

Primjena metoda umjetne inteligencije pri izboru materijala

Lisjak, Dragutin

Doctoral thesis / Disertacija

2004

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:624569>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-03-23**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSKA I BRODOGRADNJE

PRIMJENA METODA UMJETNE INTELIGENCIJE
PRI IZBORU MATERIJALA

DOKTORSKA DISERTACIJA

Mentor:
Prof. dr.sc. TOMISLAV FILETIN

DRAGUTIN LISJAK

ZAGREB, 2004.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK:..... 620.178; 004.891

Ključne riječi: Izbor materijala, umjetna inteligencija, neuronske mreže, neizrazita logika, genetički algoritmi, ekspertni sustavi.

Znanstveno područje: TEHNIČKE ZNANOSTI

Znanstveno polje: Strojarsstvo

Institucija u kojoj je rad izrađen: Fakultet strojarstva i brodogradnje u Zagrebu

Mentor rada: prof. dr.sc. Tomislav Filetin, redoviti profesor

Broj stranica:..... 269

Broj slika:..... 156

Broj tablica:..... 76

Broj korištenih bibliografskih jedinica:.... 60

Datum obrane:..... _____

Povjerenstvo:..... dr.sc. Branko Novaković, red.prof.
dr.sc. Tomislav Filetin, red.prof.
dr.sc. Mladen Stupnišek, red. prof.
dr.sc. Bojan Jerbić, izv.prof.
dr.sc. Darko Grundler, izv.prof. Tekstilno-
tehnološkog fakulteta u Zagrebu

Institucija u kojoj je rad pohranjen:..... Fakultet strojarstva i brodogradnje u Zagrebu

ZAHVALA

Zahvaljujem se mentoru prof.dr.sc. Tomislavu Filetinu na ukazanom povjerenju i strpljenju koje je iskazao tijekom izrade ovog rada.

Posebnu zahvalnost dugujem kolegici doc.dr.sc. L.Ćurković na nesebično iskazanoj pomoći tijekom izrade rada, a posebno njegova 'kemijskog dijela'.

Riječi zahvale upućujem i kolegici dipl.ing. Đ.Gorščak budućoj mr.sc., na znalački urađenim prijevodima 'čudnih' tekstova.

Kolegi (zimmeru!) mr.sc. Davoru Novaku također dugujem veliku zahvalnost, jer bi bez primjene 'njegovim GA-algoritama' izrada ovog rada trajala zauvijek.

Posebnu zahvalnost dugujem svojim sinovima Tinu i Svenu na razumijevanju zbog brojnih sati koje nisam proveo s njima.

Zahvaljujem i ostalim neimenovanim kolegama i prijateljima na ohrabrenju tijekom izrade rada.

Dragutin Lisjak

U Zagrebu, 18. listopada 2004.

SADRŽAJ

POPIS SLIKA	7
POPIS TABLICA	12
POPIS OZNAKA I KRATICA	15
PREDGOVOR	16
SAŽETAK	17
SUMMARY	18
1. UVOD	1
1.1. Uvod	1
1.2. Pregled dosadašnjih saznanja.....	2
1.3. Hipoteza rada.....	3
1.4. Metodologija rada	3
2. TEORIJSKI DIO	5
2.1. Kratki opis metoda umjetne inteligencije.....	5
2.2. <i>Backpropagation (BP)</i> neuronske mreže.....	7
2.2.1. Uvod	7
2.2.2. Struktura <i>BP</i> neuronske mreže	7
2.2.3. Algoritam učenja <i>BP</i> mreža.....	9
2.2.4. Modifikacije <i>BP</i> algoritma	13
2.2.5. <i>BP</i> -algoritam sa konstantnim koeficijentom brzine učenja – μ	14
2.2.6. <i>BP</i> -algoritam sa konstantnim koeficijentom momentuma – α	14
2.2.7. Algoritam sa varijabilnim ili adaptivnim koeficijentom brzine učenja – μ	15
2.2.8. Levenberg-Marquardt algoritam učenja	15
2.2.9. Metode za poboljšanje aproksimacije.....	16
2.2.10. Metoda regularizacije	17
2.2.11. Metoda ranog zaustavljanja	17
2.3. <i>Asocijativne neuronske mreže</i>	18
2.3.1. Uvod	18
2.3.2. Opis jednostavne asocijativne mreže.....	18
2.3.3. <i>Hebb</i> -ovo pravilo učenja bez učitelja	19
2.3.4. <i>Hebb</i> -ovo pravilo zaboravljanja	19
2.3.5. ' <i>Instar</i> ' pravilo.....	19
2.3.6. <i>Outstar</i> pravilo.....	20
2.3.7. Ocjena uspješnosti algoritma učenja	21
2.4. <i>Neizrazita logika</i>	23
2.4.1. Uvod	23
2.4.2. Neizraziti skupovi.....	23
2.4.3. Funkcije pripadnosti	25
2.4.4. Defazifikacija	28
2.4.5. Predstavljanje složenih izraza.....	29
2.4.6. Relacije implikacije	30
2.4.7. <i>Fuzzy</i> algoritam	31
2.5. <i>NeuroFuzzy</i>	32
2.5.1. Uvod	32
2.5.2. Neuronske mreže za određivanje funkcija pripadnosti.....	32
2.5.3. Adaptivni neurofuzzy sustav zaključivanja	33
2.5.4. ANFIS - hibridni algoritam učenja.....	34
2.5.5. Metoda najmanjih odstupanja.....	35

2.5.6.	ANFIS – primjer hibridnog algoritma učenja	35
2.6.	Genetički algoritmi (GA).....	39
2.6.1.	Princip rada genetičkih algoritama.....	39
2.7.	Ekspertni sustavi	44
2.7.1.	Uvod	44
2.7.2.	Ekspertni sustavi temeljeni na pravilima.....	45
2.7.3.	Mehanizam zaključivanja ekspertnih sustava temeljenih na pravilima.....	47
2.7.4.	Ekspertni sustavi temeljeni na okvirima.....	49
2.7.5.	Problem nesigurnih informacija	51
2.8.	Neke praktične značajke neuronskih mreža	54
2.8.1.	Skaliranje, normalizacija i standardizacija ulazno-izlaznih vektora podataka	54
2.8.2.	Mapiranje ili kodiranje simboličkih ulazno-izlaznih varijabli.....	54
2.8.3.	Aktivacijske ili prijenosne funkcije.....	56
2.8.4.	Broj skrivenih slojeva i broj neurona	57
2.8.5.	Metodologija učenje ili treninga mreže.....	58
2.8.6.	Pregled primjenjenih algoritama neuronskih mreža	59
2.9.	Neke praktične značajke neizrazite logike	61
2.9.1.	Metodologija izbora lingvističkih varijabli i funkcija pripadnosti	61
2.9.2.	Karakteristike metoda defazifikacije.....	62
2.9.3.	Centar maksimuma - CoM	62
2.9.4.	Prosjek maksimuma – MoM	64
2.9.5.	Centar površine - CoA.....	65
2.9.6.	Usporedba i izbor metoda defazifikacije.....	66
2.10.	Neke praktičke značajke genetičkih algoritama.....	67
2.11.	Neke praktičke značajke ekspertnih sustava	68
3.	OPIS INTELIGENTNOG SUSTAVA ZA IZBOR MATERIJALA.....	69
3.1.	Opis inteligentnog sustava za izbor materijala.....	69
3.2.	Mehanizam zaključivanja.....	72
3.2.1.	Mehanizam za obradu konverzacije	73
3.2.2.	Mehanizam za obradu asocijacija.....	74
3.2.3.	Mehanizam za obradu pravila	75
3.2.4.	Mehanizam za obradu kriterija za izbor materijala	77
3.2.5.	Mehanizam izbora postupaka modificiranja površina procjenama	78
3.2.6.	Mehanizam izbora materijala procjenama.....	80
3.2.7.	Mehanizam za procjenu svojstava nosivog materijala na bazi Fe.....	81
3.2.8.	Struktura <i>okvir</i> baza znanja	88
3.2.9.	<i>Okvir</i> mehanizam zaključivanja	89
3.2.10.	Mehanizam za učenje asocijacija	90
4.	EKSPERIMENTALNI DIO.....	91
4.1.	Plan izgradnje sustava	91
4.2.	Način prikaza rezultata eksperimenta.....	92
4.2.1.	Prikaz parametara i rezultata učenja neuronske mreže.....	92
4.2.2.	Prikaz parametara i rezultata učenja mehanizma zaključivanja neizrazite logike.....	93
4.3.	Pregled softverskih alata.....	94
4.3.1.	Problemi implementacije i međusobne komunikacije softverskih alata.....	96
4.4.	Definicije ulazno-izlaznih skupova <i>backpropagation</i> neuronskih mreža.....	98
4.4.1.	Procjena elemenata sustava	98
4.4.2.	Procjena stabilnosti i izbor algoritama asocijativnih mreža	105
4.4.3.	Procjena tipa trošenja	108
4.4.4.	Procjena mehanizma trošenja	111
4.4.5.	Procjena prikladnog površinskog sloja.....	116

4.4.6.	Procjena prikladnog površinskog sloja otpornog koroziji	120
4.4.7.	Procjena prikladnog površinskog sloja otpornog trošenju.....	123
4.4.8.	Procjena kemijske postojanosti čelika.....	126
4.4.9.	Procjena otpornosti trošenja abraziji gubitkom volumena	147
4.4.10.	Procjena otpornosti popuštanju alatnih čelika na temelju parametra popuštanja	152
4.4.11.	Procjena mehaničkih svojstava alatnih čelika pri povišenim temperaturama	174
4.5.	Definicije ulazno-izlaznih skupova neizrazite logike.....	179
4.5.1.	Ulazno-izlazni skupovi za procjenu R _m , R _e , HV i A ₅ u kaljenom stanju	180
4.5.2.	Ulazno-izlazni skupovi za procjenu R _m , R _e , HV i A ₅ u poboljšanom stanju	190
4.5.3.	Iskustvene procjene primarnih zahtjeva na alatne čelike s obzirom na utjecaj	203
	karbidotvoraca	203
4.6.	Definicije ulazno-izlaznih skupova asocijativnih neuronskih mreža	211
4.6.1.	Procjene vremenskom asocijativnom matricom.....	211
4.6.2.	Procjena elemenata tribosustava vremenskom asocijativnom matricom	212
4.6.3.	Procjena agresivnosti otopine vremenskom asocijativnom matricom.....	213
4.6.4.	Procjena koncentracije agresivne otopine vremenskom asocijativnom matricom	214
4.6.5.	Procjena radne temperature vremenskom asocijativnom matricom	215
4.6.6.	Procjena mehaničkih svojstava vremenskom asocijativnom matricom	216
4.6.7.	Procjena mase vremenskom asocijativnom matricom.....	221
5.	PROVJERA RADA SUSTAVA.....	222
5.1.	Primjer načina rada mehanizama zaključivanja.....	222
5.1.1.	Primjer načina rada mehanizma za obradu konverzacije.....	222
5.1.2.	Primjer načina rada mehanizma za obradu asocijacija	227
5.1.3.	Primjer načina rada mehanizma za obradu pravila.....	229
5.1.4.	Princip rada mehanizma za obradu kriterija za izbor materijala	231
5.1.5.	Primjer načina rada mehanizma za procjenu postupaka modificiranja površina.....	232
5.1.6.	Primjer načina rada mehanizma izbora materijala procjenama	234
5.1.7.	Primjer načina rada <i>okvir</i> mehanizma zaključivanja	243
5.1.8.	Princip učenja <i>okvir</i> baze znanja	247
5.1.9.	Primjer načina rada mehanizma za učenje asocijacija.....	249
5.1.10.	Primjer načina rada mehanizma za objašnjavanje rješenja.....	250
6.	RASPRAVA O REZULTATIMA ISTRAŽIVANJA.....	253
6.1.	Rasprava o rezultatima istraživanja.....	253
6.1.1.	Osvrt na primjenu softverskih alata	253
6.1.2.	Osvrt na procjene <i>backpropagation</i> neuronskih mreža	254
6.1.3.	Rekapitulacija parametara procjena <i>backpropagation</i> neuronskih mreža	256
6.1.4.	Osvrt na procjene neizrazite logike	258
6.1.5.	Osvrt na procjene asocijativnih neuronskih mreža.....	260
6.1.6.	Osvrt na način rada mehanizma zaključivanja	261
	ZAKLJUČAK.....	263
	LITERATURA.....	265
	ŽIVOTOPIS.....	268
	CURRICULUM VITAE.....	269

POPIS SLIKA

Slika 2.1. Model umjetnog neurona.....	7
Slika 2.2. Prikaz <i>backpropagation</i> modela neurona.....	7
Slika 2.3. Aktivacijske funkcije <i>log-sigmoid</i> tipa.....	7
Slika 2.4. Aktivacijske funkcije <i>tan-sigmoid</i> tipa.....	8
Slika 2.5. Aktivacijske funkcije <i>lin</i> tipa.....	8
Slika 2.6. Shema jednoslojne <i>unaprijedne BP</i> mreže.....	8
Slika 2.7. Shema dvoslojne <i>unaprijedne backpropagation</i> mreže.....	9
Slika 2.8. Gradijent ili nagib tangente funkcije $y=f(x)$	9
Slika 2.9. Funkcije greske $E=f(w)$	10
Slika 2.10. Prikaz <i>SSE</i> površine kao funkcije od W i B	10
Slika 2.11. Značenje koeficijenta brzine učenja.....	14
Slika 2.12. Primjer površine greške sa putanjom konvergencije.....	14
Slika 2.13. Problem lokalnog i globalnog minimuma.....	15
Slika 2.14. Problem <i>overfittinga</i> mreže.....	16
Slika 2.15. Shematski prikaz <i>early stopping</i> metode.....	17
Slika 2.16. Shematski prikaz asocijativne mreže sa jednim ulazom i sa tzv. tvrdograničnom aktivacijskom funkcijom.....	18
Slika 2.17. Grafički prikaz <i>instar pravil</i>	20
Slika 2.18. Shema <i>outstar</i> neuronske mreža.....	20
Slika 2.19. <i>Zadeh-ov</i> dijagram za neizraziti skup $B=\{\text{mali brojevi}\}$	25
Slika 2.20. Trokutasta funkcija pripadnosti.....	26
Slika 2.21. Preklapanje neizrazitih skupova unutar <i>univerzalnog skupa</i>	26
Slika 2.22. Trokutasta i trapezoidna funkcija pripadnosti.....	27
Slika 2.23. <i>S-oblik</i> funkcije pripadnosti.....	27
Slika 2.24. <i>P-oblik</i> funkcije pripadnosti.....	28
Slika 2.25. Metoda <i>centra površine</i> kao metoda defazifi.....	28
Slika 2.26. Metoda <i>sredina maksimuma</i> kao metoda defazifikacije.....	29
Slika 2.27. Predstavljanje varijable <i>temperatura</i> lingvističkim modifikatorom <i>VIŠE ili MANJE</i>	29
Slika 2.28. Primjer predstavljanja <i>neizrazitih brojeva 3 i 7 neizrazitim skupovima</i>	30
Slika 2.29. Primjer <i>Mamdami min</i> implikacijskog operatora neizrazitog broja na ulazu i izlazu.....	31
Slika 2.30. Blok shema <i>fuzzy</i> algoritma.....	31
Slika 2.31. Princip klasifikacije i <i>clusteringa</i> za određivanje funkcija pripadnosti.....	32
Slika 2.32. Jednoulazni <i>Sugeno</i> model prvog stupnja sa dva pravila.....	34
Slika 2.33. <i>ANFIS</i> struktura jednoulaznog <i>Sugeno</i> modela prvog stupnja sa tri pravila.....	36
Slika 2.34. Izgled funkcije za <i>ANFIS</i> aproksimaciju.....	36
Slika 2.35. Generiranje funkcija i stupnja pripadnosti.....	36

Slika 2.36. ANFIS aproksimacija funkcije.....	37
Slika 2.37. ANFIS optimirane funkcije pripadnosti $MF1, MF2, MF3$ i aproksimacija funkcije $f(x)=0.05x^3 - 0.02x^2 - 0.3x + 20$	38
Slika 2.38. SSE graf funkcija pripadnosti nakon učenja.....	38
Slika 2.39. Primjer umjetnog kromosoma.....	39
Slika 2.40. Binarni prikaz gena kromosoma funkcije $f(x)=15x-x^2$	40
Slika 2.41. Funkcija prikladnosti i lokacije kromosoma.....	40
Slika 2.42. Izbor kromosoma metodom <i>kola sreće</i>	42
Slika 2.43. Princip križanja kromosoma.....	42
Slika 2.44. Princip mutacije kromosoma.....	43
Slika 2.45. Shema ciklusa <i>GA</i>	43
Slika 2.46. Razvojni tim ekspertnog sustava.....	44
Slika 2.47. Struktura ekspertnog sustava.....	45
Slika 2.48. Pojednostavljeni prikaz <i>modela produkcijskih pravila</i>	45
Slika 2.49. Princip rada mehanizma zaključivanja <i>ulančavanjem unaprijed</i>	47
Slika 2.50. Princip rada mehanizma zaključivanja <i>ulančavanjem unazad</i>	48
Slika 2.51. Struktura okvira.....	49
Slika 2.52. Primjer strukture i načina rada okvira.....	50
Slika 2.53. Problem kod mapiranja kategoričkih varijabli.....	55
Slika 2.54. Utjecaj binarnog kodiranja ulaznih varijabli na grešku u procesu učenja mreže.....	55
Slika 2.55. Utjecaj premapiranog binarnog kodiranja ulaznih varijabli na grešku u procesu učenja mreže.....	56
Slika 2.56. Utjecaj broja skrivenih slojeva i broja neurona na aproksimaciju površine funkcije.....	57
Slika 2.57. Shematski prikaz dijagrama tijekom učenja neuronske mreže.....	56
Slika 2.58. Shematski prikaz <i>standardnih funkcija pripadnosti</i>	61
Slika 2.59. Shematski prikaz definicije trokutastog tipa funkcije pripadnosti neizrazitog skupa 'nula'.....	62
Slika 2.60. Shematski prikaz izračunavanja <i>tipične vrijednosti</i> izlazne varijable.....	63
Slika 2.61. Shematski prikaz izračunavanja numeričke vrijednosti lingvističke izlazne varijable metodom <i>najboljeg kompromisa</i>	63
Slika 2.62. Shematski prikaz načina rada metode <i>najboljeg kompromisa</i>	63
Slika 2.63. Prikaz problema defazifikacije <i>CoM</i> metodom.....	64
Slika 2.64. Varijante <i>MoM</i> metode defazifikacije.....	64
Slika 2.65. Shematski prikaz izračunavanja numeričke vrijednosti lingvističke izlazne varijable metodom <i>centar površine- CoA</i>	65
Slika 2.66. Shematski prikaz nedostatka <i>CoA</i> metode defazifikacije.....	65
Slika 3.1. Principijelna shema integracije metoda umjetne inteligencije unutar inteligentnog sustava za izbor materijala.....	69
Slika 3.2. Shema strukture inteligentnog sustava za izbor materijala.....	70

Slika 3.3. Principijelna shema načina postizanja ‘ <i>inteligentnog ponašanja</i> ’ sustava za izbor materijala.....	70
Slika 3.4. Primjer <i>vremenske asocijativne matrice</i> za određivanje elemenata sustava.....	71
Slika 3.5. Blok-shema strukture mehanizma zaključivanja za izbor materijala u uvjetima trošenja.....	72
Slika 3.6. Blok-shema mehanizma za obradu konverzacije.....	73
Slika 3.7. Blok-shema mehanizma za obradu asocijacija.....	74
Slika 3.8. Blok-shema strukture pravila.....	75
Slika 3.9. Blok-shema uvjeta <i>ispaljivanja</i> pravila.....	76
Slika 3.10. Princip izračunavanja <i>faktora sigurnosti</i> (CNF) pravila.....	76
Slika 3.11. Blok-shema mehanizma za obradu kriterija.....	77
Slika 3.12. Pregled podjele postupaka modificiranja i prevlačenja metala.....	78
Slika 3.13. Blok-shema mehanizma izbora postupka modificiranja površina.....	79
Slika 3.14. Blok-shema mehanizma izbora materijala.....	80
Slika 3.15. Blok-shema mehanizma za procjenu materijala na bazi <i>Fe</i>	81
Slika 3.16. Blok-shema grupa procjena materijala na bazi <i>Fe</i>	86
Slika 3.17. Blok-shema strukture <i>okvir</i> baza znanja.....	88
Slika 3.18. Blok-shema <i>okvir</i> mehanizma zaključivanja.....	89
Slika 3.19. Princip nasljeđivanja svojstva <i>okvir</i> mehanizma zaključivanja.....	89
Slika 3.20. Blok-shema mehanizma za učenje asocijacija.....	90
Slika 4.1. Shema plana izgradnje sustava	91
Slika 4.2 Primjer načina prikaza parametra i rezultata učenja neuronske mreže.....	92
Slika 4.3 Primjer načina prikaza parametra i rezultata učenja mehanizma zaključivanja neizrazite logike.....	93
Slika 4.4. Primjer mapiranja ulazno-izlaznog skupa za asocijativnu procjenu elemenata sustava.....	98
Slika 4.5. Ulazno-izlazne matrice za asocijativnu procjenu elemenata sustava.....	98
Slika 4.6. Primjer vektora procjena (<i>A</i>) s obzirom na unošeni vektor šuma (<i>P</i>) te % točnosti oporavka u odnosu na željeni vektor (<i>T</i>).....	105
Slika 4.7. Prikaz pada točnosti asocijativnih algoritama u zavisnosti od iznosa šuma.....	106
Slika 4.8. Shema mapiranja varijabli tablice klasifikacije trošenja.....	108
Slika 4.9. Primjer mapiranja ulazno-izlaznog skupa za procjenu tipa trošenja.....	108
Slika 4.10. Ulazno-izlazne matrice za procjenu tipa trošenja.....	108
Slika 4.11. Primjer mapiranja ulazno-izlaznog skupa za procjenu mehanizma trošenja.....	111
Slika 4.12. Ulazno-izlazne matrice za procjenu mehanizma trošenja.....	111
Slika 4.13. Shema mapiranja varijabli postupaka modificiranja površina.....	116
Slika 4.14. Primjer mapiranja ulazno-izlaznog skupa za određivanje prikladnog postupka modificiranja površina.....	116
Slika 4.15. Ulazno-izlazne matrice za određivanje prikladnog postupka modificiranja površina...	116
Slika 4.16. Iskustvene ocjene za procjenu prikladnog površinskog sloja otpornog koroziji.....	120

Slika 4.17. Primjer mapiranja ulazno-izlaznog skupa za procjenu prikladnog površinskog sloja otpornog koroziji.....	120
Slika 4.18. Ulazno-izlazne matrice za procjenu prikladnog površinskog sloja otpornog koroziji...	120
Slika 4.19. Iskustvene ocjene za procjenu prikladnog površinskog sloja otpornog trošenju.....	123
Slika 4.20. Primjer mapiranja ulazno-izlaznog skupa za procjenu prikladnog površinskog sloja otpornog trošenju.....	123
Slika 4.21. Ulazno-izlazne matrice za procjenu prikladnog površinskog sloja otpornog trošenju.....	123
Slika 4.22. Kemijska postojanost čelika sulfatnoj kiselini.....	126
Slika 4.23. Primjer dijela mapiranja ulazno-izlaznog skupa za učenje za slučaj postojanosti čelika sulfatnoj H_2SO_4 kiselini.....	126
Slika 4.24. Rezultati ispitivanja otpornosti trošenja abraziji gubitkom volumena GV	147
Slika 4.25. Primjer dijela mapiranja ulazno-izlaznog skupa za učenje otpornosti trošenja abraziji gubitkom volumena.....	147
Slika 4.26. Primjer dijagrama popuštanja različitih skupina alatnih čelika.....	152
Slika 4.27. Tvrdća alatnih čelika za hladni rad u zavisnosti od kemijskog sastava i parametra popuštanja P	153
Slika 4.28. Mehanička svojstva R_m , $R_{p0,2}$ i A_5 alatnih čelika za topli rad pri povišenim temperaturama.....	174
Slika 4.29. Standardni oblici funkcija pripadnosti.....	179
Slika 4.30. Ulazno-izlazna matrice za učenje (A) i za testiranje (B) procjene R_m u kaljenom stanju.....	180
Slika 4.31. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene HV u poboljšanom stanju.....	180
Slika 4.32. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene Re u poboljšanom stanju.....	190
Slika 4.33. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene HV u poboljšanom stanju.....	190
Slika 4.34. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene A_5 u poboljšanom stanju.....	190
Slika 4.35. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene A_5 u poboljšanom stanju.....	190
Slika 4.36. Ulazno-izlazna matrice za učenje (A) i za testiranje (B) procjene otpornosti popuštanju alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo).....	203
Slika 4.37. Ulazno-izlazna matrice za učenje (A) i za testiranje (B) procjene žilavosti alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo).....	204
Slika 4.38. Ulazno-izlazna matrice za učenje (A) i za testiranje (B) procjene žilavosti alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo).....	204
Slika 5.1. Primjeri odgovora na pitanja pri konverzaciji sustav-korisnik.....	222
Slika 5.2. Primjeri odgovora na pitanja pri konverzaciji sustav-korisnik.....	223

Slika 5.3. Primjer načina rada mehanizma ‘ <i>STO AKO?</i> ’	224
Slika 5.4. Primjer načina rada mehanizma ‘ <i>ZAŠTO?</i> ’	225
Slika 5.5. Primjer načina rada mehanizma ‘ <i>KAKO?</i> ’	226
Slika 5.6. Primjer dijela asocijativnih procjena.....	227
Slika 5.7. Primjer programskog koda za asocijativnu procjenu elemenata sustava.....	228
Slika 5.8. Primjer programskog koda mehanizma ulančavanja unazad.....	229
Slika 5.9. Prikaz programskog koda za izračunavanje <i>faktora sigurnosti (CNF)</i> pravila.....	230
Slika 5.10. Princip rada mehanizma za dodjelu kriterija izbora materijala.....	231
Slika 5.11. Prikaz koda funkcije <i>nn_ppmp_backprop</i> za procjenu prikladnih postupaka modificiranja površina.....	232
Slika 5.12. Primjer izbora prikladnih postupaka modificiranja površina otpornih trošenju i koroziji.....	233
Slika 5.13. Prikaz programskog koda funkcije <i>ENG_PRET</i> mehanizma izbora materijala procjenama.....	236
Slika 5.14. Primjeri izbora prikladnog materijala sloja materijala procjenama.....	237
Slika 5.15. Prikaz koda funkcije <i>nn_hso_postojanost</i> za procjenu kemijske postojanosti čelika H ₂ SO ₄	238
Slika 5.16. Primjer određivanja kemijske postojanosti čelika Č4171 (X15Cr13).....	240
Slika 5.17. Prikaz koda funkcije <i>FUZZY_ENG</i> za procjenu svojstava materijala neizrazitom logikom.....	240
Slika 5.18. Primjer određivanja <i>Rm</i> u poboljšanom stanju za ČL1330 neizrazitom logikom.....	241
Slika 5.19. Programski kod funkcije za određivanje ‘ <i>pobjednika</i> ’ pri izboru materijala sloja.....	242
Slika 5.20. Primjer rezultata izbora materijala metodom ‘ <i>pobjednika</i> ’	242
Slika 5.21. Blok-shema <i>okvir</i> mehanizma zaključivanja.....	243
Slika 5.22. Primjer primjene <i>GET_SLOT_VAL_FRAME</i> funkcije.....	244
Slika 5.23. Primjer primjene <i>GET_FRAME_LIKE_SLOT_VAL</i> funkcije.....	245
Slika 5.24. Primjer unosa i ispravka <i>okvir</i> baze znanja.....	245
Slika 5.25. Prikaz koda funkcije <i>GET_SLOT_VAL_FRAME</i>	246
Slika 5.26. Blok-shema učenja <i>okvir</i> baze znanja.....	247
Slika 5.27. Prikaz programskog koda funkcije za učenje <i>okvir</i> baze znanja.....	248
Slika 5.28. Primjer učenja <i>okvir</i> baze znanja materijala.....	248
Slika 5.29. Primjer podešavanja parametara mehanizma za učenje asocijacija.....	249
Slika 5.30. Prikaz rezultat učenja asocijativne neuronske mreže za procjenu elemenata sustava.....	250
Slika 5.31. Primjer objašnjenja rješenja problema.....	251
Slika 5.32. Primjer opisa procijenjenog postupka modificiranja površina.....	252

POPIS TABLICA

Tablica 2.1. Kvantifikacija nepreciznih pojmova.....	51
Tablica 2.2. Interpretacija faktora sigurnosti u <i>MYCINU</i>	52
Tablica 2.3. Pregled parametara funkcija algoritama <i>perceptronskih</i> , <i>BP</i> i <i>asocijativnih</i> neuronskih mreža.....	60
Tablica 2.5. Usporedba različitih metoda defazifikacije.....	66
Tablica 2.4. Pregled modela neuronskih mreža te parametara za optimizaciju <i>GA-algoritmima</i>	67
Tablica 3.1. Donje granice dopuštenog udjela legirajućih elemenata u nelegiranim čelicima/čeličnim lijevovima.....	83
Tablica 4.1. Parametri i rezultati učenja <i>HEBBUN</i> mreže za procjenu elemenata sustava	99
Tablica 4.2. Parametri i rezultati učenja <i>HEBBSU</i> mreže za procjenu elemenata sustava.....	101
Tablica 4.3. Parametri i rezultati učenja <i>INSSU</i> mreže za procjenu elemenata sustava.....	103
Tablica 4.4. Usporedba asocijativnih algoritama s obzirom na 0% i 50% šum za slučajno odabrane tipove trošenja.....	106
Tablica 4.5. Rezultati <i>t-testa</i> za izbor asocijativnog algoritma.....	107
Tablica 4.6. Parametri i rezultati učenja <i>NNP</i> mreže za procjenu tipa trošenja.....	119
Tablica 4.7. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu mehanizma trošenja	112
Tablica 4.8. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu mehanizma trošenja.....	114
Tablica 4.9. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu prikladnih postupaka modificiranja površina.....	117
Tablica 4.10. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu prikladnog sloja otpornog koroziji.....	121
Tablica 4.11. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu prikladnog sloja otpornog trošenju.....	124
Tablica 4.12. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu postojanosti prema CH_3COOH	127
Tablica 4.13. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu postojanosti prema CH_3COOH	129
Tablica 4.14. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu postojanosti prema HCl	131
Tablica 4.15. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu postojanosti prema HCl	133
Tablica 4.16. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu postojanosti prema HNO_3 ... 135	
Tablica 4.17. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu postojanosti prema HNO_3 137	
Tablica 4.18. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu postojanosti prema H_3PO_4 . 139	
Tablica 4.19. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu postojanosti prema H_3PO_4 141	
Tablica 4.20. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu postojanosti prema H_2SO_4 . 143	
Tablica 4.21. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu postojanosti prema H_2SO_4 145	
Tablica 4.22. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu otpornosti trošenja abraziji gubitkom volumena.....	148

Tablica 4.23. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu otpornosti trošenja abraziji gubitkom volumena.....	150
Tablica 4.24. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu otpornosti popuštanju nelegiranih alatnih čelika za hladni rad.....	154
Tablica 4.25. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu otpornosti popuštanju nelegiranih alatnih čelika za hladni rad.....	156
Tablica 4.26. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu otpornosti popuštanju niskolegiranih alatni čelika za hladni rad.....	158
Tablica 4.27. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu otpornosti popuštanju niskolegiranih alatni čelika za hladni rad.....	160
Tablica 4.28. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu otpornosti popuštanju visokolegiranih alatnih čelika za hladni rad.....	162
Tablica 4.29. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu otpornosti popuštanju visokolegiranih alatnih čelika za hladni rad.....	164
Tablica 4.30. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu otpornosti popuštanju.....	166
Tablica 4.31. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu otpornosti popuštanju alatnih čelika za topli rad.....	168
Tablica 4.32. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu otpornosti popuštanju brzoreznih čelika.....	170
Tablica 4.33. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu otpornosti popuštanju brzoreznih čelika.....	172
Tablica 4.34. Parametri i rezultati učenja <i>NNBMA</i> mreže za procjenu mehaničkih svojstva a latnih čelika za rad na povišenim temperaturama.....	175
Tablica 4.35. Parametri i rezultati učenja <i>NNLM</i> mreže za procjenu mehaničkih svojstva alatnih čelika za rad na povišenim temperaturama.....	177
Tablica 4.36. Prikaz operatora i metoda <i>fuzzy</i> zaključivanja.....	179
Tablica 4.37. Prikaz standardnih <i>ANFIS</i> parametar.....	179
Tablica 4.38. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu <i>Rm</i> u kaljenom stanju.....	182
Tablica 4.39. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu <i>Re</i> u kaljenom stanju.....	184
Tablica 4.40. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu <i>HV</i> u kaljenom stanju.....	186
Tablica 4.41. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu <i>A₅</i> u kaljenom stanju.....	188
Tablica 4.42. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu <i>Rm</i> u poboljšanom stanju.....	191
Tablica 4.43. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu <i>Re</i> u poboljšanom stanju.....	193
Tablica 4.44. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu <i>HV</i> u poboljšanom stanju.....	195
Tablica 4.45. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu <i>A₅</i> u poboljšanom stanju.....	197
Tablica 4.46. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu otpornosti trošenju u poboljšanom stanju.....	199
Tablica 4.47. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu otpornosti trošenju u kaljenom stanju.....	201

Tablica 4.48. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu otpornosti trošenju alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo).....	205
Tablica 4.49. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu otpornosti popuštanju alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo).....	207
Tablica 4.50. Parametri, struktura i rezultati <i>FIS</i> -a za procjenu žilavosti alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo).....	209
Tablica 4.51. Primjer dobivanja vremenskog asocijativnog vektora za procjenu elemenata sustava sa zadanom početnom i vremenskom asocijativnom matricom.....	212
Tablica 4.52. Primjer dobivanja vremenskog asocijativnog vektora za procjenu elemenata sustava bez početne asocijativne matrice.....	213
Tablica 4.53. Primjer dobivanja vremenskog asocijativnog vektora za procjenu agresivnosti otopine.....	214
Tablica 4.54. Primjer dobivanja vremenskog asocijativnog vektora za procjenu koncentracije agresivne otopine.....	215
Tablica 4.55. Primjer dobivanja vremenskog asocijativnog vektora za procjenu radne temperature.....	216
Tablica 4.56. Primjer dobivanja vremenskog asocijativnog vektora za procjenu R_m i R_e	217
Tablica 4.57. Primjer dobivanja vremenskog asocijativnog vektora za procjenu A_5	217
Tablica 4.58. Primjer dobivanja vremenskog asocijativnog vektora za procjenu HV	218
Tablica 4.59. Primjer dobivanja vremenskog asocijativnog vektora za procjenu TR	219
Tablica 4.60. Primjer dobivanja vremenskog asocijativnog vektora za procjenu popuštanja PO	220
Tablica 4.61. Primjer dobivanja vremenskog asocijativnog vektora za procjenu žilavosti ZI	220
Tablica 4.62. Primjer dobivanja vremenskog asocijativnog vektora za procjenu mase.....	221
Tablica 5.1. Prikaz grupa materijala za izbor procjenama.....	234
Tablica 5.2. Prikaz oznaka materijala prikladnih za nanošenje postupcima modificiranja površina.....	235
Tablica 5.3. Prikaz funkcija mehanizma za obradu procjenu svojstava materijala na bazi Fe	239
Tablica 5.4. Popis funkcija za pristup <i>okvir</i> mehanizma zaključivanja.....	243
Tablica 6.1. Veličine ulazno-izlaznih matrica za procjenu kemijske postojanosti čelika.....	255
Tablica 6.2. Veličine ulazno-izlaznih matrica za procjenu otpornosti popuštanju alatnih čelika.....	256
Tablica 6.3. Rekapitulacija parametara procjena neuronskih mreža.....	257
Tablica 6.4. Rekapitulacija parametara procjena neizrazite logike.....	259

POPIS OZNAKA I KRATICA

<i>A</i>	procjenjeni izlaz mreže
<i>bias</i>	neuron s konstantnom vrijednosti jednakom 1
<i>d</i>	matrica željenih vrijednost izlaza neuronske mreže
<i>d_k</i>	željena vrijednost izlaza neuronske mreže
<i>E</i>	funkcija cilja mreže
<i>HRC</i>	tvrdća Rockwellov
<i>HV</i>	tvrdća Vickers
<i>MSE</i>	srednja kvadratna pogreška
<i>N</i>	broj parova ulazno-izlaznih vrijednosti seta učenja
<i>net</i>	vrijednost funkcije sumatora
<i>NRMSE</i>	normalizirani korijen srednje kvadratne pogreške
<i>R</i>	koeficijent korelacije
<i>RMSE</i>	korijen srednje kvadratne pogreške
<i>T</i>	željeni izlaz mreže

P R E D G O V O R

Razmatrana problematika u radu predstavlja autorov dugogodišnji kontinuitet u proučavanju metoda umjetne inteligencije i primjene istih u području izbora materijala. Rad je nastao kao želja za proširenjem spoznaja o umjetnoj inteligenciji proizašlih iz istraživanja unutar magistarskog rada. U magistarskom radu istraživana je problematika abrazijskog trošenja primjenom metoda ekspertnih sustava, kao najčešće primjenjivane metode umjetne inteligencije. Zadani cilj rada je bio modelirati i izgraditi takav sustav koji će na temelju ugrađenog znanja eksperta tj. stručnjaka biti u stanju 'inteligentno' rješavati probleme abrazijskog trošenja na način sličan čovjeku ekspertu. Sa današnjim spoznajama o metodama umjetne inteligencije, i sa današnje točke gledišta, autoru se čini da je zadani cilj rada bio preambiciozno postavljen. Naime, prilikom izrade rada uočen je sljedeći problem. Razmatrana problematika abrazijskog trošenja vrlo je složena u smislu čimbenika koji u njoj sudjeluju, jer postoji vrlo veliki broj njihovih međusobnih interakcija. Posljedica rješavanja interakcija, je pojava poznata pod nazivom kao 'kombinatorne eksplozija'. S obzirom da se metodologija ekspertnih sustava temelji na primjeni 'AKO-TADA' pravila, rješenje razmatranog problem nije bilo zadovoljavajuće upravo zbog pojave kombinatorne eksplozije. Spoznaja o toj pojavi bila je ključni momenat i poticaj daljnjeg istraživanja. Kao što će se vidjeti u nastavku rada, opisani problem moguće je na zadovoljavajući način riješiti primjenom novih metoda umjetne inteligencije kao što su: neuronske mreže, neizrazita (*fuzzy/NeuroFuzzy*) logika te genetički algoritmi.

S A Ž E T A K

U radu je sažeto dan prikaz aktualnih metoda umjetne inteligencije: neuronskih mreža, neizrazite logike, genetičkih algoritama i ekspertnih sustava. Detaljno je opisana struktura zamišljenog inteligentnog sustava za izbor materijala u uvjetima trošenja kao i način za poboljšanje njegove glavne komponente mehanizma zaključivanja. Također su opisani i podmehanizmi glavnog mehanizma zaključivanja: mehanizam za obradu konverzacije, mehanizam za obradu asocijacija, mehanizam za obradu pravila mehanizam za obradu kriterija i izbor materijala, mehanizam za izbora postupaka modificiranja površina. U eksperimentalnom dijelu rada dan je plan izgradnje inteligentnog sustav za izbor materijala, način prikaza rezultata eksperimenta te pregled softverskih alata. Prikazani su načini mapiranja ulazno-izlaznih skupova za učenje neuronskih mreža i mehanizama zaključivanja neizrazite (*fuzzy*) logike. Prikazan je način kreiranja vremenskih asocijativnih matrica odgovornih za dobivanje i objašnjenje rješenja razmatranog problema. Prikazan je način optimiranja parametara neuronskih mreža genetičkim algoritmima, kao i primjena *NeuroFuzzy* modela neizrazite logike. Dan je konkretni primjer načina rada mehanizma zaključivanja inteligentnog sustava za izbor materijala.

KLJUČNE RIJEČI: Izbor materijala, umjetna inteligencija, neuronske mreže, neizrazita logika, genetički algoritmi, ekspertni sustavi.

S U M M A R Y

In the work, current artificial intelligence methods are concisely presented: neural networks, fuzzy logic, genetic algorithms and expert systems. Structure of the designed intelligent system for material selection in tribological conditions is described detailedly, as well as the ways for improvement of its main inference engine component. The subengines of the main inference engine are also presented: conversation processing engine, associations processing engine, rules processing engine, criteria processing & material selection engine, engine for selection of surface modification processes. In experimental part of the work, concept for construction of the intelligent system for material selection is given, as well as the method how to present the experimental results and an overview of software tools. Mapping methods of the input-output data for training of neural networks and inference engines using *fuzzy* logic are presented. Procedure for creating of the time associative matrices which manage obtaining and explanation of the solution of the analyzed problem is presented. Optimizing of neural network using genetic algorithms is presented, as well as application of *NeuroFuzzy* model of fuzzy logic. An actual example illustrating operating principle of inference engine of the intelligent system for material selection is provided.

KEY WORDS: material selection, artificial intelligence, neural networks, fuzzy logic, genetic algorithms, expert systems.

1. UVOD

1.1. Uvod

Prema definiciji, ekspertni sustavi (*ES*) su inteligentni računalni programi koji primjenjuju ugrađeno ljudsko znanje u cilju rješavanja problema koji su dovoljno teški te zahtijevaju značajnu ljudsku vještinu i stručnost (ekspertizu) za rješavanje. Pored baze znanja, jedna od najvažnijih cjelina svakog *ES-a* je mehanizam zaključivanja. Mehanizam zaključivanja odgovoran je za zahvaćanje znanja iz baze, njegovog povezivanja u suvislo rješenje, te na kraju tumačenje istog. Ove, naizgled jednostavne zadatke, nije lako postići. Naime, u počecima razvoja umjetne inteligencije (engl. *Artificial Intelligence -AI*) među istraživačima prevladalo je uvjerenje da se može izgraditi takav *ES* s pripadnim mehanizmom zaključivanja, koji će biti sposoban donositi suvisla rješenja neovisno od baze znanja, tj. baze iz bilo kojeg područja ljudske djelatnosti. Naravno, u tome se nije uspjelo, ali se došlo do zaključka da je moguće izgraditi *ES* koji će uspješno rješavati probleme iz nekog uskog i dobro definiranog područja. Taj se pristup pokazao kao ispravan kroz čitav niz komercijalno uporabljivih *ES-ova*. Mehanizam zaključivanja stoji između korisnika *ES-a* i baze znanja čija je struktura točno određena. Uobičajene strukture su kombinacija *AKO-TADA* pravila i okvira (engl. *frame*). U užem smislu, mehanizam zaključivanja obavlja dva osnovna zadatka: Prvo, ispituje postojeće činjenice i pravila te dodaje nove činjenice kada je to moguće (zaključivanje), i drugo, određuje redoslijed zaključivanja preko konverzacije s korisnikom. Uočena je težnja da se mehanizam zaključivanja učini što neovisnijim od baze znanja, kako bi odgovarao za što više različitih područja problema. To je naročito vidljivo kod raznih proizvođača tzv. ‘školjki’ (engl. *shell*) ekspertnih sustava, pa je tako značajan kriterij izbora školjke broj tipova problema koje njezin mehanizam zaključivanja može uspješno rješavati. S obzirom na činjenicu da baze znanja mogu sadržavati i više desetaka tisuća pravila (npr. *ES-ovi* iz područja medicine, geoloških istraživanja) postavlja se pitanje praćenja logike zaključivanja koja je ‘proizvela’ rješenje koje se predlaže kao ispravno, a posebice sigurnost istog. Praćenje slijeda zaključivanja u zadovoljavajućoj je mjeri riješena poznatim tehnikama ulančavanja principom ‘unaprijed-unazad’. Čini se da je sa procjenom sigurnosti rješenja koje predlaže *ES* situacija u najvećoj mjeri nezadovoljavajuća. Iako se u stručnoj literaturi predlažu modeli izračunavanja sigurnosti rješenja, mali je broj izgrađenih *ES-ova* koji unutar baze znanja sadrže i faktore sigurnosti činjenica i pravila. Razlog ponajprije leži u činjenici da još nije moguće shvatiti i matematički opisati misaone procese u čovjeka-stručnjaka koji rješava problem. Mehanizam zaključivanja bit će predmet daljnjih istraživanja još dugi niz godina.

Zamišljeno poboljšanje mehanizma zaključivanja koje se predlaže kao tema ove disertacije, provjeriti će se u području problematike tribološkog trošenja materijala zbog više razloga. Riješiti problem trošenja znači izabrati materijal (tribo-par) koji će se u danim uvjetima najmanje trošiti. S obzirom da niti do danas nije do kraja objašnjena sama fizika procesa trošenja s kojom bi se složili svi koji se bave problemima trošenja, nije jednostavno iznaći opći algoritam za izbor materijala u uvjetima trošenja, a posebice kada se u kriterije izbora uključe uvjeti koji vladaju u okolini tribosustava kao što je npr. agresivni medij. Na temelju mehanizma trošenja postavljaju se kriteriji za izbor materijala, pa je ključno utvrditi dominantni mehanizam trošenja. Dijelovi koji se troše često su osim trošenju, izloženi i mehaničkim (dinamičkim) naprezanjima te je potrebno postaviti kriterije za izbor materijala istovremeno otpornih dinamičkim opterećenjima i otpornih trošenju. Danas se za površine izložene trošenju, sve više primjenjuju neki od postupaka modificiranja i prevlačenja površina čime se značajno utječe na trajnost i ekonomičnost. Postupaka prevlačenja i modificiranja površina te njihovih varijacija ima značajan broj, te se postavlja pitanje koji od njih, i u kojim slučajevima primijeniti. Zbog takvih situacija materijali otporni na trošenje biraju se u većini slučajeva pokušavanjem, na temelju analogije s već poznatim ili sličnim rješenjima, zatim na temelju iskustva, te na temelju podataka iz literature. Ovakva kvalitativna opisanost područja problema preduvjet je za izgradnju svakog *ES-a*, a posebice njegovog najvažnijeg dijela – mehanizma zaključivanja.

1.2. Pregled dosadašnjih saznanja

Analizom stručne literature iz područja inženjerstva unutar posljednjih deset godina, stječe se dojam, da od aktualnih metoda umjetne inteligencije (ekspertni sustavi, neuronske mreže, neizrazita logika, genetički algoritmi) prednjači primjena neuronskih mreža. Na drugom mjestu je metodologija neizrazite logike. Zaključuje se, da je glavni uzrok ovakvog redoslijeda u primjeni metoda umjetne inteligencije, ograničenje u načinu predstavljanja znanja danas najraširenije metode umjetne inteligencije - ekspertnih sustava. Kod ekspertnih sustava znanje je računalu predstavljeno pomoću tzv. *AKO-TADA* pravila. Ograničenje ovakvog načina predstavljanja znanja je nemogućnost sagledavanja svih interakcija varijabli unutar sustava. Veliki broj interakcija varijabli kod složenih sustava rezultira velikim brojem pravila koja je potrebno eksplicitno programirati. Može se zaključiti da je primarni cilj primjene novijih metoda umjetne inteligencije izbjegavanje eksplicitnog programiranja znanja, te iznalaženje takvih algoritama koji će znanje o problemu preslikati u prikladni matematički oblik. Smatra se, da složeni problemi poput izbora materijala, nužno zahtijevaju integraciju više metoda u tzv. *hibridni* sustav. U području znanosti o materijalima, a prema navedenim literaturnim izvorima, nije uočena integracija nabrojanih metoda umjetne inteligencije na način opisan u radu. Tvrdnju potkrepljuju karakteristični primjeri parcijalne primjene metoda umjetne inteligencije u radovima [1,2,3,4,5,6,7,35].

U radu [1] predstavljena je metodologija ekspertnih sustava. Opisan je *ABRex*, ekspertni sustav za rješavanje problema abrazijskog trošenja. *ABRex*, analizira tribosustav, određuje dominantni mehanizam trošenja te predlaže prikladni materijal otporan trošenju. U radu je prikazana primjena *hipergrafike* i *hiperteksta*, kao metoda za poboljšanje konverzacije sustav-korisnik. Također je prikazan primjer konverzacije između korisnika i sustava, te način donošenja i objašnjenja rješenja problema. Znanje je predstavljeno pravilima, a mehanizam zaključivanja temelji se na metodi *ulančavanja unaprijed-unazad*.

Rad [2] predstavlja primjenu metodologije neuronskih mreža za predviđanje mehaničkih svojstva konstrukcijskih čelika. Na temelju kemijskog sastava, te stanja u kojem se materijal nalazi (normaliziran, popušten) predviđaju se sljedeća mehanička svojstva: $R_{p0,2}$ -konvencionalna granica razvlačenja u MPa, R_m -vlačna čvrstoća u Mpa i A-istezljivost u %. Primjenjena je višeslojna mreža sa povratnim rasprostiranjem pogreške. Postignuta je dobra generalizacija problema kako na podacima za učenje tako i na podacima za testiranje.

Rad [3] također predstavlja primjenu metodologije neuronskih mreža na problematici prepoznavanja mikrostrukture materijala (čelici i ljevovi). Primjenjeni RBF-algoritam neuronske mreže ima značenje klasifikatora prilikom prepoznavanja. Rad mreže temelji se na rezultatima učenja karakteristika bitmapiranih fotografija mikrostrukture. Modelirana mreža pokazuje visoki stupanj generalizacije na testnim fotografijama mikrostrukture.

Rad [4] predstavlja opširno izvješće o mogućnosti primjene neuronskim mreža u području znanosti o materijalima. U radu su uspoređivane klasične metode (multivarijabilna linerana regresija) generalizacije podataka sa neuronskim mrežama. Prema prikazanim rezultatima ispitivanja, zaključeno je da se bolja generalizacija postiže neuronskim mrežama.

Rad [5] uspoređuje rezultate primjene neuronskih mreža i relativno nove metode umjetne inteligencije -genetičkih (*GA*) algoritama, u području toplinske obradbe za određivanje parametara nitiranja. Koristeći evolucijske algoritme, *GA* uspješno zamjenjuju klasične statističke metode kao što je npr. multivarijabilna nelinearna regresija.

Rad [6] također se bavi problematikom primjene neuronskim mreža u području toplinske obradbe i to za sljedeće grupe problema: Predviđanje tvrdoća na krivulji prokaljivosti čelika na

temelju rezultata Jominy ispitivanja, predviđanje otpornosti na popuštanje, određivanje koeficijenta toplinske vodljivosti, određivanje trajanja nitiranja u plazmi i površinske tvrdoće za zadani sastav čelika.

U radu [7] opisuje se sustav 'CADET', temeljen na neizrazitoj logici. Primjenjuje se za izbor materijala u slučajevima kada su kriteriji izbora zadani neprecizno. Konceptcija sustava temelji se na tzv. *Ashby* –jevim kartama [53].

Rad [35] prikazuje primjer primjene neuronske mreže u toplinskoj obradbi i to za slučaj određivanja C-potencijala kod pougljičavanja čelika. Za zadani kemijski sastav materijala, temperaturu pougljičavanja i efektivnu dubinu pougljičavanja predviđa se vrijeme trajanja pougljičavanja te potreban C-potencijal. Rezultati dobiveni modelom neuronske mreže vrlo dobro se podudaraju sa rezultatima dobivenim matematičkim modelom koji se temelji na *Fick*-ovom zakonu.

1.3. Hipoteza rada

Kao što vidi iz prethodne točke, uočljiv je parcijalni pristup u načinu rješavanja problematike izbora materijala primjenom različitih aktualnih metoda umjetne inteligencije kao što su: ekspertni sustavi, neuronske mreže, neizrazita logika. Hipoteza rada zapravo je proizišla proučavanjem metoda ekspertnih sustava, kod čijeg su rada uočena dva problema, koja čini se nisu riješena na zadovoljavajući način.

Prvo, kvaliteta zaključka (suvislost rješenja) koje predlažu današnji algoritmi zaključivanja ekspertnih sustava ovise o 'ozbiljnosti odgovora' koje daje korisnik sustavu ili o njegovoj 'koncentraciji' u tijeku konverzacije. S obzirom na činjenicu da ES može postaviti veliki broj pitanja, korisnik može svjesno ili nesvjesno davati manje ili više kvalitetne odgovore. Takvi odgovori mogu odvesti tijekom zaključivanja u pogrešnom smjeru.

Drugi problem je pitanje sigurnosti predloženog rješenja. Kod rješavanja složenih problema, pri izgradnji *ES-a* može sudjelovati više stručnjaka-eksperta koji različito procjenjuju poznate činjenice koje utječu na zaključak, pa jedan te isti zaključak u smislu pouzdanosti ili sigurnosti može imati više vrijednosti. U prvom slučaju je dakle potrebno procijeniti kvalitetu odgovora koje daje korisnik te eventualno odstupanje na '*intelligentan*' način otkloniti. U drugom slučaju potrebno je iznaći takve algoritme čija bi primjena unutar mehanizma zaključivanja rezultirala što je moguće većom sigurnošću tj. pouzdanošću krajnjeg rješenja. Smatra se da bi integracijom postojećih aktualnih metoda umjetne inteligencije bilo moguće uspješno riješiti uočene probleme te se na temelju ovih razmatranja postavlja hipoteza ove disertacije:

Brzina odlučivanja i pouzdanost rješenja inteligentnog ekspertnog sustava (*ES-a*) za izbor materijala otpornih trošenju mogu se poboljšati integracijom algoritama aktualnih metoda umjetne inteligencije (ekspertni sustavi, neuronske mreže, neizrazita logika) unutar mehanizma zaključivanja.

1.4. Metodologija rada

Poboljšanje mehanizma zaključivanja *ES-a* postići će se kombinirajući najpoznatije metode umjetne inteligencije (*AI*): teorija neizrazitih logičkih skupova (engl. *fuzzy logic sets*) te neuronskih mreža (engl. *neural networks*). Kombinacija ovih dviju metoda u literaturi je poznatija kao *NeuroFuzzy* metoda što je danas vrlo aktualno područje istraživanja. U stručnoj literaturi iz područja materijala nije pronađen problem čije se rješenje temelji na umjetnoj inteligenciji, a koja istovremeno koristi metodologiju ekspertnih sustava, neuronskih mreža, neizrazite (*Fuzzy/NeuroFuzzy*) logike. Predviđena je izgradnja ekspertnog sustava sa takvim mehanizmom zaključivanja koji će sadržavati sljedeće mehanizme (engl. *engines*) za objašnjavanje i zaključivanje: 1. *Kako?*: objašnjava predloženo rješenje, redoslijed ispaljivanja pravila te slijed zaključivanja sa faktorima sigurnosti; 2. *Što ako?*: omogućava promjene bilo koje varijable (odgovora) te ponovno razmatranje predloženog rješenja od strane *ES-a*; 3.

Zašto?: objašnjava trenutno postavljeno pitanje te pojmove unutar istog; 4. *Rješenje?*: daje rješenje u bilo kojem trenutku konverzacije. U mehanizam zaključivanja ugraditi će se procedure (engl. *demon procedures*) koje će automatski predlagati rješenje nakon prikupljanja određenog broja činjenica. Predložiti će se posebna konstrukcija IF-THEN pravila koja će sadržavati: funkcije ulančavanja unaprijed-unazad, funkcije za izračunavanje faktora sigurnosti (engl. *CNF*) premisa i zaključka pravila, funkcije za provjeru ispaljivanja pravila u zavisnosti od postavljenog globalnog praga sigurnosti. Pojedina pravila unositi će se nezavisno o drugih pravila, a razviti će se i funkcije za pristup *okvir* bazama znanja koje će se moći uključiti unutar premisa pravila. Pri razvoju strukture *okvir* baza znanja razvit će se funkcije koje omogućavaju nasljeđivanje karakteristika od nadređenog *okvira*.

Teorijom neizrazitih skupova (engl. *fuzzy sets*) riješit će se razne iskustvene procjene prilikom postavljanja kriterija izbora materijala. Tako će se npr. *fuzzy* teorijom riješiti procjena gubitka volumena onih materijala za koje ne postoje kvantitativni podaci. Također će se *fuzzy* teorijom riješiti i procjena dominantnog mehanizma trošenja s obzirom na broj funkcionalnih dijelova te subjektivne procjene određenog relativnog gibanja. Kao glavni algoritam *fuzzy* teorije primijeniti će se *Mamdani* model.

Rad neuronske mreže temeljit će se na praćenju faktora sigurnosti pojedinih logičkih dijelova baze znanja pravila. Da bi se potvrdila razmatranja postavljena unutar hipoteze rada predviđeno je da mehanizam zaključivanja ES-a pamti faktore sigurnosti svih ispaljenih pravila. Ako korisnik pomoću sustava objašnjavanja ES-a procijeni da predloženo rješenje ima smisla, logično je itd., pohranit će se faktori sigurnosti svih ispaljenih pravila koja su dovela do smislenog rješenja. Nakon određenog broja konverzacija ES - korisnik, te spremanja faktora sigurnosti svih pravila koja su dovela do smislenog rješenja u strukturu za ulazno-izlazni set učenja neuronske mreže, rezultat učenja mreže moći će se opisati kao: 'Postoje točno određene varijable (pravila) u bazi znanja koje svojom sigurnošću u najvećoj mjeri doprinose određivanju npr. dominantnog mehanizma - abrazije'. Pretpostavka je da bi u tom slučaju određena odstupanja u odgovorima korisnika manje utjecale na to da zaključivanje ode u pogrešnom smjeru, kojeg bi klasični mehanizam zaključivanja smatrao točnim te bi predloženo rješenje bilo manje kvalitetno ali relativno sigurno s obzirom na točno izračunavanje faktora sigurnosti. Također, pretpostavlja se da bi takav pristup omogućio ES-u da na temelju relativnog malog broja odgovora korisnika dođe brže do kvalitetnog i sigurnog rješenja.

Za testiranje postavljene hipoteze izgradit će se baze podataka i znanja o klasičnim materijalima otporni na trošenje (čelici, ljevovi) kao i o postupcima modificiranja i prevlačenja metala. Razradit će se određeni broj riješenih slučajeva iz prakse te će se na temelju analize istih izgraditi baza pravila sa faktorima sigurnosti.

2. TEORIJSKI DIO

2.1. Kratki opis metoda umjetne inteligencije

Rad i imitacija rada ljudskog mozga računalom 'vječita' je inspiracija za znanstvenike. Postići da računalo samostalno rješava zadatke bez eksplicitnog programiranja istih je cilj koji nije lako postići. U početnim stadijima razvoja umjetne inteligencije 60-tih godina (paralelno razvoju računala) prevladavalo je mišljenje da je 'samo' pitanje vremena kada će ljudski rod biti u mogućnosti proizvesti računalo koje će biti u stanju imitirati rad ljudskog mozga, te da je taj problem jedino povezan sa brzinom procesora računala. Iako je danas umjetna inteligencija na zavidnoj razini, problem je još daleko od rješavanja. Posljedica dugogodišnjeg intenzivnog istraživanja iz područja, je razvoj raznih metoda umjetne inteligencije koje su prikladne za rješavanje specifičnih problema, a njihov način rješavanja problema može se smatrati 'intelligentnim'. Glavni razlog primjene metoda umjetne inteligencije u radu je zapravo izbjegavanje tzv. *kombinatorne eksplozije* koja je moguća ako se primjenjuju klasične metode izbora materijala. Vrste i svrha metoda umjetne inteligencije primjenjenih u radu su sljedeće:

1. Neuronske mreže – za procjenu različitih svojstava čelika na temelju kemijskog sastava, za procjenu prikladnih postupaka modificiranja površina, za inicijalizaciju asocijacija o prethodno naučenim procjenama svojstava, za učenje **novih procjena svojstava;**
2. Neizrazita logika – za procjenu određenih svojstava čelika u slučajevima kada je na raspolaganju relativno mali skup ulaznih podataka za učenje;
3. 'NeuroFuzzy' – za procjenu svojstava čelika kada je znanje 'sakriveno' unutar eksperimentalnih podataka, te je otežano postavljanje pravila i oblika funkcija neizrazitih skupova;
4. Genetički algoritmi – za optimalizaciju parametara učenja algoritama neuronskih mreža;
5. Ekspertni sustavi – za povezivanje primjenjenih metoda umjetne inteligencije u cjeloviti sustav, za **kontrolu i praćenje konverzacije sustava sa korisnikom, za donošenje zaključka o rješenju razmatranog problema, te objašnjenje istog.**

Slijedi kratki opis današnjih pet aktualnih metoda umjetne inteligencije, primjenjenih pri istraživanju u ovom radu.

1. Neuronske mreže

Originalna ideja za umjetnu neuronsku mrežu generirala se je iz niza pokušaja modeliranja biofiziologije mozga čovjeka, s ciljem razumijevanja i objašnjenja kako isti funkcionira. Ta ideja podrazumijeva kreiranje modela sposobnog procesuirati (prihvaća, obrađuje, generira, pohranjuje i prenosi) informacije, analogno aktivnostima mozga čovjeka. William James [8] postavlja 1890. godine, sljedeću tvrdnju: Aktivnost bilo koje točke mozga čovjeka predstavlja zbroj tendencija svih ostalih točaka da se "prazne" (ispaljuju) u nju. Ova temeljna tvrdnja poslužila je za izgradnju osnovne strukture umjetnog neurona. Naime, ako se određena točka u mozgu čovjeka zamijeni neuronom, onda se aktivnost neurona može modelirati kao zbroj "otežanih" ulaza neurona. Otežani ulazi jesu ulazi pomnoženi određenim faktorima koji se nazivaju *težine* neurona. Prema tome aktivnost umjetnog neurona ovisi o : *broju ulaza* (veza) iz okoline (okruženja) neurona, *intenzitetu tih veza* (iznosu težinskih faktora), te o *pragu osjetljivosti* koji stanje neurona mora dosegnuti prije nego što "ispali impuls" preko svog izlaza u okolinu neurona koju čine ostali neuroni umjetne neuronske mreže. Danas se neuronske mreže primjenjuju se u područjima kao što su: klasificiranju signala, kontroli vođenju sustava, robotici, području identifikacije složenih dinamičkih sustava, u medicinskoj dijagnostici, *itd.*

2. Neizrazita (fuzzy) logika

Neizrazita logika na neki način predstavlja 'proširenje' klasične logike s razlikom u baratanju relativno nepreciznim pojmovima kao što su npr. *visoka temperatura* ili *niska temperatura*. Neprecizni pojmovi se kod neizrazite logike predstavljaju kao lingvističke varijable (npr. *temperatura*), a svakoj se varijabli dodjeljuje određeni broj tzv. *neizrazitih (fuzzy) setova* (*visoka, niska*) koji ju opisuju. Ulazno-izlaznim

lingvističkih varijabla sa pripadnim neizrazitim setovima može se pomoću *ako-tada* pravila opisati ponašanje složenih sustava kod kojih je teško definirati matematički model. Karakteristika neizrazite logike (nakon primjena metoda *fazifikacije* i *defazifikacije* varijable) je ta što je ulazna vrijednost varijable realan broj koji se preslikava u lingvističku vrijednost (*neizraziti skup*), a izlaz je također realan broj. Prednost je neizrazite logike u tome što se ponašanje složenih sustava može opisati na način razumljiv čovjeku. Proširenje klasične neizrazite logike predstavlja tzv. *neurofuzzy logika* koja uključuje metode neuronskih mreža u cilju poboljšanja procjena izlaznog skupa lingvističkih varijabli. U nekoliko posljednjih godina zamjetno je povećanje broja aplikacija sa ugrađenom neizrazitom (*fuzzy*) logikom, posebno u području potrošačke elektronike (video kamere, perilice za rublje), zatim u procesnoj industriji, auto industriji, medicinskoj instrumentaciji, te kao podrška u sustavima pri odlučivanju.

3. 'NeuroFuzzy'

NeuroFuzzy je relativno nova metoda umjetne inteligencije, a predstavlja poboljšanje klasične (Lofti A. Zadeh-ove) [13] neizrazite logike uvođenjem neuronske mreže sa algoritmom *povratnog prostiranja pogreške* (engl. *backpropagation*), kao pomoć pri optimalizaciji funkcija pripadnosti i baze pravila. Potreba za uvođenjem neuronske mreže nastala je pri modeliranju funkcija neizrazitih skupova lingvističkih varijabli na temelju eksperimentalnih podataka, a zbog problema ugađanja oblika i položaja funkcija pripadnosti unutar univerzalnog skupa lingvističke varijable. Time se postiže značajno smanjenje vremena za modeliranje baze pravila neizrazitog sustava, te kasnija efikasnost istog pri rješavanju problema.

4. Genetički algoritmi

Genetički algoritmi temelje se na modelima prirodne evolucije, a spadaju u područje tzv. *evolucijskog računarstva* (engl. *evolutionary computation*). Inteligencija se u ovom području definira kao *spособnost prilagodbe ponašanja sustava okolini koja se stalno mijenja*. Način ponašanja nekog individualnog organizma u okolini temelji se na tzv. induktivnom zaključivanju o još nepoznatim aspektima okoline. Ako organizam preživi, te ako se reproducira kroz više generacija, kaže se da je taj organizam sposoban učenju predviđanja promjena u njegovoj okolini. Ta sposobnost organizma zove se *evolucijska prikladnost* (engl. *evolutionary fitness*) te predstavlja kvantitativnu mjeru za sposobnost organizma za predviđanje promjena u njegovoj okolini. Metode evolucijskog računarstva simuliraju prirodnu evoluciju stvaranjem populacija jedinki, procjenjuju evolucijske prikladnosti, generiraju nove jedinke primjenom genetičkih operatora, ponavljajući proces dok se ne postigne zadovoljavajući nivo prilagodbe. Najčešća je primjena genetičkih algoritama u području inženjerstva pri rješavanju raznih problema optimalizacije. U novije se vrijeme genetički algoritmi [15] upotrebljavaju za optimalizaciju parametara algoritama neuronskih mreža i neizrazite logike u procesu učenja.

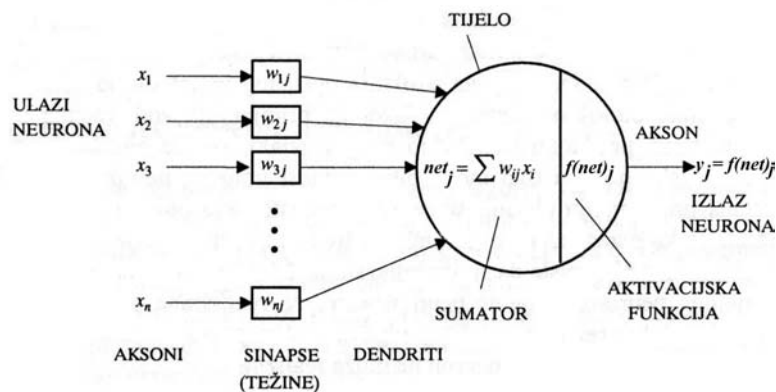
5. Ekspertni sustavi

Ekspertni sustavi su računalni programi koji na temelju ugrađenog ljudskog znanja (najčešće u obliku pravila) rješavaju određeni problem iz specifičnog područja [19,20]. Ugrađeno znanje osim činjenica, sadrži i informacije o tome kako se te činjenice povezuju u logičan slijed zaključivanja. Najvažnije komponente u strukturi svakog ekspertnog sustava su: *baza znanja* i *mehanizam zaključivanja*. Baza znanja u kodiranom obliku sadrži zbirku potrebnih elemenata znanja iz područja razmatranog problema. Zadatak komponente zaključivanja je izabrati elemente znanja iz baze znanja, te ih na kraju povezati u suvisli zaključak. Kvaliteta zaključka koji donosi mehanizam zaključivanja, ovisi od tzv. *kommunikacijske komponente* ekspertnog sustava, čiji je zadatak osigurati potrebne informacije najčešće putem dijaloga (pitanje-odgovor) s korisnikom. Važno je napomenuti da mehanizam zaključivanja ne ovisi o vrsti razmatranog problema za razliku od baze znanja. Zbog poboljšanja efikasnosti, često ekspertni sustavi uključuju ovdje nabrojane metode umjetne inteligencije čime se dobivaju tzv. *hibridni ekspertni sustavi*. Najčešća je primjena ekspertnih sustava je u sljedećim područjima: medicina, kemijska industrija, poljoprivreda, računalne znanosti, meteorologija, procesna industrija, vojna industrija itd.

2.2. Backpropagation (BP) neuronske mreže

2.2.1. Uvod

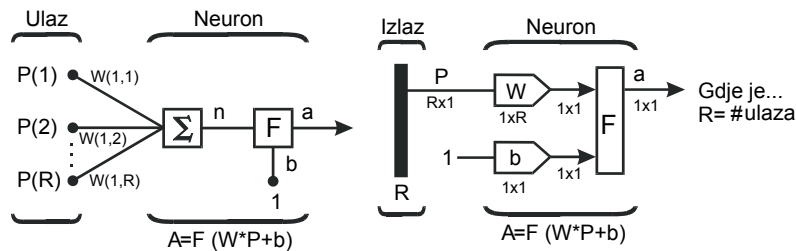
Na slici 2.1 prikazan je model umjetnog neurona (engl. *neuron, node, unit*) koji oponaša osnovne funkcije biološkog neurona [8]. Tijelo biološkog neurona zamjenjuje sumator, ulogu dendrita preuzimaju ulazi u sumator (x_1, x_2, \dots, x_n), izlaz iz sumatora je akson umjetnog neurona, a uloga praga osjetljivosti bioloških neurona preslikava se na tzv. *aktivacijske funkcije* $f(\text{net})_j$. Funkcije sinaptičke veze biološkog neurona s njegovom okolinom preslikavaju se na *težinske faktore* ili *težine* (w_{ij}), preko kojih se i ostvaruje veza umjetnog neurona s njegovom okolinom. Težinski faktori ili težine povezuju izlaze iz okoline neurona, odnosno izlaze drugih neurona s ulazima sumatora. Težinski faktor ili težina može biti nula, pozitivan ili negativan broj. Kada je težina jednaka nuli, to znači da ne postoji veza neurona sa okolinom. Izlaz iz sumatora producira izlaz umjetnog neurona y_j .



Slika 2.1. Model umjetnog neurona [8]

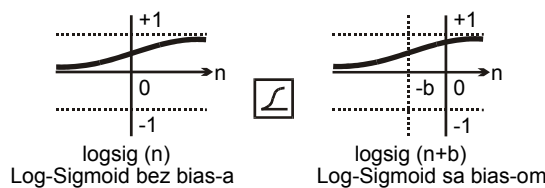
2.2.2. Struktura BP neuronske mreže

Jednostavni neuron sa R ulaza prikazan je na slici 2.2 prema notaciji iz [9]. Svakom ulazu od $P(1)$ do $P(R)$ dodijeljena je odgovarajuća težina ili težinski faktor $w(i,j)$. Suma produkta pojedinačnih iznosa ulaza i težina sa iznosom *bias* vektora b predstavlja ulaz u aktivacijsku funkciju F koja generira izlaz a . Aktivacijska funkcija može biti bilo koja diferencijabilna funkcija.



Slika 2.2 Prikaz *backpropagation* modela neurona [9]

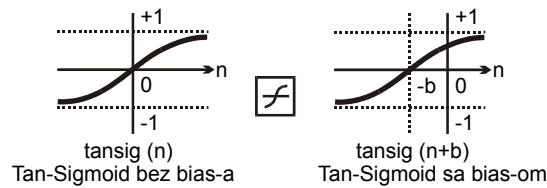
Kod višeslojnih neuronskih mreža najčešće se koriste aktivacijske funkcije *log-sigmoid* tipa, slika 2.3.



Slika 2.3. Aktivacijske funkcije *log-sigmoid* tipa [9]

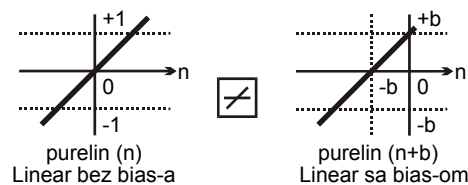
Aktivacijske funkcije generiraju izlaze iz mreže koji imaju vrijednosti između 0 i 1 i to za ulaze u mrežu čiji se iznosi kreću iz ‘-’ beskonačnosti do ‘+’ beskonačnosti. Kao što je pokazano na slici 2.3 *log-*

sigmoid aktivacijske funkcije mogu biti sa ili bez *bias*-a. Unošenjem *bias* vrijednosti u aktivacijsku funkciju postiže se viši stupanj slobode učenja mreže, te se povećava vjerojatnost mreže za pronalaženje prihvatljivog rješenja uz istovremeno smanjenje broja epoha potrebnih za učenje (treniranje) mreže.



Slika 2.4. Aktivacijske funkcije *tan-sigmoid* tipa [9]

Alternativno, kod neuronskih mreža sa *povratnim prostiranjem pogreške* (engl. *backpropagation*, u daljnjem tekstu *BP*) mogu se upotrijebiti i aktivacijske funkcije *tan-sigmoid* tipa, prikazanih na slici 2.4 ili *lin* tipa prikazanih na slici 2.5, također sa *bias*-om ili bez *bias*-a.

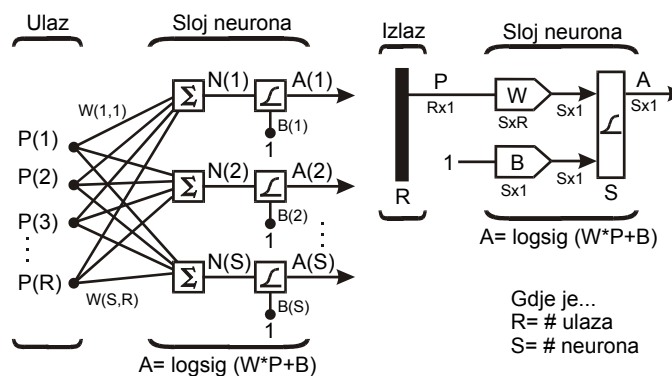


Slika 2.5. Aktivacijske funkcije *lin* tipa [9]

Ako se u posljednjem sloju *BP* neuronske mreže nalazi aktivacijska funkcija *sigmoidalnog* tipa, tada su izlazi iz mreže ograničeni na vrijednosti u području 0 do +1. Ako pak je *linernog* tipa, tada izlazi iz mreže mogu poprimiti bilo koju vrijednost.

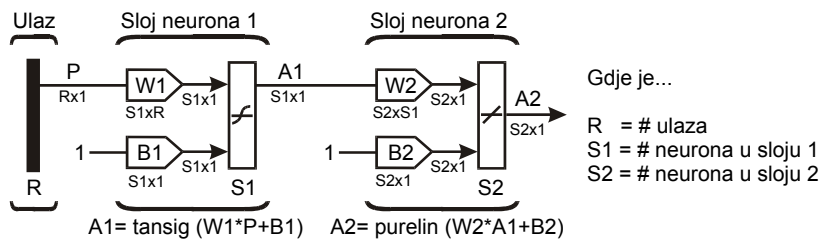
Osim što su diferencijabilne ove aktivacijske funkcije su i monotono rastuće, što znači da iznos funkcije povećava proporcionalnu povećanju nezavisnih varijabli. Ovo su najčešća tri tipa aktivacijskih funkcija koje se upotrebljavaju kod *BP* neuronskih mreža, ali kao što je već spomenuto mogu se primijeniti bilo koje diferencijabilne funkcije.

Na slici 2.6 prikazana je jednoslojna unaprijedna *backpropagation* mreža sa R ulaza sa aktivacijskom funkcijom *sigmoidalnog* tipa. Unaprijedne *BP* mreže najčešće imaju jedan ili više skrivenih slojeva sa *sigmoidalnim* aktivacijskim funkcijama nakon čega obično slijedi izlazni sloj linearnog tipa. Više slojeva sa nelinearnim aktivacijskim funkcijama omogućava da mreža nauči nelinearne i linearne interakcije između ulaznih i izlaznih vektora. Linearni izlazni sloj omogućava da izlaz iz mreže poprimiti vrijednost izvan intervala -1 do $+1$. S druge strane, ako želimo da je izlaz iz mreže u granicama 0 i 1 tada izlazni sloj mreže treba bit sastavljen od *sigmoidalnih* aktivacijskih funkcija.



Slika 2.6. Shema jednoslojne unaprijedne *BP* mreže [9]

Na slici 2.7 prikazana je shema uobičajene unaprijedne *BP* mreže sa linearnim izlaznim slojem čija je najčešća primjena pri aproksimaciji funkcija.

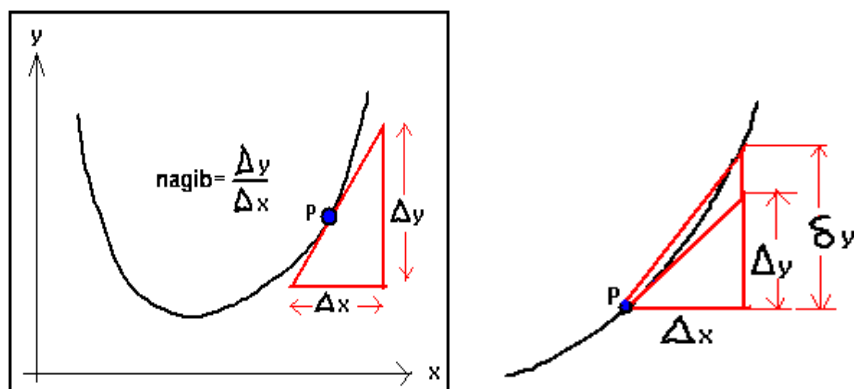


Slika 2.7. Shema dvoslojne unaprijedne backpropagation mreže [9]

Na prethodnim slikama ‘#’ predstavlja skraćenicu za riječ ‘broj’. Oznaka R predstavlja broj ulaza, B je bias vektor, F je oznaka za aktivacijsku funkciju, W je vektor težina, S je broj neurona u pojedinom sloju i A (engl. *actual*) je vektor izračunatih izlaznih vrijednosti iz mreže.

2.2.3. Algoritam učenja BP mreža

Većinom se algoritmi učenja BP mreža temelje na primjeni *algoritma najstrmijeg pada* (engl. *gradient or steepest descent*) za pronalaženje minimuma funkcije. Pretpostavimo da je $y=f(x)$ čiji točan oblik nije poznat, te se želi pronaći x -koordinata gdje funkcija ima minimum, slika 2.8 Tada se izraz $\text{nagib} = \Delta y / \Delta x$ koji prolazi bilo kojom točkom te funkcije naziva gradijent (nagib) tangente.

Slika 2.8. Gradijent ili nagib tangente funkcije $y=f(x)$ [11]

Ako je Δx mali tada je i Δy mali tako da imamo:

$$\delta y \approx \Delta y = \frac{\Delta y}{\Delta x} \Delta x, \quad (2.1)$$

$$\delta y \approx \text{nagib} \times \Delta x. \quad (2.2)$$

Ako stavimo da je

$$\Delta x = -\alpha \times \text{nagib}, \quad (2.3)$$

gdje je $\alpha > 0$ te dovoljno mali da je $\delta y \approx \Delta y$ tada je

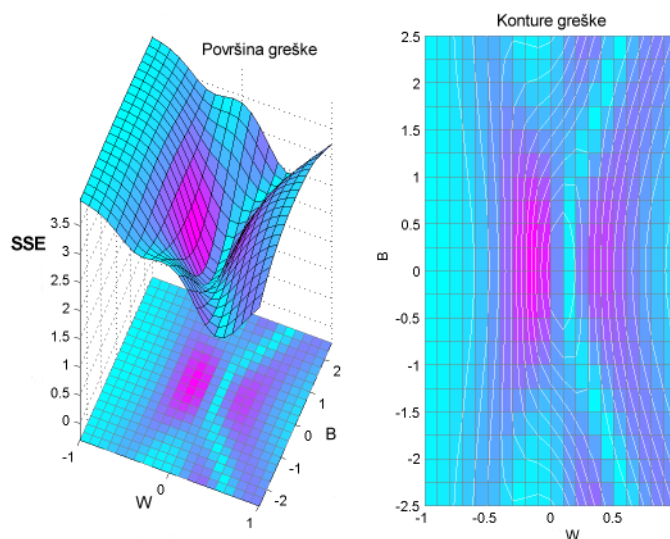
$$\delta y \approx -\alpha (\text{nagib})^2. \quad (2.4)$$

Kada je $\delta y < 0$, nagib teži nuli te se na taj način približavamo točki gdje funkcija ima minimum. Pri učenju neuronske mreže primjenom algoritma najstrmijeg pada izračunava se nagib ili gradijent G funkcije $E=f(w)$ koju nazivamo pogreška (engl. *loss, objective, error*). E je zapravo funkcija težina w_{ij} za pojedini p_i ulaz u mrežu, slika 2.9.

Slika 2.9. Funkcije greske $E=f(w)$ [11]

E je definirana kao **suma kvadrata pogreške** - *SSE* (engl. *sum squared error*) između izlaznih (t_i) i ulaznih (y_i) vektora podataka:

$$E = \frac{1}{2} \sum_{i=1}^n (t_i - y_i)^2 \equiv SSE, \quad (2.5)$$

Slika 2.10. Prikaz *SSE* površine kao funkcije od W i B [9]

Na slici 2.10 je prikazan primjer trodimenzionalnog i dvodimenzionalnog grafa *SSE* funkcije u zavisnosti od vektora težina W i bias vektora B .

Pretpostavimo da želimo naučiti višeslojnu *BP* mrežu tako da bude aproksimator nepoznate funkcije i to na temelju parova vektora (x, t) . Vektor x predstavlja uzorke ulaznih podataka dok vektor t predstavlja uzorke izlaznih podataka. Kao što se može zaključiti iz slike 2.10, izračunavanje gradijenta G , odnosi se na svaki vektor težine w_{ij} unutar mreže, te nam govori o tome kako promjena težine utječe na ukupnu grešku E . U nastavku je prikazano izračunavanje gradijenta jediničnog uzorka za slučaj linearne a zatim i nelinearne *BP* neuronske mreže.

Izraz (2.5) također možemo napisati u obliku:

$$E = \sum_p E^p, \quad E^p = \frac{1}{2} \sum_o (t_o^p - y_o^p)^2, \quad (2.6)$$

gdje p predstavlja jednu točku iz skupa za učenje, a o područje (engl. *range*) skupa podataka za učenje, tada je izraz za gradijent G :

$$G = \frac{\partial E}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \sum_p E^p = \sum_p \frac{\partial E^p}{\partial w_{ij}}. \quad (2.7)$$

Zbog jednostavnosti izraza u nastavku će se izostaviti oznaka p . Ako gradijent G uz pomoć lančanog pravila (engl. *chain rule*) [10] rastavimo na dva faktora dobivamo:

$$\frac{\partial E}{\partial w_{oi}} = \frac{\partial E}{\partial y_o} \frac{\partial y_o}{\partial w_{oi}}. \quad (2.8)$$

Prvi faktor dobije se derivacijom izraza (1)

$$\frac{\partial E}{\partial y_o} = -(t_o - y_o). \quad (2.9)$$

Ako stavimo da je,

$$y_o = \sum_j w_{oj} y_j, \quad (2.10)$$

tada je drugi faktor:

$$\frac{\partial y_o}{\partial w_{oi}} = \frac{\partial}{\partial w_{oi}} \sum_j w_{oj} y_j = y_i. \quad (2.11)$$

Povezujući izraze (2.8 – 2.11) dobivamo konačan izraz za izračun gradijenta G za linearnu mrežu:

$$G = \frac{\partial E}{\partial w_{oi}} = -(t_o - y_o) y_i. \quad (2.12)$$

Ako uvedemo da je

$$net_i = \sum_j w_{ij} y_j \quad (2.13)$$

i

$$\delta_j = -\frac{\partial E}{\partial net_j}, \quad (2.14)$$

te da je

$$\Delta w_{ij} = -\frac{\partial E}{\partial w_{ij}}. \quad (2.15)$$

Tada izraz za gradijent prema (2.7) rastavljen na dva faktora pomoću lančanog pravila, poprima sljedeći oblik:

$$\Delta w_{ij} = -\frac{\partial E}{\partial net_i} \frac{\partial net_i}{\partial w_{ij}}. \quad (2.16)$$

Prvi faktor predstavlja grešku a drugi faktor je:

$$\frac{\partial net_i}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \sum_{k \in A_i} w_{ik} y_k = y_j. \quad (2.17)$$

Tada je konačan izraz za izračun gradijenta težine w_{ij} za nelinearnu BP mrežu:

$$\Delta w_{ij} = \delta_i y_j. \quad (2.18)$$

Za izračunavanje gradijenta prema izrazu (2.18) potrebno je poznavati iznose aktivnosti i greške svih neurona u mreži.

Aktivnost y_i i -tog neurona mreže izračunava se prema izrazu:

$$y_i = f_i \left(\sum_j w_{ij} y_j \right). \quad (2.19)$$

Pogreška E svih neurona mreže izračunava se prema izrazu,

$$E = \frac{1}{2} \sum_o (t_o - y_o)^2, \quad (2.20)$$

a pogreška izlaznog neurona prema izrazu

$$\delta_o = t_o - y_o. \quad (2.21)$$

Za izračun greške neurona u skrivenom sloju primjenjuje se algoritam pod nazivom **algoritam povratnog prostiranja pogreške** (engl. *error backpropagation*).

Tada je pogreška δ_j , j -tog neurona skrivenog sloja jednaka:

$$\delta_j = - \sum_i \frac{\partial E}{\partial net_i} \frac{\partial net_i}{\partial y_j} \frac{\partial y_j}{\partial net_j} \quad (2.22)$$

Prvi faktor unutar izraza (2.22) predstavlja grešku, a drugi faktor je iznos težine w_{ij} :

$$\frac{\partial net_i}{\partial y_j} = \frac{\partial}{\partial y_j} \sum_{k \in A_i} w_{ik} y_k = w_{ij}. \quad (2.23)$$

Treći faktor je derivacija aktivacijske funkcije j -tog neurona skrivenog sloja:

$$\frac{\partial y_j}{\partial net_j} = \frac{\partial f_j(net_j)}{\partial net_j} = f'_j(net_j). \quad (2.24)$$

Konačni izraz za izračun greške j -tog neurona skrivenog sloja je:

$$\delta_j = f'_j(net_j) \sum_{i \in P_j} \delta_i w_{ij}. \quad (2.25)$$

Kod unaprijednih višeslojnih BP mreža svaki je neuron iz promatranog sloja spojen sa svakim neuronom iz sljedećeg sloja. Prikkladnosti radi, često se BP algoritam iskazuje u matričnoj formi te se ulazi u mrežu,

bias-i (b), težine (w), aktivacijske funkcije, i pogreške prikazuju u vektorskoj formi za svaki pojedini sloj (L). Tada se *BP* algoritam sažeto može prikazati kako slijedi:

1. Inicijalizacija ulaznog sloja:

$$\mathbf{y}_0 = \mathbf{x}. \quad (2.26)$$

2. Rasprostiranje aktivnosti unaprijed: $l=1,2,\dots,L$

$$\mathbf{y}_l = f_l(W_l \mathbf{y}_{l-1} + \mathbf{b}_l), \quad (2.27)$$

gdje je l -ulazni sloj, L -izlazni sloj, a b -bias vektor težina

3. Izračunavanje greške izlaznog sloja

$$\delta_L = t - y_L. \quad (2.28)$$

4. Povratno prostiranje greške: od $L-1, L-2, \dots, 1$

$$\delta_l = (W_{l+1}^T \delta_{l+1}) f_l'(\text{net}_l), \quad (2.29)$$

gdje je T označava transponiranu matricu.

