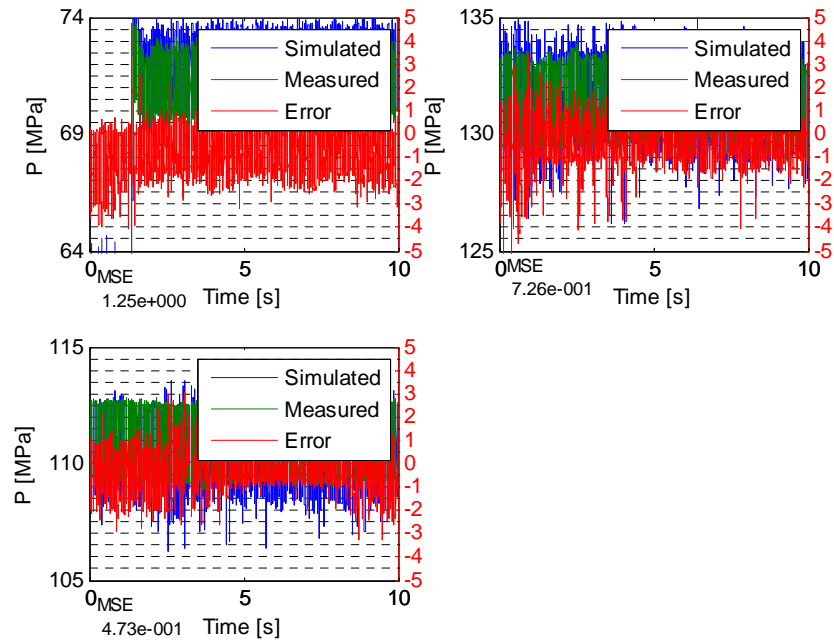


Figura 52. Indicele MSE pentru modelul LM₄ evaluat la limitele dreptunghiului asociat (sus: $\Lambda(0^\circ\text{C}, 70\text{MPa})$, $\Lambda(0^\circ\text{C}, 130\text{MPa})$, jos: $\Lambda(20^\circ\text{C}, 110\text{MPa})$)

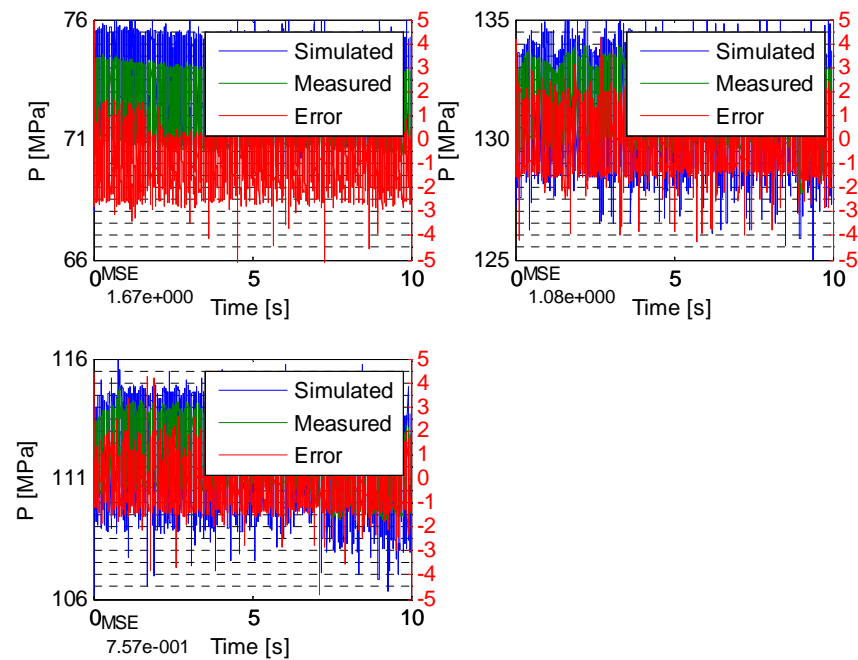


Figura 53. Indicele MSE pentru modelul LM₅ evaluat la limitele dreptunghiului asociat (sus: $\Lambda(40^\circ\text{C}, 70\text{MPa})$, $\Lambda(40^\circ\text{C}, 130\text{MPa})$, jos: $\Lambda(20^\circ\text{C}, 110\text{MPa})$)

După parcurgerea etapelor de mai sus rezultă că cel mai slab indice de performanță, determinat conform formulei (74) corespunde perechii de modele asociate centrilor $c_{2,3}$ - $c_{2,1}$. Pentru această pereche $I_{MSE\ max} = (I_{C2,3,C2,1} + I_{C2,1,C2,3})/2 = (2.15+1.51)/2 = 1.83$.

Drept urmare, rezultă ca necesară și posibilă ¹⁴, o primă separare a spațiului pe direcția axei P , la jumătatea distanței dintre punctele de sprijin pentru care s-au obținut LM_1 și LM_2 . Noul punct de sprijin este $\Lambda_6 = \Lambda(20^\circ\text{C}, 90\text{MPa})$, la mijlocul distanței dintre $c_{2,3}$ și $c_{2,1}$, iar model corespunzător va fi notat cu LM_6 . După această operație configurația punctelor de sprijin, se modifică ca în fig. 54.




Figura 54. Descompunerea spațiului intrărilor pe axele T și P pentru prima iterație

• Completarea grilei de puncte de sprijin

În continuare, aplicarea algoritmului din paragraful 4.4 continuă iterativ, prin parcurgerea repetitivă a pașilor c), ..., f). La finalul fiecărui pas f) rezultă o nouă configurație a punctelor de sprijin. Secvența ciclică se reia de la pasul c) cu mențiunea că până la final operațiunile de adaptare și evaluare se realizează doar pentru un singur LM.

6.1.2. Iterația 1 de sinteză a modelului de predicție

- **LM₆** – adaptat în jurul punctului de funcționare Λ_6

¹⁴ Se referă la faptul că în această fază este posibil să se adauge un nou punct de sprijin întrucât, deocamdată, $M < 12$.

Experimente efectuate pentru variații ale lui P și T în vecinătatea punctului Λ_6 au condus la rezultatele din Fig. 54, iar pentru momentul final $t = 20$ s, la valorile celor 12 coeficienți ai LM_6 din Tabelul VIII. În Fig. 56 este redată variația erorilor de predicție din cursul ultimelor 10 s ale experimentului.




Figura 55. Evoluția coeficienților LM_6 pe durata secvenței de antrenare

TABEL VIII. COEFICIENȚII MODELULUI LM_6 ASOCIAT NEURONULUI 6

Faza j a sistemului	Debitele masice (Q_{*}^m)	Coeficienții $LLM_{6,j}$	
		$w^1_{6,j,l}$	$w^2_{6,j,l}$
0	$Q_{INJ}^m 0$	-2.9074	-0.0089
1	$Q_{INJ}^m 1$	-2.9341	0.0098
2	$Q_{INJ}^m 2$	-3.0217	0.0099
3	$Q_{INJ}^m 3$	-2.9384	0.0098
4	$Q_{HPP}^m 1$	2.3696	0.0969
5	$Q_{HPP}^m 2$	2.4053	0.0961




Figura 56. Rezultatul validării pentru LM_6 în jurul punctului de funcționare Λ_6

La finalul secvenței de adaptare se observă convergența coeficienților, iar în urma validării, rezultă o valoare medie a indicelui de performanță mediu de $6.56 \cdot 10^{-1}$.

- **A 2 - a descompunere a spațiului $S_{T,P}$**

LM_6 este evaluat în punctele vecine: în centrele $c_{2,3}$ și $c_{2,1}$ și în punctele marginale $c_{1,2}$ și $c_{3,2}$. În fig. 57 este explicat modul de evaluare păstrându-se convenția notațiilor stabilită în preambulul paragrafului. Graficele din fig. 58 prezintă variația erorilor de predicție și valorile medii ale indicilor de performanță pe intervalul de evaluare. În mod similar, LM_1 și LM_2 , vecine cu noul punct de sprijin (fig 59), sunt evaluate în vecinătatea punctului de sprijin Λ_6 . Graficele din fig. 60, prezintă variația erorilor de predicție și valorile medii ale indicilor de performanță pe același interval de timp de evaluare.

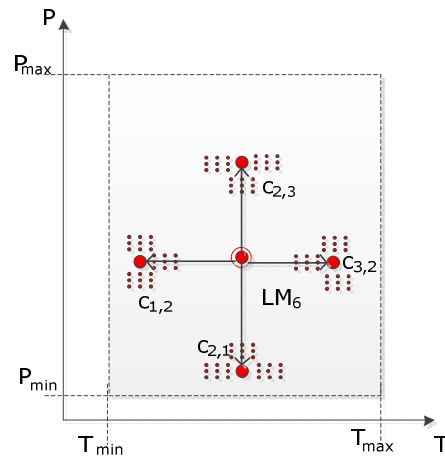


Figura 57. Evaluarea modelului adaptat în vederea unei noi partiționări.

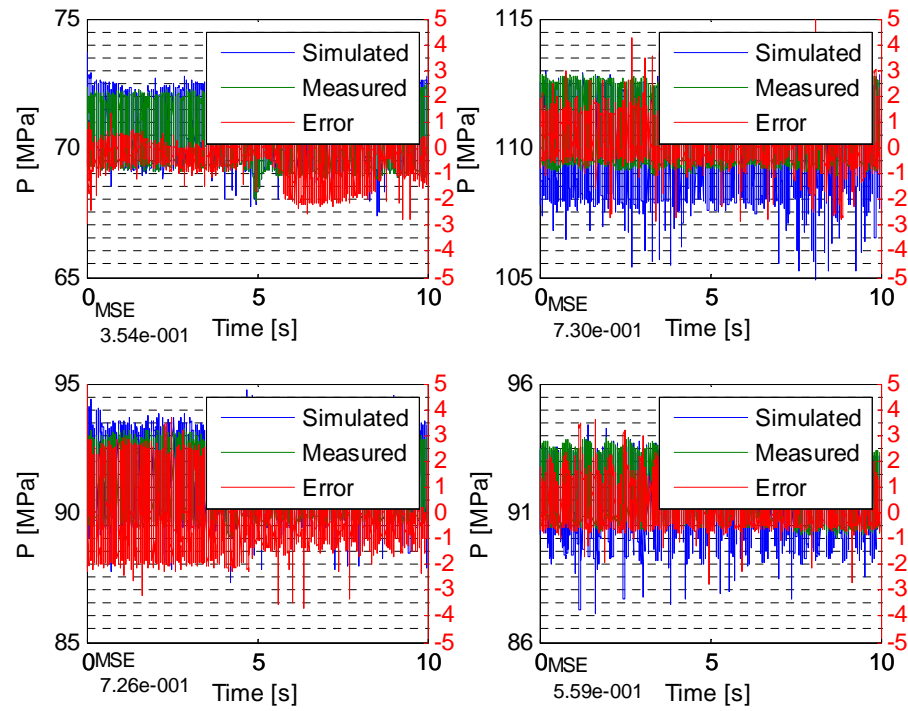


Figura 58. Indicele MSE pentru modelul LM_6 evaluat la limitele dreptunghiului asociat (sus: $\Lambda(20^\circ\text{C}, 70\text{MPa})$, $\Lambda(20^\circ\text{C}, 110\text{MPa})$, jos: $\Lambda(0^\circ\text{C}, 90\text{MPa})$, $\Lambda(40^\circ\text{C}, 90\text{MPa})$)




Figura 59. Evaluarea modelelor deja adaptate LM_1 , LM_2 în vecinătatea punctului Λ_6




Figura 60. Indicele MSE pentru modelele LM_1 și LM_2 evaluate la limita dreptunghiului asociat LM_6

Conform indicilor de performanță calculați, cel mai slab indice de performanță, determinat conform formulei (74), corespunde punctului $c_{3,1}$ (sau $\Lambda(40^\circ\text{C}, 70\text{MPa})$) pentru care avem $I_{MSE \max} = (I_{C2,1,C3,1} + I_{C3,3,C3,1})/2 = (1.67+0.75)/2=1.21$.