5. Promjena težina i bias-a:

$$\Delta W_l = \delta_l \mathbf{y}_{l-1}^T, \quad \Delta \mathbf{b}_l = \delta_l. \quad (2.30)$$

2.2.4. Modifikacije *BP* algoritma

Danas u primjeni nalazimo mnoge modifikacije prethodno opisanog osnovnog algoritma *povratnog prostiranja pogreške*. Međusobno se ti algoritmi razlikuju prema brzini konvergencije prilikom traženja rješenja, a razlike mogu biti čak do nekoliko stotina puta. Prema [9] razlikujemo dvije grupe algoritama kod unaprijednih statičkih *BP* mreža. Tzv. *spore* i *brze* algoritme. U *spore* algoritme npr. spadaju:

- *BP*-algoritam sa konstantnim koeficijentom brzine učenja (engl. *learning rate*) - μ ,
- *BP*-algoritam sa konstantnim koeficijentom momentuma (engl. *momentum*) - α

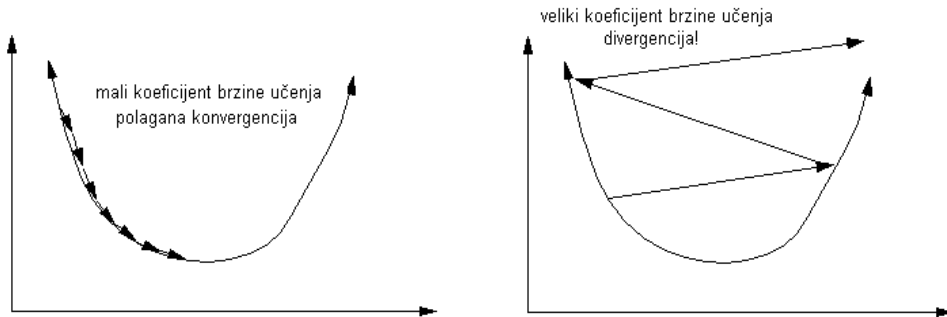
U *brze* npr. spadaju:

- *BP*-algoritam sa varijabilnim ili adaptivnim (engl. *adaptive*) koeficijentom brzine učenja,
- *Levenberg-Marquardt* algoritam

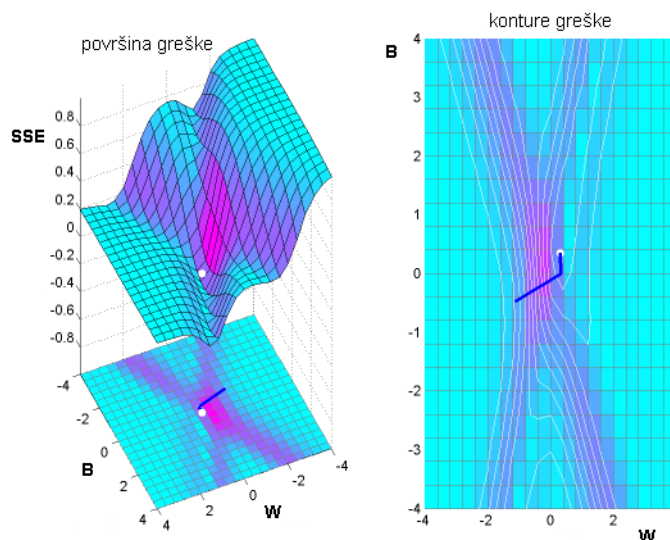
Kod *brzih* algoritma primjenjuju se tzv. *heurističke tehnike* koje su proizišle iz analize uspješnosti učenja standardnih '*steepest descent*' algoritama. Kod *Levenberg-Marquardt* algoritma primjenjuju se klasične metode numeričke optimizacije. U nastavku su ukratko opisane nabrojane modifikacije algoritama.

2.2.5. BP-algoritam sa konstantnim koeficijentom brzine učenja – μ

U osnovnoj verziji BP algoritma, vektora težina i *bias* vektor pomiču se u smjeru negativnog gradijenta funkcije uspješnosti. Kod ove modifikacije algoritma dodan je tzv. *koeficijent brzine učenja* (engl. *learning rate*) - μ , kojim određujemo iznos promjene vektora težina za svaki korak iteracije. Na slici 2.11 prikazano je značenje parametra učenja. Za slučaj malih vrijednosti koeficijenta, algoritmu će trebati puno vremena za konvergenciju, dok će za slučaj velikih vrijednosti algoritam postati nestabilan te će divergirati.



Slika 2.11. Značenje koeficijenta brzine učenja [11]

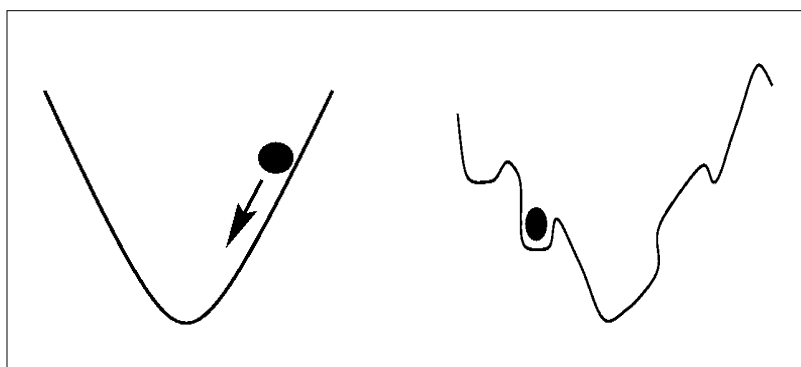


Slika 2.12. Primjer površine greške sa putanjom konvergencije [9]

Na slici 2.12 prikazan je izgled površine greške (SSE) sa putanjom konvergencije uz primjenjeni koeficijent brzine učenja $\mu=2$. Sa slike je očito da je μ je pravilno odabran jer nije došlo do divergencije. Za učenje su početni (inicijalni) iznosi vektora težina i bias vektora odabrani generatorom slučajnih brojeva. Koeficijent brzine učenja određuje učitelj, a njegova se vrijednost najčešće kreće između 10^{-3} i 10 [8].

2.2.6. BP-algoritam sa konstantnim koeficijentom momentuma – α

Kod algoritma najstrmijeg pada traženje minimuma započinje u nekoj točki površine funkcije greške, pokušavajući se gibati u smjeru globalnog minimuma (engl. *global minimum*). Ako je funkcija površine greške slična onoj na slici 2.12, tada je ta situacija pojednostavljeno prikazana lijevom skicom na slici 2.13. Vidi se da će nas svaki korak u silaznom smjeru te funkcije dovesti bliže globalnom minimumu. Kod realnih problema površina funkcije greške puno je složenija, te više nalikuje funkciji prikazanoj desnom skicom na slici 2.13. Kao što se vidi ovdje postoji više lokalnih minimuma (engl. *local minima*), a u jednom od njih može završiti crna kuglica te je napredovanje u smjeru globalnog minimuma završeno. Kao što se vidi, daljnje napredovanje kuglice moguće je njenim uspinjanjem naviše prije spuštanja prema globalnom minimumu.



Slika 2.13. Problem lokalnog i globalnog minimuma [11]

Zbog izbjegavanja lokalnog minimuma, te da bi se ubrzao proces učenja, u algoritam najstrmijeg pada uvodi se *koeficijent količine gibanja* ili *momentum* (engl. *momentum*) - α [8] te je tada modificirani izraz BP-algoritma sljedeći:

$$\Delta w_{ij}(n) = \mu_i \delta_i y_j + \alpha \Delta w_{ij}(n-1), \quad (2.31)$$

gdje n označava trenutnu promjenu težina, a $(n-1)$ prethodnu promjenu težina u procesu učenja. Vrijednost koeficijenta momentuma također određuje učitelj, a njegova vrijednost obično se kreće u intervalu: $0 < \alpha < 1$. Ako je iznos momentuma 0 promjena težina temelji se na iznosu promjene gradijenta, a ako je iznos 1 promjena je jednaka iznosu prethodne promjene težina, a promjena gradijenta se izostavlja. U pravilu bi trebalo smanjivati koeficijent brzine učenja ako se koeficijent momentuma povećava, a u protivnom se može dogoditi da se sa primjenom velikog koeficijenta brzine učenja i velikog koeficijenta momentuma 'preskoči' globalni minimum.

2.2.7. Algoritam sa varijabilnim ili adaptivnim koeficijentom brzine učenja - μ

Kod standardnog algoritma najstrmijeg pada, koeficijent brzine učenja je konstantan. Učinak algoritma vrlo je osjetljiv na pravilan izbor koeficijenta brzine učenja. Ako je izabran previsok koeficijent, algoritam može početi oscilirati te postati nestabilan, a ako je prenizak biti će potrebno više vremena za konvergenciju. Određivanje iznosa koeficijenta učenja prije procesa učenja nije od velikog praktičnog značaja, zbog toga što tako određeni koeficijent vjerojatno nije optimalni u cijelom području funkcije površine greške. Naime, kod složenih problema funkcija površine greške može imati puno lokalnih minimuma kod kojih može doći do divergencije tj. nestabilnosti algoritma. Ovi se problemi mogu izbjeći a time i povećati učinak standardnog algoritma, ako se dozvoli promjena (adaptacija) koeficijenta brzine u toku samog procesa učenja. Najčešći algoritam za adaptaciju koeficijenta brzine učenja je tzv. **bold driver** algoritam [11]. Algoritam radi na sljedeći način: nakon svake epohe učenja uspoređuje se pogreška mreže $E(n)$ sa iznosom greške u prethodnoj epohi $E(n-1)$. Ako se pogreška smanjila, povećava se koeficijent - μ u određenom postotnom iznosu (1% do 5%), a ako se pogreška povećala (u iznosu npr. 10^{-10}), poništava se zadnja promjena težina, a koeficijent - μ se smanjuje za 50%. Primjenom opisanih pravila dobiva se optimalan koeficijent brzine učenja za 'lokalni teren' na funkciji površine greške. Varijabilni ili adaptivni koeficijent brzine učenja također se kombinira sa koeficijentom momentuma.

2.2.8. Levenberg-Marquardt algoritam učenja

Levenberg-Marquardt (LMA) [9] algoritam slovi kao napredan i najbrži algoritam za nelinearnu optimizaciju. Za razliku od *Quasi-Newton* algoritma [9], kod *LMA* nije potrebno izračunavati *Hessian-ovu* matricu. S obzirom da se kod *LMA* kao funkcija pogreške primjenjuje *SSE* tada se *Hessian-ova* matrica aproksimira kako slijedi:

$$H = J^T J. \quad (2.32)$$

Gradijent se izračunava kao:

$$G = J^T E. \quad (2.33)$$

Ovdje je J^T – je transponirana *Jacobian*-ova matrica koja sadrži prve derivacije pogreške mreže, a E – je vektor pogreške mreže. U tom se slučaju *Jacobian*-ova matrica izračunava standardnim *BP*-algoritmom što je značajno jednostavnije nego izračunavanje *Hessian*-ove matrice.

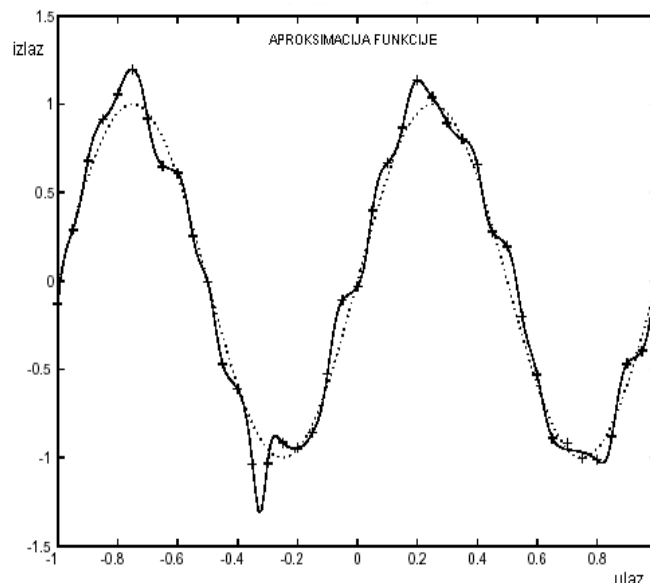
Upotrebljavajući takvu aproksimaciju *Hessian*-ove matrice izraz za *LMA* je:

$$x_{k+1} = x_k - \left[J^T J + \mu I \right]^{-1} J^T E. \quad (2.34)$$

Kada je $\mu=0$ gornji izraz postaje *Quasi-Newton* algoritam uz aproksimaciju *Hessian*-ove matrice. U slučaju da je μ velik on time zapravo postaje ‘*gradient descent*’ malog koraka. S obzirom da *Newton*-ova metoda postaje brža i preciznija u blizini minimuma funkcije pogreške, cilj je zapravo težiti k njoj što je prije moguće. μ se smanjuje nakon svakog uspješnog koraka iteracije (smanjenje pogreške), a povećava se kada probna ili testna iteracija nastoji povećati pogrešku, te se na taj način funkcija pogreške ponovno vraća u prijašnje stanje kakvo je bilo u $i-1$ koraku iteracije. Nedostatak *LMA* je taj što zahtijeva puno memorije za proračun *Jacobian*-ove matrice. Neke modifikacije *LMA* u tom slučaju dijele *Jacobian* matricu na dva dijela, dobivajući tako za proračun aproksimaciju *Hessian*-ove matrice. Međutim točnost proračuna po kojoj je *LMA* poznat se tada smanjuje.

2.2.9. Metode za poboljšanje aproksimacije

Jedan od problema koji se javlja kod učenja ili treninga neuronske mreže je problem tzv. *overfitting*-a. Naime, pogreška na ulazno-izlaznom skupu podataka je nakon učenja vrlo mala, a kad se na ulaz mreže dovedu novi podaci na kojima mreža nije učila (trenirala), pogreška je jako velika. Kaže se da mreža nema dovoljno ‘*znanja*’ za generalizaciju ili aproksimaciju novih situacija. Na slici 2.14 prikazan je primjer *overfitting*-a pri aproksimaciji sinus funkcije (prikazane točkicama) neuronskom mrežom (prikazane punom linijom) gdje se vidi da mreža ne generalizira dobro nove ulazne podatke (prikazane znakom ‘+’).



Slika 2.14. Problem *overfittinga* mreže [9]

Jednostavni način za poboljšanje aproksimacije je taj da imamo dovoljan skup ulazno-izlaznih podataka za učenje mreže. Prema nekim literaturnim izvorima, minimalan tj. dovoljan broj skupova je 10^* broj ulaznih varijali. U pravilu, što je veći broj skupova, to će biti bolja aproksimacija novih podataka koji nisu bili u skupu za učenje. Sljedeći način je pravilan izbor veličine mreže s obzirom na broj slojeva i broj neurona u svakom od njih. Ovdje je stvar puno složenija te se jedino eksperimentiranjem može doći

do pravilnog izbora broja slojeva i broja neurona. I treći način predstavljaju metode koje su ugrađene u pojedine algoritame. Te metode su: *regularizacija* (engl. *regularization*) i *rano zaustavljanje* (engl. *early Stopping*).

2.2.10. Metoda regularizacije

Najčešća funkcija uspješnosti (engl. *performance function*) za učenje unaprijednih neuronskih mreža, kao što je već spomenuto, je suma kvadrata pogreške ili *srednja suma kvadrata pogreške - MSE* (engl. *mean square error*):

$$MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (2.35)$$

gdje je t_i – ciljni ili izlazni vektor, a a_i – procijenjeni vektor (engl. *actual*) od strane naučene neuronske mreže. Aproksimaciju ili generalizaciju mreže moguće je unaprijediti ako u funkciju uspješnosti proširimo za dva člana: prvi član je tzv. *performance ratio- γ* , a drugi član je *suma kvadrata pogreške težina i biasa - msw*. Izraz (2.35) tada izgleda:

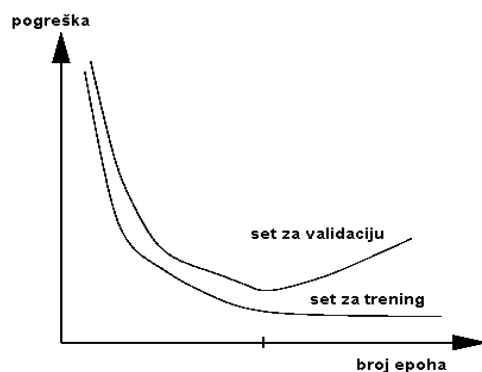
$$msereg = \gamma mse + (1 - \gamma) msw, \quad (2.36)$$

$$msw = \frac{1}{n} \sum_{j=1}^n w_j^2. \quad (2.37)$$

Problem kod primjene metode regularizacije je taj što je teško odrediti optimalan iznos za *performance ratio- γ* . Ako ovaj parametar postavimo na veliku vrijednost postoji opasnost od pojave *overfitting-a*. Ako je pak premali, vjerojatno je da niti trening skup podataka neće biti dobro aproksimiran, a time naravno niti novi skupovi koji nisu bili u procesu učenja.

2.2.11. Metoda ranog zaustavljanja

Kod ove tehnike za poboljšanje aproksimacije ulazni skup podataka dijeli se na dva dijela. Prvi skup je trening skup, pomoću kojeg se izračunava gradijent te se nakon toga mijenjaju vektori težina i bias vektori. Drugi skup je skup za validaciju (engl. *validation skup*) te se preko njega ‘nadgleda’ pogreška u procesu učenja. Pogreška validacije se u početnoj fazi učenja smanjuje isto kao i popogreška na trening skupu podataka. Kada se u procesu učenja počinje događati ‘*overfitting*’, popogreška validacijskog skupa počinje rasti. Ako se popogreška validacije značajno poveća za određeni broj iteracija, zaustavlja se proces učenja te se za daljnje proračune (aproksimacije za nove skupove) uzimaju vektori težina i bias vektora kod kojih je popogreška validacije bila minimalna. Na slici 2.15 dan je shematski prikaz *early stoping* metode.



Slika 2.15. Shematski prikaz *early stoping* metode [11]

2.3. Asocijativne neuronske mreže

2.3.1. Uvod

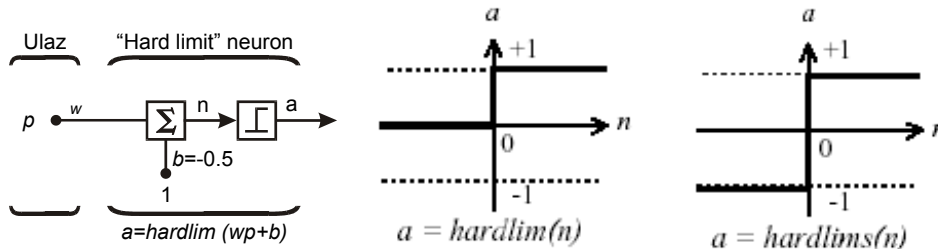
Što je asocijacija? Asocijacija je svaka veza između ulaza u sustav i izlaza, i to takva da pri ulazu uzorka A u sustav, sustav odgovara uzorkom B . Kada su dva uzorka povezana asocijacijom, ulazni uzorak se često naziva *podražajem*. Isto tako, izlazni se uzorak naziva *odzivom*. Asocijativne neuronske mreže (u daljnjem tekstu, *ASNN*) proizišle su iz tzv. *behaviorističke* škole psihologije. To je grana psihologije koja se bavi proučavanjem životinjskog i ljudskog ponašanja uporabom asocijacija i pravila za učenje asocijacija. Jedan od najranijih utjecaja na *behaviorističku* školu psihologije imao je klasični Pavlovljev eksperiment u kojemu je naučio psa da slini na zvuk zvona iako pas nije vidio hranu. To je bio primjer tzv. *klasičnog uvjetovanja*. Najutjecajniji nositelj *behaviorističke* škole bio je B.F. Skinner. Poznat je njegov klasični eksperiment treniranja štakora da pritisne tipku da bi dobio pliticu sa hranom. To je primjer tzv. *instrumentalnog uvjetovanja*. Dijelom je ovakva ponašanja objasnio Donald Hebb tzv. *Hebb-ovim pravilom*.

'Ako se neuron A više puta stimulira s drugim neuronom B , u vrijeme kad je neuron A aktivan, onda neuron A vremenom postaje osjetljiviji na stimulaciju koja dolazi od neurona B . Sinaptička veza od B ka A postaje efikasnija te je na taj način neuronu B olakšana stimulacija neurona A da proizvede neki izlaz u budućnosti.'

Brojni su istraživači pridonijeli razvoju asocijativnog učenja. Posebice su utjecajni bili Tuevo Kohonen, James Anderson i Stephen Grossberg. Anderson i Kohonen nezavisno su razvili linearnu asocijativnu mrežu u kasnim 60-tim i ranim 70-tim godinama. Grossberg je u istom razdoblju uveo nelinearne asocijativne vremenski kontinuirane mreže.

2.3.2. Opis jednostavne asocijativne mreže

Na slici 2.16 prikazana je shema jednostavne asocijativne mreže sa jednim ulazom i sa tzv. *tvrdograničnom aktivacijskom funkcijom* (engl. *hard limit transfer function*).



Slika 2.16. Shematski prikaz asocijativne mreže sa jednim ulazom i sa tzv. tvrdograničnom aktivacijskom funkcijom [9]

Izlaz neurona a određuje se iz njegova ulaza p prema

$$a = \text{hardlim}(wp + b) = \text{hardlim}(wp - b). \quad (2.38)$$

Zbog jednostavnosti, ograničit ćemo da vrijednost p može biti ili 0 ili 1, što znači da pobuda postoji ili ne postoji. Vidimo da je i a ograničen na iste vrijednosti *tvrdograničnom aktivacijskom funkcijom*, koja pokazuje da li odziv mreže postoji ili ne postoji.

$$p = \begin{cases} 1 - \text{pobuda} \\ 0 - \text{nema pobude} \end{cases} \quad a = \begin{cases} 1 - \text{odziv} \\ 0 - \text{nema odziva} \end{cases} \quad (2.39)$$

Prisutnost asocijacije između pobude $p=1$ i odziva $a=1$ diktira vrijednost w . Mreža će odgovoriti na pobudu samo ako je w veći od $-b$ (u ovom slučaju $b=0,5$).

2.3.3. Hebb-ovo pravilo učenja bez učitelja

Za jednostavne probleme nije teško modelirati mrežu s fiksnim skupom asocijacija, što nije cilj. Cilj je da mreža u nekom trenutku nauči asocijacije. Postavlja se pitanje kada bi se asocijacija trebala naučiti? Zna se da su i ljudi i životinje skloniji asociiranju (povezivanju) činjenica koje se pojavljuju istovremeno. Iz primjene Hebb-vog načela slijedi npr.: ako se pobuda na miris banane pojavljuje istovremeno s nekom drugom pobudom kao što je npr. pogled na oblik banane, mreža tad jača vezu između te dvije pobude, tako da se kasnije aktivira odziv ‘to je banana’ i to već na sami miris banane, dakle bez da se vidi oblik. Hebb-ovo pravilo učenja bez učitelja upravo to i čini, povećanjem težine w_{ij} između ulaza neurona p_j i izlaza a_i proporcionalno njihovom umnošku:

$$w_{ij}(q) = w_{ij}(q-1) + \alpha a_i(q) p_j(q). \quad (2.40)$$

Ovdje je α je koeficijent brzine učenja koji diktira koliko se puta pobuda i odziv moraju pojaviti zajedno prije uspostavljanja asocijacije. Npr. ako $b = -0,5$ asocijacija će se uspostaviti kada $w > b$ jer će tada $p = 1$ proizvesti odziv $a = 1$, bez obzira na vrijednost p .

Izraz (2.40) koristi signale koji su na raspolaganju unutar sloja koji sadrži težine koje se obnavljaju. Pravila koja zadovoljavaju ovakvim uvjetima zovu se *lokalna pravila učenja* (engl. *local learnings rules*). To je u suprotnosti s pravilom kod BP algoritma gdje se osjetljivost algoritma širi od završnog sloja prema natrag. Također se Hebb-ovo pravilo učenja bez učitelja može napisati u vektorskom obliku:

$$W(q) = W(q-1) + \alpha a(q) p^T(q). \quad (2.41)$$

U izrazima (2.40) i (2.41) simbol q predstavlja broj iteracije.

2.3.4. Hebb-ovo pravilo zaboravljanja

Jedan od način za poboljšanje Hebb-ovog osnovnog pravila učenja bez učitelja (izraz 13.6) je dodavanje koeficijenta *brzine zaboravljanja* (engl. *decay rate*) - γ :

$$W(q) = W(q-1) + \alpha a(q) p^T(q) - \gamma W(q-1) = (1-\gamma)W(q-1) + \alpha a(q) p^T(q), \quad (2.42)$$

a γ je pozitivni koeficijent < 1 . Približavanjem koeficijenta $\gamma \approx 0$, pravilo učenja postaje osnovnim pravilom. Približavanjem koeficijenta γ jedinici, pravilo učenja brzo zaboravlja stare ulaze i sjeća se samo posljednjih ulaza. Time se onemogućava nekontrolirani i preveliki rast vektora matrice težina. Ova ideja ‘filtriranja’ promjena vektora težina je zapravo slična primjeni koeficijenta momentuma kod BP algoritma. Maksimalna vrijednost težine w_{ij}^{max} određena je s γ , a pronalazi se postavljanjem a_i i p_j na vrijednost 1 za sve q (u cilju maksimizacije učenja) u izraz 2.42 te rješavanjem slučaja u kojem su novi i stari vektori težina jednaki, izraz 2.43 .

$$\begin{aligned} w_{ij} &= (1-\gamma)w_{ij} + \alpha a_i p_j, \\ w_{ij} &= (1-\gamma)w_{ij} + \alpha, \\ w_{ij} &= \frac{\alpha}{\gamma}. \end{aligned} \quad (2.43)$$

2.3.5. ‘Instar’ pravilo

Jedan od problema Hebb-ovog pravila s koeficijentom brzine zaboravljanja je u tome što pobudu treba ponavljati ili se u protivnom asocijacije izgube. Bolje bi pravilo bilo ono koje bi omogućavalo zaboravljanje vektora težina u slučaju je kada je $a \neq 0$. Rast vrijednosti vektora težina još bi uvijek bio ograničen, ali bi zaboravljanje bilo minimizirano.

Da bi se izvukla koristi od zaboravljanja težina uz istovremeno ograničavanje zaboravljanja, može se u originalno Hebb-ovo pravilo dodati uvjet zaboravljanja koji je proporcionalan $a_i(q)$:

$$w_{ij}(q) = w_{ij}(q-1) + \alpha a_i(q) p_j(q) - \gamma a_i(q) w_{ij}^{stari}. \quad (2.44)$$

Izraz (2.44) možemo pojednostaviti postavljanjem γ koji je jednak α (tako se nove vrijednosti težine uče istom brzinom kojom se stare vrijednosti zaboravljaju) pa dobivamo izraz:

$$w_{ij}(q) = w_{ij}(q-1) + \alpha a_i(q)(p_j(q) - w_{ij}^{stari}). \quad (2.45)$$

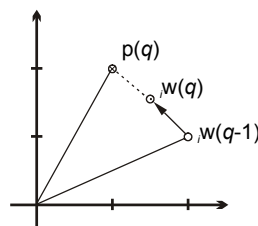
Izraz (2.45) naziva se *instar pravilo*, a može se napisati u vektorskom obliku:

$${}_i w(q) = {}_i w(q-1) + \alpha a_i(q)(p(q) - {}_i w(q-1)). \quad (2.46)$$

Učinak *instar pravila* može se najbolje razumjeti ako razmotrimo slučaj kada je *instar* aktivan tj. kada je $a_i=1$. Izraz (2.46) može se tada napisati kao

$${}_i w(q) = {}_i w(q-1) + \alpha(p(q) - {}_i w(q-1)) = (1-\alpha) {}_i w(q-1) + \alpha p(q), \quad (2.47)$$

a grafička interpretacija je na slici 2.17.



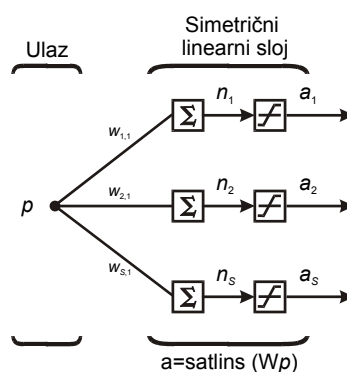
Slika 2.17. Grafički prikaz *instar pravila* [9]

Kao što se vidi na slici 2.17, kada je *instar* aktivan, težinski se vektor pomiče prema ulaznom vektoru po pravcu između starog težinskog vektora i ulaznog vektora. Razmak po kojemu se težinski vektor pomiče ovisi o vrijednosti α . Kada $\alpha = 0$, novi je težinski vektor jednak starom težinskom vektoru (nema pomicanja). Kada $\alpha = 1$, novi težinski vektor je jednak ulaznom vektoru (maksimalni pomak). Ako je $\alpha = 0,5$ novi će težinski vektor biti na pola puta između starog težinskog vektora i ulaznog vektora.

Korisna je karakteristika *instar pravila* da ako su ulazni vektori normalizirani, tada će ${}_i w$ nakon učenja određenog vektora p također biti normalizirane. Dakle, ustanovilo se pravilo koje ne samo da minimizira zaboravljanje, već i rezultira normaliziranim vektorima težina, ako su ulazni vektori bili normalizirani.

2.3.6. Outstar pravilo

Kao što se uočava *instar* neuronska mreža (s vektorskim ulazom i skalarnim izlazom) može raspoznavati uzorke povezivanjem određene vektorske pobude s odzivom. *Outstar* neuronska mreža, prikazana na slici 2.18, ima skalarni ulaz i vektorski izlaz. Ona može izvršiti *poziv uzorka* povezivanjem pobude s vektorskim odzivom.



Slika 2.18. Shema *outstar* neuronske mreže [9]

Ulazno-izlazni izraz za *outstar* mrežu je:

$$a = \text{satlins}(Wp). \quad (2.48)$$

Simetrična aktivacijska funkcija *satlins* odabrana je stoga što će se mreža koristiti za pozivanje vektora s vrijednostima -1 ili 1. Ako bismo mrežu htjeli povezati s pobudom ($p=1$) s određenim izlaznim vektorom a^* , možemo jednostavno postaviti W (koji sadrži vektor od samo jednog stupca) koji je jednak a^* . Tada, ako je $p=1$, izlaz će biti a^* :

$$a = \text{satlins}(Wp) = \text{satlins}(a^* \times 1) = a^*. \quad (2.49)$$

Podrazumijeva se da su elementi od a^* po iznosu manji ili jednaki 1. Time smo zapravo izmodelirali mrežu za pozivanje, postavljanjem *stupca* matrice težina u željeni vektor. Kod *instar* neuronske mreže izmodelirali smo mrežu za prepoznavanje time što smo *red* matrice težina postavili u željeni vektor. Da bi mogli modelirati neuronsku mrežu koja može pozvati poznati vektor a^* , potrebno je definirati novo pravilo učenja bez učitelja. U procesu učenja sa *instar pravilom*, zaboravljanje je bilo ograničeno time što se postavilo da je uvjet zaboravljanja težina *Hebb*-ovog pravila proporcionalan izlazu mreže a_i . Obratno, da bi se dobilo *outstar pravilo* učenja, uvjet zaboravljanja težina proporcionalan je ulazu u mrežu p_j :

$$w_{ij}(q) = w_{ij}(q-1) + \alpha a_i(q) p_j(q) - \gamma p_j(q) w_{ij}(q-1). \quad (2.50)$$

Ako postavimo da je koeficijent brzine zaboravljanja γ jednak koeficijentu brzine učenja α dobivamo:

$$w_{ij}(q) = w_{ij}(q-1) + \alpha (a_i(q) - w_{ij}(q-1)) p_j(q). \quad (2.51)$$

Kao i *instar pravilo*, *outstar pravilo* se može napisati u vektorskom obliku:

$$w_j(q) = w_j(q-1) + \alpha (a(q) - w_j(q-1)) p_j(q), \quad (2.52)$$

gdje je w_j j -ti stupac matrice W .

2.3.7. Ocjena uspješnosti algoritma učenja

Za procjenu točnosti (uspješnosti) (engl. *performance index*) algoritma učenja u rješavanju postavljenog zadatka, potrebno je definirati tzv. mjeru (indeks) točnosti. Pomoću mjere točnosti za tipske zadatke učenja moguće je uspoređivati primjenjivani algoritam sa ostalim algoritmima učenja. Danas su najčešće u uporabi sljedeće tri mjere točnosti algoritma učenja [8]:

1. Srednja kvadratna greška (engl. *mean squared error* – **MSE**)

$$MSE = \frac{\sum_{n=1}^N (d_n - O_n)^2}{N}. \quad (2.53)$$

2. Korjen srednje kvadratne greška (engl. *root mean square error* - **RMSE**)

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum_{n=1}^N (d_n - O_n)^2}{N}}. \quad (2.54)$$

3. Normalizirani korijen srednje kvadratne greške (engl. *normalized root mean square error - NRMSE*)

$$NRMSE = \frac{RMSE}{\sigma d_n} = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - O_n)^2}{N}}}{\sigma d_n}, \quad (2.55)$$

$$\sigma d_n = \sqrt{\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^2}, \quad (2.56)$$

$$\bar{d} = \frac{1}{N} \sum_{n=1}^N d_n, \quad (2.57)$$

gdje je: σd_n – standardno odstupanje; N – broj uzoraka; O_n – željeni izlaz; d_n – procjenjeni izlaz

Kao mjera za usporedbu različitih algoritama učenja neuronskih mreža koristiti će se **NRMSE**. Prednost je odabrane mjere njena bezdimenzionalnost koja osigurava neovisnost mjere o dimenzijama učenih veličina i koja omogućava usporedbu izvedenih algoritama učenja s drugim algoritmina, neovisno o korištenoj sklopovskoj ili programskoj podršci.

2.4. Neizrazita logika

2.4.1. Uvod

Matematički temelji *neizrazite logike* (engl. *fuzzy logic*) počivaju u *teoriji neizrazitih (fuzzy) skupova*, o kojoj se može razmišljati kao o generalizaciji teorije klasičnih skupova. Nerazumljivost je jedno od svojstava jezika. Njen glavni izrok je nepreciznost pri definiciji i uporabi simbola. Razmotrimo primjerice, grupu stolica u sobi. U teoriji skupa, skup stolica se može stvoriti tako da se pokaže na svaki objekt u sobi i postavi pitanje: *Je li to stolica?* U klasičnoj teoriji skupa, dopušteno nam je dati samo dva odgovora: *Da* ili *Ne*. Označimo *Da* s 1 , a *Ne* s 0 , naši će odgovori biti u paru $(0,1)$. Ako je odgovor 1 , element pripada skupu; ako je odgovor 0 , element ne pripada skupu. Na kraju prikupimo sve elemente koji su označeni s 1 i dobivamo *skup stolica u sobi*. Pretpostavimo sljedeće pitanje: *Koji objekt u sobi može poslužiti kao stolica?* I ovdje odgovor može biti ograničen na $\{0,1\}$. Ipak, skup objekata u sobi koji *bi mogli* funkcionirati kao stolica ne obuhvaćaju samo stolice već i stolove, kutije, dijelove poda i tako dalje. To je skup koji nije jednoznačno određen. To zapravo ovisi o tome što podrazumijevamo pod riječju *funkcija*. Riječi poput riječi *funkcija*, imaju mnogostruka značenja i mogu se koristiti na različite načine. Njihovo značenje i uporaba mogu varirati s različitim osobama, okolnostima i namjenama; to ovisi o specifičnosti situacije. Stoga za skup objekata koji *bi mogli* funkcionirati kao stolica kažemo da je to *fuzzy skup*, a pritom treba imati na umu da nismo sasvim precizno definirali kriterije za članstvo u tom skupu. Objekti kao što su stolovi, kutije i dio poda mogu funkcionirati kao *stolice*, do nekog stupnja. Međutim, trebalo bi zamijetiti da nema ničega *fuzzy* kod samih materijalnih objekata. Stolice, kutije i stolovi su ono što jesu. *Fuzziness* je karakteristika njihovog predstavljanja u miljeu simbola i općenito je svojstvo modela, računalskih procedura i jezika.

U klasičnoj teoriji *klasični skupovi* su jasno definirani skupovi elemenata (brojeva, simbola, objekata, itd.) i iz tog ćemo ih razloga zvati *određenim skupovima*. Elementi svih skupova koji se razmatraju u danoj situaciji pripadaju nepromjenjivom, konstantnom skupu, kojeg zovemo *univerzalni skup* (engl. *universe, universe of discourse*¹). Činjenica da elementi x_i ili pripadaju ili ne pripadaju određenom skupu A može se formalno označiti karakterističnom funkcijom od $x_A(x)$, koja je definirana kao:

$$x_A(x) \equiv \begin{cases} 1 & \text{iff } x \in A \\ 0 & \text{iff } x \notin A \end{cases}, \quad (2.58)$$

gdje simboli \in i \notin označavaju da x *jest* i *nije* član od A , respektivno, a *iff* je kratica za *ako i samo ako*. Par brojeva $\{0,1\}$ zove se *procjenidbeni skup* (engl. *valuation skup*). Drugi način pisanja izraza (2.58) je

$$x_A(x): X \rightarrow \{0,1\}. \quad (2.59)$$

Izraz (2.59) čita se kako slijedi: *Postoji funkcija $x_A(x)$ koja pridružuje svaki element skupa X (naš univerzalni skup) skupu $\{0,1\}$* . To naglašava da je karakteristična funkcija mehanizam za pridruživanje skupa X procjenidbenom skupu $\{0,1\}$. Važne operacije u određenim skupovima kao što su *unija, presjek i komplement* poznati su nam iz elementarne matematike. Obično se predstavljaju pomoću *Venn-ovih dijagrama*, ali se mogu izraziti i karakterističnom funkcijom.

U osnovi, skupovi su *kategorije*. Definiranje prikladnih kategorija i uporaba operacija za njihovo manipuliranje je glavni zadatak modeliranja i izračuna. Od prepoznavanja slike do mjerenja i kontrole, *kategorija* tj. *skup*, je od najvećeg značaja za definiciju sistemskih varijabli, parametara, njihovih raspona i njihovih interakcija. Ograničenje skupa da ima dvojni stupanj pridruženosti (pripadnosti) skupu, tipa *sve-ili-ništa*, je posljedica želje da se opis sustava odvoji od zamršenosti i kompleksnosti koje postoje u stvarnosti i fokusira se na faktore od primarnog utjecaja.

2.4.2. Neizraziti skupovi

Kao što smo vidjeli u uvodnom dijelu, u klasičnoj teoriji, skupu je dodijeljen vrlo određen pojam pripadnosti skupu; to znači da element ili *pripada* ili *ne pripada* skupu. Međutim, 1965. godine **Lofti A. Zadeh** je uveo *neizrazite skupove* (engl. *fuzzy sets*), kod kojih je pojam pripadnosti fleksibilniji. U

¹ Pojam *Universe of discourse*? koristi se u neizrazitoj logici a proizišao je iz klasične logike i opisuje cjelokupni skup pojedinačnih elemenata koje je moguće kvantificirati [12].

neizrazitim skupovima dozvoljeno je više stupnjeva pripadnosti. Stupanj pripadnosti u skupu označen je brojevima između 0 i 1 – što znači nekim brojem u intervalu $\{0,1\}$. Točka odstupanja za neizrazite skupove jednostavno generalizira procjenidbeni skup iz para brojeva $\{0,1\}$ svim brojevima pronađenim u $\{0,1\}$. Polazna točka za neizrazite skupove je jednostavno generaliziranje procjenidbenog skupa iz para brojeva $\{0,1\}$. Proširenjem procjenidbenog skupa mijenjamo prirodu karakteristične funkcije, koju zovemo *funkcijom pripadnosti* (engl. *membership function*) i označavamo je sa $\mu_A(x)$. Dakle više ne govorimo o *određenim skupovima*, već umjesto njih uvodimo *neizrazite ili fuzzy skupove*. Kako interval $\{0,1\}$ sadrži beskonačno mnogo brojeva, mogući su i beskonačni mnogo stupnjeva pripadnosti. Stoga, vezano uz izraz (2.59), kažemo da funkcija pripadnosti pridružuje svaki element univerzalnog skupa X intervalu $\{0,1\}$, a formalno to pridruživanje zapisujemo u sljedećem obliku:

$$\mu_A(x): X \rightarrow [0,1]. \quad (2.60)$$

Izraz (2.60) je generalizacija pridruživanja koje je prikazano u jednadžbi (2.59). Funkcije pripadnosti su jednostavan, a ipak svestran matematički alat za označivanje fleksibilnosti pripadnosti skupu, te za modeliranje i kvantificiranje simboličkih značenja. Postavlja se pitanje kako se definiraju funkcije pripadnosti tj. što one zapravo predstavljaju? Funkcije pripadnosti mogu predstavljati individualni (subjektivni) zapis nejasnih klasa - primjerice, *visoki ljudi, niska temperatura, prihvatljivi učinak, mali doprinos stabilnosti sustava, malo poboljšanje, velika korist*, itd. Pri radu kontrolera ili alata za automatsko donošenje odluka, modeliranje i kvantifikacija takvih simboličkih opisa je vrlo važan zadatak. Funkcije pripadnosti mogu se odrediti i na temelju statističkih podataka ili uz pomoć neuronskih mreža [1]. Može se jednostavno reći da su funkcije pripadnosti prvenstveno subjektivne po svojoj prirodi, što ne znači da su svojevóljno pridružene, već da se temelje na kriterijima koji su specifični za primjenu (Kaufmann, 1975; Dubois i Prade, 1980; Zimmermann, 1985).

Postoje dva načina koji se najčešće koriste za označivanje neizrazitih skupova. Ako je X univerzalni skup, a x je određeni element X -a, tada se neizraziti skup A koji je definiran na X -u može napisati kao skup uređenih parova:

$$A = \{(x, \mu_A(x))\}, \quad x \in X, \quad (2.61)$$

gdje se svaki par $(x, \mu_A(x))$ zove *singleton ili fuzzy broj* kojem je x prvi član, a drugi član je njegova pripadnost u A , tj. $\mu_A(x)$. U klasičnoj teoriji skupova, *singleton* je jednostavno element x , dok u *neizrazitim skupovima*, *singleton* čine: x i $\mu_A(x)$. Npr., skup *integers*, A subjektivno definiran pomoću univerzalnog skupa pozitivnih integers može se dati kao skup *singletona*.

$$A = \{(1,1.0), (2,1.0), (3,0.75), (4,0.5), (5,0.3), (6,0.3), (7,0.1), (8,0.1)\}.$$

Tako npr. četvrti *singleton* govori da broj 4 pripada A sa stupnjem pripadnosti od 0,5. *Singleton* se također piše kao $\mu_A(x)/x$ -što znači da se stupanj pripadnosti stavlja na prvo mjesto². Singletoni čije je stupanj pripadnosti skupu jednaka nuli mogu se ispustiti iz skupa. Alternativni izraz koji se koristi češće od izraza (2.61) eksplicitno označuje neizraziti skup kao *uniju* svih *singletona* $\mu_A(x)/x$, tako da je

$$A = \sum_{x_i \in X} \mu_A(x_i) / x_i. \quad (2.62)$$

Znak sumiranja u izrazu (2.62) označuje *uniju* svih *singletona* (operacija *unije* je u teoriji skupova poput operacije zbrajanja). Izraz (2.62) podrazumijeva da imamo *diskretni univerzalni skup*. U ovom alternativnom zapisu, gornji skup *malih integers* se može napisati kao

$$\begin{aligned} A &= \mu_A(1)/1 + \mu_A(2)/2 + \mu_A(3)/3 + \mu_A(4)/4 + \mu_A(5)/5 + \mu_A(6)/6 + \mu_A(7)/7 + \mu_A(8)/8 \\ &= 1.0/1 + 1.0/2 + 0.75/3 + 0.5/4 + 0.3/5 + 0.3/6 + 0.1/7 + 0.1/8. \end{aligned}$$

² Znak / ne označava operaciju dijeljenja već oznaku za razdvajanje.

Za kontinuirani univerzalni skup izraz (2.62) možemo napisati kao:

$$A = \int_x \mu_A(x) / x, \quad (2.63)$$

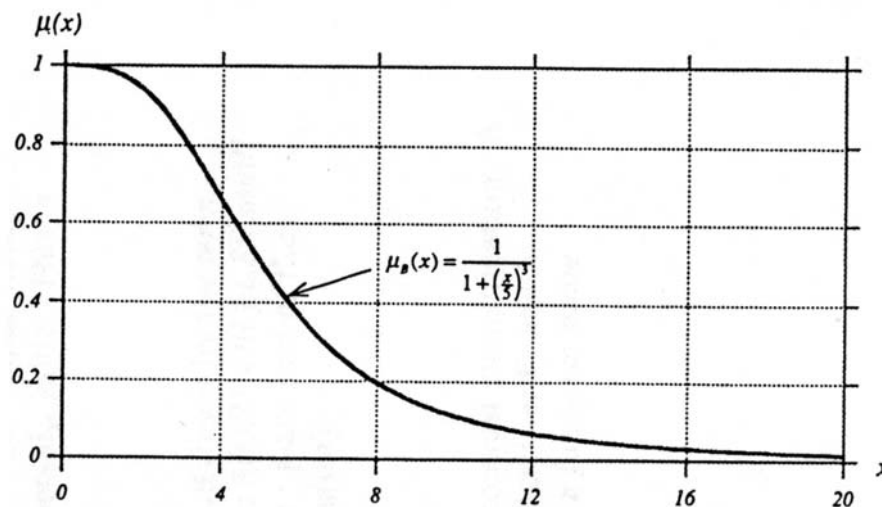
gdje znak *integrala* u izrazu (2.63) označuje *uniju* svih $\mu_A(x)/x$ *singletona*³. Ako npr. razmotrimo neizraziti skup *malih brojeva* koji je definiran (subjektivno) skupom nenegativnih realnih brojeva pomoću kontinuirane funkcije pripadnosti $\mu_B(x)$ koja je dana izrazom:

$$\mu_B(x) = \frac{1}{1 + \left(\frac{x}{5}\right)^3}, \quad (2.64)$$

onda uporabom izraza (2.64) neizraziti skup *B* može se napisati kao

$$B = \int_{x \geq 0} \mu_B(x) / x = \int_{x \geq 0} \left[\frac{1}{1 + \left(\frac{x}{5}\right)^3} \right] / x. \quad (2.65)$$

Funkcija pripadnosti neizrazitog skupa *B* prikazana na slici 2.19 je tzv. *Zadeh-ovim dijagramom*.



Slika 2.19. Zadeh-ov dijagram za neizraziti skup $B = \{\text{mali brojevi}\}$ [12]

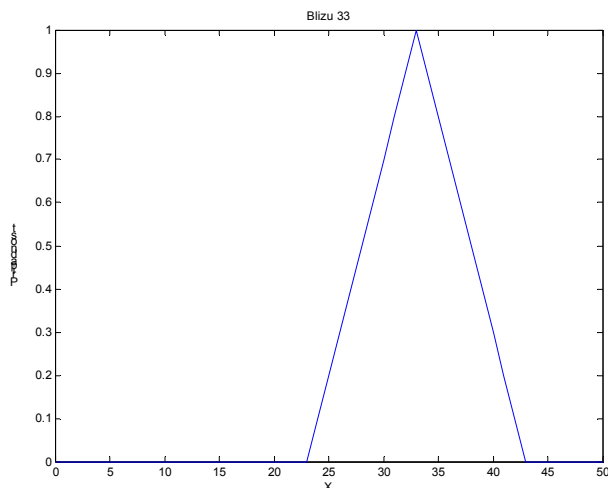
2.4.3. Funkcije pripadnosti

Svakom *neizrazitom skupu* pojedine lingvističke varijable dodjeljuje se određeni oblik funkcije pripadnosti unutar *univerzalnog skupa*. Oblici funkcija pripadnosti mogu biti različiti, a najčešće su to: trokutasti, trapezoidni, *S* i *II* oblici. Kod neuronskih mreža analogno funkcijama pripadnosti su *aktivacijske funkcije*. U nastavku su opisane standardne funkcije pripadnosti na primjeru lingvističke varijable *temperatura* sa tri neizrazita skupa: *hladno*, *toplo*, *vruće*.

³ Znak integrala nema značenje znaka integrala kod integralnog računa. U teoriji skupova on ima značenje *zbroja* ili *unije* pojedinih *singletona*.

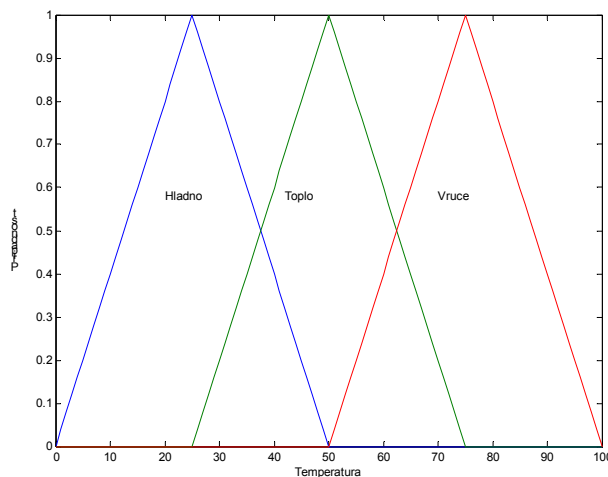
a) Trokutasta funkcija pripadnosti

Trokutasta funkcija pripadnosti definira se parametrima $[a \ b \ c]$, gdje je a lijevi presjek funkcije s pripadnošću $\mu=0$, b je središnji vrh ili tipična vrijednost (engl. *typical value*) s pripadnošću $\mu=1$, dok je c desni presjek funkcije s pripadnošću $\mu=0$. Dakle, funkcija $trokut(x, [a \ b \ c])$ vraća vrijednost pripadnosti μ koje odgovaraju definiranom *univerzalnom skupu* x . Npr., na slici 2.20. je prikazana trokutasta funkcija lingvističke varijable x za *neizraziti skup x je blizu 33*, a definirana je kao: $\mu=[0:1]$ sa $[a \ b \ c]=[23 \ 33 \ 43]$.



Slika 2.20. Trokutasta funkcija pripadnosti [12]

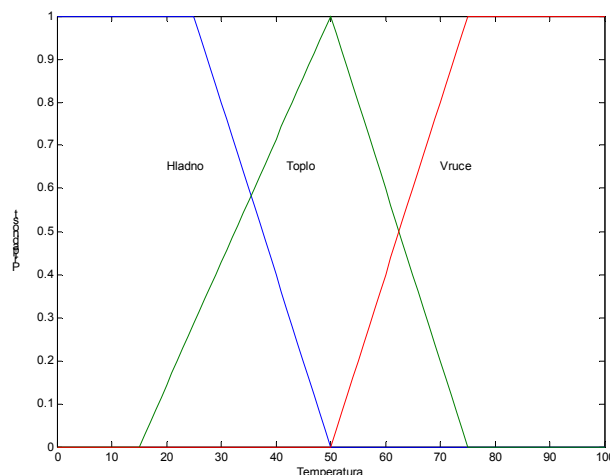
Neizraziti skupovi funkcija pripadnosti mogu se preklapati unutar *univerzalnog skupa*. Na slici 2.21 prikazano je preklapanje neizrazitih skupova (*hladno*, *toplo*, *vruće*) lingvističke varijable *temperatura* u °C unutar *univerzalnog skupa* $[0:100]$.



Slika 2.21. Preklapanje neizrazitih skupova unutar *univerzalnog skupa* [12]

b) Trapezoidna funkcija pripadnosti

Kao što se vidi na slici 2.21, vrijednost 0 lingvističke varijable *temperatura* je u drugom i trećem skupu. Zbog toga je na slici 2.22 napravljena 'mala' rekonstrukcija oblika neizrazitih skupova *hladno* i *vruće* primjenom trapezoidne funkcije pripadnosti.



Slika 2.22. Trokutasta i trapezoidna funkcija pripadnosti [12]

Primjena trapezoidne funkcije rezultira pravilnom dodjelom iznosa θ , temperaturi kada je pripadnost $\mu=1$ za neizraziti skup *hladno*. Analogno tome, visokim se temperaturama pravilno dodjeljuju visoke vrijednosti pripadnosti μ za neizraziti skup *toplo*.

c) Funkcija pripadnosti S – oblika

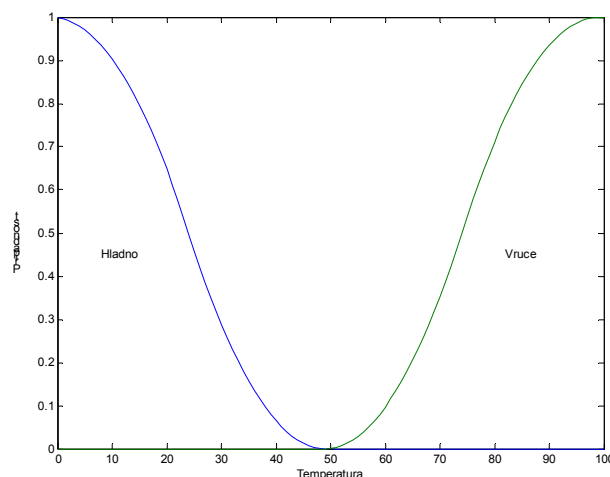
Funkcija pripadnosti S-oblika definirana je trima parametrima $[\alpha \beta \gamma]$, sljedećim izrazima:

$$\begin{aligned}
 S_oblik(\alpha, \beta, \gamma) &= 0, & \text{za } x \leq \alpha, \\
 S_oblik(\alpha, \beta, \gamma) &= 2 \left(\frac{x - \alpha}{\gamma - \alpha} \right)^2, & \text{za } \alpha \leq x \leq \beta, \\
 S_oblik(\alpha, \beta, \gamma) &= 1 - 2 \left(\frac{x - \gamma}{\gamma - \alpha} \right)^2, & \text{za } \beta \leq x \leq \gamma, \\
 S_oblik(\alpha, \beta, \gamma) &= 1, & \text{za } \gamma \leq x,
 \end{aligned} \tag{2.66}$$

gdje je:

$$\begin{aligned}
 \alpha &= \text{točka gdje je } \mu(x)=0, \\
 \beta &= \text{točka gdje je } \mu(x)=0,5, \\
 \gamma &= \text{točka gdje je } \mu(x)=1,0,
 \end{aligned}$$

Treba primijetiti da $(\beta-\alpha)$ mora biti jednak $(\gamma-\beta)$ zbog kontinuiteta nagiba. Na slici 2.23 prikaza je funkcija pripadnosti S-oblika za lingvističku varijablu *temperatura*.



Slika 2.23. S-oblik funkcije pripadnosti [12]

d) Funkcija pripadnosti *P-oblika*

Funkcija pripadnosti *P-oblika* definirana je dvama parametrima $[\gamma \ \beta]$, sljedećim izrazima:

$$P_oblik(\gamma, \delta) = S_oblik\left(x; \gamma - \delta, \frac{\gamma - \delta}{2}, \gamma\right) \quad \text{za} \quad x \leq \gamma, \quad (2.67)$$

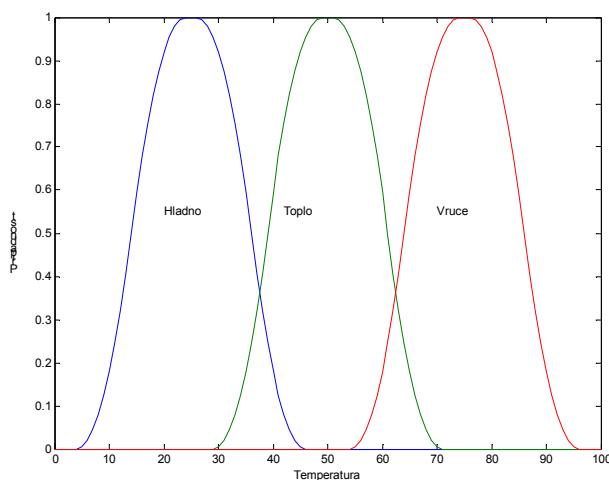
$$P_oblik(\gamma, \delta) = 1 - S_oblik\left(x; \gamma, \frac{\gamma + \delta}{2}, \gamma + \delta\right) \quad \text{za} \quad x \geq \gamma,$$

gdje je:

γ = centar funkcije pripadnosti,

β = širina funkcije pripadnosti sa $\mu = 0,5$.

Na slici 2.24 prikaza je funkcija pripadnosti *P-oblika* za lingvističku varijablu *temperatura*.

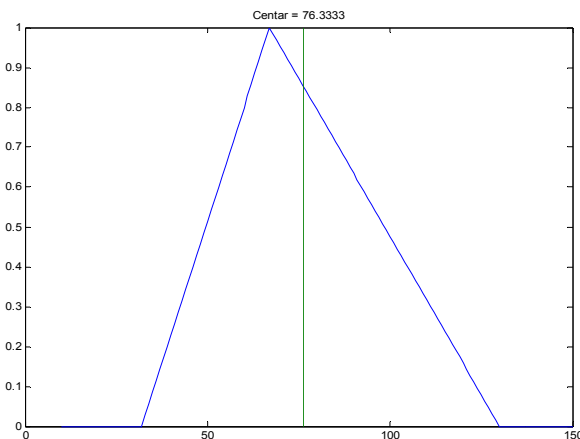


Slika 2.24. *P-oblik* funkcije pripadnosti [12]

2.4.4. Defazifikacija

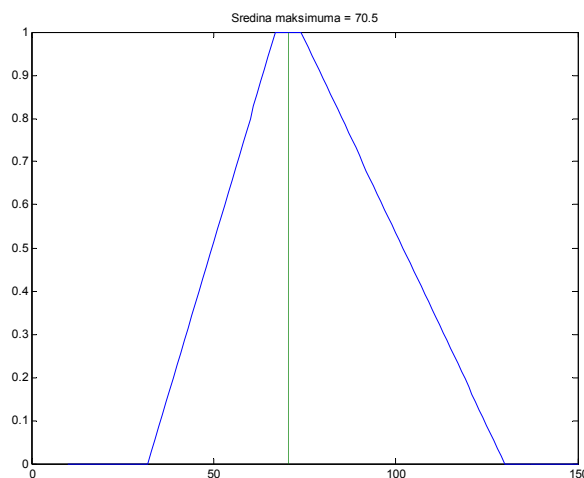
Defazifikacija je proces predstavljanja neizrazitog skupa određenim brojem. Unutarnja predstavljanja podataka u *fuzzy* sustavu su obično neizraziti skupovi, ali izlaz mora biti određeni i jasan broj koji se koristi za izvršenje neke funkcije upravljanja (npr. ventilom).

Najčešće korištena metoda defazifikacije je metoda *centra površine* (engl. *center of area*), kojom se određuje središte područja neizrazitog skupa. Pronalaženje centra neizrazitog skupa ovom metodom slično je metodi kojom se pronalazi ravnotežna točka na opterećenoj gredi. Ilustracija ove metode za slučaj trokutaste funkcije pripadnosti prikazana je na slici 2.25.



Slika 2.25. Metoda *centra površine* kao metoda defazifikacije [12]

Postoji i nekoliko drugih metoda defuzifikacije kao što su: *sredina maksimuma* (*mean of max*), *maksimum maksimuma* (engl. *max of max*) i *minimum od maksimuma* (engl. *mean of max*). Na slici 2.26 je prikazana defuzifikacija metodom *sredina maksimuma*:



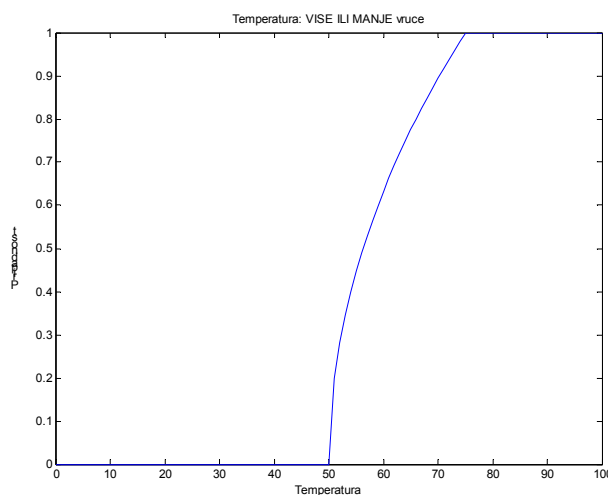
Slika 2.26. Metoda *sredina maksimuma* kao metoda defazifikacije [12]

2.4.5. Predstavljanje složenih izraza

Operatori kao što su: **I** (engl. *AND*) i **ILI** (engl. *OR*), te modifikatori kao što su: **NIJE** (engl. *NOT*), **JAKO** (engl. *VERY*) i **VIŠE ili MANJE** (engl. *MORE or LESS*) koriste se za generiranje složenih vrijednosti iz osnovnih vrijednosti npr.:

- **ILI** - odgovara maksimumu ili uniji
- **I** - odgovara minimumu ili presjeku
- **NIJE** - odgovara komplementu
- **JAKO, VIŠE, MANJE** - odgovaraju različitim stupnjevima pojačavanja suprotnosti

JAKO, **VIŠE**, **MANJE** zovu se lingvističkim modifikatorima. Implementacija Modifikator (**JAKO**) implementira se kvadriranjem, a modifikator (**VIŠE ili MANJE**) vađenjem kvadratnog korijena iz stupnja pripadnosti μ . Na slici 2.27 prikazan je primjer izgleda funkcije pripadnosti varijable *temperatura* predstavljene modifikatorom **VIŠE ili MANJE**.



Slika 2.27. Predstavljanje varijable *temperatura* lingvističkim modifikatorom **VIŠE ili MANJE** [12]

Treba spomenuti, da lingvistički modifikatori različito utječu na različite funkcije pripadnosti što ovisi od oblika tih funkcija. Npr. na funkcije pripadnosti koje daju jednoznačne vrijednosti modifikatori nemaju utjecaja.

2.4.6. Relacije implikacije

Analitički oblik *if/then* pravila je neizrazita (*fuzzy*) relacija koja se zove *relacijom implikacije* (engl. *implication relation*): $R(x,y)$. Postoji nekoliko operatora relacije implikacije (ϕ) [12] a to su:

Operator implikacije **Zadeh Max-Min**:

$$\phi[\mu_A(x), \mu_B(y)] = (\mu_A(x) \wedge \mu_B(y)) \vee (1 - \mu_A(x)). \quad (2.68)$$

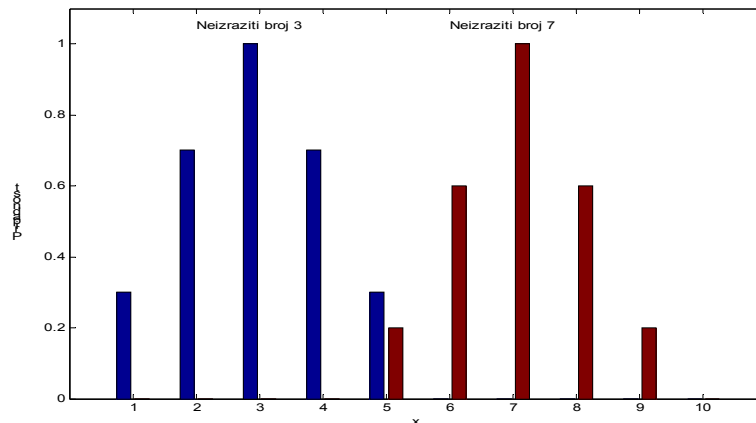
Operator implikacije **Mamdani Min**:

$$\phi[\mu_A(x), \mu_B(y)] = \mu_A(x) \wedge \mu_B(y). \quad (2.69)$$

Operator implikacije, **Larsonov umnožak**:

$$\phi[\mu_A(x), \mu_B(y)] = \mu_A(x) \cdot \mu_B(y). \quad (2.70)$$

Kao što je već spomenuto, *neizraziti brojevi* (*singletoni*) su neizraziti skupovi koji se koriste kod aplikacija kod kojih je poželjno eksplicitno predstavljanje nejasnoća i nesigurnosti koje su utvrđene u numeričkim podacima. Na slici 2.28 je primjer neizrazitih brojeva 3 i 7.

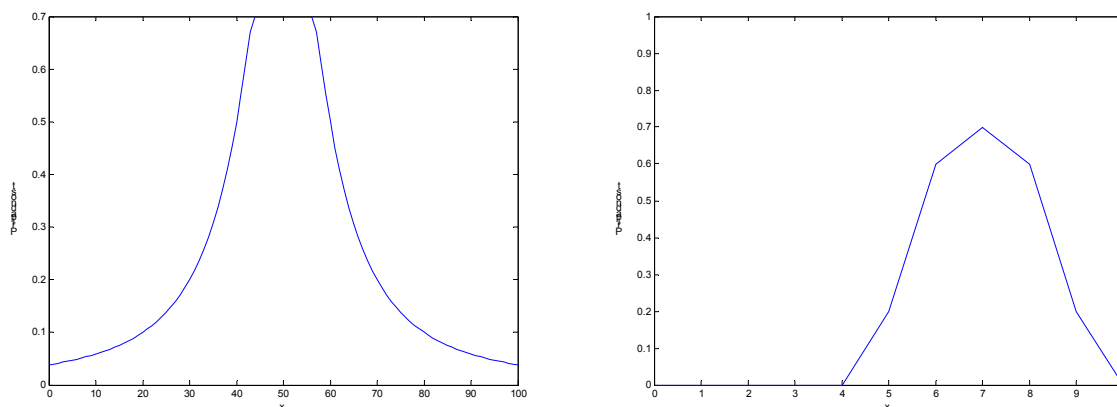


Slika 2.28. Primjer predstavljanja *neizrazitih brojeva 3 i 7 neizrazitim skupovima* [12]

Kao primjer za ilustraciju *Mamdani Min* operatora implikacije, pretpostavimo sljedeće pravilo:

if x je "neizraziti broj 3",
then y je "neizraziti broj 7".

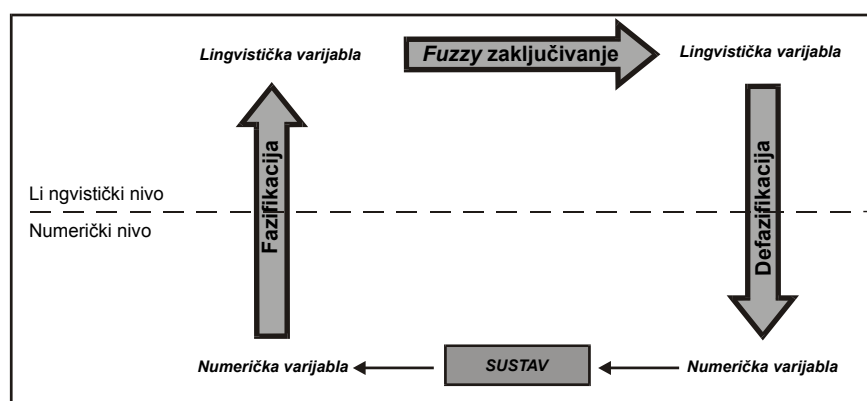
Npr. kada je $x=2$, on odgovara *neizrazitom skupu 3* sa stupnjem pripadnosti $\mu=0,7$. Ova se vrijednost zove *stupanj ispunjenja* (engl. *degree of fulfillment – DOF, firing strenght*) *if* dijela pravila (engl. *antecedent*). Stoga i *then* dio pravila (engl. *consequent*) ima isti *DOF*. Ovo ima za posljedicu tzv. *podrezivanje* izlaznog neizrazitog broja na maksimalnu vrijednost od 0,7 (slika 2.29).



Slika 2.29. Primjer Mamdani min implikacijskog operatora neizrazitog broja na ulazu i izlazu [12]

2.4.7. Fuzzy algoritam

Cilj je neizrazite logike kao jedne od metoda umjetne inteligencije, da ljudski način razmišljanja tj. zaključivanja na određeni način pretvori u algoritam upotrebljavajući pri tome matematičke metode. Rad fuzzy algoritma temelji se na tri procesa (slika 2.30): **fazifikacije** (engl. *fuzzification*), **zaključivanja** (engl. *inference*) i **defazifikacije** (engl. *defuzzification*). Fazifikacija je proces u kojem se izračunava stupanj pripadnosti μ lingvističkih varijabli pomoću određene funkcije pripadnosti. Sve lingvističke varijable sa mogućim vrijednostima (skupovima) nalaze se unutar *if/then* pravila. U procesu zaključivanja se numeričke vrijednosti varijabli pretvaraju u lingvističke varijable te se za danu situaciju pronalazi prikladno *if/then* pravilo iz kojeg se dobiva preslikana lingvistička vrijednost varijable. U procesu defazifikacije se lingvističke vrijednosti varijabli dobivene u procesu zaključivanja pomoću određenih funkcija pripadnosti pretvaraju u numeričke vrijednosti.



Slika 2.30. Blok shema fuzzy algoritma [13].

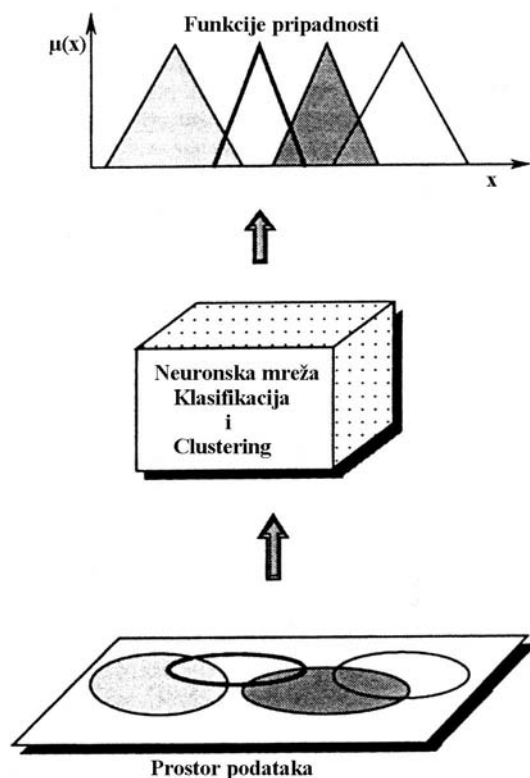
2.5. NeuroFuzzy

2.5.1. Uvod

Uporabom tehnika učenja neuronskih mreža omogućava nam ugrađivanje empiričkih informacija u *fuzzy* sustav, čime se značajno povećava područje primjene *fuzzy* logike. Korisnost *fuzzy* sustava će se zbog ugrađenih empiričkih i ekspertnih (iskustvenih) informacija uvelike poboljšati. Prednost je ekspertnih informacija u tome što omogućavaju smanjenje broja mogućih kombinacija *fuzzy* pravila na nekolicinu koja su najvažnija, a zbog toga je i kasnije održavanje *fuzzy* sustava relativno jednostavno. Međutim, ograničenje uporabe samo ekspertnih informacija, je nemogućnost finog podešavanja *fuzzy* sustava koji bi davao točne izlaze za slučaj nekoliko, vjerojatno kontradiktornih ulaznih kombinacija. Primjenom tehnika učenja temeljenih na greški, omogućavaju *fuzzy* sustavu učenje kompliciranih interakcija unutar empirijskih podataka. Osim u procesu učenja, metodologija neuronskih mreža se kod modeliranja *fuzzy* sustava primjenjuje i kod izbora pravila, određivanja oblika funkcija pripadnosti, te kod tzv. *hibridnih* sustava koji su kombinacija neuronskih mreža i *fuzzy* sustava. U nastavku su opisane neke od implemetacija neuronskih mreža u *fuzzy* sustave.

2.5.2. Neuronske mreže za određivanje funkcija pripadnosti

Određivanje funkcija pripadnosti može se promatrati kao problem 'skupina grozdova' i *klasifikacije* podataka. Podaci se najprije klasificiraju (korak *klasifikacije*) u skupine (engl. *clusters*), a zatim se pojedinačnim uzorcima u skupinama dodjeljuju stupnjevi pripadnosti μ (korak *fazifikacije*). Poznata arhitektura neuronskih mreža koja je prilagođena za pronalaženje *cluster*a u ulaznim podacima su Kohonen-ove *samoorganizirajuće mape* (engl. *self organizing maps-SOM*) [14]. Nakon utvrđivanja centara *cluster*a, parametri širine *SOM* funkcija (obično Gauss-ova funkcija) postavljaju se tako da *SOM* izlazi predstavljaju stupnjeve pripadnosti. Princip *klasifikacije* i *clusteringa* prikazan je na slici 2.31.



Slika 2.31. Princip *klasifikacije* i *clusteringa* za određivanje funkcija pripadnosti [12]

Ova dva koraka za određivanje funkcija pripadnosti implementirana su u neuronsku mrežu pomoću *Adeli-Hung algoritma (AHA)* [15]. *Adeli-Hung* algoritam pretpostavlja da imamo N ulaznih uzoraka s M ulaza na temelju čega se modelira dvoslojna neuronsku mreža s M ulaza i C *cluster*a.

Algoritam se sastoji od sljedećih koraka:

1. *korak:*

Izračunava se stupanj razlike između ulaznog vektora X_i i svakog centra *cluster*a C_i pomoću euklidove udaljenosti:

$$\text{dist}(X, C_i) = \sqrt{\sum_{j=1}^M (x_j - c_{ij})^2}, \quad (2.71)$$

gdje je:

x_j je j -ti ulaz,
 c_{ij} je j -ti ulaz i -tog *cluster*a,
 M je broj skupina.

2. *korak:*

Pronalaženje *cluster*a C_p koji je najbliži ulaznom uzorku

3. *korak:*

Usporedba udaljenosti najbližeg *cluster*a (X, C_p) s nekom od ranije određenom udaljenošću. Ako je ta udaljenost bliža od ranije određene udaljenosti, ona se dodaje *clusteru*, ako je dalje, dodaje se novi *cluster* centriran na ulazni vektor. Kada se ulaz doda *clusteru*, centar *cluster*a se ponovno izračunava kao srednja vrijednost svih uzoraka u *clusteru*:

$$C_p = [c_{p1} \ c_{p2} \ \dots \ c_{pM}] = \frac{1}{n_p} \sum_{i=1}^{n_p} X_i^p. \quad (2.72)$$

4. *korak:*

Pripadnost ulaznog vektora X_i *clusteru* C_p definira se kao:

$$\mu_p = \begin{cases} 0 & , \text{ if } D^w(X_i^p, C_p) > \kappa, \\ 1 - \frac{D^w(X_i^p, C_p)}{\kappa} & , \text{ if } D^w(X_i^p, C_p) < \kappa, \end{cases} \quad (2.73)$$

gdje je:

κ - širina trokutaste funkcije pripadnosti

$$D^w(X_i^p, C_p) = \sqrt{\sum_{j=1}^M (x_{ij}^p - c_{pj})^2} - \text{weighted norm je euklidova udaljenost.}$$

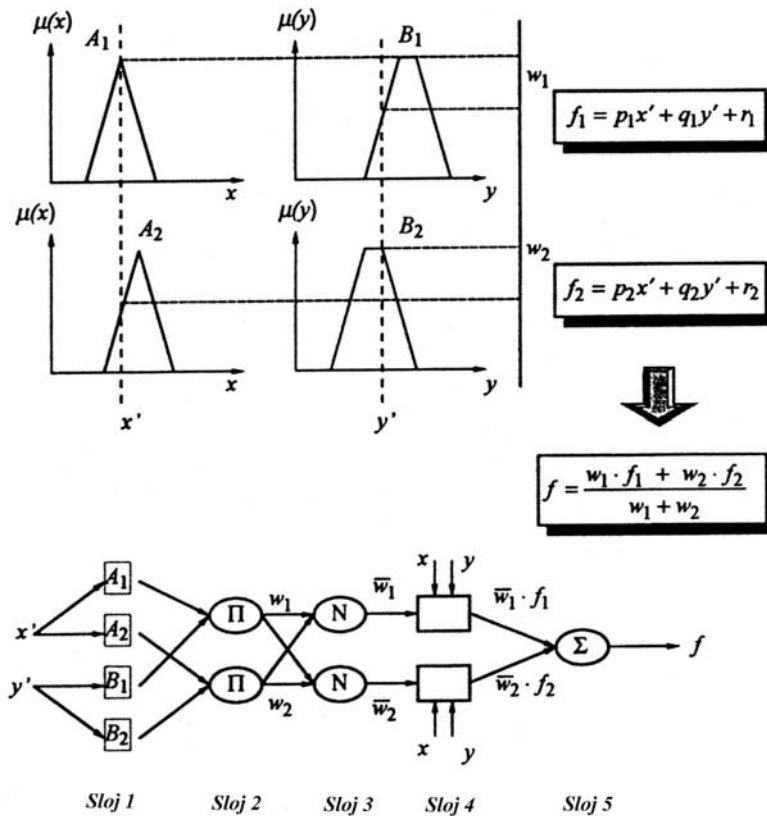
Rezultat je trokutasta funkcija pripadnosti.

2.5.3. Adaptivni neurofuzzy sustav zaključivanja

Jang, Sun i Gulley [16,17] uvode tzv. *adaptivni neurofuzzy sustav zaključivanja* (engl. *adaptive network-based fuzzy inference system-ANFIS*). Ovaj sustav koristi hibridno pravilo učenja za optimiranje parametara Sugeno [18] *fuzzy* sustava prvog stupnja. Sugeno *ANFIS* sustav prvog stupnja za slučaj dva ulaza i dva pravila prikazan je na slici 2.32. Karakteristika Sugeno tipa zaključivanja prvog stupnja je ta, što su izlazne funkcije pripadnosti lineranog tipa ili su konstante. U slučaju na slici 2.32 imamo dva pravila čiji je *consequent* dio linearnog tipa:

$$\begin{aligned} \text{if } x \text{ is } A_1 \text{ AND } y \text{ is } B_1 \text{ then } f_1 &= p_1x + q_1y + r_1, \\ \text{if } x \text{ is } A_2 \text{ AND } y \text{ is } B_2 \text{ then } f_2 &= p_2x + q_2y + r_2. \end{aligned} \quad (2.74)$$

Oznake p_n , q_n i r_n predstavljaju parametre polinoma prvog stupnja.



Slika 2.32. Jednoulazni *Sugeno* model prvog stupnja sa dva pravila [12]

2.5.4. ANFIS - hibridni algoritam učenja

Struktura *ANFIS*-a sastoji se od dvaju tipa parametara čije se vrijednosti mogu dobiti učenjem ili treniranjem:

1. *Antecedent* parametri $[a, b, c, d]$ – parametri funkcija pripadnosti na *if* (lijevoj) strani pravila.
2. *Consequent* parametri $[p, q, r]$ – parametri funkcija pripadnosti ili parametri polinoma na *then* (desnoj) strani pravila.

ANFIS algoritam učenja primjenjuje algoritam padajućeg gradijenta (*BP-algoritam*) za optimiranje *antecedent* parametara i algoritam najmanjih kvadrata za optimiranje *consequent* parametara. Upravo zbog korištenja dvaju različitih algoritama za smanjenje greške, *ANFIS* algoritam treniranja naziva se hibridnim. Struktura *ANFIS*-a sastoji se od pet slojeva, pri čemu je izlaz iz čvorova u svakom pojedinom sloju zastupljen s O_i^l , gdje je i -ti čvor sloja 1. Slijede sloj po sloj koji se sastoje od dva ulaza i dva *Sugeno* pravila prvog stupnja. U nastavku je dan opis *ANFIS* algoritma po slojevima:

Sloj 1: Generiranje stupnja pripadnosti:

$$O_i^1 = \mu_{A_i}(x). \tag{2.75}$$

Sloj 2. Generiranje *firing strengths*

$$O_i^2 = w_i = \prod_{j=1}^m \mu_{A_j}(x) = \mu_{B_i}(x)\mu_{A_i}(x), \quad i = 1, 2. \tag{2.76}$$

Sloj 3: Normalizacija *firing strengths*

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}. \tag{2.77}$$

Sloj 4: Izračun izlaznih pravila koji se temelje na *consequent* parametrima

$$O_i^4 = y_i = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i). \quad (2.78)$$

Sloj 5: Zbrajanje svih izlaza iz sloja 4

$$O_1^5 = \sum_i y_i = \sum_i \bar{w}_i f_i = (\bar{w}_1 x_1) p_1 + (\bar{w}_1 x_2) q_1 + \bar{w}_1 r_1 + (\bar{w}_2 x_2) p_2 + (\bar{w}_2 x_2) q_2 + \bar{w}_2 r_2. \quad (2.79)$$

U posljednjem se sloju *consequent* parametri mogu riješiti primjenom algoritma najmanjih kvadrata. Uporabljiviji oblik izraza (2.79) je sljedeći:

$$O_1^5 = y = (w_1 x_1) p_1 + (w_1 x_2) q_1 + w_1 r_1 + (w_2 x_1) p_2 + (w_2 x_2) q_2 + w_2 r_2, \quad (2.80)$$

$$y = \begin{bmatrix} w_1 x_1 & w_1 x_2 & w_1 & w_2 x_1 & w_2 x_2 & w_2 \end{bmatrix} \begin{bmatrix} p_1 \\ q_1 \\ r_1 \\ p_2 \\ q_2 \\ r_2 \end{bmatrix} = \mathbf{XW}.$$

2.5.5. Metoda najmanjih odstupanja

Kao što je već rečeno, *consequent* parametri mogu se riješiti metodom *najmanjih odstupanja* (engl. *least squares regression*). Kada izlazni sloj mreže obavlja linearnu kombinaciju izlaza iz prethodnog sloja, za izračun težina upotrebljava se metoda najmanjih kvadrata, što je bolje od iterativnog učenja sa BP-algoritmom. Izlazi pravila predstavljeni su sa $(p \times 3n)$ dimenzionalnom matricom X , s p -redaka što odgovara broju ulaznih uzoraka i n -stupaca što odgovara broju pravila. Željeni ili ciljani izlazi predstavljeni su sa $(p \times m)$ dimenzionalnom matricom Y s p -redaka i m -kolona što odgovara broju izlaza. Metode najmanjih kvadrata primjenjujemo za matricu težina W dimenzija $(n \neq 1, m \neq 1)$.

$$Y = X * W. \quad (2.81)$$

Ako matrica X ima inverziju, tada je izraz za izračunavanje vektora težina W jednak:

$$W = X^{-1} * Y. \quad (2.82)$$

Međutim, obično nije slučaj da matrica X ima inverziju. Stoga se primjenjuje pseudoinverzija matrice za izračunavanje vektora težina W :

$$W = (X^T * X)^{-1} * X^T * Y. \quad (2.83)$$

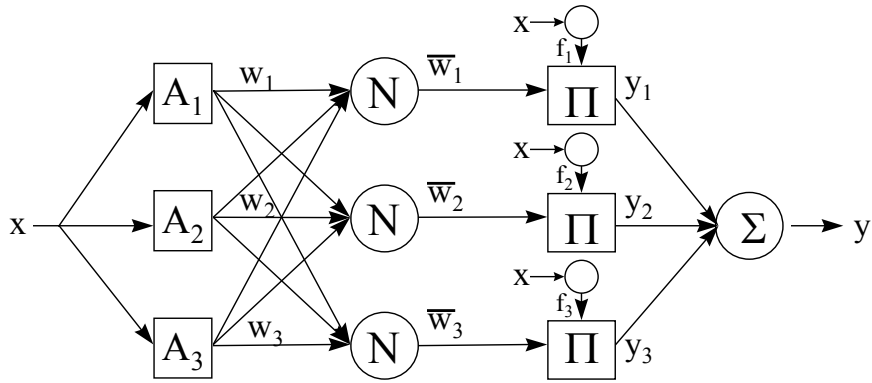
U izrazu (2.83) X^T je transponirani X .

2.5.6. ANFIS – primjer hibridnog algoritma učenja

Za bolje razumijevanje strukture *ANFIS-a* i procesa učenja, razmotrit će se *Sugeno* sustav prvog reda sa tri pravila za slučaj aproksimacije funkcije [12]:

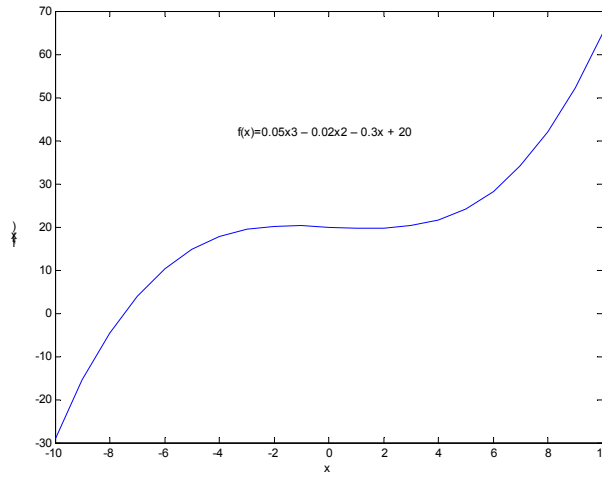
$$\begin{aligned} \text{if } x \text{ is } A_1 \text{ then } f_1 &= p_1 x + r_1, \\ \text{if } x \text{ is } A_2 \text{ then } f_2 &= p_2 x + r_2, \\ \text{if } x \text{ is } A_3 \text{ then } f_3 &= p_3 x + r_3. \end{aligned} \quad (2.84)$$

Ovaj ANFIS ima tri trapezoidne funkcije pripadnosti (A_1, A_2, A_3) i može se prikazati sljedećim blok-dijagramom, slika 2.33.



Slika 2.33. ANFIS struktura jednoulaznog Sugeno modela prvog stupnja sa tri pravila [12]

Funkcija koja će se aproksimirati je polinom trećeg stupnja: $f(x)=0.05x^3 - 0.02x^2 - 0.3x + 20$, a ulazni podaci su u intervalu $x=[-10,10]$, slika 2.34.

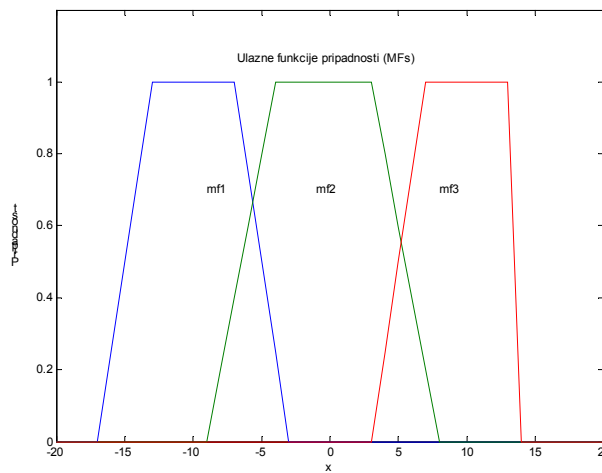


Slika 2.34. Izgled funkcije za ANFIS aproksimaciju [12]

Slijedi ANFIS algoritam po slojevima:

Sloj 1: Generiranje trapezoidnih funkcija i stupnja pripadnosti:

$$O_i^1 = \mu_{A_i}(x)$$



Slika 2.35. Generiranje funkcija i stupnja pripadnosti [12]

Prema slici 2.35, *antecedent* parametri $[a,b,c,d]$ trapezoidnih funkcija pripadnosti su sljedeći:

$$mf1 = [-17, -13, -7, -3],$$

$$mf2 = [-9, -4, 3, 8],$$

$$mf3 = [3, 7, 13, 8].$$

Sloj 2. Generiranje *firing strengths* ili *degree of fulfillment -DOS*

S obzirom da nemamo *AND* ili *OR* operatore u pravilima tada je *DOS* :

$$O_i^2 = w_i = \mu_{A_i}(x), \text{ odnosno,}$$

$$w_1 = \mu_1(x),$$

$$w_2 = \mu_2(x),$$

$$w_3 = \mu_3(x).$$

Sloj 3: Normalizacija *firing strengths*

Normalizacija se izračunava prema sljedećem izrazu:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2 + w_3}.$$

Ako je $w_1=0$, $w_2=0$ i $w_3=0$ tada je po definiciji $n\bar{w}_i = 0$ zbog sprečavanja dijeljenja sa nulom.

Sloj 4: Izračun izlaznih pravila koji se temelje na *consequent* parametrima

$$O_i^4 = y_i = \bar{w}_i f_i = \bar{w}_i (p_i x_i + r_i).$$

Za konkretan slučaj *consequent* parametri su:

$$p1 = 8.3762,$$

$$p2 = 0.7055,$$

$$p3 = 8.2927,$$

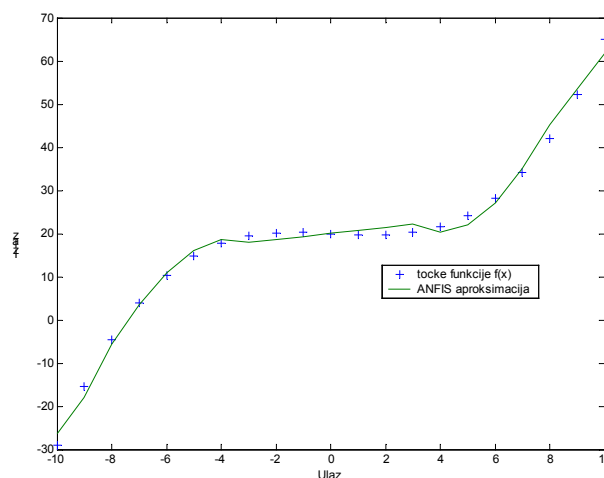
$$r1 = 57.4508,$$

$$r2 = 20.0514,$$

$$r3 = -21.1564.$$

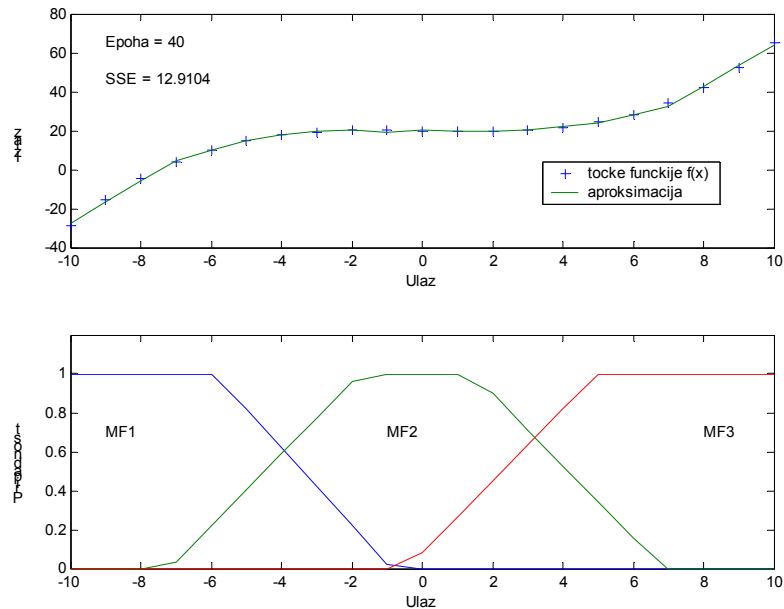
Sloj 5: Zbrajanje svih izlaza iz sloja 4 i ispis rezultata

$$O_1^5 = \sum_i y_i = \sum_i \bar{w}_i f_i = (w_1 x) p_1 + w_1 r_1 + (w_2 x) p_2 + w_2 r_2 + (w_3 x) p_3 + w_3 r_3.$$

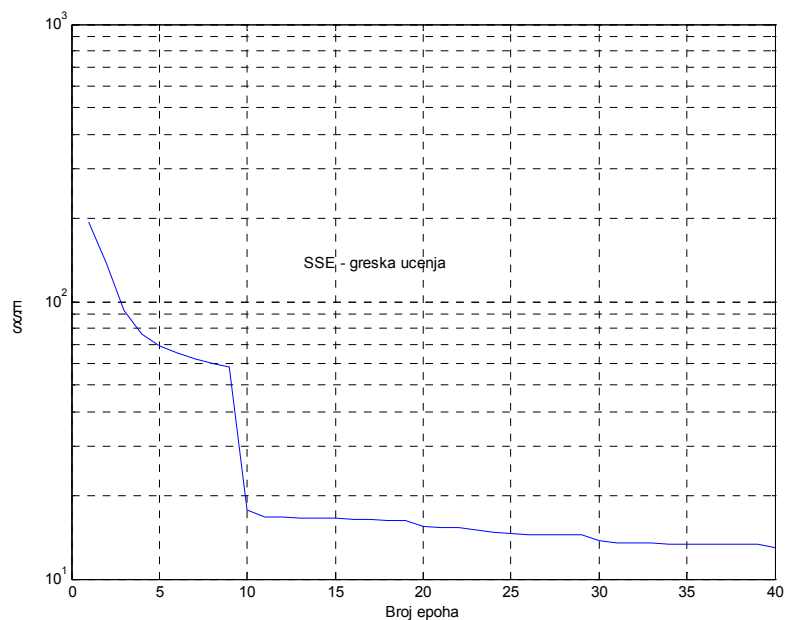


Slika 2.36. ANFIS aproksimacija funkcije [12]

Kao što se vidi na slici 2.36, već se samim rješavanjem *consequent* parametara dobila se vrlo dobra aproksimacija funkcije $f(x)=0.05x^3 - 0.02x^2 - 0.3x + 20$. Kao što je već rečeno, *antecedent* parametri rješavaju se primjenom algoritma padajućeg gradijenta (*BP-algoritam*). Na slici 2.37 dan konačni izgled *antecedent* dijela funkcija pripadnosti, kao i *consequent* dijela već spomenute funkcije $f(x)$ sa završnim parametrima: $p_1=11.0308$; $p_2=7.3120$; $p_3=10.5315$; $r_1=82.7411$; $r_2=25.4364$; $r_3=-41.2865$.



Slika 2.37. ANFIS optimirane funkcije pripadnosti $MF1, MF2, MF3$ i aproksimacija funkcije $f(x)=0.05x^3 - 0.02x^2 - 0.3x + 20$ [12]



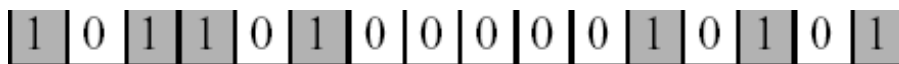
Slika 2.38. SSE graf funkcija pripadnosti nakon učenja [12]

Može se zaključiti da je ANFIS naučio za zadane ulazno-izlazne uzorke aproksimaciju funkcije $f(x)=0.05x^3 - 0.02x^2 - 0.3x + 20$ sa visokim stupnjem podudarnosti. SSE graf na slici 2.38 ukazuje na značajan pad greške nakon 40 epoha. Koeffijenti brzine učenja za *antecedent* parametre bili su: $lr_a=0.3$, $lr_b=0.5$, $lr_c=0.5$, $lr_d=0.3$.

2.6. Genetički algoritmi (GA)

2.6.1. Princip rada genetičkih algoritama

Genetičke algoritme uveo je ranih 70-tih godina John Holland [23]. Njegova je ideja bila izgraditi takvo računalo koje bi na temelju algoritama za manipulaciju sa stringovima u binarnom obliku radilo isto što i priroda radi. Njegova zamjena za prirodni kromosom je umjetni kromosom, koji se kao i prirodni sastoji od određenog broja gena, s time da je svaki umjetni gen predstavljen sa 0 ili 1 (slika 2.39).



Slika 2.39. Primjer umjetnog kromosoma [23]

Postoji težnja ka dobivanju kromosoma sa dobrim nasljednim svojstvima. Kao što znamo, priroda ima sposobnost prilagodbe i učenja bez da joj je netko kazao što i kako činiti. Drugim riječima, priroda dobre kromosome pronalazi naslijepo. Genetički algoritmi (GA) čine istu stvar, pomoću dva mehanizma koja povezuju GA sa problemom koji se rješava: *kodiranje* (engl. *encoding*) i *evaluacije* (engl. *evaluation*). Osnovni GA algoritam sastoji se od deset koraka:

1. korak

Varijable iz područja problema predstavljaju se kao geni koje čine kromosomi fiksne dužine, izabire se veličina populacije kromosoma N , *vjerojatnost križanja* (engl. *crossover probability*) p_c i *vjerojatnost mutacije* (engl. *mutation probability*) p_m .

2. korak

Definira se *funkcija prikladnosti* (engl. *fitness function*) kao mjera za procjenu primjerenosti individualnih kromosoma iz područja problema. Funkcijom prikladnosti uspostavlja se baza za selekciju kromosoma prikladnih za reproduksijsko parenje.

3. korak

Metodom slučajnog izbora generira se početna populacija kromosoma veličine N :

$$x_1, x_2, \dots, x_N$$

4. korak

Izračunava se prikladnost svakog individualnog kromosoma:

$$f(x_1), f(x_2), \dots, f(x_N)$$

5. korak

Izabire se par kromosoma za križanje iz trenutne populacije. Kromosomi roditelji izabrani su sa vjerojatnošću koja je u relaciji sa njihovom prikladnošću.

6. korak

Stvori se par kromosoma potomaka primjenom genetičkih operatora *križanja* (engl. *crossover*) i *mutacije* (engl. *mutation*).

7. korak

Stvoreni kromosomi potomci umeću se u novu populaciju.

8. korak

Korak 5 se ponavlja tako dugo dok nova populacija kromosoma ne postane jednaka po veličini početnoj populaciji N .

9. korak

Zamijeni se početna (roditelj) populacija kromosoma sa novom (potomak) populacijom.

10. korak

Vratiti se na korak 4, i proces ponavljati tako dugo dok se ne udovolji uvjetima za prekid.

Kao što se vidi *GA* su iterativni proces. Svaka iteracija zove se *generacija* (engl. *generation*). Tipični broj generacija za jednostavne (s manjim brojem kromosoma) *GA* kreće se u granicama od 50 do 500. Zbog toga što se kod *GA* primjenjuju stohastičke metode pretraživanja, prikladnost populacije postaje stabilna tek nakon velikog broja generacija prije nego što se pojavi superioran kromosom. Zbog toga se prakticira prekid procesa iteracija nakon zadanog broja generacija, a nakon se traži najbolji kromosom u populaciji. Ako se ne pronade zadovoljavajuće rješenje ponavljaju se koraci od 1 do 10.

Kao primjer, navesti će se traženje maksimuma funkcije $f(x)=15x-x^2$. Slijedi razrada po koracima od 1 do 10.

1. korak

Pretpostavka je da varijabla x (kromosom) može poprimiti samo cijele brojeve (integer) od 1 do 15. Ako te cijele brojeve prikažemo binarno, svih petnaest kromosoma imati će samo četiri gena, kao što je prikazano slikom 2.40.

<i>integer</i>	<i>binarno</i>	<i>integer</i>	<i>binarno</i>	<i>integer</i>	<i>binarno</i>
1	0 0 0 1	6	0 1 1 0	11	1 0 1 1
2	0 0 1 0	7	0 1 1 1	12	1 1 0 0
3	0 0 1 1	8	1 0 0 0	13	1 1 0 1
4	0 1 0 0	9	1 0 0 1	14	1 1 1 0
5	0 1 0 1	10	1 0 1 0	15	1 1 1 1

Slika 2.40. Binarni prikaz gena kromosoma funkcije $f(x)=15x-x^2$ [23]

Veličina populacije kromosoma je $N=6$, vjerojatnost križanja $p_c=0.7$ i vjerojatnost mutacije $p_m=0.001$

2. korak

Funkcija prikladnosti je:

$$f(x) = 15x - x^2.$$

3. korak

Slučajnim izborom izabire se $N=6$ kromosoma. Kromosomi imaju oznake $X1$ do $X6$, a oznakama su pridruženi integeri kromosoma.

$$X1=12; X2=4; X3=1; X4=14; X5=7; X6=9.$$

4. korak

Izračunane prikladnosti funkcije $f(x)=15x-x^2$ su kako slijedi:

$$f(12) = 36,$$

$$f(4) = 44,$$

$$f(1) = 14,$$

$$f(14) = 14,$$

$$f(7) = 56,$$

$$f(9) = 54.$$

5. korak

Izbor kromosoma za parenje iz trenutne populacije izabire se na temelju iznosa *omjera prikladnosti* (engl. *fitness ratio*) - fr , a izračunava se prema izrazu:

$$f_r(i) = \frac{f(i)}{\sum_{i=1}^N f(i)} * 100, \% . \quad (2.85)$$

Za $f(i)$ iz koraka 4 a prema izrazu (2.85) proizlazi $fr(i)$:

$$f_r(36) = 16.5 \%,$$

$$f_r(44) = 20.2 \%,$$

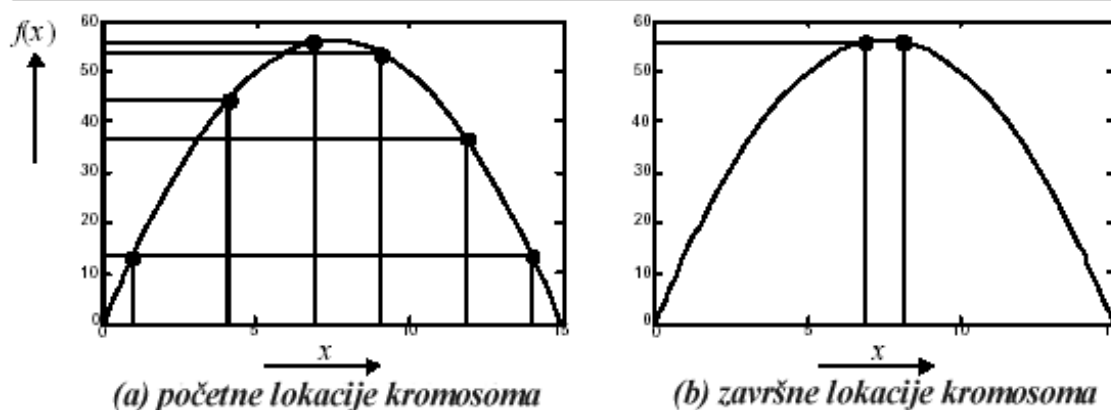
$$f_r(14) = 6.4 \%,$$

$$f_r(14) = 6.4 \%,$$

$$f_r(56) = 25.7 \%,$$

$$f_r(54) = 24.8 \%.$$

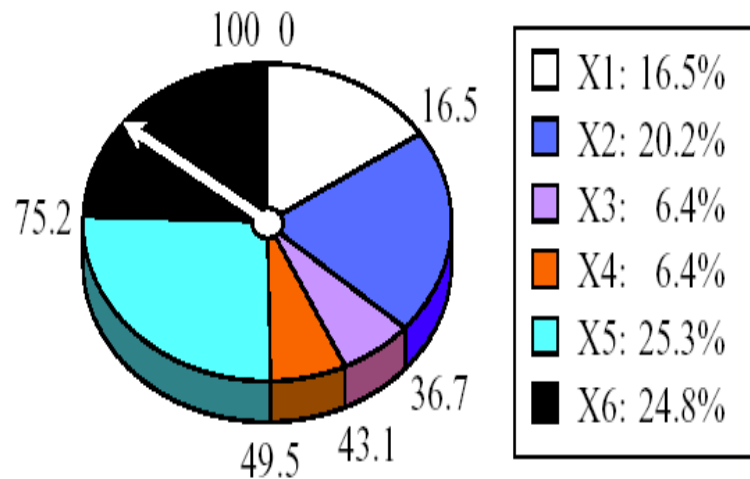
oznaka kromosoma	binarno	integer	prikladnost kromosoma	omjer prikladnosti
X1	1 1 0 0	12	36	16.5
X2	0 1 0 0	4	44	20.2
X3	0 0 0 1	1	14	6.4
X4	1 1 1 0	14	14	6.4
X5	0 1 1 1	7	56	25.7
X6	1 0 0 1	9	54	24.8



Slika 2.41. Funkcija prikladnosti i lokacije kromosoma [23]

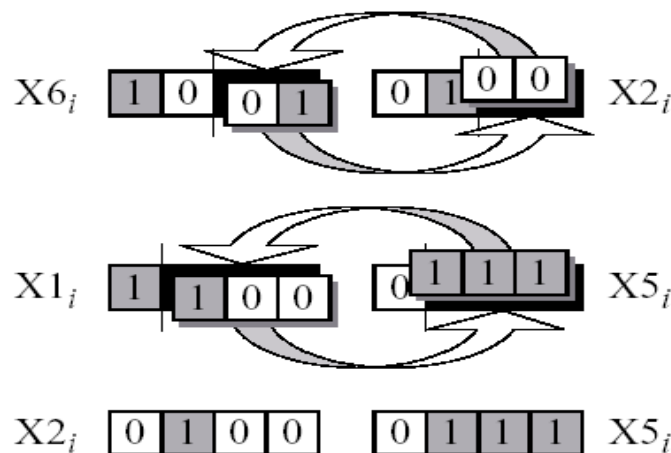
U prirodi, kao što je već spomenuto, samo evolucijski prikladni uzorci mogu preživjeti te eventualno prenijeti svoje gene u sljedeću generaciju. Za razliku od prirodnih kromosoma veličina populacije GA kromosoma ostaje neizmjenjena iz generacije u generaciju. Mjera za evolucijsku prikladnost GA kromosoma, te prenošenje gena u sljedeću generaciju, je već spomenuti omjer prikladnosti fr . Kromosomi koji imaju veći fr imaju veću vjerojatnost prenošenja gena u sljedeću generaciju. Na taj se način prosječna prikladnost kromosoma povećava iz generacije u generaciju.

Najčešća metoda za izbor roditelj kromosoma je tzv. *kolo sreće* (engl. *roulette wheel*), a prikazana je na slici 2.42. S obzirom da je početna populacija bila 6 kromosoma to će i sljedeća generacija imati 6 kromosoma. To znači da će *kolo sreće* trebati okrenuti 6 puta. Pretpostavka je da su na taj način izabrani sljedeći kromosomi: $X6, X1, X2, X2, X5, X5$.

Slika 2.42. Izbor kromosoma metodom *kola sreće* [23]

6. korak

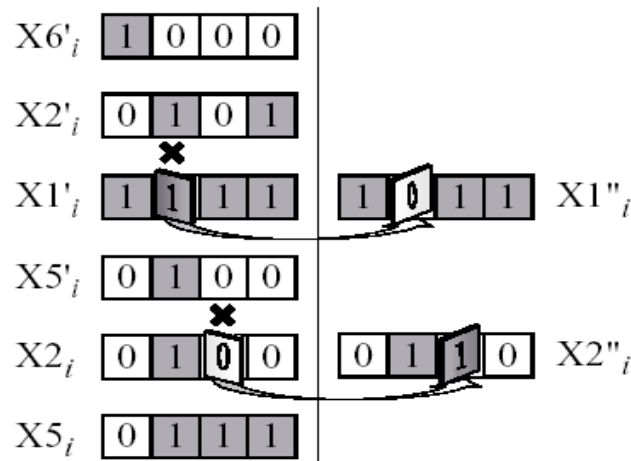
Nakon što su izabrani roditelj kromosomi primjenjuje se operator *križanja* (engl. *crossover*). Operator križanja slučajnim odabirom izabire točku križanja dvaju roditelj kromosoma, koja se nalazi na nekom od gena kromosoma. Geni oba kromosoma desno od te točke križanja razmjenjuju se između roditelj kromosoma, a kao rezultat zamjene gena nastaje novi potomak. Princip križanja kromosoma prikazan je na slici 2.43.



Slika 2.43. Princip križanja kromosoma [23]

Ako ne dođe do križanja parova kromosoma, tada mjesto zauzimaju klonovi, a potomci koji su u tom slučaju nastali su kopija svojih roditelja.

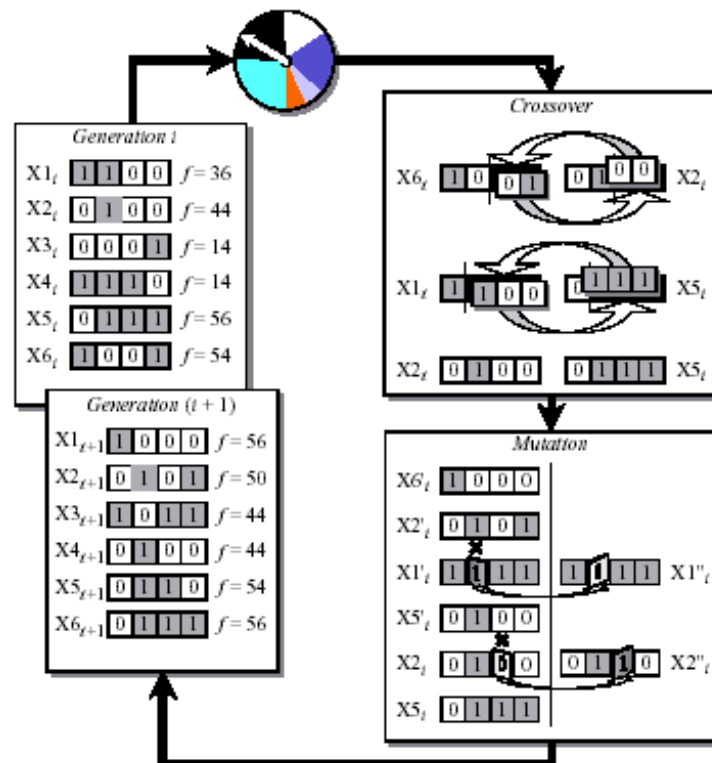
Nakon križanja može se primijeniti *operator mutacije* (engl. *mutation operator*) čiji je zadatak modifikacija gena. Operator mutacije analogan je *mementumu* kod neuronskih mreža, a s matematičke strane gledišta njegov zadatak je izbjegavanje lokalnih minimuma. Operator mutacije mijenja (slika 2.44) slučajno izabrani gen u kromosomu za određeni iznos čime se zapravo simulira utjecaj prirode na genetsku u tijeku evolucije i to u oba smjera: poboljšanja ili pogoršanja određenih svojstva uzorka. Tipični iznos vjerojatnosti mutacije kreću se od 0.001 do 0.01.



Slika 2.44. Princip mutacije kromosoma [23]

7. korak

Stvoreni novi kromosomi potomci $X1''$ i $X2''$ stavljaju se u novu populaciju te slijede ponavljanja opisan u koracima 8,9,10. Pojednostavljena shema cjelokupanog ciklusa *GA* prikazana je slikom 2.45.

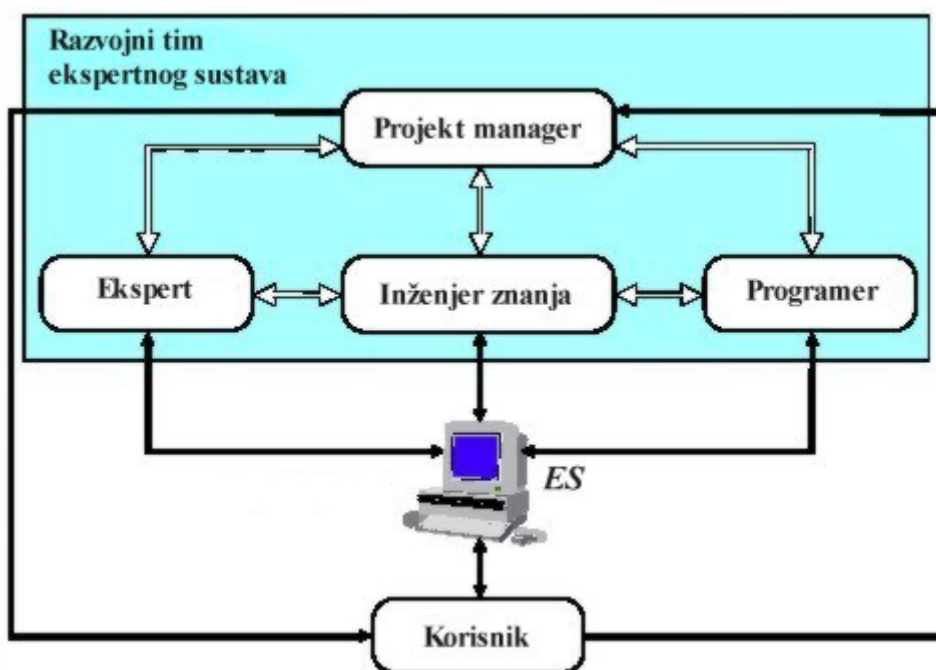
Slika 2.45. Shema ciklusa *GA* [23]

S obzirom na razmatranu problematiku ovog rada, genetički algoritmi primjenjeni za optimizaciju parametra (*koeficijent brzine učenja, momentum, vrste prijenosnih funkcija, broj slojeva, broj neurona*) algoritama neuronskim mreža. Uvođenjem *GA* izbjeglo se ručno podešavanje nabrojanih parametara što je vrlo mukotrpno i vremenski zahtjevno, a iziskuje i značajno iskustvo u primjeni neuronskih mreža.

2.7. Ekspertni sustavi

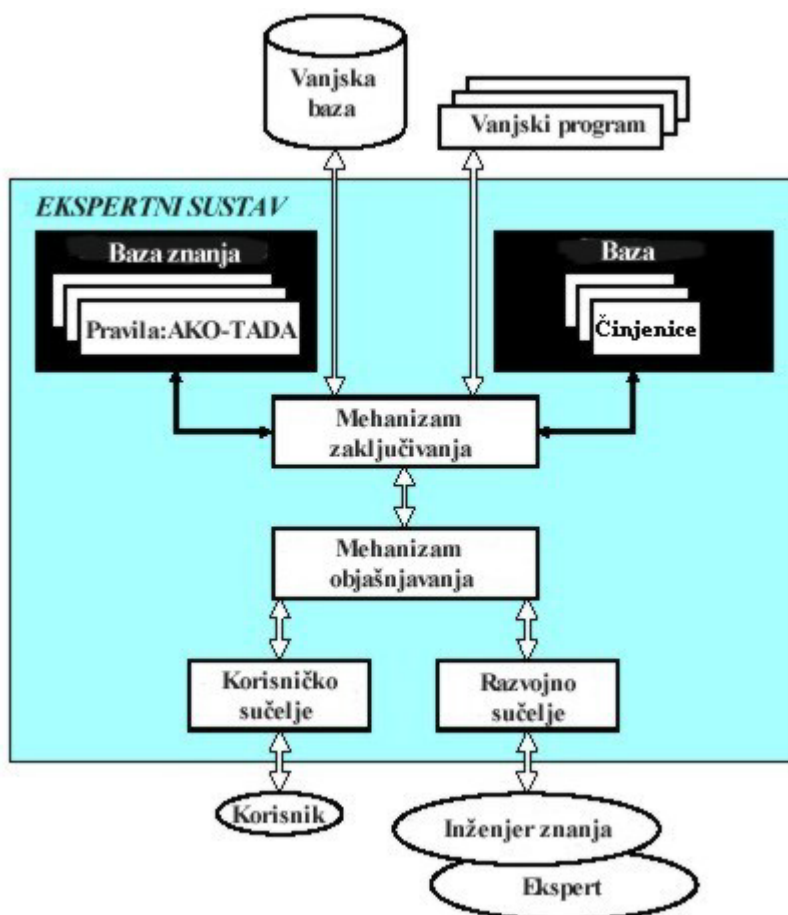
2.7.1. Uvod

U literaturnim izvorima [19,20] navode se slične definicije pojma "ekspertni sustavi" (engl. *expert systems*), a sinteza definicije je: *Ekspertni sustavi su računalni programi u koje je ugrađeno ljudsko znanje uz pomoć kojeg rješavaju probleme iz nekog specifičnog područja na sličan način kako ih rješava čovjek-stručnjak*. Pristup u razvoju ekspertnog sustava (u daljnjem tekstu *ES*) je multidisciplinarnan (slika 2.46), što znači da u njegovu razvoju sudjeluju stručnjaci različitih zanimanja, a obično su to: *projekt manager*, *ekspert iz područja*, *inženjer znanja*, *programer* i *korisnik*. Od kvalitete njihove suradnje ovisi i kvaliteta *ES*-a. Najvažniji član razvojnog tima je *ekspert* (stručnjak) s najviše iskustva iz područja problema. Od njega se očekuje dobra sposobnost komunikacije i prenošenja znanja. Sljedeći važan član je *inženjer znanja* (engl. *knowledge engineer*) od kojeg se u prvome redu očekuje vještina 'brzog ulaženja' u različite vrste problema, te smisao za dizajn, modeliranje i izgradnju *ES*-a. Zadaća *projekt managera* je nadziranje i koordiniranje fazama razvoja *ES*-a. *Programer* je zadužen za kodiranje tj. prevođenje znanja o problemu u oblik koji je razumljiv računalu. Uloga korisnika u razvojnoj fazi *ES*-a je "savjetnička" u smislu informiranja o "težini" rada sa korisničkim sučeljem.



Slika 2.46. Razvojni tim ekspertnog sustava [19]

Struktura *ES*-a sa glavnim komponentama shematski je prikazana na slici 2.47. U kodiranom obliku *baza znanja* i *baza činjenica* sadrže zbirku potrebnih elemenata znanja iz područja problema. Za razliku od baze znanja koja obično ima strukturu *pravila* (engl. *rules*) ili *okvira* (engl. *frames*), *vanjska baza* ima matričnu strukturu koja se sastoji od *slogova* i *polja*. Zadatak *mehanizma zaključivanja* (engl. *inference engine*) je izabrati elemente znanja relevantne za rješavanje određenog problema i povezati ih u zaključak koji se, ovisno o zadanom okviru, može interpretirati kao slijed zaključivanja (npr. od simptoma do dijagnoze) ili kao plan djelovanja (npr. slijed operacija). Komponente zaključivanja ne mogu to činiti samostalno, nego su im potrebne informacije o određenom problemu. Za vrijeme procesa rješavanja problema, te se informacije osiguravaju pomoću komunikacijskih komponenata. Taj se postupak često odvija putem dijaloga (pitanje-odgovor) s korisnikom putem zaslona i tipkovnice računala. Također je u procesu zaključivanja značajna i mogućnost komunikacije s ostalim vanjskim sustavima (*vanjskim programima*), kao npr. senzorima, regulatorima ili s drugim softverskim sustavima kao što su baze podataka. *Mehanizam objašnjavanja* (engl. *explanation facilities*) ima zadatak obrade slijeda zaključivanja te pojašnjavanja korisniku zašto je postavljeno neko pitanje u tijeku konverzacije te na kraju opravdati ponuđeno rješenje od strane *ES*-a.

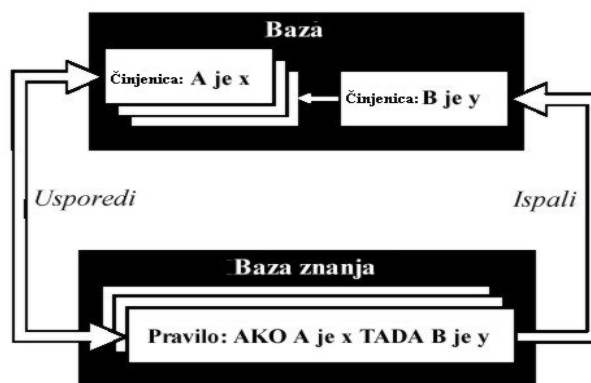


Slika 2.47. Struktura ekspertnog sustava [19]

Ekspertni sustavi bazirani su na metodama umjetne inteligencije (engl. *artificial intelligence - AI*). Stoga njihove osnove ne proizlaze samo iz informacijskih znanosti, nego i iz psihologije spoznaje i lingvistike. Struktura i oblik predstavljanja znanja temelji se na modelu vjerojatne spoznaje tj. modelu kako znanje može biti pohranjeno u ljudskom mozgu. Slično je sa *mehanizmom zaključivanja* koji simulira (oponaša) ljudski način rješavanja problema. Kriterij uspješnosti *ES*-a nije savršena simulacija ljudskog načina rješavanja problema, nego uspješno rješavanje svakodnevnih, složenih problema koji zahtijevaju ljudsku ekspertizu. U nastavku će se razmatrati dva najčešća tipa *ES*-a: *ES*-ovi temeljeni na pravilima (engl. *rule-based expert systems*) i *ES*-ovi temeljeni na okvirima (engl. *frame-based expert systems*). Podjela je proizašla iz načina predstavljanja ljudskog znanja u *ES*-ovima

2.7.2. Ekspertni sustavi temeljeni na pravilima

Struktura ekspertnih sustava temeljenih na pravilima predložena je u ranim sedamdesetim godinama od istraživača *Newell*-a i *Simon*-a sa *Carnegie-Mellon* sveučilišta [19] tzv. *modelom produkcijskih pravila* (engl. *production system model*), što se smatra pretečom današnjih modernih *ES*-ova temeljenih na pravilima, slika 2.48.



Slika 2.48. Pojednostavljeni prikaz modela produkcijskih pravila [19]

Ljudski mentalni procesi su prekompleksni da bi se mogli opisati algoritmom. Međutim, većina eksperata sposobna je izraziti svoje znanje za rješavanje problema u formi tzv. **pravila** (engl. *rules*). Pojam *rule* u području *AI*, najčešći je primjenjivani tip predstavljanja znanja računalu, a definira se kao **IF-THEN** struktura koja određene informacije na strani *IF* dijela pravila dovodi u relaciju na *THEN* strani pravila, izazivajući time određenu akciju. Pravila su relativno jednostavna za kreiranje i razumijevanje, a sastoje se od dva dijela: *IF* dio se zove *premisa* (engl. *antecedent, premise, condition*), a *THEN* dio zove se *zaključak* (engl. *consequent, conclusion, action*), izraz (2.86):

$$\begin{array}{l} IF \quad < premisa > \\ THEN < zaključak > \end{array} \quad (2.86)$$

Pravila također mogu imati višestruke premise povezane logičkim operatorima *AND* (*konjunkcija*) i *OR* (*disjunkcija*), kao i njihove kombinacije unutar istog pravila, izraz (2.87):

$$\begin{array}{ll} IF < premisa 1 >; & IF < premisa 1 > \\ AND < premisa 2 >; & OR < premisa 2 > \\ AND < premisa 2 >; & OR < premisa 2 > \\ \dots & \dots \\ THEN < zaključak >; & THEN < zaključak > \end{array} \quad (2.87)$$

Premisa pravila sastoji se od dva dijela: *objekta* (engl. *linguistic object*) i *vrijednosti objekta* (engl. *object value*). Objekt i vrijednost objekta povezani su *operatorom*. Operatori kao što su *je* (engl. *is*), *jesu* (engl. *are*), *nije* (engl. *is not*), *nisu* (engl. *are not*) zovu se simbolički operatori a služe za pridruživanje tzv. *simboličkih vrijednosti* (engl. *symbolic value*) objektu. Osim simboličkih operatora, primjenjuju se i matematički operatori (<, >, =) za pridruživanje numeričkih vrijednosti objektu. Pomoću pravila možemo predstaviti *zaključake* koji implementiraju:

1. **Relacije** – objektu se dodjeljuje simbolička ili numerička vrijednost preko simboličkog ili matematičkog operatora:

$$\begin{array}{l} IF < funkcionalni_dio1 = DA > \\ AND < funkcionalni_dio2 = DA > \\ THEN < postoje_fun_dijelovi_tribo_sustava = DA > \end{array} \quad (2.87)$$

2. **Preporuke** – objektu se dodjeljuje simbolička vrijednost preko simboličkog operatora. Pridružena vrijednost ima karakter *preporuke*:

$$\begin{array}{l} IF < obradljivost = DOBRA > \\ AND < za_varljivost = DOBRA > \\ THEN < potencija_na_grupa_čelika = PODEUTEKTOIDNI > \end{array} \quad (2.89)$$

3. **Direktive** - objektu se dodjeljuje simbolička vrijednost preko simboličkog operatora. Pridružena vrijednost ima karakter direktive ili akcije koju treba poduzeti:

$$\begin{array}{l} IF < broj_pravila = 17 > \\ AND < prag_pravila = OK > \\ THEN < izracunaj_CNF_pravila > \\ AND < ispali_pravilo() > \end{array} \quad (2.90)$$

4. **Strategije** - objektu se dodjeljuje simbolička ili numerička vrijednost preko simboličkog ili matematičkog operatora. Pridružena vrijednost ima karakter strategije, u smislu, da ako je jedna ili grupa akcija uspjela ili nije uspjela, poduzima se sljedeća akcija ili grupa akcija:

$IF \quad < prekid_konverzacije = DA >$
 $THEN \quad < formiraj_matricu_za_asocijativnu_NN >$

 $IF \quad < prekid_konverzacije = DA >$
 $AND \quad < postoji_formirana_matrica_za_asocijativnu_NN = DA >$
 $THEN \quad < odredi_do\ min\ antni_mehanizam_sa_asocijativnom_NN() >$
(2.91)

U izrazu (2.91) prikazan je izvod dijela koda za slučaj kada korisnik prekine konverzaciju sa sustavom. S obzirom da sustav nije dobio sve potrebne informacije (prva strategija) za određivanje dominantnog mehanizma trošenja, odlučuje se za poziv asocijativne neuronske mreže (druga strategija) uz pomoć koje će se dobiti procjena dominantnog mehanizma trošenja.

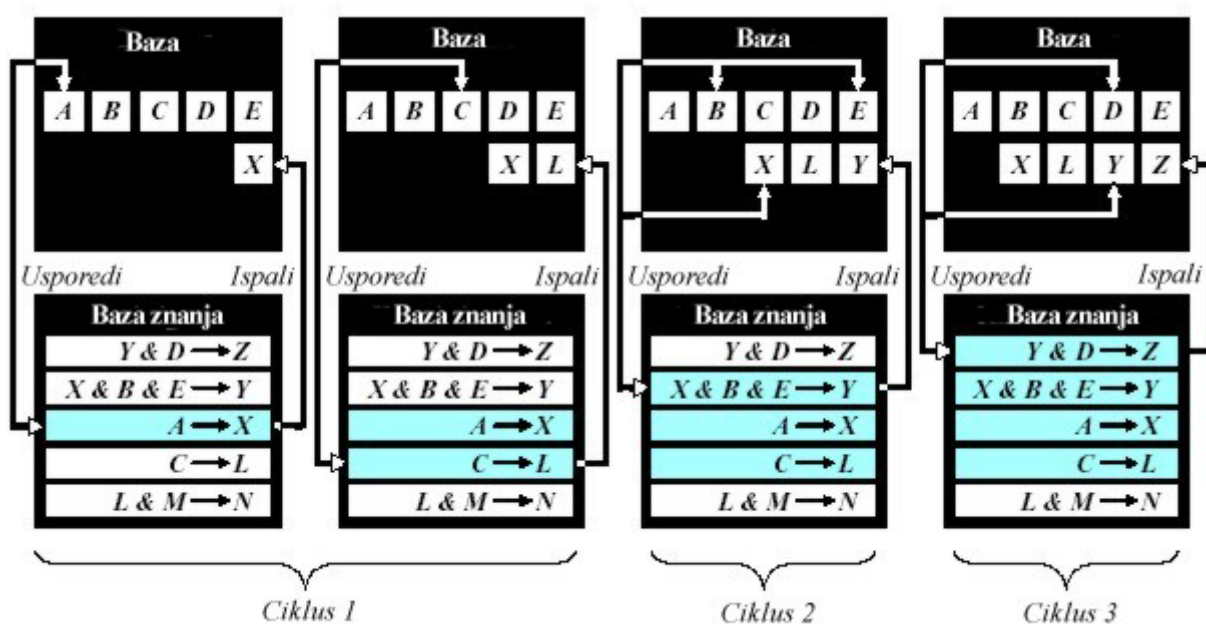
Kada su zadovoljene sve premise tj. kada su pronađene vrijednosti svih objekata unutar *IF* dijela pravila, nastupa događaj koji se zove *ispaljivanja pravila* (engl. *firing of rule*). Proces koji prethodi ispaljivanju pravila zove se *proces uspoređivanja* (engl. *matching*). Nakon događaja ispaljivanja pravila, svi objekti sa vrijednostima spremaju se u privremenu memoriju (engl. *stack*) ili tzv. bazu činjenica (engl. *facts database*). Nakon toga sustav obrađuje sljedeće pravilo principom *uspoređivanja-ispaljivanja*, te se proces nastavlja dok se ne postigne cilj tj. rješenje.

2.7.3. Mehanizam zaključivanja ekspertnih sustava temeljenih na pravilima

Jedna od najvažnijih komponenti *ES*-a je mehanizam zaključivanja koji povezuje pravila iz baze podataka sa činjenicama spremljenim u bazu fakata te na temelju toga donosi zaključak. Proces donošenja zaključka naziva se *lanac zaključivanja* (engl. *inference chains*) čime se zapravo ‘*simulira*’ ljudsko zaključivanje pri rješavanju problema. Mehanizam zaključivanja je komponenta *ES*-a koja ne zavisi od vrste problema tj. baze znanja, što znači da se jedan te isti mehanizam može primijeniti za različite probleme. Kod ekspertnih sustava temeljenih na pravilima u uporabi su dva tipa mehanizma zaključivanja:

1. **Ulančavanje unaprijed** (engl. *forward chaining*) ili *zaključivanje vođeno podacima* (engl. *data-driven reasoning*)
2. **Ulančavanje unazad** (engl. *backward chaining*) ili *zaključivanje vođeno ciljem* (engl. *goal-driven reasoning*)

Kod mehanizma *ulančavanja unaprijed* (slika 2.49) proces zaključivanja započinje sa poznatim podacima, te se propagacija unaprijed nastavlja sa tim istim podacima.

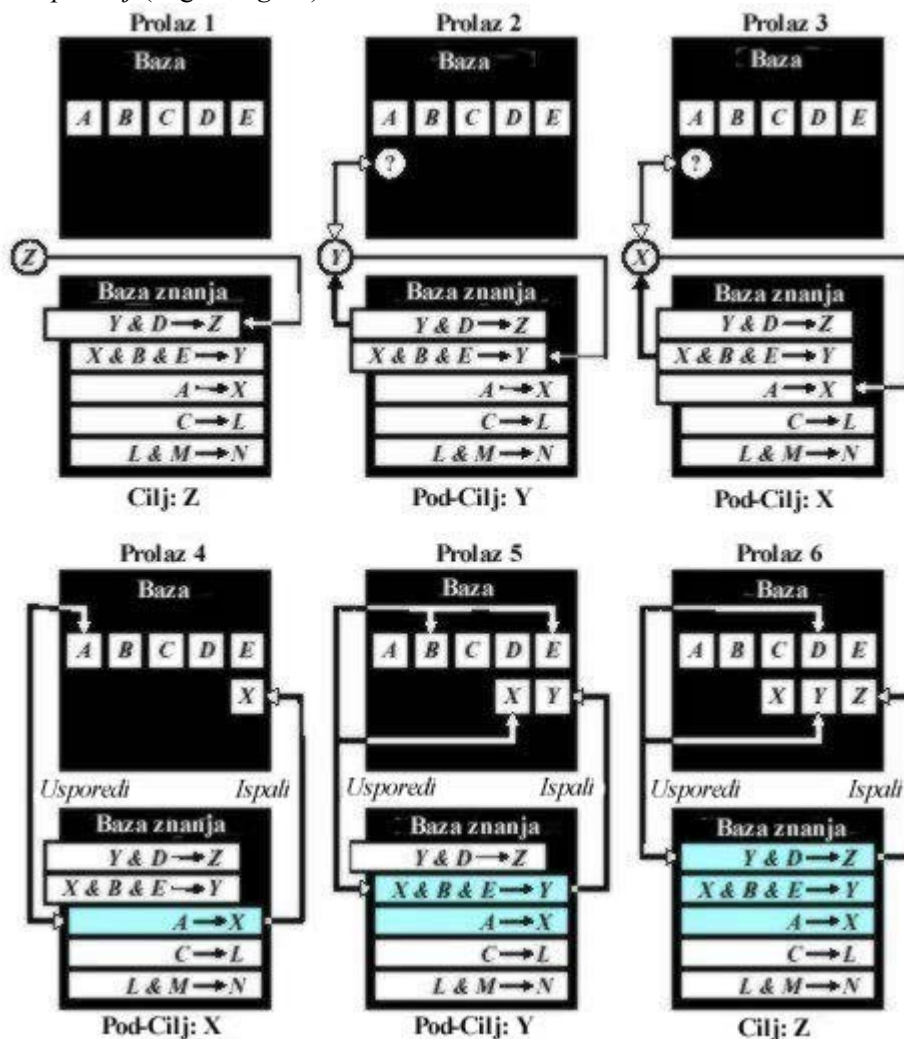


Slika 2.49. Princip rada mehanizma zaključivanja *ulančavanjem unaprijed* [19]

Ispaljuje se uvijek najgornje napisano pravilo i to samo jednom. Nakon ispaljivanja pravila nove činjenice se dodaju u bazu. Ciklus *uspoređivanja-ispaljivanja* zaustavlja se kada nema više niti jednog pravila koje bi moglo biti ispaljeno. Tako će se prema slici 2.49 u procesu uspoređivanja prvo ispaliti pravilo $A \rightarrow X$ zbog toga što u bazi fakata (ili *steku*) već postoji vrijednost objekta A a u bazu će se dodati objekt X zajedno sa vrijednošću. Daljnim uspoređivanjem pronaći će se vrijednost objekta C te će se ispaliti pravilo $C \rightarrow L$, a u bazu će se dodati objekt L sa vrijednošću. Time je završen proces uspoređivanja-ispaljivanja iz ciklusa 1. Ciklus 2 započet će uspoređivanjem i ispaljivanjem pravila $X \& B \& E \rightarrow Y$. Kao što se vidi, u privremenoj memoriji od ranije već postoje objekti X, B, E sa vrijednostima, a novi objekt koji se dodaje je Y . U ciklusu 3 ispaljuje se pravilo $Y \rightarrow D$, svi objekti sa vrijednostima su već na steku, a novi objekt koji se dodaje na stek je Z . Ciklus uspoređivanja-ispaljivanja nastavio bi se dalje pretraživanjem za objektom M .

Simbol ' \rightarrow ' pojednostavljeno označava *IF-THEN* riječi unutar pravila. Ulančavanje unaprijed je zapravo tehnika prikupljanja podatka, što znači da će se mnoga pravila ispaliti a da pri tome ne mora nužno biti postignut cilj zaključivanja. Jedna od najčešćih primjena te tehnike je kod raščlambe ulaznih podataka dobivenih u tijeku konverzacije *ES*-a sa korisnikom, najčešće s ciljem odabira određenih skupova pitanja koja postavlja *ES*.

Kod mehanizma *ulančavanja unazad* (slika 2.50) cilj ili hipotetsko rješenje je zadano, a mehanizam zaključivanja nastoji dokazati to rješenje. Prvo se pretražuje baza znanja, pokušavajući pri tome pronaći pravilo koje možda sadrži željeno rješenje s obzirom da svako pravilo ima neko od rješenja u svome *THEN* dijelu. Ako je takvo pravilo pronađeno, i ako se pronađu sve vrijednosti svih objekata iz *IF* dijela pravila u bazi fakata, tada se pravilo ispaljuje i cilj (hipoteza) je dokazan. Ako se u prvome prolazu ne dokaže rješenje, tada se pravilo koje mehanizam zaključivanja trenutno obrađuje stavlja u privremenu memoriju, a nastoji se dokazati novi cilj, koji je sada prvi objekt iz *IF* dijela pravila i kojeg u ovom slučaju nazivamo *podcilj* (engl. *subgoal*).



Slika 2.50. Princip rada mehanizma zaključivanja *ulančavanjem unazad* [19]

Baza znanja će se pretraživati dok se svi podciljevi ne dokažu, a svi objekti u privremenoj memoriji koji nisu imali vrijednosti u prethodnim prolazima dodjeljuju se vrijednosti, i to redoslijedom unazad. Primjer na slici xx-5 pokazuje primjer dokazivanja cilja ili hipoteze Z . Očito je da u prolazu 1 u bazi činjenica (u privremenoj memoriji) ne postoji vrijednost objekta Y . Objekt Y postaje podcilj, te se u drugom prolazu traži pravilo koje dokazuje objekt Y , a to je pravilo $X \& B \& E \rightarrow Y$. U ovom pravilu na steku ne postoji vrijednost objekta X , te on postaje podcilj u trećem prolazu kada se pronalazi pravilo $A \rightarrow X$, koje dodjeljuje vrijednost objektu X . U četvrtom prolazu vrijednost objekta X stavlja se na stek, a u petom prolazu dodjeljuje se vrijednost objektu Y s obzirom da se na steku već nalaze vrijednosti objekata B i E . U šestom prolazu vrijednosti svih objekata koje dokazuju cilj tj. hipotezu Z nalaze se na steku, čime je ista dokazana.

2.7.4. Ekspertni sustavi temeljeni na okvirima

Okvire (engl. *frames*) je prvi predložio Minsky [21] kao predodžbu znanja koja na način prikladan za strojnu obradu predodžbuje podatke i znanja o objektu i događajima vezanim uz objekt, posebice za specifično stanje u kojem se objekt može naći. Okviri olakšavaju donošenje zaključaka u danom kontekstu čak i u slučaju kada nisu izričito poznate sve detaljnosti vezane uz taj kontekst. Okvir opisuje grupu ili skupinu objekata kojima se mogu pripisati zajednička svojstva. Činjenice koje se odnose na objekt, a poznate su od ranije ili unaprijed pohranjene su u tzv. **pretincima** ili **slotovima** (engl. *slots*). Pretinci sadrže opis objekta, događaja vezanih uz objekt, stanje objekta, itd. Važno je uočiti da su neki pretinci (slotovi) popunjeni tzv. početnim vrijednostima (engl. *default*). Ukoliko se pri popunjavanju okvira ne popune takvi pretinci, onda se uzima početna vrijednost. Takva predodžba znanja posredstvom početnih vrijednosti omogućuje rasuđivanje koje uključuje "očekivanje". Prije nego li je poznat konkretan sadržaj pojedinog pretinca za dano stanje, moguće je na temelju početnih vrijednosti pretinaca "očekivati podatke" unutar tih pretinaca. Čak i ako se ne navedu podaci za sve pretince, moguće je na temelju početnih vrijednosti dopuniti znanje o promatranom objektu. Uz poznavanje nekih svojstava novog i nepoznatog objekta, moguće je pronaći okvir koji najbolje odgovara tom objektu u danom kontekstu, te zatim popuniti znanje dotada nepoznatim svojstvima objekta. Svaki od pretinaca može i sam biti okvir, a pretinci tog okvira mogu biti opet okviri itd. Postupak rasuđivanja uz primjenu okvira svodi se na popunjavanje poznatih pretinaca i upotrebu početnih vrijednosti za nepoznate podatke okvira, odabiru najprikladnijih okvira, te zatim na zaključivanje o nepoznatim podacima na temelju cjelokupne strukture okvira. Početne vrijednosti i ne moraju potpuno odgovarati svakom pojedinom objektu okvira, ali se na taj način simulira tzv. *zdravi razum* (engl. *common sense*). Svaki okvir unutar baze znanja predstavlja malu jedinicu znanja o nekom objektu čija se struktura prema slici 2.51 sastoji od:

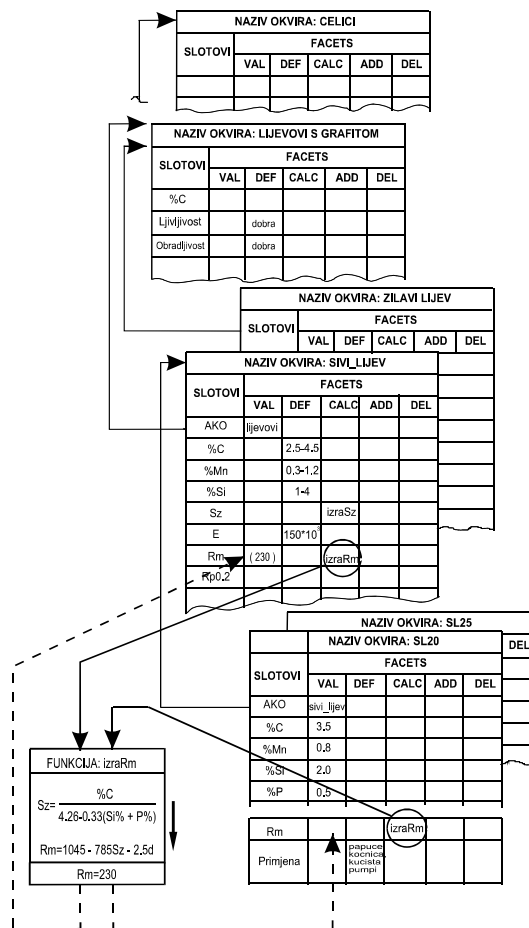
Naziv okvira					
Pretinac (slot)	Facets				
	VAL	DEF	CALC	ADD	DEL
AKO					

Slika 2.51. Struktura okvira [21]

Naziv okvira	- naziv okvira
Pretinac	- naziv pretinca ili slot
AKO	- preddefinirani naziv pretinca, služi za vezu sa drugim okvirima
VAL	- vrijednost pretinca.
DEF	- početnu vrijednost pretinca ako VAL vrijednost nije zadana
CALC	- naziv funkcije koja poziva i izračunava vrijednost pretinca ako nisu zadane VAL ili DEF vrijednosti.
ADD	- naziv funkcije koja se poziva ako se unese VAL vrijednost
DEL	- naziv funkcije koja se poziva ako se briše VAL vrijednost

Na slici 2.52 prikazan je primjer i način rada okvira unutar *ES*-a za rješavanje problema trošenja [22]. Za jedan od prikazanih primjera, pretpostavlja se da je sustavu postavljen zahtjev za prijedlogom materijala za izradu kućišta pumpi. Mehanizam za zaključivanje će pretražiti okvir bazu znanja te pronaći da npr. SL20 odgovara zadanom uvjetu s obzirom na sadržaj DEF vrijednosti pretinca *primjena*. Ako se zadaju složeniji zahtjev na pretraživanje kao npr. traži se materijal sa *dobrom obradljivošću* i *dobrom ljivljivošću* ta se svojstva materijala ne moraju nalaziti unutar VAL pretinca okvira SL20 pa čak niti unutar grupe

SIVI_LIJEV. Tada do izražaja dolazi važno svojstvo okvira, a to je mogućnost *nasljeđivanja* (engl. *inheritance*). Ukoliko mehanizam zaključivanja ne pronađe sve atribute (svojstva) kod jednog okvira, on će ih automatski pretražiti pomoću vrijednosti iz AKO (engl. *a-kind-of, is-a*) pretinca kod drugih okvira, te će njihove vrijednosti usporediti sa zahtjevanim vrijednostima. Iako SL20 nema sve tražene atribute, on ih nasljeđuje od okvira grupe materijala kojoj pripada, a to je u ovom slučaju grupa materijala LJEVOVI_S_GRAFITOM. Druga vrlo važna značajka okvira je mogućnost poduzimanja određene akcije u cilju izračunavanja vrijednosti nekog svojstva tj. atributa. U slučaju da nisu poznate VAL ili DEF vrijednosti zadanog svojstva okvira ono se mora unijeti ili izračunati. Ako se izračunava tada se u CALC svojstvo unese naziv funkcije za izračunavanje VAL vrijednosti traženog svojstva. Sljedeći primjer prema slici 2.52, a koji demonstrira spomenutu značajku, je procjena grupa materijala koje bi mogle doći u uži izbor prilikom predizbora materijala, ako su zadani R_m i kemijski sastav. Za većinu grupa materijala poznati su iznosi granica za R_m dok se kod SL-a R_m izračunava na temelju empiričke formule koja uključuje kemijski sastav i debljinu stijenke. U konkretnom slučaju mehanizam zaključivanja poziva funkciju pohranjenju u CALC *facetu* okvira SIVI_LIJEV svojstva R_m . U funkciju (*izraRm*) koju mehanizam zaključivanja poziva, prenose se vrijednosti sastava (%C, %Si, %P, d) kao parametri, izračunava se vrijednost S_z , a zatim R_m . Izračunata vrijednost privremeno se pohranjuje u VAL *facet* okvira SIVI_LIJEV, a nakon toga se izračunata vrijednost uspoređuje sa zadanom vrijednošću R_m .



Slika 2.52. Primjer strukture i načina rada okvira [22]

Kao što se vidi, okvir osim sposobnosti spremanja znanja, ima i sposobnost provjere i manipulacije znanjem. To svojstvo omogućavaju tzv. *metod i demon procedure* (engl. *methods and demons procedure*). Izračunavanja vrijednosti VAL pretinca u gornjem primjerom funkcijom *izraRm*, izvedeno je jednom od metoda mehanizma zaključivanja okvira koju zovemo *kada treba metodom* (engl. *when needed method*). Sljedeća važna metoda je *demon* (engl. *demon method*). Najčešće se primjenjuje kao *okidač* (engl. *trigger*) u slučaju promjene vrijednosti neke od varijabli u sustavu. Metoda *demon* je vrlo korisna za razne slučajeve automatskog pokretanja procedura kao npr. procedure međupretraživanja, procedure za prikazivanje međurezultata itd. Današnji moderni ekspertni sustavi često su kombinacija sustava temeljenih na pravilima i sustava temeljenih na okvirima. Kod takvih hibridnih sustava

jednostavnija je manipulacija tj. održavanje dijela spremljenog znanja u okviru nego unutar baze znanja pravila. Naime, zbog svojstva nasljeđivanja koju posjeduju okviri broj pravila koje je potrebno napisati u bazu znanja se značajno smanji. Veza između okvira i pravila su funkcije za pristup okviru bazi znanja, koje se kao objekti ugrađuju u premisu pravila tj u *IF* dio pravila.

2.7.5. Problem nesigurnih informacija

Informacije mogu biti djelomične, nedosljedne, nesigurne ili sve troje. Drugim riječima, informacije su često neprikladne za rješavanje problema. Zbog toga se uvodi pojam *nesigurnosti* (engl. *uncertainty*) koja se definira kao nedostatak preciznog znanja o problemu, a koje bi nam omogućavalo donošenje vjerodostojnog rješenja. U klasičnoj logici dopušteno je samo egzaktno zaključivanje što pretpostavlja da precizno znanje o problemu uvijek postoji. U pogledu informacija prirodni govor čovjeka je nesiguran i neprecizan. Često se činjenice opisuju pojmovima kao npr. *često*, *ponekad*, *gotovo uvijek* itd. Takve neprecizne činjenice tj. znanja, vrlo je teško izraziti strogo definiranom strukturom *IF-THEN* produkcijskih pravila. Međutim, ipak je i neprecizne činjenice moguće kvantificirati što su dokazali R. Simpson (1944) i M. Hakel (1968) [23]. Oni su nezavisno jedan od drugog u vremenskom razmaku od 24 g. postavili zadatak za 355 studenata da za dvadeset nepreciznih pojmova daju ocjene između 1 i 100. Ocjene imaju značenje vremenske učestalosti pojavljivanja događaja označenog pojedinim pojmom. Tako npr. ako je događaj označen sa nepreciznim pojmom *nikad* njegova će ocjena biti 0, ako je označen pojmom *uvijek* ocjena će biti 100. Rezultati njihova istraživanja prikazani su u tablici 2.1.

Tablica 2.1. Kvantifikacija nepreciznih pojmova [23]

Istraživanje R. Simpson (1944)		Istraživanje M. Hakel (1968)	
Pojam	Ocjena	Pojam	Ocjena
Uvijek	99	Uvijek	100
Vrlo često	88	Vrlo često	87
Obično	85	Obično	79
Često	78	Često	74
U pravilu	78	U pravilu	72
Učestalo	73	Učestalo	72
Prilično često	65	Prilično često	74
Prije da nego ne	50	Prije da nego ne	50
Sada i tada	20	Sada i tada	34
Ponekad	20	Ponekad	29
Povremeno	20	Povremeno	28
Jednom	15	Jednom	22
Ne često	13	Ne često	16
Obično ne	10	Obično ne	16
Malokad	10	Malokad	9
Gotovo uvijek	7	Gotovo uvijek	8
Vrlo rijetko	6	Vrlo rijetko	7
Rijetko	5	Rijetko	5
Gotovo nikad	3	Gotovo nikad	2
Nikad	0	Nikad	0

Kao što se vidi kod jednog i drugog istraživanja kvantitativne ocjene nepreciznih pojmova su vrlo slične, što navodi na zaključak da različiti ljudi u različitom vremenskom razdoblju tretiraju događaje uz koje su vezani neprecizni pojmovi na sličan način. U slučaju da su informacije necjelovite ili pak nedostaju, tada se takve informacije procesiraju pod pojmom *nepoznate informacije*. Problem nesigurnosti informacija pojavljuje se i kod velikih *ES*-ova. Veliki *ES*-ovi pohranjuju znanje više eksperata, pa je čest slučaj da za iste situacije oni imaju različita rješenja što dovodi do produciranja *spornih rješenja* a time i nesigurnosti cijelog sustava. Za rješavanje takvih situacija inženjer znanja dodjeljuje svakom ekspertu *težinu* [24] te se na temelju toga izračunava *mješovit* ili *kompozitni* zaključak. Problem je u tome da ne postoji egzaktna metoda za određivanje iznosa težina, već je to iskustvena stvar inženjera znanja.

Teorije koje se bave nesigurnim informacijama su *teorija vjerojatnosti* sa primjenom statističkih metoda (Bayesov teorem) i *teorija faktora sigurnosti* [25]. Poblježe će se razmotriti teorija faktora sigurnosti. Faktor sigurnosti (*cf*) predstavlja brojčanu mjeru ekspertovog vjerovanja u vjerodostojnost rješenja. Vrijednost faktora kreće se u granicama $+1$ ili $+100$ do -1 ili -100 . Iznos $+1$ označava *potpunu istinu* (engl. *definitely true*), a iznos -1 označava *potpunu neistinu* (engl. *definitely false*). Ako npr. ekspert smatra da su neke činjenice *gotovo sigurno istinite* (engl. *almost certainly true*) tada će zaključku pravila

dodijeliti $cf=0,8$. U tablici 2.2 navedena je interpretacija nesigurnih informacija pomoću faktora sigurnosti na način kako je to riješeno u najpoznatijem ekspertnom sustavu MYCIN [26].

Tablica 2.2. Interpretacija faktora sigurnosti u MYCINU [26]

Pojam	Faktor sigurnosti cf
sasvim sigurno ne	-1,0
sigurno ne	-0,8
vjerojatno ne	-0,6
možda ne	-0,4
nepoznato	-0,2 do +0,2
možda	+0,4
vjerojatno	+0,6
sigurno	+0,8
sasvim sigurno	+1,0

Prošireni oblik *IF-THEN* pravila u koje je dodan faktor sigurnosti cf imati će oblik prema sljedećem izrazu:

$$\begin{aligned} \text{IF} & \quad < \text{premissa } (E) > \\ \text{THEN} & \quad < \text{zaključak } (H) > \{cf\} \end{aligned} \quad (2.92)$$

U izrazu (2.92) cf predstavlja 'vjerovanje' u zaključak ili hipotezu (H) ako je premisa (E) istinita. Teorija faktora sigurnosti temelji se na dvije funkcije: **mjeri vjerovanja** (engl. *measure of belief*) – $MB(H,E)$ i **mjeri nevjerovanja** (engl. *measure of disbelief*) – $MD(H,E)$:

$$\begin{aligned} MB(H,E) &= \begin{cases} \frac{\max[p(H|E), p(H)] - p(H)}{\max[1,0] - p(H)} & \text{ako je } p(H) = 1 \\ \text{inače} & \end{cases} \\ MD(H,E) &= \begin{cases} \frac{\min[p(H|E), p(H)] - p(H)}{\min[1,0] - p(H)} & \text{ako je } p(H) = 0 \\ \text{inače} & \end{cases} \end{aligned} \quad (2.93)$$

U izrazu (2.93) $p(H)$ je iznos vjerojatnosti kada je zaključak ili hipoteza H istinita, a $p(H/E)$ je iznos vjerojatnosti kada je zaključak ili hipoteza H istinita za zadanu premisu E .

Iznosi $MB(H,E)$ i $MD(H,E)$ kreću se u granici između 0 i 1. Iznos faktora sigurnosti tj. iznos vjerovanja ili nevjerovanja u hipotezu H zavisi od vrste objekata te njihovih iznosa u *IF* dijelu pravila. Neki objekti pojačavaju vjerovanje (MB) u hipotezu H a neki pojačavaju u nevjerovanje (MD). Ukupni iznos faktora sigurnosti cf odnosno vjerovanja ili nevjerovanja u hipotezu H je:

$$cf = \frac{MB(H,E) - MD(H,E)}{1 - \min[MB(H,E), MD(H,E)]} \quad (2.94)$$

Za pravila koja unutar premisa sadrže simbolički operator **AND** kao npr.

$$\begin{aligned} \text{IF} & \quad < \text{premissa } (E_1) > \\ & \quad \cdot \\ & \quad \cdot \\ & \quad \cdot \\ \text{AND} & \quad < \text{premissa } (E_n) > \\ \text{THEN} & \quad < \text{zaključak } (H) > \{cf\} \end{aligned} \quad (2.95)$$

sigurnost u hipotezu H izračunava se prema izrazu:

$$cf(H, E_1 \cap E_2 \cap \dots \cap E_n) = \min[cf(E_1), cf(E_2), \dots, cf(E_n)] * cf. \quad (2.96)$$

Za pravila koja unutar premisa sadrže simbolički operator **OR** kao npr.

$$\begin{array}{l} IF \quad <premissa (E_1)> \\ \quad \quad \cdot \\ \quad \quad \cdot \\ \quad \quad \cdot \\ OR \quad <premissa (E_n)> \\ THEN \quad <zaključak (H)> \{cf\} \end{array} \quad (2.97)$$

sigurnost u hipotezu H izračunava se prema izrazu:

$$cf(H, E_1 \cup E_2 \cup \dots \cup E_n) = \min[cf(E_1), cf(E_2), \dots, cf(E_n)] * cf. \quad (2.98)$$

U slučaju da u bazi znanja postoje dva različita pravila koja potvrđuju istu hipotezu, npr.,

$$\begin{array}{l} Pravilo 1: IF \quad A \text{ je } X \\ \quad \quad \quad THEN \quad C \text{ je } Z \{cf = 0.8\} \\ Pravilo 2: IF \quad B \text{ je } Y \\ \quad \quad \quad THEN \quad C \text{ je } Z \{cf = 0.6\} \end{array} \quad (2.99)$$

tada se izračunava skupni faktor sigurnosti prema izrazu:

$$cf(cf_1, cf_2) = \begin{cases} cf_1 + cf_2 * (1 - cf_1) & \text{ako } cf_1 > 0 \text{ i } cf_2 > 0 \\ \frac{cf_1 + cf_2}{1 - \min[|cf_1|, |cf_2|]} & \text{ako } cf_1 < 0 \text{ ili } cf_2 < 0 \\ cf_1 + cf_2 * (1 + cf_1) & \text{ako } cf_1 < 0 \text{ i } cf_2 < 0 \end{cases} \quad (2.100)$$

Faktori sigurnosti upotrebljavaju se u slučajevima kada klasična vjerojatnost događaja nije poznata ili bi je bilo presloženo i skupo dobiti eksperimentom. To je ujedno i najčešći slučaj u praksi pri izgradnji ES-a. U slučaju da su na raspolaganju eksperimentalni podaci nekog sustava, primijeniti će se već spomenuta Bayes-ova statistička metoda.

2.8. Neke praktične značajke neuronskih mreža

2.8.1. Skaliranje, normalizacija i standardizacija ulazno-izlaznih vektora podataka

Operacije skaliranja, normalizacije i standardizacije ulazno-izlaznih podataka spadaju u tzv. 'preprocessing korake' (engl. *preprocessing steps*), što znači da se poduzimaju prije procesa učenja odnosno treninga mreže u cilju povećanja efikasnosti učenja. Pod pojmom *skaliranja* vektora podrazumijevamo dodavanje ili oduzimanje konstante a nakon toga množenje ili dijeljenje sa konstantom (npr. pretvaranje stupnjeva celzija u farenheite). Pojam *normalizacije* vektora prema literaturi o neuronskim mrežama podrazumijeva skaliranje elemenata vektora unutar vrijednosti 0 i 1 ili -1 i 1. *Standardizacija* podrazumijeva normalizaciju ulazno-izlaznog vektora na normalnu razdiobu sa srednjom vrijednošću 0 i standardnom devijacijom 1. Postavlja se pitanje je li neku od ovih operacija potrebno provesti u svim slučajevima? To u prvome redu ovisi od samih vrijednosti ulazno-izlaznih varijabli, tipu mreže koji će se primijeniti za dani problem itd. Npr. smatra se da bi ulazni podaci kod višeslojne perceptronske mreže (engl. *MPLP*) trebali biti skalirani u interval $[0, 1]$. Međutim, ako se vrijednosti ulaznih podataka grupiraju oko nule, tada ih nije potrebno dodatno skalirati. Ako pak prijenosna funkcija u izlaznom sloju daje rezultate u intervalu $[0, 1]$, tada je očito da se mora osigurati da vrijednosti izlazne varijable leže unutar tog intervala. Najbolji bi izbor bila bi prijenosna funkcija sa oblikom distribucije koji odgovara upravo izlaznim podacima danog problema. Za većinu je problema, ako prijenosna funkcija ima interval $[0, 1]$, uobičajeno skaliranje izlaznih vrijednosti unutar interavala $[0.1, 0.9]$. Međutim, takvo skaliranje kod problema klasifikacije daje kasnije pogrešne vrijednosti procjene vjerojatnosti. Također, takvo skaliranje je nepotrebno kod efikasnih algoritama učenja kao što je npr. *Levenberg-Marquardt* [27]. Prije operacije skaliranja potrebno je obratiti pažnju na način upisa vrijednosti varijabli unutar ulazno-izlaznih matrica. Vrijednosti mjerenja upisuju se kao vektori retka matrice, tako da kolone matrica predstavljaju ulazno-izlazne varijable, te tada na kolonama sprovesti normalizaciju ili standardizaciju. U radu je, gdje god je to bilo moguće, a prema preporukama iz [28,29] većina skaliranja ulazno-izlaznih podataka izvedena normalizacijom unutar intervala $[-1, 1]$ te su prema tome i odabrane odgovarajuće prijenosne funkcije. Normalizacija ulazno-izlaznih podataka je dana izrazom (2.101).

$$p_n = 2 \frac{p - \min_p}{\max_p - \min_p} - 1 \quad (2.101)$$

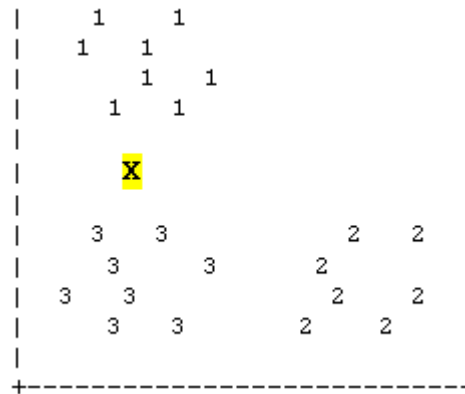
Postupak vraćanja (denormalizacija) normaliziranih podataka na originalne vrijednosti dan je izrazom (2.102),

$$p = 0.5(p_n + 1)(\max_p - \min_p) + \min_p \quad (2.102)$$

U izrazima (3.1 i (3.2) je: p -denormalizirani vektor, p_n -normalizirani vektor, \min_p -minimalna vrijednost denormaliziranog vektora, \max_p – maksimalna vrijednost denormaliziranog vektora.

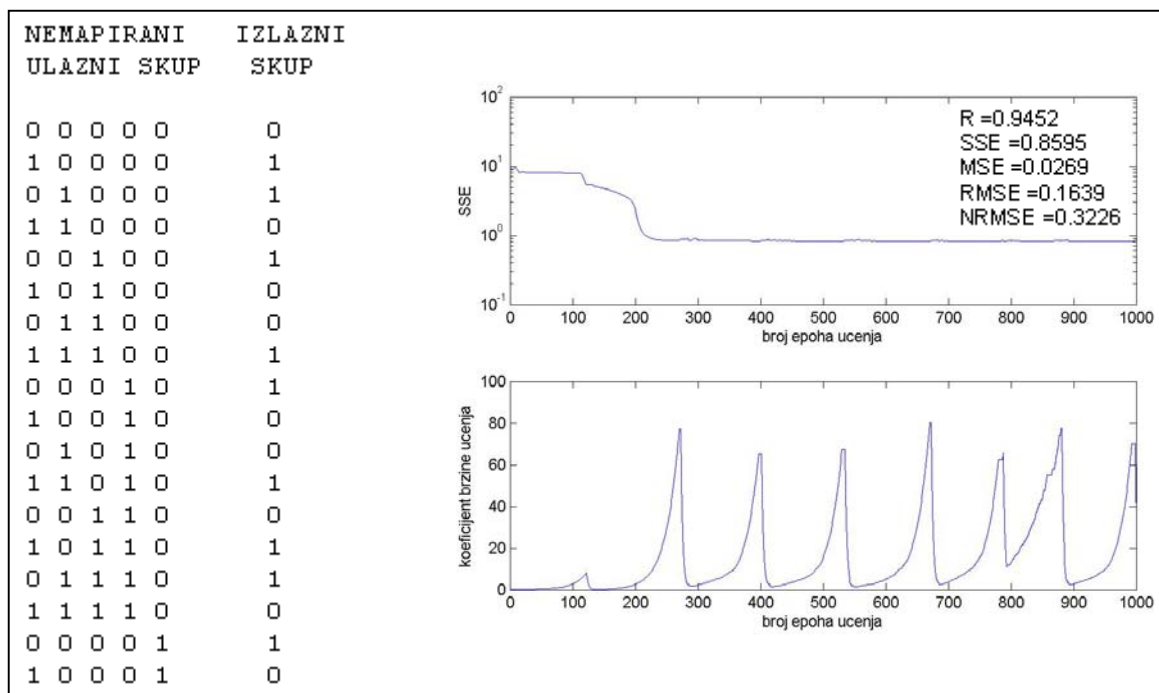
2.8.2. Mapiranje ili kodiranje simboličkih ulazno-izlaznih varijabli

S obzirom da računala izvode računske operacije sa numeričkim vrijednostima varijabli, simboličke vrijednosti varijabli potrebno je mapirati ili kodirati u kvantitativni oblik pogodan za računalnu obradu. Problem koji se pri tome javlja je izbor pogodnog oblika kvantifikacije takvih varijabli. U radu su primjenjene dvije grupe takvih varijabli. Prva grupa su tzv. *kategoričke varijable* (engl. *categorical variable*), a druga grupa su tzv. *binarne varijable*, čije se simboličke vrijednosti mogu prikazati binarno. Primjer kategoričke varijable je varijabla *tip_trosenja*. Kao što se vidi iz tablice 2 u prilogu, postoji 15 tipova (kategorija) trošenja: 1. *Hidrodinamičko*, 2. *Sklizno*, 3. *Kotrljajuće*, 4. *Izjedanje (fretting)*, 5. *Udarno*, 6. *Abrazija-udarno*, 7. *Abrazija-sklizno*, 8. *Abrazija-trotijelno*, 9. *Erozija-hidroabrazija*, 10. *Erozija-sklizno*, 11. *Erozija-strujanjem*, 12. *Erozija-kavitacija*, 13. *Erozija-udarno*, 14. *Erozija-kapljevinom*, 15. *Erozija-plinom*. Najjednostavniji način mapiranja ove varijable bilo bi tzv. *redno mapiranje* (engl. *ordinal encoding*) dodjeljivanjem rednih brojeva (od 1 do 15) svakoj od spomenutih kategorija. Prema [30] ovakav način mapiranja nije pogodan zbog razloga prikazanog na slici 2.53.

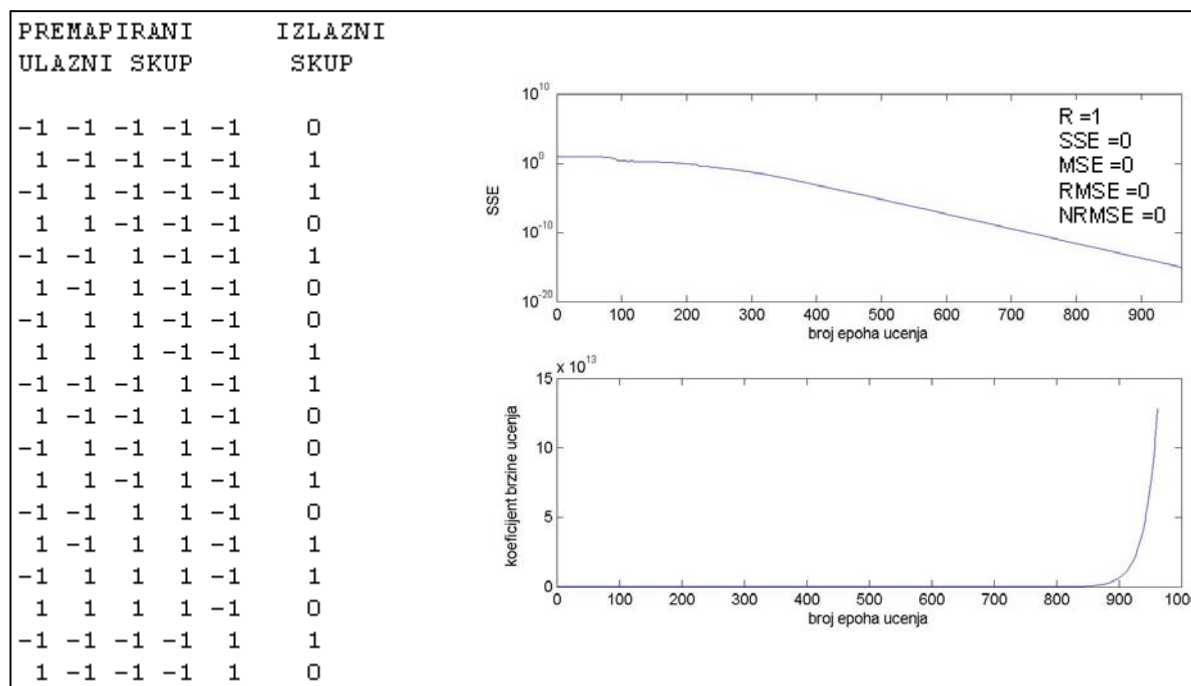


Slika 2.53. Problem kod mapiranja kategoričkih varijabli [31]

Prema slici 2.53 nakon procesa učenja mreže po principu rednog mapiranja, za zadani ulaz, izlaz iz mreže može biti kategorija X tj. bilo koja kategorija između 1 i 3 (npr. 2,5), koja realno ne postoji. Bolji način mapiranja je tzv. *1-od-C mapiranje* (engl. *1-of-C coding*), kod kojeg se svaka kategorička varijabla prikazuje vektorom retka, sa brojem elemenata koji odgovara broju kategorija. Vrijednosti pojedinih elemenata vektora iznose 1 ili 0. Jedinica je na onom rednom mjestu u vektoru koje odgovara rednom broju kategorije varijable. Tako je npr. hidrodinamičkom tipu trošenja dodijeljena kategorija 1, pa je prema *1-od-C* principu mapiranja njegov vektor retka $[10000000000000]$, za sklizni tip $[010000000000000]$ itd. Treba napomenuti da za definiciju kategorija nema pravila te se one proizvoljno definiraju. Sljedeću grupu varijabli čine binarne varijable čije su kvantitativne vrijednosti 0 ili 1. Npr. neka varijabla *funkcionalni_dio_1* poprima simboličke vrijednosti *IMA-NEMA*. Na prvi pogled, logičan izbor bio bi binaran oblik mapiranja te varijable, kod kojeg se vrijednosti *IMA* dodjeljuje brojka 1 a vrijednosti *NEMA* brojka 0. Uspješnost učenja binarno mapiranog ulaznog skupa može se poboljšati premapiranjem skupa u interval $[-1, 1]$ [31]. Kao dokaz, navode se primjeri učenja neuronske mreže sa nemapiranim binarnim ulaznim skupom, i tim istim skupom premapiranim u interval $[-1, 1]$, prikazanih na slikama 2.54 i 2.55. Karakteristike mreže su sljedeće: broj ulaznih varijabli=5, broj izlaznih varijabli=1, broj neurona u skrivenom sloju=5, struktura mreže=5-5-1, prijenosna funkcija skrivenog sloja=*tansig*, prijenosna funkcija izlaznog sloja=*logsig*, funkcija greške=*SSE*, algoritam učenja=*algoritam sa povratnim rasprostiranjem pogreške*, koeficijent brzine učenja=0.1, momentum=0.9 i broj epoha učenja=1000.



Slika 2.54. Utjecaj binarnog kodiranja ulaznih varijabli na grešku u procesu učenja mreže [31]



Slika 2.55. Utjecaj premapiranog binarnog kodiranja ulaznih varijabli na grešku u procesu učenja mreže [31]

Kao što se vidi na slici 2.54 premapiranjem u interval $[-1, 1]$ došlo je drastičnog pada SSE za iste parametre mreže. Proces učenja (treninga) ponavljan je desetak puta za oba slučaja, sa slučajno generiranim inicijalnim vrijednostima matrica težina.

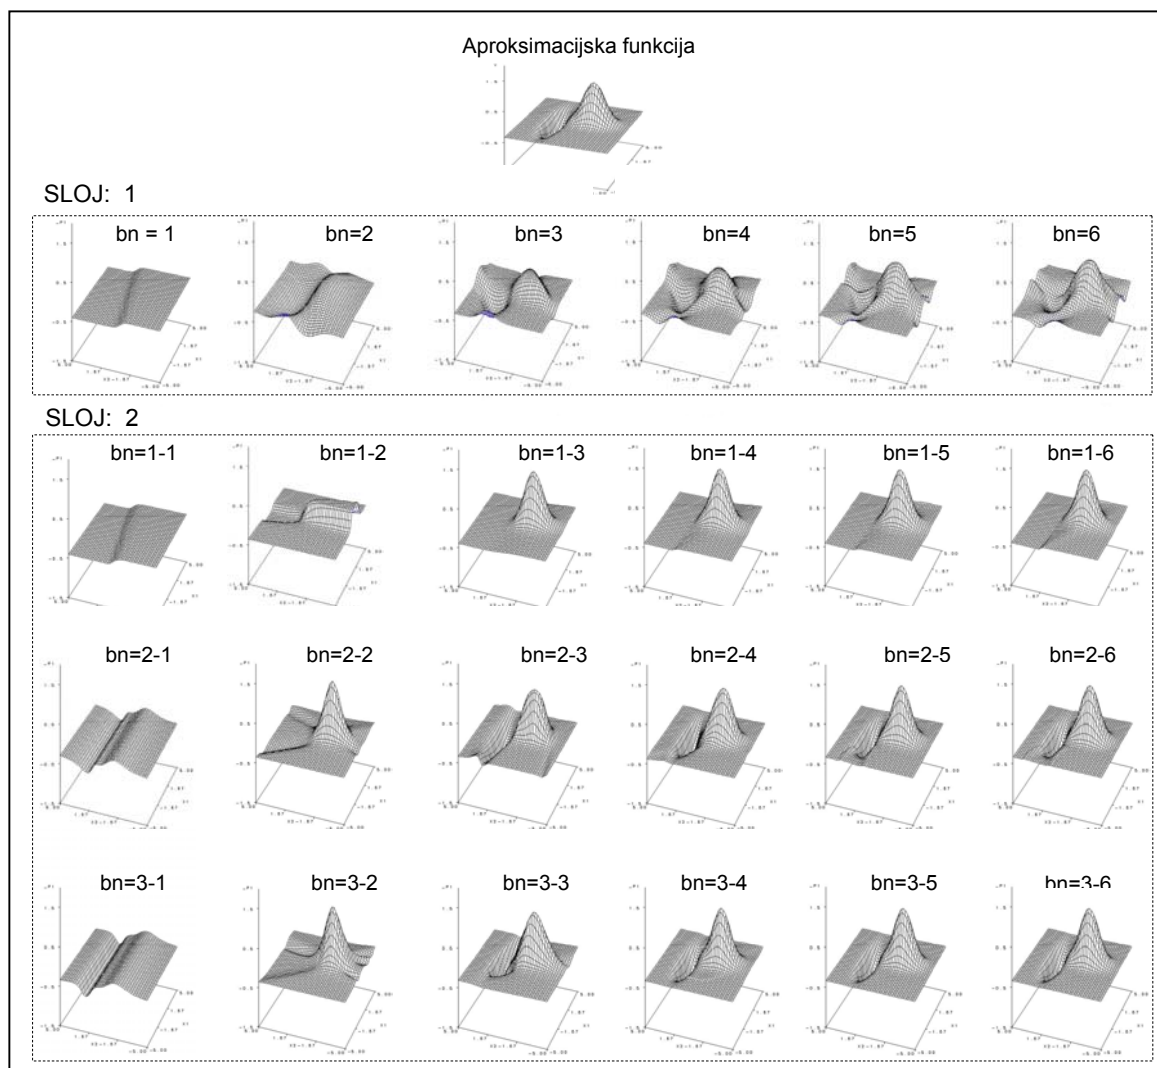
2.8.3. Aktivacijske ili prijenosne funkcije

Kao što je spomenuto u teorijskom dijelu rada, aktivacijske ili prijenosne funkcije imaju zadatak preslikavanja vrijednosti rezultata sumatora u izlaznu vrijednost neurona. Pravilnim odabirom aktivacijske funkcije u kombinaciji sa više slojeva mreže, uspješno se rješavaju nelinearnosti unutar skupa podataka za učenje. U radu se za *ASNN* tip mreže eksperimentiralo sa *hardlim* i *hardlims* aktivacijskim funkcijama (engl. *threshold activation functions*), a sa *BP* tipom mreže uglavnom linearno-sigmoidalnim tipovima aktivacijskim funkcijama i to: *purelin*, *tansig* i *logsig*. Važno je znati da kod *BP* modela mreže aktivacijska funkcija mora biti isključivo diferencijabilna i po mogućnosti ograničena unutar intervala -1 do 1 ili 0 do 1 . *BP* mreža modelirana sa diferencijabilnim aktivacijskim funkcijama koje daju i pozitivne i negativne vrijednosti karakteristične su po bržem učenju, za razliku od mreža modelirane sa aktivacijskim funkcijama koje daju samo pozitivne vrijednosti. Za takve aktivacijske funkcije koje produciraju brže učenje kaže se da imaju bolje *numeričko kondicioniranje* [31]. Za ulazni i skrivene slojeve neurona odabire se kombinacija sogmoidalnih i linearnih aktivacijskih funkcija, dok bi za vanjski sloj trebalo obratiti pozornost na sljedeće [31]:

- Za izlazne vrijednosti mapirane po binarnoj shemi (0/1), logičan izbor je *logsig* aktivacijska funkcija.
- Za kategoričke izlazne vrijednosti mapirane po principu *1-od-C* biraju se *softmax* ili *logsig* aktivacijske funkcije.
- Za kontinuirane izlazne vrijednosti unutar nekog intervala (npr. -1 do 1) biraju se *logsig* i *tansig* s tim da treba provesti postupak normalizacije i to u interval vrijednosti koje daje aktivacijska funkcija.
- Za kontinuirane izlazne pozitivne vrijednosti bez ograničenja gornjeg intervala bira se eksponencijalna aktivacijska funkcija, međutim primjenom te funkcije postoji opasnost od *overfitting-a*.
- Za kontinuirane izlazne varijable koje nemaju ograničenja gornjeg i donjeg intervala upotrebljava se linearna *purelin* aktivacijska funkcija.