Rezultă ca necesară și posibilă o nouă separare a spațiului pe cele două axe, prin introducerea unui nou punct de sprijin la limita superioară a axei T și la limita inferioară a axei P . Noul LM, LM_7 , va avea centrul $c_{3,1}$ în punctul de sprijin $\Lambda_7=\Lambda(40^\circ\text{C}, 70\text{MPa})$. Configurația punctelor de sprijin ale spațiului $S_{T,P}$ va arăta ca în fig. 61.




Figura 61. Descompunerea spațiului intrărilor pe axele T și P pentru a doua iterație

6.1.3. Iterația a 2-a de sinteză a modelului de predicție

- LM_7 – adaptat în jurul punctului de funcționare Λ_7

Experimentele efectuate pentru variații ale lui P și T în vecinătatea punctului Λ_7 au condus la rezultatele din Fig. 62, iar pentru momentul final $t = 20$ s, la valorile celor 12 coeficienți ai LM_7 din Tabelul IX. În Fig. 63 este redată variația erorilor de predicție din cursul ultimelor 10 s ale experimentului.




Figura 62. Evoluția coeficienților LM_7 pe durata secvenței de antrenare

TABEL IX. COEFICIENȚII MODELULUI LM_7 ASOCIAT NEURONULUI 7

Faza j a sistemului	Debitele masice (Q_{\cdot}^m)	Coeficienții $LLM_{7,i}$	
		$w^1_{7,j,l}$	$w^2_{7,j,l}$
0	$Q_{INJ}^m 0$	-3.1064	-0.0102
1	$Q_{INJ}^m 1$	-3.2881	0.0105
2	$Q_{INJ}^m 2$	-3.3390	0.0099
3	$Q_{INJ}^m 3$	-3.3135	0.0104
4	$Q_{HPP}^m 1$	2.5451	0.0084
5	$Q_{HPP}^m 2$	2.6012	0.0145




Figura 63. Rezultatul validării pentru LM_7 în jurul punctului de funcționare Λ_7

La finalul secvenței de adaptare se observă convergența coeficienților, iar în pe ansamblul validării o valoare medie a indicelui de performanță de $6.07 \cdot 10^{-1}$.

- **A 4-a descompunere a spațiului $S_{T,P}$**

LM_7 este evaluat în centrele vecine $c_{3,3}$ și $c_{2,1}$, ambele puncte de sprijin, cărora le corespund LM_4 și LM_2 , deja determinate. În fig. 64 este explicat modul de evaluare păstrându-se convenția notațiilor stabilită la inițializarea algoritmului. Graficele din fig. 65 prezintă variația erorilor de predicție și valorile medii ale indicilor de performanță pe intervalul de evaluare.




Figura 64. Evaluarea modelului adaptat în vederea unei noi partiționări. Sus: $\Lambda(40^\circ\text{C}, 110\text{MPa})$, jos: $\Lambda(20^\circ\text{C}, 70\text{MPa})$

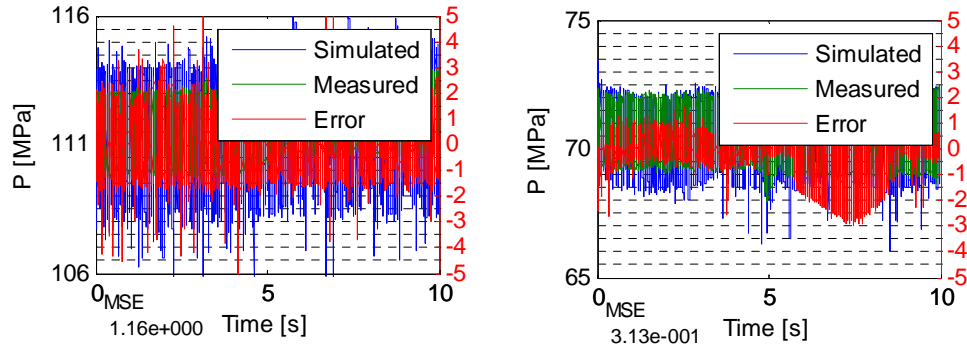


Figura 65. Indicele MSE pentru modelul LM_7 evaluat la limitele dreptunghiului asociat (sus: $\Lambda(40^\circ\text{C}, 110\text{MPa})$, jos: $\Lambda(20^\circ\text{C}, 70\text{MPa})$)

După evaluarea tuturor indicilor de performanță, rezultă că cel mai slab indice de performanță, determinat conform formulei (74), corespunde centrului $c_{1,1}$ pentru care avem $I_{MSE\ max} = (I_{c_{2,1},c_{1,1}} + I_{c_{1,3},c_{1,1}})/2 = (1.25+0.77)/2=1.01$.

Rezultă, ca necesară și posibilă, o nouă separare a spațiului pe axele T și P , prin introducerea unui nou punct de sprijin $\Lambda_8 = \Lambda(0^\circ\text{C}, 70\text{MPa})$, aflat la limita inferioară a celor două axe. Noul model se notează cu LM_8 , iar configurația punctelor de sprijin din spațiului $S_{T,P}$, va arăta ca în fig. 66.




Figura 66. Descompunerea spațiului intrărilor pe axele T și P pentru a treia iterație

6.1.4. Iterația a 3-a de sinteză a modelului de predicție

- **LM_8** – adaptat în jurul punctului de funcționare Λ_8

Experimentele efectuate pentru variații ale lui P și T în vecinătatea punctului Λ_8 au condus la rezultatele din Fig. 67, iar pentru momentul final $t = 20$ s, la valorile

celor 12 coeficienți ai LM_8 din Tabelul X. În Fig. 68 este redată variația erorilor de predicție din cursul ultimelor 10 s ale experimentului.




Figura 67. Evoluția coeficienților LM_8 pe durata secvenței de antrenare

TABEL X. COEFICIENȚII MODELULUI LM_8 ASOCIIAT NEURONULUI 8

Faza j a sistemului	Debitele masice (Q_{INJ}^m)	Coeficienții $LLM_{8,j}$	
		$w_{8,j,l}^1$	$w_{8,j,l}^2$
0	$Q_{INJ}^m 0$	-3.079	-0.0144
1	$Q_{INJ}^m 1$	-3.2611	0.0194
2	$Q_{INJ}^m 2$	-3.2276	0.0099
3	$Q_{INJ}^m 3$	-3.0661	0.0101
4	$Q_{HPP}^m 1$	1.5997	0.0644
5	$Q_{HPP}^m 2$	1.6128	0.0694




Figura 68. Rezultatul validării pentru LM_8 în jurul punctului de funcționare Λ_8

La finalul secvenței de adaptare se observă convergența coeficienților, iar în cursul validării o valoare medie a indicelui de performanță de $4.87 \cdot 10^{-1}$.

- **A 5-a descompunere a spațiului $S_{T,P}$**

LM_8 este evaluat în centrele vecine $c_{1,3}$ și $c_{2,1}$, ambele puncte de sprijin, având asociate LM_3 și LM_2 . În fig. 69 este explicat modul de evaluare. Graficele din fig. 70 prezintă variația erorilor de predicție și valorile medii ale indicilor de performanță pe intervalul de evaluare.




Figura 69. Evaluarea modelului adaptat în vederea unei noi partiționări

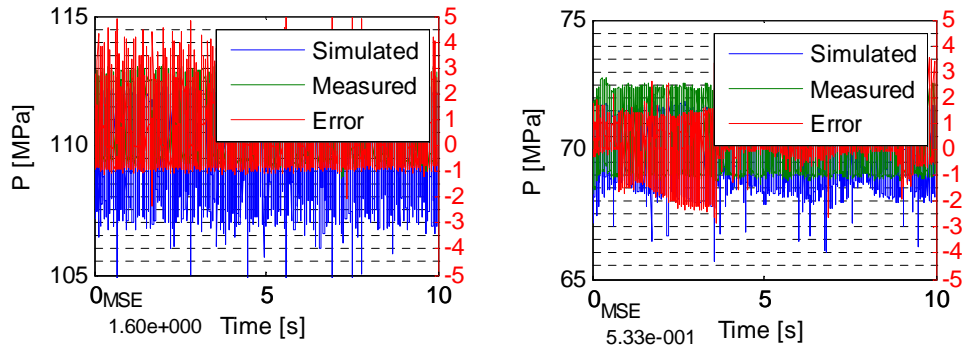


Figura 70. Indicele MSE pentru modelul LM_8 evaluat la limitele dreptunghiului asociat (sus: $\Lambda(0^\circ\text{C}, 110\text{MPa})$, jos: $\Lambda(20^\circ\text{C}, 70\text{MPa})$)

După evaluarea tuturor indicilor de performanță, cel mai slab indice de performanță, determinat conform formulei (74), corespunde perechii de modele asociate centrilor $c_{3,1}-c_{3,3}$ pentru care avem $I_{MSE\ max} = (I_{C_{3,1},C_{3,3}} + I_{C_{3,3},C_{3,1}})/2 = (1.67+1.16)/2=1.41$.

Rezultă, ca necesară și posibilă, o nouă separare a spațiului pe axa P , introducând un nou punct de sprijin $\Lambda_9=\Lambda(40^\circ\text{C}, 90\text{MPa})$. Noul model se notează cu LM_9 , iar configurația punctelor spațiului $S_{T,P}$ va arăta ca în fig. 71.




Figura 71. Descompunerea spațiului intrărilor pe axele T și P pentru a patra iterație

6.1.5. Iterația a 4-a de sinteză a modelului de predicție

- LM_9 – adaptat în jurul punctului de funcționare Λ_9

Experimentele efectuate pentru variații ale lui P și T în vecinătatea punctului Λ_9 au condus la rezultatele din Fig. 72, iar pentru momentul final $t = 20$ s, la valorile

celor 12 coeficienți ai LM_9 din Tabelul XI. În Fig. 73 este redată variația erorilor de predicție din cursul ultimelor 10 s ale experimentului.




Figura 72. Evoluția coeficienților LM_9 pe durata secvenței de antrenare

TABEL XI. COEFICIENȚII MODELULUI LM_9 ASOCIAT NEURONULUI 9

Faza j a sistemului	Debitele masice (Q_{\cdot}^m)	Coeficienții $LLM_{9,i}$	
		$w_{9,j,l}^1$	$w_{9,j,l}^2$
Faza j a sistemului	Debitele masice	Coeficienții $LLM_{9,i}$	
		$w_{9,i,l}^1$	$w_{9,i,l}^2$
0	$Q_{INJ}^m 0$	-3.1610	-0.0067
1	$Q_{INJ}^m 1$	-3.1204	0.0773
2	$Q_{INJ}^m 2$	-3.1985	0.0778
3	$Q_{INJ}^m 3$	-3.0722	0.0629
4	$Q_{HPP}^m 1$	2.9547	0.0144
5	$Q_{HPP}^m 2$	2.9358	0.0194




Figura 73. Rezultatul validării pentru LM_9 în jurul punctului de funcționare Λ_9

La finalul secvenței de adaptare se observă convergența coeficienților iar în cursul validării o valoare medie a indicelui de performanță de $5.65 \cdot 10^{-1}$.