2.8.4. Broj skrivenih slojeva i broj neurona

Trenutno ne postoji egzaktno pravilo koje bi govorilo o tome koliko je skrivenih slojeva ili neurona potrebno za aproksimaciju neke zadane funkcije. Ako imamo samo jednu ulaznu varijablu nije potrebno imati više od jednog skrivenog sloja. Međutim stvar se komplicira sa dvije ili više ulaznih varijabli. Na slici 2.56 prikazan je izgled površine funkcije (uzvišenje i udolina) koju je potrebno aproksimirati, te utjecaj broja slojeva i broja neurona na aproksimaciju te funkcije [32]. Modelirana je 2-21-21-1 struktura mreže, a na slici je prikazan dio odzivnih površina aproksimirane funkcije u zavisnosti od broja slojeva i broja neurona u pojedinom sloju.



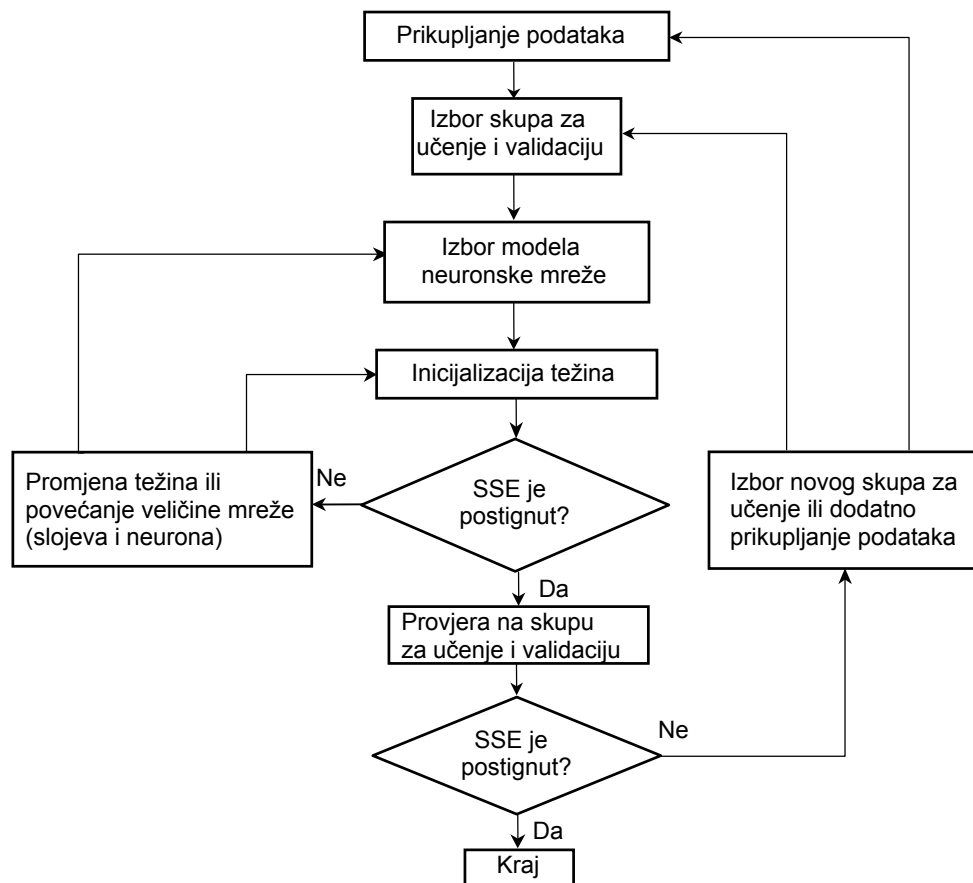
Slika 2.56. Utjecaj broja skrivenih slojeva i broja neurona na aproksimaciju površine funkcije [33]

Kao što je vidljivo sa slike 2.56 u slučaju jednog skrivenog sloja tek povećanjem broja neurona ($bn=6$) dobiva se približno željeni oblik površine aproksimacijske funkcije. Tek uvođenjem drugog skrivenog sloja te povećanje broja neurona u drugom sloju dobiva se izgled površine funkcije slične zadanoj. Tako je prema slici 2.56 najbolja odzivna površina sa 3 neurona u prvome sloju i 6 neurona u drugom skrivenom sloju ($bn=3-6$). Prema literaturnim podacima [29] za većinu praktičnih slučajeva za *BP* modele neuronskih mreža bit će dovoljna dva skrivena sloja neurona, dok će uvođenje trećeg sloja obuhvatiti gotovo sve nelinearnosti unutar mjerenih podataka. Kao što se vidi na slici 2.56, određeni broj slojeva podrazumijeva i određeni broj neurona. Ako imamo premali broj neurona u sloju dobit ćemo veliku grešku nakon procesa treninga i veliku grešku (*underfitting*) i bias pri generalizaciji novih podataka. Uvođenje velikog broja neurona smanjuje se greška treninga, međutim povećava se greška (*overfitting*) te bias pri novoj generalizaciji. Pravilan izbor broja neurona ovisiti će o nekoliko bitnih stvari a to su: broj slučajeva za učenje (engl. *training cases*), količina šuma sadržanog u izlaznim ili mjerenim podacima, te kompleksnosti funkcije koju je potrebno aproksimirati. Generalno pravilo prema [33] je da broj neurona ne bi trebao biti veći od broja slučajeva za učenje. Jedini način pronalaženja

optimalnog broja neurona je metodom pokušaja i pogreške za svaki razmatrani problem zasebno. Nedostatak takvog načina je velika sporost. U radu se problem pronalaženja optimalnog broja skrivenih slojeva i neurona, za neke slučajeve riješio primjenom genetičkih algoritama.

2.8.5. Metodologija učenje ili treninga mreže

Na slici 2.57 prikazan je opći dijagram tijeka učenja neuronskih mreža. Kao što se sa slike vidi prvi korak je prikupljanje podataka, a nakon toga podjela podataka na podatke za učenje ili trening i na podatke za validaciju i testiranje. Važno je da podaci izabrani za učenje predstavljaju (pokrivaju) cijeli prostor problema. Ne postoji pravilo o tome kolika mora biti veličina skupa za učenje a kolika za validaciju i testiranje. U širem smislu, poželjan je što veći skup za učenje, što ne znači da je veći skup dovoljno dobar reprezentant podataka iz cijelog prostora problema. U nekim slučajevima to može biti i mali skup podataka za učenje. Skup podataka za validaciju služi za provjeru generalizacije skupa za učenje. U tijeku procesa učenja nadgleda se greška validacijskog skupa koja se u pravilu povećava sa greškom skupa za učenje (slučaj 'overfitting-a'). Ukoliko se greška validacije poveća za zadani broj iteracija zaustavlja se proces učenja te se vraćaju matrice težina i bias vektori kod kojeg je mreža imala najmanju grešku validacije. Skup za testiranje ne ulazi u procesu učenja već služi za grafički prikaz greške skupa za testiranje tijekom procesa učenja, te za usporedbu greše različitih modela mreže.



Slika 2.57. Shematski prikaz dijagrama tijeka učenja neuronske mreže

Nakon izbora skupa podataka za učenje i testiranje potrebno je izabrati model i veličinu neuronske mreže. Prema literaturnim podacima [11], 90% slučajeva svih uspješnih implementacija modela neuronskih mreža spada u *BP* modele neuronskih mreža. U pogledu određivanja veličine mreže postoje dva pristupa. Kod prvog pristupa odabire se velika mreža s najmanje dva skrivena sloja i velikim brojem neurona u svakom sloju u cilju osiguravanja minimalne greške učenja (*SSE*), a zatim se veličina mreže (broj slojeva i neurona) postepeno smanjuje tako dugo dok se ne dobije prihvatljiva greška na testnim podacima. Drugi pristup je obrnut prvome. Odabire se mala veličina mreže, obično s jednim skrivenim slojem i malim brojem neurona. Zatim se veličina mreže povećava dok se ne dobije prihvatljiva greška na podacima za učenje, a zatim i na podacima za testiranje. Prihvatljiva greška (*SSE*) bilo na skupu za učenje, bilo na skupu za testiranje, ne mora se postići nakon jednog ili nekoliko ciklusa ponavljanja procesa učenja. Broj

ciklusa ponavljanja procesa učenja, a time i greška učenja, ovise od početne inicijalizacije matrica težina i bias vektora koja u svim slučajevima inicijalizacije ne daje prihvatljivu *SSE*. Obično se početna inicijalizacija provodi generatorom slučajnih brojeva. Ako se *SSE* ne smanjuje, potrebno je povećati skup za učenje. Broj ponavljanja ciklusa učenja kreće se uobičajeno prema [33] od broja 100 do 1000.

2.8.6. Pregled primjenjenih algoritama neuronskih mreža

U radu je eksperimentirano i implementirano u ekspertni sustav ukupno 11 različitih algoritama neuronskih mreža prema. U nastavku su prema tipovima mreža, nabrojani korišteni algoritmi te nazivi funkcija sa listom parametara.

- **Tip mreže 1: Perceptronska**

Red. broj	Naziv algoritma	Funkcija	Lista parametara
1	PERCEPTRON	NNP	disp_freq,max_epoch,fun_lay1
2	WIDROW-HOFF	NNWH	disp_freq,max_epoch,err_goal,fun_lay1,lr

- **Tip mreže 2: Backpropagation**

Red. broj	Naziv algoritma	Funkcija	Lista parametara
3	BACKPROPAGATION	NNB	disp_freq,max_epoch,err_goal,lr, fun_lay1,fun_lay2,fun_lay3
4	BACKPROPAGATION-MOMENTUM	NNBM	disp_freq,max_epoch,err_goal,lr,momentum,err_ratio,fun_lay1, fun_lay2,fun_lay3
5	BACKPROPAGATION-ADAPTIVE	NNBA	isp_freq,max_epoch,err_goal,lr,lr_inc,lr_dec,err_ratio,fun_lay1, fun_lay2,fun_lay3
6	BACKPROPAGATION-MOMENTUM-ADAPTIVE	NNBMA	isp_freq,max_epoch,err_goal,lr,lr_inc,lr_dec,momentum,err_ratio fun_lay1,fun_lay2,fun_lay3
7	LEVENBERG-MARQUARDT	NNLM	disp_freq,max_epoch,err_goal,min_grad,mu,mu_inc,mu_dec, mu_max,fun_lay1,fun_lay2,fun_lay3

- **Tip mreže 3: Asocijativna**

Red. broj	Naziv algoritma	Funkcija	Lista parametara
8	UNSUPERVISED HEBBIAN LEARNING WITH LEARNING RATE & DECAY RATE	NNHEBBUN	lr,mu
9	SUPERVISED HEBBIAN LEARNING WITH LEARNING RATE & DECAY RATE	NNHEBBSU	lr,mu
10	GROSSBERG INSTAR SUPERVISED ASSOCIATIVE LEARNING WITH LEARNING RATE	NNINSSU	lr
11	GROSSBERG OUTSTAR SUPERVISED ASSOCIATIVE LEARNING WITH LEARNING RATE	NNOUTSU	lr

Zbog problema sa tzv. 'net objektom' (detaljnije objašnjenje u eksperimentalnom dijelu!), svi nabrojani algoritmi iznova su prekodirani bez 'net objekta' te implementirani u ES. Provjera ispravnosti rada algoritama izvedena je prema primjerima iz [9] te prema radovima [34,35] (algoritmi pod rednim brojem 6 i 7). U sve algoritme ugrađene su procedure za izračunavanje značajki uspješnosti učenja: *R*, *SSE*, *MSE*, *RMSE*, *NRMSE*. Za simulaciju naučene (istrenirane) mreže tj. za generalizaciju novih podataka, razvijene su dvije funkcije: NN_ISTRE, i NNISTREN. Prva funkcija postavlja parametre potrebne za simulaciju (npr. novi ulazni podaci, tip mreže, broj slojeva, itd.), te ih sprema u datoteku *nparam.txt*. Druga funkcija prema podacima iz datoteke *nparam.txt* simulira zadani tip mreže, tj. procjenjuje izlazne varijable na temelju novih ulaznih podataka te rezultate simulacije sprema u datoteku *rezisdat.txt*.

U tablici 2.3 prikazani su opisi 40-tak parametara, sa preporučenim početnim vrijednostima. Dio parametara odnosi se na ulazno-izlazne operacije sa datotekama u koje se upisuju ili čitaju podaci za razmjenu s ostalim dijelovima sustava.

Tablica 2.3. Pregled parametara funkcija algoritama *perceptronskih*, *BP* i *asocijativnih* neuronskih mreža

Redni broj	Naziv parametra	Početna vrijednost	Opis
1.	ulaz_dat	'ulaz_dat'	Naziv ulazne datoteke (ulazna matrica)
2.	br_kol_ulaz	?	Broj broj kolona ulazne matrice
3.	izlaz_dat	'izlaz_dat'	Naziv izlazne datoteke (izlazna matrica)
4.	zeljeni_izlaz_dat	'zeljeni_izlaz_dat'	Naziv zeljene izlazne datoteke (zeljena izlazna matrica)
5.	br_kol_izlaz	?	Broj kolona izlazne matrice
6.	reztrdat	'reztrdat'	Naziv datoteke sa rezultatima istrenirane mreže
7.	br_layera	?	Broj layer-a
8.	br_neuro_layer1	?	Broj neurona u prvom layer-u ili "br_kol_izlaz" ako je "br_layera=1"
9.	br_neuro_layer2	?	Broj neurona u drugom layer-u ili "br_kol_izlaz" ako je "br_layera=2"
10.	fun_layer1	'tansig'	Prijenosna funkcija layer-a 1
11.	fun_layer2	'logsig'	Prijenosna funkcija layer-a 2
12.	fun_layer3	'purelin'	Prijenosna funkcija layer-a 3
13.	tip_mreze	7	Tip mreže (od 1 do 11)
14.	disp_freq	5	Brij epoha između prikaza
15.	max_epoch	1000	Maksimalni broj epoha učenja
16.	err_goal	1e-15	Dozvoljena pogreška učenja
17.	lr	0.01	Koeficijent brzine učenja
18.	lr_inc	1.05	Omjer za povećanje koeficijenta brzine učenja
19.	lr_dec	0.7	Omjer za smanjenje koeficijenta brzine učenja
20.	err_ratio	1.04	Maximum performance increase
21.	momentum	0.9	Momentum
22.	min_grad	1e-10	Minimum gradient
23.	mu	0.001	Inicijalna vrijednost za mu (mu=Decay Rate kod Hebbia)
24.	mu_inc	10	Množitelj za povećanje mu
25.	mu_dec	0.1	Množitelj za smanjenje mu
26.	mu_max	1e10	Maksimalna vrijednost za mu
27.	rezisdat	'rezisdat'	Naziv datoteke rezultata istrenirane mreže
28.	W1_dat	'W1_dat'	Naziv datoteke matrice težina layer-a 1
29.	W2_dat	'W2_dat'	Naziv datoteke matrice težina layer-a 2
30.	W3_dat	'W3_dat'	Naziv datoteke matrice težina layer-a 3
31.	B1_dat	'B1_dat'	Naziv datoteke bias vektora layer-a 1
32.	B2_dat	'B2_dat'	Naziv datoteke bias vektora layer-a 2
33.	B3_dat	'B3_dat'	Naziv datoteke bias vektora layer-a 3
34.	minP_dat	'minP_dat'	Naziv datoteke sa min. vrijednostima normalizacije vektora P
35.	maxP_dat	'maxP_dat'	Naziv datoteke sa max. vrijednostima normalizacije vektora P
36.	minT_dat	'minT_dat'	Naziv datoteke sa min. vrijednostima normalizacije vektora T
37.	maxT_dat	'maxT_dat'	Naziv datoteke sa max. vrijednost normalizacije vektora T
38.	norm_ulaz	1	Provjera normalizacije ulaznih varijabli (1=DA; 0=NE)
39.	norm_izlaz	1	Provjera normalizacije izlaznih varijabli (1=DA; 0=NE)
40.	chek_plot_R	1	Provjera ispisa regresijskog dijagrama sa koef. korelacije R (1=DA; 0=NE)
41.	chek_regularization	0	1. metoda za poboljšanje generalizacije (1=DA; 0=NE)
42.	chek_early_stopping	0	2. metoda za poboljšanje generalizacije (1=DA; 0=NE)
43.	chek_val_data	0	Provjera uzimanja validacijskog skupa podataka kod učenja (1=DA; 0=NE)
44.	chek_test_data	0	Provjera uzimanja testnog skupa podataka kod učenja (1=DA; 0=NE)

U gornjoj tablici simbol '?' označava slobodan unos u zavisnosti od promatranog slučaja. Parametri pod rednim brojem 38. i 39. omogućavaju kontrolu normalizacije ulazno-izlaznih matrica. Moguća je dakle, normalizacija obje matrice, niti jedne matrice, samo ulazne ili samo izlazne matrice. Početni parametri učenja pod rednim brojevima od 14. do 26., preporuka su prema [12]. Parametar pod rednim brojem 40. omogućava opcionalni prikaz regresijskog dijagrama nakon procesa učenja između mjerenih i procjenjenih rezultata, sa izračunatim koeficijentom korelacije R . Parametar pod rednim brojem 'zeljeni_izlaz_dat' sadrži naziv tekstualne datoteke u koji su spremljene vrijednosti matrice za uspoređivanje sa procjenjenim iznosima matrice koje daju asocijativni tipovi mreža sa učiteljem ili bez učitelja. Parametri pod rednim brojevima 41. i 42. uključuju/isključuju metodu za poboljšanje generalizacije mreže, a parametri pod rednim brojem 43. i 44. uključuju/isključuju uzimanje validacijskog odnosno testnog skupa podataka u tijeku procesa učenja.

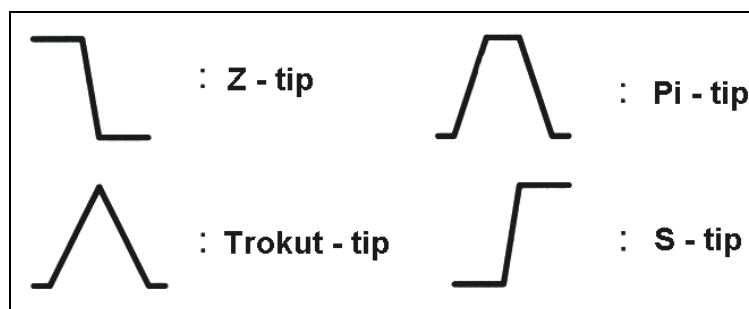
2.9. Neke praktične značajke neizrazite logike

2.9.1. Metodologija izbora lingvističkih varijabli i funkcija pripadnosti

Lingvističke varijable su varijable pomoću kojih čovjek opisuje ponašanje određenog neizrazitog sustava, te se preslikavaju u numeričku vrijednost varijabli. Kao što je već spomenuto u teorijskom dijelu, moguće vrijednosti preslikanih lingvističkih varijabli zovu se *neizraziti* ili *lingvistički skupovi* (engl. *linguistic terms, linguistic sets, fuzzy sets*), a skup numeričkih iznosa koje može poprimiti preslikana lingvistička varijabla, *univerzalni skup* (engl. *universe, universe of discourse, base variable*). U znanstvenoj literaturi [36] postoji više pristupa u načinu izbora broja preslikanih lingvističkih varijabli kao i oblika njihovih funkcija pripadnosti. Najčešće se upotrebljava između tri i sedam neizrazitih skupova po jednoj preslikanoj lingvističkoj varijabli. Manje od tri skupa rjeđe se upotrebljava, što proizlazi iz koncepcije ljudskog govora. U ljudskoj je naravi, običaj opisivati intenzitet neke pojave sa dvije ekstremne točke te jednom točkom u sredini. S druge strane, istovremena primjena više od sedam neizrazitih skupova po jednoj preslikanoj lingvističkoj varijabli, u ljudskoj je memoriji teško predstaviti kao oblik interpolacije između ekstremnih vrijednosti. U komercijalnim primjenama većina lingvističkih varijabli ima neparan broj neizrazitih skupova: tri, pet i sedam. Da li upotrijebiti tri, pet ili sedam skupova, poželjno je držati se sljedećih preporuka [13]:

- Formulira se nekoliko tipičnih *fuzzy* pravila, što zapravo predstavlja način za dobivanje ideje o obliku i broju neizrazitih skupova na temelju definicije baze pravila.
- Ako unaprijedna formulacija pravila nije moguća, definiraju se po tri neizrazita skupa za svaku ulaznu lingvističku varijablu i po pet neizrazitih skupova za svaku izlaznu varijablu. Iskustvo pokazuje da je to minimalan broj skupova za većinu primjena. Novi skupovi se mogu dodavati kasnije pri formulaciji baze pravila.

Osim broja neizrazitih skupova potrebno je definirati njihov oblik pomoću *funkcija pripadnosti* (engl. *membership functions*). Kao što je to već spomenuto u teorijskom dijelu, funkcije pripadnosti mapiraju bilo koju vrijednost iz *univerzalnog skupa* u *stupanj pripadnosti* (engl. *membership degree*) određenom neizrazitom skupu lingvističke varijable. U primjeni su najčešće četiri tzv. *standardne funkcije pripadnosti* (engl. *standard membership functions-MBF*) prikazane na slici 2.58.



Slika 2.58. Shematski prikaz standardnih funkcija pripadnosti [13]

Standardne funkcije pripadnosti su relativno jednostavne funkcije, međutim dovoljno su točne za primjenu u bilo kojem sustavu odlučivanja. Definicija funkcija pripadnosti provodi se u nekoliko koraka kao što je shematski prikazano na slici 2.59.

korak 1:

Za svaki neizraziti skup definira se tzv. *tipična vrijednost* (engl. *the most typical value*), vrijednost koja najbolje odražava lingvističko značenje skupa. Tipičnoj vrijednosti svakog neizrazitog skupa dodjeljuje se *stupanj pripadnosti* $\mu=1$.

korak 2:

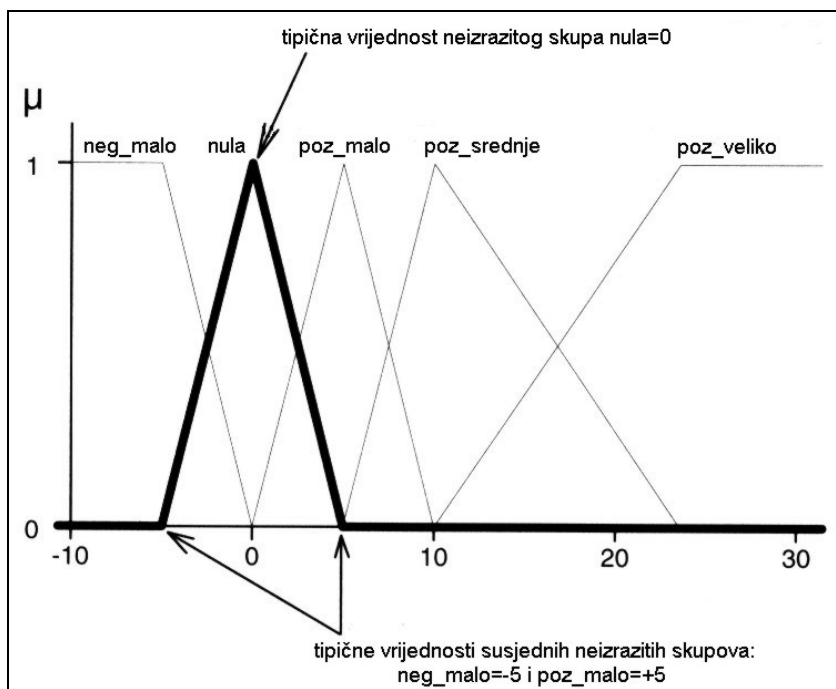
Za svaki neizraziti skup, dodjeljuje se *stupanj pripadnosti* $\mu=0$, na onom mjestu unutar *univerzalnog skupa* gdje susjedni neizraziti skup imaju tipičnu vrijednost tj. *stupanj pripadnosti* $\mu=1$.

korak 3:

Spojiti linijom točku gdje je $\mu=1$ sa točkama gdje je $\mu=0$. Ovaj način spajanja daje trokutasti tip funkcije pripadnosti.

korak 4:

Za neizrazite skupove koji graniče sa granicama lingvističke varijable, a to su krajnji lijevi i krajnji desni skup, ne postoje susjedni neizraziti skupovi. U tom slučaju svaka vrijednosti neizrazitog skupa iza točke gdje skup ima definirani $\mu=1$, skup također poprima iznos $\mu=1$. Za krajnji lijevi neizraziti skup to rezultira *Z-tipom* funkcije pripadnosti, a za krajnji desni neizraziti skup rezultira *S-tipom* funkcije pripadnosti.



Slika 2.59. Shematski prikaz definicije trokutastog tipa funkcije pripadnosti neizrazitog skupa 'nula' [13]

2.9.2. Karakteristike metoda defazifikacije

Defazifikacija je proces pretvaranja lingvističkih (simboličkih) rezultata dobivenih na temelju zaključivanja iz baze pravila u numeričke vrijednosti (engl. *crisp values*). U primjeni su sljedeće metode defazifikacije:

1. **Centar maksimuma** (engl. *center-of-maximum – CoM*);
2. **Prosjek maksimuma** (engl. *mean-of-maximum - MoM*)
3. **Centar površine** (engl. *center-of-area – CoA, center-of-gravity - CoG*);

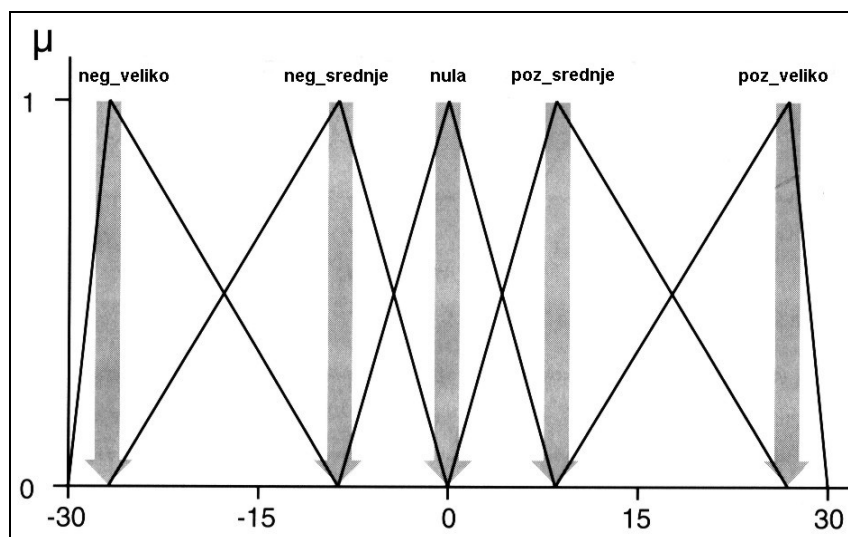
2.9.3. Centar maksimuma - CoM

Metoda *centar maksimuma* (CoM) je najčešće primjenjivana metoda defazifikacije. Metoda se sastoji od dva koraka:

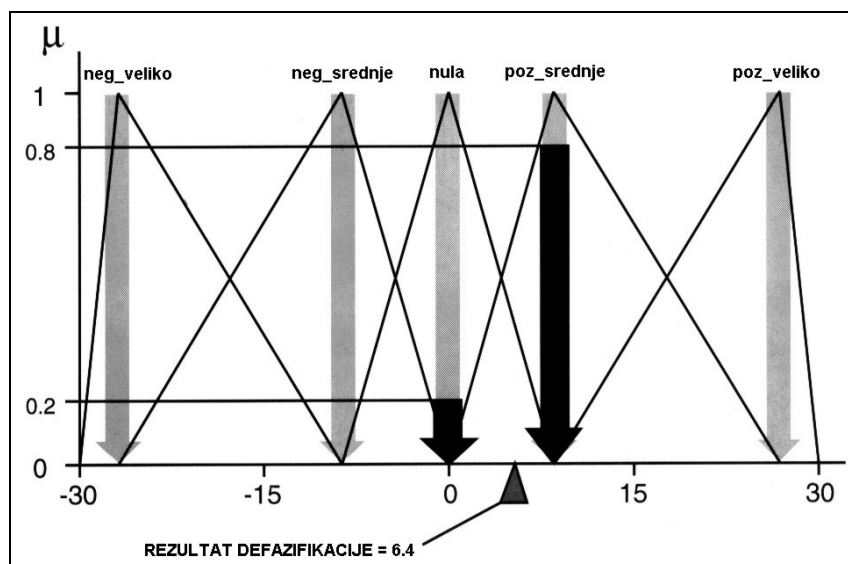
- U prvom koraku se izračunavaju tipične vrijednosti za svaki neizraziti skup lingvističke varijable
- U drugom koraku se metodom *najboljeg kompromisa* (engl. *best compromise*) izračunava numerička vrijednost izlazne lingvističke varijable

Na slici 2.60 prikazana je shema izračunavanja tipične vrijednosti izlazne varijable. Kao što se vidi u danom slučaju, tipična vrijednost je zapravo maksimum pojedine funkcije pripadnosti za određeni neizraziti skup. U konkretnom slučaju lokaciju tipičnih vrijednosti određuju sive strelice pojedinog

neizrazitog skupa na osi univerzalnog skupa. Ako pak je maksimum funkcije pripadnosti interval, tada se se za tipičnu vrijednost uzima srednja vrijednost intervala.

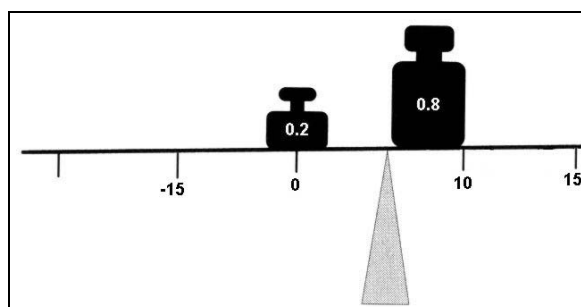


Slika 2.60. Shematski prikaz izračunavanja *tipične vrijednosti* izlazne varijable [13]



Slika 2.61. Shematski prikaz izračunavanja numeričke vrijednosti lingvističke izlazne varijable metodom *najboljeg kompromisa* [13]

Na slici 2.62 prikazan je drugi korak *CoM* defazifikacije primjenom metode najboljeg kompromisa. Slučaj na slici prikazuje lingvističku varijablu koja je nakon faze implikacije i agregacije (*fuzzy* zaključivanja) poprimila sljedeće vrijednosti neizrazitih skupova: $nula=0.2$ i $poz_srednje=0.8$.

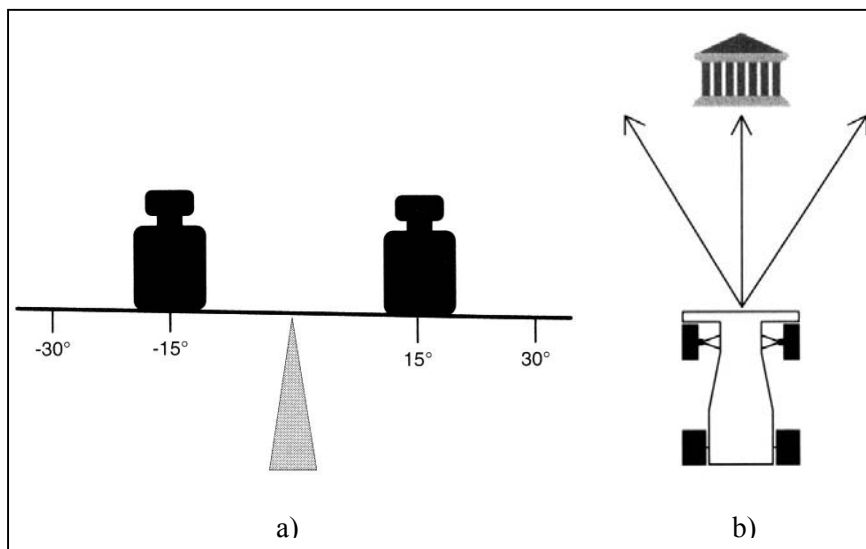


Slika 2.62. Shematski prikaz načina rada metode *najboljeg kompromisa* [13]

Rezultat *CoM* defazifikacije je zapravo lokacija ‘oslonca’ na osi univerzalnog skupa i to kada je poluga u ravnoteži, kao što je zorno prikazano na slici 2.62. Za prikazani slučaj na slici 2.61 i slici 2.62 iznos loakcije na kojoj se nalazi oslonac, tj. rezultat defazifikacije je 6.4.

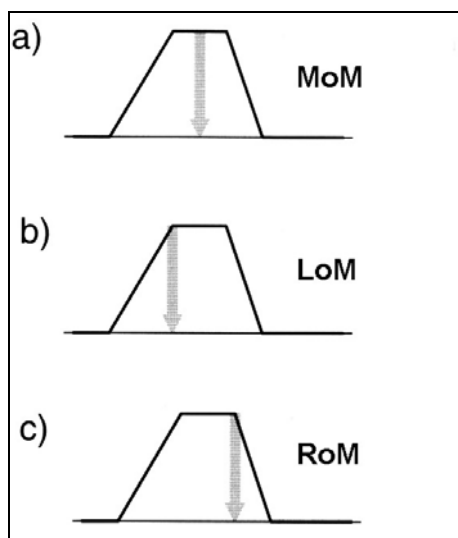
2.9.4. Prosjek maksimuma – MoM

U nekim slučajevima *CoM* metoda defazifikacije predstavlja neprikladno rješenje. Pojednostavljena shema jednog takvog slučaja prikazana je na slici 2.63. Kao što se vidi, mogući rezultat *fuzzy* zaključivanja prikazan je shemom a), a na shemi b) je situacija prenesena u stvarni svijet. Ako je ispred vozila prepreka, nameće se problem određivanja mogućeg smjera u kojim se vozilo treba gibati. Prema *CoM* metodi defazifikacije i te koraku *najboljeg kompromisa*, rezultat defazifikacije bilo bi pravocrtno gibanje vozila, dakle izravno u prepreku.



Slika 2.63. Prikaz problema defazifikacije *CoM* metodom [13]

Rješenje ovakvih slučajeva nalazimo u primjeni *MoM* metode defazifikacije te u nju ugrađene logike *najvjerojatnijeg rezultata* (engl. *most plausible result*). To znači da će *MoM* metoda defazifikacije izabrati onu tipičnu vrijednost neizrazitog seta, koja je u većini slučajeva najvjerojatnija. Za dani slučaj prema slici 2.63 u veći slučajeva najvjerojatniji rezultati su smjerovi lijevo (-15°) ili desno (+15°).



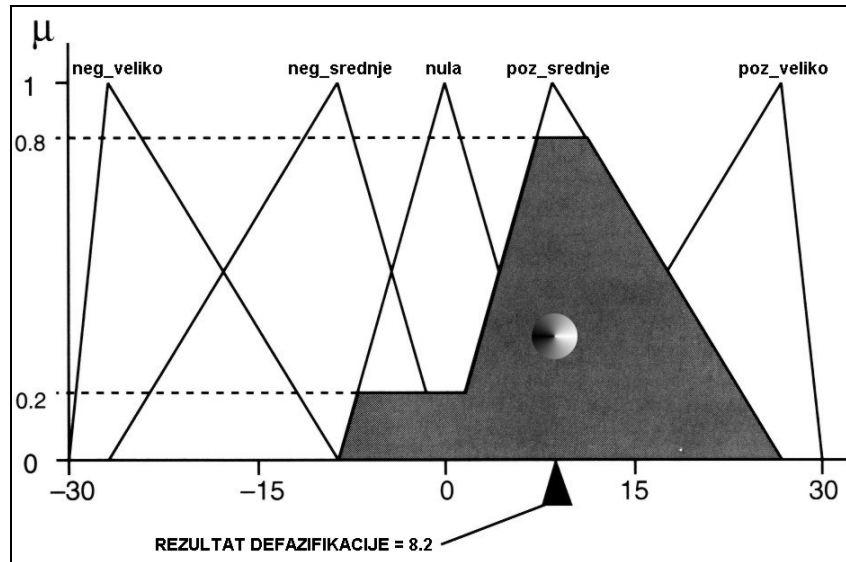
Slika 2.64. Varijante *MoM* metode defazifikacije [13]

Na slici 2.64 prikazane su varijante *MoM* metode defazifikacije. Razlika u varijantama je u izračunavanju tipičnih vrijednosti funkcija pripadnosti. Za trokutasti tip, tipična vrijednost jednoznačno je definirana.

Za *Pi-tip* funkcije postoje varijante *a*), *b*) i *c*), lijevo od maksimuma (engl. *left-of-maximum-LoM*) i desno od maksimuma (engl. *right-of-maximum-RoM*).

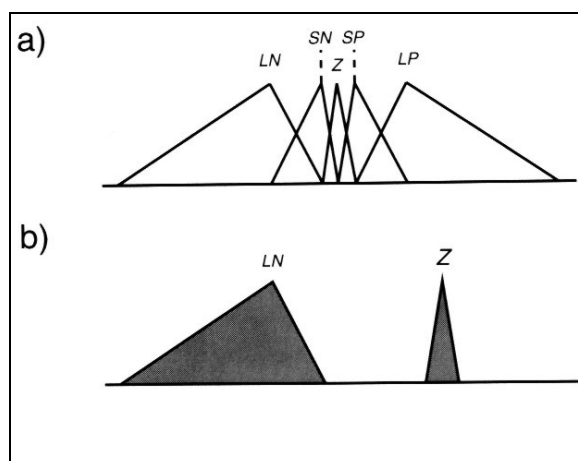
2.9.5. Centar površine - CoA

Kod ove se metode, određeni neizraziti skupovi izlazne lingvističke varijable ‘režu’ za iznos μ dobiven implikacijom. Npr., na slici 2.65 određeni su neizraziti skupovi izlazne lingvističke varijable su *nula* i *poz_srednje*, a njihovi koeficijenti pripadnosti su $\mu_{nula}=0,2$ i $\mu_{poz_srednje}=0,8$. Površine ispod μ za svaki pojedini određeni neizraziti set, superponiraju se u novi neizraziti skup (sjenčana površina) te se izračunava težište. Iznos težišta ili rezultat defazifikacije prema slici 2.65 je 8,2.



Slika 2.65. Shematski prikaz izračunavanja numeričke vrijednosti lingvističke izlazne varijable metodom centar površine- CoA [13]

Jedan od nedostataka *CoA* metode defazifikacije je velika osjetljivost na oblik pojedinog neizrazitog skupa izlazne lingvističke varijable. Na slici 2.66 a) i b) prikazan je primjer agregacije skupova *LN* i *Z* sa $\mu_{LN}=1$ i $\mu_Z=1$. Iako imaju jednaki μ , zbog veće površine, veći će učinak na rezultat defazifikacije imati *LN* nego *Z* neizraziti skup.



Slika 2.66. Shematski prikaz nedostatka *CoA* metode defazifikacije [13]

Drugi nedostatak *CoA* metode defazifikacije, a koji dolazi do izražaja kod primjene više izlaznih lingvističkih varijabli (npr. 5 i više neizrazitih skupova po svakoj varijabli), je vremenski odziv na rezultat defazifikacije zbog izračunavanja površina skupova numeričkom integracijom.

2.9.6. Usporedba i izbor metoda defazifikacije

U tablici 2.5 prikazane su usporedbe različitih metoda defazifikacije te mogućnost izbora s obzirom na područje primjene.

Tablica 2.5. Usporedba različitih metoda defazifikacije [13]

	Centar maksimuma (CoM)	Prosjek maksimuma (MoM)	Centar površine (CoA, CoG)
Lingvističke karakteristike	'najbolji kompromis'	'najvjerojatnije rješenje'	'najbolji kompromis'
Poklapanje sa intuicijom	dobra	dobra	slaba, sa primjenom različitih MBF oblika
Kontinuiranost	da	ne	da
Efikasnost proračuna	visoka	visoka	niska
Primjena	kontrola, podrška odlučivanju, analiza podataka	prepoznavanje uzoraka, podrška odlučivanju, analiza podataka	kontrola, podrška odlučivanju, analiza podataka

Jedno od najvažnijih svojstava defazifikacije je *kontinuiranost*. Metoda defazifikacije je kontinuirana ako infinitesimalna promjena ulazne varijable ne uzrokuje iznenadnu promjenu bilo koje izlazne varijable [13]. *CoM* i *CoA/CoG* metode su kontinuirane zbog logike *najboljeg kompromisa*, koja nema 'skokova' u iznosima pri maloj promjeni ulazne varijable, dok je *MoM* metoda diskontinuirana. S druge strane, kod *CoM* i *CoA/CoG*, uvijek postoji točka gdje *najvjerojatnije rješenje* dobiva različiti iznos. Posebice je kontinuiranost važna kod sustava sa zatvorenom petljom regulacije, kada mali skokovi izlaznih vrijednosti mogu izazvati nestabilnost i oscilacije cijelog sustava. Neke *fuzzy* aplikacije ne upotrebljavaju niti jednu metodu defazifikacije, već iznose vektora koeficijenta pripadnosti izlazne lingvističke varijable nakon procesa implikacije koriste npr. za klasifikaciju. Slijedi nekoliko praktičnih iskustava u pogledu metoda defazifikacije [13]:

- U praktičnim primjenama, razlika između nabrojanih metoda defazifikacije je u metodi primjene logike *najboljeg kompromisa* ili *najvjerojatnijeg rješenja*.
- Složenije oblici funkcija pripadnosti ne daju bolje rezultate za izlazne varijable. Preporuka je koristiti samo *A-tip* (trokut) funkcija pripadnosti, zbog toga što *CoM* i *MoM* metode defazifikacije koriste samo maksimum funkcija pripadnosti.
- U sustavima sa zatvorenom petljom preporučuje se korištenje *CoM* metode defazifikacije. Alternativa je *MoM* metoda kada je izlaz iz *fuzzy* kontrolera ulaz u integrator koji tada varijablu drži kontinuiranom.
- Zbog osjetljivosti prekrivanja i mogućih različitih površina funkcija pripadnosti *CoA/CoG* metoda daje nepovoljnije rezultate, te je preporuka upotrebljavati *CoM* metodu.

2.10. Neke praktičke značajke genetičkih algoritama

U cilju smanjenja vremena u procesa učenja te iznalaženja optimalnog rješenja (minimum *SSE*-funkcije cilja) primjenjeni su *GA-algoritmi* za optimizaciju parametara neuronski mreža. U tablici 2.4 prikazane su razvijene rutine koje omogućavaju optimizaciju parametara neuronskih mreža i pripadnih parametara učenja.

Tablica 2.4. Pregled modela neuronskih mreža te parametara za optimizaciju *GA-algoritima*

	Naziv rutine/modela mreže	Parametri za optimizaciju
1.	GA_NNBMA: Model povratnog prostiranja pogreške (<i>Backpropagation</i>) sa momentumom i adaptivnim koeficijentom brzine učenja	1. br_layera 2. br_neuro_lay1 3. br_neuro_lay2 4. br_neuro_lay3 5. lr 6. lr_inc 7. lr_dec 8. momentum 9. tip prijenosne funkcije (redni brojevi funkcija: 3-purelin; 4-tansig; 5-logsig)
2.	GA>NNLM: <i>Levenberg-Marquardt</i> model	1. br_layera 2. br_neuro_lay1 3. br_neuro_lay2 4. br_neuro_lay3 5. min_grad 6. mu 7. mu_inc 8. mu_dec 9. mu_max 10. tip prijenosne funkcije (redni brojevi funkcija: 3-purelin; 4-tansig; 5-logsig)
3.	GA>NNHEBBUN: <i>Hebb</i> -ov model bez nadziranog učenja	1. lr 2. mu (decay rate) 3. tip prijenosne funkcije (redni brojevi funkcija: 1-hardlim; 2-hardlims)
4.	GA>NNHEBBSU: <i>Hebb</i> -ov model sa nadziranim učenjem	1. lr 2. mu (decay rate) 3. tip prijenosne funkcije (redni brojevi funkcija: 1-hardlim; 2-hardlims)
5.	GA>NNINSSU: <i>Grossberg</i> -ov <i>instar</i> model sa nadziranim učenjem	1. lr 2. tip prijenosne funkcije (redni brojevi funkcija: 1-hardlim; 2-hardlims)

Modeli neuronskih mreža pod 1. i 2. spadaju u najnaprednije *backpropagation* modele, te zbog toga nisu razvijene *GA* rutine za ostale *BP* modele. Rutine pod 3., 4., i 5. predstavljaju *GA* optimizaciju asocijativnih modela neuronskih mreža s kojima se eksperimentiralo. *GA* optimizacija sprovedena je paralelno sa optimizacijom *pokušaja-pogreške* prema shemi na slici 2.57, i to za sve razmatrane slučajeve u disertaciji. Izabrani su parametri učenja one optimizacije koji su davali manju *SSE* pogrešku.

2.11. Neke praktičke značajke ekspertnih sustava

1. Izbor mehanizma zaključivanja

Ako stručnjak tj. ekspert rješava problem tako da prvo treba prikupiti neke od informacija o problemu, te na temelju njih kasnije donosi zaključke izabire se mehanizam zaključivanja sa *ulančavanjem unaprijed*. U slučaju da stručnjak rješava problem tako da prvo postavlja *hipotezu* tj. predviđa rješenje, a kasnije prikuplja činjenice ili fakte da bi hipotezu dokazao, izabire se mehanizam zaključivanja sa *ulančavanjem unazad*.

2. Sporna rješenja (engl. *conflict resolution*)

Problem koji nastaje kod mehanizma *zaključivanja unaprijed* kada imamo dva pravila sa istim premisama tj. sa istim *IF* dijelovima pravila, a različitim *THEN* dijelom. Oba pravila će se ispaliti kada su ispunjeni svi uvjeti tj. sve premise i to redoslijedom kako su pravila unešena u bazu znanja. To može prouzročiti velike probleme u radu *ES*-a s obzirom da su zaključci (akcije) pravila različiti. Tako mehanizam zaključivanja nikada neće razmatrati zaključak pravila koje je u bazi znanja prvo po redoslijedu upisa.

Takva pravila predstavljaju *sporna pravila* (engl. *conflict skup*), a mehanizam zaključivanja tada mora odrediti koje će se pravilo prvo ispaliti. Postoji nekoliko metoda [19] za rješavanje takvih problema, a koje se ugrađuju u mehanizam zaključivanja. Prva je metoda *najvišeg prioriteta* (engl. *highest priority*). Prema ovoj metodi se pravila u bazu znanja upisuju po određenom prioritetu. Metoda je prikladna za *ES*-ove do 100 pravila. Druga je metoda *najspecifičnijeg pravila* (engl. *most specific rule*). Metoda se bazira na pretpostavci da neko pravilo sadrži specifičniji zaključak ili važniju akciju od drugog pravila sa istim premisama, te se tada tom pravilu daje prioritet kod ispaljivanja. I treća je metoda *nedavnog unošenja ili promjene podataka* (engl. *data most recently entered*). Metoda se temelji na dodjeljivanju vremenske (npr. datum/vrijeme) oznake za svaku premisu unutar pravila. U slučaju nastupa spornog rješenja ispaliti će se ono pravilo koje je imalo '*najčešće promjene u zadnje vrijeme*'.

3. Metaznanje (engl. *metaknowledge*)

Metaznanje se jednostavno može definirati kao *zanje o znanju*. Kod *ES*-ova temeljenih na pravilima metaznanje je predstavljeno sa *metapравilima* (engl. *metarules*), kojima se određuje strategija primjene specifičnih pravila unutar baze znanja. Tako se npr. u metapравilima može definirati da pravila koja sadrže znanje iskusnijeg stručnjaka imaju veći prioritet od pravila koja sadrže znanje manje iskusnog stručnjaka.

4. Prednosti ekspertnih sustava

- Predstavljanje znanja prirodnim jezikom
- Uniformnost strukture predstavljanja znanja pravilima
- Odvojenost znanja od mehanizma zaključivanja
- Mogućnost izražavanja *nesigurnog znanja* (engl. *uncertain knowledge*)

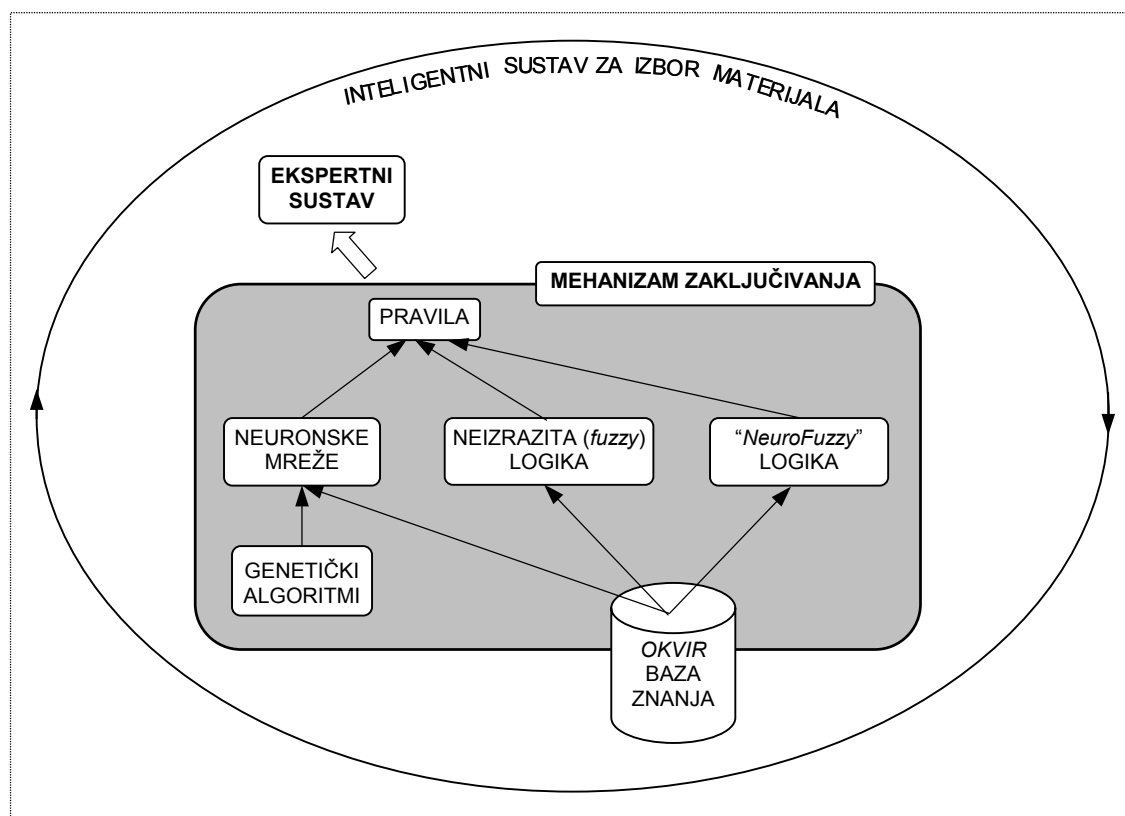
5. Nedostaci ekspertnih sustava

- Nemogućnost učenja
- Sporost pretraživanja kod *ulančavanja unazad*
- Otežano uspostavljanje relacija između velikog broja pravila

3. OPIS INTELIGENTNOG SUSTAVA ZA IZBOR MATERIJALA

3.1. Opis inteligentnog sustava za izbor materijala

Prema postavljenoj hipotezi za razmatranu problematiku rada, očekuje se poboljšanje rada mehanizma zaključivanja s obzirom na način integracije metoda umjetne inteligencije unutar kao što je prikazano na slici 3.1. Zamišljeni inteligentni sustav za izbor materijala je zapravo ekspertni sustav (ES) sa unaprijeđenim mehanizmom zaključivanja. Unapređenje mehanizma zaključivanja očituje se u integraciji različitih algoritama neuronskih mreža (čiji su parametri optimizirani genetičkim algoritmima), neizrazite logike i *neurofuzzy* logike unutar baze pravila ekspertnog sustava. Na taj se način izbjegava problem tzv. *kombinatorne eksplozije*, koji se često javlja kod same primjene metoda ekspertnih sustava. Posljedica takvog načina rješavanja razmatranog problema je pojednostavljenje baze pravila ekspertnog sustava te kasnijeg jednostavnijeg održavanje iste. Naime, pri uključivanju novog znanja u sustav, nije više potrebno reprogramiranje baze pravila već je dovoljno npr., iznova pokrenuti učenje neuronske mreže ili *fuzzy* mehanizma zaključivanja za onu cjelinu u sustavu za koju se znanje osvježava. Također se pojednostavljuje i sadržaj *okvir* baze znanja, koja u ovom slučaju u najvećem dijelu sadrži podatke o kemijskim sastavima čelika. Sastavi čine ulazne skupove (matrice) u naučenu neuronsku mrežu ili u naučeni mehanizam zaključivanja neizrazite logike. Na taj se način kao izlazni skupovi dobivaju različite procjene kao npr., procjena prikladnih postupaka modificiranja površina, procjena mehaničkih svojstava Fe - materijala (čvrstoća, tvrdoća) itd.

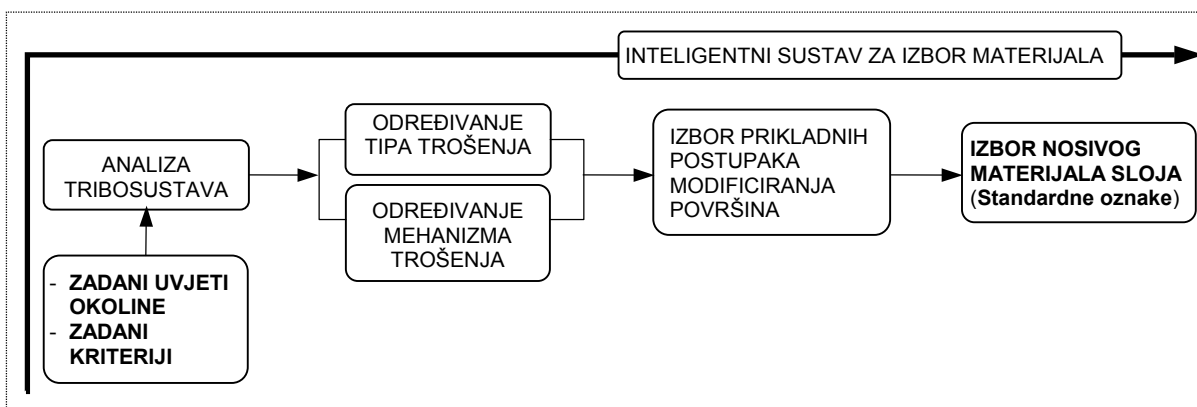


Slika 3.1. Principijelna shema integracije metoda umjetne inteligencije unutar inteligentnog sustava za izbor materijala

Pojednostavljeni prikaz strukture inteligentnog sustava za izbor materijala prikazan je na slici 3.2. Rezultat rada sustava temeljen je na sljedećim logičkim cjelinama tj. strukturi:

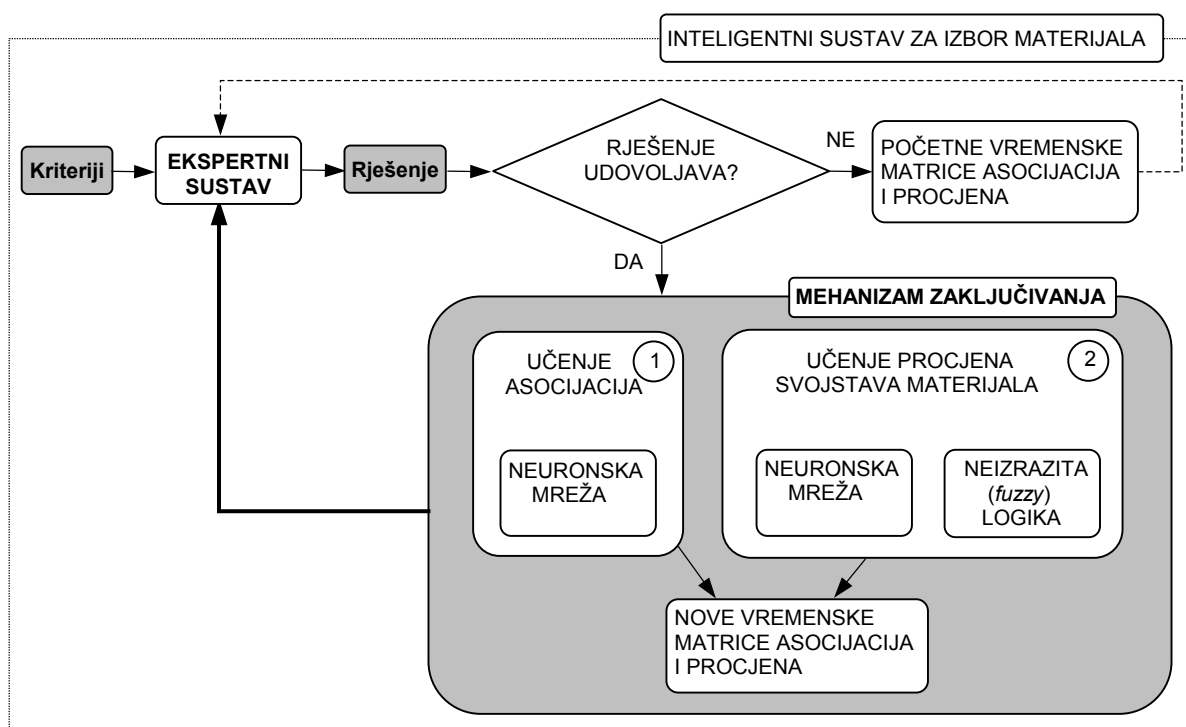
1. Analiza tribosustava (analiza na temelju uvjeta okoline i zadanih kriterija na svojstva osnovnog materijala)
2. Određivanje tipa trošenja (npr. sklizno, kotrljajuće, abrazija-udarano)
3. Određivanje mehanizma trošenja (npr. adhezija, abrazija, umor površine, tribokorozija)
4. Izbor prikladnih postupaka modificiranja površina (npr. cementiranje, boriranje, vanadiranje)
5. Izbor nosivog materijala sloja (npr. ČL1330, Č1220, Č4730)

Prema slici 3.2., rezultat rada sustava je određivanje standardnih oznaka materijala koje je moguće primijeniti kao osnovu za prethodno izabrani postupak modificiranja površina. Izbor oznake materijala temelji se na eksplicitno zadanim kriterijima ili kriterijima koji su rezultat tzv. *asocijativne procjene*. Pod eksplicitno zadanim kriterijima podrazumijevaju se kriteriji koje zadaje korisnik za vrijeme konverzacije ekspertni sustav (ES) – korisnik. Tijekom rada sa sustavom korisnik može unijeti sve kriterije koji su predviđeni unutar sustava, ne mora unijeti niti jedan kriterij ili može unijeti samo dio kriterija. U slučaju nedostatka potrebnih kriterija koji su važni za izbor modificiranja površina ili izbor materijala, sustav asocijativno procjenjuje iste. Pod asocijativnim će se procjenama podrazumijevati one procjene koje su proizišle kao rezultat učenja sustava tijekom vremena. Detaljnije će asocijativne procjene biti pojašnjene u eksperimentalnom dijelu rada. S obzirom na poznatu činjenicu da su mehanička svojstva materijala posljedica strukturnog stanja, proizlazi da su ista kao kriteriji izbora materijala, rezultat procjene kemijskog sastava, grupe i stanja Fe - materijala. Predviđa se da, s obzirom na ugrađenu sposobnost učenja sustava, neće biti potrebno ispitivati mehanička svojstva za novi kemijski sastav materijala, već će se ona zadovoljavajuće procjenjivati naučenom neuronskom mrežom ili naučenim mehanizmom zaključivanja neizrazite (*fuzzy*) logike.



Slika 3.2. Shema strukture inteligentnog sustava za izbor materijala

Primjenom opisanih metoda umjetne inteligencije predviđeno je postizanje određenog ‘*inteligentnog*’ ponašanja sustava za izbor materijala na način prikazan shemom na slici 3.3.



Slika 3.3. Principijelna shema načina postizanja ‘*inteligentnog ponašanja*’ sustava za izbor materijala

Hipotezom rada predviđeno je ‘*inteligentno ponašanje*’ sustava, na način da će sustav nakon određenog vremena biti u stanju davati suvisle odgovore bez da korisnik odgovori na ijedno ili da djelomično odgovori na postavljena pitanja sustava. Prema slici 3.3., predviđena su dva načina u pristupu (označeno sa 1 i 2) postizanja ‘*inteligentnog ponašanja*’:

1. UČENJE ASOCIJACIJA,
2. UČENJE PROCJENA SVOJSTAVA MATERIJALA.

Pristup učenja asocijacija podrazumijeva primjenu algoritama asocijativnih neuronskih mreža. U teorijskom dijelu rada opisane su specifičnosti asocijativnih neuronskih mreža, a najznačajnija je sposobnost ispravljanja (obnavljanja) pogrešnog ulaznog asocijativnog vektora (vektora šuma) u ispravni ili originalni asocijativni vektor. Ova se specifičnost u najvećoj mjeri primjenjuje pri konverzaciji *ES* – korisnik, na način da je korisniku dozvoljeno namjerno ili nenamjerno unošenje pogrešnih odgovora ili odgovora tipa ‘*nije važno*’ ili ‘*ne znam*’. U tom slučaju, mehanizam zaključivanja primjenom asocijativne neuronske mreže provjerava pravilnost odgovora na postavljena pitanja, ispravljajući pri tome samo one elemente (odgovore) asocijativnog vektora koji su pogrešni. Može se zaključiti da pogrešni asocijativni vektor odgovora, inicijalizira ispravni (naučeni) asocijativni vektor odgovora. Tijekom vremena, potvrđivanjem ispravnosti krajnjeg rješenja, mehanizam zaključivanja formira tzv. *vremenske asocijativne matrice* koje sadrže naučeno znanje o mogućim rješenjima problema. Na taj se način sustav (slično čovjeku-ekspertu) može specijalizirati za rješavanje samo određenih problema. Način pretvaranja (mapiranja) odgovora na pitanja u elemente asocijativnog vektora te formiranje vremenskih asocijativnih matrica biti će pojašnjen u eksperimentalnom dijelu rada. Na slici 3.4. je informativno prikazan izgled vremenske asocijativne matrice za određivanje elemenata sustava.

		Elementi sustava									
		f1	f2	č	p	t	F	v	ω	o	α
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Početna asocijativna matrica	Broj prihvaćenih rješenja										
	1	1	1	-1	-1	1	1	-1	1	-1	-1
	2	1	1	-1	-1	-1	1	1	-1	-1	-1
	3	1	1	-1	-1	-1	1	-1	1	-1	-1
	4	1	1	-1	-1	-1	1	-1	1	1	-1
	5	1	1	-1	-1	-1	1	-1	-1	-1	-1
	6	1	-1	1	-1	-1	1	-1	-1	-1	-1
	7	1	-1	1	-1	-1	1	1	-1	-1	-1
	8	1	1	1	-1	-1	1	1	-1	-1	-1
	9	1	1	1	-1	-1	1	1	-1	-1	-1
	10	1	1	1	-1	-1	1	-1	-1	-1	-1
	11	1	-1	1	-1	1	-1	1	-1	-1	1
	12	1	-1	1	-1	1	-1	1	-1	-1	-1
	13	1	-1	1	1	-1	-1	1	-1	-1	1
14	1	-1	-1	-1	-1	1	-1	1	-1	-1	
15	1	-1	-1	1	-1	-1	1	-1	-1	1	
16	1	-1	-1	-1	1	-1	-1	1	-1	1	
17	1	-1	-1	1	-1	-1	1	-1	-1	-1	
18	1	1	1	-1	-1	1	1	-1	-1	-1	
19	1	1	1	-1	-1	1	1	-1	-1	-1	
20	1	1	1	-1	-1	1	1	-1	-1	-1	
21	1	1	1	-1	-1	1	1	-1	-1	-1	
22	1	1	1	-1	-1	1	1	-1	-1	-1	
23	1	1	1	-1	-1	1	1	-1	-1	-1	
24	1	1	1	-1	-1	1	1	-1	-1	-1	
25	1	1	1	-1	-1	1	1	-1	-1	-1	
26	1	1	1	-1	-1	1	1	-1	-1	-1	
27	1	1	1	-1	-1	1	1	-1	-1	-1	
28	1	1	1	-1	-1	1	1	-1	-1	-1	
29	1	1	1	-1	-1	1	1	-1	-1	-1	
30	1	1	1	-1	-1	1	1	-1	-1	-1	
31	1	1	1	-1	-1	1	1	-1	-1	-1	
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		1	1	1	-1	-1	1	1	-1	-1	-1

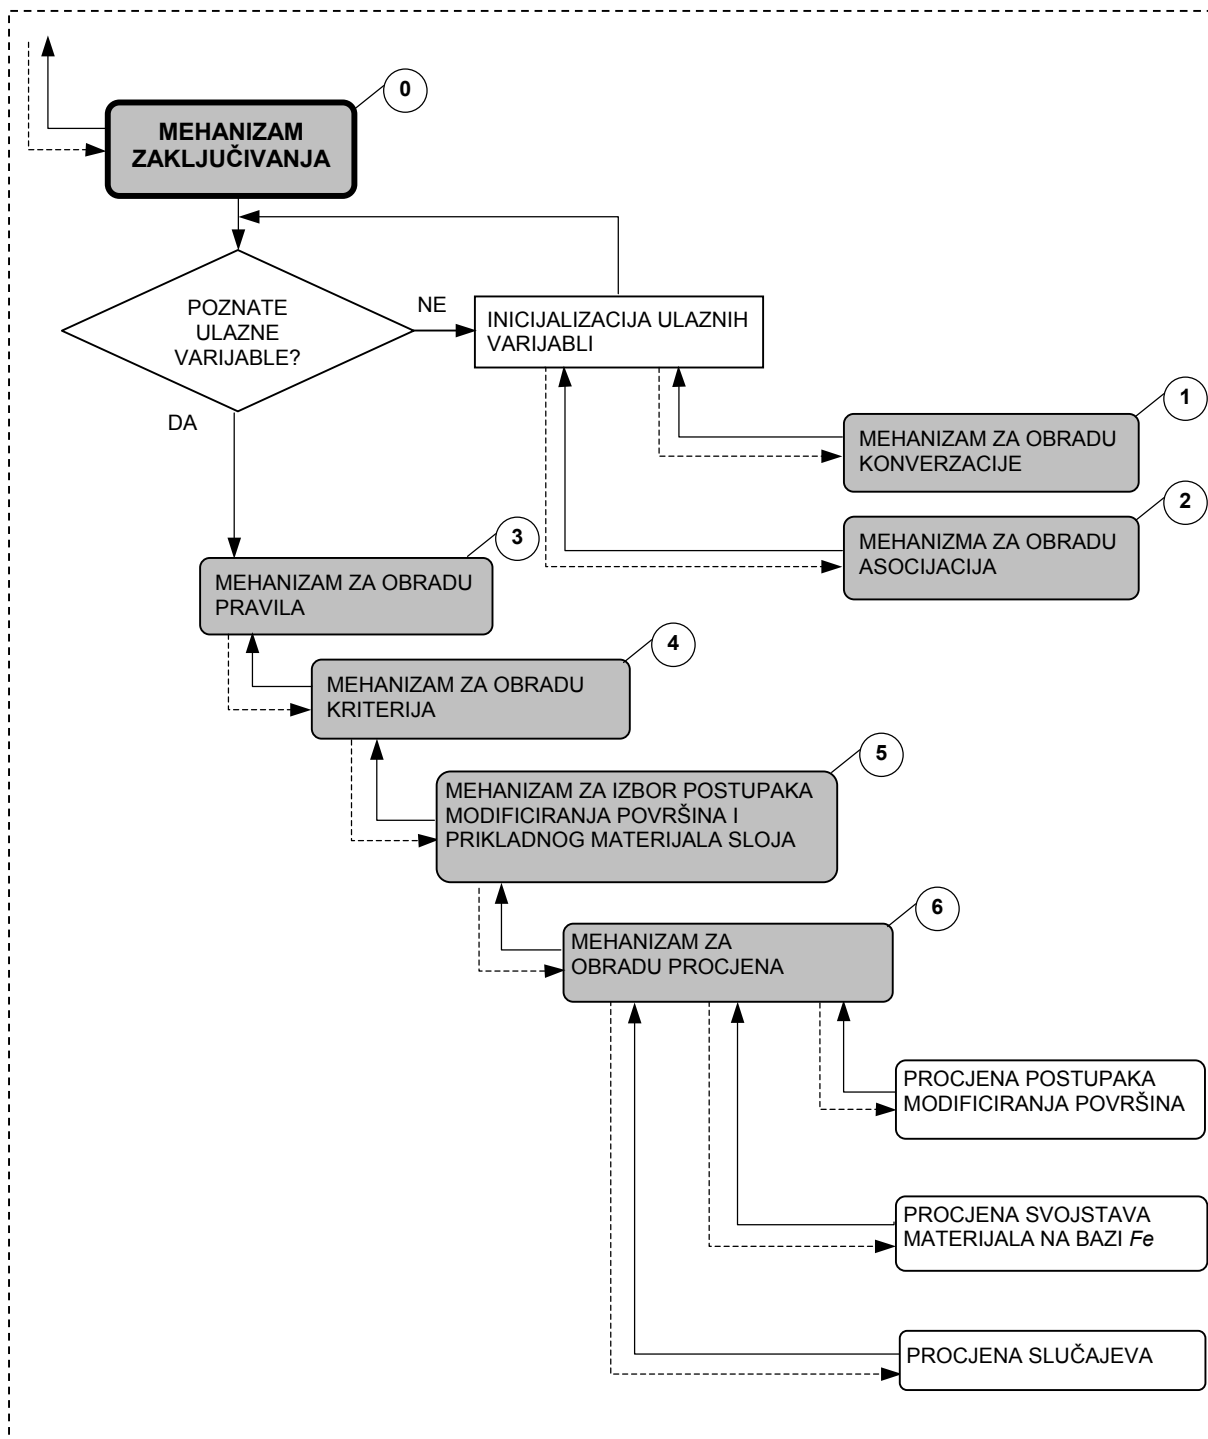
Slika 3.4. Primjer *vremenske asocijativne matrice* za određivanje elemenata sustava

U drugom pristupu postizanja ‘*inteligentnog ponašanja*’ sustava, razlikujemo primjenu algoritama povratnog prostiranja pogreške tj. *BP* neuronske mreže i neizrazite (*fuzzy*) logike. Navedeni algoritmi primjenjuju se u većini slučajeva za procjenu različitih mehaničkih svojstava materijala. Procjene pojedinih mehaničkih svojstava su zapravo matrice dobivene u procesu učenja sa određenim algoritmima neuronske mreže ili neizrazite logike. Već spomenuta *kombinatorna eksplozija*, na ovaj se način izbjegava, a elementi naučenih matrica predstavljaju zapravo ‘*znanje*’ ili ‘*inteligenciju*’. Unošenjem novih materijala tj. kemijskih sastava u okvir bazu znanja, mehanizam zaključivanja pokreće proceduru za ponovno učenje predefiniраниh procjena mehaničkih svojstava, te se nakon procesa učenja stare matrice zamjenjuju sa novim matricama. U jednom i u drugom pristupu podrazumijevane su tzv. *početne matrice* koje sadrže početno znanje o problemu, što pak omogućava dobivanje rješenja kada korisnik ne odgovori niti na jedno pitanje.

U nastavku slijedi detaljan opis strukture i načina rada mehanizma zaključivanja sa pripadajućim podmehanizmima.

3.2. Mehanizam zaključivanja

Iz razmatranja o ekspertnim sustavima (*ES*) u drugom dijelu rada, može se zaključiti da je praktički navažnija komponenta u strukturi svakog *ES*-a *mehanizam zaključivanja*. Cilj te komponente je povezati sve relevantne činjenice prikupljene tijekom procesa konverzacije s korisnikom u smislenu cjelinu na način, tako da ih *mehanizam za objašnjavanje* može smisleno tumačiti tj. objasniti. Blok-shema strukture mehanizma zaključivanja prikazana je na slici 3.5.



Slika 3.5. Blok-shema strukture mehanizma zaključivanja za izbor materijala u uvjetima trošenja

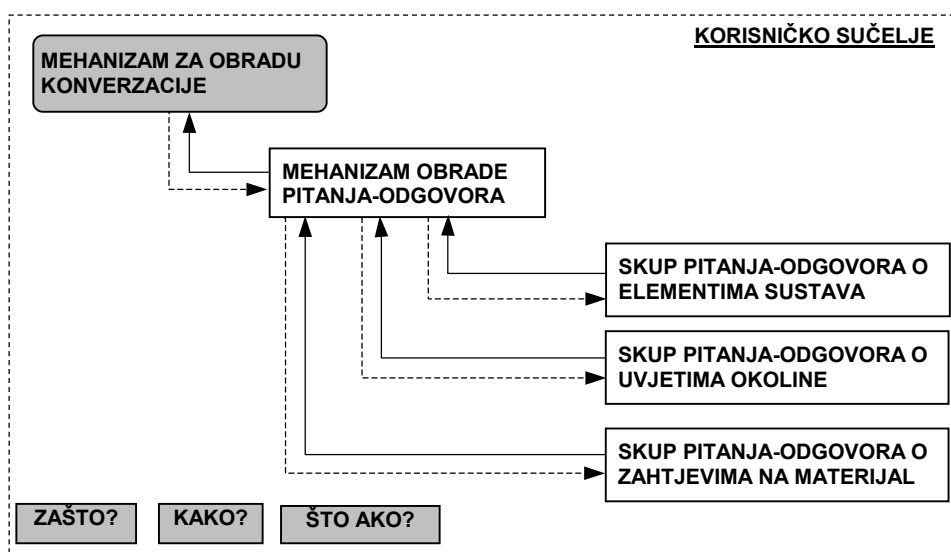
Predviđeni zadaci prikazanih mehanizama su:

1. Mehanizma za obradu konverzacije
-postavljanje pitanja korisniku i kontrola odgovora, formiranje vremenskih asocijativnih matrica pozivom tzv. *daemon* procedura, kontrola *logike* odgovora na pitanja
2. Mehanizma za obradu asocijacija
-inicijalizacija asocijativnih vrijednosti varijabli iz vremenskih asocijativnih matrica.
3. Mehanizma za obradu pravila
-pozivanje pravila iz baze znanja, izračunavanje faktora sigurnosti, kontrola ispaljivanja pravila.
4. Mehanizam za obradu kriterija
-formiranje liste kriterija za pretraživanje na temelju zahtjeva zadanih od strane korisnika te činjenica iz baze znanja.
5. Mehanizam za izbor postupaka modificiranja površina procjenama i prikladnog materijala sloja
-formiranje liste postupaka modificiranja površina na temelju određenog dominantnog mehanizma trošenja, dodjeljivanje prikladnih materijala pojedinom postupku modificiranja površina.
6. Mehanizam za obradu procjena
-procjena prikladnih postupaka modificiranja površina i prikladnih materijala za zadane kriterije.

U nastavku slijedi detaljniji opis pojedinih mehanizama zaključivanja.

3.2.1. Mehanizam za obradu konverzacije

Predviđena je integracija ovog mehanizma unutar korisničkog sučelja sa zadatkom postavljanja određenih pitanja korisniku iz područja problema. Pitanja koja *ES* postavlja korisniku svrstana su u tri grupe tj. skupa, kao što je prikazao na slici 3.6.



Slika 3.6. Blok-shema mehanizma za obradu konverzacije

1. Skup pitanja-odgovora o elementima sustava npr.:
-broj funkcionalnih dijelova, relativna gibanja funkcionalnih dijelova.
2. Skup pitanja-odgovora o uvjetima okoline npr.:
-vrsta agresivnog medija, intenzitet agresivnosti, radna temperatura.
3. Skup pitanja-odgovora o zahtjevima na materijal npr.:
-željeni iznos vlačne čvrstoće, granice razvlačenja, tvrdoće površine.

Također je putem ovog mehanizma predviđena kontrola *logike* odgovaranja na pitanja, što znači da sustav ima mogućnost obavještanja korisnika u slučaju davanja nelogičnih odgovora na pitanja. Tako će se npr. smatrati *nelogičnim* odgovorom o nepostojanju niti jednog funkcionalnog dijela u sustavu. Takve kontrole unutar sustava izvesti će se pomoću tzv. *daemon* procedura što će biti detaljnije pojašnjeno u eksperimentalnom dijelu rada. Iste će se primijeniti i za formiranje tzv. vremenskih asocijativnih matrica koje koriste mehanizam za obradu asocijacija te mehanizam za učenje novih

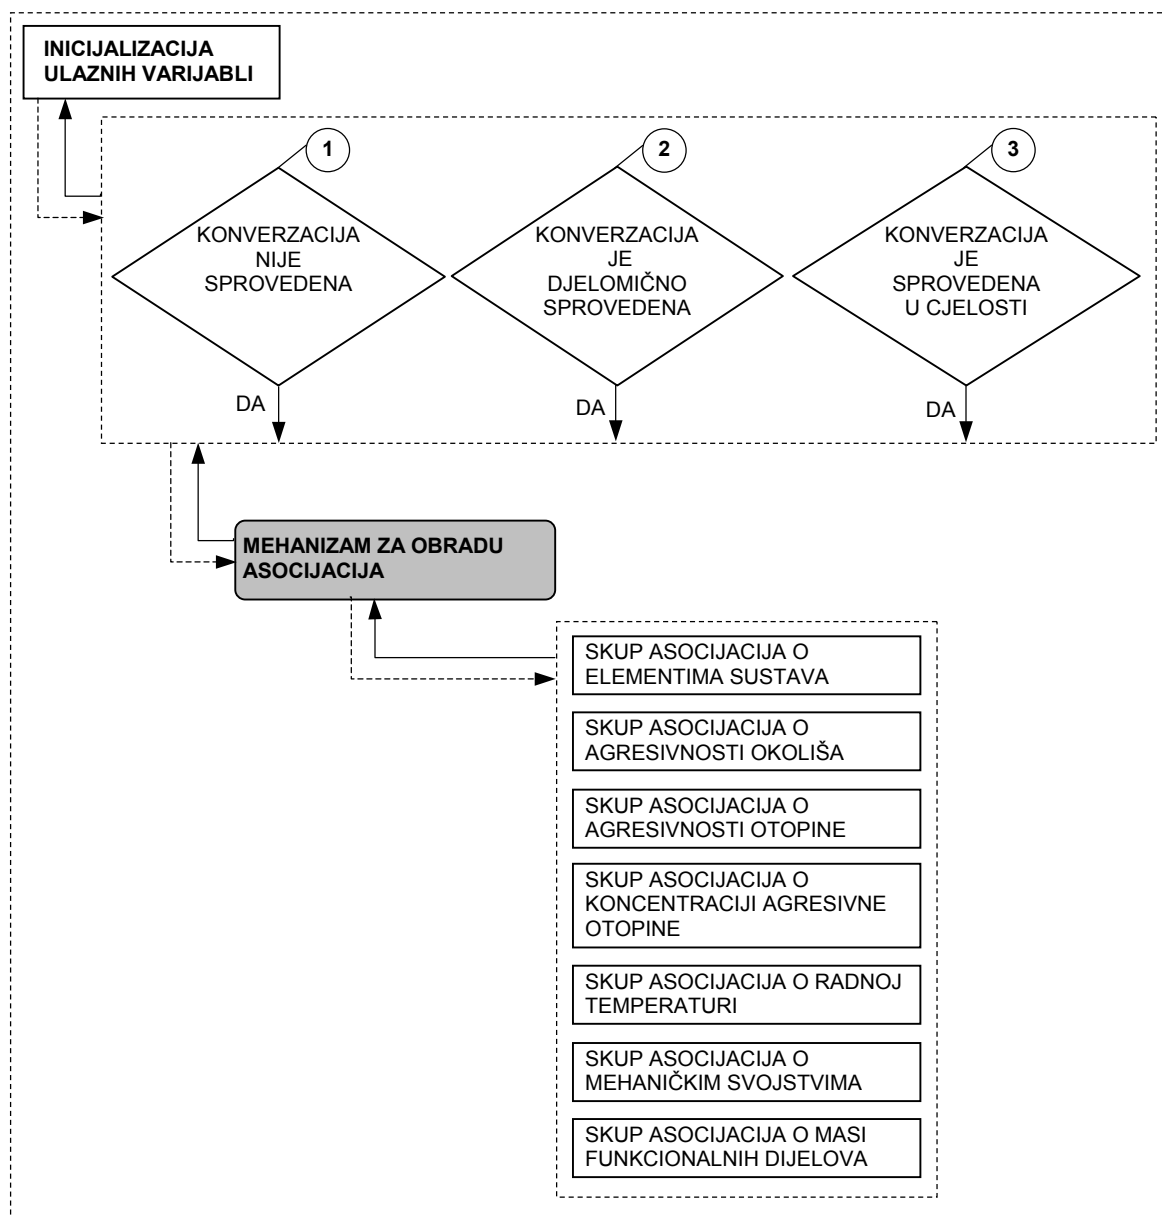
asocijacija. Kao što se vidi na slici 3.6 unutar istog korisničkog sučelja, a u interakciji sa mehanizmom konverzacije, nalaze se i mehanizmi za objašnjavanje tijekom konverzacije čije je značenje sljedeće:

1. **ZAŠTO?** -objašnjavanje postavljenog pitanja ili nekog pojma unutar pitanja;
2. **KAKO?** -objašnjavanje redosljeda *ispaljivanja* pravila sa faktorima sigurnosti;
3. **ŠTO AKO?** -mogućnost promjene odgovora na postavljena pitanja.

3.2.2. Mehanizam za obradu asocijacija

Asocijacije se pozivaju u slučajevima kad iz nekog razloga nedostaju vrijednosti određenih varijabli potrebnih za donošenje zaključka. Tada se na temelju vremenskih asocijativnih matrica inicijaliziraju one vrijednosti varijabli koje su vremenom *najčešće* potvrđivane unutar zadovoljavajućeg rješenja od strane korisnika. Na slici 3.7 prikazana je blok-shema mehanizma za obradu asocijacija. Vidljivo je da se asocijativna inicijalizacija varijabli sprovodi u tri slučaja:

1. Konverzacija ES-korisnik nije sprovedena;
2. Konverzacija ES-korisnik je djelomično sprovedena;
3. Konverzacija ES-korisnik je u cjelosti sprovedena.