- **A 6-a descompunere a spațiului $S_{T,P}$**

LM_9 este evaluat în centrele vecine $c_{3,1}$, $c_{3,3}$ și $c_{2,2}$, toate puncte de sprijin ale rețelei în construcție. În fig. 74 este explicat modul de evaluare. Graficele din fig. 75 prezintă variația erorilor de predicție și valorile medii ale indicilor de performanță pe intervalul de evaluare. În mod similar, LM-urile corespunzătoare centrelor vecine cu noul punct de sprijin (fig 76), LM_3 , LM_6 și LM_7 , sunt evaluate în vecinătatea punctului de sprijin Λ_9 . Graficele din fig. 77, prezintă variația erorilor de predicție și valorile medii ale indicilor de performanță pe intervalul de evaluare.




Figura 74. Evaluarea LM_9 adaptat în vederea unei noi partiționări

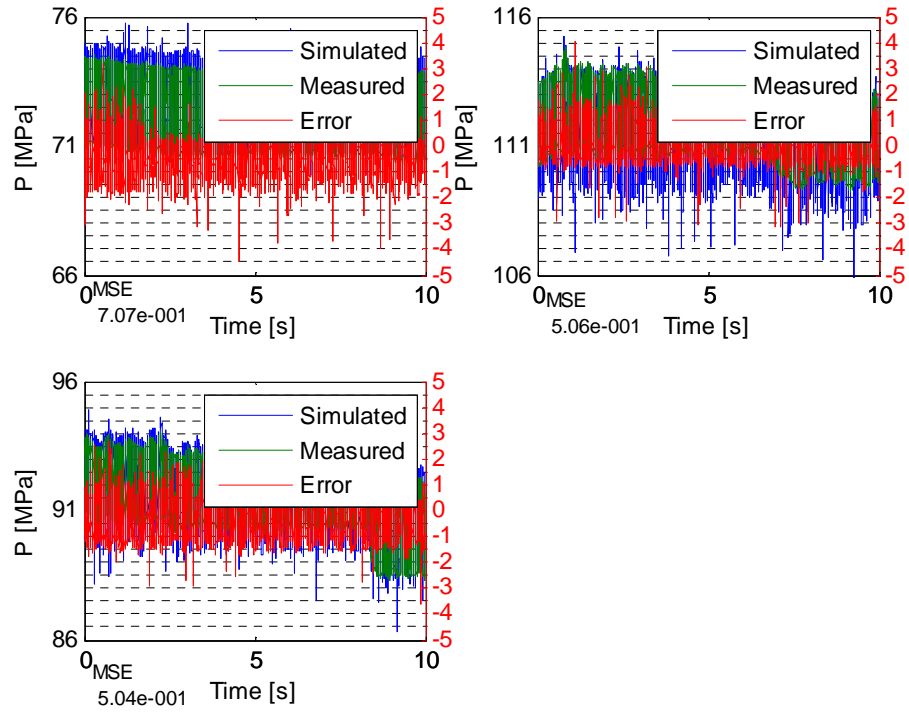


Figura 75. Indicele MSE pentru modelul LM₉ evaluat la limitele dreptunghiului asociat (sus: $\Lambda(40^\circ\text{C}, 70\text{MPa})$, $\Lambda(40^\circ\text{C}, 110\text{MPa})$, jos: $\Lambda(20^\circ\text{C}, 90\text{MPa})$)




Figura 76. Evaluarea modelelor deja adaptate LM₃, LM₆ și LM₇ în vecinătatea punctului Λ_9

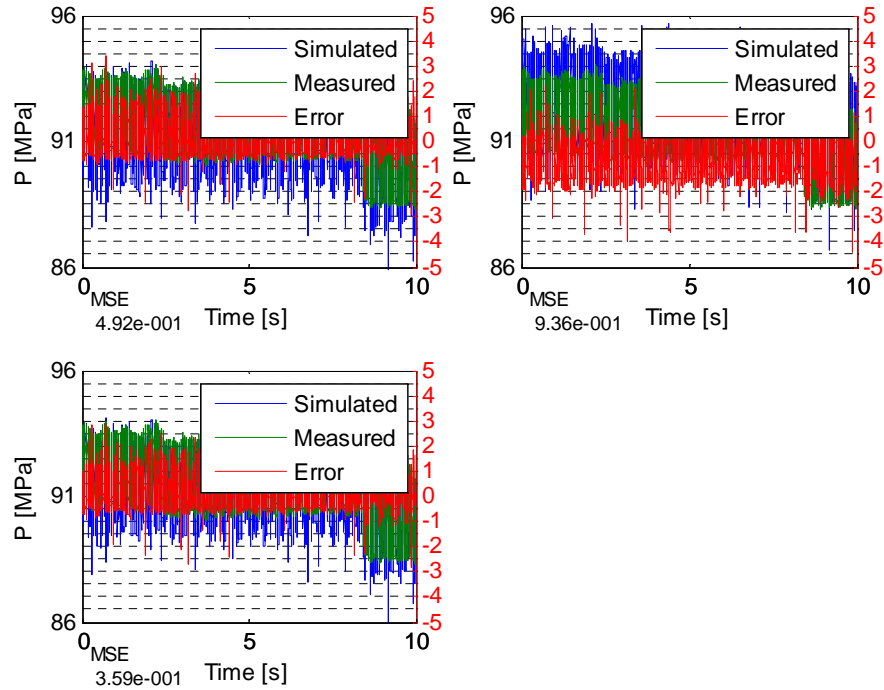


Figura 77. Indicele MSE pentru LM_3 , LM_6 și LM_7 evaluate la limita dreptunghiului asociat cu LM_9

După evaluarea tuturor indicilor de performanță, rezultă că cel mai slab indice de performanță, determinat conform formulei (74), corespunde perechii de modele asociate centrilor $c_{1,1}$ - $c_{1,3}$ pentru care avem $I_{MSE\ max} = (I_{c_{1,1},c_{1,3}} + I_{c_{1,3},c_{1,1}})/2 = (1.6 + 0.86)/2 = 1.23$.

Rezultă, ca necesară și posibilă, o nouă separare a spațiului pe axa P , prin introducerea unui nou punct de sprijin $\Lambda_{10}(0^\circ\text{C}, 90\text{MPa})$. Noul model se notează cu LM_{10} , iar configurația punctelor de sprijin din spațiului $S_{T,P}$ va arăta ca în fig.78.




Figura 78. Descompunerea spațiului intrărilor pe cele două axe T și P pentru a cincea iterație

6.1.6. Iterația a 5-a de sinteză a modelului de predicție

- **LM₁₀** – adaptat în jurul punctului de funcționare Λ_{10}

Experimentele efectuate pentru variații ale lui P și T în vecinătatea punctului Λ_{10} au condus la rezultatele din Fig. 79, iar pentru momentul final $t = 20$ s, la valorile celor 12 coeficienți ai LM₁₀ din Tabelul XII. În Fig. 80 este redată variația erorilor de predicție din cursul ultimelor 10 s ale experimentului.




Figura 79. Evoluția coeficienților LM_{10} pe durata secvenței de antrenare

TABEL XII. COEFICIENȚII MODELULUI LM_{10} ASOCIAT NEURONULUI 10

Faza j a sistemului	Debitele masice (Q_{INJ}^m)	Coeficienții $LLM_{10,j}$	
		$w^1_{10,j,l}$	$w^2_{10,j,l}$
0	$Q_{INJ}^m 0$	-2.8892	-0.0088
1	$Q_{INJ}^m 1$	-3.2482	0.0067
2	$Q_{INJ}^m 2$	-3.2742	0.0051
3	$Q_{INJ}^m 3$	-3.2243	0.0018
4	$Q_{HPP}^m 1$	2.3139	0.1438
5	$Q_{HPP}^m 2$	2.3053	0.1167




Figura 80. Rezultatul validării pentru LM_{12} în jurul punctului de funcționare Λ_{10}

La finalul secvenței de adaptare se observă convergența coeficienților, iar în cursul validării o valoare medie a indicelui de performanță de $4.30 \cdot 10^{-1}$.

- **A 7-a descompunere a spațiului $\Lambda(P,T)$**

LM_{10} este evaluat în centrele vecine $c_{1,1}$, $c_{1,3}$ și $c_{2,2}$. În fig. 81 este explicat modul de evaluare. Graficele din fig. 82 prezintă valorile medii ale indicilor de performanță pe intervalul de evaluare. În mod similar, LM-urile punctelor de sprijin vecine cu noul punct de sprijin (fig.83), LM_3 , LM_6 și LM_8 , sunt evaluate în vecinătatea punctului de sprijin Λ_{10} . Fig. 84, prezintă variația erorilor de predicție și valorile medii ale indicilor de performanță pe intervalul de evaluare.




Figura 81. Evaluarea modelului adaptat LM_{10} în vederea unei noi partiționări

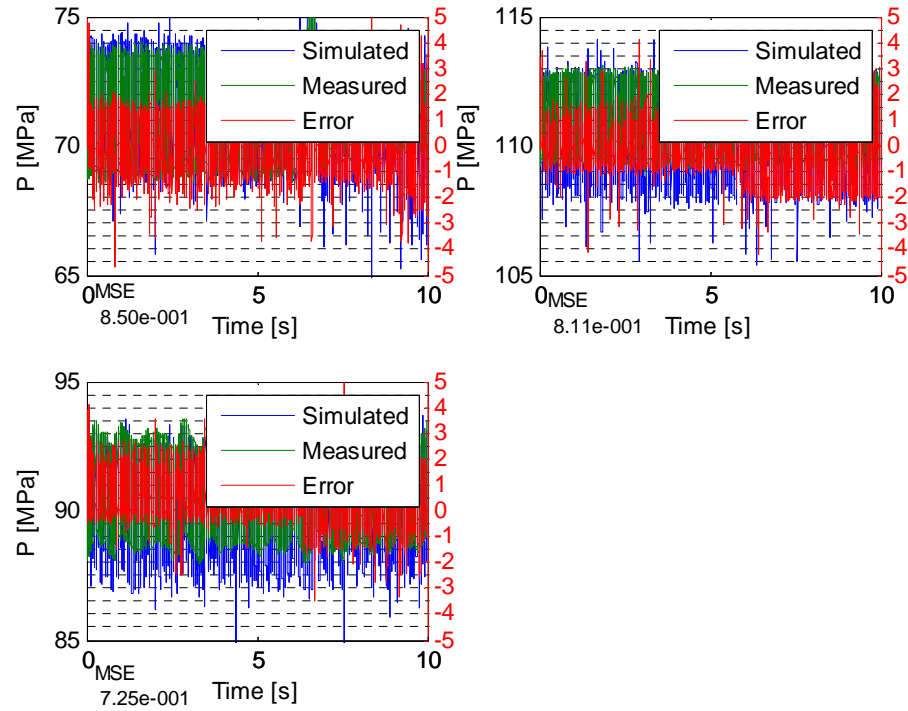


Figura 82. Indicele MSE pentru modelul LM_{10} evaluat la limitele dreptunghiului asociat (sus: $\Lambda(0^\circ\text{C}, 70\text{MPa})$, $\Lambda(0^\circ\text{C}, 110\text{MPa})$, jos: $\Lambda(20^\circ\text{C}, 90\text{MPa})$)




Figura 83. Evaluarea modelelor deja adaptate LM_3 , LM_6 și LM_8 în vecinătatea punctului Λ_{10}

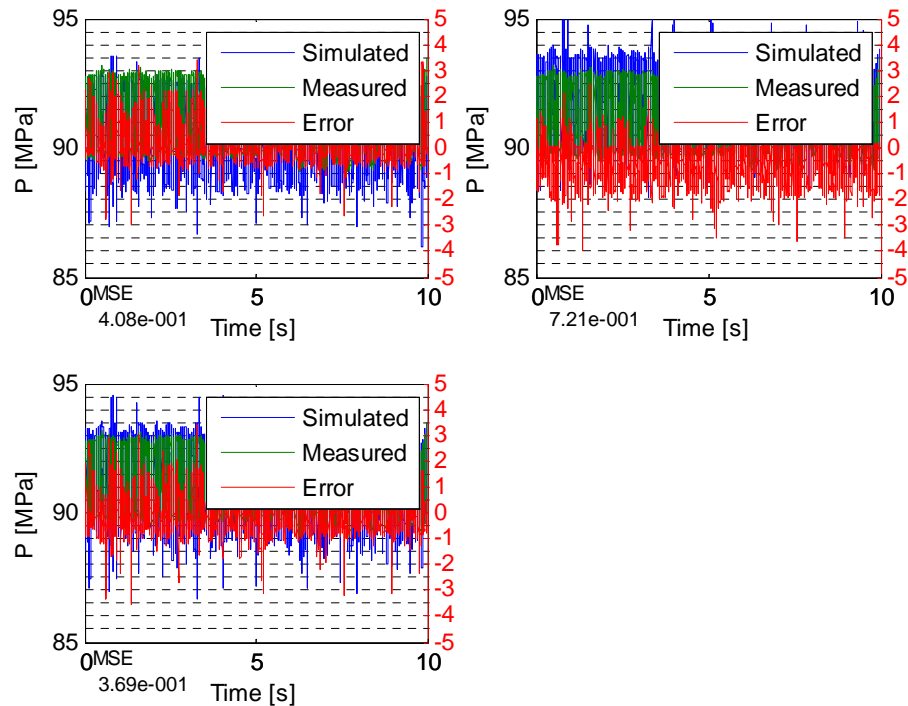


Figura 84. Indicele MSE pentru LM_3 , LM_6 și LM_8 evaluate la limita dreptunghiului asociat cu LM_{10}

După evaluarea tuturor indicilor de performanță, cea mai mare valoare, determinată conform formulei (74), corespunde centrului $c_{3,4}$ pentru care avem $I_{MSE_{max}} = (I_{C2,4,C3,4} + I_{C3,3,C3,4})/2 = 1.08$.

Rezultă o nouă separare a spațiului pe ambele axe prin introducerea unui nou punct de sprijin $\Lambda_{11} = \Lambda(40^\circ\text{C}, 130\text{MPa})$, situat la limita superioară a celor două axe. Noul model se notează cu LM_{11} , iar configurația punctelor de sprijin din spațiul $S_{T,P}$ va arăta ca în fig. 85.




Figura 85. Descompunerea spațiului intrărilor pe axele T și P pentru a șasea iterație

6.1.7. Iterația a 6-a de sinteză a modelului de predicție

- **LM₁₁** – adaptat în jurul punctului de funcționare Λ_{11}

Experimentele efectuate pentru variații ale lui P și T în vecinătatea punctului Λ_{11} au condus la rezultatele din fig. 86, iar pentru momentul final $t = 20$ s, la valorile celor 12 coeficienți ai LM₁₁ din Tabelul XIII. În fig. 87 este redată variația erorilor de predicție din cursul ultimelor 10 s ale experimentului.




Figura 86. Evoluția coeficienților LM_{11} pe durata secvenței de antrenare

TABEL XIII. COEFICIENȚII MODELULUI LM_{11} ASOCIAT NEURONULUI 11

Faza j a sistemului	Debitele masice (Q_{\bullet}^m)	Coeficienții $LLM_{11,j}$	
		$w^1_{11,j,l}$	$w^2_{11,j,l}$
0	$Q_{INJ}^m 0$	-3.117	-0.0097
1	$Q_{INJ}^m 1$	-2.8719	-0.0103
2	$Q_{INJ}^m 2$	-3.0542	-0.0101
3	$Q_{INJ}^m 3$	-2.9456	-0.0101
4	$Q_{HPP}^m 1$	3.0635	-0.0244
5	$Q_{HPP}^m 2$	2.8687	0.0507




Figura 87. Rezultatul validării pentru LM_{11} în jurul punctului de funcționare Λ_{11}

La finalul secvenței de adaptare se observă convergența coeficienților, iar în cursul validării o valoare medie a indicelui de performanță de $4.30 \cdot 10^{-1}$.

- **A 7-a descompunere a spațiului $\Lambda(P,T)$**

LM_{11} este evaluat în centrele vecine $c_{2,4}$ și $c_{3,3}$. În fig. 88 este explicat modul de evaluare păstrându-se convenția notațiilor stabilită în preambulul paragrafului. Graficele din fig. 89 prezintă variația erorilor de predicție și valorile medii ale indicilor de performanță pe intervalul de evaluare.




Figura 88. Evaluarea modelului LM_{11} adaptat în vederea unei noi partiționări

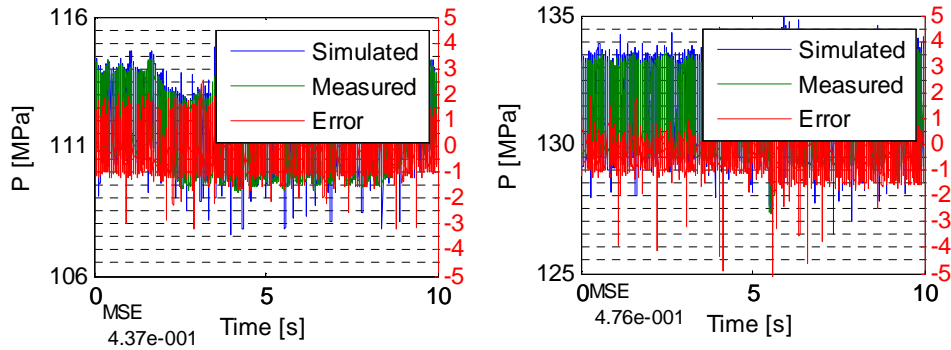


Figura 89. Indicele MSE pentru modelul LM_{11} evaluat la limitele dreptunghiului asociat (sus: $\Lambda(40^{\circ}\text{C}, 110\text{MPa})$, jos: $\Lambda(20^{\circ}\text{C}, 130\text{MPa})$)




Figura 90. Evaluarea modelelor deja adaptate LM_3 și LM_4 în vecinătatea punctului Λ_{11}




Figura 91. Indicele MSE pentru LM_3 , LM_4 evaluate la limita dreptunghiului asociat LM_{11}

În urma evaluării tuturor indicilor de performanță, cel mai slab indice de performanță, determinat conform formulei (74), corespunde centrului $c_{1,4}$ pentru care avem $I_{MSE\ max} = (I_{C_{2,4},C_{1,4}} + I_{C_{1,3},C_{1,4}})/2 = 0.992$. Rezultă o nouă separare a spațiului pe ambele axe, prin introducerea un nou punct de sprijin la limita

superioară a axei P și limita inferioară a axei T : $\Lambda_{14} = \Lambda(0^\circ\text{C}, 130\text{MPa})$. Noul model se notează cu LM_{12} , iar configurația punctelor de sprijin din spațiului $S_{T,P}$ va arăta ca în fig. 92.




Figura 92. Descompunerea spațiului intrărilor pe axele T și P pentru a șaptea iterație

6.1.8. Iterația a 7-a de sinteză a modelului de predicție

- **LM₁₂** – adaptat în jurul punctului de funcționare $\Lambda_{12}(0^\circ\text{C}, 130\text{MPa})$

Rezultatele experimentelor efectuate pentru variații ale lui P și T în vecinătatea punctului Λ_{12} sunt date în fig. 93. Pentru momentul final $t = 20$ s, cei 12 coeficienți ai LM_{12} iau valorile din Tabelul XIV. În fig. 94 este redată variația erorilor de predicție din cursul ultimelor 10 s ale experimentului.




Figura 93. Evoluția coeficienților LM_{12} pe durata secvenței de antrenare

TABEL XIV. COEFICIENȚII MODELULUI LM_{12} ASOCIAT NEURONULUI 12

Faza j a sistemului	Debitele masice (Q_a^m)	Coeficienții $LLM_{12,i}$	
		$w^1_{12,j,l}$	$w^2_{12,j,l}$
0	$Q_{INJ}^m 0$	-3.2542	-0.0096
1	$Q_{INJ}^m 1$	-3.7964	-0.0078
2	$Q_{INJ}^m 2$	-4.1235	-0.0053
3	$Q_{INJ}^m 3$	-3.7546	-0.049
4	$Q_{HPP}^m 1$	2.8241	-0.0584
5	$Q_{HPP}^m 2$	2.7069	0.0037




Figura 94. Rezultatul validării pentru LM_{12} în jurul punctului de funcționare Λ_{12}

Ajungând, pe de-o parte, la un număr de 12 LM adaptate, iar pe de altă parte, observând că toate modelele au $I_{MSE} < 1$, rezultă că ambele criterii de oprire a algoritmului sunt îndeplinite. Ca urmare, operațiunile de partiționare a spațiului intrărilor și de sinteză a modelului de predicție sunt încheiate. Coeficienții LM-urilor reținuți în final sunt dați în tabelele III – XIV.

6.2. Validarea modelului de predicție a presiunii în sistemul PCR

După ce a fost identificat, modelul de predicție a presiunii în CR a fost supus unor experimente de regim dinamic finale, în vederea evaluării performanțelor sale și a validării ansamblului.

Procedural, experimentele finale nu aduc nimic nou în comparație cu experimentele care au însoțit operațiile din paragraful 6.1. Procesul de adaptare desfășurându-se pe tot parcursul experimentelor de validare, pentru evaluarea performanțelor s-au utilizat atât înregistrări ca cele din fig. 94, însă cu privire la toate cele 12 LM-uri, cât și înregistrări care au condus la variațiile din fig. 94 și 95.

Neaducând elemente noi metodologice și valorice, prima categorie de înregistrări nu mai este redată în continuare. Valorile medii ale indicelui de performanță au variat în domeniul $[4.30 \cdot 10^{-1}, 7.71 \cdot 10^{-1}]$.

În figurile 95 și 96 sunt prezentate comparativ presiunea măsurată în CR cu recurența de 1 ms (verde), presiunea medie pe segmentul anterior $j-1$ (albastru), calculată la momentul t_{SEGj} , ce corespunde utilizată actualmente în calcule (v. fig. 4) și presiunea predictată de model (roșu) la momentul t_{SEGj} pentru intervalul $[t_{SEGj}, 0.5(t_{SOIj+1} + t_{EOIj+1})]$. Sistemul de presiune este controlat în buclă închisă astfel că în fig. 95 avem răspunsul sistemului la o treaptă în referința de presiune de 20 MPa iar în fig. 96 avem răspunsul sistemului la o treaptă în referința de presiune de -10 MPa. Scopul acestui experiment este de a oferi o apreciere calitativă asupra performanțelor modelului de predicție a presiunii în CR pentru o tranziție ascendentă respectiv descendentă a presiunii.