Slika 3.7. Blok-shema mehanizma za obradu asocijacija

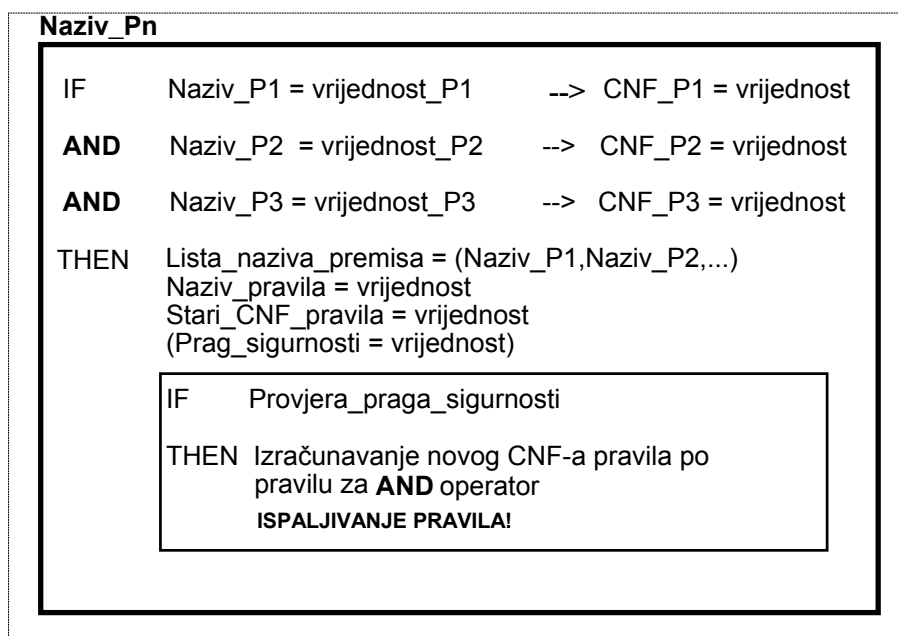
U prvom slučaju, predviđena je mogućnost sustava za donošenjem rješenja a da korisnik nije odgovorio niti na jedno pitanje. Mehanizam za obradu asocijacija tada izvršava potpunu inicijalizaciju vrijednosti svih potrebnih varijabli na temelju vremenske asocijativne matrice. U drugom slučaju, sustav donosi rješenje na temelju djelomičnih odgovora na pitanja postavljenih korisniku. U tom se slučaju izvršava djelomična inicijalizacija vrijednosti onih varijabli, koje nisu poprimile vrijednost u trenutku zahtjeva za rješenjem. U trećem je slučaju konverzacija ES-korisnik sprovedena u cjelosti, sve varijable konverzacije poprimile su vrijednosti, a ipak je potrebno sprovesti asocijativnu inicijalizaciju varijabli zbog predviđene mogućnosti davanja 'nesigurnih odgovora' kao što su 'NE ZNAM' ili 'NIJE VAŽNO'. Naime, u sustavu postoje određene varijable, koje u svakom slučaju moraju poprimiti kvantitativne vrijednosti bez obzira na to što je korisnik dao nesiguran odgovor za vrijednosti istih. Tipičan primjer takve varijable je radna temperatura na temelju čijeg se iznosa donose važni zaključci unutar mehanizma zaključivanja. Korisniku je dana mogućnost davanja *nesigurnog odgovora* u pogledu iznosa temperature, ali se kvantitativna vrijednost za tu varijablu dobiva asocijativnom inicijalizacijom.

Prema slici 3.7 asocijativno se inicijaliziraju vrijednosti varijabli koje se nalaze unutar sljedećih skupova asocijacija:

1. Skup asocijacija o elementima sustava
2. Skup asocijacija o agresivnosti okoliša
3. Skup asocijacija o agresivnosti otopine
4. Skup asocijacija o koncentraciji agresivne otopine
5. Skup asocijacija o radnoj temperaturi
6. Skup asocijacija o mehaničkim svojstvima
7. Skup asocijacija o masi funkcionalnih dijelova

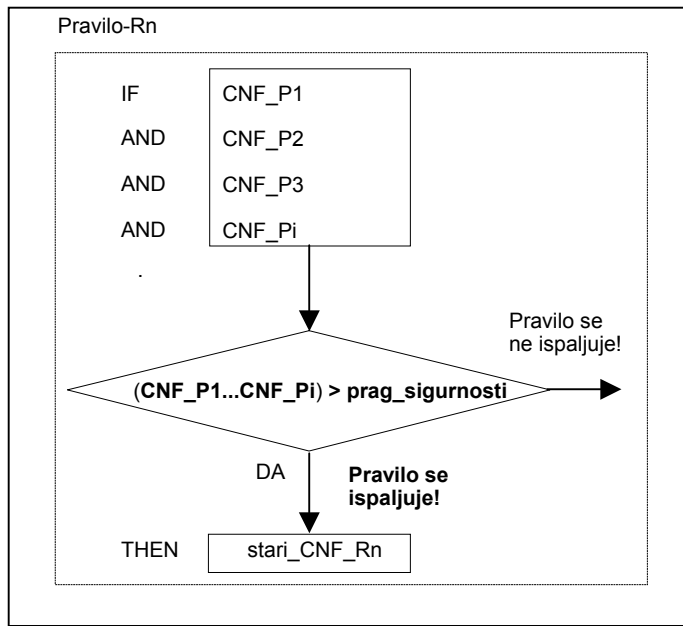
3.2.3. Mehanizam za obradu pravila

Zadaci mehanizma za obradu pravila su sljedeći: pozivanje pravila iz baze znanja, izračunavanje faktora sigurnosti i kontrola ispaljivanja pravila. Primjer strukture pravila Naziv_Pn sa tri premise Naziv_P1, NAZIV_P2, Naziv_P3, povezane logičkim operatorom AND prikazan je na slici 3.8.

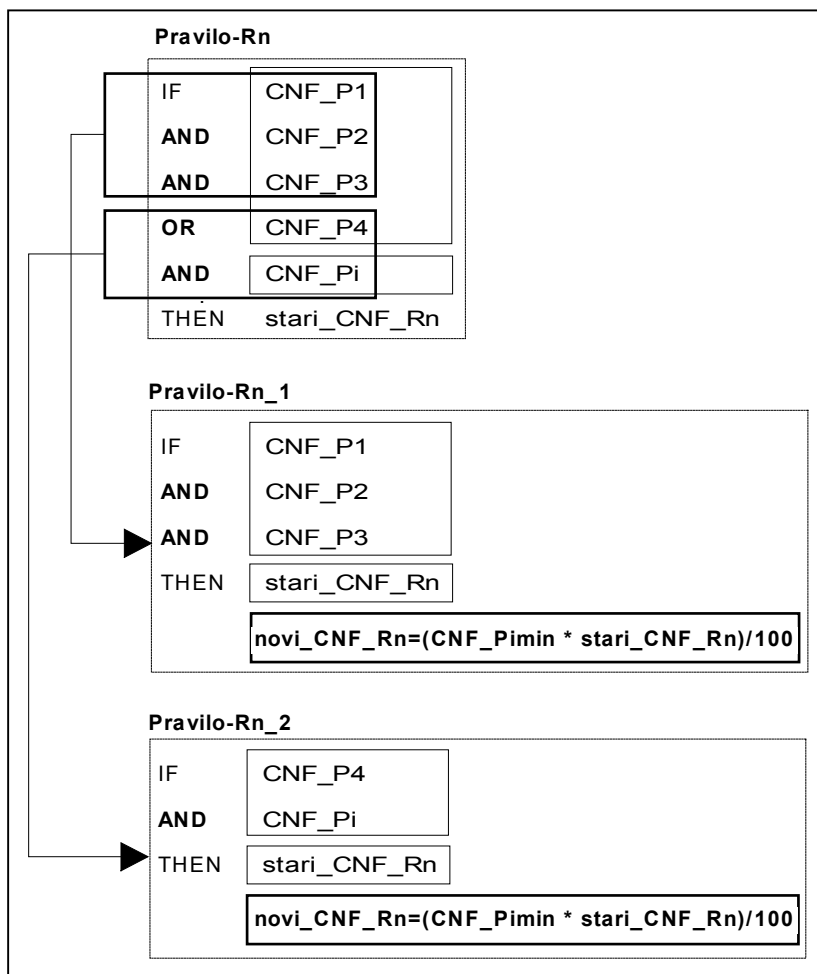


Slika 3.8. Blok-shema strukture pravila

Svako od *premise* unutar pravila dodjeljuju se *faktori sigurnosti*: CNF_P1,CNF_P2,CNF_P3. Premise Naziv_P1, NAZIV_P2, Naziv_P3 u većini slučajeva predstavljaju nazive već ranije *ispaljenih* pravila koja se pozivaju mehanizmom *ulančavanja unazad*. Također je unutar pravila predviđena ugradnja tzv. *globalnog praga sigurnosti* (engl. *threshold*) čija je funkcija kontrola ispaljivanja pravila. Naime, pravilo će biti ispaljeno samo ako su svi faktori sigurnosti premise (CNF) veći od vrijednosti globalnog praga sigurnosti (slika 3.9).



Slika 3.9. Blok-shema uvjeta *ispaljivanja* pravila

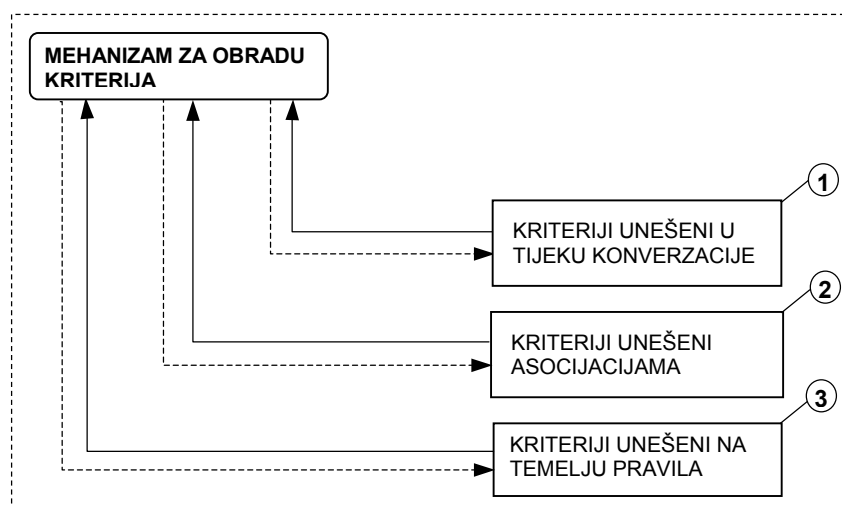


Slika 3.10. Princip izračunavanja *faktora sigurnosti* (CNF) pravila

U slučajevima kada pravilo pored AND operatora sadrži i OR operator, isto se dijeli pravila na dva nova AND pravila, a faktori sigurnosti se u tom slučaju izračunavaju prema izrazu **novi_CNF_Rn** kao što je prikazano na slici 3.10.

3.2.4. Mehanizam za obradu kriterija za izbor materijala

Mehanizam za obradu kriterija formira liste kriterija za pretraživanje na temelju zahtjeva zadanih od strane korisnika te činjenica iz baze znanja. Prema slici 3.11, unutar ovog mehanizma predviđena je obrada, po načinu nastanka, tri različite grupe kriterija:



Slika 3.11. Blok-shema mehanizma za obradu kriterija

1. Kriteriji unešeni u tijeku konverzacije s korisnikom

-to su kriteriji koje je eksplicitno zadao korisnik tijekom konverzacije preko korisničkog sučelja, kao npr. broj funkcionalnih dijelova, relativna gibanja funkcionalnih dijelova itd.

2. Kriteriji unešeni asocijacijama

-to su kriteriji koji su u tijeku konverzacije poprimili *nesigurne* vrijednosti, a mehanizam za obradu asocijacija pretvara ih u konkretne vrijednosti, npr. već spomenuta radna temperatura.

3. Kriteriji unešeni na temelju pravila

-ovi su '*nevidljivi*' kriteriji jer se formiraju na temelju ugrađenog znanja unutar baze pravila.

Npr. jedan od takvih kriterija koji se formira na temelju pravila, je potreban stupanj legiranosti materijala a na temelju iznosa radne temperature. Isti će poprimiti vijednost VISOKOLEGIRANI ako je npr. radna temperature viša od 600 °C.

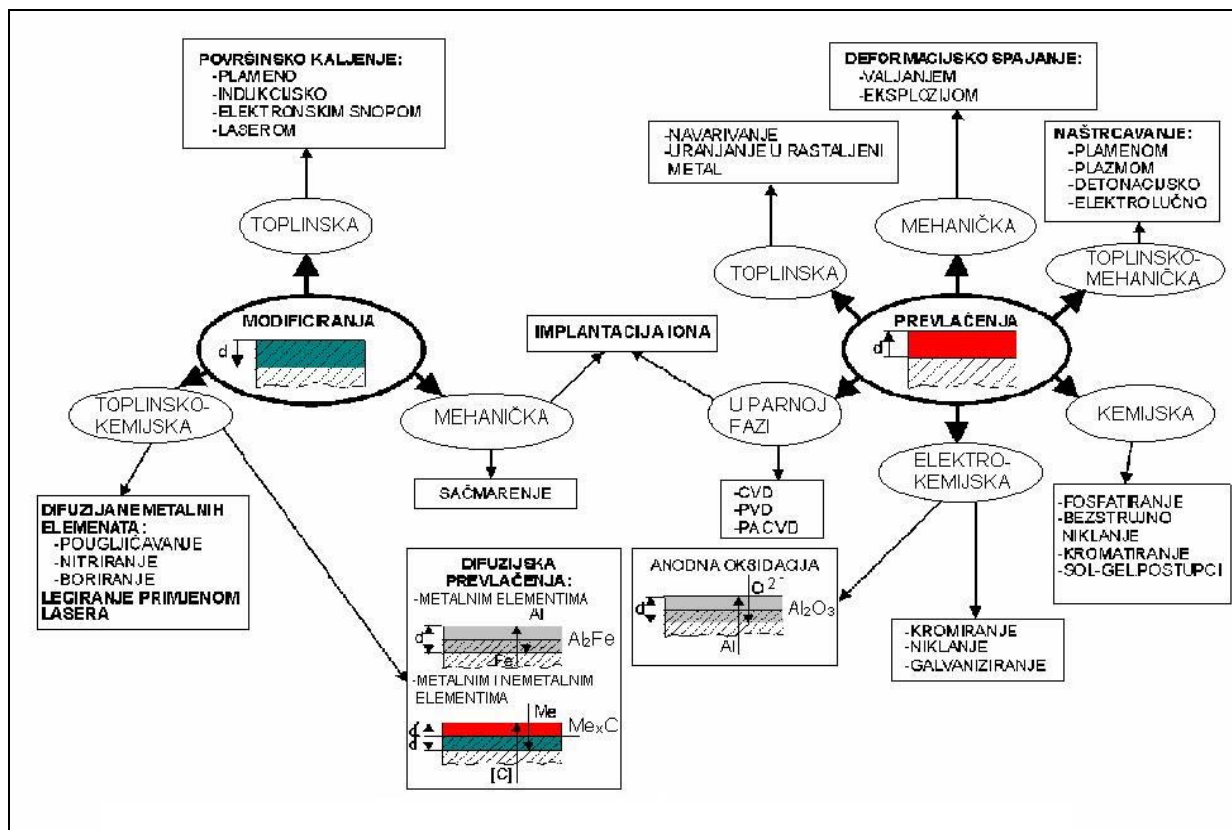
Dio kriterija koji se formiraju unutar nabrojanih grupa kriterija odnose se za izbor prikladnog postupka modificiranja površina, a dio za izbor prikladnog materijala sloja. Kriteriji za izbor prikladnog postupka modificiranja površina formiraju se uglavnom na temelju razmatranja elemenata sustava trošenja te relativnog gibanja, dok se kriteriji za izbor prikladnog materijala sloja temelje na eksplicitnim vrijednostima koje je unio korisnik ili vrijednostima inicijaliziranim pomoću asocijacija.

Smatra se da se ovakvim načinom obrade kriterija postiže određeni stupanj '*inteligencije*' sustava, jer praktički korisnik ne treba znati previše o kriterijima koje je potrebno postaviti da bi sustav odredio suvislo tj. zadovoljavajuće rješenje. Naime, u slučaju davanja pogrešnih odgovora od strane korisnika (namjerno ili nenamjerno) kod klasičnih sustava uzrokuje se formiranje pogrešnih kriterija pa je prema tome takvo i krajnje rješenje, dok je kod inteligentnih sustava situacija obrnuta. Kod sustava koji se razmatra u ovom radu, predviđena je mogućnost namjernog unošenja pogrešnih ili nesigurnih odgovora na temelju kojih se formiraju kriteriji za izbor postupka modificiranja površina ili pak prikladnog materijala. Međutim, naučeni će sustav na temelju vremenskih asocijativnih matrica pravilno formirati potrebne kriterije te predložiti zadovoljavajuće rješenje problema.

Detaljnije će se formiranje vremenskih asocijativnih matrica kao i formiranje kriterija objasniti u eksperimentalnom dijelu rada.

3.2.5. Mehanizam izbora postupaka modificiranja površina procjenama

Veliki broj postojećih postupaka modificiranja i prevlačenja površina, koji se koriste u cilju povećanja otpornosti na trošenje, sve više se primjenjuje u industrijskoj praksi a razvijaju se i novi postupci. Svaki od postupaka je specifičan kako u pogledu podobnosti za mehanizme i uvjete trošenja tako i u pogledu primjenjivosti obrađivanih materijala i tehnoloških posebnosti primjene. Pravilan izbor postupka povezan sa cjelovitom analizom velikog broja utjecajnih čimbenika.

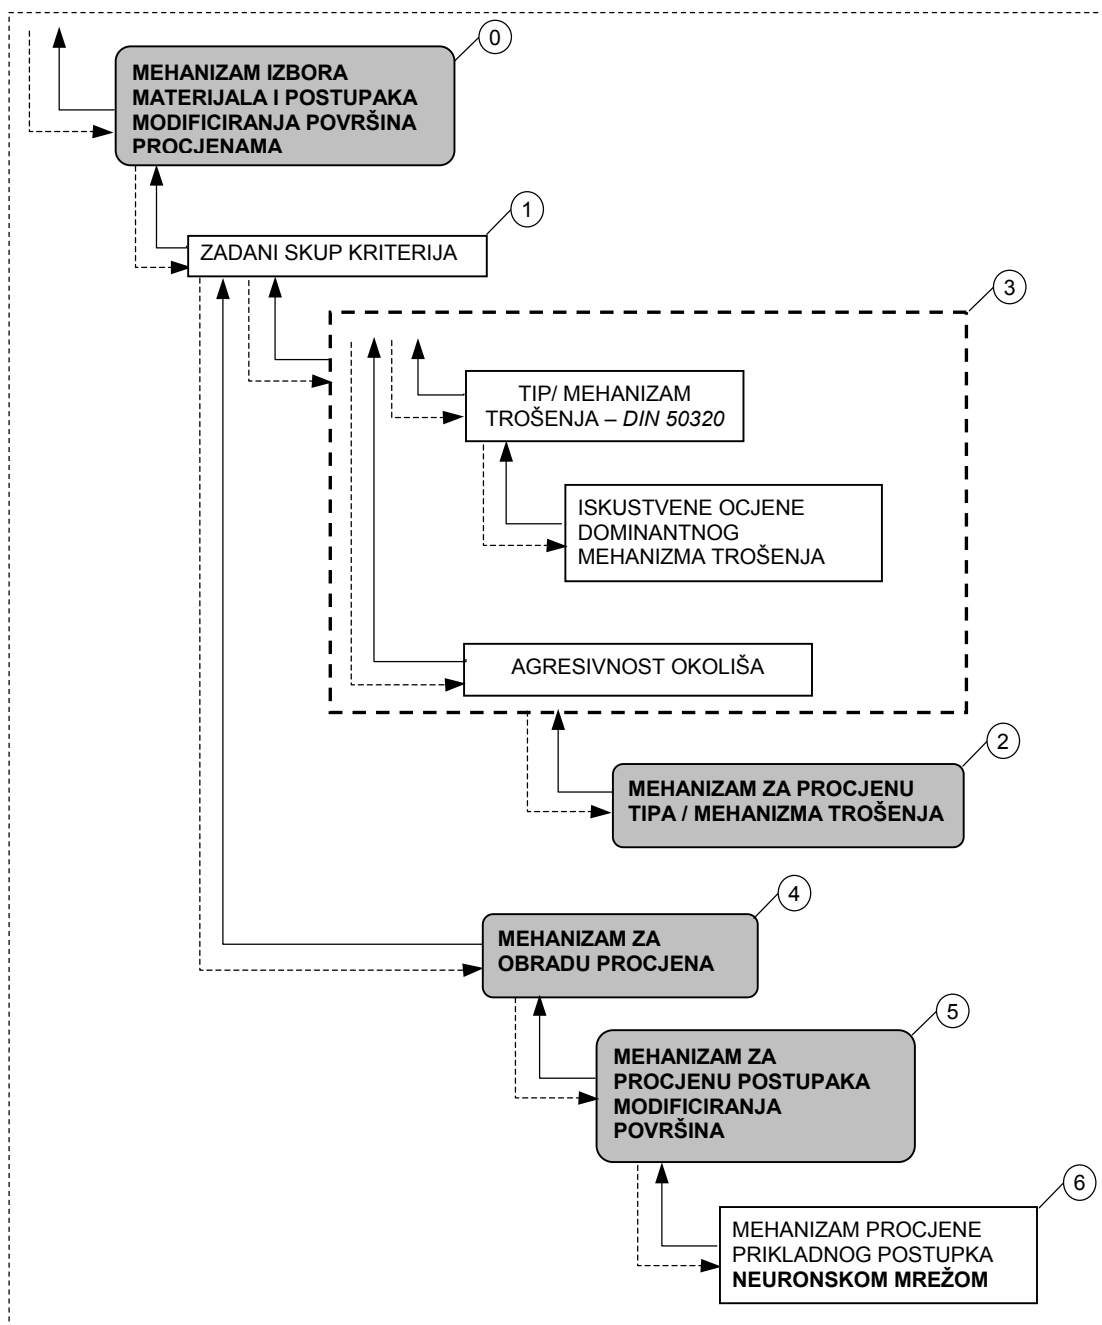


Slika 3.12. Pregled podjele postupaka modificiranja i prevlačenja metala [48]

Pregled novije podjele postupaka modificiranja i prevlačenja metala prema [48] prikazan je na slici 3.12. U prilogu II. detaljno su dane sljedeće karakteristike većine prikazanih postupaka, a uključenih u bazu znanja .

1. Zahtjev za primjenom
2. Definicija postupka
3. Karakteristike i shema postupka
4. Zahtjevi uvjetovani konstrukcijom obradka
5. Troškovi
6. Materijali obradka
7. Materijali-Struktura sloja
8. Poželjna toplinska obradba obradka prije prevlačenja
9. Poželjno stanje površine obradka prije prevlačenja
10. Varijante procesa
11. Praktične debljine slojeva
12. Promjena dimenzija i oblika obradka
13. Naknadna obrada sloja
14. Ravnomjernost debljine površinskog sloja i održanje konture sloja
15. Otpornost trošenju sloja
16. Ostala svojstva sloja
17. Primjena slojeva
18. Fotografija mikrostrukture - primjer primjene

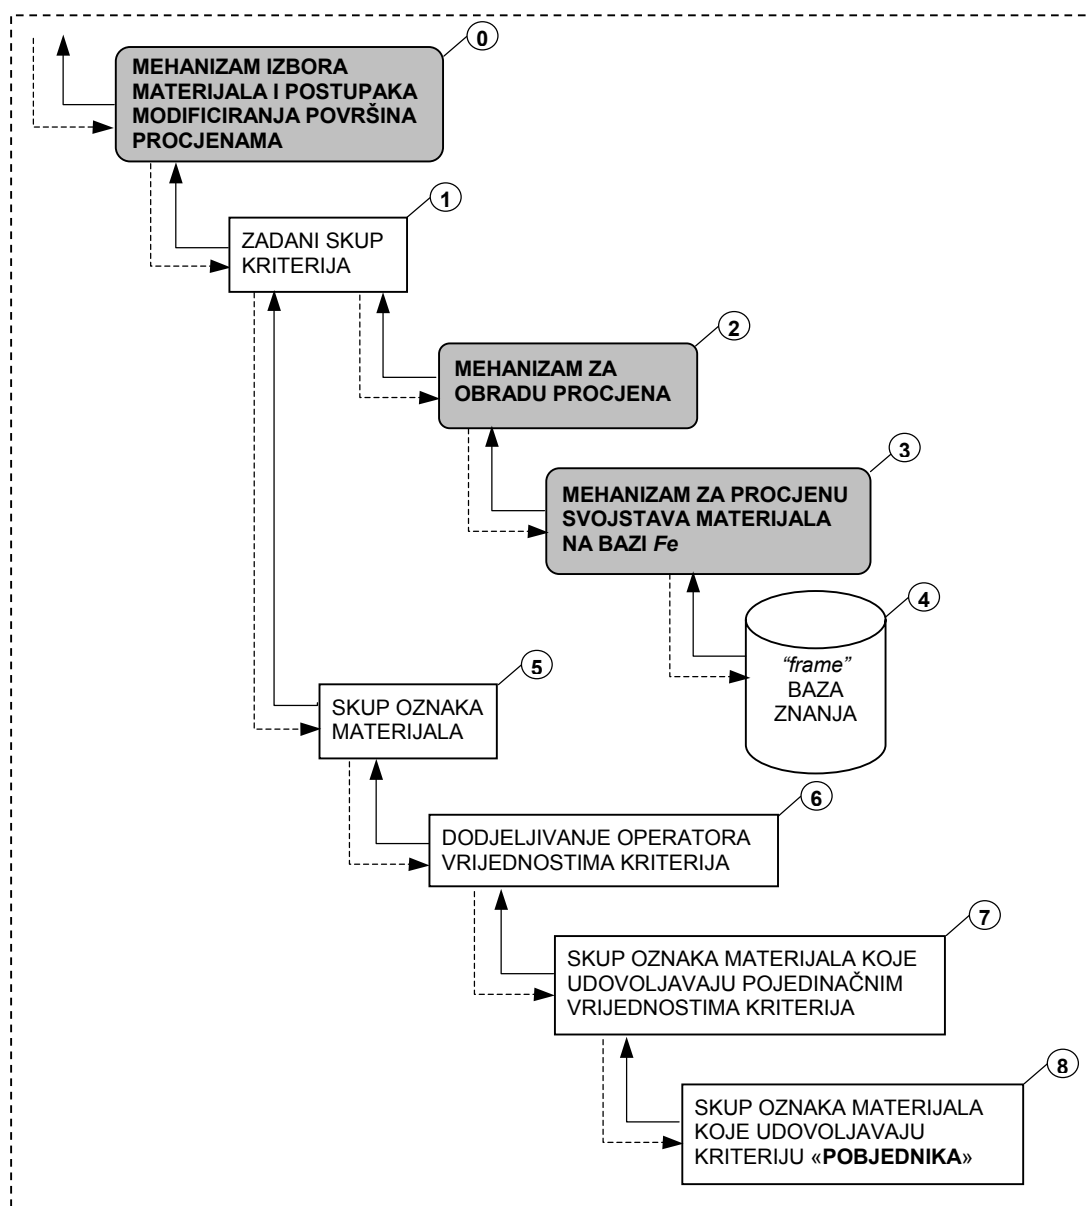
Razlika između postupaka procjena materijala i procjena prikladnog postupka modificiranja površina je u tome, što se kod prvog postupka većina vrijednosti zadanog skupa kriterija unose izravno u tijeku konverzacije s korisnikom, dok su kod izbora postupka modificiranja površina vrijednosti zadanog skupa kriterija procijenjene, tj. dobivene kao izlaz iz neuronske mreže za određivanje tipa odnosno mehanizma trošenja (2). Slijedi zaključak da će pravilna procjena postupka modificiranja površina ovisiti o kvaliteti rada neuronske mreže za procjene tipa tj. mehanizma trošenja. Nadalje je postupak dobivanja procjene prikladnog postupka analogan postupku dobivanja prikladnog materijala na bazi Fe . Skup kriterija sa vrijednostima se prosljeđuje do mehanizma za obradu procjena (4), a zatim do mehanizma za procjenu prikladnog postupka neuronskom mrežom (6) koji procjenjuje oko tridesetak različitih postupaka modificiranja površina. Na slici 3.13 prikazana je blok-shema mehanizma izbora postupka modificiranja površina.



Slika 3.13. Blok-shema mehanizma izbora postupka modificiranja površina

3.2.6. Mehanizam izbora materijala procjenama

Nakon postavljanja kriterija za izbor prikladnih materijala, mehanizam za obradu kriterija iste prosljeđuje mehanizmu izbora materijala i postupaka modificiranja površina, gdje se u prvom koraku (1) formira lista (skup) kriterija (npr. *Rm*, *Re*, *HV*, *primjena*, itd.). Zadani skup kriterija u koraku (2) prosljeđuje se mehanizmu za obradu procjena koji iz *okvir* baze znanja (koraci 3 i 4) izdvaja skup oznaka materijala (korak 5) sa vrijednostima pojedinačnih kriterija. Dodjeljivanje operatora pretraživanja vrijednostima kriterija izvodi se u koraku (6), nakon čega se u koraku (7) se *metodom presjeka* dobiva skup oznaka koje udovoljavaju pojedinačnim vrijednostima kriterija. I na kraju, u koraku (8) se *metodom pobjednika* dobivaju one oznake materijala koje udovoljavaju svim postavljenim kriterijima. Zbog prednosti nasljeđivanja svojstava, predviđena je *okvir* struktura baze podataka, a ne klasična struktura baze podataka. Prema slici 3.14 čini se da su koraci 6, 7 i 8 nepotrebni te da ih se može izbjeći modeliranejm standardnog *SQL* –upita. Izbjeći ih nije moguće, zbog kriterija koji nemaju zadane početne vrijednosti (engl. *default*), a koje se nasljeđuju izravno od okvira roditelja. U tome je i nedostatak klasičnog pretraživanja (zadavanjem *SQL*-upita), jer kriteriji koji nemaju vrijednost, ne ulaze u daljni izbor.



Slika 3.14. Blok-shema mehanizma izbora materijala

Predviđeni su sljedeći operatori pretraživanja: $<$, $>$, $=$, *min*, *max*, i *like*. Za sve nabrojane operatore osim operatora *like* vrijednosti kriterija zadaju se kvantitativno. Kod primjene *like* operatora vrijednosti kriterija zadane su opisno, te se zbog toga *like* operator primjenjuje kod pretraživanja polja koja sadrže tekstualne

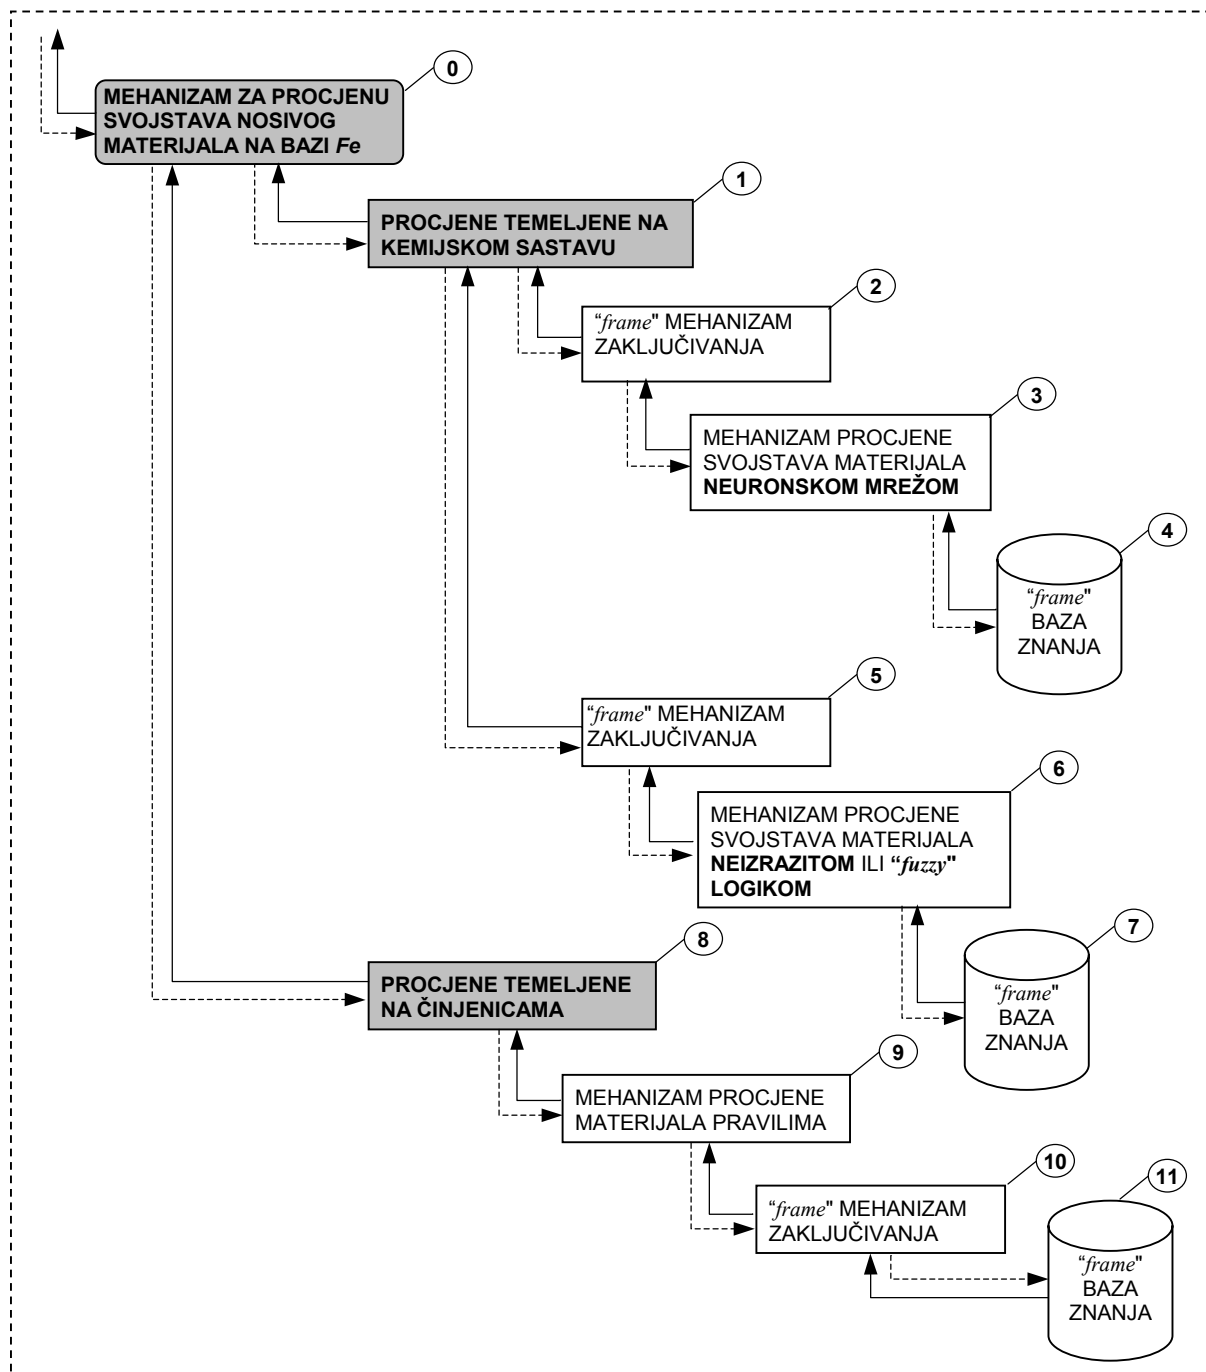
podatke (tzv. *memo polja*) kao što je npr. polje *PRIMJENA MATERIJALA*. Unutar postavljenih kriterija, moguća je kombinacija nabrojanih operatora.

3.2.7. Mehanizam za procjenu svojstava nosivog materijala na bazi Fe

Predviđene su dvije vrste procjena materijala na bazi *Fe* koje sustav procjenjuje:

1. Procjene temeljene na kemijskom sastavu
2. Procjene temeljene na činjenicama

Procjene pod rednim brojem 1. dobivaju se metodologijom neuronskih mreža i *neizrazite* ili *fuzzy logike*, a procjene pod rednim brojem 2. metodologijom ekspertnih sustava (modeliranjem pravila). Kao što se vidi na slici 3.15, predviđene su veze mehanizama neuronskih mreža, neizrazite ili *fuzzy logike* sa *okvir* mehanizmom zaključivanja te *okvir* bazom znanja u koju su pohranjeni podaci o kemijskim sastavima i mehaničkim svojstvima materijala.



Slika 3.15. Blok-shema mehanizma za procjenu materijala na bazi *Fe*

Na slici 3.16 detaljno su prikazane sve grupe i podgrupe procjena materijala na bazi *Fe*, koje je mehanizam za procjenu u stanju procjenjivati na temelju zadanih kriterija koje mu prosljeđuje mehanizam za obradu kriterija. *Okvir* mehanizam zaključivanja sa već spomenutom *okvir* bazom znanja materijala, na ovom nivou zaključivanja, služi kao servis koji dobavlja ulazne podatke naučnoj neuronskoj mreži ili *FIS-u*. Za svaku od nabrojanih grupa ili podgrupa procjena na temelju kemijskog sastava na slici 3.16 predviđen je optimalni izbor algoritma mreže odnosno *FIS-a*.

U nastavku slijedi opis značajki pojedinih procjena, te pravila za primjenu odnosno za usporedbu materijala na temelju istih. Treba napomenuti da su navedene procjene grube, te se primjenjuju kao kriteriji u predizboru materijala.

1. Mehanizam procjena svojstava materijala na temelju kemijskog sastava

1. Procjena mehaničkih svojstava pri normalnim temperaturama

Predviđene su sljedeće procjene mehaničkih svojstava pri normalnim temperaturama na temelju kemijskog sastava (*C, Si, Mn, Cr, Ni, Mo*) te stanja (kaljenog i poboljšanog) materijala:

1. R_m , N/mm² – vlačna čvrstoća
2. R_e , N/mm² – granica razvlačenja
3. HV – tvrdoća po Vickersu
4. A_5 , % – istezljivost
5. TR – ocjena trošenja: 1...3

Vrijedi sljedeće pravilo za usporedbu materijala:

1. *Bolji je onaj materijal čiji je iznos procjenjivanog mehaničkog svojstva pri normalnim temperaturama viši.*

2. Procjena kemijske postojanosti otopinama kiselina

Predviđene su procjene kemijske postojanosti (ocjene: 0...3) sljedećim otopinama kiselina na temelju kemijskog sastava (*C, Si, Mn, Cr, Ni, Mo*), radne temperature (20...100 °C) i koncentracije otopine (1...100 %):

1. CH_3COOH - octena otopina
2. HCl - kloridna otopina
3. HNO_3 - nitratna otopina
4. H_3PO_4 - fosfatna otopina
5. H_2SO_4 - sulfatna otopina

Vrijedi sljedeće pravilo za usporedbu materijala:

1. *Postojaniji je onaj materijal čiji je iznos procjenjivane postojanosti otopine kiseline niži.*

3. Procjena otpornosti trošenja abraziji gubitkom volumena

Procjena otpornosti abraziji GV , mm³ temelji se na kemijskom sastavu (*C, Si, Mn, Cr, W, Mo, V, Co*) i temperaturi popuštanja.

Vrijedi sljedeće pravilo za usporedbu materijala [47]:

1. *Otporniji je onaj materijal čiji je iznos procjenjivane otpornosti abraziji niži.*

4. Procjena otpornosti popuštanju alatnih čelika

Predviđene su procjene otpornosti popuštanju (relativni pad *HRC* tvrdoće) sljedećih grupa alatnih čelika na temelju kemijskog sastava (*C, Si, Mn, Cr, W, Mo, V, Co*) i parametra popuštanja:

1. Nelegirani čelici za hladni rad
2. Niskolegirani čelici za hladni rad
3. Visokolegirani čelici za hladni rad
4. Alatni čelici za topli rad
5. Brzorezni alatni čelici

Vrijedi sljedeće pravilo za usporedbu materijala [47]:

1. *Otporniji je onaj materijal čiji je iznos procjenjivane otpornosti popuštanju viši.*

5. Procjena mehaničkih svojstva alatnih čelika pri povišenim temperaturama

Predviđene su sljedeće procjene mehaničkih svojstava pri povišenim temperaturama na temelju kemijskog sastava (*C, Si, Mn, Cr, Ni, Mo, V, Co*) i temperature popuštanja (20...700 °C):

1. R_m , N/mm² – vlačna čvrstoća
2. $R_{p0,2}$, N/mm² – konvencionalna granica razvlačenja
4. A_5 , % – istezljivost

Vrijedi sljedeće pravilo za usporedbu materijala [47]:

1. *Nepostojaniji je onaj materijal čiji je iznos procjenjivanog mehaničkog svojstva pri povišenim temperaturama niži.*

6. Procjena legiranosti

Legiranost (*nelegiran, niskolegiran, visokolegiran*) se procjenjuje na temelju kemijskog sastava materijala (*Al, Co, Cr, Mn, Mo, Ni, Si, V, W*). Prema [39] čelik/čelični lijev se smatra *nelegiranim* ako sadrži udjele primjesa i legirajućih elemenata niže od nabrojanih u tablici 3.1 Čelik/čelični lijev smatra se *niskolegiran* ako je zbroj postotnih udjela legirajućih elemenata ≤ 5 , a *visokolegiran* ako je taj zbroj > 5 .

Tablica 3.1. Donje granice dopuštenog udjela legirajućih elemenata u nelegiranim čelicima/čeličnim lijevovima [39]

Legirni element	Donja granica dopuštenog udjela, %
Al	0,10
Cu	0,40
B	0,0008
Co	0,1
Cr	0,30
Mn	1,6
Mo	0,08
Ni	0,30
Nb	0,05
Pb	0,40
Si	0,50
Ti	0,05
V	0,10
W	0,05

Vrijede sljedeća pravila za procjenu legiranosti materijala [39]:

1. ***Ako je*** $Al < 0.1$ ***i*** $Co < 0.1$ ***i*** $Cr < 0.3$ ***i*** $Mn < 1.6$ ***i*** $Mo < 0.08$ ***i*** $Ni < 0.30$ ***i*** $Si < 0.5$ ***i*** $V < 0.1$ ***i*** $W < 0.05$ ***tada je*** materijal *nelegiran*.
2. ***Ako je*** $(Al + Co + Cr + Mn + Mo + Ni + Si + V + W) \leq 5$ ***tada je*** materijal *niskolegiran*.
3. ***Ako je*** $(Al + Co + Cr + Mn + Mo + Ni + Si + V + W) > 5$ ***tada je*** materijal *visokolegiran*.

7. Procjena obradljivosti

Iako nije samo funkcija sastava, pojednostavljeno se obradljivost (*niska, srednja, visoka*) procjenjuje na temelju legiranosti (*nelegiran, niskolegiran, visokolegiran*) materijala.

Vrijede sljedeća pravila za procjenu obradljivosti toplonski neobrađenih materijala s obzirom na legiranost [46]:

1. *Ako je materijal nelegiran tada je obradljivost = [VISOKA]*
2. *Ako je materijal niskolegiran tada je obradljivost = [NISKA, SREDNJA]*
3. *Ako je materijal visokolegiran tada je obradljivost = [NISKA]*

8. Procjena zavarljivosti na temelju - C_E

Uobičajena i najčešća metoda određivanja metalruške zavarljivosti, naročito ugljičnih i niskougljičnih čelika je ekvivalent ugljika - C_E . U izrazu za izračunavanje ekvivalenta ugljika obuhvaćeni su elementi koji na određeni način utječu na zavarljivost čelika tako da povećavaju samo zakaljivost što je za zavar nepovoljno. Različiti autori navode različite izraze za određivanje C_E , a najčešće je korišten izraz (3.1) međunarodnog instituta za zavarivanje (*IIW*) [41]. Materijali kojima je iznos $C_E=(0,40 \text{ do } 0,45)$, skloni su stvaranju hladnih pukotina.

$$C_E = \%C + \frac{\%Mn}{6} + \frac{\%Ni + \%Cu}{15} + \frac{\%Cr + \%Mo + \%V}{5}, \% \quad (3.1)$$

Vrijedi sljedeće pravilo za usporedbu materijala:

1. *Zavarljiviji je onaj čelik čiji je iznos procjenjivane zavarljivosti na temelju C_E niži.*

9. Procjena žilavosti

Žilavost materijala se procjenjuje na temelju kemijskog sastava iznosa omjera Mn/C i iznosa Re , N/mm^2 . Treba napomenuti da sponenuti omjer vrijedi samo djelomično, i to za grupu konstrukcijskih čelika.

Vrijede sljedeća pravila za usporedbu materijala [46]:

1. *Žilaviji je onaj materijal čiji je iznos Mn/C viši.*
2. *Žilaviji je onaj materijal čiji je iznos Re viši.*

2. Mehanizam procjena materijala temeljenim na činjenicama

1. Procjena oblikovljivosti

Oblikovljivost se procjenjuje na temelju iznosa Re , N/mm^2 .

Vrijedi sljedeće pravilo za usporedbu materijala [46]:

1. *Veću sposobnost oblikovanju ima materijal čiji je iznos Re niži.*

2. Procjena osjetljivosti na zarezno djelovanje

Osjetljivost materijala na zarezno djelovanje procjenjuje se na temelju iznosa omjera Re/Rm .

Vrijedi sljedeće pravilo za usporedbu materijala [46]:

1. *Osjetljiviji na zarezno djelovanje je onaj materijal čiji je iznos Re/Rm niži.*

3. Procjena visine radne temperature

Visina radne temperature (*NISKA*, *SREDNJA*, *VISOKA*) procjenjuje se na temelju iznosa varijable tr koji je korisnik tijekom konverzacije.

Vrijede sljedeća pravila za procjenu visine radne temperature čelika [46]:

1. ***Ako je $tr \leq 180$ °C tada je radna temperatura NISKA.***
2. ***Ako je $180 > tr \leq 450$ °C tada je radna temperatura SREDNJA.***
3. ***Ako je $450 > tr \leq 1200$ °C tada je radna temperatura VISOKA.***

4. Procjena primjene grupe konstrukcijskih čelika na temelju radne temperature

Grupa konstrukcijskih čelika (*NELEGIRANI*, *NISKOLEGIRANI*, *VISOKOLEGIRANI*, *VATROOTPORNI*) za primjenu procjenjuje se na temelju radne temperature tj. iznosa varijable tr koju je korisnik unio u tijeku konverzacije.

Vrijede sljedeća pravilo za procjenu primjene grupe konstrukcijskih čelika na temelju iznosa radne temperature [46]:

1. ***Ako je $tr=0 -480$ °C tada je grupa materijala NELEGIRANI I NISKOLEGIRANI.***
2. ***Ako je $tr=600 -800$ °C tada je grupa materijala VISOKOLEGIRANI.***
3. ***Ako je $tr=800 -1200$ °C tada je grupa materijala VATROOTPORNI.***

5. Procjena primjene grupe alatnih čelika na temelju radne temperature

Grupa alatnih čelika (*HLADNI RAD*, *TOPLI RAD*, *BRZOREZNI ČELICI*) za primjenu procjenjuje se na temelju radne temperature tj. iznosa varijable tr koji je korisnik unio u tijeku konverzacije.

Vrijede sljedeća pravila za procjenu primjene grupe materijala na temelju iznosa radne temperature [39]:

1. ***Ako je $tr=0 -200$ °C tada je grupa alatnih materijala HLADNI RAD.***
2. ***Ako je $tr=200 -600$ °C tada je grupa alatnih materijala TOPLI RAD.***
3. ***Ako je $tr=500 -600$ °C tada je grupa alatnih materijala BRZOREZNI ČELICI.***

6. Procjena nastajanja oksidacije na temelju radne temperature

Procjena nastajanja oksidacije procjenjuje se na temelju radne temperature tj. iznosa varijable tr koji je korisnik unio u tijeku konverzacije.

Vrijedi sljedeće pravilo za procjenu nastajanja oksidacije [46]:

1. ***Oksidacija nastaje ako je $tr > 550$ °C.***

7. Procjena uspješnosti sprečavanja oksidacije na temelju sadržaja Cr

Procjena uspješnosti sprečavanja oksidacije procjenjuje se na temelju sadržaja Cr u materijalu.

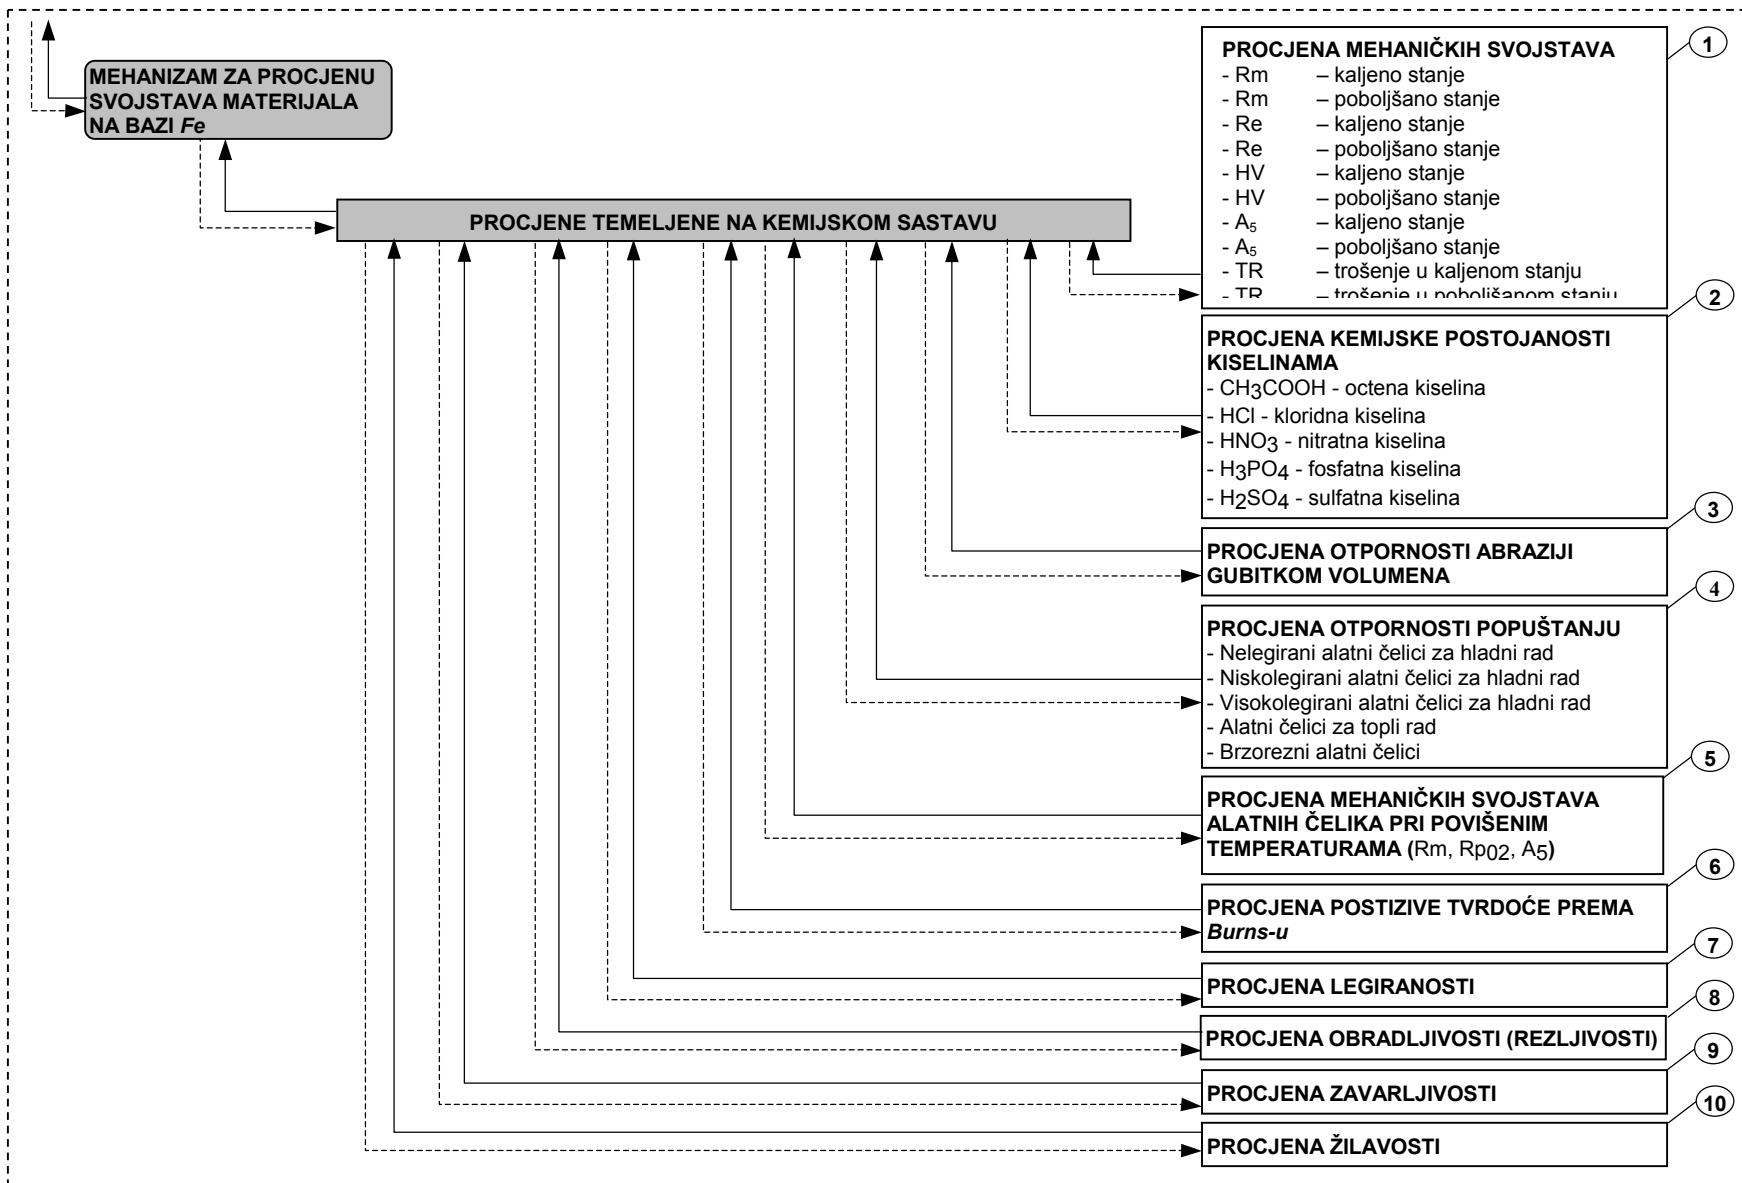
Vrijedi sljedeće pravilo za procjenu uspješnosti sprečavanja oksidacije [46]:

1. Oksidacija se sprečava ako je sadržaj $Cr \geq 13$ %.

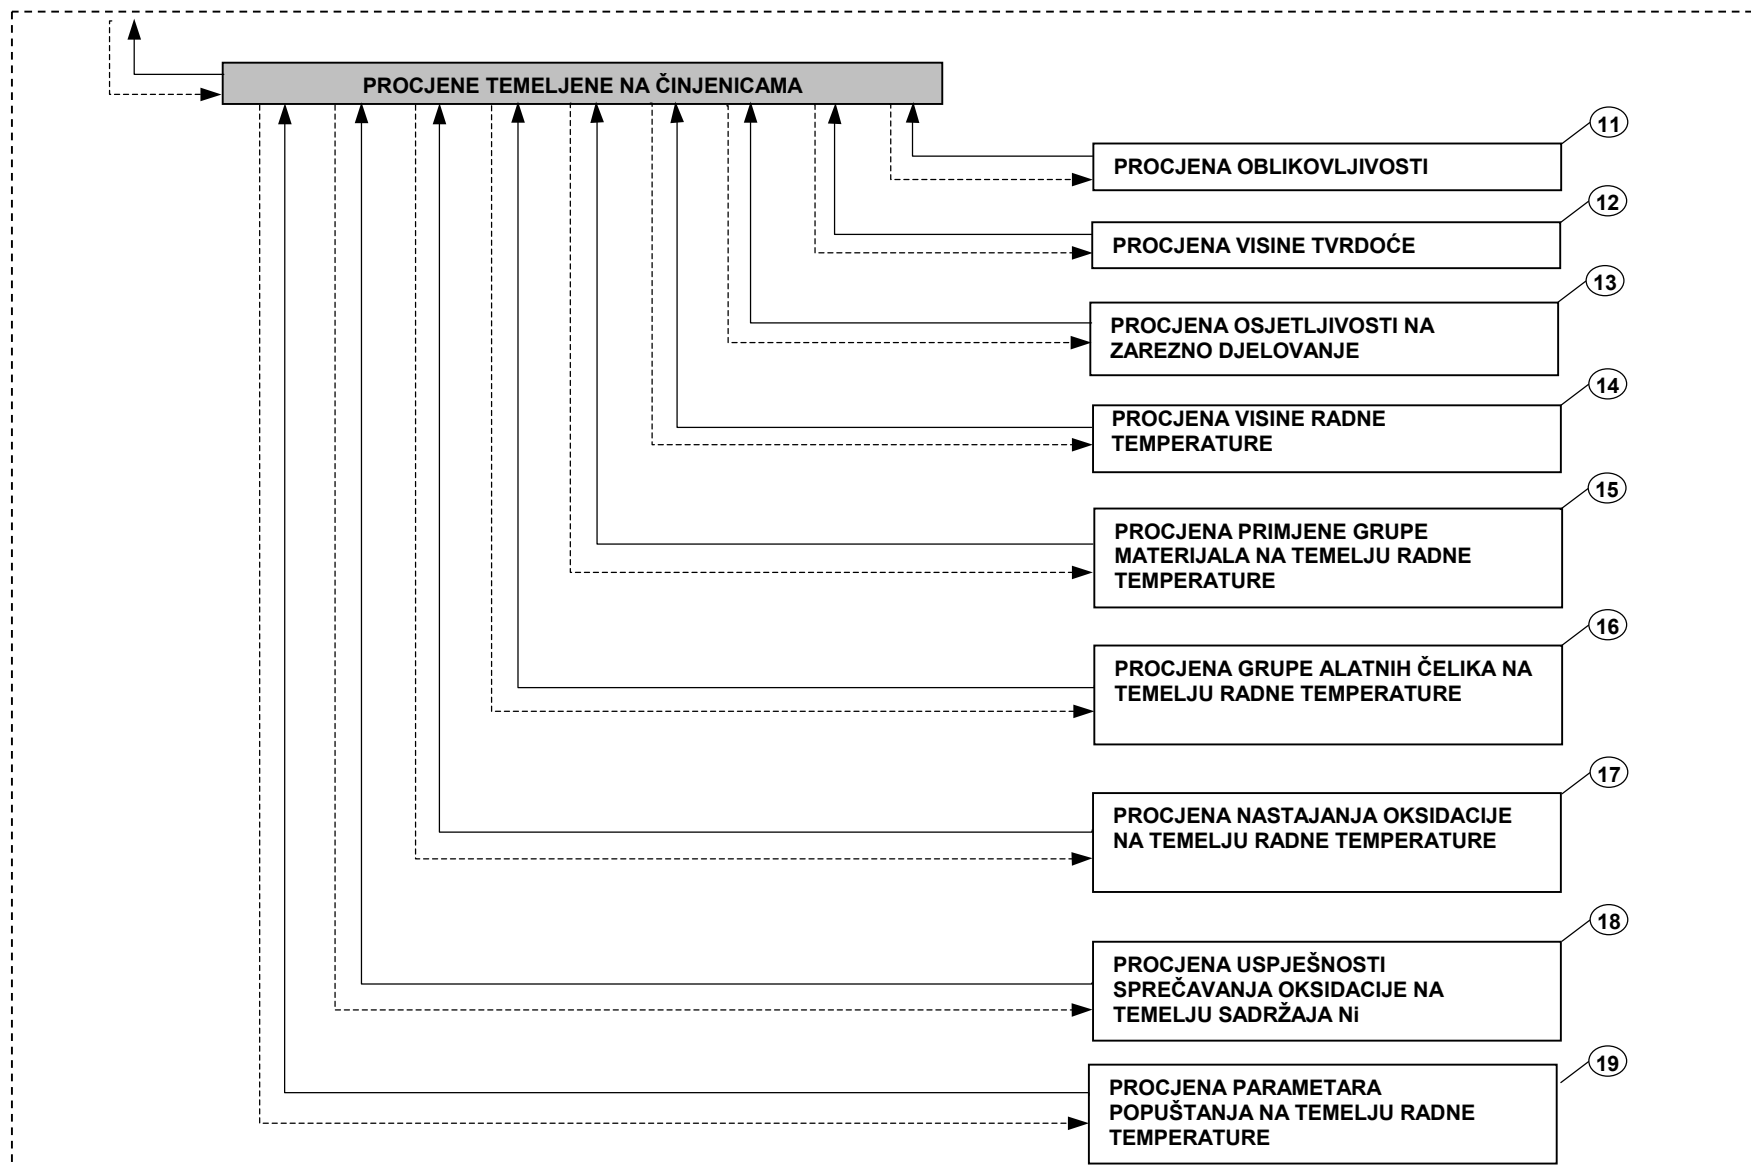
8. Procjena parametra popuštanja na temelju radne temperature

Parametar popuštanja procjenjuje se na temelju *HALLOMON* i *JAFFE* [42] izraza (3.2) na temelju zadane radne temperature tr (T , u donjem izrazu) i predefiniranog vremena trajanja t .

$$P = T(C + \lg t). \quad (3.2)$$



Slika 3.16. Blok-shema grupa procjena materijala na bazi Fe



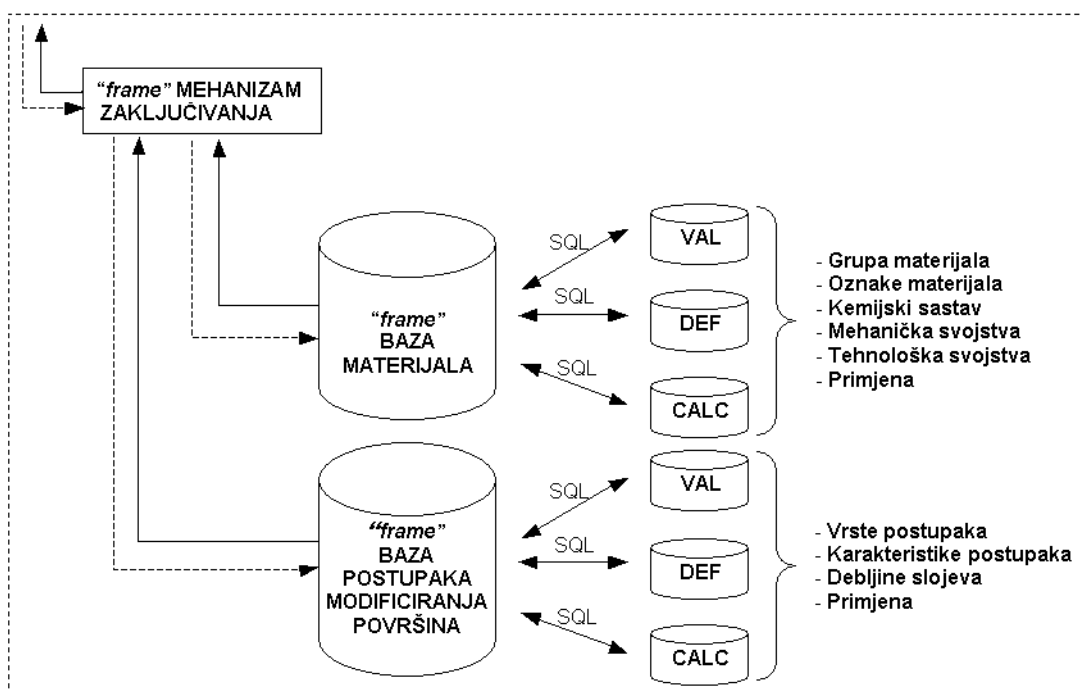
Nastavak - Slika 3.16. Blok-shema grupa procjena materijala na bazi *Fe*

3.2.8. Struktura *okvir* baza znanja

Predviđene su sljedeće *okvir* baze znanja (slika 3.17.):

1. Baza materijala na bazi *Fe*
2. Baza postupaka modificiranja površina

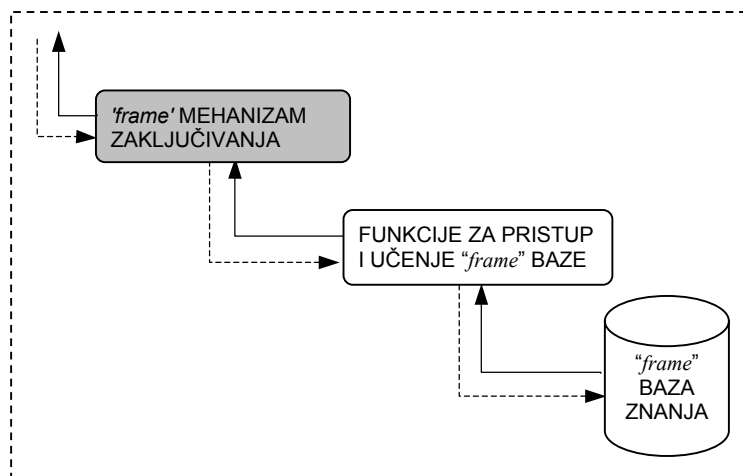
Struktura baze materijala modelirati će se tako da sadrži podatke o grupama, oznakama, kemijskom sastavu, mehaničkim i tehnološkim svojstvima te području primjene materijala, dok će struktura baze postupaka modificiranja površina sadržavati podatke o vrstama i karakteristikama postupaka modificiranja, debljinama slojeva koje je moguće postići pojedinim postupkom, te zahtjevima za primjenom. Svaka od baza sadrži skup od tri tablice u koje se spremaju VAL, DEF i CALC vrijednosti *okvira* tj. slotova. Unutar iste tablice spremaju se i 'roditelj' i 'djeca' *okviri*, a međusobno su povezani preko AKO pretinca. Podaci se zahvaćaju pomoću funkcija razvijenih unutar *okvir* mehanizma zaključivanja kao što je već opisano.



Slika 3.17. Blok-shema strukture *okvir* baza znanja

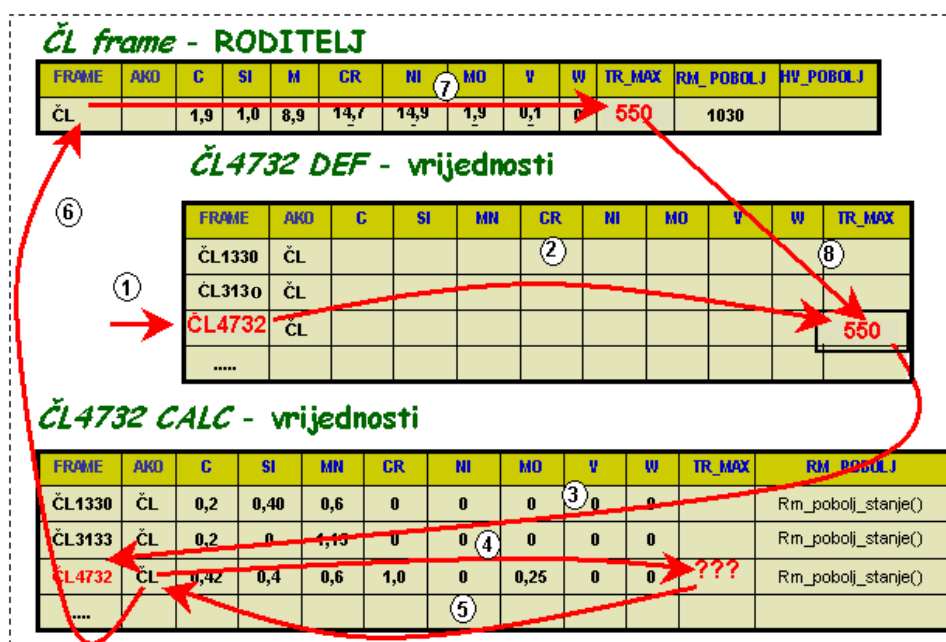
3.2.9. Okvir mehanizam zaključivanja

U okvir bazu materijala u **DEF** pretince pohranjuju se tzv. početne (engl. *default*) vrijednosti za pojedina svojstva materijala kao što je npr.: kemijski sastav, mehanička svojstva, primjeri primjene itd. Za svojstva koja nemaju početne vrijednosti, ista se izračunavaju pomoću funkcije predefiniране u **CALC** pretincu, ili se nasljeđuju od *okvir* roditelja predefiniранog u **AKO** pretincu.



Slika 3.18. Blok-shema *okvir* mehanizma zaključivanja

Osim razvoja standardnih funkcija za pristup *okvir* bazi znanja koje posjeduju sposobnost nasljeđivanja, predviđen je razvoj funkcija koje omogućavaju učenje *okvir* baze znanja o svojstvima materijala. Pod pojmom učenja podrazumijeva se dobivanje VAL-vrijednosti slotova metodama umjetne inteligencije (neuronske mreže, neizrazita ili *fuzzy* logika) na temelju predefiniраниh funkcija iz **CALC** pretinca, koje pozivaju određeni algoritam naučene neuronske mreže ili *fuzzy FIS-a*. Na taj se način *okvir* baza unaprijed nauči procjenjivati neko svojstvo pohranjujući je u VAL pretinac. Time se ubrzavaju proračuni unutar sustava, čime se značajno ubrzava proces dobivanja rješenja. Na slici 3.19 prikazan je primjer nasljeđivanja pri određivanju maksimalne radne temperature koju materijal može podnijeti bez opasnosti pojave stvaranja oksidacije za ČL4732. Prema tijeku pretraživanja 1-2-3-4 taj podatak nije pronađen, te se on nasljeđuje od *okvira* roditelja (tijek pretraživanja 5-6-7-8), a to je u ovom slučaju *okvir* (grupa materijala) čelični lijev (ČL).

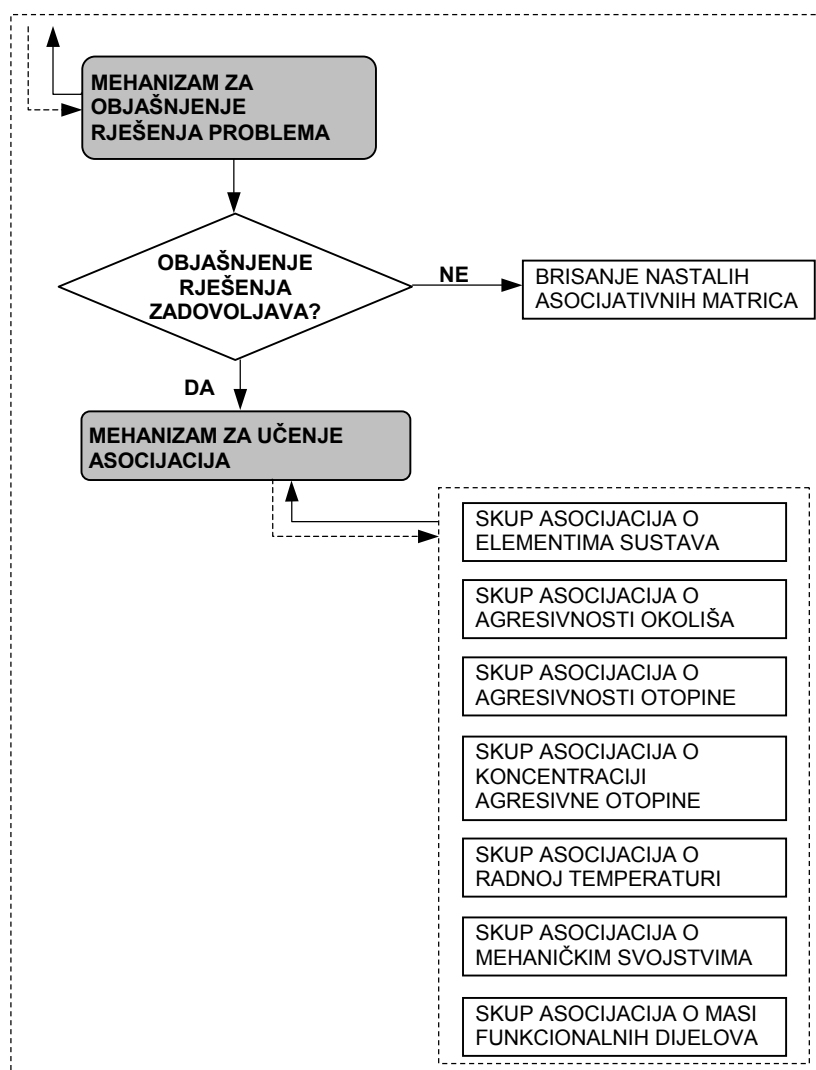


Slika 3.19. Princip nasljeđivanja svojstva *okvir* mehanizma zaključivanja

3.2.10. Mehanizam za učenje asocijacija

Učenje asocijacija pokreće se nakon što je sustav predložio rješenje razmatranog problema, a korisnik je to rješenje ocijenio kao zadovoljavajuće. Princip rada asocijacija je sljedeći. Sustav inicijalno sadrži asocijacije koje su rezultat iskustvenog znanja, a tijekom konverzacije s korisnikom *'pamti'* sve vrijednosti varijabli (kriterije) koje su ključne za rješavanje problema te ih na kraju sprema u tzv. *vremenske asocijativne matrice*. Tako npr. postoje vremenske asocijativne matrice o radnoj temperaturi, o zahtijevanim mehaničkim svojstvima materijala itd. Nakon što je rješenje ocijenjeno kao zadovoljavajuće mehanizam učenja pokreće asocijativnu neuronsku mrežu za učenje željene asocijacije. Proces učenja željene asocijacije traje tako dugo, dok se ne postigne željena točnost tj. stabilnost asocijacije. Nastale matrice težina i *bias* vektor izabrane asocijacije sustav sprema pod određenim nazivom te je željena asocijacija spremna za korištenje pri sljedećoj konverzaciji. Kao što je već spomenuto u uvodnom dijelu, smisao uvođenja asocijacija je želja za postizanjem *specijalizacije* sustava za bržim rješavanjem problema, posebice u slučajevima kada nisu poznati svi kriteriji ili čak niti jedan kriterij pretraživanja. Predviđeno je tzv. *'početno'* učenje sustava *'uobičajenim'* asocijacijama unutar razmatrane područja problema, te će na taj način sustav biti u mogućnosti predložiti suvislo rješenje iako nije unešen niti jedan kriterij tj., korisnik nije odgovorio niti na jedno pitanje. Već je spomenuto, da je sustav moguće, osim pravilnim asocijacijama, naučiti i pogrešnim asocijacijama potvrđivanjem predloženih rješenja kao zadovoljavajućim, a koja u stvarnosti zapravo ne zadovoljavaju. U slučaju ocjene rješenja kao nezadovoljavajućeg, nastale asocijativne matrice se brišu iz sustava.

Vrste asocijacija s kojima je moguće naučiti sustav prikazane su blok-shemom na slici 3.20. To su asocijacije o: *elementima sustava, agresivnosti okoliša, agresivnosti otopine, koncentraciji agresivne otopine, radnoj temperaturi, mehaničkim svojstvima i masi funkcionalnih dijelova*.

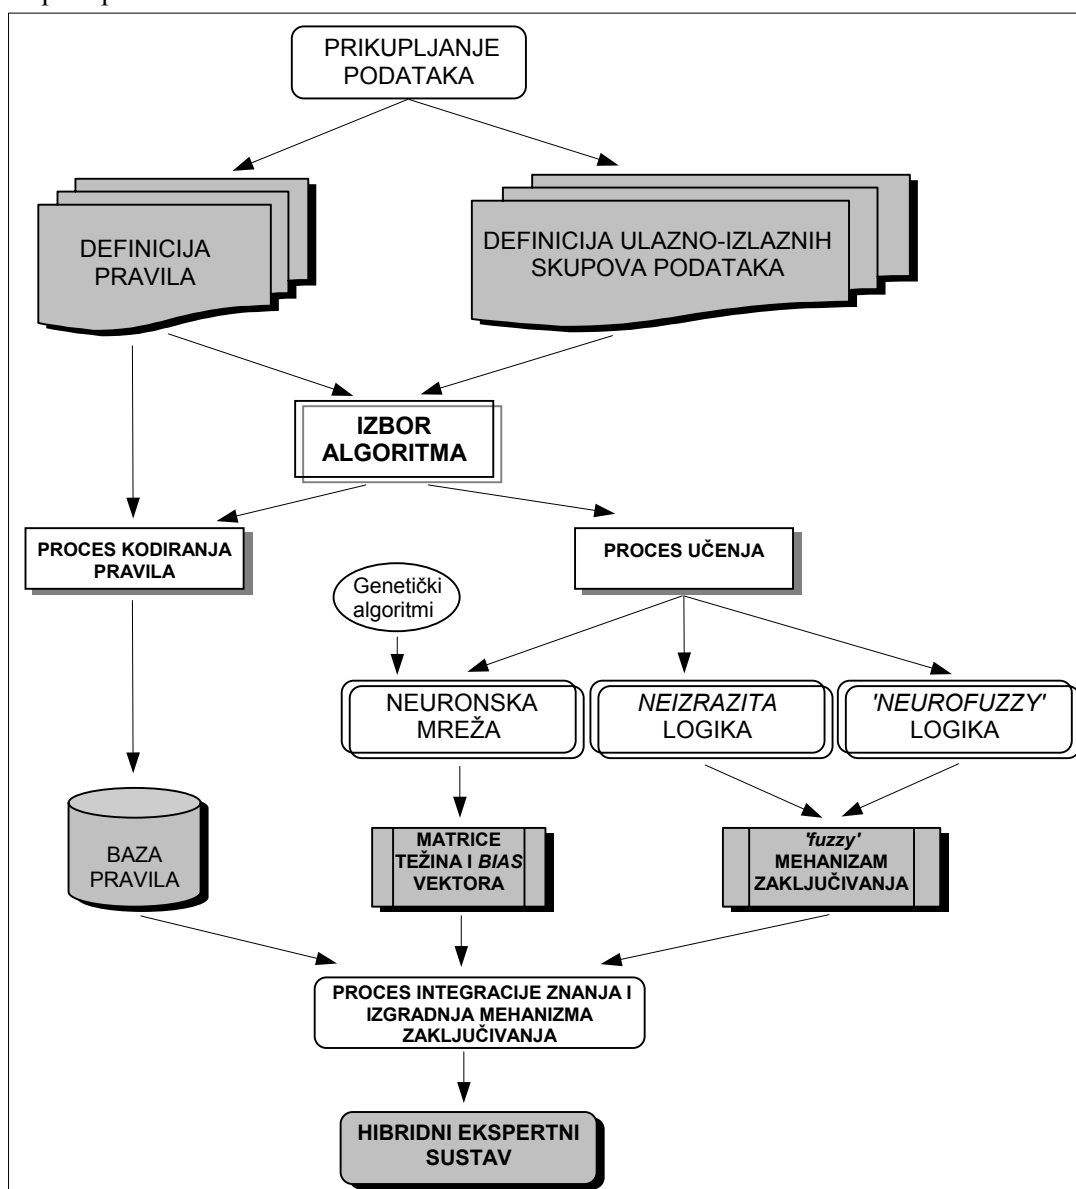


Slika 3.20. Blok-shema mehanizma za učenje asocijacija

4. EKSPERIMENTALNI DIO

4.1. Plan izgradnje sustava

Prema zamisli i razmatranjima iz prethodnih poglavlja, praktički glavni cilj rada je izgradnja hibridnog inteligentnog sustava (ekspertnog sustava) za izbor materijala, koji će opisane metode umjetne inteligencije integrirati unutar zajedničkog mehanizma zaključivanja. Za ostvarenje tog cilja, predviđen je plan izgradnje kao što je prikazano shemom na slici 4.1. Prikupljeni podaci o problemu podijeljeni su na dvije skupine: podaci potrebni za definiciju pravila i podaci za definiciju ulazno-izlaznih skupova neuronskih mreža i neizrazite i *neurofuzzy* logike. Prva skupina podataka uključuje uglavnom činjenično znanje o problemu te znanje potrebno za kontrolu tijeka izvođenja konverzacije, dok druga skupina podataka većinom uključuje podatke o kemijskim sastavima materijala. Za obradu prve skupine podataka izabrani su sljedeći algoritmi zaključivanja: *ulančavanje unaprijed-unazad*, *okvir zaključivanje*. Za obradu druge skupine podataka izabrano je 11 algoritama neuronskih mreža (vidjeti točku 2.8.6) i 2 algoritma (*Mamdani*, *Sugeno*) neizrazite logike. Zbog ograničenja opsega rada, prikazani su rezultati samo za prva dva najbolja algoritma neuronskih mreža. Nakon izbora algoritma, slijede faze procesa kodiranja pravila za prvu skupinu podataka, te procesa učenja neuronske mreže i neizrazite logike za drugu skupinu podataka.



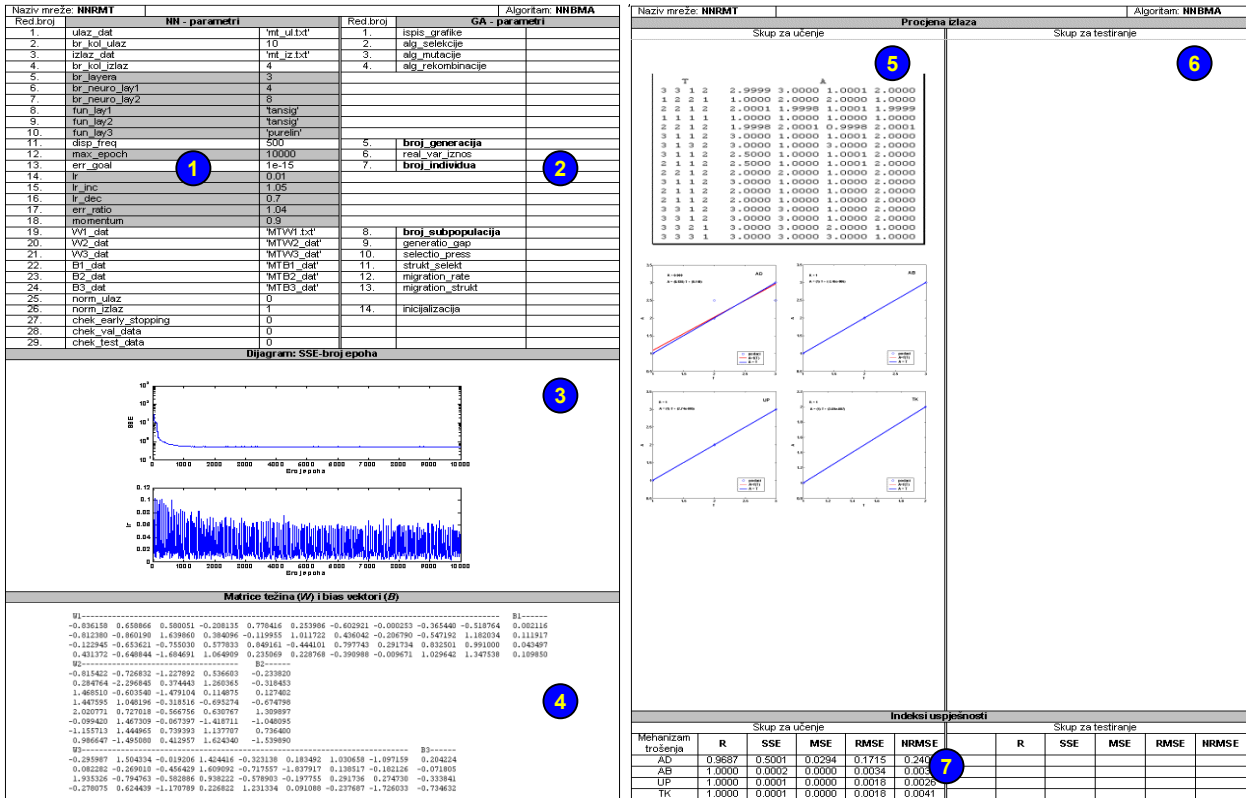
Slika 4.1. Shema plana izgradnje sustava

Rezultat ove faze je formirano znanje o problemu u vidu baze pravila, matrica težina i bias vektora te *fuzzy* mehanizma zaključivanja. Slijedi proces integracije znanja i mehanizma zaključivanja unutar hibridnog ekspertnog sustava.

4.2. Način prikaza rezultata eksperimenta

4.2.1. Prikaz parametara i rezultata učenja neuronske mreže

Parametri i rezultati učenja neuronskom mrežom za slučajevne procjena opisanih u 3. poglavlju prikazuju su obrascem kao na slici 4.2. Obrazac je podijeljen na sljedećih sedam različitih područja:

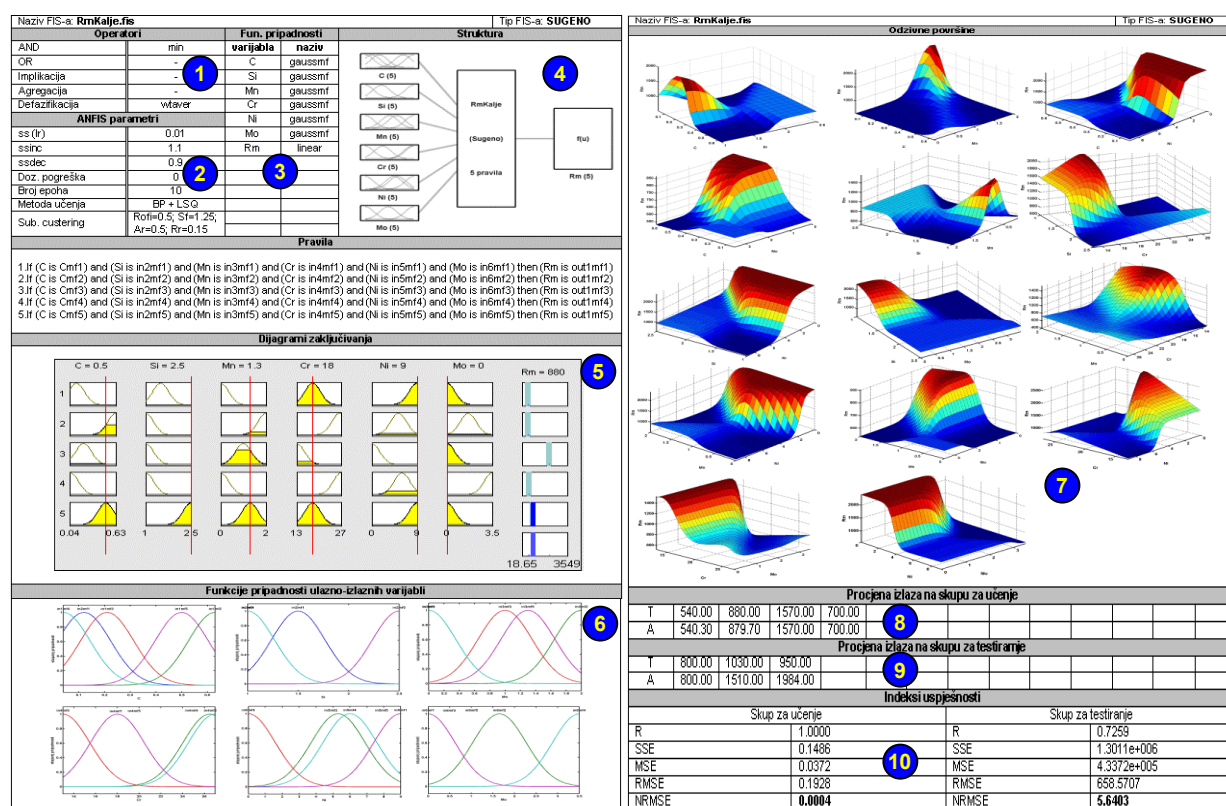


Slika 4.2 Primjer načina prikaza parametara i rezultata učenja neuronske mreže

- Unutar ovog područja prikazani su svi parametri sa vrijednostima određenog algoritma neuronske mreže (npr. *NNBMA*). Neki od parametara su npr.: naziv ulazne datoteke za učenje mreže, broj slojeva, broj neurona, tip prijenosnih funkcija, koeficijent brzine učenja, momentum, nazivi datoteka matrica težina, nazivi datoteka bias vektora;
- U slučaju optimizacije parametara neuronske mreže unutar ovog područja prikazani su parametri genetičkog algoritma, a najvažniji parametri su broj generacija i broj subpopulacija. Parametri neuronske mreže koji se optimiraju genetičkim algoritmima prikazani su na obrascu zatamnjeno, a to su: broj slojeva, broj neurona u pojedinom sloju i tip prijenosne funkcije u pojedinom sloju;
- Unutar ovog područja obrasci prikazani su sljedeći dijagrami: dijagram promjene pogreške (*SSE*) učenja za zadani broja epoha, promjena koeficijenta brzine učenja za zadani broj epoha učenja, a u slučaju asocijativnih algoritama prikazan je Hintonov dijagram;
- Unutar ovog područja prikazane su matrice težina i bias vektori;
- Unutar ovog područja prikazane su za skup učenja, željene (*T*) nasuprot procjenjenih (*A*) vrijednosti izlaznih varijabli kao i korelacije istih;
- Jednako kao područje (5), ali u ovom slučaju za skup za testiranje;
- U ovom području prikazani su indeksi uspješnosti (*R*, *SSE*, *MSE*, *RMSE*, *NRMSE*) zasebno za svaku od izlaznih varijabli skupa za učenje i testiranje.