Figura 96 permite compararea situației actuale cu cea propusă de autor. În acest scop se consideră tripletele de puncte: (A_1, A_2, A) , (B_1, B_2, B) , (C_1, C_2, C) și (D_1, D_2, D) . Ideea este următoarea: la momentul în care se realizează injecția,




Figura 95. Variația presiunii măsurate (1 ms), a valorii medii pe segmentul anterior cu care se lucrează în prezent și a valorii furnizate de modelul de predicție pentru o treaptă ascendentă de presiune




Figura 96. Variația presiunii măsurate (1 ms), a valorii medii pe segmentul anterior cu care se lucrează în prezent și a valorii furnizate de modelul de predicție pentru o treaptă descendentă de presiune

presiunea are valoarea din punctul A și soluția curentă folosește pentru calculul parametrilor de injecție valoarea presiunii din punctul A₁. În cazul soluției propuse în teză, se folosește valoarea ce corespunde lui A₂ care este mult mai apropiată de valoarea reală a presiunii. Idem, pentru B, C și D.

Din analiza celor două înregistrări¹⁵ se desprind următoarele constatări care validează modelul:

- Răspunsul dinamic al modelului de predicție (roșu punctat) este apropiat de valorile măsurate (la 1 ms) ale presiunii P (verde).
- Diferențele momentane între răspunsul dinamic al modelului de predicție și valorile măsurate ale presiunii P, comparativ cu diferențele dintre valoarea lui P mediată pe intervalul de timp aferent segmentului anterior (albastru) și valorile momentane măsurate, sunt mult mai mici. Ca urmare, valoarea predictată este mult mai apropiată de valoarea reală a presiunii de la momentul realizării injecției.

6.3. Restructurarea modelului experimental

Fig. 92 conține grila carteziană finală de compartimentare a domeniului S_{T,P}. Din perspectiva metodei RIP (Rule based InterPolation) [57, 66] celor trei valori de temperatură din grilă le putem asocia valorile lingvistice: *joasă* (0 °C), *medie* (20 °C) și *ridicată* (40 °C), iar celor 4 valori de presiune valorile lingvistice: *joasă* (70 Mpa), *moderată* (90 Mpa), *medie* (110 Mpa) și *ridicată* (130 Mpa)¹⁶. Din perspectiva metodei fuzzy aceluiași valori lingvistice le corespund funcții de apartenență de tipul celor din Fig. 22, date de relațiile (68) și utilizate conform explicațiilor date pentru Fig. 28. Indiferent care ar fi perspectiva de abordare, modelul experimental dezvoltat în paragraful 6.1. poate fi redat sub forma bazei de reguli din Tabelul XV care asociază celor 12 perechi de valori lingvistice câte un model local LM_i. Tabelul XV poate fi interpretat și ca o reprezentare condensată a LM-urilor de pe nivelul 1 al arhitecturii neuro-fuzzy considerate inițial.

TABEL XV. BAZA DE REGULI ASOCIATĂ MODELULUI EXPERIMENTAL

		LM			
Temperatură joasă		LM ₈	LM ₁₀	LM ₃	LM ₁₂
Temperatură medie		LM ₂	LM ₆	LM ₁	LM ₅
Temperatură ridicată		LM ₇	LM ₉	LM ₄	LM ₁₁
T	P	Presiune joasă	Presiune moderată	Presiune medie	Presiune ridicată

¹⁵ În teză au fost reținute, din numeroasele experimentări făcute, doar cele din fig. 95 și 96, suficiente pentru validarea modelului.

¹⁶ În cazul metodei RIP există multiple posibilități de asociere a valorilor lingvistice. Cea menționată corespunde unor asocieri de tip singleton. La fel de bine, valorile menționate pot fi asociate unor intervale concatenate, în lungul axelor T și P, care includ câte unul dintre punctele date.

Fiecare dintre LM-urile din tabelul XV este descris prin 6 relații în care intervin 12 coeficienți $w_{i,j,l}^1$ și $w_{i,j,l}^2$, $j = 0, 1, \dots, 5$. Ca urmare, tabelul XV poate fi defalcat pe 12 tabele, câte unul pentru fiecare coeficient, reprezentând baze de reguli de tip RIP.

Ca exemplu se consideră tabelul XVI corespunzător coeficientului $w_{i,4,1}^1$, și tabelul XVII corespunzător coeficientului $w_{i,4,1}^2$. Datele au fost extrase din tabelele III – XIV.

TABEL XVI. BAZA DE REGULI ASOCIATĂ MODELULUI EXPERIMENTAL

		$w_{i,4,1}^1$			
Temperatură joasă		1.59857	2.313914	2.388336	2.823641
Temperatură medie		1.975175	2.370694	2.489594	2.903594
Temperatură ridicată		2.545424	2.954728	3.007494	3.062723
T	P	Presiune joasă	Presiune moderată	Presiune medie	Presiune ridicată

TABEL XVII. BAZA DE REGULI ASOCIATĂ MODELULUI EXPERIMENTAL

		$w_{i,4,1}^2$			
Temperatură joasă		0.0644	0.1438	0.073	-0.0584
Temperatură medie		0.0454	0.0969	0.0152	0.0893
Temperatură ridicată		0.0084	0.0144	0.0596	-0.0244
T	P	Presiune joasă	Presiune moderată	Presiune medie	Presiune ridicată

Comparând datele din cele două tabele se observă că în valoare absolută valorile $w_{i,4,1}^1$ sunt mai mari decât valorile $w_{i,4,1}^2$ (cel puțin cu un ordin de mărime). Constatarea este generală: valorile $w_{i,j,l}^1$ sunt, în valoare absolută, considerabil mai mari decât valorile $w_{i,j,l}^2$. Ca urmare, având în vedere că valorile $\tilde{x}_j(k-1)$ și $\tilde{x}_j(k-2)$ sunt comparabile, în formulele (67) primul termen este dominant.

Întregul model experimental poate fi privit ca un ansamblu de 6 formule de tipul (67) cu coeficienții extrași din tabele de forma XVI și XVII. Datele din aceste tabele se modifică în permanență, odată la 10 ms datorită procesului de adaptare care se derulează continuu, iar la fiecare 1 ms (pas de discretizare) se realizează o predicție a gradientului de presiune ΔP folosind date dintr-o pereche de tabele.

Restructurarea menționată în titlu se referă la faptul că fiecare tabel poate fi considerat ca reprezentând punctele de sprijin ale unor funcții $w_{i,\bullet,l}^1(T, P)$ și

$w_{i,\bullet,l}^2(T,p)$ generabile prin interpolare. În cazul interpolării biliniare, suprafețele generate pentru coeficienții termenilor dominanți au aspectul din figurile 97 – 102 (hărți de interpolare).




Figura 97. Variația coeficientului $w_{i,4,1}^1$ pe domeniul de intrare S_{TP} . (Reprezentarea grafică a valorilor coeficientului 1 al LLM corespunzător pistonului 1 al pompei. V. tabelul XVI.)




Figura 98. Variația coeficientului $w_{i,5,1}^1$ pe domeniul de intrare S_{TP} . (Reprezentarea grafică a valorilor coeficientului 1 al LLM corespunzător pistonului 2 al pompei)




Figura 99. Variația coeficientului $w_{i,0,2}^1$ pe domeniul de intrare S_{TP} . (Reprezentarea grafică a valorilor asociate coeficientului 1 al LLM corespunzător injectorului 1)




Figura 100. Variația coeficientului $w_{i,1,2}^1$ pe domeniul de intrare S_{TP} . (Reprezentarea grafică a valorilor asociate coeficientului 1 al LLM corespunzător injectorului 2)




Figura 101. Variația coeficientului $w_{1,2,2}^1$ pe domeniul de intrare S_{TP} . (Reprezentarea grafică a valorilor asociate coeficientului 1 al LLM corespunzător injectorului 3)




Figura 102. Variația coeficientului $w_{1,3,2}^1$ pe domeniul de intrare S_{TP} . (Reprezentarea grafică a valorilor asociate coeficientului 1 al LLM corespunzător injectorului 4)

Identificarea modelelor de tip interpolativ $w_{i,\bullet,l}^1(T,P)$ și $w_{i,\bullet,l}^2(T,P)$ permite o altă organizare a calculelor de predicție decât cea prezentată în capitolul 5, folosind în locul celor 144 de interpolatoare biliniare organizate pe ochiuri de rețea definite prin 4 puncte de sprijin un număr de 12 interpolare definite pe câte 12 puncte de sprijin. Adaptarea valorilor de sprijin (coeficienții w) va fi însă aceeași în cele două abordări.

Analizând suprafețele din figurile 97 - 102 se constată că valorile coeficienților $w_{i,j,l}^1$ ai modelelor LLM prezintă variații pronunțate și nemonotone. Prin secționarea suprafețelor pentru diferite niveluri de temperatură se obțin caracteristicile $w_{i,j,l}^1(P)$ de parametru $T = 0^\circ\text{C}$, 20°C și 40°C reprezentate în figurile 103 - 108, asociate debitelor masice ale pistoanelor pompei respectiv ale injectoarelor.




Figura 103. Caracteristicile coeficientului $w_{i,4,l}^1(P)$, $T = \text{const.}$ (coeficientul 1 al LLM corespunzător pistonului 1 al pompei)




Figura 104. Caracteristicile coeficientului $w_{i,5,1}^1(P)$, $T = const.$ (coeficientul 1 al LLM corespunzător pistonului 2 al pompei)




Figura 105. Caracteristicile coeficientului $w_{i,0,2}^1(P)$, $T = const.$ (coeficientul 1 al LLM corespunzător injectorului 1)




Figura 106. Caracteristicile coeficientului $w_{i,1,2}^1(P), T = const.$ (coeficientul 1 al LLM corespunzător injectorului 2)




Figura 107. Caracteristicile coeficientului $w_{i,2,2}^1(P), T = const.$ (coeficientul 1 al LLM corespunzător injectorului 3)




Figura 108. Caracteristicile coeficientului $w_{i,3,2}^1(P)$, $T = const.$ (coeficientul 1 al LLM corespunzător injectorului 4)

Dacă graficele coeficienților LLM asociate pistoanelor pompei urmăresc oarecum caracteristica din figura 13, nu același lucru îl putem spune despre graficele coeficienților LLM asociați injectoarelor.

În consecință, putem afirma faptul că dinamica presiunii în sistemul PCR are un comportament puternic neliniar ce nu poate fi modelat doar pe baza ecuațiilor fizice ale procesului.

*

*

*

Ca o concluzie finală, putem afirma că, arhitectura bazată pe rețele neuro-fuzzy are capacitatea de a partiționa pe primul nivel spațiul de operare al sistemului $\Lambda(T,P)$, iar pe al doilea nivel poate modela, folosind modele liniare, dinamica presiunii în funcție de debitele masice. Rezultatele obținute confirmă potențialul modelului de a permite în timp real atât realizarea adaptării cât și predicția presiunii în sistemul PCR.

7 CONCLUZII, CONTRIBUȚII ȘI PERSPECTIVE

7.1. Concluzii

Teza de doctorat are ca principal rezultat dezvoltarea unui tip de model neuro-fuzzy implementat în variantă interpolativă, destinat predicției variației de presiune din rampa comună a unui motor diesel. Demersul este întreprins în trei etape:

- fundamentare sintetică fenomenologică (capitolul 2) și teoretică (capitolul 3),
- dezvoltare metodologică (capitolul 4) și aplicativă (capitolul 5),
- exemplificare și validare (capitolul 6).

Implementarea modelului de predicție în variantă interpolativă, avantajoasă din punctul de vedere al resurselor necesare pentru o implementare on-line, a fost posibilă ca urmare a modificării, față de varianta LOLIMOT consacrată, a formei funcțiilor de apartenență asociate modelelor locale, prin înlocuirea celor de tip gaussian cu funcții de apartenență triunghiulare. Pe baza rezultatului obținut se poate afirma că modelul reprezentat este performant și că posedă două caracteristici importante: poate îngloba ușor cunoștințele apriorice despre sistem oferind interpretabilitate proceselor studiate, și poate fi implementat cu ușurință pentru calcule de timp real folosind tabele de interpolare.

Implementarea include și adaptarea permanentă, în timp real, a coeficienților modelelor liniarizate local folosind mărimi măsurate din sistem. Adaptarea se bazează pe metoda celor mai mici pătrate recursivă, aplicabilă în acest caz datorită caracterului ergodic al procesului studiat și a liniarității modelor în raport cu coeficienții utilizați. Prin predictarea valorilor variației de presiune se crează premise pentru adaptarea on-line a timpilor de injecție la diferitele regimuri de funcționare a sistemului de injecție, cu efecte economice și de mediu benefice.

Cercetarea care face obiectul acestei teze de doctorat a fost, până în prezent, valorificată prin publicații, doar parțial, prin următoarele 4 lucrări apărute în cadrul unei reviste și a unei conferințe din circuitul ISI, respectiv al unor conferințe internaționale cu vizibilitate IEEE:

- Ioanas, G.L., „Modeling, Identification and Prediction of Inherent quasi-stationary Pressure Dynamics of a Common-Rail System using Neuro-Fuzzy Structures with Local Linear ARX models”, *Control Engineering and Applied Informatics Journal*, Bucuresti, Romania, Vol. 14, no.3, pp. 61-70, 2012.
- Ioanas, G.L., Dragomir, T.L., „Common-rail Pressure Estimation using a Neuro-Fuzzy architecture with Local Hammerstein Models”, *Proc. of SACII 2013, IEEE 8th International Symposium on Applied Computational Intelligence and Informatics*, Timișoara, pp. 281-286, 2013.

- Ioanas, G.L., Dragomir, T.L., „Local linear models adaptation for a 4 Inj – 2PP Commonrail Pressure System”, IEEE 11th International Symposium on Intelligent Systems and Informatics, SISY 2013, Subotica, pp. 253-258, 2013.
- Ioanas, G.L., Dragomir, T.L., „Dynamic models adaptation for a 4 Inj – 2PP Commonrail Pressure System”, 39th Annual Conference of the IEEE Industrial Electronics Society IECON 2013, Viena, pp. 3490 – 3495, 2013.

Lucrărilor de mai sus li se mai adauga încă două lucrări comunicate, menționate în bibliografie la nr. [88] și [89] și două referate de cercetare prezentate în cadrul Departamentului de Automatică și Informatică Aplicată de la Universitatea „Politehnica” din Timișoara.

7.2. Contribuții

În plan aplicativ, practic, teza de doctorat sintetizează următoarele contribuții personale:

- Sinteza modelului unei structuri de predictor neuro-fuzzy cu modele locale liniare pentru calculul variației presiunii din rampa comună (CR) a unui sistem de injecție cu 4 injectoare. Modelul, ca sistem dinamic, include atât o structură de identificare adaptivă a coeficienților bazată pe metoda RLS, cât și predictorul propriu-zis. Metodologia de modelare este reproductibilă.
- Implementarea structurii pe un sistem de timp real cu un microprocesor de tip Tricore deservit de un sistem de operare OSEK –VDA.
- Validarea structurii de predictor implementate pe o plajă largă a punctelor de funcționare, folosind un stand de experimentare adecvat.

În plan științific și teoretic, teza de doctorat sintetizează următoarele contribuții personale:

- Determinarea unui model analitic debit – presiune pentru sistemul PCR.
- Aplicarea teoriei modelelor neuro-fuzzy pentru realizarea predicției variației de presiune din rampa comună pe un interval de timp prestabilit în funcție de debitele masice ale principalelor componente.
- Evaluarea critică și constructivă a soluției teoretice de mai sus și elaborarea unei noi soluții pragmatice, specifice proceselor din rampa comună, caracterizată de următoarele aspecte, toate fundamentate teoretic pe parcursul lucrării:
 - structurarea modelelor din interiorul neuronilor în funcție de evenimentele hidraulice care au loc în rampa comună
 - modificarea funcțiilor de apartenență de la nivelul neuronilor sub o formă care a permis reorganizarea ansamblului calculelor de o manieră care să permită interpolarea biliniară cu păstrarea metodei de calcul adaptiv a coeficienților;

- Încadrarea rezultatului final în conceptul de interpolare bazată pe reguli (RIP)
- Reformularea algoritmului de partiționare a spațiului intrărilor bazat pe conceptul general LOLIMOT în acord cu restructurările introduse și cu conceptul de punct de sprijin asociat teoriei interpolării. Algoritmul eficientizează modul de lucru, de o manieră inginerescă, și reduce numărul de încercări experimentale ale sistemului, în diverse puncte de funcționare, necesare dezvoltării modelului de predicție.
- Utilizarea unui algoritm de adaptare robust bazat pe metoda RLS capabil să rejeteze zgomotul de măsură și să prezinte insensibilitate în cazul semnalelor cu excitație slabă.

7.3. Perspective

Rezumându-ne numai la perspective de factură practică considerăm că:

- Modelul de predicție a variației presiunii în common-rail, dezvoltat și implementat în cadrul tezei, împreună cu metodologiile dezvoltate, poate fi adaptat pentru a fi testat în diverse condiții industriale de către marii producători auto.
- Încadrarea modelului de predicție în clasa modelelor cu interpolare bazată pe reguli (RIP) se poate realiza, prin exploatarea adecvată a suportului teoretic și metodologic din teză, cu simplificări semnificative, relativ ermetice, ale metodologiei de dezvoltare a modelului de predicție.

ANEXA 1

SISTEMUL COMMON-RAIL CU PIEZO-INJECTOARE

În continuare este prezentat sistemul cu care s-a lucrat și componentele sale.

Prezentarea sistemului Common – rail cu piezo-injectoare (PCR) de generație nouă

Sistemul PCR [85] (fig. A1-1) este format din HPP, CR, INJ și țevile de legătură. Comanda sistemului se realizează de către unitatea de calcul ECU.



Figura A1-1. Sistemul hidraulic PCR de nouă generație (NG)

În fig. A1-2 [86] este reprezentat piezo-injectorul asociat cu acest tip de sistem common-rail. Caracteristica ce-l deosebește de celelalte tipuri de injectoare constă în comanda în curent a piezo-actuatorului ce acționează apoi direct (direct drive) asupra acului injectorului.



Figura A1-2. Injector PCR NG cu „direct drive”

Caracteristicile pompei de înaltă presiune (HPP)

Pompa de înaltă presiune folosită în experimente are 2 cilindri fiecare cu o capacitate de 0.8 cm³/rot. În figura A1-3 este prezentată pompa de înaltă presiune în secțiune laterală [87]:




Figura A1-3. Pompa de înaltă presiune radială cu două pistoane. 1-Ax rotație; 2-Cama dublă; 3-Piston; 4-Carcasa de aluminiu; 5-Ventil admisie; 6-Element acționare ventil; 7-Ventil distribuție; 8-Piesă etanșare; 9-Ieșirea de înaltă presiune către rampa comună; 10 Supapă presiune; 11-Electrovalva PCV cu bilă; 12-Ieșire către circuit retur; 13-Alimentare combustibil; 14-Supapă siguranță; 15-Circuit ungere internă

Specificații tehnice:

- Combustibil: Diesel DIN EN 590
- Conținutul de aer în combustibil: 5 bule la un volum de 0.14 mm³ / minut
- Presiunea la intrarea în pompă: 0,7...1.0 bar (valoare absolută)
- Presiunea de amorsare: max 2.5 bar pe perioada amorsării circuitului de joasă presiune (30 sec).
- Debitul la intrare: max 3400 cm³ /min
- Temperatura minim admisibilă la intrare: -25 °C
- Temperatura maxim admisibilă la intrare: 80 °C
- Presiunea maximă de retur: 1...1.8 bar (valoare absoluta la nivelul mării)
- Debitul pe retur: max 3400 cm³ /min
- Temperatura pe retur: max 120 °C
- Presiunea de operare maximă: 2000 bar
- Raportul de angrenare $N_{\text{pump}} / N_{\text{engine}} = 1/1$.

Electrovalva volumetrică (VCV)

VCV [87] este o electrovalvă volumetrică acționată electromagnetic, cu deschiderea proporțională cu curentul aplicat. Arcul are rolul de a o readuce în poziția neutră (închis complet).




Figura A1-4. Reprezentarea schematică a VCV (A – intrarea, B - ieșirea)

Electrovalva de presiune (PCV)

PCV [87] este o electrovalvă de reducere a presiunii acționată electromagnetic. Arcul are rolul de a o readuce în poziția neutră (deschis complet).




Figura A1-5. Reprezentarea schematică a PCV (P – presiunea de intrare)

Caracteristicile senzorului de presiune (HPS)

Sistemul de reglare a presiunii în CR (fig. 1), se bazează pe informația de presiune primită de la HPS [87] (fig. A1-6). Componenta furnizează către ECU o tensiune proporțională cu presiunea aplicată.



Figura A1-6. Senzorul de presiune (HPS)

Specificații tehnice:

- Tensiunea de operare: 4.75 ... 5.25 VDC (5 VDC nominal)
- Curentul de operare: 10 mA
- Temperatura de operare: -40...240 °C
- Presiunea de operare: 0... 2200 bar
- Domeniul de variație a tensiunii de ieșire: 0.5 – 5 V
- Presiunea maximă (momentană): 3000 bar
- Rezistența de sarcină: 5k Ω
- Sensitivitatea nominală: 2.222 mV/bar
- Greutate: 43 g

Factori de influență ai variației presiunii în CR

Pentru a stabili variabilele cu care operează modelul de predicție a variației de presiune s-a procedat la o analiză detaliată a factorilor de influență a acesteia. Rezultatul este sintetizat în diagrama *fish-bone* din fig. A1-7:

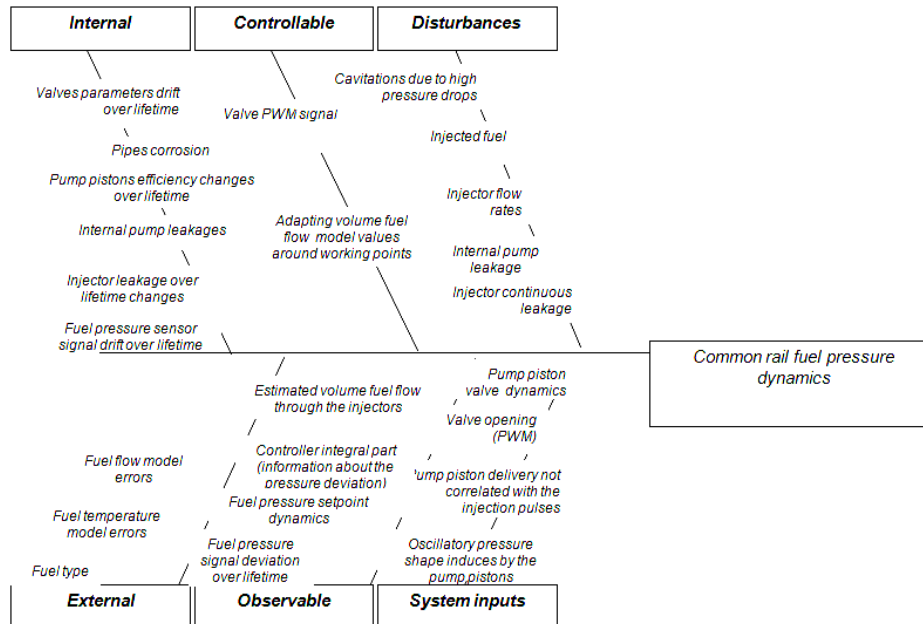


Figura A1-7. Diagrama fish-bone pentru factorii de influență ai variației presiunii în CR [88].