4.2.2. Prikaz parametara i rezultata učenja mehanizma zaključivanja neizrazite logike

U cilju jednostavnijeg praćenja rezultata eksperimentalnog dijela rada, definiran je i obrazac za prikaz parametara i rezultata učenja mehanizma zaključivanja neizrazite logike kako je prikazano na slici 4.3. Obrazac je podijeljen na sljedećih deset različitih područja:



Slika 4.3 Primjer načina prikaza parametara i rezultata učenja mehanizma zaključivanja neizrazite logike

- (1) U ovom području prikazani su iznosi sljedećih operatora: AND, OR, implikacija, agregacija, defazifikacija;
- (2) U slučajevima primjene *Sugeno* ('neurofuzzy') algoritma neizrazite logike u ovom području prikazani su tzv. *ANFIS*-parametri;
- (3) U ovom području prikazani nazivi su lingvističkih varijabli sa pripadnim tipovima funkcija pripadnosti;
- (4) U ovom području prikazana je struktura *fuzzy* mehanizma zaključivanja;
- (5) U ovom području u grafičkom je obliku prikazan *fuzzy* mehanizam zaključivanja;
- (6) U ovom području prikazani su *fuzzy* skupovi pojedinih lingvističkih varijabli sa pripadnim tipovima i oblicima funkcija pripadnosti;
- (7) U ovom području prikazane su 3-D odzivne površine pojedinih lingvističkih varijabli;
- (8) U ovom području prikazane su procjene željene (*T*) i procjenjene (*A*) izlazne varijable skupa za učenje;
- (9) U ovom području prikazane su procjene željene (*T*) i procjenjene (*A*) izlazne varijable skupa za testiranje;
- (10) U ovom području prikazani su indeksi uspješnosti (*R*, *SSE*, *MSE*, *RMSE*, *NRMSE*) zasebno za svaku od izlaznih varijabli skupa za učenje i testiranje.

4.3. Pregled softverskih alata

Kao što je već spomenuto da je zamišljeni inteligentni sustav tzv. *hibridni ekspertni sustav* jer kombinira sljedeće *AI* metode: 1. **ekspertne sustave**, 2. **neuronske mreže**, 3. **neizrastu logiku** (*fuzzy logic*), 4. **neurofuzzy** i 5. **genetičke algoritme**. Pri izboru alata postavljani su sljedeći kriteriji:

- Svaki alat mora predstavljati zasebnu *AI* metodu
- Izabrani alati moraju biti otvoreni za spajanje sa drugim *AI* alatima (specifikacije: I/O, DDE, OLE, SQL, pokretanje vanjskih EXE modula)
- Svi alati moraju imati vlastiti prevodilac (engl. *compiler*) za prevođenje izvornog koda u C++ kod

Ovim kriterijima udovoljili su alati kako slijedi:

1. Alat za ekspertne sustave: **KnowledgePro[®] for Windows**, Ver. 3.0, američke firme *The Konowledge Garden Inc.*, <http://www.kgarden.com/>.
2. Alat za neuronske mreže: **Neural Network Toolbox** for use with Matlab[®], Ver. 4.0, američke firme *The Mathworks Inc.*, <http://www.mathworks.com/>.
3. Alat za *fuzzy logic* i *NeuroFuzzy*: **Fuzzy Logic Toolbox** for use with Matlab[®], Ver. 2.0, američke firme *The Mathworks Inc.*, <http://www.mathworks.com/>.
4. Alat za genetičke algoritme: **Genetic Search Toolbox** for use with Matlab[®], Ver. 1.01, američke firme *The Optimal Synthesis Inc.*, <http://www.optisyn.com/>. Ovaj alat je tzv. '*third party products*' odobren od strane *The Mathworks Inc.*

Za proizvodnju izvršnog koda (engl. *EXE-executable*) na temelju C++ koda primijenjen je Microsoft[®] C++ *linker* iz programskog paketa Visual Studio 6.0[®]. Treba napomenuti da su svi nabrojani alati licencirani. Dio licenci osiguran je od strane Sveučilišta u Zagrebu, a dio od strane Fakulteta strojarstva i brodogradnje Zagreb. U nastavku slijedi kratki pregled mogućnosti pojedinih alata.

1. KnowledgePro[®] for Windows

KnowledgePro je sustav za brzi razvoj složenih aplikacija, a posebice je pogodan za razvoj ekspertnih sustava. Sustav se sastoji od sljedećih cjelina:

- vrlo bogatog objektno-orijentiranog jezika (engl. *OOP*) za procesiranje lista
- vizualnih alata za dizajniranje formi
- biblioteka funkcija za povezivanje sa vanjskim sustavima (npr. vanjske baza *SQL* baze podataka)
- biblioteka funkcija (engl. *API functions*) za povezivanje sa operativnim sustavom
- alata za '*debugging*' ili ispravljanje grešaka
- *interpreter* modula
- *compiler*-a i *linker*-a

Pri ocjenjivanju složenosti sintakse nekog programskog jezika, uobičajeno je brojanje potrebnih komandi za ispis riječi '*Hello world*' na zaslon monitora. U *KnowledgePro*-u sintaksa za ispis tih riječi je sljedeća:

```
window().
text('Hello world').
```

Kao što se vidi, broj komandi (poziva funkcija) je minimalan. U prvom redu je komanda za otvaranje prozora, a u drugom komanda za ispis teksta. Cijeli sustav interno se temelji na pozivima raznih funkcija (sličnih gornjoj funkciji *text*) sa određenim parametrima, a eksterno na pozivima tzv. *topic* procedura sa ili bez parametara.

2. *Neural Network Toolbox*

Inspirirana biološkim živčanim sustavom, metodologija neuronskih mreža primjenjuje se za rješavanje složenih problema u područjima znanosti, inženjerstva, financija itd. *Neural Network Toolbox*[®] potpuno je integriran je u računalnu okolinu paketa *Matlab*[®]. S obzirom na način učenja, dvije su skupine mreža podržane u *toolbox*-u:

1. Mreže u kojima je učenje nadzirano od strane učitelja (engl. *supervised networks*):
 - Unaprijedne statičke mreže (engl. *feed-forward networks*)
 - Mreže sa radijalnim baznim funkcijama (engl. *radial basis networks*)
 - Rekurentne mreže (engl. *recurrent networks*)
 - *Learning vector quantization* mreže (LVQ) (engl. *learning vector quantization*)
2. Mreže u kojima učenje nije nadzirano od strane učitelja (engl. *unsupervised networks*):
 - Asocijativne mreže (engl. *associative networks*)
 - *Competitive layers* mreže (engl. *competitive layers*)
 - *Self-organizing maps* mreže (engl. *self-organizing maps*)

Od metoda predprocesiranja i postprocesiranja u *toolbox* su uključene:

- *Principal component analysis* – smanjuje dimenzije ulaznih vektora
- *Post-training analysis* - provodi regresijsku analizu željenih vektora i procijenjenih izlaznih vektora
- Skaliranje ulazno-izlaznih vektora – skaliranje se provodi na način da ulazno-izlazni skupovi padaju u u interval [-1,1].
- Skaliranje srednje vrijednosti i standardnog odstupanja skupa za učenje

Od metoda za poboljšanje generalizacije u cilju sprečavanja *underfitting*-a i *overfitting*-a u *toolbox* su uključene:

- *Regularization* – metoda modificira funkciju uspješnosti (engl. *performance function*) kao mjeru greške u koja se u procesu učenja nastoji minimizirati
- *Early stopping* – metoda upotrebljava dva različita skupa podataka: prvi skup je za učenje, na temelju kojeg se mijenjaju matrica težina i bias vektor, a drugi skup je tzv. validacijski skup koji služi za zaustavljanje procesa učenja ako dođe do *overfitting*-a ili *underfitting*-a podataka

U teorijskom dijelu (točka 2.7.6.) nabrojani su tipovi mreža sa parametrima algoritama koje su primjenjivane u eksperimentalnom dijelu rada.

3. *Fuzzy Logic-NeuroFuzzy Toolbox*

Primjena neizrazite logike dolazi do izražaja u onim situacijama kada nije poznat eksplicitni matematički model ponašanja određenog sustava, te se opis ponašanja takvih sustava temelji na iskustvenim spoznajama. Iskustvene se pak spoznaje mogu opisati pomoću pravila (engl. *rules*), što nam na jednostavan način omogućava *Fuzzy Logic Toolbox*[®] koji je također dio matematičke okoline paketa *Matlab*[®]. Toolbox se sastoji od nekolicine međusobno povezanih modula:

- Editor *fuzzy* mehanizam zaključivanja (engl. *FIS - fuzzy inference system*) – prikazuje sve relevantne informacije o *fuzzy* zaključivanju kao što su: *fuzzy* dijagrami, broj ulaznih i izlaznih varijabli, metode defazifikacije, itd.
- Editor funkcija pripadnosti – omogućava prikaz i promjenu svih funkcija pripadnosti pridruženih ulazno-izlaznim varijablama mehanizma zaključivanja.
- Editor pravila – omogućava prikaz i promjenu pravila i to u jednom od tri formata: tzv. *full English-like syntax*, *concise symbolic notation*, i *indexed notation*.
- Preglednik pravila – omogućava detaljni uvid u ponašanje *fuzzy* mehanizma zaključivanja zadavanjem kvantitativnih vrijednosti ulaznim varijablama.
- Preglednik površina – omogućava trodimenzionalni prikaz odzivne površine u zavisnosti od bilo koje dvije ulazne varijable.

Pored upravo opisanog tzv. *Mamdani fuzzy* modela, toolbox sadrži i tzv. *Sugeno fuzzy* model. *Sugeno* model je zapravo adaptivno *neurofuzzy* model (engl. *ANFIS - adaptive neuro-fuzzy inference system*), koji primjenjuje metodologiju neuronskih mreža u cilju optimalnog izbora tipa i oblika funkcija pripadnosti. Karakteristika ovog modela je učenje iz podataka na temelju kojih se neizraziti sustav modelira. Treba također napomenuti da *toolbox* podržava napredne tehnike modeliranja kao što je *fuzzy clustering*, čija je primjena kod problema klasifikacije i prepoznavanja uzoraka.

4. Genetic Search Toolbox

Srcce *genetic search toolbox* – a čini stroj sastavljen od *C-MEX* funkcija koji uz pomoć *Matlab*[®]-ove računalne okoline pokreće ugrađene procedure za optimizaciju. Unutar ovog *toolbox*-a integrirane su dvije trenutno poznate *genetic* metodologije:

- genetičko programiranje, i
- genetički algoritmi

U *toolbox* je ugrađeno preko 40 funkcija za optimizaciju, te je moguća manipulacija sa sljedećim tipovima podataka: stringovima, numeričkim podacima i algebarskim izrazima. U radu je korištena metodologija genetičkih algoritama i to za optimizaciju parametara neuronske mreže (npr. oblika prijenosne funkcije, broja slojeva, koeficijenta brzine učenja, itd.).

4.3.1. Problemi implementacije i međusobne komunikacije softverskih alata

U uvodnom dijelu vidljivo je, da je postavljen relativno mali broj ali vrlo oštih kriterija izbora na sve *AI* alate, a posebice se to odnosi na kriterij prevodenja u *C++* kod, te nakon toga u *izvršni kod*. Kao što je već spomenuto, jedan od postavljenih zadataka u radu bio je integrirati *AI* metode u hibridni *AI* sustav. Naime, glavni problem je u povezivanju različitih alata u zajednički sustav koji bi razmjenjivao potrebne informacije. Svi nabrojani alati rade u tzv. interpreterskom načinu rada (npr. *KnowledgePro*) ili u određenoj razvojnoj okolini (npr. *Matlab toolbox*) i nije ih moguće izravno povezati. Danas se kao standard za povezivanje, smatra sposobnost interpretera ili razvojne okoline proizvodnja odgovarajućih modula sa *C++* kodom. *C++* module moguće je tada povezati u zajednički izvršni tzv. *EXE* modul. Iako *Matlab*[®] ima vlastiti prevodilac (engl. *compiler*) pomoću njega nije moguće prevesti u *C++* niti jedan algoritam neuronskih mreža, iako se oni nalaze unutar tzv. *matlab m* datoteka. Razlog leži u činjenici da je u novijim verzijama (od ver. 4.0) *toolbox*-a pri svakoj definiciji modela mreže potrebno pozvati funkciju koja će kreirati tip mreže te na kraju vratiti tzv. interni *net* objekt, kojeg prevodilac nije u stanju prevesti u *C++* kod. Primjer jednog takvog poziva funkcije (**newff()**) za kreiranje dvoslojne unaprijedne statičke mreže sa normaliziranim ulaznim vektorom *pn_tre*, te *Levenberg-Marquardt* algoritmom učenja dan je u narednom retku.

```
pn_tre=[0 1 0; -1 1 1];
net = newff(minmax(pn_tre),[10,1],{'tansig','purelin'},'trainlm');
```

Originalni sadržaj spornog **net** objekta je sljedeći:

architecture:	subobject structures:	functions:
numInputs: 1	inputs: {1x1 cell} of inputs	adaptFcn: 'trains'
numLayers: 2	layers: {2x1 cell} of layers	initFcn: 'initlay'
biasConnect: [1; 1]	outputs: {1x2 cell} containing 1 output	performFcn: 'mse'
inputConnect: [1; 0]	targets: {1x2 cell} containing 1 target	trainFcn: 'trainlm'
layerConnect: [0 0; 1 0]	biases: {2x1 cell} containing 2 biases	parameters:
outputConnect: [0 1]	inputWeights: {2x1 cell} containing 1 input weight	adaptParam: .passes
targetConnect: [0 1]	layerWeights: {2x2 cell} containing 1 layer weight	initParam: (none)
numOutputs: 1 (read-only)		performParam: (none)
numTargets: 1 (read-only)		trainParam: .epochs, .goal, .max_fail, .mem_reduc,
numInputDelays: 0 (read-only)		.min_grad, .mu, .mu_dec, .mu_inc,
numLayerDelays: 0 (read-only)		.mu_max, .show, time
		weight and bias values:
		IW: {2x1 cell} containing 1 input weight matrix
		LW: {2x2 cell} containing 1 layer weight matrix
		b: {2x1 cell} containing 2 bias vectors

Kasniji pozivi funkcija kao što su npr. simulacija mreže ili poboljšanje generalizacije, trebaju upravo **net** objekt u koji su upisane sve karakteristike izabranog tipa mreže. Naravno da nedostupnost tih podataka u izvršnom modulu izaziva pojavu sistemске greške. Ovaj problem riješen je na način da su iznova napisani

(prekodirani) svi *NN* algoritmi učenja s kojima se eksperimentiralo u radu, čime je izbjegnuta *nef* objekt. Nakon toga bilo je moguće prevesti i povezati sve module (algoritme) neuronskih mreža u izvršni modul, a ujedno i u hibridni inteligentni sustav.

Sa implementacijom *fuzzy* mehanizma zaključivanja praktički nije bilo problema jer uz *fuzzy toolbox* dolazi izvorni *C* kod (*fismain.c*) modula koji je, nakon što se prevede i poveže u izvršni (*fismain.exe*) oblik, u stanju pokrenuti već izmodelirani *fuzzy* mehanizam zaključivanja *Mamdami* ili *Sugeno* tipa. Sintaksa za pokretanje već izmodeliranog *FIS*-a npr. *Mamdami* tipa je sljedeća:

```
fismain ulaz.dat mamdami.fis → izlaz.dat
```

Gdje je: *ulaz.dat* – tekstualna datoteka sa ulaznim podacima
 mamdami.fis – izmodelirani *fuzzy* mehanizam zaključivanja *Mamdami* tipa
 → - oznaka redirekcije rezultata u tekstualnu datoteku
 izlaz.dat – tekstualna datoteka u koji se spremaju rezultati *FIS*-a

KnowledgePro alat za izgradnju ekspertnih sustava u verziji *KPWIN++ 1.5a* ima mogućnost prevođenja *KPWIN* izvornog koda u izvršni kod uz pomoć Microsoft® *C++ Ver. 1.5* prevodioca i *linkera*. *KPWIN++ 1.5a* dozvoljava čak i ubacivanje *C++* koda u izvorni *KPWIN++* kod te prevođenje i povezivanje takvog hibridnog koda. Sintaksa za poziv vanjskog izvršnog programa (npr. gornji *mamdami.fis*) je sljedeća:

```
run('fismain ulaz.dat mamdami.fis → izlaz.dat').
```

Metodologija genetičkih algoritama nije izravno uključena u inteligentni hibridni sustav kroz izvršne module, već je primjenjena zbog optimizacije parametara neuronske mreže u procesu učenja, zbog čega nije bilo potrebe za stvaranjem posebnih izvršnih modula. Sve simulacije optimizacije izvedene su unutar razvojne okoline *Genetic Search Toolbox*-a. U tu je svrhu nekolicina naprednih modela mreža modificirana i prilagođena za komunikaciju sa genetičkim algoritimima.

4.4. Definicije ulazno-izlaznih skupova *backpropagation* neuronskih mreža

4.4.1. Procjena elemenata sustava

Ulazno-izlazni skup za asocijativnu procjenu elemenata sustava trošenja prikazan je na slici 4.4. Kao što se vidi, izlazni skup jednak je ulaznom. Izlaz iz asocijativne mreže je zapravo ulaz u *perceptronsku* ili *backpropagation* mrežu koje u ovom slučaju služe za ‘pogađanje’ tipa, odnosno mehanizma trošenja. Kvaliteta pogotka neće više ovisiti o idealnoj istreniranosti određenog tipa asocijativne neuronske mreže, već o stabilnosti mreže koja u unatoč činjenici, da ulazni vektor sadrži određeni iznos šuma (npr. pogrešni odgovori na pitanja), daje izlazni vektor jednak željenom. Prema slici 4.4 željeni izlazni vektor je $[1 \ 1 \ 1 \ -1 \ -1 \ 1 \ 1 \ -1 \ -1 \ -1]$, a ulazni vektor koji npr. sadrži 30% šuma u odnosu na originalni željeni izlazni vektor je $[-1 \ -1 \ -1 \ -1 \ -1 \ 1 \ 1 \ -1 \ -1 \ -1]$. Moguće je pomoću genetičkih algoritama naći takve iznose matrica težina i bias vektora asocijativnih algoritama, koji za 0% šuma daju izlazni vektor jednak ulaznom vektoru. Pri tome treba voditi računa o stabilnosti odabranog asocijativnog modela. Ukoliko stabilnost ne zadovoljava treba eksperimentirati sa različitim parametrima učenja.

Slučajevi trošenja	ULAZNO - IZLAZNI SKUP										
	Elementi sustava					Relativno gibanje					
	f1	f2	č	p	t	F	v	ω	o	α	
1	2	3	4	5	6	7	8	9	10	11	12
8		1	1	1	-1	-1	1	1	-1	-1	-1

Slika 4.4. Primjer mapiranja ulazno-izlaznog skupa za asocijativnu procjenu elemenata sustava (izvod iz tablice P1.3 u prilogu I)

Prema slici 4.4. navedene oznake predstavljaju: f1-funkcionalni dio 1, f2-funkcionalni dio 2, č-čestice, p-plin, t-tekućina, F-djelovanje sile, v-brzina, ω -kutna brzina, o-titraji (oscilacije), α -kut upada čestica.

Slika 4.5. prikazuje vrijednosti ulazno-izlazne matrice za učenje asocijacija za procjenu elemenata sustava. Isti izlazni skup upotrijebljen je za nadzirano (pomoću učitelja) i nenadzirano učenje (bez učitelja).

ULAZNI SKUP										=	IZLAZNI SKUP									
1	1	-1	-1	1	1	-1	1	-1	-1	1	1	-1	-1	1	1	-1	1	-1	-1	
1	1	-1	-1	-1	1	1	-1	-1	-1	1	1	-1	-1	-1	1	1	-1	-1	-1	
1	1	-1	-1	-1	1	-1	1	-1	-1	1	1	-1	-1	-1	1	-1	1	-1	-1	
1	1	-1	-1	-1	1	-1	1	1	-1	1	1	-1	-1	-1	1	-1	1	1	-1	
1	1	-1	-1	-1	1	-1	-1	-1	-1	1	1	-1	-1	-1	1	-1	-1	-1	-1	
1	-1	1	-1	-1	1	-1	-1	-1	-1	1	-1	1	-1	-1	1	-1	-1	-1	-1	
1	-1	1	-1	-1	1	1	-1	-1	-1	1	-1	1	-1	-1	1	1	-1	-1	-1	
1	1	1	-1	-1	1	1	1	-1	-1	1	1	1	-1	-1	1	1	-1	-1	-1	
1	1	1	-1	-1	1	-1	-1	-1	-1	1	1	1	-1	-1	1	-1	-1	-1	-1	
1	-1	1	-1	1	-1	1	-1	-1	1	1	-1	1	-1	1	-1	1	-1	-1	1	
1	-1	1	-1	1	-1	1	-1	-1	-1	1	-1	1	-1	1	-1	1	-1	-1	-1	
1	-1	1	1	-1	-1	1	-1	-1	1	1	-1	1	-1	-1	1	-1	-1	-1	1	
1	-1	-1	-1	1	-1	1	-1	-1	-1	1	-1	-1	-1	1	-1	1	-1	-1	-1	
1	-1	-1	1	-1	-1	1	-1	-1	1	1	-1	-1	-1	1	-1	-1	-1	-1	1	
1	-1	-1	-1	1	-1	1	-1	-1	1	1	-1	-1	-1	1	-1	1	-1	-1	1	
1	-1	-1	1	-1	-1	1	-1	-1	-1	1	-1	-1	-1	1	-1	-1	-1	-1	-1	

Slika 4.5. Ulazno-izlazne matrice za asocijativnu procjenu elemenata sustava

Parametri učenja (l_r, m_u) za *HEBBUN*, *HEBBSU* i *INSSU* asocijativne mreže, dobiveni su pomoću *GA*-algoritama uz minimizaciju *SSE* kao funkcije cilja te imaju zadovoljavajuću stabilnost. Većina parametara za *GA*-algoritme odabrana je prema preporukama iz *Genetic Search Toolbox-a*[®].

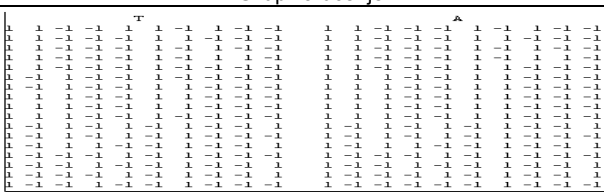
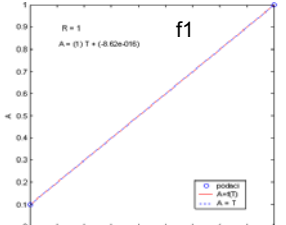
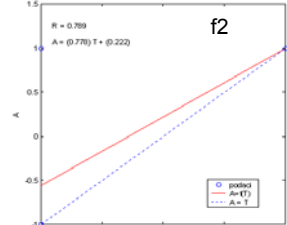
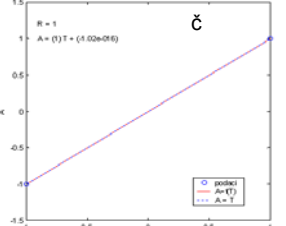
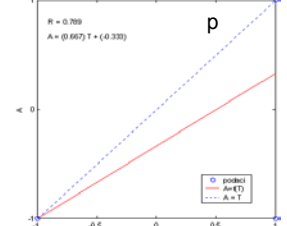
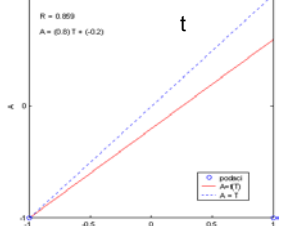
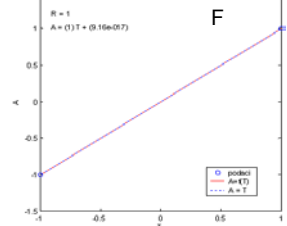
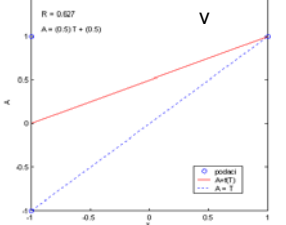
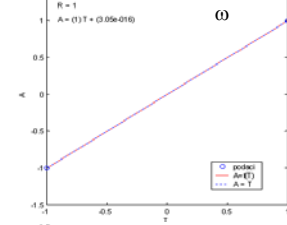
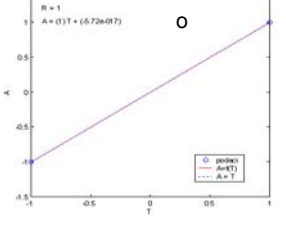
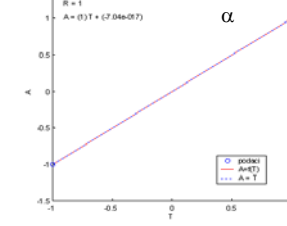
Tablica 4.1. Parametri i rezultati učenja *HEBBUN* mreže za procjenu elemenata sustava

Naziv mreže: NNRPE			Algoritam: HEBBUN		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'pe_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	10	2.	alg_selekcije	0
3.	izlaz_dat	'pe_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	10	4.	alg_rekombinacije	14
5.	br_layera	1			
6.	br_neuro_lay1	10			
7.	br_neuro_lay2				
8.	fun_lay1				'hardlims'
9.	fun_lay2				
10.	fun_lay3				
11.	disp_freq	25	5.	broj_generacija	100
12.	max_epoch	100000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	20
14.	min_grad	1e-10			
15.	lr				0.0001
16.	mu				0
17.	mu_inc				
18.	mu_dec				
19.	mu_max				
20.	ulaz_dat		8.	broj_subpopulacija	6
21.	W1_dat	'PEW1.txt'	9.	generatio_gap	0.8
22.	W2_dat		10.	selectio_press	1
23.	W3_dat		11.	strukt_selekt	0
24.	B1_dat	'PEB1.txt'	12.	migration_rate	0.25
25.	B2_dat		13.	migration_strukt	0
26.	norm_ulaz	0	14.	inicijalizacija	0
27.	norm_izlaz	0			
28.	chek_early_stopping	0			
29.	chek_val_data	0			
30.	chek_test_data	0			

Hintonov dijagram										
1	1	2	3	4	5	6	7	8	9	10
2	1	2	3	4	5	6	7	8	9	10
3	1	2	3	4	5	6	7	8	9	10
4	1	2	3	4	5	6	7	8	9	10
5	1	2	3	4	5	6	7	8	9	10
6	1	2	3	4	5	6	7	8	9	10
7	1	2	3	4	5	6	7	8	9	10
8	1	2	3	4	5	6	7	8	9	10
9	1	2	3	4	5	6	7	8	9	10
10	1	2	3	4	5	6	7	8	9	10

Matrice težina (<i>W</i>) i bias vektori (<i>B</i>)										
W1-----										B1-----
171.000000	-10.000000	-10.000000	-110.000000	-70.000000	30.000000	50.000000	-110.000000	-150.000000	-90.000000	-0.500000
28.127000	132.873000	8.127000	-88.127000	-88.127000	168.127000	-91.123800	31.873000	-8.127000	-108.127000	-0.500000
-10.000000	-30.000000	171.000000	-10.000000	-10.000000	10.000000	30.000000	-50.000000	-10.000000	10.000000	-0.500000
-129.750600	-30.249400	9.750600	151.249400	29.750600	-70.249400	-9.750600	69.750600	109.750600	129.750600	-0.500000
-89.916600	-69.916600	9.916600	29.916600	151.083400	-109.916600	29.916600	30.083400	69.916600	89.916600	-0.500000
30.000000	130.000000	10.000000	-90.000000	-90.000000	171.000000	-90.000000	30.000000	-10.000000	-110.000000	-0.500000
85.237200	-93.261600	58.254400	-25.237200	-25.237200	-54.762800	135.762800	-145.237200	-105.237200	-5.237200	-0.500000
-110.000000	70.000000	-50.000000	50.000000	50.000000	30.000000	-110.000000	171.000000	130.000000	30.000000	-0.500000
-150.000000	30.000000	-10.000000	90.000000	50.000000	-10.000000	-70.000000	130.000000	171.000000	70.000000	-0.500000
-90.000000	-70.000000	10.000000	110.000000	70.000000	-110.000000	30.000000	30.000000	70.000000	171.000000	-0.500000

Nastavak: Tablica 4.1. Parametri i rezultati učenja *HEBBUN* mreže za procjenu elemenata sustava

Naziv mreže: NNRPE		Procjena izlaza					Algoritam: HEBBUN				
Skup za učenje						Skup za testiranje					
											
											
											
											
											
											
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Funkcionalni dijelovi	R	SSE	MSE	RMSE	NRMSE		R	SSE	MSE	RMSE	NRMSE
f1	1.0000	0.0000	0.0000	0.0000	0.0000						
f2	0.7888	8.0000	0.4706	0.6860	0.6667						
č	1.0000	0.0000	0.0000	0.0000	0.0000						
p	0.7888	4.0000	0.2353	0.4851	0.6172						
t	0.8593	4.0000	0.2353	0.4851	0.6172						
F	1.0000	0.0000	0.0000	0.0000	0.0000						
v	0.6268	12.0000	0.7059	0.8402	0.8528						
ω	1.0000	0.0000	0.0000	0.0000	0.0000						
o	1.0000	0.0000	0.0000	0.0000	0.0000						
α	1.0000	0.0000	0.0000	0.0000	0.0000						

Tablica 42. Parametri i rezultati učenja *HEBBSU* mreže za procjenu elemenata sustava

Naziv mreže: NNRPE			Algoritam: HEBBSU		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'pe_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	10	2.	alg_selekcije	0
3.	izlaz_dat	'pe_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	10	4.	alg_rekombinacije	14
5.	br_layera	1			
6.	br_neuro_layer1	10			
7.	br_neuro_layer2				
8.	fun_layer1				'hardlims'
9.	fun_layer2				
10.	fun_layer3				
11.	disp_freq	25	5.	broj_generacija	100
12.	max_epoch	100000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	20
14.	min_grad	1e-10			
15.	lr				0.5
16.	mu				0.05
17.	mu_inc				
18.	mu_dec				
19.	mu_max				
20.	ulaz_dat		8.	broj_subpopulacija	6
21.	W1_dat	'PEW1.txt'	9.	generatio_gap	0.8
22.	W2_dat		10.	selectio_press	1
23.	W3_dat		11.	strukt_selekt	0
24.	B1_dat	'PEB1.txt'	12.	migration_rate	0.25
25.	B2_dat		13.	migration_strukt	0
26.	norm_ulaz	0	14.	inicijalizacija	0
27.	norm_izlaz	0			
28.	chek_early_stopping	0			
29.	chek_val_data	0			
30.	chek_test_data	0			

Hintonov dijagram

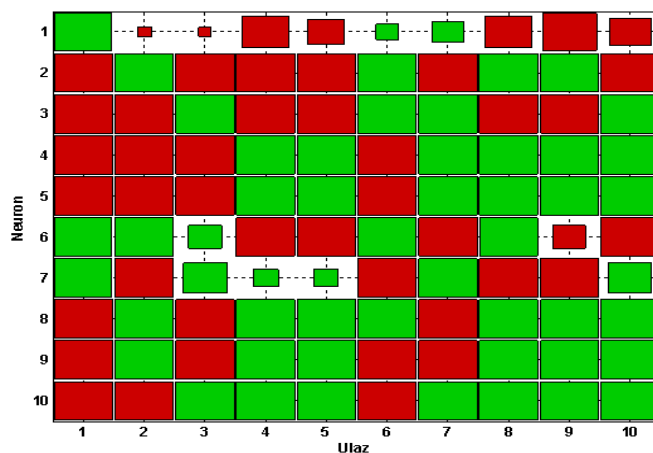
Matrice težina (W) i bias vektori (B)

W1-----	B1-----
2.700000	-0.100000
-0.100000	2.700000
-0.100000	-0.300000
-1.100000	2.700000
-0.816600	-0.616600
0.300000	1.300000
0.500000	-0.900000
-1.100000	0.700000
-1.500000	0.300000
-0.900000	-0.700000
0.300000	0.700000
0.500000	0.300000
-1.100000	2.700000
-1.500000	2.700000
-0.900000	2.700000

Tablica 4.3. Parametri i rezultati učenja *INSSU* mreže za procjenu elemenata sustava

Naziv mreže: NNRPE			Algoritam: INSSU		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'pe_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	10	2.	alg_selekcije	0
3.	izlaz_dat	'pe_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	10	4.	alg_rekombinacije	14
5.	br_layera	1			
6.	br_neuro_layer1	10			
7.	br_neuro_layer2				
8.	fun_layer1				'hardlims'
9.	fun_layer2				
10.	fun_layer3				
11.	disp_freq	25	5.	broj_generacija	100
12.	max_epoch	100000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	20
14.	min_grad	1e-10			
15.	lr				0.003
16.	mu				
17.	mu_inc				
18.	mu_dec				
19.	mu_max				
20.	ulaz_dat		8.	broj_subpopulacija	6
21.	W1_dat	'PEW1.txt'	9.	generatio_gap	0.8
22.	W2_dat		10.	selectio_press	1
23.	W3_dat		11.	strukt_selekt	0
24.	B1_dat	'PEB1.txt'	12.	migration_rate	0.25
25.	B2_dat		13.	migration_strukt	0
26.	norm_ulaz	0	14.	inicijalizacija	0
27.	norm_izlaz	0			
28.	chek_early_stopping	0			
29.	chek_val_data	0			
30.	chek_test_data	0			

Hintonov dijagram

Matrice težina (*W*) i bias vektora (*B*)

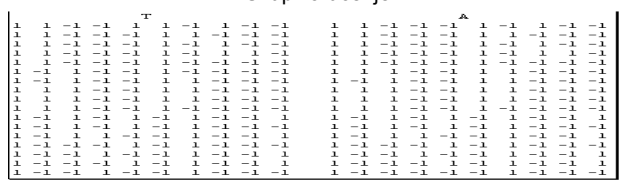
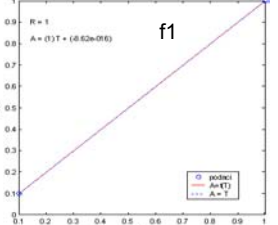
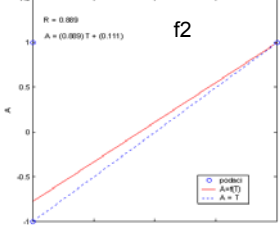
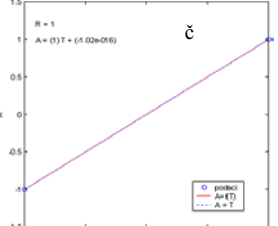
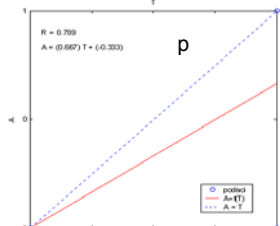
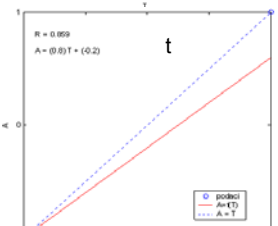
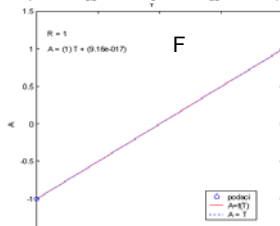
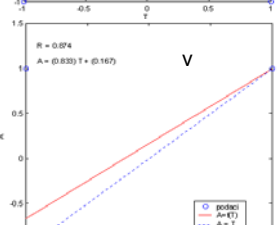
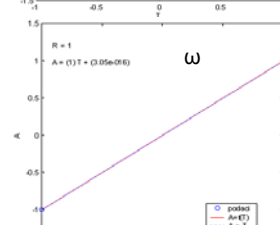
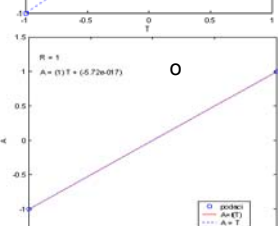
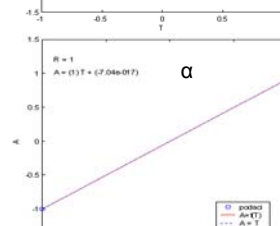
```

W1-----B1-----
      1.000000      -0.069427      -0.057488      -0.640673      -0.500000
-4973209677558.117200  87673907613714.766000 -15593545328700.145000 -25786127066318.023000 -0.500000
-4973209677557.934600 -15103719234473.332000  86628760758842.000000 -5156927477923.644500 -0.500000
      -5.2309e+142      -8.0320e+141      1.4868e+143      9.6586e+141      -0.500000
      -7.4110e+090      -5.2954e+090      -1.0260e+090      1.1020e+090      -0.500000
      1.000000      4.348340      0.348106      -3.004146      -0.500000
      1.000000      -1.782876  0.579978      0.195738      0.192168      -0.500000
      -9.6688e+142      6.1505e+142      -4.5121e+142      4.4379e+142      -0.500000

```

Napomena: Zbog velikih iznosa težina prikazan je samo dio matrice težina i bias vektora!

Nastavak: Tablica 4.3. Parametri i rezultati učenja INSSU mreže za procjenu elemenata sustava

Naziv mreže: NNRPE		Procjena izlaza					Algoritam: INSSU								
Skup za učenje						Skup za testiranje									
															
															
															
															
															
															
Indeksi uspješnosti															
Skup za učenje						Skup za testiranje									
Funkcionalni dijelovi	R	SSE	MSE	RMSE	NRMSE		R	SSE	MSE	RMSE	NRMSE				
f1	1.0000	0.0000	0.0000	0.0000	0.0000										
f2	0.8889	4.0000	0.2353	0.4851	0.4714										
č	1.0000	0.0000	0.0000	0.0000	0.0000										
p	0.7888	4.0000	0.2353	0.4851	0.6172										
t	0.8593	4.0000	0.2353	0.4851	0.5164										
F	1.0000	0.0000	0.0000	0.0000	0.0000										
v	0.8740	4.0000	0.2353	0.4851	0.4924										
ω	1.0000	0.0000	0.0000	0.0000	0.0000										
o	1.0000	0.0000	0.0000	0.0000	0.0000										
α	1.0000	0.0000	0.0000	0.0000	0.0000										

4.4.2. Procjena stabilnosti i izbor algoritama asocijativnih mreža

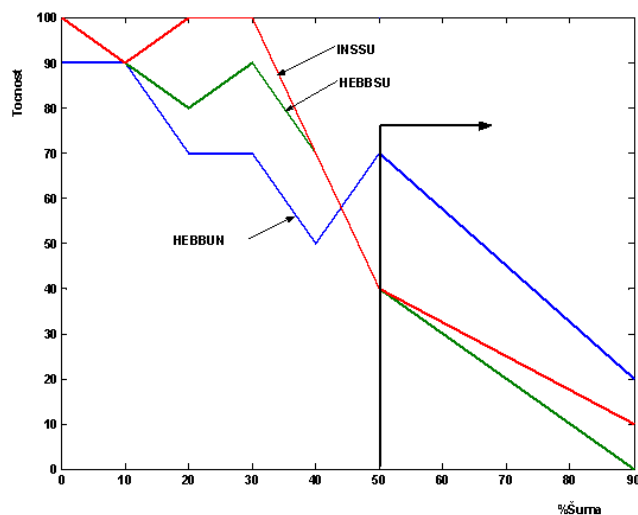
Stabilniji će biti onaj asocijativni algoritam koji nakon unošenja određenog iznosa šuma u originalni ulazno-izlazni vektor, 'oporavlja' taj isti vektor sa većom točnošću. Na slici 4.6 prikazan je način ispitivanja stabilnosti *HEBBUN* asocijativnog algoritam za slučaj trošenja tipa 1. Za unešene iznose šuma 0,10,20,30,40,50 i 90%, dobivene su točnosti oporavka 90,90,70,70,50,70 i 20%. Iznos šuma 0% odgovara originalnom ili željenom vektoru $T=[1 \ 1 \ -1 \ -1 \ 1 \ 1 \ -1 \ 1 \ -1 \ -1]$, vektoru procjene $A=[1 \ 1 \ -1 \ -1 \ -1 \ 1 \ -1 \ 1 \ -1 \ -1]$ te točnosti 90%. Pogrešna procjena za ovaj slučaj je u petom elementu vektora A . Točnost se izračunava prema sljedećem izrazu:

$$\text{točnost procjene} = 100 - \frac{\text{broj pogrešnih procjena}}{\text{broj točnih procjena}}, \% \quad (3.1)$$

Tip trošenja	Sum %	Zeljeni izlaz - T Novi ulaz - P	Elementi sustava										Točnost %	
		Procijenjeni izlaz - A	f1	f2	č	p	t	F	v	o	o	α		
HEBBUN														
1	0	T	1	1	-1	-1	1	1	-1	-1	-1	-1	-1	90
		A	1	1	-1	-1	-1	1	1	-1	-1	-1	-1	
	10	P	1	-1	-1	-1	1	1	1	-1	-1	-1	-1	90
		A	1	1	-1	-1	-1	1	1	-1	-1	-1	-1	
	20	P	1	1	-1	-1	-1	1	1	-1	-1	-1	-1	70
		A	1	1	-1	-1	-1	1	1	-1	-1	-1	-1	
	30	P	-1	-1	-1	-1	1	1	-1	1	1	-1	-1	70
		A	-1	1	-1	1	1	1	-1	1	1	-1	-1	
	40	P	1	-1	-1	1	-1	-1	-1	1	-1	-1	-1	50
		A	1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	
	50	P	-1	-1	-1	-1	1	1	-1	-1	-1	-1	1	70
		A	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	
90	P	-1	-1	1	1	-1	-1	-1	-1	-1	1	1	20	
	A	-1	-1	1	1	1	1	-1	1	1	1	1		

Slika 4.6. Primjer vektora procjena (A) s obzirom na unošeni vektor šuma (P) te % točnosti oporavka u odnosu na željeni vektor (T) (izvod iz tablice P1.4. u prilogu I)

U idealnim slučajevima za 0% šuma odgovara točnost od 100%. Vektori P predstavljaju vektore šuma. Elementi vektora P koji će se razlikovati od elemenata vektora T birani su generatorom slučajnih brojeva mijenjanjem predznaka. Iznos šuma u vektoru P od 40% znači da se on u odnosu na željeni vektor T razlikuje u 4 elementa (mjesto 2, 4, 5 i 6). Na slici 4.7 prikazan je dijagram pada točnosti asocijativnih algoritama u zavisnosti od iznosa šuma. Dijagram je konstruiran na temelju eksperimentalnih podataka iz tablice P1.4 u prilogu I. Generatorom slučajnih brojeva izabrana su tri tipa trošenja (1, 2 i 3) te je za pojedini tip trošenja provjerena točnost određenog asocijativnog algoritma za sljedeće iznose šumova: 0, 10, 20, 30, 40, 50 i 90 %. Treba napomenuti da u ovom koraku nije cilj uspoređivanje međusobne točnosti asocijativnih algoritama, već dobivanje kvalitativne slike o stabilnosti s obzirom na iznos unešenog šuma, tj. približno određivanje maksimalnog iznosa šuma koji daje najvišu točnost. Maksimalni iznos šuma koji je moguće unijeti u sustav, a da se dobije zadovoljavajuća točnost procjenjenog vektora u odnosu na željeni vektor, zavisi od prirode problema kojeg opisuje ulazno-izlazne matrice. Npr. prema [9], za matrice ($6 \times 5 = 30$ elemenata) koje opisuju brojeve 0, 1 i 2 moguće je za unešeni 50-67% šum dobiti 100% oporavak ili točnost sa *HEBBUN* algoritmom. Za problem koji se ovdje razmatra, eksperimentom je potvrđeno da je za dane slučajno izabrane ulazne vektore (tipove trošenja) moguće dobiti 100% točnost pri maksimalnom iznosu šuma od 30% (slika 4.7, *INSSU* algoritam). Prema slici 4.7, 50-70% točnost dobiva se pri 40% šumu. Kao što se vidi, točnost značajno opada kod iznosa šumova većih od 50%. Može se zaključiti, da će se za razmatrani problem točnosti asocijativnih algoritama kretati u intervalu od 0% do 50% šuma, a praktički prihvatljiva točnost u intervalu od 0% do 30% šuma. U tablicama P1.5, P1.6 i P1.7 u prilogu I, prikazani su rezultati procjena točnosti za 0% i 50% iznos šuma za 13 slučajno odabranih ulaznih vektora, a u tablici 4.4 dana je usporedba procjena točnosti asocijativnih algoritama s obzirom na 0% i 50% šum.



Slika 4.7. Prikaz pada točnosti asocijativnih algoritama u zavisnosti od iznosa šuma

Tablica 4.4. Usporedba asocijativnih algoritama s obzirom na 0% i 50% šum za slučajno odabrane tipove trošenja

Red. broj	Tip Troš.	Šum	Točnost HEBBUN algoritma %	Točnost HEBBSU algoritma %	Točnost INSSU algoritma %
1	5	0%	90	90	100
		50%	50	60	50
2	17	0%	90	100	90
		50%	40	50	30
3	2	0%	100	100	100
		50%	60	50	60
4	1	0%	90	90	90
		50%	50	50	50
5	6	0%	80	100	80
		50%	40	50	50
6	16	0%	100	100	100
		50%	70	70	70
7	8	0%	100	100	100
		50%	80	50	60
8	2	0%	100	100	100
		50%	50	40	50
9	6	0%	80	100	80
		50%	80	70	80
10	13	0%	100	100	100
		50%	70	70	70
11	16	0%	100	100	100
		50%	50	60	50
12	8	0%	100	100	100
		50%	10	50	30
13	7	0%	90	90	100
		50%	30	40	30

S obzirom na velik broj kombinacija šumova i ulaznih vektora, te relativne sličnosti rezultata različitih modela algoritama asocijativnih mreža, postavljene su dvije statističke hipoteze na temelju kojih se izabire najtočniji odnosno najstabilniji asocijativni algoritam.

1. Za 0% šuma postoji granična, tj. maksimalna točnost koju postižu sva tri asocijativna algoritma uz veću ili manju vjerojatnost
2. Za 50% šuma postoji granična, tj. maksimalna točnost koju postižu sva tri asocijativna algoritma uz veću ili manju vjerojatnost

Postavljene hipoteze obrađene su *t-testom* čiji su rezultati prikazani u tablici 4.5. Za testiranje je primjenjen standardni $\alpha=0.05$. Za ispitivanje pokoravanja skupa podataka zakonu normalne razdiobe primjenjen je *Jarque-Bera* test [43]. Kao što se vidi, svih šest skupova podataka pokoravaju se zakonu normalne razdiobe te su prikladni za testiranje *t-testom*. Za iznos 0% šuma odgovara maksimalna točnost $\mu_o=99\%$, (kol 6) koju postižu sva tri algoritma, te je time udovoljeno prvoj hipotezi H_o (kol 8). Međutim najveću vjerojatnost $p=0.8046$ (kolona 12) postizanja prve hipoteze ima *HEBBSU* asocijativni algoritam. Za 50% šum postiže se maksimalna točnost $\mu_o=60\%$ čime je udovoljeno drugoj hipotezi, a najveću vjerojatnost ($p=0.1921$) postizanja te točnosti ima *HEBBUN* asocijativni algoritam. Maksimalni iznosi procjena točnosti $\mu_o=99\%$ i $\mu_o=60\%$ dobiveni su iterati-vnom metodom *pokušaja-pogreške* tako da se udovolji postavljena hipoteza H_o .

Tablica 4.5. Rezultati *t-testa* za izbor asocijativnog algoritma

0% Šuma											
X	Algoritam	Jarque-Bera H_o	\bar{X} %	σ_X %	t-test						
					μ_o %	α	H_o	k	t_o	C_i	p
1	2	3	4	5	6	7	8	9	10	11	12
[90 90 100 90 80 100 100 100 80 100 100 90]	HEBBUN	Da	93.8	7.67	99	0.05	Da	12	-1.95	89.2055 98.4868	0.0749
[90 100 100 90 100 100 100 100 100 100 100 90]	HEBBSU		97.7	4.38					-0.25	95.0423 100.3423	0.8046
[100 90 100 90 80 100 100 100 80 100 100 100]	INSSU		95.3	7.76					-1.21	90.6938 100.0754	0.2478
50% Šuma											
[50 40 60 50 40 70 80 50 80 70 50 10 30]	HEBBUN	Da	52.3	20.0	60	0.05	Da	12	-1.38	40.1831 64.4322	0.1921
[60 50 50 50 50 70 50 40 70 70 60 50 40]	HEBBSU		54.6	10.5					-1.84	48.2701 60.9607	0.0892
[50 30 60 50 50 70 60 50 80 70 50 30 30]	INSSU		52.3	15.8					-1.74	42.7041 61.9113	0.1065

Zbog najviše *p-vrijednosti* pri $\mu_o=99\%$ odabire se *HEBBSU* asocijativni algoritam za procjenu elemenata sustava. Prema rezultatima iz tablice 4.5, iako *HEBBSU* asocijativni algoritam nije najstabilniji ($p=0.0892$), ipak se prednost daje postizanju veće točnosti. Razlog za to je pretpostavka da će se u realnim uvjetima primjene vjerojatnije u sustav unositi šumovi manji od 50%, a najčešće sa 0% šuma. S obzirom da izlazni vektor asocijativne mreže ujedno i ulazni vektor u neki drugi model mreže, potrebna je što veća točnost istog, kako bi se iz drugog modela mreže dobio što točniji izlazni vektor. Naime, nije realno očekivati veliku točnost izlaznog vektora drugog modela mreže uz 60% točnost ulaznog vektora.

Tablica 4.6. Parametri i rezultati učenja *NNP* mreže za procjenu tipa trošenja

Naziv mreže: NNRTT				Algoritam: NNP			
Red.broj	NN - parametri			Red.broj	GA - parametri		
1.	ulaz_dat		'tt_ul.txt'	1.	ispis_grafike		
2.	br_kol_ulaz		10	2.	alg_selekcije		
3.	izlaz_dat		'tt_iz.txt'	3.	alg_mutacije		
4.	br_kol_izlaz		15	4.	alg_rekombinacije		
5.	br_layera		1				
6.	br_neuro_lay1		15				
7.	br_neuro_lay2						
8.	fun_lay1		'hardlim'				
9.	fun_lay2						
10.	fun_lay3						
11.	disp_freq		25	5.	broj_generacija		
12.	max_epoch		5000	6.	real_var_iznos		
13.	err_goal		1e-15	7.	broj_individua		
14.	lr						
15.	lr_inc						
16.	lr_dec						
17.	err_ratio						
18.	momentum						
19.	W1_dat		'TTW1.txt'	8.	broj_subpopulacija		
20.	W2_dat			9.	generatio_gap		
21.	W3_dat			10.	selectio_press		
22.	B1_dat		'TTB1.txt'	11.	strukt_selekt		
23.	B2_dat			12.	migration_rate		
24.	B3_dat			13.	migration_strukt		
25.	norm_ulaz		0				
26.	norm_izlaz		0	14.	inicijalizacija		
27.	chek_early_stopping		0				
28.	chek_val_data		0				
29.	chek_test_data		0				

Dijagram: SSE-broj epoha

Matrice težina (W) i bias vektori (B)

W1-----										B1-----	
-9.101974	3.975428	-4.262669	8.055292	11.485226	-0.666057	-6.418814	12.605701	5.268541	5.453999	-8.095022	
-6.155498	6.174002	-5.166938	1.284130	0.662084	3.262081	2.774962	-0.402494	2.222716	-0.215241	-7.301787	
-3.606092	0.583497	-3.338216	3.544720	-1.045078	0.264241	-3.590432	4.719676	-1.033865	2.019848	-3.644350	
-7.426415	5.711914	1.715700	2.425908	-1.640890	5.224051	-5.307753	5.346364	10.154261	-0.094163	-8.953835	
-4.470160	0.417272	-4.108312	0.956989	0.553545	0.582697	-5.827379	-5.469420	1.275469	0.743328	-3.366769	
-4.379693	-2.743459	4.141382	0.318742	-0.126130	1.183776	-2.906228	-1.162972	1.786875	1.549960	-3.601816	
-6.277398	-5.544120	6.352794	1.630677	-2.473821	6.675406	3.687783	0.980382	5.590288	-0.207090	-6.019812	
-7.441037	11.785155	14.149959	2.459337	-0.496084	2.695518	4.173631	-3.383052	3.762476	1.275106	-8.035637	
-6.740441	-3.473741	2.428434	4.864596	10.014820	-7.101803	0.024060	5.395314	5.785719	7.762916	-5.822047	
-9.746417	-5.049770	7.783566	3.950222	10.404617	-6.593437	-0.043172	3.210479	8.175516	-6.151861	-9.139980	
-8.138810	-2.120687	4.657105	13.207072	-0.972079	-5.694272	-1.507105	7.056380	7.400780	12.095820	-8.718405	
-5.163924	-2.339441	-4.342876	1.367693	7.375923	-3.541623	3.330044	2.162891	4.926200	-1.468882	-6.711765	
-10.044001	-5.397597	-2.704293	12.903137	5.165093	-8.219034	0.136512	5.640726	8.465077	14.101032	-10.561724	
-7.421472	-1.674019	-5.620564	0.289508	7.646494	-3.334398	2.590931	1.499128	4.435930	8.703765	-6.441939	
-3.476079	-0.905274	-2.289651	8.626676	-0.491140	-3.523740	1.331516	1.245841	2.681425	-5.831306	-4.634228	

4.4.4. Procjena mehanizma trošenja

Prema slici 4.4 shema mapiranja ulaznog skupa varijabli za određivanje mehanizma trošenja jednaka je shemi za određivanje tipa trošenja. Razlika je u mapiranju izlaznog skupa varijabli. Izlazni skup varijabli mapiran je prema iskustvenim procjenama iz tablice P1.1 odnosno, kvantitativnim vrijednostima iz tablice P1.3 u prilogu I. Utjecajnost ili dominantnost pojedinog mehanizma trošenja ocjenjuje se ocjenana od 1 do 3. Ocjena 1 označava najveći utjecaj, a ocjena 3 najmanji utjecaj pojedinog mehanizma na trošenje. Na slici 4.11 dan je primjer mapiranja ulazno-izlaznog skupa za određivanje najutjecajnijeg mehanizma trošenja za *abrazijsko trotijelni* tip trošenja. U danom primjeru podjednako su utjecajna i abrazija (*AB*) i umor površine (*UP*).

Slučajevi trošenja	ULAZNI SKUP										IZLAZNI SKUP					
	Elementi sustava					Relativno gibanje					Tip Troše.	Mehanizam trošenja				
	f1	f2	č	p	t	F	v	ω	o	α		AD	AB	UP	TK	
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
8		1	1	1	-1	-1	1	1	-1	-1	-1	00000001 0000000	3	1	1	2

Slika 4.11. Primjer mapiranja ulazno-izlaznog skupa za procjenu mehanizma trošenja (izvod iz tablice P1.3 u prilogu I)

Slika 4.12 prikazuje vrijednosti ulazno-izlazne matrice za procjenu mehanizma trošenja za trening ili učenje mreže.

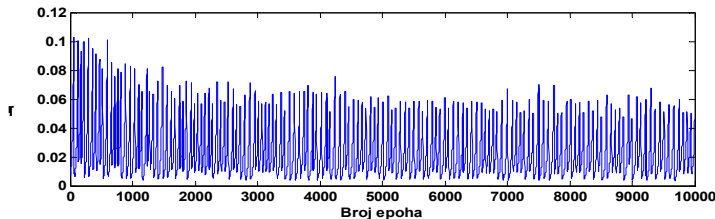
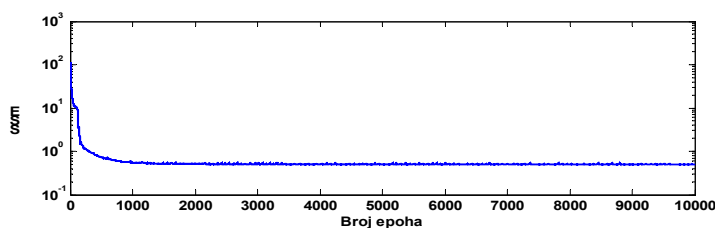
	ULAZNI SKUP										IZLAZNI SKUP			
1	1	-1	-1	1	1	-1	1	-1	-1	3	3	1	2	
1	1	-1	-1	-1	1	1	-1	-1	-1	1	2	2	1	
1	1	-1	-1	-1	1	-1	1	-1	-1	2	2	1	2	
1	1	-1	-1	-1	1	-1	1	1	-1	1	1	1	1	
1	1	-1	-1	-1	1	-1	-1	-1	-1	2	2	1	2	
1	-1	1	-1	-1	1	-1	-1	-1	-1	3	1	1	2	
1	-1	1	-1	-1	1	1	-1	-1	-1	3	1	3	2	
1	1	1	-1	-1	1	1	-1	-1	-1	3	1	1	2	
1	1	1	-1	-1	1	1	-1	-1	-1	2	1	1	2	
1	1	1	-1	-1	1	-1	-1	-1	-1	2	2	1	2	
1	-1	1	-1	1	-1	1	-1	-1	1	3	1	1	2	
1	-1	1	-1	1	-1	1	-1	-1	-1	2	1	1	2	
1	-1	1	1	-1	-1	1	-1	-1	1	2	1	1	2	
1	-1	-1	-1	1	-1	1	-1	-1	-1	3	3	1	2	
1	-1	-1	1	-1	-1	1	-1	-1	1	3	3	1	2	
1	-1	-1	-1	1	-1	1	-1	-1	1	3	3	2	1	
1	-1	-1	1	-1	-1	1	-1	-1	-1	3	3	3	1	

Slika 4.12. Ulazno-izlazne matrice za procjenu mehanizma trošenja

Tablica 4.7. Parametri i rezultati učenja *NNBMA* mreže za procjenu mehanizma trošenja

Naziv mreže: NNRMT			Algorithm: NNBMA	
Red.broj	NN - parametri		Red.broj	GA - parametri
1.	ulaz_dat	'mt_ul.txt'	1.	ispis_grafike
2.	br_kol_ulaz	10	2.	alg_selekcije
3.	izlaz_dat	'mt_iz.txt'	3.	alg_mutacije
4.	br_kol_izlaz	4	4.	alg_rekombinacije
5.	br_layera	3		
6.	br_neuro_lay1	4		
7.	br_neuro_lay2	8		
8.	fun_lay1	'tansig'		
9.	fun_lay2	'tansig'		
10.	fun_lay3	'purelin'		
11.	disp_freq	5000	5.	broj_generacija
12.	max_epoch	10000	6.	real_var_iznos
13.	err_goal	1e-15	7.	broj_individua
14.	lr	0.01		
15.	lr_inc	1.05		
16.	lr_dec	0.7		
17.	err_ratio	1.04		
18.	momentum	0.9		
19.	W1_dat	'MTW1.txt'	8.	broj_subpopulacija
20.	W2_dat	'MTW2_dat'	9.	generatio_gap
21.	W3_dat	'MTW3_dat'	10.	selectio_press
22.	B1_dat	'MTB1_dat'	11.	strukt_selekt
23.	B2_dat	'MTB2_dat'	12.	migration_rate
24.	B3_dat	'MTB3_dat'	13.	migration_strukt
25.	norm_ulaz	0		
26.	norm_izlaz	1	14.	inicijalizacija
27.	chek_early_stopping	0		
28.	chek_val_data	0		
29.	chek_test_data	0		

Dijagram: SSE-broj epoha

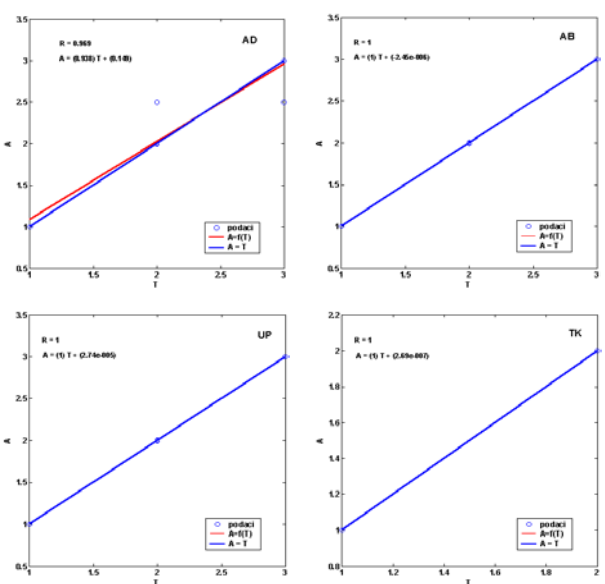
Matrice težina (*W*) i bias vektori (*B*)

```

W1-----B1-----
-0.836158  0.658866  0.580051 -0.208135  0.778416  0.253986 -0.602921 -0.000253 -0.365440 -0.518764  0.002116
-0.812380 -0.860190  1.639860  0.384096 -0.119955  1.011722  0.436042 -0.206790 -0.547192  1.182034  0.111917
-0.122945 -0.653621 -0.755030  0.577833  0.849161 -0.444101  0.797743  0.291734  0.832501  0.991000  0.043497
 0.431372 -0.648844 -1.684691  1.064909  0.235069  0.228768 -0.390988 -0.009671  1.029642  1.347538  0.109850
W2-----B2-----
-0.815422 -0.726832 -1.227892  0.536603 -0.233820
 0.284764 -2.296845  0.374443  1.260365 -0.318453
 1.468510 -0.603540 -1.479104  0.114875  0.127402
 1.447595  1.048196 -0.318516 -0.695274 -0.674798
 2.020771  0.727018 -0.566756  0.630767  1.309897
-0.099420  1.467309 -0.067397 -1.418711 -1.048095
-1.155713  1.444965  0.739393  1.137707  0.736400
 0.986647 -1.495080  0.412957  1.624340 -1.539890
W3-----B3-----
-0.295987  1.504334 -0.019206  1.424416 -0.323138  0.183492  1.030658 -1.097159  0.204224
 0.082282 -0.269010 -0.456429  1.609092 -0.717557 -1.837917  0.138517 -0.182126 -0.071805
 1.935326 -0.794763 -0.582886  0.938222 -0.578903 -0.197755  0.291736  0.274730 -0.333841
-0.278075  0.624439 -1.170789  0.226822  1.231334  0.091088 -0.237687 -1.726033 -0.734632

```

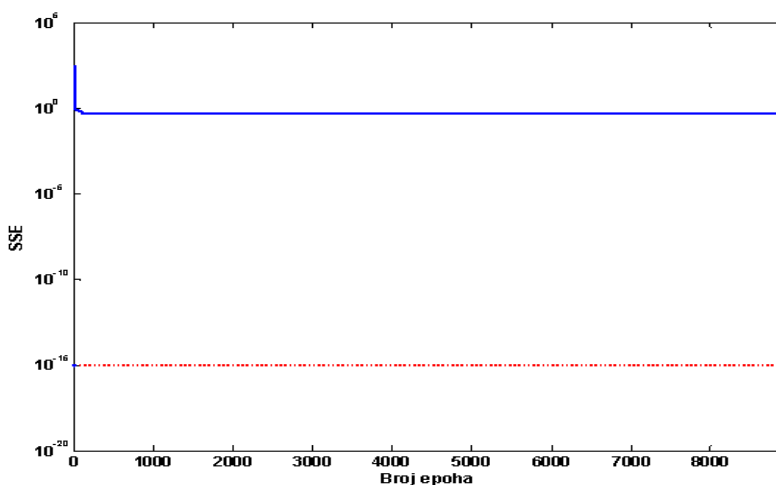
Nastavak: Tablica 4.7. Parametri i rezultati učenja *NNBMA* mreže za procjenu mehanizma trošenja

Naziv mreže: NNRMT		Procjena izlaza					Algorithm: NNBMA																																																																																																																																																		
Skup za učenje						Skup za testiranje																																																																																																																																																			
<table border="1"> <thead> <tr> <th colspan="2">T</th> <th colspan="4">A</th> </tr> </thead> <tbody> <tr><td>3</td><td>3</td><td>1</td><td>2</td><td>2.9999</td><td>3.0000</td><td>1.0001</td><td>2.0000</td></tr> <tr><td>1</td><td>2</td><td>2</td><td>1</td><td>1.0000</td><td>2.0000</td><td>2.0000</td><td>1.0000</td></tr> <tr><td>2</td><td>2</td><td>1</td><td>2</td><td>2.0001</td><td>1.9998</td><td>1.0001</td><td>1.9999</td></tr> <tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1.0000</td><td>1.0000</td><td>1.0000</td><td>1.0000</td></tr> <tr><td>2</td><td>2</td><td>1</td><td>2</td><td>1.9998</td><td>2.0001</td><td>0.9998</td><td>2.0001</td></tr> <tr><td>3</td><td>1</td><td>1</td><td>2</td><td>3.0000</td><td>1.0000</td><td>1.0001</td><td>2.0000</td></tr> <tr><td>3</td><td>1</td><td>3</td><td>2</td><td>3.0000</td><td>1.0000</td><td>3.0000</td><td>2.0000</td></tr> <tr><td>3</td><td>1</td><td>1</td><td>2</td><td>2.5000</td><td>1.0000</td><td>1.0001</td><td>2.0000</td></tr> <tr><td>2</td><td>1</td><td>1</td><td>2</td><td>2.5000</td><td>1.0000</td><td>1.0001</td><td>2.0000</td></tr> <tr><td>2</td><td>2</td><td>1</td><td>2</td><td>2.0000</td><td>2.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3</td><td>1</td><td>1</td><td>2</td><td>3.0000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>2</td><td>1</td><td>1</td><td>2</td><td>2.0000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>2</td><td>1</td><td>1</td><td>2</td><td>2.0000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3</td><td>3</td><td>1</td><td>2</td><td>3.0000</td><td>3.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3</td><td>3</td><td>1</td><td>2</td><td>3.0000</td><td>3.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3</td><td>3</td><td>2</td><td>1</td><td>3.0000</td><td>3.0000</td><td>2.0000</td><td>1.0000</td></tr> <tr><td>3</td><td>3</td><td>3</td><td>1</td><td>3.0000</td><td>3.0000</td><td>3.0000</td><td>1.0000</td></tr> </tbody> </table>						T		A				3	3	1	2	2.9999	3.0000	1.0001	2.0000	1	2	2	1	1.0000	2.0000	2.0000	1.0000	2	2	1	2	2.0001	1.9998	1.0001	1.9999	1	1	1	1	1.0000	1.0000	1.0000	1.0000	2	2	1	2	1.9998	2.0001	0.9998	2.0001	3	1	1	2	3.0000	1.0000	1.0001	2.0000	3	1	3	2	3.0000	1.0000	3.0000	2.0000	3	1	1	2	2.5000	1.0000	1.0001	2.0000	2	1	1	2	2.5000	1.0000	1.0001	2.0000	2	2	1	2	2.0000	2.0000	1.0000	2.0000	3	1	1	2	3.0000	1.0000	1.0000	2.0000	2	1	1	2	2.0000	1.0000	1.0000	2.0000	2	1	1	2	2.0000	1.0000	1.0000	2.0000	3	3	1	2	3.0000	3.0000	1.0000	2.0000	3	3	1	2	3.0000	3.0000	1.0000	2.0000	3	3	2	1	3.0000	3.0000	2.0000	1.0000	3	3	3	1	3.0000	3.0000	3.0000	1.0000						
T		A																																																																																																																																																							
3	3	1	2	2.9999	3.0000	1.0001	2.0000																																																																																																																																																		
1	2	2	1	1.0000	2.0000	2.0000	1.0000																																																																																																																																																		
2	2	1	2	2.0001	1.9998	1.0001	1.9999																																																																																																																																																		
1	1	1	1	1.0000	1.0000	1.0000	1.0000																																																																																																																																																		
2	2	1	2	1.9998	2.0001	0.9998	2.0001																																																																																																																																																		
3	1	1	2	3.0000	1.0000	1.0001	2.0000																																																																																																																																																		
3	1	3	2	3.0000	1.0000	3.0000	2.0000																																																																																																																																																		
3	1	1	2	2.5000	1.0000	1.0001	2.0000																																																																																																																																																		
2	1	1	2	2.5000	1.0000	1.0001	2.0000																																																																																																																																																		
2	2	1	2	2.0000	2.0000	1.0000	2.0000																																																																																																																																																		
3	1	1	2	3.0000	1.0000	1.0000	2.0000																																																																																																																																																		
2	1	1	2	2.0000	1.0000	1.0000	2.0000																																																																																																																																																		
2	1	1	2	2.0000	1.0000	1.0000	2.0000																																																																																																																																																		
3	3	1	2	3.0000	3.0000	1.0000	2.0000																																																																																																																																																		
3	3	1	2	3.0000	3.0000	1.0000	2.0000																																																																																																																																																		
3	3	2	1	3.0000	3.0000	2.0000	1.0000																																																																																																																																																		
3	3	3	1	3.0000	3.0000	3.0000	1.0000																																																																																																																																																		
																																																																																																																																																									
Indeksi uspješnosti																																																																																																																																																									
Skup za učenje						Skup za testiranje																																																																																																																																																			
Mehanizam trošenja	R	SSE	MSE	RMSE	NRMSE		R	SSE	MSE	RMSE	NRMSE																																																																																																																																														
AD	0.9687	0.5001	0.0294	0.1715	0.2408																																																																																																																																																				
AB	1.0000	0.0002	0.0000	0.0034	0.0038																																																																																																																																																				
UP	1.0000	0.0001	0.0000	0.0018	0.0026																																																																																																																																																				
TK	1.0000	0.0001	0.0000	0.0018	0.0041																																																																																																																																																				

Tablica 4.8. Parametri i rezultati učenja *NNLM* mreže za procjenu mehanizma trošenja

Naziv mreže: NNRMT			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'mt_ul.txt'	1.	ispis_grafike	
2.	br_kol_ulaz	10	2.	alg_selekcije	
3.	izlaz_dat	'mt_iz.txt'	3.	alg_mutacije	
4.	br_kol_izlaz	4	4.	alg_rekombinacije	
5.	br_layera	3			
6.	br_neuro_layer1	4			
7.	br_neuro_layer2	8			
8.	fun_layer1	'tansig'			
9.	fun_layer2	'tansig'			
10.	fun_layer3	'purelin'			
11.	disp_freq	500	5.	broj_generacija	
12.	max_epoch	10000	6.	real_var_iznos	
13.	err_goal	1e-15	7.	broj_individua	
14.	min_grad	1e-10			
15.	mu	0.001			
16.	mu_inc	10			
17.	mu_dec	0.1			
18.	mu_max	1e10			
19.	ulaz_dat	'MTW1.txt'	8.	broj_subpopulacija	
20.	W1_dat	'MTW2_dat'	9.	generatio_gap	
21.	W2_dat	'MTW3_dat'	10.	selectio_press	
22.	W3_dat	'MTB1_dat'	11.	strukt_selekt	
23.	B1_dat	'MTB2_dat'	12.	migration_rate	
24.	B2_dat	'MTB3_dat'	13.	migration_strukt	
25.	norm_ulaz	0	14.	inicijalizacija	
26.	norm_izlaz	1			
27.	chek_early_stopping	0			
28.	chek_val_data	0			
29.	chek_test_data	0			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

```

W1-----B1-----
-0.147002 -1.168907 0.568152 -1.016506 0.182953 -0.174528 -1.556963 -0.000000 -0.025390 1.199459 -0.263626
0.849610 -6.316298 -0.484383 0.305500 -1.875495 -1.546531 3.927358 -0.727910 -0.182352 0.077612 0.198097
0.378784 -2.234208 2.990914 1.842300 -0.996928 -1.341049 0.470647 -0.000000 -2.082248 -2.839229 1.172969
1.318007 2.737607 -3.056001 0.267070 -0.531004 1.018646 2.112139 0.263572 -0.345386 -0.798074 0.895034
W2-----B2-----
-1.757659 -5.017855 -1.416092 0.089746 -1.724766
4.130005 -4.202924 4.266961 0.718436 1.752356
0.171136 -0.667962 2.976862 -4.251874 0.681139
1.886587 -1.503304 -1.850831 -1.283968 -1.752858
-3.136403 -1.454702 -3.218615 0.794808 1.503118
3.001517 0.595387 0.352818 2.543689 2.163382
1.812124 1.539592 -0.299728 1.828639 1.643816
0.939471 -1.743251 3.652536 -1.665941 -1.528618
W3-----B3-----
-1.376712 2.956313 0.352853 0.825756 1.468574 0.131115 1.089570 -2.012876 1.366412
-0.911770 2.946592 -1.418088 -0.974438 1.423443 -3.113578 4.475835 -1.306228 -0.991625
-1.309239 -0.087144 5.010246 -0.868298 4.599019 -0.277808 1.195931 -1.897085 -0.491827
0.222977 2.517247 -1.309935 -3.307935 -1.089778 -1.183620 0.779095 -1.523461 -1.332431

```

Nastavak: Tablica 4.8. Parametri i rezultati učenja NNLM mreže za procjenu mehanizma trošenja

Naziv mreže: NNRMT		Procjena izlaza					Algorithm: NNLM																																																																																														
Skup za učenje						Skup za testiranje																																																																																															
<table border="1"> <thead> <tr> <th>T</th> <th colspan="4">A</th> </tr> </thead> <tbody> <tr><td>3 3 1 2</td><td>3.0000</td><td>3.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>1 2 2 1</td><td>1.0000</td><td>2.0000</td><td>2.0000</td><td>1.0000</td></tr> <tr><td>2 2 1 2</td><td>2.0000</td><td>2.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>1 1 1 1</td><td>1.0000</td><td>1.0000</td><td>1.0000</td><td>1.0000</td></tr> <tr><td>2 2 1 2</td><td>2.0000</td><td>2.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3 1 1 2</td><td>3.0000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3 1 3 2</td><td>3.0000</td><td>1.0000</td><td>3.0000</td><td>2.0000</td></tr> <tr><td>3 1 1 2</td><td>2.5000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>2 1 1 2</td><td>2.5000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>2 2 1 2</td><td>2.0000</td><td>2.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3 1 1 2</td><td>3.0000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>2 1 1 2</td><td>2.0000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>2 1 1 2</td><td>2.0000</td><td>1.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3 3 1 2</td><td>3.0000</td><td>3.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3 3 1 2</td><td>3.0000</td><td>3.0000</td><td>1.0000</td><td>2.0000</td></tr> <tr><td>3 3 2 1</td><td>3.0000</td><td>3.0000</td><td>2.0000</td><td>1.0000</td></tr> <tr><td>3 3 3 1</td><td>3.0000</td><td>3.0000</td><td>3.0000</td><td>1.0000</td></tr> </tbody> </table>						T	A				3 3 1 2	3.0000	3.0000	1.0000	2.0000	1 2 2 1	1.0000	2.0000	2.0000	1.0000	2 2 1 2	2.0000	2.0000	1.0000	2.0000	1 1 1 1	1.0000	1.0000	1.0000	1.0000	2 2 1 2	2.0000	2.0000	1.0000	2.0000	3 1 1 2	3.0000	1.0000	1.0000	2.0000	3 1 3 2	3.0000	1.0000	3.0000	2.0000	3 1 1 2	2.5000	1.0000	1.0000	2.0000	2 1 1 2	2.5000	1.0000	1.0000	2.0000	2 2 1 2	2.0000	2.0000	1.0000	2.0000	3 1 1 2	3.0000	1.0000	1.0000	2.0000	2 1 1 2	2.0000	1.0000	1.0000	2.0000	2 1 1 2	2.0000	1.0000	1.0000	2.0000	3 3 1 2	3.0000	3.0000	1.0000	2.0000	3 3 1 2	3.0000	3.0000	1.0000	2.0000	3 3 2 1	3.0000	3.0000	2.0000	1.0000	3 3 3 1	3.0000	3.0000	3.0000	1.0000						
T	A																																																																																																				
3 3 1 2	3.0000	3.0000	1.0000	2.0000																																																																																																	
1 2 2 1	1.0000	2.0000	2.0000	1.0000																																																																																																	
2 2 1 2	2.0000	2.0000	1.0000	2.0000																																																																																																	
1 1 1 1	1.0000	1.0000	1.0000	1.0000																																																																																																	
2 2 1 2	2.0000	2.0000	1.0000	2.0000																																																																																																	
3 1 1 2	3.0000	1.0000	1.0000	2.0000																																																																																																	
3 1 3 2	3.0000	1.0000	3.0000	2.0000																																																																																																	
3 1 1 2	2.5000	1.0000	1.0000	2.0000																																																																																																	
2 1 1 2	2.5000	1.0000	1.0000	2.0000																																																																																																	
2 2 1 2	2.0000	2.0000	1.0000	2.0000																																																																																																	
3 1 1 2	3.0000	1.0000	1.0000	2.0000																																																																																																	
2 1 1 2	2.0000	1.0000	1.0000	2.0000																																																																																																	
2 1 1 2	2.0000	1.0000	1.0000	2.0000																																																																																																	
3 3 1 2	3.0000	3.0000	1.0000	2.0000																																																																																																	
3 3 1 2	3.0000	3.0000	1.0000	2.0000																																																																																																	
3 3 2 1	3.0000	3.0000	2.0000	1.0000																																																																																																	
3 3 3 1	3.0000	3.0000	3.0000	1.0000																																																																																																	
Indeksi uspješnosti																																																																																																					
Skup za učenje						Skup za testiranje																																																																																															
Mehanizam trošenja	R	SSE	MSE	RMSE	NRMSE		R	SSE	MSE	RMSE	NRMSE																																																																																										
AD	0.9687	0.5001	0.0294	0.1715	0.2408																																																																																																
AB	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																
UP	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																
TK	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																

4.4.5. Procjena prikladnog površinskog sloja

Na slici 4.13 prikazana je shema mapiranja izlaznog skupa varijabli za određivanje prikladnog postupka modificiranja površina. Kao što se vidi, prikladni postupci modificiranja površina (ukupno 31 postupak!) podijeljeni su u grupe (npr. *Martenzitni slojevi*, *Rubni slojevi s promjenom kem. sastava*) i podgrupe (npr. *prokaljeni slojevi dobiveni u grijavanjem cijelog presjeka*, *plameno kaljeni slojevi*, *indukcijski kaljeni slojevi* itd.). Podgrupe prikladnih postupaka mapirane su po digitalnom principu: -1 (NEMA) ili 1 (IMA). -1 označava neprikladnost postupka, a 1 prikladnost postupka modificiranja površina. Ulazni skup predstavlja varijable tipa trošenja i dominantnog mehanizma trošenja.

Sifre/Nazivi slojeva	Map. vrije.
GRUPA 1: MARTENZITNI	
1.1 PROKALJENI SLOJEVI DOBIVENI UGRJAVANJEM CIJELOG PRESJEKA	(-1,0)
1.2 PLAMENO KALJENI SLOJEVI	(-1,0)
1.3 INDUKCIJSKI KALJENI SLOJEVI	(-1,0)
1.4 LASERSKI KALJENI SLOJEVI	(-1,0)
1.5 ELEKTRONSKIM SNOPOM KALJENI SLOJEVI	(-1,0)
1.6 CEMENTIRANI SLOJEVI	(-1,0)
GRUPA 2: RUBNI S PROMJENOM KEM. SASTAVA	
2.1 NITRIRANI/NITROKARBURIRANI SLOJEVI	(-1,0)
2.2 BORIRANI SLOJEVI	(-1,0)
2.3 VANADIRANI SLOJEVI	(-1,0)
GRUPA 3: TOPLINSKI NASTRČANI	
3.1 SLOJEVI SAMOTEKUĆIH LEGURA	(-1,0)
3.2 SLOJEVI CISTIH METALA	(-1,0)

Slika 4.13. Shema mapiranja varijabli postupaka modificiranja površina (izvod iz tablice P1.8 u prilogu I)

Slučajevi Trošenja	ULAZNI SKUP					IZLAZNI SKUP																	
	Tip	Meh. trošenja				GRUPA 1						GRUPA 2			GRUPA 3					GRUPA 4			
		AD	AB	UP	TK	1.1	1.2	1.3	1.4	1.5	1.6	2.1	2.2	2.3	3.1	3.2	3.3	3.4	3.5	3.6	4.1	4.2	4.3
1	1	3	3	1	2	1	1	1	1	1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
2	2	1	2	2	1	-1	-1	-1	-1	-1	-1	1	1	-1	-1	1	1	1	-1	-1	-1	1	-1

Slika 4.14. Primjer mapiranja ulazno-izlaznog skupa za određivanje prikladnog postupka modificiranja površina (izvod iz tablice P1.9 u prilogu I)

Na slici 4.14 prikazan je primjer mapiranja ulazno-izlaznog skupa za određivanje prikladnog postupka modificiranja površina za dva slučaja trošenja. Treba napomenuti, da su iznosi varijabli ulaznog skupa (*tip trošenja* i *dominantni mehanizam trošenja*) dobiveni iz zasebnih mreža (*asocijativne* i *backpropagation* mreže). Slika 4.15 prikazuje vrijednosti ulazno-izlazne matrice za određivanje prikladnog postupka modificiranja površina.

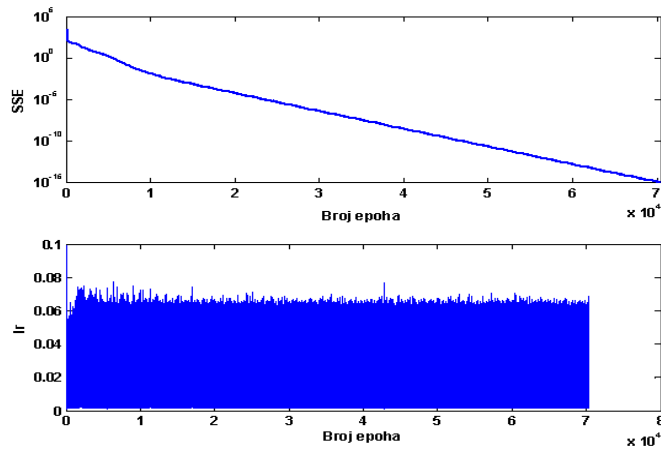
ULAZNI SKUP	IZLAZNI SKUP																							
1 3 3 1 2	1	1	1	1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	1	1
2 1 2 2 1	-1	-1	-1	-1	-1	-1	1	1	-1	-1	-1	-1	-1	-1	-1	1	1	1	-1	-1	-1	-1	-1	-1
3 2 2 1 2	1	1	1	1	1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
5 1 1 1 1	1	1	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	1	1
4 2 2 1 2	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	1	1	1	1	1	-1	-1	-1	
6 3 1 1 2	1	1	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	
7 3 1 3 2	-1	-1	-1	-1	-1	-1	1	1	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	1	
8 3 1 1 2	-1	-1	-1	-1	-1	-1	1	1	1	1	-1	1	1	1	1	1	1	1	1	-1	-1	-1	-1	
8 2 1 1 2	-1	-1	-1	-1	-1	-1	1	1	1	1	-1	1	1	1	1	1	1	1	1	-1	-1	-1	-1	
8 2 2 1 2	-1	-1	-1	-1	-1	-1	1	1	1	1	-1	1	1	1	1	1	1	1	1	-1	-1	-1	-1	
9 3 1 1 2	-1	-1	-1	-1	-1	-1	1	1	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	1	
10 2 1 1 2	-1	-1	-1	-1	-1	-1	1	1	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	
11 2 1 1 2	-1	-1	-1	-1	-1	-1	1	1	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	
12 3 3 1 2	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	
13 3 3 1 2	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	
14 3 3 2 1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	
15 3 3 3 1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	

Slika 4.15. Ulazno-izlazne matrice za određivanje prikladnog postupka modificiranja površina

Tablica 4.9. Parametri i rezultati učenja *NNBMA* mreže za procjenu prikladnih postupaka modificiranja površina

Naziv mreže: NNRPPMP			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'mpp_ul.txt'	1.	ispis_grafike	
2.	br_kol_ulaz	5	2.	alg_selekcije	
3.	izlaz_dat	'mpp_iz.txt'	3.	alg_mutacije	
4.	br_kol_izlaz	31	4.	alg_rekombinacije	
5.	br_layera	2			
6.	br_neuro_layer1	26			
7.	br_neuro_layer2	31			
8.	fun_layer1	'tansig'			
9.	fun_layer2	'purelin'			
10.	fun_layer3				
11.	disp_freq	1000	5.	broj_generacija	
12.	max_epoch	100000	6.	real_var_iznos	
13.	err_goal	1e-15	7.	broj_individua	
14.	lr	0.1			
15.	lr_inc	1.05			
16.	lr_dec	0.7			
17.	err_ratio	1.04			
18.	momentum	0.9			
19.	W1_dat	'MPPW1.txt'	8.	broj_subpopulacija	
20.	W2_dat	'MPPW2.txt'	9.	generatio_gap	
21.	W3_dat		10.	selectio_press	
22.	B1_dat	'MPPB1.txt'	11.	strukt_selekt	
23.	B2_dat	'MPPB2.txt'	12.	migration_rate	
24.	B3_dat		13.	migration_strukt	
25.	norm_ulaz	1	14.	inicijalizacija	
26.	norm_izlaz	0			
27.	chek_early_stopping	1			
28.	chek_val_data	0			
29.	chek_test_data	0			

Dijagram: SSE-broj epoha

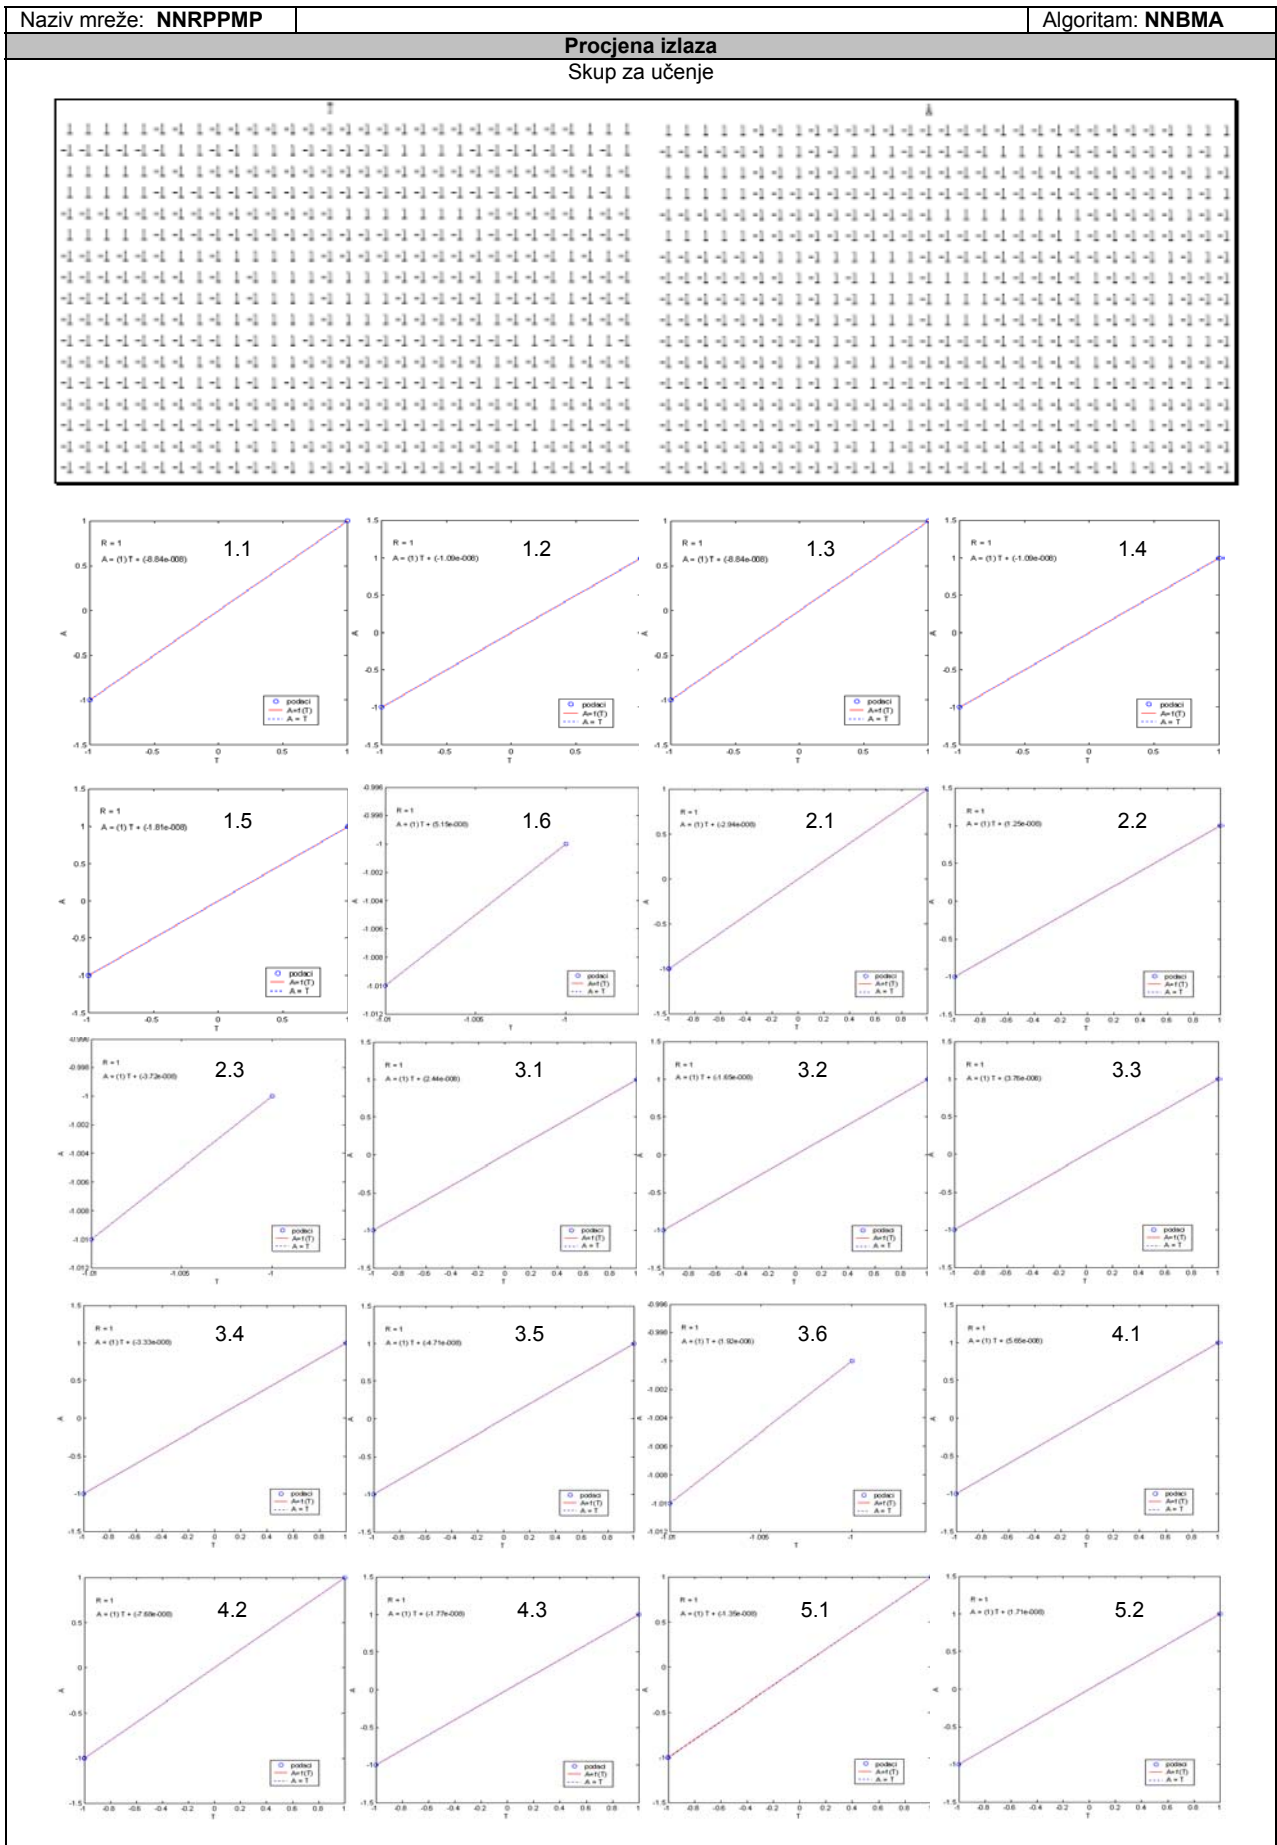


Matrice težina (*W*) i bias vektori (*B*)

W2				B2				W1				B1			
-2.422041	-0.559069	-0.214280	1.123386	-0.278799	-0.486868	7.266369	-6.885039	-4.025804	0.950335	6.157436	-0.815408				
-2.371166	-1.065516	0.765203	1.008320	-0.698072	-0.527423	-0.234248	-0.454486	1.827264	1.811646	-2.441187	-1.294253				
-2.110096	-0.318130	-0.526474	0.844990	0.192603	-1.166864	0.585727	0.914849	0.403460	-1.390158	1.553118	-0.479711				
-2.372890	-0.288427	0.211559	1.001403	-0.457485	-0.227721	5.375351	-1.013634	-0.308743	0.504871	0.303025	1.825893				
-2.259524	-1.202352	0.508926	0.860865	-0.536033	-1.754919	-0.438069	0.096570	0.036882	-0.173689	2.295290	1.022906				
-0.120938	0.332069	0.521389	0.127758	-0.353248	0.225933	-4.658238	1.291133	1.468755	-1.726977	0.576554	1.286295				
-0.301830	0.540691	-0.031824	0.132079	0.824777	-0.017237	2.214361	0.483537	2.773690	0.573636	-0.540415	0.338820				
-0.169140	-0.403788	0.080049	1.834985	-0.276877	-1.120060	0.021276	-1.404531	-0.329987	0.296155	1.394197	0.510351				
0.037782	-0.486615	0.058560	-0.027662	0.231694	-0.644434	-0.136469	-0.553774	0.476483	-0.445477	0.091954	-1.312512				
0.543851	0.387494	0.586584	1.005229	-0.348838	-0.234009	-0.973462	0.737581	0.662426	0.966947	-0.668537	-1.943763				
-0.326486	0.866711	-0.409833	0.123720	0.733585	-1.133466	4.308410	-1.015569	0.151807	0.515844	0.683382	-1.960525				
0.411405	1.693803	-0.225716	1.045676	0.501926	-0.540415	1.778788	0.384846	-0.954434	-0.443483	0.776944	0.818307				
0.460312	1.080717	0.562101	0.814126	-0.962899	-1.037019	-0.206804	-1.312813	1.747051	2.562770	-4.025628	-4.632383				
0.933819	-1.528915	-0.762738	1.337560	-0.010840	-0.479730	-0.724905	-0.626339	-1.908282	-0.630313	-0.254127	1.816861				
-0.120613	-0.327214	1.080791	0.049040	-0.655483	-0.803815	3.451216	0.395295	-2.051012	1.123798	0.707965	-2.464384				
-2.513862	0.296468	-0.600691	-0.434531	0.258840	-0.582324	-0.479893	-0.449381	-0.238592	1.309092	-1.954618	-1.637094				
2.447979	-0.106570	0.454807	-0.280169	-0.250064	0.637147	3.580857	2.545552	0.036498	1.444788	-0.056665	-0.177673				
2.347855	0.433203	0.111522	-0.187628	0.458406	-0.456419	6.721185	3.002010	2.403933	0.490092	-2.883146	1.967882				
1.659045	0.122266	0.513679	-1.940433	0.008268	0.036080	1.663225	0.663116	0.639557	1.505479	-0.623750	-0.722664				
1.711108	0.238441	-0.191591	-1.965247	0.219956	-0.154537	-1.815167	-0.623069	-2.383907	-0.316624	1.871050	0.340619				
1.895371	0.447129	0.107083	-2.025323	0.142609	-0.312538										
1.883614	0.144220	0.642391	-2.102816	-0.715043	-0.141200										
0.378522	1.128366	0.477037	-1.667021	0.759321	-0.383577										
0.685760	-0.667257	0.140347	0.987999	-0.046750	0.088004										
-0.188409	0.331372	0.430921	0.145213	-0.343809	0.015063										
-0.179397	0.354402	-0.257288	-0.054896	0.426409	-1.345796										
-0.178191	-0.189890	-0.701485	0.017102	0.605033	-0.440349										
0.884263	-0.851459	-0.055441	0.625094	-0.036180	-0.328178										
1.935867	0.526216	0.132255	-2.094672	-0.623259	-0.444220										
-1.328016	0.085556	-0.425909	1.136615	0.753635	-0.352963										
0.111202	-0.340522	-0.999988	0.010480	0.272725	0.540411										

Napomena: Zbog veličine matrice *W2* (31 kolona) dan je njezin djelomični prikaz.

Nastavak: Tablica 4.9. Parametri i rezultati učenja *NNBMA* mreže za procjenu prikladnih postupaka modifikiranja površina



Nastavak: Tablica 4.9 Parametri i rezultati učenja *NNBMA* mreže za procjenu prikladnih postupaka modificiranja površina

Naziv mreže: NNRPPMP		Procjena izlaza				Skup za učenje						Skup za testiranje					
		Skup za učenje															
Indeksi uspješnosti																	
Skup za učenje						Skup za testiranje											
Šifra prik. sloja	R	SSE	MSE	RMSE	NRMSE		R	SSE	MSE	RMSE	NRMSE						
1.1	1.0000	0.0000	0.0000	0.0000	0.0000												
1.2	1.0000	0.0000	0.0000	0.0000	0.0000												
1.3	1.0000	0.0000	0.0000	0.0000	0.0000												
1.4	1.0000	0.0000	0.0000	0.0000	0.0000												
1.5	1.0000	0.0000	0.0000	0.0000	0.0000												
1.6	1.0000	0.0000	0.0000	0.0000	0.0000												
2.1	1.0000	0.0000	0.0000	0.0000	0.0000												
2.2	1.0000	0.0000	0.0000	0.0000	0.0000												
2.3	1.0000	0.0000	0.0000	0.0000	0.0000												
3.1	1.0000	0.0000	0.0000	0.0000	0.0000												
3.2	1.0000	0.0000	0.0000	0.0000	0.0000												
3.3	1.0000	0.0000	0.0000	0.0000	0.0000												
3.4	1.0000	0.0000	0.0000	0.0000	0.0000												
3.5	1.0000	0.0000	0.0000	0.0000	0.0000												
3.6	1.0000	0.0000	0.0000	0.0000	0.0000												
4.1	1.0000	0.0000	0.0000	0.0000	0.0000												
4.2	1.0000	0.0000	0.0000	0.0000	0.0000												
4.3	1.0000	0.0000	0.0000	0.0000	0.0000												
5.1	1.0000	0.0000	0.0000	0.0000	0.0000												
5.2	1.0000	0.0000	0.0000	0.0000	0.0000												
5.3	1.0000	0.0000	0.0000	0.0000	0.0000												
5.4	1.0000	0.0000	0.0000	0.0000	0.0000												
6.1	1.0000	0.0000	0.0000	0.0000	0.0000												
6.2	1.0000	0.0000	0.0000	0.0000	0.0000												
6.3	1.0000	0.0000	0.0000	0.0000	0.0000												
6.4	1.0000	0.0000	0.0000	0.0000	0.0000												
6.5	1.0000	0.0000	0.0000	0.0000	0.0000												
7.1	1.0000	0.0000	0.0000	0.0000	0.0000												
7.2	1.0000	0.0000	0.0000	0.0000	0.0000												
7.3	1.0000	0.0000	0.0000	0.0000	0.0000												
7.4	1.0000	0.0000	0.0000	0.0000	0.0000												

4.4.6. Procjena prikladnog površinskog sloja otpornog koroziji

Na slici 4.16 prikazan je dio tablice iskustvenih ocjena za procjenu prikladnog površinskog sloja otpornog koroziji. Značenje ocjena s obzirom na podobnost primjene za određeni tip korozije je sljedeće: 0-*Nepodobno*; 1-*Moguće*; 2-*Podobno*. Obradeno je ukupno 13 vrsta površinskih slojeva otpornih koroziji.

Oznake sloja prema tab.3.7	Površinski sloj (postupak)	Tip korozije			
		M0/M1	M2	M3	M4
2.1	Nitrirani/Nitrokarburirani slojevi (Nitriranje/Karbonitriranje)	2	2	1	0
2.2	Borirani slojevi (Boriranje)	2	1	0	0
3.2	Slojevi čistih metala Molibden (Naštrcavanje)	2	2	1	1
3.3	Slojevi metalnih karbida (Naštrcavanje)	2	2	1	0
3.4	Slojevi metalnih oksida (Naštrcavanje)	2	2	1	0

Slika 4.16. Iskustvene ocjene za procjenu prikladnog površinskog sloja otpornog koroziji (izvod iz tablice P1.10 u prilogu I) [45]

Oznake M0, M1, M2, M3, M4 predstavljaju razrede korozije prema StBK-N4 normi švedskog komiteta za čelične konstrukcije [44]. S obzirom na agresivnost medija, razredi predstavljaju sljedeće stupnjeve opasnosti od korozije: M0-*nikakava*, M1-*slaba*, M2-*srednja*, M3-*velika*, M4-*jako velika*.

Tip korozije	ULAZNI SKUP	IZLAZNI SKUP												
	Mapirane vrijednosti	Oznake slojeva												
		2.1	2.2	3.2	3.3	3.4	3.5	3.6	6.3	4.3	5.1	5.2	5.3	5.4
M0/M1	(1 0 0 0)	2	2	2	2	2	2	2	2	2	2	2	2	2
M2	(0 1 0 0)	2	1	2	2	2	2	2	2	2	2	2	2	2
M3	(0 0 1 0)	1	0	1	1	1	2	1	1	1	2	2	2	2
M4	(0 0 0 1)	0	0	1	0	0	2	1	0	0	1	1	1	1

Slika 4.17. Primjer mapiranja ulazno-izlaznog skupa za procjenu prikladnog površinskog sloja otpornog koroziji (izvod iz tablice P1.11 u prilogu I)

Na slici 4.17 prikazan je primjer mapiranja ulazno-izlaznog skupa za procjenu prikladnog površinskog sloja otpornog koroziji. S obzirom da ne postoje kvantitativne vrijednosti varijable 'Tip korozije', mapiranje je iste izvedeno je po principu *I-od -C* mapiranja. Na slici 4.18 prikazane su vrijednosti ulazno-izlazne matrice.

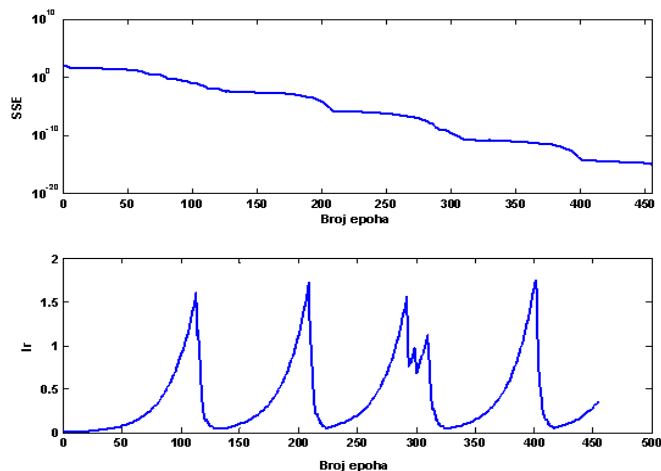
ULAZNI SKUP	IZLAZNI SKUP
1 0 0 0	2 2 2 2 2 2 2 2 2 2 2 2 2 2
0 1 0 0	2 1 2 2 2 2 2 2 2 2 2 2 2 2
0 0 1 0	1 0 1 1 1 2 1 1 1 2 2 2 2 2
0 0 0 1	0 0 1 0 0 2 1 0 0 1 1 1 1 1

Slika 4.18. Ulazno-izlazne matrice za procjenu prikladnog površinskog sloja otpornog koroziji

Tablica 4.10. Parametri i rezultati učenja *NNBMA* mreže za procjenu prikladnog sloja otpornog koroziji

Naziv mreže: NNROKPP			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'sloj_ul.txt'	1.	ispis_grafike	
2.	br_kol_ulaz	4	2.	alg_selekcije	
3.	izlaz_dat	'sloj_iz.txt'	3.	alg_mutacije	
4.	br_kol_izlaz	13	4.	alg_rekombinacije	
5.	br_layera	2			
6.	br_neuro_layer1	8			
7.	br_neuro_layer2	13			
8.	fun_layer1	'logsig'			
9.	fun_layer2	'purelin'			
10.	fun_layer3				
11.	disp_freq	500	5.	broj_generacija	
12.	max_epoch	5000	6.	real_var_iznos	
13.	err_goal	1e-15	7.	broj_individua	
14.	lr	0.01			
15.	lr_inc	1.05			
16.	lr_dec	0.7			
17.	err_ratio	1.04			
18.	momentum (mu)	0.9			
19.	W1_dat	'SLOKW1.txt'	8.	broj_subpopulacija	
20.	W2_dat	'SLOKW2.txt'	9.	generatio_gap	
21.	W3_dat		10.	selectio_press	
22.	B1_dat	'SLOKB1.txt'	11.	strukt_selekt	
23.	B2_dat	'SLOKB2.txt'	12.	migration_rate	
24.	B3_dat		13.	migration_strukt	
25.	norm_ulaz	0	14.	inicijalizacija	
26.	norm_izlaz	1			
27.	chek_early_stopping	0			
28.	chek_val_data	0			
29.	chek_test_data	0			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

```

W1-----B1-----
1. 797473  1. 921963 -1. 318133 -0. 121745 -0. 651741
1. 382808 -0. 547877 -0. 427205 -0. 404049 -1. 056224
-0. 448028 -0. 832134  0. 446253  1. 411712 -0. 123733
-1. 002617 -0. 488800  0. 231510 -0. 281164 -0. 210748
1. 161660  1. 098861  0. 980707 -2. 565220  0. 251740
-0. 392604 -0. 822176 -0. 814489  1. 095489  0. 081254
1. 897306  1. 590377  0. 009559 -1. 859585 -0. 400348
-0. 505998 -0. 530164  0. 644132 -1. 335739 -0. 350833

W2-----B2-----
0. 172700  0. 122880 -1. 186755 -0. 124095  0. 709775 -0. 232987  1. 123039 -0. 306567 -0. 044439
-0. 026526  2. 150268 -0. 946846 -0. 954256  0. 081047  0. 380304  1. 104209 -0. 720175 -0. 582380
1. 646345  0. 307177 -0. 516898  0. 501015 -0. 306173 -0. 674696  1. 576385 -1. 016536 -0. 809513
1. 230799  0. 164828 -0. 544185 -0. 453178  0. 674763 -0. 712751  0. 367640  0. 709918 -0. 482748
1. 062308  0. 003810 -0. 280962 -0. 429515  1. 624078 -0. 233799  0. 175950 -0. 159280 -0. 912143
-0. 545643 -0. 100974 -0. 348079  0. 318568  0. 200670  0. 681499  0. 469637 -0. 478960  1. 834720
1. 698170  0. 039649 -1. 008457 -0. 660239 -0. 163770 -0. 160353  1. 108335 -0. 228342 -0. 434421
0. 706957 -0. 204346 -0. 196043 -0. 722856  0. 671792 -0. 313401  1. 276125  0. 468100 -0. 771395
0. 834546  0. 231109 -0. 927430 -0. 233837  1. 362982 -0. 395366  0. 063068 -0. 296509 -0. 271503
-0. 754601  0. 255577 -0. 281540  0. 004389  1. 513592 -1. 514985  0. 784828 -0. 354137  0. 412013
-0. 132135  0. 326721 -0. 866125  0. 476298  0. 982041 -0. 692571  0. 709382  1. 304261 -0. 351516
-0. 676712 -0. 142057  0. 175045 -0. 086625  1. 750391 -0. 630992  1. 297254  0. 093927 -0. 676421
-0. 371866 -0. 152282 -0. 173530 -0. 605818  1. 033369 -0. 719248  1. 222188  1. 361663 -0. 359483

```

Nastavak: Tablica 4.10. Parametri i rezultati učenja *NNBMA* mreže za procjenu prikladnog sloja otpornog koroziji

Naziv mreže: NNROKPP		Procjena izlaza					Skup za učenje					Skup za testiranje					
		T					A										
		2 2 2 2 2 2 2 2 2 2 2 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 1 0 1 1 1 2 1 1 1 2 2 2 2 0 0 1 0 0 2 1 0 0 1 1 1 1					2 2 2 2 2 2 2 2 2 2 2 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 1 0 1 1 1 2 1 1 1 2 2 2 2 0 0 1 0 0 2 1 0 0 1 1 1 1										
													Indeksi uspješnosti				
		Skup za učenje					Skup za testiranje										
Prikladni sloj otp. koroziji	R	SSE	MSE	RMSE	NRMSE		R	SSE	MSE	RMSE	NRMSE						
2.1	1.0000	0.0000	0.0000	0.0000	0.0000												
2.2	1.0000	0.0000	0.0000	0.0000	0.0000												
3.2	1.0000	0.0000	0.0000	0.0000	0.0000												
3.3	1.0000	0.0000	0.0000	0.0000	0.0000												
3.4	1.0000	0.0000	0.0000	0.0000	0.0000												
3.5	1.0000	0.0000	0.0000	0.0000	0.0000												
3.6	1.0000	0.0000	0.0000	0.0000	0.0000												
6.3	1.0000	0.0000	0.0000	0.0000	0.0000												
4.3	1.0000	0.0000	0.0000	0.0000	0.0000												
5.1	1.0000	0.0000	0.0000	0.0000	0.0000												
5.2	1.0000	0.0000	0.0000	0.0000	0.0000												
5.3	1.0000	0.0000	0.0000	0.0000	0.0000												
5.4	1.0000	0.0000	0.0000	0.0000	0.0000												

4.4.7. Procjena prikladnog površinskog sloja otpornog trošenju

Na slici 4.19 prikazan je dio tablice iskustvenih ocjena za procjenu prikladnog površinskog sloja otpornog trošenju. Značenje ocjena s obzirom na podobnost primjene jednako je kao kod otpornosti koroziji: 0-*nepodobno*, 1-*moguće*, 2-*podobno*. Također je obrađeno ukupno 13 vrsta površinskih slojeva otpornih trošenju.

Oznake slojeva prema tab.3.7	Površinski slojevi (postupak)	Mehanizam/Tip trošenja					
		Adhezija		Abrazija		Erozija česticama	Izjedanje
		slaba	jaka	slaba	jaka		
2.1	Nitrirani/Nitrokarburirani slojevi (Nitriranje/Karbonitriranje)	2	1	1	1	0	1
2.2	Borirani slojevi (Boriranje)	2	1	2	1	0	2
3.2	Slojevi čistih metala Molibden (Naštrcavanje)	2	2	2	1	1	2
3.3	Slojevi metalnih karbida (Naštrcavanje)	1	0	2	1	0	2
3.4	Slojevi metalnih oksida (Naštrcavanje)	1	0	2	1	0	2

Slika 4.19. Iskustvene ocjene za procjenu prikladnog površinskog sloja otpornog trošenju (izvod iz tablice P1.10 u prilogu I) [45]

Na slici 4.20 prikazan je primjer mapiranja ulazno-izlaznog skupa za procjenu prikladnog površinskog sloja otpornog trošenju. Ulazni skup predstavljaju nazivi površinskih slojeva koji su mapirani po principu *I-od-C* mapiranja, a izlazni skup predstavljaju mehanizmi ili tipovi trošenja.

Oznake slojeva prema tab.3.7	ULAZNI SKUP Mapirane vrijednosti	IZLAZNI SKUP					
		Adhezija		Abrazija		Erozija česticama	Izjedanje
		slaba	jaka	slaba	jaka		
2.1	(1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0)	2	1	1	1	0	1
2.2	(0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0)	2	1	2	1	0	2
3.2	(0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0)	2	2	2	1	1	2
3.3	(0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0)	1	0	2	1	0	2
3.4	(0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0)	1	0	2	1	0	2

Slika 4.20. Primjer mapiranja ulazno-izlaznog skupa za procjenu prikladnog površinskog sloja otpornog trošenju (izvod iz tablice P1.11 u prilogu I)

Na slici 4.21 prikazane su vrijednosti ulazno-izlazne matrice za procjenu određivanje prikladnog površinskog sloja otpornog trošenju.

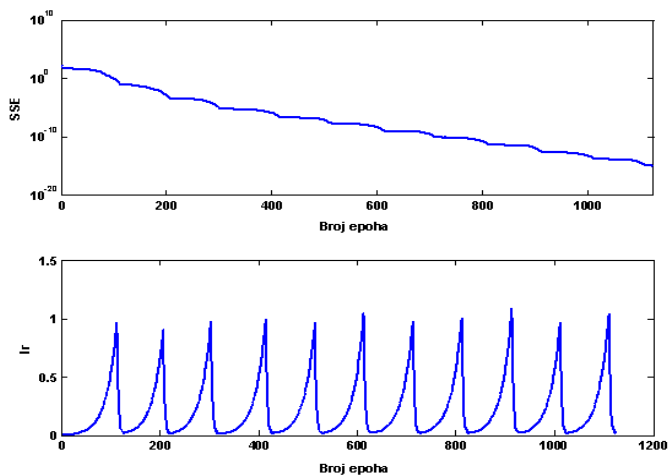
ULAZNI SKUP																IZLAZNI SKUP							
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	1	1	1	0	1		
0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1	0	2		
0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	2	2	2	1	1	2		
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	2	1	0	2		
0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	2	1	0	2		
0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	1	2	2	1	2		
0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0	1	1	0	1		
0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	1	2	2	1	1		
0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	2	2	2	1	0	2		
0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	1	2	1	0	2		
0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	1	2	1	0	2		
0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	1	2	1	0	2		
0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	1	2	1	0	2		
0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	1	2	1	0	2		

Slika 4.21. Ulazno-izlazne matrice za procjenu prikladnog površinskog sloja otpornog trošenju

Tablica 4.11. Parametri i rezultati učenja NNBA mreže za procjenu prikladnog sloja otpornog trošenju

Naziv mreže: NNRSLOT			Algoritam: NNBA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'sloj_ul.txt'	1.	ispis_grafike	
2.	br_kol_ulaz	13	2.	alg_selekcije	
3.	izlaz_dat	'sloj_iz.txt'	3.	alg_mutacije	
4.	br_kol_izlaz	6	4.	alg_rekombinacije	
5.	br_layera	2			
6.	br_neuro_layer1	8			
7.	br_neuro_layer2	6			
8.	fun_layer1	'logsig'			
9.	fun_layer2	'purelin'			
10.	fun_layer3				
11.	disp_freq	500	5.	broj_generacija	
12.	max_epoch	5000	6.	real_var_iznos	
13.	err_goal	1e-15	7.	broj_individua	
14.	lr	0.01			
15.	lr_inc	1.05			
16.	lr_dec	0.7			
17.	err_ratio	1.04			
18.	momentum	0.9			
19.	W1_dat	'SLOTW1.txt'	8.	broj_subpopulacija	
20.	W2_dat	'SLOTW2.txt'	9.	generatio_gap	
21.	W3_dat		10.	selectio_press	
22.	B1_dat	'SLOTB1.txt'	11.	strukt_selekt	
23.	B2_dat	'SLOTB2.txt'	12.	migration_rate	
24.	B3_dat		13.	migration_strukt	
25.	norm_ulaz	0	14.	inicijalizacija	
26.	norm_izlaz	1			
27.	chek_early_stopping	0			
28.	chek_val_data	0			
29.	chek_test_data	0			

Dijagram: SSE-broj epoha



Matrice težina (W) i bias vektori (B)

```

W1-----
0.7506  1.4613  2.1293 -0.6810  0.1160  0.5649 -1.3965 -1.1800  1.2148  0.2411 -0.1378  0.5241 -0.1867 -0.5612
-0.7226  0.1755  1.3302 -0.0460  0.4448 -0.9748 -0.5138  1.5603 -0.5949  0.1397  0.1068  0.1649 -0.0679 -0.9225
-1.6218  0.7666  0.4532 -0.2712 -0.3030  1.2021 -2.8266  1.0015  0.7512 -0.2357  0.0434 -0.4459 -0.1073  0.6423
-1.1949 -1.0847  0.7710 -0.5342 -0.2349  1.5779  0.1321  0.8714 -0.7924  0.4549  1.2763 -0.1153  0.6639 -0.1320
0.9672  0.2196 -1.6674 -0.7078  0.1292  1.0958  0.2529  1.7244 -0.2544  0.0413 -0.4597  0.4429 -0.4774  0.0504
1.1167  1.3699  0.0766 -0.5195 -0.1756 -1.5695  0.1197 -0.3060  0.7947 -0.0648  0.7476 -0.6850  0.1349  0.1151
-0.1107 -0.4147  0.1322 -1.1753 -1.1282 -0.9421 -0.9413 -0.1544  1.2938  0.6354  0.4211  0.8103  0.5331 -0.3290
-1.8659  0.2518 -1.6842  0.9524  1.4774 -0.5070 -0.7115 -1.7544 -0.3974  0.8532  0.8088  0.8885  0.6800  0.1452
W2-----
2.012483 -0.430963 0.666723 -1.595027 -0.749194  1.564924 -0.188171 -1.764694 -0.198718
0.999090 -0.288928 0.846639  0.356985 -0.377261  0.070973  1.928918 -1.132298 -1.167630
-0.065240 0.929632 2.460647 -0.175377 -0.487759 -0.787815  0.503539  1.222925 -1.164384
-0.818165 -0.495687 1.920701  0.755824  1.658074 -0.907863 -0.611296 -1.227755 -1.244122
0.681774  0.993935 1.166248  1.328026  0.054326 -1.604772 -0.939304 -2.027019 -0.252506
1.665214 -0.859915 1.365346  0.362094 -1.474292 -0.910199  0.041823  2.077312 -0.764909
B1-----
B2-----
    
```

Nastavak: Tablica 4.11. Parametri i rezultati učenja *NNBMA* mreže za procjenu prikladnog sloja otpornog trošenju

Naziv mreže: NNRSLOT		Procjena izlaza					Algorithm: NNBMA																																																																																																																																																																										
<p style="text-align: center;">Skup za učenje</p> <table border="1" style="margin-left: auto; margin-right: auto;"> <thead> <tr> <th colspan="5">T</th> <th colspan="5">A</th> </tr> </thead> <tbody> <tr><td>2</td><td>1</td><td>1</td><td>1</td><td>0</td><td>1</td><td>2</td><td>1</td><td>1</td><td>1</td><td>0</td><td>1</td></tr> <tr><td>2</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td><td>2</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td></tr> <tr><td>2</td><td>2</td><td>2</td><td>1</td><td>1</td><td>2</td><td>2</td><td>2</td><td>2</td><td>1</td><td>1</td><td>2</td></tr> <tr><td>1</td><td>0</td><td>2</td><td>1</td><td>0</td><td>2</td><td>1</td><td>0</td><td>2</td><td>1</td><td>0</td><td>2</td></tr> <tr><td>1</td><td>0</td><td>2</td><td>1</td><td>0</td><td>2</td><td>1</td><td>0</td><td>2</td><td>1</td><td>0</td><td>2</td></tr> <tr><td>1</td><td>1</td><td>2</td><td>2</td><td>1</td><td>2</td><td>1</td><td>1</td><td>2</td><td>2</td><td>1</td><td>2</td></tr> <tr><td>1</td><td>0</td><td>1</td><td>1</td><td>0</td><td>1</td><td>1</td><td>0</td><td>1</td><td>1</td><td>0</td><td>1</td></tr> <tr><td>1</td><td>1</td><td>2</td><td>2</td><td>1</td><td>1</td><td>1</td><td>1</td><td>2</td><td>2</td><td>1</td><td>1</td></tr> <tr><td>2</td><td>2</td><td>2</td><td>1</td><td>0</td><td>2</td><td>2</td><td>2</td><td>2</td><td>1</td><td>0</td><td>2</td></tr> <tr><td>1</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td><td>1</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td></tr> <tr><td>1</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td><td>1</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td></tr> <tr><td>1</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td><td>1</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td></tr> <tr><td>1</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td><td>1</td><td>1</td><td>2</td><td>1</td><td>0</td><td>2</td></tr> </tbody> </table>												T					A					2	1	1	1	0	1	2	1	1	1	0	1	2	1	2	1	0	2	2	1	2	1	0	2	2	2	2	1	1	2	2	2	2	1	1	2	1	0	2	1	0	2	1	0	2	1	0	2	1	0	2	1	0	2	1	0	2	1	0	2	1	1	2	2	1	2	1	1	2	2	1	2	1	0	1	1	0	1	1	0	1	1	0	1	1	1	2	2	1	1	1	1	2	2	1	1	2	2	2	1	0	2	2	2	2	1	0	2	1	1	2	1	0	2	1	1	2	1	0	2	1	1	2	1	0	2	1	1	2	1	0	2	1	1	2	1	0	2	1	1	2	1	0	2	1	1	2	1	0	2	1	1	2	1	0	2
T					A																																																																																																																																																																												
2	1	1	1	0	1	2	1	1	1	0	1																																																																																																																																																																						
2	1	2	1	0	2	2	1	2	1	0	2																																																																																																																																																																						
2	2	2	1	1	2	2	2	2	1	1	2																																																																																																																																																																						
1	0	2	1	0	2	1	0	2	1	0	2																																																																																																																																																																						
1	0	2	1	0	2	1	0	2	1	0	2																																																																																																																																																																						
1	1	2	2	1	2	1	1	2	2	1	2																																																																																																																																																																						
1	0	1	1	0	1	1	0	1	1	0	1																																																																																																																																																																						
1	1	2	2	1	1	1	1	2	2	1	1																																																																																																																																																																						
2	2	2	1	0	2	2	2	2	1	0	2																																																																																																																																																																						
1	1	2	1	0	2	1	1	2	1	0	2																																																																																																																																																																						
1	1	2	1	0	2	1	1	2	1	0	2																																																																																																																																																																						
1	1	2	1	0	2	1	1	2	1	0	2																																																																																																																																																																						
1	1	2	1	0	2	1	1	2	1	0	2																																																																																																																																																																						
Indeksi uspješnosti																																																																																																																																																																																	
Skup za učenje						Skup za testiranje																																																																																																																																																																											
Prikladni sloj otp. trošenju	R	SSE	MSE	RMSE	NRMSE		R	SSE	MSE	RMSE	NRMSE																																																																																																																																																																						
2.1	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
2.2	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
3.2	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
3.3	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
3.4	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
3.5	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
3.6	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
6.3	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
4.3	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
5.1	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
5.2	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
5.3	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												
5.4	1.0000	0.0000	0.0000	0.0000	0.0000																																																																																																																																																																												

4.4.8. Procjena kemijske postojanosti čelika

Na slici 4.22 prikazan je izvod dijela ocjena kemijske postojanosti sulfatnoj (H_2SO_4) kiselini nehrđajućih i kemijski postojanih čelika. Prikazane ocjene baziraju se na laboratorijskim ispitivanjima [45] u kemijski čistim otopinama. Treba napomenuti da u praksi rijetko postoje sustavi kod kojih je čelik izravno izložen kemijski čistoj otopini, te se stoga navedene ocjene uzimaju kao relativne. Apsolutna ocjena kemijske postojanosti može se dobiti jedino ako se čelik izloži mediju koji se javlja u eksploatacijskim uvjetima. Osim sulfatne u ulazno-izlazni skup uzete su još i sljedeće kiseline: Nitratna (HNO_3), fosfatna (H_3PO_4), octena (CH_3COOH) i kloridna (HCl).

Otopina	Maseni udio w %	Temp. °C	Oznaka čelika			
			C4170 Č4171 C4172 C4173 C4175 Č4770	C4750	C4571 Č4572 C4580 C4582	C4573 Č4574 C4583
			Ocjena postojanosti			
Sulfatna H_2SO_4	1	20	3	1	1	0
		70	3	3	1	0
		100	3	3	1	1
	5	20	3	3	1	0
		70	3	3	1	1
		100	3	3	1	2
		100	3	3	3	3
	80	20	3	3	1	1
		70	3	3	3	2
		100	3	3	3	3

Legenda: 0=Potpuno postojan, 1=Manje postojan, 2=Slabo postojan, 3=Nepostojan, 4=Nepoznata postojanost

Slika 4.22. Kemijska postojanost čelika sulfatnoj kiselini (izvod iz tablice P1.14 u prilogu I)

	ULAZNI SKUP								IZLAZNI SKUP postojanost
	%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	
	0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000
	0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000
	0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	20.0000	1.0000
	0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
	0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000
	0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000
\bar{x}	0,1685	1,0000	1,4285	15,6428	4,8571	0,2857	32,4000	63,3333	2,4238
Min	0,0800	1,0000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,4000	1,0000	2,0000	18,0000	12,0000	2,0000	98,0000	100,0000	4,0000
σ_x	0,1054	0,0000	0,4960	2,3156	5,1232	0,7015	33,6881	33,0771	0,9364

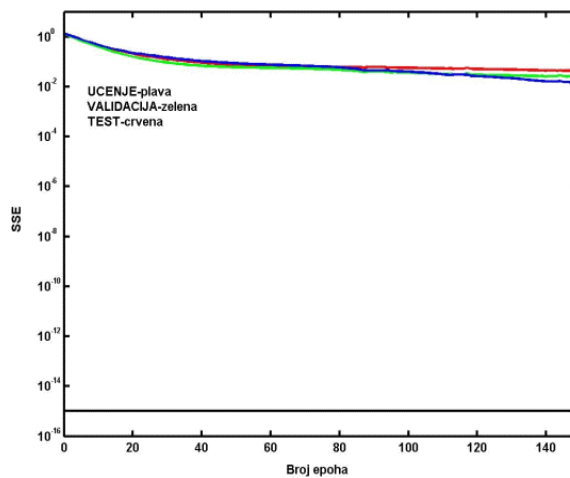
Slika 4.23. Primjer dijela mapiranja ulazno-izlaznog skupa za učenje za slučaj postojanosti čelika sulfatnoj H_2SO_4 kiselini (izvod iz tablice P1.27 u prilogu I)

Primjer mapiranja ulazno-izlaznog skupa prikazan je na slici 4.23. Ulazni skup čine podaci o kemijskom sastavu (C , Si , Mn , Cr , Ni , Mo), masenom udjelu otopine (w) i temperaturi otopine (T). Izlazni skup čine ocjene postojanosti izražene brojkama od 0 do 4. Značenje ocjena prikazano na legendi slike 4.22. Ulazno-izlazni skup podataka za svaki od nabrojanih agresivnih podijeljen je na tri dijela: podatke za učenje, podatke za validaciju i podatke za testiranje. Pri tome je od ukupnog broja podataka, 50% podataka izuzeto za učenje, a po 25% za validaciju i testiranje. Za izuzimanje podataka za učenje, validaciju i testiranje, korištena je metoda slučajnih brojeva. Cjelokupan prikaz ulazno-izlaznih skupova podataka nabrojanih agresivnih medija dano u prilogu I. U nastavku su prikazane statističke vrijednosti ulazno-izlaznih skupova, parametri korištenih tipova mreža, te rezultati učenja i testiranja.

Tablica 4.12. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema CH_3COOH

Naziv mreže: NNCH ₃ COOH			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'chcoh_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'chcoh_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				2
6.	br_neuro_lay1				9
7.	br_neuro_lay2				1
8.	fun_lay1				'tansig'
9.	fun_lay2				'purelin'
10.	fun_lay3				-
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.025416
15.	lr_inc	1.050000			
16.	lr_dec	0.700000			
17.	err_ratio	1.04			
18.	momentum				0.358690
19.	W1_dat	'CHCOW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'CHCOW2.txt'	9.	generatio_gap	0.8
21.	W3_dat		10.	selectio_press	1
22.	B1_dat	'CHCOB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'CHCOB2.txt'	12.	migration_rate	0.25
24.	B3_dat		13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

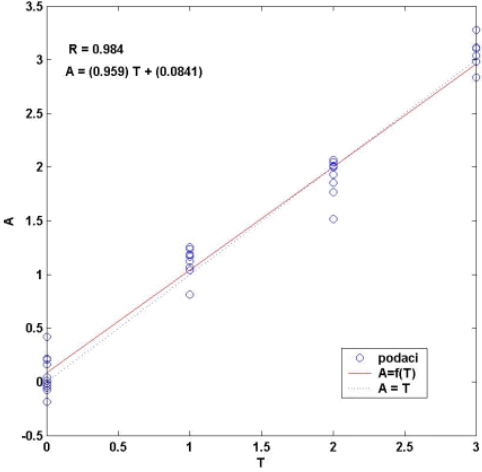
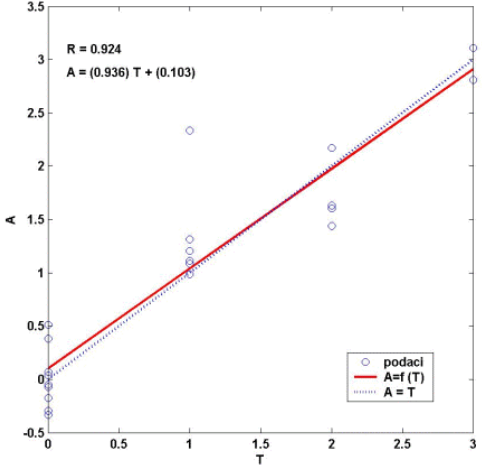
Matrice težina (*W*) i bias vektori (*B*)

```

W1-----
9.7416e-001 7.5681e-003 -1.0842e+000 -8.6235e-002 -1.2234e+000 1.9617e-001 -1.7262e-002 5.6712e-001 -1.6474e+000
-7.3782e-001 1.1222e-001 -5.5317e-001 9.4579e-001 4.9936e-001 -5.0527e-001 9.5535e-001 8.2702e-001 1.4034e+000
6.0927e-001 -2.1721e-001 7.4456e-001 4.0175e-001 -8.0641e-001 -4.4377e-001 1.3207e+000 -3.2528e-001 -1.0510e+000
-7.1069e-001 -2.0411e-001 -6.5883e-001 -8.8454e-001 1.4575e-001 -9.9332e-001 1.0514e+000 4.9285e-001 1.2972e-001
4.3398e-001 2.9270e-001 -5.5298e-002 1.3824e+000 3.8544e-001 -4.9608e-001 1.0578e+000 3.5845e-001 4.4434e-001
6.5301e-001 2.2312e-001 -9.5197e-001 -6.5864e-001 -1.0469e+000 3.1228e-001 6.4730e-001 -1.3396e-001 8.5592e-001
9.6477e-001 2.5576e-002 3.5896e-001 1.0716e+000 -8.4210e-002 1.9977e-001 -3.6159e-002 -1.3275e+000 1.1911e+000
5.5182e-001 -2.2549e-001 -5.4487e-001 2.0968e-001 -1.1026e+000 -1.4261e-001 1.2753e+000 9.6555e-001 1.2990e+000
1.2008e+000 1.9619e-001 -7.4428e-001 8.1900e-001 2.2745e-001 -7.8558e-001 -7.7722e-001 9.7830e-002 2.3975e+000
W2-----
6.3992e-001 6.3264e-001 -6.1247e-001 7.0148e-001 -3.5823e-001 -4.4516e-001 1.3488e-001 2.2345e-001 -3.1915e-001 -6.9927e-001
B2-----

```

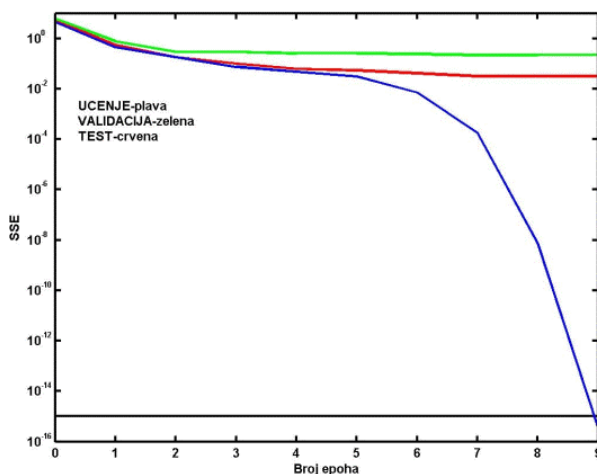
Nastavak: Tablica 4.12. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema CH_3COOH

Naziv mreže: NNCH_3COOH						Procjena izlaza						Algorithm: NNBMA					
Skup za učenje						Skup za testiranje											
<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 						<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 											
Indeksi uspješnosti																	
Skup za učenje						Skup za testiranje											
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE						
CH_3COOH	0.9843	1.5467	0.0368	0.1919	0.1777	CH_3COOH	0.9239	3.2721	0.1558	0.3947	0.3857						

Tablica 4.13. Parametri i rezultati učenja *NNLM* mreže za procjenu postojanosti prema CH_3COOH

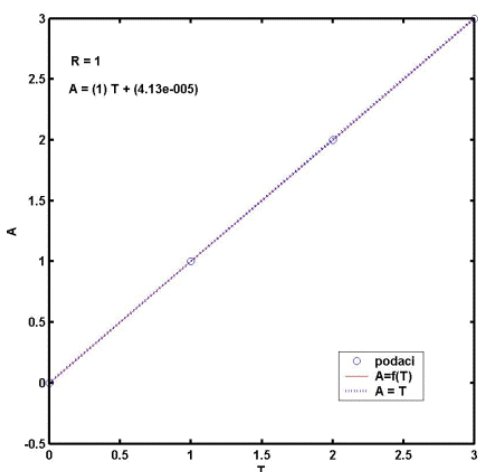
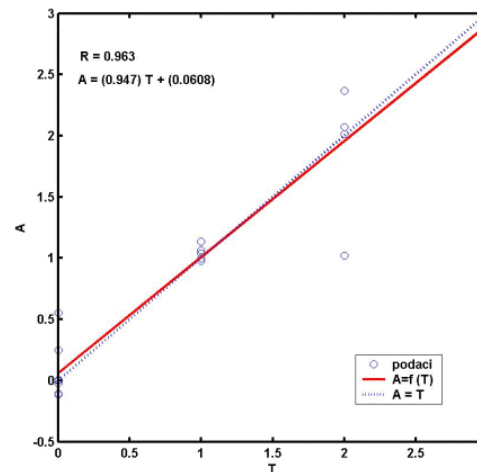
Naziv mreže: NNCH₃COOH			Algoritam: NNLM		
NN-GA parametri					
1.	ulaz_dat	'chcoh_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'chcoh_iz.txt'	3.	alg_mutacije	21
5.	br_kol_izlaz	1	4.	alg_rekombinacije	14
7.	br_layera				3
8.	br_neuro_lay1				9
9.	br_neuro_lay2				10
11.	fun_lay1				'tansig'
12.	fun_lay2				'tansig'
13.	fun_lay3				'purelin'
14.	disp_freq	100	5.	broj_generacija	100
15.	max_epoch	10000	6.	real_var_iznos	0
16.	err_goal	1e-15	7.	broj_individua	22
17.	min_grad	0.000100			0.000100
18.	mu				0.910468
19.	mu_inc	10.000000			
20.	mu_dec	0.100000			
21.	mu_max	10000000000			
28.	W1_dat	'CHCOW1.txt'	8.	broj_subpopulacija	6
29.	W2_dat	'CHCOW2.txt'	9.	generatio_gap	0.8
30.	W3_dat	'CHCOW3.txt'	10.	selectio_press	1
31.	B1_dat	'CHCOB1.txt'	11.	strukt_selekt	0
32.	B2_dat	'CHCOB2.txt'	12.	migration_rate	0.25
33.	B3_dat	'CHCOB3.txt'	13.	migration_strukt	0
38.	norm_ulaz	1	14.	inicijalizacija	0
39.	norm_izlaz	1			
42.	chek_early_stopping	1			
43.	chek_val_data	1			
44.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1-----	B1-----
5.3195e-001 -7.1766e-002 8.0341e-001 -1.0858e+000 -8.6717e-001 -1.3945e-001 8.8908e-001 -1.1568e-001 -1.8459e+000	
-1.2563e+000 2.0570e-001 6.2629e-001 -8.1227e-001 7.4492e-001 -5.0984e-001 -8.3412e-001 2.0957e-001 1.2899e+000	
-5.2790e-001 1.1625e-002 8.2661e-001 -4.2883e-001 1.1901e+000 -9.8972e-001 1.4571e-001 7.6587e-001 8.5757e-001	
1.4472e-001 -9.3894e-002 1.6703e-001 1.2657e-001 9.3025e-002 7.5362e-001 2.0200e+000 -1.4792e+000 3.8391e-001	
-2.0991e-001 -1.5367e-001 -7.2119e-001 9.2868e-001 -1.1338e+000 8.2288e-001 2.5900e-001 -1.0729e+000 -1.9743e-001	
7.9277e-001 -2.4841e-001 -1.0784e+000 1.3493e-001 1.0152e+000 -3.5321e-001 -6.4751e-001 -4.2699e-002 2.9935e-001	
2.9788e-001 -7.7906e-002 2.4494e-001 -6.8539e-001 2.9395e-001 1.8221e+000 -1.8930e-001 -9.0652e-001 9.7876e-001	
-1.2699e+000 -1.7955e-001 7.8585e-002 -9.3975e-002 5.5277e-001 -1.0794e+000 -7.7187e-001 -7.3823e-002 -1.9350e+000	
8.7024e-001 3.6968e-001 -9.0889e-001 2.8168e-001 -9.0662e-001 4.9717e-001 6.0497e-001 -3.5409e-001 2.5371e+000	
W2-----	B2-----
4.3825e-001 -5.2093e-001 -7.8297e-001 -6.5008e-001 -3.3794e-001 4.0321e-001 5.4050e-001 -3.6523e-001 -9.1122e-001 -1.9566e+000	
-1.2008e-001 7.8318e-002 -5.6141e-001 -7.0203e-001 9.2841e-001 4.2099e-002 9.3899e-001 -7.9968e-001 1.5946e-001 -1.4177e+000	
-4.8572e-002 3.9297e-001 2.8505e-001 -2.5311e-001 2.3346e-001 1.2851e+000 -3.8487e-001 8.7208e-001 -9.4004e-001 1.0193e+000	
-1.0926e-001 -2.1830e-001 9.2000e-001 4.4954e-001 1.0188e+000 5.3497e-001 -8.7544e-001 3.4585e-001 -6.8496e-001 -5.2422e-001	
3.8747e-001 -1.0482e-001 1.3308e+000 7.6013e-001 -9.9074e-002 -2.6933e-001 7.5629e-001 2.3260e-001 -8.7101e-001 9.3971e-002	
-5.2373e-001 -2.7372e-001 1.7761e-002 -8.9270e-001 -1.2988e+000 -1.0789e-001 -1.1035e+000 8.1444e-002 3.8353e-001 -2.2503e-001	
-1.1895e-001 -1.6228e-001 7.5900e-001 1.4256e-002 3.7877e-001 -9.6677e-001 9.9695e-001 4.6119e-001 -6.8170e-002 -6.5124e-001	
-3.9099e-001 -6.1293e-001 2.4920e-001 -1.2152e+000 3.7594e-001 6.4286e-001 5.5386e-001 -9.1770e-002 1.2444e-001 -9.9353e-001	
-1.7932e-001 2.4962e-001 6.3537e-001 -1.5507e-001 9.2749e-001 -1.9652e-001 7.0836e-001 -7.1290e-001 -8.6825e-001 -1.3829e+000	
-3.8192e-001 4.8733e-001 7.9932e-001 -2.7621e-001 -8.8168e-001 -7.9680e-001 -5.0179e-001 -6.6022e-001 6.3300e-001 -1.7149e+000	
W3-----	B3-----
9.1830e-001 -1.4873e-001 5.7625e-001 -9.1302e-001 -9.6573e-001 -6.9475e-001 1.4337e-001 -4.3491e-001 -3.3817e-001 8.4891e-001 -7.1663e-001	

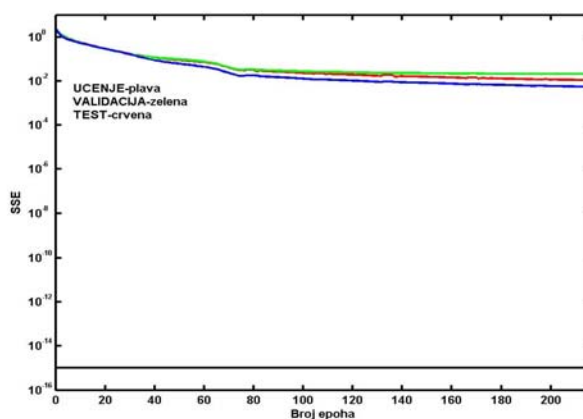
Nastavak: Tablica 4.13. Parametri i rezultati učenja *NNLM* mreže za procjenu postojanosti prema CH_3COOH

Naziv mreže: NNCH_3COOH		Procjena izlaza		Algoritam: NNLM	
Skup za učenje			Skup za testiranje		
<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p> 			<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p> 		
Indeksi uspješnosti					
Skup za učenje			Skup za testiranje		
R	1.0000	R	0.9634	SSE	1.5168
SSE	0.0000	SSE	1.5168	MSE	0.0722
MSE	0.0000	MSE	0.0722	RMSE	0.2688
RMSE	0.0000	RMSE	0.2688	NRMSE	0.2626
NRMSE	0.0000	NRMSE	0.2626		

Tablica 4.14. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema HCl

Naziv mreže: NNHCL			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hcl_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hcl_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				2
6.	br_neuro_layer1				9
7.	br_neuro_layer2				7
8.	fun_layer1				'tansig'
9.	fun_layer2				'tansig'
10.	fun_layer3				-
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.025416
15.	lr_inc	1.050000			
16.	lr_dec	0.700000			
17.	err_ratio	1.04			
18.	momentum				0.358690
19.	W1_dat	'HCLW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'HCLW2.txt'	9.	generatio_gap	0.8
21.	W3_dat		10.	selectio_press	1
22.	B1_dat	'HCLB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HCLB2.txt'	12.	migration_rate	0.25
24.	B3_dat		13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

```

W1-----B1-----
-5.2681e-001 -3.5719e-002 -5.0332e-001 6.5784e-002 1.0344e+000 -4.3962e-002 -1.3478e+000 7.3192e-001 1.7498e+000
1.9246e+000 -6.4262e-002 6.1785e-001 -6.7892e-001 1.0577e-001 -2.6376e-001 -9.5402e-002 7.6594e-001 -1.0991e+000
-1.6675e+000 3.7952e-002 2.6965e-001 3.6058e-001 2.7091e-001 -4.9560e-001 -1.9583e-001 1.1437e+000 6.6486e-001
-7.2241e-001 -5.9884e-002 -5.9554e-001 1.2854e+000 3.1115e-001 9.7965e-001 9.6809e-001 1.8121e-001 2.5719e-001
1.4605e+000 9.5430e-002 -3.3614e-001 -1.6324e-001 1.1122e+000 -9.9622e-001 1.5707e-002 1.6269e-002 4.1862e-001
8.7937e-001 -3.8112e-002 2.0375e-001 -8.6118e-001 -1.2689e+000 -6.3012e-001 9.4083e-001 -5.5031e-002 6.1680e-001
1.1246e+000 8.8705e-002 -3.9012e-001 7.2885e-001 -1.0605e+000 -4.3381e-001 -9.1810e-001 4.3171e-001 1.3002e+000
1.0762e+000 2.9829e-002 -5.0375e-001 -7.0624e-001 3.1530e-001 -5.3867e-001 -1.0328e+000 -1.0512e+000 1.6951e+000
-5.6376e-001 2.4382e-002 -9.0075e-001 -7.9994e-001 -6.2349e-001 6.6302e-001 -3.6172e-001 1.1082e+000 -2.0240e+000
W2-----B2-----
-2.5295e-001 3.5042e-001 -6.3102e-001 -1.0306e+000 1.0517e+000 6.8222e-001 5.0110e-001 -4.7534e-001 -1.7061e-001

```

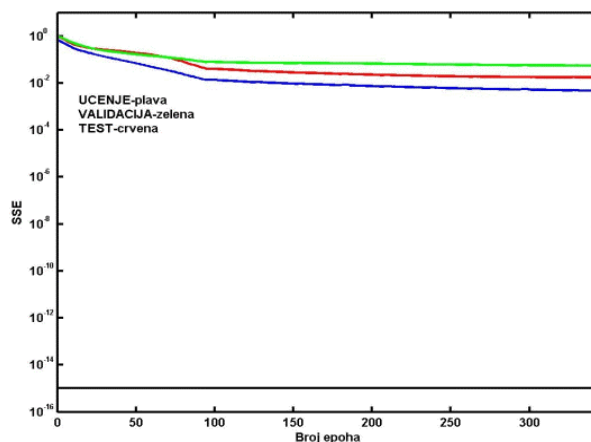
Nastavak: Tablica 4.14. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema HCl

Naziv mreže: NNHCL		Procjena izlaza						Algoritam: NNBMA					
Skup za učenje						Skup za testiranje							
<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p>						<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p>							
Indeksi uspješnosti													
Skup za učenje						Skup za testiranje							
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE		
HCL	0.9944	0.7117	0.0127	0.1127	0.1053	HCL	0.9922	0.7117	0.0254	0.1594	0.1332		

Tablica 4.15. Parametri i rezultati učenja *NNLM* mreže za procjenu postojanosti prema HCl

Naziv mreže: NNHCL			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hcl_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hcl_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_layer1				8
7.	br_neuro_layer2				8
8.	fun_layer1				'tansig'
9.	fun_layer2				'tansig'
10.	fun_layer3				'purelin'
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad	0.000100			
15.	mu				0.507515
16.	mu_inc	10.000000			
17.	mu_dec	0.100000			
18.	mu_max	10000000000			
19.	W1_dat	'HCLW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'HCLW2.txt'	9.	generatio_gap	0.8
21.	W3_dat		10.	selectio_press	1
22.	B1_dat	'HCB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HCB2.txt'	12.	migration_rate	0.25
24.	B3_dat		13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

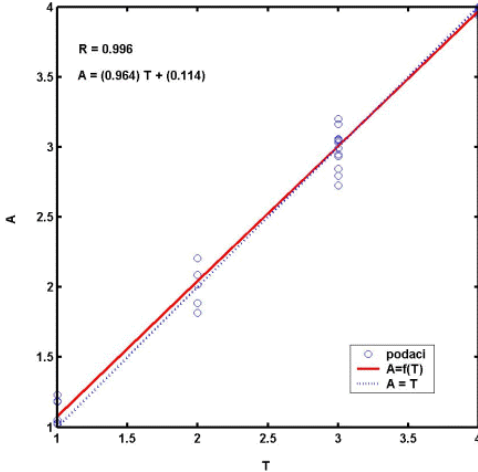
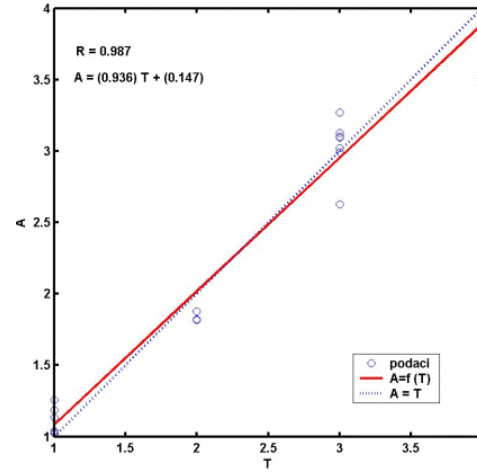
Matrice težina (*W*) i bias vektori (*B*)

```

W1-----B1-----
1.6240e+000 -1.4398e-002 -6.4186e-001 2.1479e-001 1.0447e+000 -1.1374e-001 7.2131e-001 -3.3456e-001 -1.5876e+000
-7.7509e-001 -1.6309e-001 1.1073e+000 -1.2195e+000 3.7667e-002 3.9466e-002 -6.9669e-001 -5.2153e-001 1.0486e+000
-1.1650e+000 4.5164e-002 9.4959e-001 5.4523e-001 -8.8301e-001 -6.3224e-001 -5.7003e-001 4.2023e-001 7.5835e-001
1.1355e+000 -1.7640e-001 -3.0315e-001 -1.4513e+000 -9.8312e-001 7.0957e-002 -1.2876e-001 -1.8785e-001 -4.2778e-001
-8.6268e-001 5.7965e-002 -8.1222e-001 -4.9857e-001 1.2913e+000 -1.4815e-001 3.5761e-002 -6.9453e-001 -1.2749e-001
-2.3217e-001 5.7309e-001 -1.0784e+000 5.8683e-001 1.0141e+000 -6.2634e-001 1.5925e+000 5.4703e-001 7.0604e-002
-6.5729e-001 -4.5988e-003 -6.2382e-001 1.0945e+000 2.9972e-001 2.7312e-001 1.0441e+000 1.3057e+000 -1.0959e+000
-1.3851e+000 1.0800e-001 8.5389e-001 7.5493e-001 -2.0562e-001 -8.8867e-001 4.7727e-002 8.5267e-001 -1.6017e+000
-6.2937e-001 3.8742e-001 -8.5217e-001 -6.4808e-001 -1.0042e+000 -1.2470e+000 1.0837e+000 -1.3756e-001 -1.6493e+000
W2-----B2-----
-2.3672e-001 9.6256e-001 3.4507e-002 1.6961e+000 5.4346e-002 1.2991e+000 5.2918e-001 -8.8325e-002 6.1209e-001

```

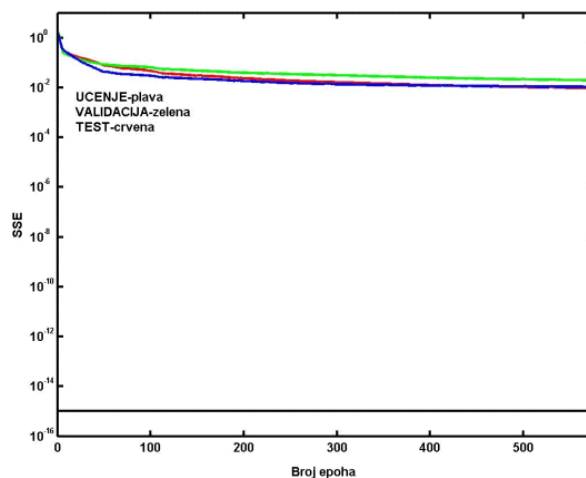

Nastavak: Tablica 4.15. Parametri i rezultati učenja NNLM mreže za procjenu postojanosti prema HCl

Naziv mreže: NNHCL			Procjena izlaza					Algorithm: NNLM				
Skup za učenje						Skup za testiranje						
<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 						<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 						
Indeksi uspješnosti												
Skup za učenje						Skup za testiranje						
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE	
HCL	0.9956	0.5971	0.0107	0.1033	0.0965	HCL	0.9870	1.1056	0.0395	0.1987	0.1660	

Tablica 4.16. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti pema HNO_3

Naziv mreže: NNHNO_3			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hno_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hno_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				9
7.	br_neuro_lay2				7
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig'
10.	fun_lay3				'tansig'
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.105833
15.	lr_inc	1.050000			
16.	lr_dec	0.70000			
17.	err_ratio	1.04			
18.	momentum				0.494056
19.	W1_dat	'HNOW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'HNOW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HNOW3.txt'	10.	selectio_press	1
22.	B1_dat	'HNOB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HNOB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HNOB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

```

W1-----
-1.1780e+000 1.9526e-002 -5.8393e-001 6.4945e-001 6.8430e-001 -4.5289e-001 -1.0770e+000 6.6050e-001 1.7126e+000
-8.7759e-001 -5.2506e-002 8.5773e-001 8.8487e-001 -5.8719e-001 4.4321e-001 -7.7582e-001 9.4279e-001 1.2490e+000
-1.9208e-001 1.6095e-001 -1.3400e+000 9.8418e-002 -3.2313e-001 -8.4615e-001 9.6727e-001 -2.0191e-001 1.2298e+000
9.8576e-001 2.4658e-001 3.0859e-001 -5.5068e-001 -1.3135e-001 6.9483e-001 8.6727e-001 -1.1689e+000 -1.3161e-001
-8.9593e-001 -1.5967e-001 1.0545e+000 -6.0521e-001 -3.4415e-001 -2.3069e-001 -1.2650e+000 -5.7475e-001 -2.2877e-001
-9.7413e-002 -1.8908e-001 -3.9672e-001 8.1844e-001 1.5983e+000 -8.7986e-001 6.6638e-001 -8.1704e-001 -4.5831e-001
-9.5584e-001 -2.6937e-001 -4.1580e-001 -8.8920e-001 -6.3848e-001 -9.1203e-001 2.8163e-001 6.9631e-001 -1.1257e+000
5.4259e-001 -2.5389e-001 7.8859e-001 2.4814e-002 7.7775e-002 1.0643e+000 -2.0691e+000 3.4299e-001 1.1480e+000
-2.5144e-002 -4.5542e-001 1.2359e+000 -1.4271e+000 -4.4000e-001 1.3437e-001 1.5426e+000 3.9423e-001 1.0623e+000
7.5847e-001 4.8666e-002 -2.3430e-001 5.9027e-001 -4.4174e-002 -7.6079e-001 1.0612e+000 9.8634e-001 2.1612e+000
W2-----
4.1650e-001 -2.7088e-001 7.7047e-001 -7.8872e-001 3.9600e-001 7.2422e-001 3.8850e-001 1.2437e-001 2.8888e-001 -5.6594e-001 -1.5857e+000
-9.2473e-001 2.8938e-001 7.3135e-001 -4.0469e-001 -6.6533e-001 -6.2348e-001 2.3982e-001 2.4254e-001 8.3677e-001 3.7060e-001 2.0371e-001
2.6063e-002 5.8096e-001 8.0188e-001 -6.2699e-001 6.5733e-001 1.0522e+000 -3.3491e-001 1.2943e+000 -1.5394e+000 6.0297e-001 -3.9644e-001
4.3237e-001 -2.9304e-001 1.5905e-001 1.9438e-001 -8.4206e-001 4.9502e-001 -7.1374e-001 4.2687e-001 -7.6609e-001 -8.1130e-001 1.4203e+000
W3-----
-4.6480e-001 1.2583e+000 -2.2055e+000 -4.1200e-001 -7.0625e-002
B1-----
B2-----
B3-----

```

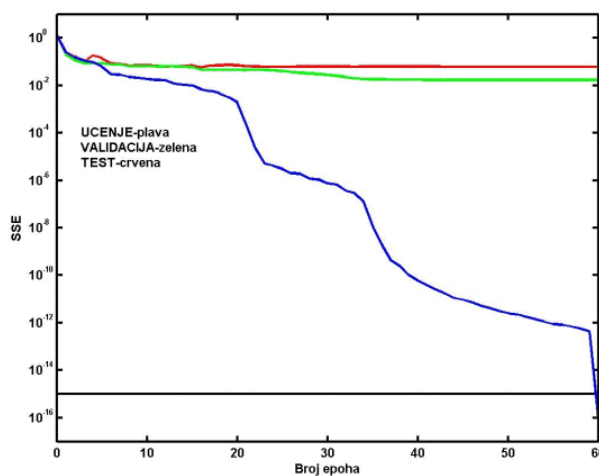
Nastavak: Tablica 4.16. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema HNO_3

Naziv mreže: NNHNO₃		Procjena izlaza						Algoritam: NNBMA					
Skup za učenje						Skup za testiranje							
<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p>						<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p>							
Indeksi uspješnosti													
Skup za učenje						Skup za testiranje							
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE		
HNO ₃	0.9930	5.6943	0.0428	0.2069	0.1178	HNO ₃	0.9940	2.5692	0.0383	0.1958	0.1096		

Tablica 4.17. Parametri i rezultati učenja *NNLM* mreže za procjenu postojanosti prema HNO_3

Naziv mreže: NNHNO₃			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hno_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hno_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				2
6.	br_neuro_lay1				8
7.	br_neuro_lay2				1
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig'
10.	fun_lay3				-
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad				0.000100
15.	mu				0.704793
16.	mu_inc				10.000000
17.	mu_dec				0.100000
18.	mu_max				10000000000
19.	W1_dat	'HNOW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'HNOW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HNOW3.txt'	10.	selectio_press	1
22.	B1_dat	'HNOB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HNOB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HNOB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

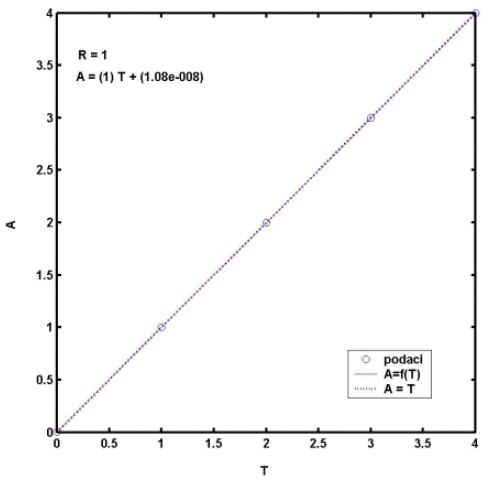
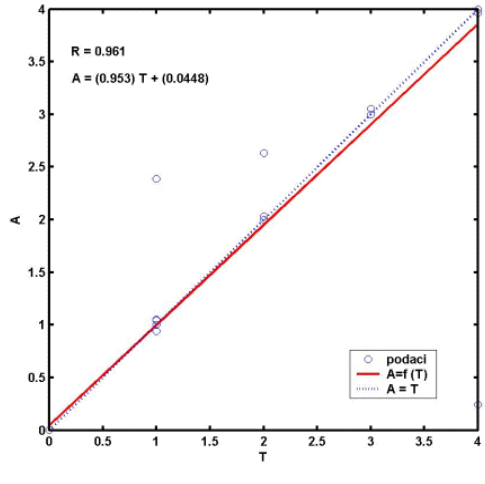
Matrice težina (*W*) i bias vektori (*B*)

```

W1----- B1-----
-1.0956e+000 -6.1587e-002 -8.3851e-001 -1.8001e+000 -1.3078e+000 7.5917e-001 -5.4933e+000 2.9627e+000 1.4316e+000
1.2644e+000 -1.1408e+000 5.9314e-001 8.9271e-001 1.1974e+000 9.4239e-001 -5.0708e-001 -1.3682e-001 -1.9563e+000
-9.7817e-001 -1.1768e-001 2.1136e-001 2.6626e+000 1.1260e+000 2.9657e-001 1.6623e+000 -1.0178e+000 -8.1326e-002
-2.0412e-004 -1.8018e-001 2.7524e+000 2.0682e-001 1.6374e+000 -3.5363e-001 -5.5415e+000 -4.8569e-001 5.2380e-001
-2.7213e-003 8.4897e-002 3.4360e+000 -4.3467e+000 5.2324e-001 -5.7397e-001 4.4897e+000 -5.0769e-001 1.4082e+000
-5.6723e-004 -8.3256e-002 1.2702e-001 -1.9764e+000 1.2755e-001 -1.5853e+000 8.4238e-001 1.4919e+000 -2.1100e+000
W2----- B2-----
1.7047e+000 8.6846e-001 1.7549e+000 3.2283e+000 1.7025e-002 1.4843e+000 -3.9951e+000
2.7242e-001 -2.6438e+000 -1.6004e+000 1.0794e+000 -1.1854e+000 -2.1413e+000 3.2632e+000
1.3174e-001 -2.4400e+000 -1.2292e+000 2.1905e+000 -3.5746e+000 -7.1543e-002 -2.0654e+000
4.2462e+000 -6.2794e-001 2.0152e+000 -5.1483e+000 7.5650e+000 1.9407e+000 -3.3242e+000
-2.3899e+000 -9.1271e-001 2.5783e+000 5.3464e+000 2.0028e+000 -4.0609e+000 1.3503e+000
6.1374e-001 8.0528e-001 4.2003e+000 -1.9747e+000 2.4644e-001 -1.5419e+000 1.5776e-001
1.3479e+000 1.4009e+000 2.2924e+000 -1.4703e+000 1.4321e+000 -1.7967e+000 1.0139e+000
1.2522e+000 -2.0499e+000 2.0572e+000 -1.0339e+000 -2.2511e-001 -2.3550e+000 2.5344e+000
1.8619e+000 1.3791e+000 1.5603e+000 7.3911e-001 7.1939e-001 -2.5041e+000 3.6596e+000
-1.8632e+000 6.5596e-001 2.6508e+000 2.5536e+000 1.0752e-001 5.1560e-001 -4.5768e+000
W3----- B3-----
1.2897e+000 7.6406e-001 -1.5042e+000 1.0192e+000 -9.1670e+000 -2.1658e+000 8.2205e-001 1.1999e+000 -1.3840e-001 -1.7347e+000 -8.3094e-001

```

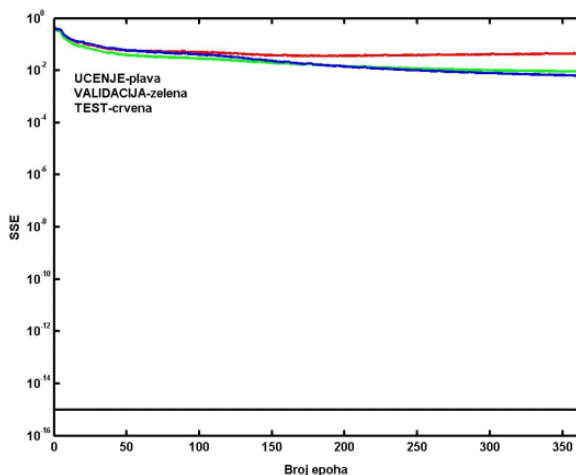
Nastavak: Tablica 4.17. Parametri i rezultati učenja NNLM mreže za procjenu postojanosti prema HNO₃

Naziv mreže: NNHNO ₃		Procjena izlaza					Algorithm: NNLM				
Skup za učenje						Skup za testiranje					
<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 						<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 					
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE
HNO ₃	1.0000	0.0000	0.0000	0.0000	0.0000	HNO ₃	0.9608	16.4402	0.2454	0.4954	0.2772

Tablica 4.18. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema H_3PO_4

Naziv mreže: NNH_3PO_4			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hpo_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hpo_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				9
7.	br_neuro_lay2				8
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig'
10.	fun_lay3				'tansig'
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.789554
15.	lr_inc	1.050000			
16.	lr_dec	0.70000			
17.	err_ratio	1.04			
18.	momentum				0.244581
19.	W1_dat	'HPOW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'HPOW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HPOW3.txt'	10.	selectio_press	1
22.	B1_dat	'HPOB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HPOB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HPOB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

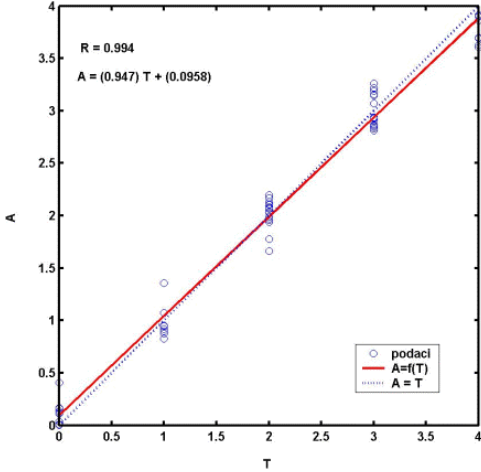
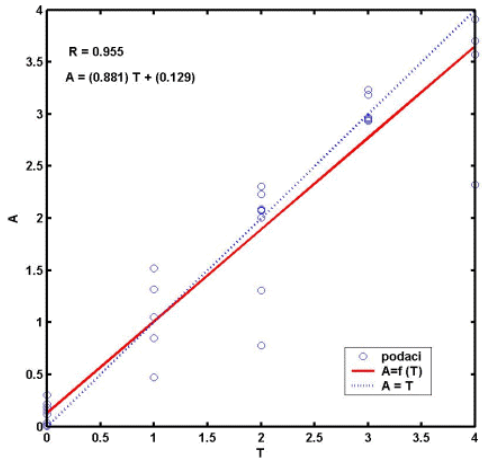
Matrice težina (*W*) i bias vektori (*B*)

```

W1-----B1-----
1.8193e-001 -1.2511e-002 9.6802e-001 -4.9152e-001 9.9827e-001 8.1986e-001 7.4483e-001 -4.1737e-001 -1.8932e+000
3.9682e-001 -4.5860e-002 -1.7100e-001 1.0750e+000 -8.0490e-001 9.2430e-001 8.1231e-001 -2.2483e-001 -1.4133e+000
2.0237e-001 2.0889e-002 7.3725e-001 -8.9284e-001 7.4186e-001 7.2216e-001 -1.0562e+000 6.1547e-001 -8.7561e-001
1.6588e-001 8.5815e-002 -1.4280e+000 -1.6738e-001 3.0924e-001 -7.5070e-001 -1.4982e+000 5.1484e-001 -3.3277e-001
4.0257e-001 5.8462e-002 4.1616e-001 3.0387e-001 7.5170e-001 7.4955e-001 5.8495e-001 1.2945e+000 1.5716e-001
6.0581e-001 -9.1952e-002 1.1658e+000 -5.6975e-001 -5.9602e-001 -2.4314e-001 5.1736e-001 1.2597e+000 5.1452e-001
8.6098e-001 -1.3285e-001 -9.8463e-001 -9.1857e-002 -5.0168e-001 6.1657e-001 7.6163e-001 1.1458e+000 9.9598e-001
-2.5721e-001 2.9313e-001 -9.2163e-001 -1.4176e-001 2.0809e-001 2.1214e-001 1.6361e+000 -1.2475e+000 -1.2067e+000
-1.1952e+000 3.2253e-002 8.0029e-001 2.8840e-001 2.6161e-002 9.4393e-001 8.9931e-001 -1.0088e+000 -2.1255e+000
W2-----B2-----
-3.9611e-001 -6.4117e-001 6.5009e-001 4.1449e-001 -4.8716e-001 -9.9881e-001 3.5458e-001 -6.6787e-001 -1.1140e-001
-2.5261e-001 7.6511e-001 9.8169e-001 6.3022e-001 7.1612e-001 7.0743e-001 9.2090e-002 8.9599e-001 -8.5043e-001
-6.0278e-001 -2.2705e-001 4.5783e-001 6.3584e-001 1.9756e-001 -6.3032e-001 7.9499e-001 1.0251e+000 2.0529e-001
3.2475e-001 4.1290e-001 6.0167e-001 4.5452e-002 5.7594e-001 -1.0776e+000 -2.4067e-001 -9.7511e-001 -4.9202e-001
6.6063e-001 -3.8562e-001 4.4502e-001 4.4155e-003 1.0828e+000 8.9438e-001 -2.8923e-002 -6.7036e-001 -2.0995e-001
-5.4074e-001 8.2706e-001 5.4552e-001 -6.1247e-001 -5.5514e-001 9.9790e-001 4.0018e-001 4.5796e-001 -4.6159e-001
-6.5634e-001 5.9095e-001 -4.3790e-001 -8.6514e-001 5.0256e-001 3.6331e-001 3.6777e-001 -1.0921e+000 7.4278e-001
-7.7073e-001 1.0885e-001 -9.6152e-001 1.0122e+000 -5.3147e-001 -1.9985e-001 -3.8556e-001 4.7380e-001 4.6044e-001
W3-----B3-----
-2.0032e-001 9.6611e-001 2.9900e-001 -1.2985e+000 7.8831e-002 -6.7507e-001 1.1834e+000 1.1820e+000 -1.1651e-001

```

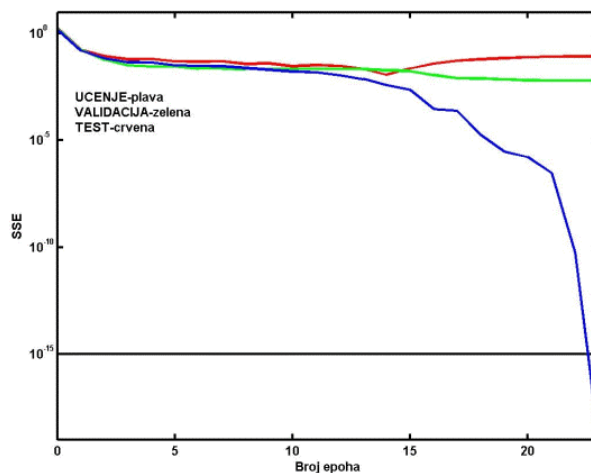
Nastavak: Tablica 4.18. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema H_3PO_4

Naziv mreže: NNH_3PO_4		Procjena izlaza					Algorithm: NNBMA				
Skup za učenje						Skup za testiranje					
<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 						<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 					
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE
H_3PO_4	0.9939	1.7874	0.0255	0.1598	0.1171	H_3PO_4	0.9550	6.2278	0.1779	0.4218	0.2970

Tablica 4.19. Parametri i rezultati učenja *NNLM* mreže za procjenu postojanosti prema H_3PO_4

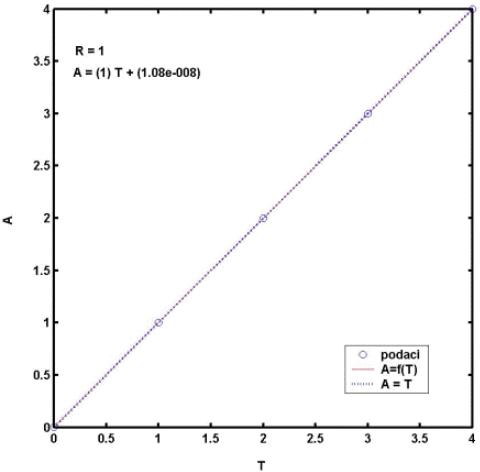
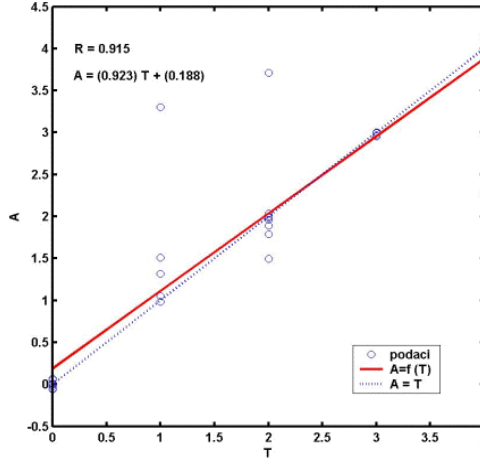
Naziv mreže: NNH_3PO_4			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hpo_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hpo_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_layer1				9
7.	br_neuro_layer2				7
8.	fun_layer1				'logsig'
9.	fun_layer2				'tansig'
10.	fun_layer3				'purelin'
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad	0.000100			
15.	mu				0.918161
16.	mu_inc	10.000000			
17.	mu_dec	0.100000			
18.	mu_max	10000000000			
19.	W1_dat	'HPOW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'HPOW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HPOW3.txt'	10.	selectio_press	1
22.	B1_dat	'HPOB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HPOB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HPOB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1-----	B1-----
2.4118e+000 9.0255e-002 -1.4436e+000 1.3760e+000 1.9036e+000 1.2596e+000 -1.5846e+000 -1.4647e+000	-3.2056e+000
-3.2059e-001 8.3775e-001 4.1797e-001 7.3360e-001 -2.2995e+000 -1.0816e+000 -4.6435e+000 2.8653e+000	3.3737e+000
2.4011e-001 1.1949e+000 2.1665e+000 4.6214e-001 2.8214e-002 4.7587e-001 -1.6289e+000 3.4362e+000	2.7901e+000
5.9952e-002 -5.6057e-002 7.2753e-001 -8.0612e-001 1.7046e+000 -2.1992e+000 -3.7800e+000 -2.4443e+000	-7.8542e-001
-6.2820e-001 7.7476e-001 1.9002e+000 -2.0707e+000 -4.3088e-001 -1.2372e+000 -9.2598e-001 2.9070e+000	5.0735e-001
-2.3952e-001 1.1386e-001 -1.3861e+000 -1.1228e+000 9.1085e-001 -1.2916e+000 2.1712e+000 1.8672e+000	-1.2601e+000
-4.9839e-001 4.6896e-001 7.4288e-001 2.4410e+000 -1.1013e+000 -2.6097e+000 -2.8461e-001 -2.1966e+000	-1.7701e+000
-2.3382e+000 -5.7331e-001 8.9203e-001 -3.3758e-001 3.9722e+000 5.8384e-001 -2.3877e+000 -1.2231e+000	-3.9712e+000
-7.4149e-001 5.7767e-002 1.5154e+000 9.4075e-001 -1.2152e+000 -2.2780e+000 -2.4220e+000 -5.5847e-001	-4.3046e+000
W2-----	B2-----
-3.3172e-001 2.2853e+000 -1.7928e+000 -4.6223e-001 2.1637e+000 1.0676e+000 -8.1647e-002 9.1072e-001 2.8050e-001	2.7864e-001
1.6652e+000 1.2290e+000 7.5651e-001 1.3248e+000 -1.7792e-001 -1.2835e+000 -1.7045e+000 -6.6228e-001 -1.0667e-001	-2.3403e+000
1.5925e+000 1.4654e+000 1.4948e+000 -2.3227e-001 4.0571e-001 -3.1411e+000 -6.1161e-001 5.2280e-001 2.1675e+000	-2.6671e+000
-9.7925e-001 -4.4682e-001 -2.2432e+000 -2.5333e+000 -9.2460e-001 1.2205e+000 1.4311e+000 6.1116e-001 -1.1550e+000	3.3027e+000
1.1066e-001 3.8668e+000 -1.9497e+000 2.6895e+000 -4.5088e-001 -1.3648e+000 -8.8942e-001 1.0229e+000 -9.2842e-001	-6.1225e-001
-9.0519e-001 -1.6173e+000 2.2950e+000 4.6742e-001 -1.5997e-001 5.7121e-001 -6.5317e-002 1.7158e-001 6.1396e-001	-1.4529e+000
-4.1304e-001 -7.6021e-001 3.5639e-001 3.8549e-001 -2.2213e+000 -1.0705e+000 -1.5711e+000 -8.5554e-001 1.6896e+000	-1.2647e+000
W3-----	B3-----
1.2197e+000 7.0784e-001 -4.8327e-001 1.1964e+000 6.3115e-001 1.0211e+000 4.7099e-001	-2.7319e-001