În concordanță cu diagrama din figură, au fost realizate un număr important de experimente pe standul din figura 33 precum și o bogată documentare bibliografică [15] - [31]. Principalele concluzii desprinse în urma studiului experimental premergător, a cărui prezentare nu face obiectul tezei de doctorat, au fost următoarele:

- Mărimile de intrare (mărimi cauza) asociate procesului complex, care induc în CR variații de presiune, sunt de două categorii: mărimi de intrare utile și mărimi perturbatoare.
- Mărimile de intrare utile se înscriu într-o bandă de frecvență de până la 100 Hz ceea ce permite operarea cu un pas de discretizare a timpului de 1 ms. Coroborând observațiile experimentale cu mărimile care afectează variația de presiune (rel. (6) și (7)), rezultă că valorile lui T și P determină dinamica variației de presiune iar restul mărimilor „modulează” această dinamică. Ca urmare, pentru dezvoltarea modelului, s-a considerat un spațiu de lucru de coordonate (T,P) și variații ale punctului de funcționare cauzate de celelalte mărimi. Dependentele referitoare la restul mărimilor sunt cele menționate la sfârșitul paragrafului 2.3 respectiv prin relațiile (80).
- Mărimile perturbatoare de înaltă frecvență pot afecta valorile calculate pentru coeficienții modelului. Pentru a nu influența calculele, respectiv convergența operațiilor de adaptare, sunt necesare anumite tipuri de filtrări dintre care două sunt referite în cap. 5 (v. fig 34 și operațiile de mediere din relația (89)).

ANEXA 2

ARHITECTURA APLICATIEI SOFTWARE PENTRU MODELUL ADAPTIV DE PREDICȚIE A PRESIUNII ÎN CR

În figura A2 -1 este prezentată arhitectura aplicației software cu care s-a lucrat.

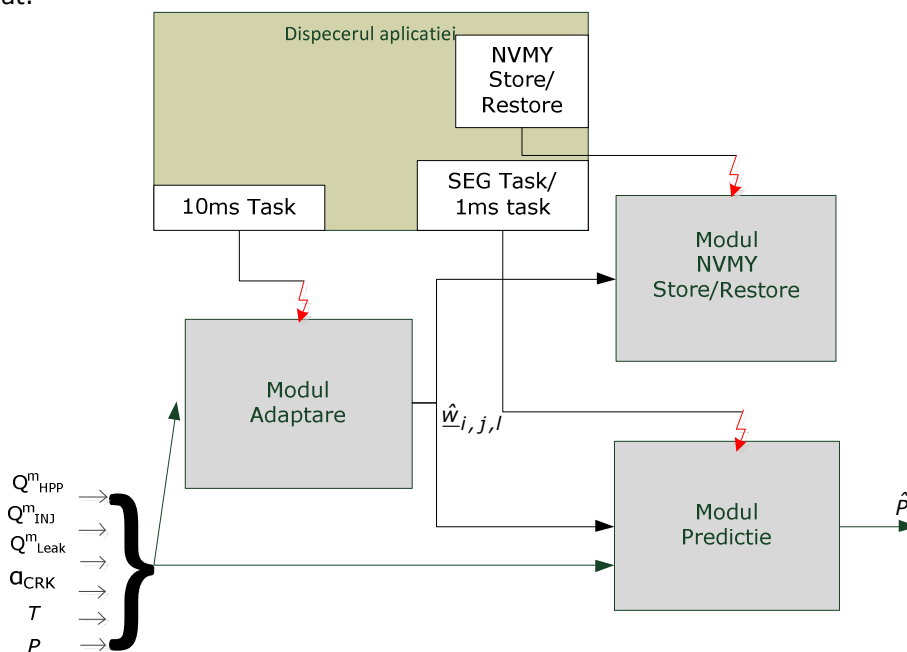


Figura A2-1. Arhitectura software a aplicației adaptive de predicție a presiunii în rampa comună (CR)

Blocul „Adaptation” implementează structura adaptivă din fig.35, iar blocul „Prediction” implementează modelul de predicție propus în fig.31. Blocul de memorare/redare „NVMY Store/Restore adapted coefficients” are rolul de a înregistra coeficienții adaptați după oprirea ECU și de a-i reda aplicației în momentul pornirii ECU. „Task”-urile „10ms”, „SEG” și „NVMY Store/Restore” sunt primite din partea sistemului de operare al ECU.

Dispecerul „Application Scheduler” are rolul de a apela funcțiile corespunzătoare „task”-ului asociat. Conform figurii 32, subsistemele „Adaptation” și „Prediction” includ bucle de calcul repetitiv (for loops) cu rol de parcurgere la fiecare apelare a „buffer”-elor circulare ce conțin date măsurate de la proces.

Hărțile de interpolare ce conțin valorile coeficienților adaptați și sunt interpolate corespunzător punctelor de operare ale sistemului, pot fi vizualizate *online* cu ajutorul aplicației INCA aparținând ETAS.

Aplicația a fost implementată pe sistemul de timp real folosind tehnica de prototipare rapidă iRPT cu ajutorul Matlab/Simulink 7.1 și ETAS eHooks.

BIBLIOGRAFIE

- [1] Hafner, M., Schuler, M. and Nelles, O., „Neural net models for diesel engines- simulation and exhaust optimization“, *Control Engineering Practice*, Vol. 30, No. 2, pp. 402-412, 2002.
- [2] R. Isermann O. Nelles, A. Fink, „Local linear model trees (lolimot) toolbox for nonlinear system identification“, 12th IFAC Symposium on System Identification, (SYSID), Santa Barbara, USA, 2000.
- [3] Jakubek S., Keuth N. „A local neuro-fuzzy network for high-dimensional models and optimization“. *Engineering Applications of Artificial Intelligence* 19 705–717, 2006.
- [4] Froehlich M., „Informationstheoretische Optimierung kunstlicher neuronaler Netze für den Einsatz in Steuergeräten“, *PhD thesis at Eberhard-Karls University of Tübingen*, 2003.
- [5] https://www.avl.com/c/document_library/get_file?uuid=56fe5fc4-3e6d-4f9e-93a9-dd419b026fea&groupId=10138. Accesat în 30.08.2013.
- [6] <http://www.dieselnet.com/standards/eu/ld.php>. Accesat în 30.08.2013.
- [7] http://www.dieselnet.com/standards/us/ld_ca.php. Accesat în 30.08.2013.
- [8] Bosch, R. GmbH, Diesel-Engine Management, 3rd edition, Automotive Technology, 2004.
- [9] Liu, Y, Zhang, Y., Qiu, T. *et al.* , „Optimization research for a high pressure common rail diesel engine based on simulation“, *International Journal of Automotive Technology*, Volume 11, Issue 5, pp 625-636, October 2010.
- [10] Ljung L., „System Identification: Theory for the user“, *Prentice Hall PTR*, 1999.
- [11] Johansen T. A., „Operating Regime based Process Modeling and Identification“, Dr. Ing. Thesis, *Norwegian Institute of Technology-NTH*, Trondheim, 1994.
- [12] Sbarbaro D., Murray-Smith R., „Self-Tuning Control of Nonlinear Systems Using Gaussian Process Prior Models“, *Springer-Verlag Berlin Heidelberg, LNCS 3355*, pp. 140-157, 2005
- [13] Abonyi J., Babuska R., Verbruggen H. B., Szeifert F., „Incorporating Prior Knowledge in Fuzzy Model Identification“, *International Journal of Systems Science*, Vol. 31, No. 5, pp. 657-667(11), 1 May 2000.
- [14] Murray-Smith R., „A Local Model Network Approach to Nonlinear Modelling“, *PhD Thesis, University of Strathclyde*, November 1994.
- [15] Continental Automotive GmbH, LI, Hui, „Superimposed Pressure of the Common rail System“, WO/2009/ 132898, 05.11.2009.

-
- [16] Continental Automotive GmbH, Adler, Ch., Jung, U. *et al*: "Kraftstoffdruckregelsystem", DE102007060006B3 09.07.2009
- [17] Borchsenius, F., Stegemann, D., Gebhardt, X. *et al.*, "Simulation of diesel common rail injection systems", *MTZ worldwide*, Volume 71, Issue 6, pp 42-45, 2010.
- [18] Catania A. E., Ferrari A., Manno M., "Development and Application of a Complete Multijet Common-Rail Injection-System Mathematical Model for Hydrodynamic Analysis and Diagnostics", *Transactions-Asme Journal of Engineering for Gas Turbines and Power*; 130, 6; 062809, American Society of Mechanical Engineers, 2008.
- [19] Catania A. E., Ferrari A., Spessa E., "Numerical-Experimental Study and Solutions to Reduce The Dwell Time Threshold for Fusion-Free Consecutive Injections in a Multijet Solenoid-Type CR System ^{1st}", *Journal of Engineering for Gas Turbines and Power*, Vol. 131, Issue 2, Dec 2008.
- [20] Catania A. E., Ferrari A., Manno M., Spessa E., "Experimental Investigation of Dynamics Effects on Multiple-Injection Common Rail System Performance", *Journal of Engineering for Gas Turbines and Power-transactions of The Asme* 01/2008.
- [21] Wang T. C., Schwarz E., Bryzik W., Han J. S., Xie X. B., Lai M. C., Henein N. A., "Parametric Characterization of High-Pressure Diesel Fuel Injection Systems", *Journal of Engineering for Gas Turbines and Power*, Vol. 125, Issue 2, Apr 29, 2003.
- [22] Baratta M., Catania A. E., Ferrari A., "Hydraulic Circuit Design Rules to remove the Dependence of the Injected Fuel Amount on Dwell Time in Multijet CR Systems", *Journal of Fluids Engineering*, Vol. 130, Issue 12, 27 Oct 2008.
- [23] Gauthier C., Sename O., Dugard L., Meissonnier G., "Modelling of a Diesel Engine Common Rail Injection System", *Proceedings of the 16th IFAC World Congress*, Vol. 16, Part 1, Czech Republic, 2005.
- [24] **Ioanas, G.L.**, Dragomir, T.L., "Common-rail Pressure Estimation using a Neuro- Fuzzy architecture with Local Hammerstein Models", *Proc. of SACII 2013, IEEE 8th International Symposium on Applied Computational Intelligence and Informatics*, pp. 281-286, 2013.
- [25] Lino P., Maione B., Rizzo A., "Nonlinear Modelling and Control of a Common Rail Injection System for Diesel Engines", *Applied Mathematical Modelling* 31 (2007) 1770-1784.
- [26] Lino P., Maione B., Amorese C., "Modelling and Predictive Control of a New Injection System for Compressed Natural Gas Engines", *Control Engineering Practice* 16 (2008) 1216-1230.

- [27] Li, Z., „Condition Monitoring of Axial Piston Pump“, Thesis for the Degree of Master of Science in the Department of Mechanical Engineering University of Saskatchewan, Saskatoon, Canada, November 2005.
- [28] Seykens, X.J.L., Somers, L.M.T. & Baert, R.S.G . Modeling of common rail fuel injection system and influence of fluid properties on injection process. Proceedings of VAFSEP, Dublin, Ireland, 2004.
- [29] Boudy, F., Seers, P. „Impact of physical properties of biodiesel on the injection process in a common-rail direct injection system“, Energy Conversion and Management 50, p. 2905 – 2912, 2009.
- [30] Kijjarvi, J., „Diesel fuel injection system simulation“, Publications of the Internal Combustion Engine Laboratory, Helsinki University of Technology, No. 77, pp. 126, 2003.
- [31] Zhang Z., Sun Z., „Rotational Angle Based Pressure Control of a Common Rail Fuel Injection System for Internal Combustion Engines“, American Control Conference Hyatt Regency Riverfront, St. Louis, MO, USA, 2009.
- [32] Schaschke, C., Fletcher, I. and Glen, N., “Density and Viscosity Measurement of Diesel Fuels at Combined High Pressure and Elevated Temperature”, Processes 2013, 1, 30-48.
- [33] **Ioanas, G.L.**, „Modeling, Identification and Prediction of Inherent quasi-stationary Pressure Dynamics of a Common-Rail System using Neuro-Fuzzy Structures with Local Linear ARX models“, Control Engineering and Applied Informatics Journal, Bucuresti, Romania, Vol. 14, no.3, pp. 61-70, 2012.
- [34] **Ioanas, G.L.**, Dragomir, T.L., „Local linear models adaptation for a 4 Inj – 2PP Commonrail Pressure System“, IEEE 11th International Symposium on Intelligent Systems and Informatics, SISY 2013, Subotica, pp. 253 – 258, 2013.
- [35] **Ioanas, G.L.**, Dragomir, T.L., „Dynamic models adaptation for a 4 Inj – 2PP Commonrail Pressure System“, 39th Annual Conference of the IEEE Industrial Electronics Society, IECON 2013, Viena, pp. 3490 – 3495, 2013.
- [36] Nelles, O., Nonlinear System Identification, Springer- Verlag, cap. 11, 13, 14, 19, 20, 21, 23, 2001.
- [37] Minsky, M. and Papert, S, „Perceptrons“, The MIT Press, Expanded edition, 1988.
- [38] Kurkova, V., Kolmogorov's theorem and multilayer neural networks, Neural Networks (1992), Volume: 5, Issue: 3, Pages: 501-506.
- [39] Lin, J.-N. and Unbehauen, R. (1993). „On the Realization of a Kolmogorov Network,“ *Neural Computation*, 5(1), 21-31.
- [40] Teodorescu, H.N., Sisteme Neuro-Fuzzy, curs, Accesat în 20.10.2011.

- [41] http://www.ac.tuiasi.ro/ro/library/cursDIAGNOZAwweb/p3_cap1_web.pdf. Accesat in 30.10.2013.
- [42] Murray-Smith R., Hunt K. J., „Local Model Architectures for Nonlinear Modelling and Control”, *Springer pp. 61-82*, Berlin 1995.
- [43] Obodeh O., Ajuwa C. I., „Evaluation of Artificial Neural Network Performance in Predicting Diesel Engine NO_x Emissions”, *European Journal of Scientific Research*, Vol. 33, No. 4, pp. 642-653, 2009.
- [44] Kosmatopoulos E. B., Polycarpou M. M., Christodoulou M. A., Ioannou P. A., „High-Order Neural Network Structures for Identification of Dynamical Systems”, *IEEE Transactions on Neural Networks*, Vol. 6, No.2, March 1995.
- [45] Novak J., Bobal V., „Predictive Control of the Heat Exchanger Using Local Model Network”, *17th Mediterranean Conference on Control & Automation*, Makedonia Palace, Thessaloniki, Greece, June 24-26, 2009.
- [46] Roll J., Bemporad A., Ljung L., „Identification of Piecewise Affine Systems via Mixed-Integer Programming”, *Automatica*, Vol. 40, Issue 1, pp. 37-50, Jan 2004.
- [47] Yen J., Wang L., Gillespie C. W., “Improving the Interpretability of TSK Fuzzy Models by Combining Global Learning And Local Learning”, *IEEE Transactions on Fuzzy Systems*, Vol. 6, No. 4, Nov 1998.
- [48] Murray-Smith R., „Local Model Networks and Local Learning”, *Fuzzy-Duisburg ,94, Univ. Of Duisburg*, April 7-8, 1994.
- [49] Hunt K. J., Irwin G. R., Warwick K., „Neural Network Engineering in Dynamic Control Systems”, *Springer pp. 61-82*, Berlin, 1995.
- [50] Fink A., Nelles O., Isermann R., „Nonlinear Internal Model Control for MISO Systems Based on Local Linear Neuro-Fuzzy Models”, *IFAC 15th Triennial World Congress*, Barcelona, Spain, 2002.
- [51] Fink A., Topfer S., Isermann R., „Nonlinear Model-Based Control with Local Linear Neuro-Fuzzy Models”, *Springer-Verlag, Archive of Applied Mechanics*, 72, pp. 911-922, 2003.
- [52] Zhang J., Morris J., „Nonlinear Model Predictive Control Based on Multiple Local Linear Models”, *Proceedings of the American Control Conference*, Arlington, VA June 25-27, 2001.
- [53] Nelles O., “Local Linear Model Trees for On-Line Identification of Time-Variant Nonlinear Dynamic Systems”, *Artificial Neural Networks-ICANN 96, Lecture Notes in Computer Science*, Vol. 1112, pp. 115-120, 1996.
- [54] Vazquez, A., Antelo, E., „Implementation of the exponential function in a floating-point unit”, *Journal of VLSI Signal Processing*, vol. 33, no. 1-2, pp. 125-145, Jan. 2003.

- [55] Pineiro, J. A., Ercegovic, M. D., Bruguera, J. D., „Algorithm and architecture for logarithm, exponential, and powering computation”, *IEEE Transactions on Computers*, vol. 53, no. 9, pp. 1085–1096, 2004.
- [56] Chen, G., T.T. Pham, *Introduction to Fuzzy Sets, Fuzzy Logic, and Fuzzy Control Systems*, CRC, 2001.
- [57] Zadeh, L.A., „*Fuzzy Sets*”, *Information and Control*, 8, pp. 338-353, 1965.
- [58] Preitl S., Precup R.E., *Introducere în conducerea fuzzy a proceselor* – Editura Tehnica, 1997.
- [59] Drechsel D., *Regelbasierte Interpolation und Fuzzy Control*, Vieweg, 1996.
- [60] Lee J., Mathews V. J., „A Fast Recursive Least Squares Adaptive Second-Order Volterra Filter and Its Performance Analysis”, *IEEE Transactions on signal processing*, vol. 41, NO. 3, March 1993.
- [61] Ljung L., „Analysis of Recursive Stochastic Algorithms”, *IEEE Transactions on Automatic Control*, Vol. AC-22, NO. 4, August 1977.
- [62] Gao Y., Er M. J., „Online Adaptive Fuzzy Neural Identification and Control of a Class of MIMO Nonlinear Systems”, *IFAC 15th Triennial World Congress*, Barcelona, Spain, 2002.
- [63] Ljung L., „Some Aspects on Nonlinear System Identification”, *Proceedings of the 14th IFAC Symposium on System Identification*, pp. 553-564, 2006.
- [64] Bradley R. S., „The Robust Stability of Iterative Learning Control”, *University of Southampton*, September 2010.
- [65] OSEK/VDX operating system: <http://portal.osek- vdx.org/files/pdf/specs/os223.pdf> . Accesat in 29.09.2013.
- [66] <http://www.etas.com/en/products/ehooks.php> . Accesat in 29.09.2013.
- [67] Gribbon, K.T., Bailey, D.G., „A novel approach to real-time bilinear interpolation”, *IEEE International Conference on Field-Programmable Technology*, 2004.
- [68] Dumitrache, I., *Automatica. Volumul 2*, Editura Academiei Romane, Bucuresti, Romania, 2013.
- [69] Riebens W. *Digital engine control systems* (Cap. 4 din: Crolla, D. (editor), *Automotive Engineering e-Mega Reference - Automotive engineering, powertrain, chassis systems and vehicle body*, Butterworth-Heinemann, 2009.
- [70] Drechsel D., *Regelbasierte Interpolation und Fuzzy Control*, Vieweg, 1996.
- [71] <http://www.etas.com/en/products>.
http://www.etas.com/en/products/etk7_1.php. Accesat in 29.09.2013.

-
- [72] Ljung L., „Recursive Least Squares and Accelerated Convergence in Stochastic Approximation Schemes“, *International Journal of Adaptive Control and Signal Processing*, 2001.
- [73] Soderstrom T., „Uniqueness and On-line Algorithms in Identification of Dynamic Systems“, *Lund Institute of Technology*, 1973.
- [74] Landau I. D., Karimi A., „An Output Error Recursive Algorithm for Unbiased Identification in Closed Loop“, *Automatica*, Vol. 33, No. 5, pp. 933-938, 1997.
- [75] Bittanti S., Campi M., „Adaptive RLS Algorithms Under Stochastic Excitation- L^2 Convergence Analysis“, *IEEE Transactions on Automatic Control*, Vol. 36, NO.8, August 1991.
- [76] Borisagar K. R., Kulkarni Dr. G. R., „Simulation and Comparative Analysis of LMS and RLS Algorithms Using Real Time Speech Input Signal“, *Global Journal of Researches in Engineering*, Vol. 10 Issue 5, Oct. 2010.
- [77] Marcet A., Sargent Th. J., „Speed of Convergence of Recursive Least Squares Learning with ARMA Perceptions“, *Economics Working Paper*, 15 May 1992.
- [78] Soderstrom T., Stoica P., „System Identification“, *Prentice Hall International (UK) Ltd.*, 1989.
- [79] Kamenetsky M., Widrow B., „A Variable Leaky LMS Adaptive Algorithm“, *Signals, Systems and Computers*, Vol.1, 2004, pp. 125 - 128.
- [80] Michaletzky G., Gerencser L., „BIBO Stability of Linear Switching Systems“, *Automatic Control*, *IEEE Transactions on* (Volume: 47, Issue:11), Nov 2002
- [81] Gerencsér L.A., „Representation Theorem for the Error of Recursive Estimators“, *SIAM J. Control and Optimization*, 44 (6), pp. 2123-2188, 2006.
- [82] Waterschoot T., Rombouts G., Moonen M., „Optimally Regularized Recursive Least Squares for Acoustic Echo Cancellation“, *Proceedings of The second annual IEEE BENELUX/DSP Valley Signal Processing Symposium (SPS-DARTS 2006)*, Antwerp, Belgium, March 28-29, 2006.
- [83] Cerone, V., Regruto, D., „Parameter Bounds for Discrete-Time Hammerstein Models with Bounded Output Errors“, *IEEE Transactions on Automatic Control*, vol. 48, no. 10, 2003.
- [84] Matlab 7.09, Simulink Library.
- [85] Hummel, K. et. al. , „Generation Pkw-Common-Rail von Bosch mit Piezo-Inline-Injektoren“, *MTZ*, Volume 65, Issue 3 , pp 180-189, 2004.

- [86] http://www.conti-online.com/www/automotive_de_en/themes/passenger_cars/powertrain/engine_systems/engine_systems_en.html?page=2 . Accesat in 30.09.2013.
- [87] Holz, H, Mollenhauer, Tshoke, H., Kolbenmaschinen, Springer – Verlag, 2007.
- [88] **Ioanas, G. L.**, „Perspectives on Neuro-Fuzzy Modeling and Identification for Diesel Common Rail High Pressure Systems”, Workshop “Cercetari doctorale in domeniul tehnic”,in cadrul POSDRU/88/1.5/S/50783, Craiova, Februarie 2011.
- [89] **Ioanas, G. L.**, „External Rapid Prototyping with Motorola MPC5xx via Nexus Interface using dSPACE DCI GSI and Matlab/Simulink”, Workshop-ul nr.2, Interdisciplinaritatea și managementul cercetării. Prezentarea rezultatelor obtinute de doctoranzi, Universitatea „Politehnica” din Timișoara 24-25 noiembrie 2011.