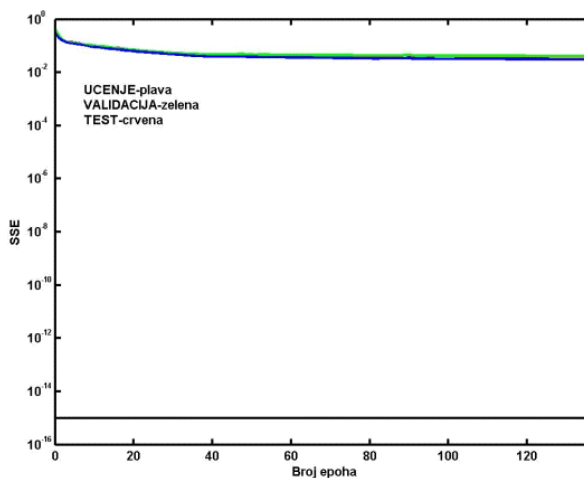
Nastavak: Tablica 4.19. Parametri i rezultati učenja *NNLM* mreže za procjenu postojanosti prema H_3PO_4

Naziv mreže: NNH₃PO₄						Procjena izlaza						Algoritam: NNLM					
<p style="text-align: center;">Skup za učenje</p> <p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 						<p style="text-align: center;">Skup za testiranje</p> <p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 											
Indeksi uspješnosti																	
Skup za učenje						Skup za testiranje											
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE						
H_3PO_4	1.0000	0.0000	0.0000	0.0000	0.0000	H_3PO_4	0.9149	11.9233	0.3407	0.5837	0.4110						

Tablica 4.20. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema H_2SO_4

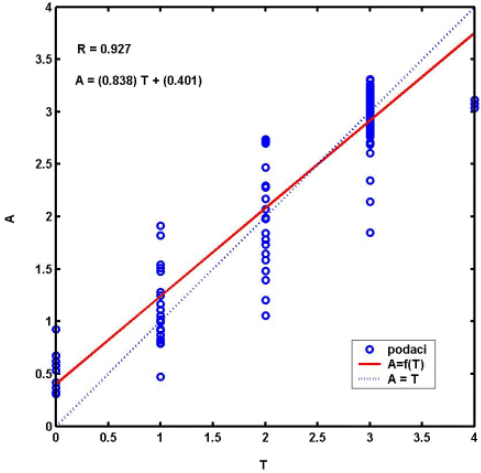
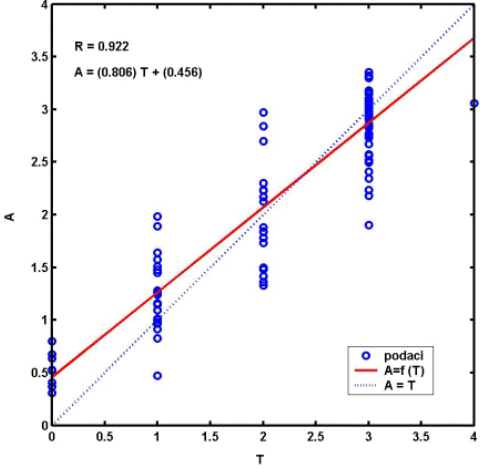
Naziv mreže: NNH_2SO_4			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hso_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hso_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_layer1				9
7.	br_neuro_layer2				7
8.	fun_layer1				'tansig'
9.	fun_layer2				'tansig'
10.	fun_layer3				'tansig'
11.	disp_freq		5.	broj_generacija	100
12.	max_epoch	100	6.	real_var_iznos	0
13.	err_goal	10000	7.	broj_individua	22
14.	lr				0.291655
15.	lr_inc	1.050000			
16.	lr_dec	0.70000			
17.	err_ratio	1.04			
18.	momentum				0.607293
19.	W1_dat		8.	broj_subpopulacija	6
20.	W2_dat	'HSOW1.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HSOW2.txt'	10.	selectio_press	1
22.	B1_dat	'HSOW3.txt'	11.	strukt_selekt	0
23.	B2_dat	'HSOB1.txt'	12.	migration_rate	0.25
24.	B3_dat	'HSOB2.txt'	13.	migration_strukt	0
25.	norm_ulaz	'HSOB3.txt'	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1-----	B1-----
2.6828e-001 -1.0003e-001 -2.6447e-001 -5.7541e-001 -9.0700e-001 -1.2380e+000 3.0180e-001 -6.4052e-001	-1.9683e+000
9.0529e-001 -2.2144e-001 1.2628e+000 4.0324e-002 1.1111e-001 1.4972e-001 -1.3419e+000 -8.4617e-002	-1.4775e+000
-1.3260e+000 -2.2135e-002 6.2257e-001 9.4522e-002 8.4120e-002 -1.1438e+000 -9.8515e-001 -1.3919e-001	6.5310e-001
5.0039e-001 -1.1377e-002 -8.2904e-001 3.6237e-001 8.1078e-001 -6.4641e-001 6.7965e-001 1.0461e+000	-3.3299e-001
3.6656e-001 1.9957e-002 -6.6888e-001 -6.4752e-001 -7.5718e-001 8.6789e-001 9.8335e-001 6.4825e-001	7.2746e-002
-8.5924e-001 -2.3975e-001 -1.1541e+000 -4.6874e-001 6.9520e-001 8.3881e-001 2.7877e-001 -1.9280e-001	-9.5255e-001
4.0790e-001 -1.6180e-001 -1.0515e+000 3.6813e-001 1.0781e+000 6.8001e-001 3.7692e-001 9.9193e-001	8.4284e-001
-6.4725e-001 -2.5132e-001 -4.3673e-001 7.4169e-001 2.6870e-001 3.4200e-001 1.5984e+000 -8.7258e-002	-1.8503e+000
-5.9846e-001 2.4964e-001 8.8648e-001 8.8346e-001 -6.5755e-001 -7.0586e-001 -6.5537e-001 1.0383e+000	-1.7613e+000
W2-----	B2-----
-3.7317e-001 1.6059e-002 -1.1518e-001 -1.7886e-001 8.8645e-001 -6.6079e-001 -9.6457e-001 -7.3198e-001	3.4788e-001
-4.6581e-001 -6.3403e-001 6.3307e-001 8.7037e-001 9.0042e-001 -2.6606e-001 -7.0546e-001 -2.0504e-002	4.6219e-001
-1.1016e+000 -2.0930e-001 2.1696e-001 -3.8008e-001 6.0913e-001 5.2879e-001 -7.3696e-001 2.2204e-001	-4.8026e-001
-1.0090e+000 2.9115e-001 3.4778e-001 5.6979e-001 3.0123e-001 -6.2918e-001 -1.5512e-002 8.7485e-001	3.4809e-001
2.1086e-001 1.0258e+000 6.9209e-001 9.7074e-001 3.5930e-001 2.8686e-001 -2.7980e-001 4.4300e-001	1.8974e-001
2.5595e-002 1.3933e+000 -2.9530e-002 2.8760e-001 -3.4247e-002 -1.8820e-001 -1.6790e-001 1.2247e+000	-3.8119e-001
-7.0305e-001 -7.0328e-001 2.2039e-001 3.6345e-002 4.6922e-001 -5.8742e-001 1.1858e+000 1.4021e-001	6.1588e-001
W3-----	B3-----
-8.8745e-002 6.4786e-001 2.0672e-001 -6.3533e-001 -1.0710e-001 -4.6790e-001 7.5786e-001 -3.5545e-001	

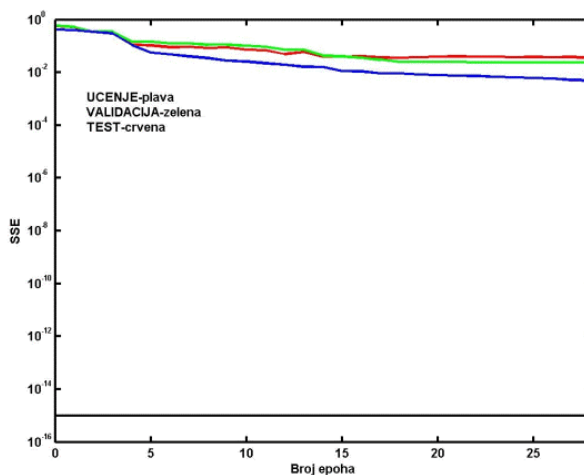
Nastavak: Tablica 4.20. Parametri i rezultati učenja *NNBMA* mreže za procjenu postojanosti prema H_2SO_4

Naziv mreže: NNH_2SO_4		Procjena izlaza					Algoritam: <i>NNBMA</i>				
Skup za učenje						Skup za testiranje					
<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 						<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 					
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE
H_2SO_4	0.9274	25.7582	0.1227	0.3502	0.3740	H_2SO_4	0.9218	16.5390	0.1575	0.3969	0.3895

Tablica 4.21. Parametri i rezultati učenja *NNLM* mreže za procjenu postojanosti prema H_2SO_4

Naziv mreže: NNH_2SO_4			Algoritam: <i>NNLM</i>		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hso_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hso_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				8
7.	br_neuro_lay2				8
8.	fun_lay1				'logsig'
9.	fun_lay2				'tansig'
10.	fun_lay3				'tansig'
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad	0.000100			
15.	mu				0.006675
16.	mu_inc	10.000000			
17.	mu_dec	0.100000			
18.	mu_max	10000000000			
19.	W1_dat	'HSOW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'HSOW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HSOW3.txt'	10.	selectio_press	1
22.	B1_dat	'HSOB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HSOB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HSOB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

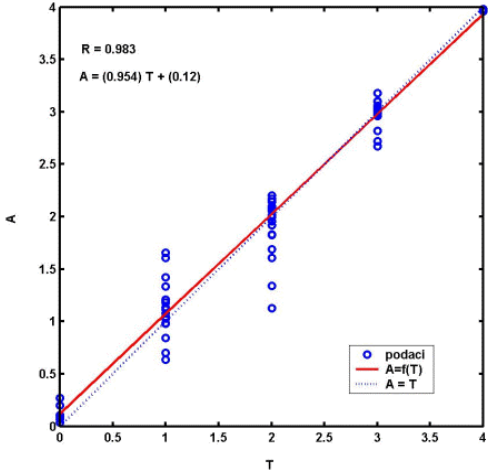
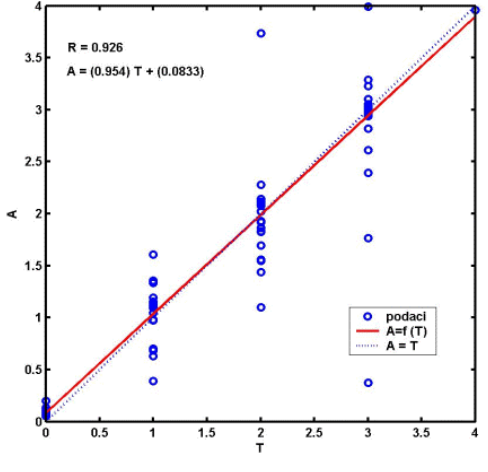
Matrice težina (*W*) i bias vektori (*B*)

```

W1-----B1-----
1.3231e-001 6.4133e-001 -2.0667e+000 4.6004e-001 -1.3103e+000 -2.4224e-001 -1.4303e+000 7.1726e-001 -1.1751e+000
-1.0349e+000 -2.8466e-001 -6.8811e-001 -9.8643e-001 -3.9725e-001 -2.6632e-001 -1.9601e+000 -2.1439e+000 7.4555e-001
-1.2013e+000 1.2014e-001 1.0629e+000 -8.3218e-001 8.3712e-001 -1.0333e+000 -3.3480e+000 1.7490e+000 6.6222e-001
7.2263e-002 -5.2307e-002 7.1180e-001 -3.6631e-002 -3.2182e-001 2.6243e+000 3.7598e+000 -5.6868e-001 -2.0891e-001
6.8848e-001 3.8158e-001 1.6265e+000 3.7068e-001 1.1825e+000 -5.2391e-001 3.3742e+000 -1.3077e+000 8.7156e-001
1.3730e-001 -4.8019e-001 -9.3084e-001 3.8487e-001 -1.0316e+000 1.3867e+000 1.4446e+000 -3.9995e-001 -1.3350e+000
1.0072e+000 -2.1463e-001 -3.4188e-001 -2.0526e+000 -4.6433e-002 4.6075e-001 8.5762e-001 8.7881e-001 1.2912e+000
-1.0639e+000 -1.1384e-001 -8.8459e-001 6.2593e-001 -6.6441e-002 1.2314e+000 1.7363e-001 -9.7541e-001 -2.2834e+000
W2-----B2-----
-2.6918e-001 -1.6612e+000 7.7673e-001 1.0820e+000 -6.4058e-001 1.2199e-001 1.5035e-001 5.2907e-002 1.8153e+000
-1.1015e-001 -9.4349e-001 3.8119e-001 -2.1269e+000 -1.1554e+000 6.2754e-001 -4.0036e-001 -4.6990e-001 1.2416e+000
-1.1054e+000 3.2525e-001 1.8406e+000 -5.5562e-001 2.2752e+000 1.3499e+000 5.2142e-001 1.6435e+000 9.6004e-001
-6.9032e-001 7.2447e-001 8.1913e-001 -9.2699e-001 6.0802e-001 -2.1371e+000 1.0619e+000 -1.7514e+000 6.9978e-001
1.2141e+000 -1.5371e+000 8.8179e-001 1.5971e-001 -5.6426e-001 6.3133e-001 1.5228e-001 6.3869e-001 4.1847e-001
-7.9485e-001 2.3957e-001 8.6562e-001 -1.3836e+000 1.0309e-001 -9.8707e-001 -5.6243e-001 -3.8787e-001 -1.6442e-001
1.2745e+000 -1.4835e+000 -6.2544e-001 3.0456e+000 1.8854e-001 -1.5343e+000 -1.2898e-002 -2.2079e+000 2.0205e+000
4.8775e-001 1.7126e-001 1.1420e+000 -1.7060e+000 1.4144e-001 -7.7220e-002 -1.3862e+000 -9.6387e-001 2.3394e+000
W3-----B3-----
-1.1377e+000 3.3500e-001 8.2996e-001 2.0711e+000 1.1247e+000 -5.4718e-002 1.5928e+000 -2.0245e+000 -5.3084e-001

```

Nastavak: Tablica 4.21. Parametri i rezultati učenja *NNLM* mreže za procjenu postojanosti prema H_2SO_4

Naziv mreže: NNH₂SO₄		Procjena izlaza					Algorithm: NNLM				
Skup za učenje						Skup za testiranje					
<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 						<p><i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i></p> 					
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Postojanost	R	SSE	MSE	RMSE	NRMSE	Postojanost	R	SSE	MSE	RMSE	NRMSE
H ₂ SO ₄	0.9833	6.1245	0.0292	0.1708	0.1824	H ₂ SO ₄	0.9259	16.6072	0.1582	0.3997	0.3903

4.4.9. Procjena otpornosti trošenja abraziji gubitkom volumena

Na slici 4.24 prikazan je dio rezultata laboratorijskog ispitivanja abrazivnog trošenja gubitkom volumena prema standardu ASTM G65 [46]. Otpornost čelika je to veća što je gubitak volumena GV manji. Iako ispitivanje ne simulira sve moguće parametre koji utječu na proces trošenja, kao što su vrsta, veličina, oblik abraziva, naprezanje, udarno i korozivno djelovanje itd., ono omogućava 'relativno' rangiranje različitih materijala u abrazivnoj okolini, što je vrlo važno, jer se na taj način može predvidjeti međusoban odnos (rang) otpornosti čelika abraziji koji je u velikoj mjeri sličan otpornosti u realnom tribosustavu. Kao ulazni skup podataka za učenje procjene otpornosti abraziji gubitka volumena jesu podaci o kemijskom sastavu (C, Si, Mn, Cr, Ni, Mo, W, V) i temperatura popuštanja (T_{pop}) dok izlazni skup čine podaci mjerenja gubitka volumena GV , mm^3 .

Oznaka	C	Si	Mn	Cr	Ni	Mo	W	V	%Le	T_A °C	T_{pop} °C	GV mm^3
Č1940 C105W1	1,0	0,2	0,3	0,0	0,0	0,0	0,0	0,0	0,45	788	0	61,05
											149	64,35
											177	66,55
											316	93,20
											371	104,60
440	116,60											
Č3840 90MnV8	0,9	0,0	2,0	0,3	0,0	0,0	0,0	0,1	2,40	802	0	59,50
											204	70,60
											316	98,55
											371	104,60
468	118,65											

Slika 4.24. Rezultati ispitivanja otpornosti trošenja abraziji gubitkom volumena GV (izvod iz tablice P1.43 u prilogu I)

ULAZNI SKUP									IZLAZNI SKUP
C	Si	Mn	Cr	Ni	Mo	W	V	T_{pop} °C	GV mm^3
1,0	0,2	0,3	0,0	0,0	0,0	0,0	0,0	0	61,05
1,0	0,2	0,3	0,0	0,0	0,0	0,0	0,0	149	64,35
1,0	0,2	0,3	0,0	0,0	0,0	0,0	0,0	177	66,55
1,0	0,2	0,3	0,0	0,0	0,0	0,0	0,0	316	93,20
1,0	0,2	0,3	0,0	0,0	0,0	0,0	0,0	371	104,60
1,0	0,2	0,3	0,0	0,0	0,0	0,0	0,0	440	116,60
0,9	0,0	2,0	0,3	0,0	0,0	0,0	0,1	0	59,50
0,9	0,0	2,0	0,3	0,0	0,0	0,0	0,1	204	70,60
0,9	0,0	2,0	0,3	0,0	0,0	0,0	0,1	316	98,55
0,9	0,0	2,0	0,3	0,0	0,0	0,0	0,1	371	104,60
0,9	0,0	2,0	0,3	0,0	0,0	0,0	0,1	468	118,65
2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	0	24,65
2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	149	23,95
2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	204	28,95
2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	316	30,15
2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	482	31,70
2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	552	39,10
2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	593	48,25
2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	649	64,35

Slika 4.25. Primjer dijela mapiranja ulazno-izlaznog skupa za učenje otpornosti trošenja abraziji gubitkom volumena (izvod iz tablice P1.43 u prilogu I)

Na slici 4.25 prikazano je mapiranje ulazno-izlaznog skupa za učenje. Kao što se vidi, jednom kemijskom sastavu odgovara više različitih temperatura popuštanja T_p . U nastavku su prikazane tablice sa parametrima korištenih tipova mreža, te rezultati učenja i testiranja.

Tablica 4.22. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti trošenja abraziji gubitkom volumena

Naziv mreže: NNGV			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'gv_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	9	2.	alg_selekcije	0
3.	izlaz_dat	'gv_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_layer1				9
7.	br_neuro_layer2				9
8.	fun_layer1				'purelin'
9.	fun_layer2				'tansig'
10.	fun_layer3				'purelin'
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.026642
15.	lr_inc	1.050000			
16.	lr_dec	0.700000			
17.	err_ratio	1.04			
18.	momentum				0.644681
19.	W1_dat	'GVW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'GVW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'GVW3.txt'	10.	selectio_press	1
22.	B1_dat	'GVB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'GVB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'GVB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha	

Matrice težina (<i>W</i>) i bias vektori (<i>B</i>)	
W1-----	B1-----
-4.8517e-001 -7.7858e-001 3.2717e-001 -6.1622e-002 5.6418e-002 1.5666e-001 8.6975e-001 -7.0027e-001 9.9263e-001 -8.6810e-001	
5.6956e-001 6.5081e-001 6.4641e-001 8.9284e-001 -6.2695e-001 9.4384e-001 -7.4015e-001 1.0187e-001 2.3108e-001 7.0671e-001	
-4.0506e-001 7.0156e-001 -5.5839e-001 -5.8534e-001 -1.0204e-001 -9.8088e-001 1.5889e-002 4.2730e-001 -5.3788e-001 -5.2423e-001	
2.3392e-001 -6.1738e-001 -2.5004e-002 7.1801e-001 -6.8520e-002 7.5981e-001 7.6241e-001 -1.7252e-001 4.1544e-001 -9.8427e-001	
9.4377e-001 -7.1985e-001 -5.3394e-001 2.7183e-001 3.7457e-001 -9.0069e-001 9.8894e-001 -2.8316e-001 4.0720e-001 4.2249e-001	
1.4901e-001 4.6651e-001 -7.6643e-001 7.0354e-001 2.7135e-001 5.5195e-002 -2.8261e-001 -4.9661e-001 -8.8775e-001 6.4140e-002	
9.4401e-001 3.3760e-001 -8.8701e-001 -3.3736e-002 8.1719e-001 -6.9629e-001 -1.1628e-001 6.3833e-001 -9.2624e-001 -3.7588e-001	
7.7035e-001 3.7443e-001 7.1987e-001 1.0748e+000 -5.5951e-001 4.3567e-001 5.2145e-002 2.3394e-001 -4.7103e-001 -3.7685e-001	
8.1345e-001 5.9288e-001 -3.5683e-001 -2.0422e-001 -7.1167e-001 -5.3663e-001 -7.3885e-001 -5.1102e-001 -7.4741e-001 -1.0331e+000	
W2-----	B2-----
8.8404e-001 1.4614e-001 -2.7042e-001 -9.4718e-001 -7.6559e-001 3.4934e-001 -1.2205e-001 2.7807e-001 8.2084e-001 -1.7798e+000	
6.6609e-001 7.6279e-001 -5.3236e-002 -4.3944e-001 6.5236e-001 -7.4049e-001 -7.0718e-001 3.0380e-001 -3.9604e-001 -1.4001e+000	
-7.3063e-001 8.6195e-001 -3.6438e-002 -1.4651e-001 -4.6634e-001 1.0801e+000 -4.0054e-001 5.1808e-001 3.9669e-001 8.2438e-001	
3.2769e-001 -8.4703e-001 1.7560e-001 -3.6988e-002 6.5322e-001 6.1257e-001 8.2844e-001 5.2133e-001 -8.0549e-001 -4.9378e-001	
-7.0394e-001 6.8030e-001 -6.6468e-001 -9.1845e-001 -1.7270e-001 4.1583e-001 7.1323e-001 3.9469e-002 -4.7463e-001 -6.7641e-003	
2.6841e-001 -6.1804e-001 -9.8678e-001 1.0574e+000 -1.9531e-001 -1.3033e-002 -1.9724e-001 5.6529e-001 6.2159e-001 3.4839e-001	
-3.9803e-001 2.7638e-001 7.0450e-001 -7.4124e-001 2.0235e-001 -8.0535e-001 9.9260e-001 6.8969e-003 3.9421e-001 -8.9175e-001	
3.0707e-001 4.7080e-001 8.5105e-003 -3.0065e-001 -7.6785e-001 8.5116e-001 -2.1789e-002 2.8569e-001 -1.1849e+000 1.3753e+000	
8.1719e-001 6.1242e-001 -6.4357e-001 -4.0052e-001 7.9978e-002 -6.7228e-001 1.5853e-001 1.0554e+000 1.6571e-001 1.7765e+000	
W3-----	B3-----
-1.2572e-001 5.2347e-001 -5.9980e-001 -5.5958e-001 -1.5991e-001 8.9931e-001 8.8465e-001 4.6593e-001 -2.4558e-001 3.7329e-001	

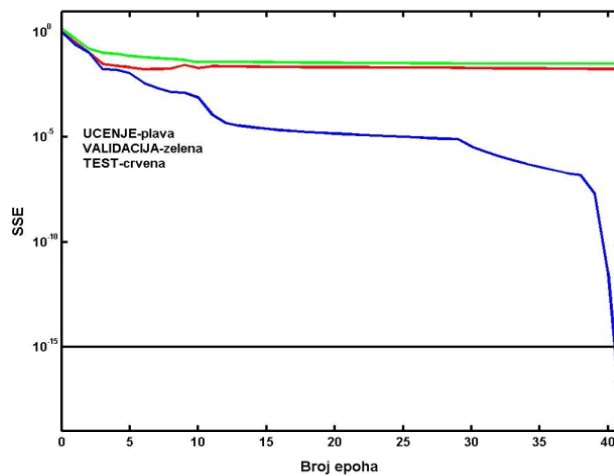
Nastavak: Tablica 4.22. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti trošenja abraziji gubitkom volumena

Naziv mreže: NNGV						Procjena izlaza						Algoritam: NNBMA																																																																																	
Skup za učenje						Skup za testiranje																																																																																							
<table border="1"> <thead> <tr> <th>T</th> <th>A</th> </tr> </thead> <tbody> <tr><td>61.0500</td><td>59.6564</td></tr> <tr><td>104.6000</td><td>105.1096</td></tr> <tr><td>98.5500</td><td>99.6773</td></tr> <tr><td>23.9500</td><td>25.4920</td></tr> <tr><td>39.1000</td><td>41.5401</td></tr> <tr><td>127.0000</td><td>128.8760</td></tr> <tr><td>57.7500</td><td>60.3059</td></tr> <tr><td>83.4000</td><td>84.8387</td></tr> <tr><td>25.8000</td><td>26.4452</td></tr> <tr><td>77.7500</td><td>63.1168</td></tr> <tr><td>56.8500</td><td>55.0631</td></tr> <tr><td>75.2300</td><td>76.0943</td></tr> <tr><td>81.7000</td><td>81.8614</td></tr> <tr><td>66.5500</td><td>69.0371</td></tr> <tr><td>59.5000</td><td>59.7962</td></tr> <tr><td>118.6500</td><td>119.2518</td></tr> <tr><td>30.1500</td><td>32.2127</td></tr> <tr><td>64.3500</td><td>64.4710</td></tr> <tr><td>144.7000</td><td>143.3393</td></tr> <tr><td>62.2500</td><td>60.4818</td></tr> <tr><td>59.9000</td><td>60.1118</td></tr> <tr><td>41.5500</td><td>58.4020</td></tr> <tr><td>36.1500</td><td>37.4390</td></tr> <tr><td>57.8000</td><td>59.8545</td></tr> <tr><td>118.1000</td><td>118.4618</td></tr> <tr><td>113.7500</td><td>114.3217</td></tr> </tbody> </table>						T	A	61.0500	59.6564	104.6000	105.1096	98.5500	99.6773	23.9500	25.4920	39.1000	41.5401	127.0000	128.8760	57.7500	60.3059	83.4000	84.8387	25.8000	26.4452	77.7500	63.1168	56.8500	55.0631	75.2300	76.0943	81.7000	81.8614	66.5500	69.0371	59.5000	59.7962	118.6500	119.2518	30.1500	32.2127	64.3500	64.4710	144.7000	143.3393	62.2500	60.4818	59.9000	60.1118	41.5500	58.4020	36.1500	37.4390	57.8000	59.8545	118.1000	118.4618	113.7500	114.3217	<table border="1"> <thead> <tr> <th>T</th> <th>A</th> </tr> </thead> <tbody> <tr><td>64.3500</td><td>66.6363</td></tr> <tr><td>116.6000</td><td>124.9637</td></tr> <tr><td>104.6000</td><td>107.3274</td></tr> <tr><td>28.9500</td><td>29.6889</td></tr> <tr><td>48.2500</td><td>51.0969</td></tr> <tr><td>136.0500</td><td>102.1871</td></tr> <tr><td>61.2500</td><td>61.6352</td></tr> <tr><td>107.7000</td><td>101.3249</td></tr> <tr><td>27.9500</td><td>27.3872</td></tr> <tr><td>39.3500</td><td>65.5060</td></tr> <tr><td>57.4000</td><td>61.4601</td></tr> <tr><td>106.3000</td><td>75.0477</td></tr> <tr><td>81.3000</td><td>96.1515</td></tr> </tbody> </table>						T	A	64.3500	66.6363	116.6000	124.9637	104.6000	107.3274	28.9500	29.6889	48.2500	51.0969	136.0500	102.1871	61.2500	61.6352	107.7000	101.3249	27.9500	27.3872	39.3500	65.5060	57.4000	61.4601	106.3000	75.0477	81.3000	96.1515
T	A																																																																																												
61.0500	59.6564																																																																																												
104.6000	105.1096																																																																																												
98.5500	99.6773																																																																																												
23.9500	25.4920																																																																																												
39.1000	41.5401																																																																																												
127.0000	128.8760																																																																																												
57.7500	60.3059																																																																																												
83.4000	84.8387																																																																																												
25.8000	26.4452																																																																																												
77.7500	63.1168																																																																																												
56.8500	55.0631																																																																																												
75.2300	76.0943																																																																																												
81.7000	81.8614																																																																																												
66.5500	69.0371																																																																																												
59.5000	59.7962																																																																																												
118.6500	119.2518																																																																																												
30.1500	32.2127																																																																																												
64.3500	64.4710																																																																																												
144.7000	143.3393																																																																																												
62.2500	60.4818																																																																																												
59.9000	60.1118																																																																																												
41.5500	58.4020																																																																																												
36.1500	37.4390																																																																																												
57.8000	59.8545																																																																																												
118.1000	118.4618																																																																																												
113.7500	114.3217																																																																																												
T	A																																																																																												
64.3500	66.6363																																																																																												
116.6000	124.9637																																																																																												
104.6000	107.3274																																																																																												
28.9500	29.6889																																																																																												
48.2500	51.0969																																																																																												
136.0500	102.1871																																																																																												
61.2500	61.6352																																																																																												
107.7000	101.3249																																																																																												
27.9500	27.3872																																																																																												
39.3500	65.5060																																																																																												
57.4000	61.4601																																																																																												
106.3000	75.0477																																																																																												
81.3000	96.1515																																																																																												
Indeksi uspešnosti																																																																																													
Skup za učenje						Skup za testiranje																																																																																							
Trošenje	R	SSE	MSE	RMSE	NRMSE	Trošenje	R	SSE	MSE	RMSE	NRMSE																																																																																		
GV	0.9901	548.6964	21.1037	4.5939	0.1395	GV	0.8923	3177	244.3821	15.6327	0.4370																																																																																		

Tablica 4.23. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti trošenja abraziji gubitkom volumena

Naziv mreže: NNGV			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'gv_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	9	2.	alg_selekcije	0
3.	izlaz_dat	'gv_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				9
7.	br_neuro_lay2				9
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig'
10.	fun_lay3				'tansig'
11.	disp_freq	100	5.	broj_generacija	100
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad	0.000100			
15.	mu				0.300376
16.	mu_inc	10.000000			
17.	mu_dec	0.100000			
18.	mu_max	10000000000			
19.	W1_dat	'GVW1.txt'	8.	broj_subpopulacija	6
20.	W2_dat	'GVW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'GVW3.txt'	10.	selectio_press	1
22.	B1_dat	'GVB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'GVB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'GVB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1	-8.3849e-001	7.9054e-001	1.0478e-001	-6.2026e-001	2.4932e-001	-1.1001e+000	5.2683e-001	5.7958e-001	-2.9210e-001	B1	1.7767e+000
	1.3367e+000	2.0698e-001	-1.2933e+000	2.3308e-001	-3.4141e-001	-3.0740e-001	-1.0510e+000	-6.4953e-001	-5.2432e-001		-1.0715e+000
	-1.7169e-001	-4.2649e-001	-4.7866e-001	1.3354e-001	-6.6641e-001	-4.9375e-001	-1.1637e+000	7.7407e-001	2.4340e-001		9.0277e-001
	6.6324e-001	-2.7410e-001	4.9334e-001	1.2383e+000	4.1835e-001	-6.2650e-001	-2.0823e-001	1.1124e+000	1.2329e+000		-6.7706e-001
	-5.9939e-001	4.2046e-001	-3.1852e-001	6.7042e-001	-2.0936e-001	-1.0469e-001	-9.7767e-001	5.4440e-001	-1.2957e+000		4.3848e-002
	1.1464e+000	-7.4732e-001	-1.3328e-001	7.4475e-001	-1.3724e-001	6.1672e-001	1.4300e-001	2.3010e-001	1.1186e+000		6.3838e-001
	-2.1139e-001	-4.9070e-001	-2.1004e-001	4.3931e-001	5.5507e-001	1.2771e+000	4.2574e-002	8.3024e-001	-7.0838e-002		6.4156e-001
	-1.2576e-001	-6.1420e-001	-4.0424e-001	-8.7936e-001	3.3950e-001	-1.1845e+000	2.7283e-001	6.3407e-001	1.4768e+000		-1.5005e+000
	6.9216e-001	-6.5478e-001	5.2827e-001	6.9386e-001	2.9876e-001	2.7750e-001	-8.0837e-001	-5.6175e-001	5.2196e-001		1.7909e+000
W2	5.3790e-001	4.1739e-001	7.8707e-001	-3.3630e-001	-7.0263e-001	9.4109e-001	-5.4787e-001	-2.4613e-002	-3.7003e-001	B2	-1.9920e+000
	-7.1404e-001	-2.0199e-001	-3.4667e-001	-3.7328e-001	-8.5096e-001	-1.2215e+000	1.3153e-001	4.7891e-001	-7.2275e-001		1.3345e+000
	-1.4462e+000	-8.6140e-001	-1.0759e-001	-9.4133e-002	-2.5089e-001	-9.7798e-001	-7.0953e-001	-3.9644e-001	4.5565e-001		7.7762e-001
	8.1698e-002	-8.0546e-001	4.6499e-001	4.9072e-001	-3.2152e-001	-1.0185e+000	2.0375e-001	1.2428e+000	-3.8977e-001		-2.3873e-001
	-6.7217e-001	5.7043e-001	8.1247e-002	-4.3238e-001	1.0013e+000	-1.8253e-001	-3.7274e-002	4.3596e-001	1.2023e+000		2.2545e-001
	-4.5869e-001	-3.4710e-001	-3.8646e-001	1.4324e+000	-5.2427e-001	-3.6291e-001	4.2971e-001	1.3928e+000	-8.3371e-001		2.9405e-001
	-5.1000e-001	-7.2469e-001	-2.0194e-001	4.2418e-001	6.0066e-001	-9.7639e-001	-7.7163e-001	-9.5084e-003	-8.8147e-001		-1.0675e+000
	7.0522e-001	6.1032e-001	3.7485e-001	1.6753e+000	-7.4908e-001	-1.0922e+000	4.1038e-003	5.5314e-002	2.0702e-001		-1.0675e+000
	6.1847e-001	8.7848e-001	3.3497e-001	-9.0954e-002	1.1311e-001	4.7850e-001	6.9042e-001	1.9996e-001	-9.4063e-001		1.4514e+000
W3	-5.1354e-001	3.5149e-001	-9.9501e-001	9.4618e-001	8.8352e-001	1.0993e+000	4.2879e-001	1.3992e+000	-2.2558e-001	B3	2.2693e-002

Nastavak: Tablica 4.23. Parametri i rezultati učenja NNLM mreže za procjenu otpornosti trošenja abraziji gubitkom volumena

Naziv mreže: NNGV					Procjena izlaza					Algoritam: NNLM																																																																																	
Skup za učenje										Skup za testiranje																																																																																	
<table border="1" style="margin: auto;"> <thead> <tr><th>T</th><th>A</th></tr> </thead> <tbody> <tr><td>61.0500</td><td>61.0500</td></tr> <tr><td>104.6000</td><td>104.6000</td></tr> <tr><td>98.5500</td><td>98.5500</td></tr> <tr><td>23.9500</td><td>23.9500</td></tr> <tr><td>39.1000</td><td>39.1000</td></tr> <tr><td>127.0000</td><td>127.0000</td></tr> <tr><td>57.7500</td><td>57.7500</td></tr> <tr><td>83.4000</td><td>83.4000</td></tr> <tr><td>25.8000</td><td>25.8000</td></tr> <tr><td>77.7500</td><td>77.7500</td></tr> <tr><td>56.8500</td><td>56.8500</td></tr> <tr><td>75.2300</td><td>75.2300</td></tr> <tr><td>81.7000</td><td>81.7000</td></tr> <tr><td>66.5500</td><td>66.5500</td></tr> <tr><td>59.5000</td><td>59.5000</td></tr> <tr><td>118.6500</td><td>118.6500</td></tr> <tr><td>30.1500</td><td>30.1500</td></tr> <tr><td>64.3500</td><td>64.3500</td></tr> <tr><td>144.7000</td><td>144.7000</td></tr> <tr><td>62.2500</td><td>62.2500</td></tr> <tr><td>59.9000</td><td>59.9000</td></tr> <tr><td>41.5500</td><td>41.5500</td></tr> <tr><td>36.1500</td><td>36.1500</td></tr> <tr><td>57.8000</td><td>57.8000</td></tr> <tr><td>118.1000</td><td>118.1000</td></tr> <tr><td>113.7500</td><td>113.7500</td></tr> </tbody> </table>					T	A	61.0500	61.0500	104.6000	104.6000	98.5500	98.5500	23.9500	23.9500	39.1000	39.1000	127.0000	127.0000	57.7500	57.7500	83.4000	83.4000	25.8000	25.8000	77.7500	77.7500	56.8500	56.8500	75.2300	75.2300	81.7000	81.7000	66.5500	66.5500	59.5000	59.5000	118.6500	118.6500	30.1500	30.1500	64.3500	64.3500	144.7000	144.7000	62.2500	62.2500	59.9000	59.9000	41.5500	41.5500	36.1500	36.1500	57.8000	57.8000	118.1000	118.1000	113.7500	113.7500	<table border="1" style="margin: auto;"> <thead> <tr><th>T</th><th>A</th></tr> </thead> <tbody> <tr><td>64.3500</td><td>64.6186</td></tr> <tr><td>116.6000</td><td>123.9124</td></tr> <tr><td>104.6000</td><td>109.6616</td></tr> <tr><td>28.9500</td><td>24.7514</td></tr> <tr><td>48.2500</td><td>44.0641</td></tr> <tr><td>136.0500</td><td>103.7846</td></tr> <tr><td>61.2500</td><td>61.3398</td></tr> <tr><td>107.7000</td><td>96.8645</td></tr> <tr><td>27.9500</td><td>24.4361</td></tr> <tr><td>39.3500</td><td>30.5427</td></tr> <tr><td>57.4000</td><td>56.9779</td></tr> <tr><td>106.3000</td><td>93.1819</td></tr> <tr><td>81.3000</td><td>81.5457</td></tr> </tbody> </table>					T	A	64.3500	64.6186	116.6000	123.9124	104.6000	109.6616	28.9500	24.7514	48.2500	44.0641	136.0500	103.7846	61.2500	61.3398	107.7000	96.8645	27.9500	24.4361	39.3500	30.5427	57.4000	56.9779	106.3000	93.1819	81.3000	81.5457
T	A																																																																																										
61.0500	61.0500																																																																																										
104.6000	104.6000																																																																																										
98.5500	98.5500																																																																																										
23.9500	23.9500																																																																																										
39.1000	39.1000																																																																																										
127.0000	127.0000																																																																																										
57.7500	57.7500																																																																																										
83.4000	83.4000																																																																																										
25.8000	25.8000																																																																																										
77.7500	77.7500																																																																																										
56.8500	56.8500																																																																																										
75.2300	75.2300																																																																																										
81.7000	81.7000																																																																																										
66.5500	66.5500																																																																																										
59.5000	59.5000																																																																																										
118.6500	118.6500																																																																																										
30.1500	30.1500																																																																																										
64.3500	64.3500																																																																																										
144.7000	144.7000																																																																																										
62.2500	62.2500																																																																																										
59.9000	59.9000																																																																																										
41.5500	41.5500																																																																																										
36.1500	36.1500																																																																																										
57.8000	57.8000																																																																																										
118.1000	118.1000																																																																																										
113.7500	113.7500																																																																																										
T	A																																																																																										
64.3500	64.6186																																																																																										
116.6000	123.9124																																																																																										
104.6000	109.6616																																																																																										
28.9500	24.7514																																																																																										
48.2500	44.0641																																																																																										
136.0500	103.7846																																																																																										
61.2500	61.3398																																																																																										
107.7000	96.8645																																																																																										
27.9500	24.4361																																																																																										
39.3500	30.5427																																																																																										
57.4000	56.9779																																																																																										
106.3000	93.1819																																																																																										
81.3000	81.5457																																																																																										
Indeksi uspješnosti																																																																																											
Skup za učenje					Skup za testiranje																																																																																						
Trošenje	R	SSE	MSE	RMSE	NRMSE	Trošenje	R	SSE	MSE	RMSE	NRMSE																																																																																
GV	1.0000	0.0000	0.0000	0.0000	0.0000	GV	0.9597	1535	118.0787	10.8664	0.3038																																																																																

4.4.10. Procjena otpornosti popuštanju alatnih čelika na temelju parametra popuštanja

Otpornost popuštanju kao kriterij izbora, važan je kod čelika koji su izvrgnuti povišenim temperaturama, obično $> 200\text{ }^{\circ}\text{C}$, npr. kokile i ukovnji. Povišena temperatura uzrokuje veći ili manji pad čvrstoće i tvrdoće i otpornosti na trošenje, zavisno od vrste čelika. U užem smislu (uobičajeno kod alatnih čelika za hladni rad) otpornost na popuštanje definira se kao:

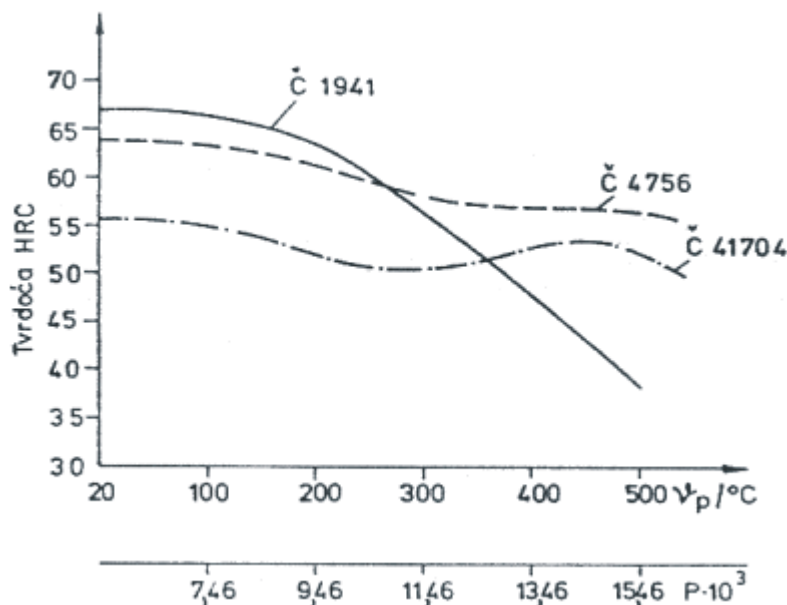
1. Razlika vrijednosti tvrdoće nakon kaljenja pri $20\text{ }^{\circ}\text{C}$ i tvrdoće nakon popuštanja pri određenoj temperaturi popuštanja ϑ_{px} :

$$\Delta HRC = HRC_{20} - HRC_{\vartheta_{px}} \quad (3.2)$$

2. Razlika vrijednosti tvrdoće nakon popuštanja pri $200\text{ }^{\circ}\text{C}$ i tvrdoće nakon popuštanja pri određenoj temperaturi popuštanja ϑ_{px} :

$$\Delta HRC = HRC_{200} - HRC_{\vartheta_{px}} \quad (3.3)$$

Tvrdoće (engl. *red hardness*) se očitavaju iz *dijagrama popuštanja* za pojedinu vrstu čelika kao što je prikazano na slici 4.26.



Slika 4.26. Primjer dijagrama popuštanja različitih skupina alatnih čelika [42]

Proces popuštanja je difuzijskog (difuzija atoma C i legiranih elemenata iz martenzitne rešetke) karaktera te je tvrdoća popuštanja:

$$HRC_p = f(\vartheta_p, t_p) \quad (3.4)$$

gdje je:

- ϑ_p – temperatura popuštanja u $^{\circ}\text{C}$
 t_p – vrijeme popuštanja u satima

Obično su krivulje iz dijagrama popuštanja snimljene na temelju $t_p=1\text{h}$. Za izračunavanje pada tvrdoće *HRC* za $t_p < 1\text{h}$, odnosno za bilo koje vrijeme, HALLOMON i JAFFE [42] uvode izraz nazvan *parametar popuštanja P*:

$$P = T(C + \lg t) \quad (3.5)$$

- gdje je: P - parametar popuštanja
 C - konstanta ovisna o materijalu ($C \approx 20$ za legirane čelike)
 T - temperatura popuštanja, K
 t - vrijeme popuštanja, h

Može se reći da je:

$$HRC_p = f(P) \quad (3.6)$$

Prema gornjem dijagramu za npr. $T = 220 \text{ }^\circ\text{C}$ i $t_p = 2\text{h}$ dobiva se:

$$P_{200} = (220+273) (20 + \lg 2) = 10008,$$

a tvrdoće popuštanja iznose:

$$\begin{aligned} \text{HRC}_{\text{C1941}} &= 63 \\ \text{HRC}_{\text{C4756}} &= 60,5 \\ \text{HRC}_{\text{C41704}} &= 51 \end{aligned}$$

U tablici P1.37 i prilogu I vidljivo je da se u ulaznom skupu podataka za procjenu otpornosti popuštanju alatnih čelika nalaze podaci o kemijskom sastavu čelika i parametar popuštanja, dok je izlazni skup HRC tvrdoća. Za određenu radnu temperaturu ϑ_{Rx} i vrijeme t_{Rx} koje materijal provede na istoj, mehanizam zaključivanja ES -a izračunava parametar popuštanja, te ga zajedno sa podacima o kemijskom sastavu prosljeđuje neuronskoj mreži koja kao izlaz daje podatak o tvrdoći HRC_{Rx} . Otporniji popuštanju je onaj čelik koji ima manji dekrement tvrdoće (ΔHRC) prema izrazu (3.3). Vrijeme t_{Rx} je predefiniramo, te iznosi 9000^h , što približno odgovara radu alata u tri smjene tokom cijele godine.

Treba napomenuti da su vrijednosti za HRC u tablici P1.37 u prilogu I dobivene očitavanjem krivulja popuštanja za slučaj ohlađivanja na zraku.

Na slici 4.27 prikazan izvod dijela podataka tablice P1.37 tvrdoća alatnih čelika za hladni rad u zavisnosti od kemijskog sastava i parametra popuštanja P

%C	%Si	%Mn	%V	P	HRC
C1941					
1,00	0,30	0,30	0,10	6000	67,8
1,00	0,30	0,30	0,10	7000	67,8
1,00	0,30	0,30	0,10	8000	67,0
1,00	0,30	0,30	0,10	9000	65,5
1,00	0,30	0,30	0,10	10000	63,0
1,00	0,30	0,30	0,10	11000	59,0
1,00	0,30	0,30	0,10	12000	54,0
1,00	0,30	0,30	0,10	13000	50,0
1,00	0,30	0,30	0,10	14000	47,0
C1840					
0,80	0,25	0,25	0,00	6000	67,7
0,80	0,25	0,25	0,00	7000	67,7

Slika 4.27. Tvrdoća alatnih čelika za hladni rad u zavisnosti od kemijskog sastava i parametra popuštanja P (izvod iz tablice P1.37 u prilogu I)

U tablicama 4.24 do 4.33 prikazani su parametri učenja dvaju algoritama ($NNBMA$ i $NNLM$) neuronskih mreža za procjenu otpornosti popuštanju na temelju parametra popuštanja P , te su uspoređivani indeksi uspješnosti učenja za sljedeće grupe alatnih čelika:

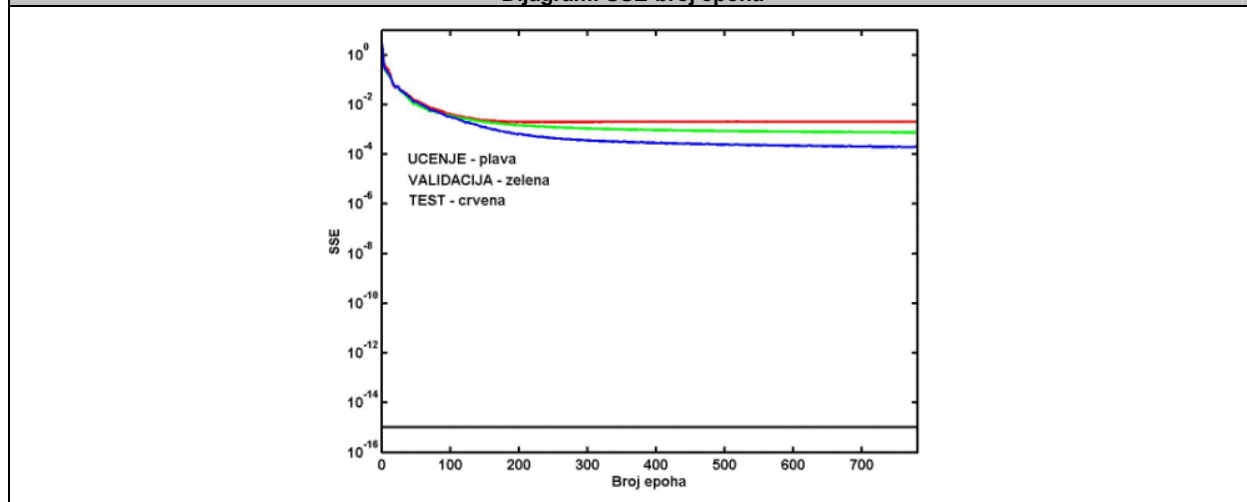
1. Nelegirani za hladni rad
2. Niskolegirani za hladni rad
3. Visokolegirani za hladni rad
4. Čelici za topli rad
5. Brzorezni čelici

Parametri obaju algoritama dobiveni su pomoću GA -algoritama, a ciklus ponavljanja učenja sa istim parametrima za svaki algoritam izveden je sto puta. Usvojene su matrice težina i bias vektor za onaj ciklus koji je postigao najmanji SSE .

Tablica 4.24. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanju nelegiranih alatnih čelika za hladni rad

Naziv mreže: NNHRCNE			Algoritam: NNBMA		
Red.broj	NN – parametri		Red.broj	GA – parametri	
1.	ulaz_dat	'hrcne_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	5	2.	alg_selekcije	0
3.	izlaz_dat	'hrcne_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				7
7.	br_neuro_lay2				8
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig'
10.	fun_lay3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.205578
15.	lr_inc	1.050000			
16.	lr_dec	0.700000			
17.	err_ratio	1.04			
18.	momentum				0.292776
19.	W1_dat	'HNEW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HNEW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HNEW3.txt'	10.	selectio_press	1
22.	B1_dat	'HNEB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HNEB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HNEB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha



Matrice težina (W) i bias vektori (B)

<p>W1-----</p> <p>-4.1662131e-001 3.5634884e-001 -2.9214070e-001 1.3677749e+000 1.4974685e+000</p> <p>-1.2855315e+000 -3.4599226e-001 -3.3154690e-001 -9.3725996e-001 -1.2063250e+000</p> <p>1.0977383e+000 -6.7460548e-001 9.5627798e-001 7.8053123e-001 -9.5680512e-001</p> <p>-8.0260594e-001 -1.4674019e-001 6.6265518e-001 1.2865250e+000 -1.3046070e+000</p> <p>-2.1733370e-002 -7.1266080e-001 5.0749137e-001 4.2108369e-001 -1.7586155e+000</p> <p>1.0865752e+000 -1.2557487e+000 7.2550291e-001 -4.2789673e-001 -6.2332981e-001</p> <p>-4.1031429e-003 1.1831059e+000 3.5534681e-001 -1.7808605e+000 -2.5707865e-001</p>	<p>B1-----</p> <p>1.9192995e+000</p> <p>1.5046255e+000</p> <p>-4.4709128e-001</p> <p>-1.0028881e-001</p> <p>1.1745334e+000</p> <p>1.5775817e+000</p> <p>-1.8144152e+000</p>
<p>W2-----</p> <p>-1.0068330e+000 -1.0538230e+000 -1.9326202e-001 -4.9650457e-001 -8.4136120e-001</p> <p>-2.6196209e-001 -3.8622858e-001 -1.5528440e-001 -3.6595857e-001 7.4330183e-001</p> <p>-1.9258676e-001 -1.1089249e+000 -3.8786131e-001 9.9639016e-001 -7.9710554e-001</p> <p>-2.3469416e-001 7.6195563e-001 9.6455982e-001 -4.4633643e-001 1.3884262e+000</p> <p>8.9818902e-001 -9.5697184e-002 -3.9613613e-001 3.2368539e-001 -1.1967908e+000</p> <p>-9.5832602e-001 1.0720744e+000 -5.1108034e-001 7.4586862e-001 -9.5021272e-002</p> <p>2.7069482e-001 -5.9386277e-001 7.0494627e-001 5.3025465e-001 1.3299890e+000</p> <p>1.9963257e-001 1.5909603e-002 5.3796582e-001 7.9979455e-001 -1.3699679e+000</p>	<p>B2-----</p> <p>1.7871801e+000</p> <p>1.3376368e+000</p> <p>7.2902147e-001</p> <p>4.6567499e-001</p> <p>3.5819240e-001</p> <p>-8.3366093e-001</p> <p>1.4013220e+000</p> <p>1.0577652e+000</p> <p>1.7793790e+000</p>
<p>W3-----</p> <p>3.43023e-005 -5.97116e-001 -1.28868e-001 7.31345e-001 -1.13714e-001</p> <p>-6.91017e-002 3.67632e-001 4.57985e-002 2.7331359e-001</p>	<p>B3-----</p> <p>2.7331359e-001</p>

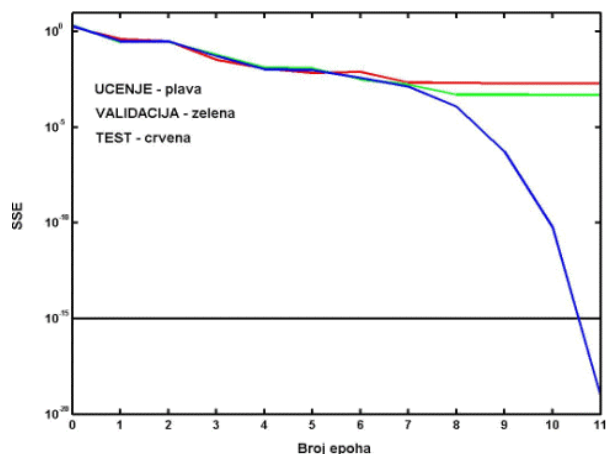
Nastavak: Tablica 4.24. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanju nelegiranih alatnih čelika za hladni rad

Naziv mreže: NNHCNE					Procjena izlaza					Algoritam: NNBMA	
Skup za učenje					Skup za testiranje						
<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p>					<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p>						
Indeksi uspešnosti											
Skup za učenje					Skup za testiranje						
Tvrdća	R	SSE	MSE	RMSE	NRMSE	Tvrdća	R	SSE	MSE	RMSE	NRMSE
HRC	1.0000	0.0000	0.0000	0.0000	0.0000	HRC	0.9980	3.6033	0.3276	0.5723	0.0689

Tablica 4.25. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju nelegiranih alatnih čelika za hladni rad

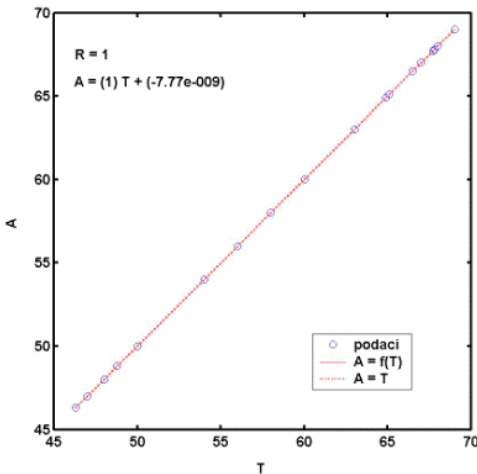
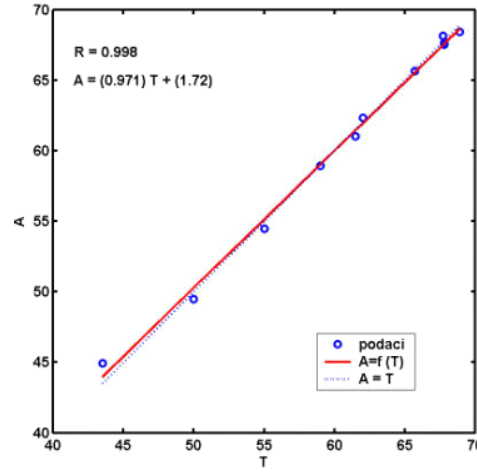
Naziv mreže: NNHRCNE			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrcne_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	5	2.	alg_selekcije	0
3.	izlaz_dat	'hrcne_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				8
7.	br_neuro_lay2				10
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig'
10.	fun_lay3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad				0.000100
15.	mu				0.521932
16.	mu_inc				10.000000
17.	mu_dec				0.100000
18.	mu_max				10000000000
19.	W1_dat	'HNEW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HNEW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HNEW3.txt'	10.	selectio_press	1
22.	B1_dat	'HNEB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HNEB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HNEB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1		B1	
8.8462922e-001	6.2979459e-001	-9.6050649e-001	-1.6018734e+000
1.29395e-001	-1.05689e+000	-1.01865e+000	5.62670e-001
5.0289551e-001	1.3149284e+000	-1.1933506e+000	1.0612738e+000
5.1118348e-001	-1.3506883e+000	-1.4831764e+000	2.3449097e-001
-1.4140285e+000	-6.2824925e-001	8.5093953e-002	9.3320720e-001
-2.4962330e-001	9.6258157e-001	-6.4907293e-001	-1.2122234e-001
7.8776121e-001	-1.3940271e+000	1.0100953e+000	-9.4677004e-001
-2.5700542e-001	1.2445449e+000	-1.2559838e+000	2.4504256e-001
			-8.7280004e-001
W2		B2	
1.01866e-001	1.51323e+000	2.56209e-001	2.49623e-001
-5.22395e-001	-1.05689e+000	-1.01865e+000	5.62670e-001
6.86239e-001	-8.98080e-001	-8.99624e-001	2.47154e-001
6.54724e-001	1.99293e-001	-5.38774e-001	4.65390e-001
7.03679e-001	3.42968e-001	-7.51480e-001	-8.40009e-001
-4.89374e-002	6.48260e-001	1.21267e+000	4.45621e-001
-9.98891e-001	3.08882e-001	7.99849e-001	-1.20847e-001
8.45522e-002	-1.88083e-001	-1.23704e+000	1.14133e-001
-4.82104e-001	-3.07308e-001	-4.86914e-001	1.10458e+000
-4.08987e-001	4.49695e-001	6.64240e-001	1.05058e+000
			9.40992e-001
			-4.32539e-001
			3.94984e-001
			8.33917e-001
			-1.8325119e+000
W3		B3	
8.3684e-001	-6.1436e-001	2.0122e-003	-7.7213e-002
			2.5371e-002
			-2.8997e-001
			-7.7715e-001
			-1.1662e-001
			1.2261e-001
			5.7519867e-001

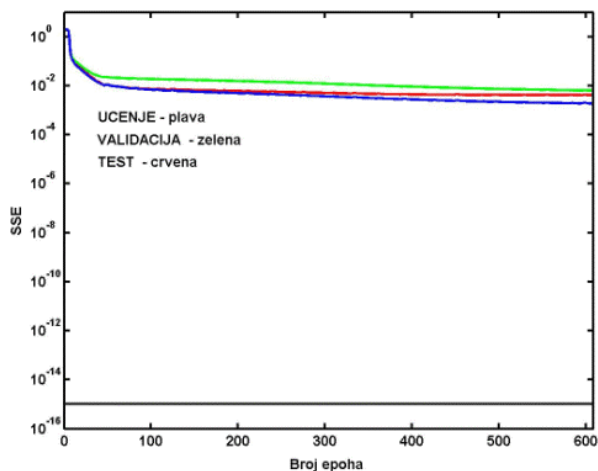
Nastavak: Tablica 4.25. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju nelegiranih alatnih čelika za hladni rad

Naziv mreže: NNHRCNE		Procjena izlaza				Algoritam: NNLM					
Skup za učenje					Skup za testiranje						
<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p>					<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p>						
											
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Tvrdoaća	R	SSE	MSE	RMSE	NRMSE	Tvrdoaća	R	SSE	MSE	RMSE	NRMSE
HRC	1.0000	0.0000	0.0000	0.0000	0.0000	HRC	0.9977	3.5284	0.3208	0.5664	0.0682

Tablica 4.26. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanju niskolegiranih alatni čelika za hladni rad

Naziv mreže: NNHRCNI			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrcni_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hrcni_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				2
6.	br_neuro_lay1				8
7.	br_neuro_lay2				1
8.	fun_lay1				'tansig'
9.	fun_lay2				'purelin'
10.	fun_lay3				-
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.987384
15.	lr_inc	1.050000			
16.	lr_dec	0.70000			
17.	err_ratio	1.04			
18.	momentum				0.385508
19.	W1_dat	'HNIW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HNIW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	-	10.	selectio_press	1
22.	B1_dat	'HNIB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HNIB2.txt'	12.	migration_rate	0.25
24.	B3_dat	-	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

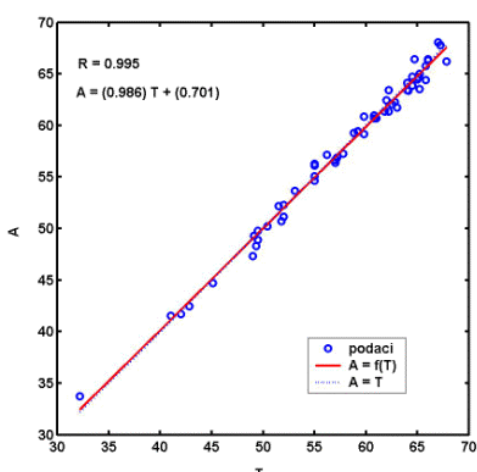
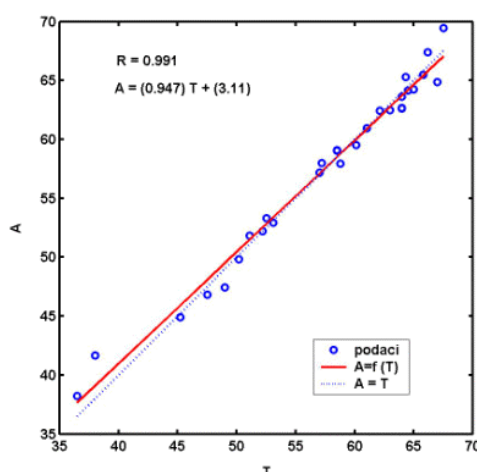
```

W1-----
8.96621e-001 -3.50517e-001 -9.69727e-001 8.14140e-001 -6.56331e-001 0.00000e+000 1.44880e-001 1.13639e+000
5.39618e-002 -3.46769e-001 8.62546e-001 -1.57933e+000 -1.69805e-001 0.00000e+000 2.50399e-001 -4.03385e-001
9.27440e-001 2.14917e-002 2.57278e-001 -2.63360e-002 -5.08103e-001 0.00000e+000 9.57414e-002 1.47235e+000
1.10437e+000 -1.03718e+000 -4.15464e-001 8.55347e-001 5.37575e-002 0.00000e+000 -4.45186e-001 1.46815e-001
3.84684e-001 2.45828e-001 -1.18941e+000 1.08803e+000 -6.42251e-001 0.00000e+000 1.30672e-001 5.56535e-001
6.24529e-001 -9.77143e-001 1.14553e+000 4.40294e-001 9.07232e-001 0.00000e+000 -1.32078e-001 3.00787e-001
-7.17231e-001 -1.02292e+000 -3.75826e-001 -4.91470e-001 -1.00014e+000 0.00000e+000 8.72597e-001 8.10924e-001
-5.63341e-002 1.53728e-001 -7.21579e-002 7.89680e-001 -1.17141e+000 0.00000e+000 7.06877e-001 1.22131e+000
W2-----
7.07416e-002 9.57992e-002 -6.17645e-001 2.72939e-001 -4.81424e-001 -4.18298e-001 -2.68632e-001 -3.46519e-001

B1-----
-1.6020709e+000
1.2362941e+000
-1.2678041e+000
-3.5079337e-001
4.4675914e-001
7.2988267e-001
-9.3156313e-001
-1.7891049e+000
B2-----
-3.7432428e-002

```

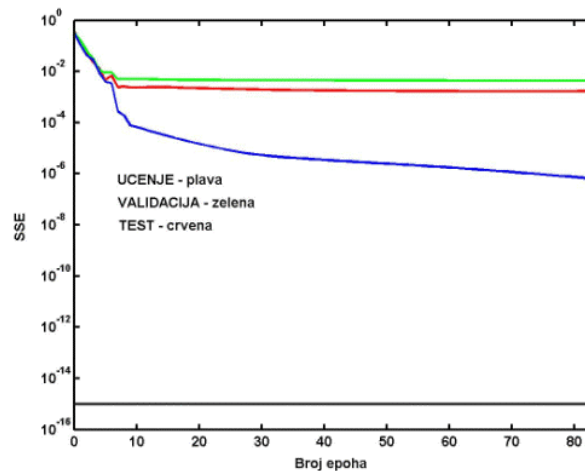
Nastavak: Tablica 4.26. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanj u niskolegiranih alatni čelika za hladni rad

Naziv mreže: NNHRCNI		Procjena izlaza					Algoritam: NNBMA				
Skup za učenje						Skup za testiranje					
<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p> 						<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p> 					
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Tvrdoća	R	SSE	MSE	RMSE	NRMSE	Tvrdoća	R	SSE	MSE	RMSE	NRMSE
HRC	0.9949	35.1438	0.6166	0.7852	0.1010	HRC	0.9909	38.8062	1.3381	1.1568	0.1369

Tablica 4.27. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju niskolegiranih alatni čelika za hladni rad

Naziv mreže: NNHRCNI			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrcni_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hrcni_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				9
7.	br_neuro_lay2				5
8.	fun_lay1				'tansig'
9.	fun_lay2				'logsig'
10.	fun_lay3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad				0.000100
15.	mu				0.161733
16.	mu_inc				10.000000
17.	mu_dec				0.100000
18.	mu_max				10000000000
19.	W1_dat	'HNIW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HNIW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HNIW3.txt'	10.	selectio_press	1
22.	B1_dat	'HNIB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HNIB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HNIB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

```

W1..... B1.....
-3.77416e-001 -1.23413e+000 4.94678e-001 -1.08988e-001 1.73939e-001 0.00000e+000 -5.54524e-001 1.35105e+000 -1.3488879e+000
4.43474e-001 2.44196e-004 -9.98354e-001 1.35564e-001 1.01654e+000 0.00000e+000 -1.50030e+000 -3.65288e-001 1.4171187e+000
-9.59313e-001 -8.71806e-001 -9.01005e-001 1.44592e+000 -4.15687e-001 0.00000e+000 4.12623e-001 3.66571e-003 1.1996348e+000
1.11020e+000 5.32907e-001 -1.52230e+000 -1.09728e+000 -1.60965e+000 0.00000e+000 1.48211e-001 1.36057e+000 -1.2162033e+000
3.35761e-001 -2.62657e+000 -5.19140e-001 3.16702e-001 -1.28610e+000 0.00000e+000 5.44910e-001 4.40150e+000 -1.4175729e+000
-1.68146e+000 -1.22277e+000 -4.67297e-002 -7.35643e-001 1.13864e+000 0.00000e+000 -2.42269e-001 3.08850e+000 -3.5249711e-001
-1.18996e+000 5.17601e-001 -1.04640e+000 -5.71053e-001 -3.65098e-001 0.00000e+000 1.26845e+000 -3.79318e-001 -6.6824297e-001
1.15154e-001 -2.02652e+000 6.54806e-001 -6.75744e-001 6.64988e-001 0.00000e+000 7.45273e-001 -1.79636e-001 -1.2253741e+000
8.93099e-001 1.14164e+000 -1.12878e-001 2.44557e-001 -4.97115e-001 0.00000e+000 -1.13134e+000 1.88521e-001 2.0609040e+000
W2..... B2.....
-2.18299e+000 1.32353e+000 -2.94975e-001 -2.24133e+000 -5.47523e-001 8.44005e-001 -2.18549e-001 1.55311e+000 1.03277e+000 2.9669845e+000
-5.66348e-001 -1.63514e+000 -3.86033e-001 -1.42388e-001 9.00677e-001 -1.79594e-001 -9.82415e-002 -1.76386e+000 -2.71014e+000 1.2085131e+000
1.63520e+000 4.93536e-001 -1.74113e+000 1.13366e-001 3.24543e-001 1.49907e+000 6.68193e-003 -8.84206e-001 -1.55587e+000 -2.1763722e-002
2.11534e+000 -3.13225e-001 -1.91050e-001 2.45077e+000 -1.05457e+000 -6.86185e-001 1.11679e+000 3.03384e-001 -1.24416e+000 1.3250926e+000
-1.50591e+000 1.01688e+000 -1.92514e+000 9.04711e-001 -3.20607e-001 -1.90245e+000 2.73237e-001 1.62513e-001 1.11568e-001 -3.4405645e+000
W3..... B3.....
1.5550948e+000 -8.9710503e-001 -7.3681646e-001 -1.1282936e+000 1.8217818e+000 -8.2673235e-001

```

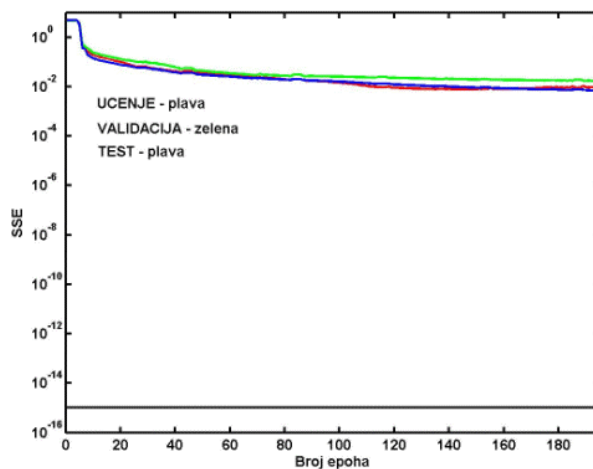
Nastavak: Tablica 4.27. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju niskolegiranih alatni čelika za hladni rad

Naziv mreže: NNHRCNI		Procjena izlaza						Algoritam: NNLM			
Skup za učenje			Skup za testiranje								
<p><i>Napomena:</i> Zbog veličine, matrice (<i>T</i>) i (<i>A</i>) nisu prikazane.</p>			<p><i>Napomena:</i> Zbog veličine, matrice (<i>T</i>) i (<i>A</i>) nisu prikazane.</p>								
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Tvrdoća	R	SSE	MSE	RMSE	NRMSE	Tvrdoća	R	SSE	MSE	RMSE	NRMSE
HRC	1.0000	0.0000	0.0000	0.0000	0.0000	HRC	0.9976	15.7722	0.5439	0.7375	0.0873

Tablica 4.28. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanj u visokolegiranih alatnih čelika za hladni rad

Naziv mreže: NNHRCVI			Algorithm: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrcvi_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hrcvi_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				8
7.	br_neuro_lay2				9
8.	fun_lay1				'purelin'
9.	fun_lay2				'tansig '
10.	fun_lay3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.726780
15.	lr_inc	1.050000			
16.	lr_dec	0.700000			
17.	err_ratio	1.04			
18.	momentum				0.254535
19.	W1_dat	'HVIW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HVIW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HVIW3.txt'	10.	selectio_press	1
22.	B1_dat	'HVIB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HVIB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HVIB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

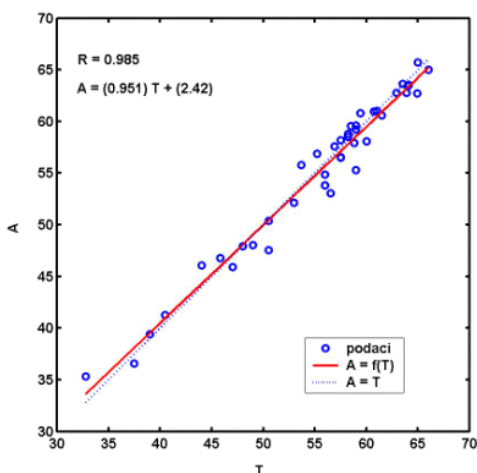
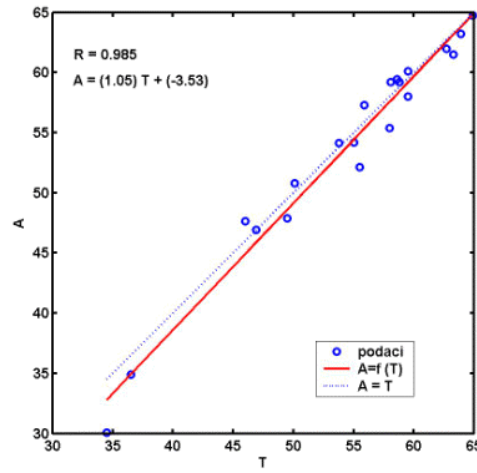
Matrice težina (*W*) i bias vektori (*B*)

```

W1.....
-3.0254879e-001 -8.8546179e-001 -6.8142920e-001 3.0941232e-001 -7.0050666e-001 8.5361540e-001 5.3940883e-001 -9.3887793e-003 -7.5993478e-001
4.9698178e-001 9.7035574e-001 1.2078422e-001 5.7680409e-001 -8.6976952e-003 6.3547888e-001 -1.0053167e-001 -1.0858587e+000 3.4504442e-001
1.6784748e-002 5.2175473e-001 2.5876482e-001 4.3019822e-001 7.3449188e-001 2.2834423e-001 -6.1582193e-001 -6.3609900e-001 5.1911935e-001
6.9446476e-001 -4.9530249e-001 -9.0310730e-001 2.2628505e-001 -9.7836676e-001 -5.2761327e-001 -9.1037197e-002 6.8860324e-001 -6.2365156e-001
6.2760028e-002 5.1709488e-001 -4.6519680e-001 -1.6418457e-001 -5.1829478e-001 2.0614642e-001 1.0054056e+000 7.3282641e-001 -9.2832720e-001
3.8660238e-003 2.5488586e-001 7.1644655e-001 -1.0280071e+000 7.5739501e-001 1.0207476e+000 -7.0569627e-001 9.1790766e-001 -4.8426876e-001
8.1066425e-001 -5.3027461e-001 -1.6986445e-001 8.7624622e-001 -4.8175971e-001 7.4719138e-001 7.1652733e-002 -1.0505900e-001 -7.3738307e-001
3.1042352e-001 -5.4322276e-001 -1.0165656e+000 -5.3438395e-001 -6.1419165e-002 4.4800813e-001 3.6046620e-001 -1.1734205e+000 8.8101865e-001
W2.....
9.2494530e-001 1.1191198e+000 -4.0909651e-001 -4.3372791e-001 -2.7301710e-001 3.4922011e-001 1.4010974e-002 -8.5931112e-001 -1.8197414e+000
-6.2096488e-001 -6.3174267e-001 -1.0031111e+000 7.8435276e-002 8.0333917e-001 5.0606485e-001 -8.7047056e-001 -1.2401137e-001 1.3194406e+000
-1.5745889e-002 9.6916967e-001 -4.2524875e-001 7.2622205e-001 -3.7663818e-001 -1.0744922e+000 5.3675556e-001 8.0182043e-001 8.6575679e-001
5.0948962e-001 2.7216079e-001 6.8688676e-001 2.2464024e-001 1.0354633e+000 5.6205024e-001 1.0718780e+000 2.4434322e-001 -4.5195672e-001
2.1413090e-001 5.4555194e-001 -8.8272297e-001 -6.5364211e-001 -9.2704000e-001 8.5180301e-001 -4.5086444e-003 -5.1834264e-001 9.8823076e-002
-4.0786317e-001 4.6499234e-001 8.3059182e-001 1.7736705e-001 -8.7328702e-001 7.5414404e-001 -8.3735406e-001 7.2200192e-001 -4.4550159e-001
1.3534606e-001 3.4219013e-001 -7.2458024e-001 -4.0506436e-001 9.3088405e-001 2.9550116e-001 -2.4699594e-001 -1.4031491e+000 8.2829816e-001
-6.2044080e-001 -6.3495373e-001 8.0652897e-001 5.2629789e-001 -1.1663479e+000 -7.7044444e-001 5.7663207e-001 3.7548952e-001 -1.1954583e+000
-3.4463432e-001 -9.7855697e-001 -1.0783242e+000 -4.1266397e-002 6.7853951e-001 9.8179070e-001 -2.3627489e-001 -5.2790446e-001 -1.7929363e+000
W3.....
-1.03631e-001 -1.86256e-001 4.78789e-001 1.40382e-001 -2.64638e-001 6.41731e-001 1.99254e-001 -4.61222e-001 -5.55049e-001 -3.7614334e-001
B1.....
-7.5993478e-001
3.4504442e-001
5.1911935e-001
-6.2365156e-001
-9.2832720e-001
-4.8426876e-001
-7.3738307e-001
8.8101865e-001
B2.....
-1.8197414e+000
1.3194406e+000
8.6575679e-001
-4.5195672e-001
9.8823076e-002
-4.4550159e-001
8.2829816e-001
-1.1954583e+000
-1.7929363e+000
B3.....
-3.7614334e-001

```

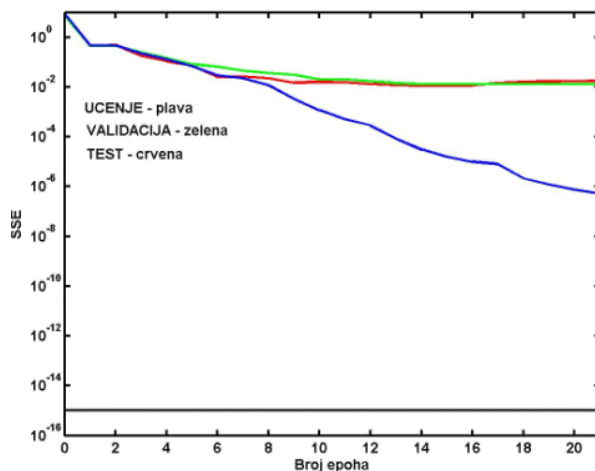
Nastavak: Tablica 4.28. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanju visokolegiranih alatnih čelika za hladni rad

Naziv mreže: NNHRCVI		Procjena izlaza					Algoritam: NNBMA				
Skup za učenje						Skup za testiranje					
<p><i>Napomena:</i> Zbog veličine, matrice (<i>T</i>) i (<i>A</i>) nisu prikazane.</p> 						<p><i>Napomena:</i> Zbog veličine, matrice (<i>T</i>) i (<i>A</i>) nisu prikazane.</p> 					
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Tvrdoća	R	SSE	MSE	RMSE	NRMSE	Tvrdoća	R	SSE	MSE	RMSE	NRMSE
HRC	0.9847	84.1008	2.0512	1.4322	0.1765	HRC	0.9849	57.8941	2.8947	1.7014	0.2016

Tablica 4.29. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju visokolegiranih alatnih čelika za hladni rad

Naziv mreže: NNHRCVI			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrcvi_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	8	2.	alg_selekcije	0
3.	izlaz_dat	'hrcvi_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				9
7.	br_neuro_lay2				7
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig '
10.	fun_lay3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad				0.000100
15.	mu				0.235657
16.	mu_inc				10.000000
17.	mu_dec				0.100000
18.	mu_max				10000000000
19.	W1_dat	'HVIW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HVIW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HVIW3.txt'	10.	selectio_press	1
22.	B1_dat	'HVIW1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HVIW2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HVIW3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

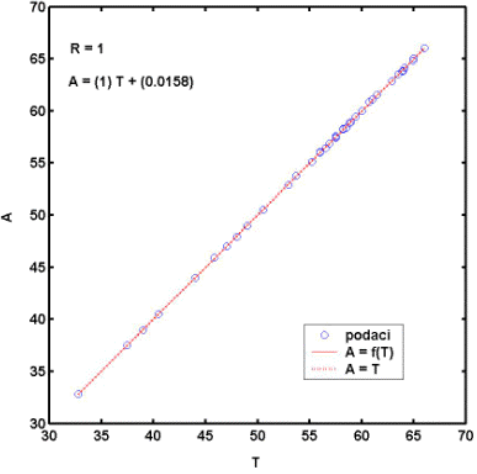
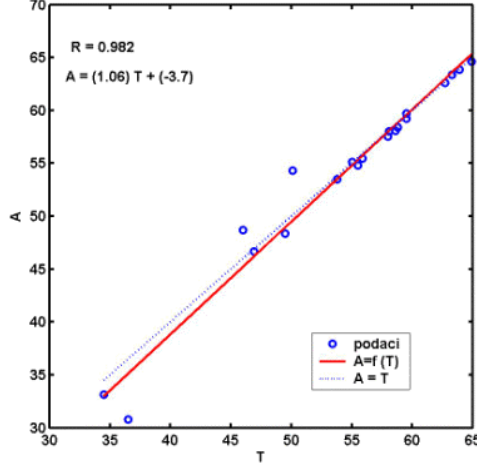
Dijagram: SSE-broj epoha



Matrice težina (W) i bias vektori (B)

W1----- B1-----
7.4972786e-001 3.9227131e-001 8.0771058e-001 -7.8474891e-001 8.3825404e-001 5.4187544e-001 -8.1104115e-001 -3.3445846e-001 -1.8563274e+000
-6.5825012e-001 2.4390671e-001 8.1735602e-001 -7.9652768e-001 2.8457440e-001 4.7609135e-001 1.9305636e-001 1.2311485e+000 2.0218575e+000
1.1619060e+000 9.1316348e-002 1.1205654e-001 4.4016110e-001 -6.0996599e-001 -3.2974123e-001 -6.7586942e-001 -1.4869301e+000 -1.2699399e+000
5.1503933e-004 -1.5059887e-001 6.1853756e-001 -3.7135369e-001 1.2472843e+000 -9.0514221e-001 -1.6074035e-001 -1.4842586e+000 -9.6342882e-003
-1.8658327e-001 6.3806833e-001 -9.9817821e-001 -6.7249892e-001 9.2202533e-001 1.9980061e-001 5.4626738e-001 2.0637317e+000 7.4193897e-002
3.6709558e-001 -5.6884058e-001 -5.9853080e-001 8.6487326e-001 3.6442989e-001 -1.3463245e+000 1.7698787e-002 -7.7044301e-001 4.4133997e-001
1.2308857e-001 -3.4326800e-001 8.2059050e-001 2.8853479e-001 -6.1007653e-001 -5.7354785e-001 4.3016024e-001 -1.0143580e+000 6.3133616e-001
-1.9955730e-001 1.1771262e+000 9.5640359e-001 2.3044461e-001 1.0235909e+000 4.0864513e-001 -4.0609217e-001 3.9242856e-001 1.4123218e+000
1.0365943e-001 1.3571738e-001 -1.0456347e+000 8.4436958e-001 -1.6695515e-001 -4.0338767e-001 2.1845622e-001 2.7529082e+000 -1.9951393e+000
W2----- B2-----
1.64427e-002 -8.02370e-001 -8.33178e-001 8.75392e-001 -8.50433e-001 -8.15052e-001 -3.03911e-001 4.15974e-001 8.38540e-001 1.6285704e+000
-7.37615e-001 8.58534e-001 -8.19500e-001 -8.63741e-002 -5.19879e-001 -4.17275e-001 4.87487e-001 -8.69691e-001 2.35607e-001 1.4912500e+000
5.99133e-001 3.27367e-002 2.42191e-001 8.88023e-001 -3.56143e-001 -4.56403e-001 6.56173e-001 -3.05797e-001 5.67815e-001 -6.4395586e-001
8.12700e-002 6.40752e-001 1.38485e+000 8.01465e-001 3.76747e-001 3.79185e-001 3.54956e-001 -1.90360e-001 4.65802e-001 -4.1542033e-001
5.10356e-003 9.41447e-001 1.15895e-002 -4.08344e-002 1.02117e+000 -8.31782e-001 -2.57477e-001 4.52178e-001 1.16618e+000 1.1757199e+000
-1.16637e+000 2.16736e-001 -1.02155e-002 1.91588e-001 4.33055e-002 -5.27506e-001 -1.50028e-002 1.07999e+000 1.24453e+000 -1.0686170e+000
-9.80908e-001 1.71695e-001 5.50567e-002 -8.30949e-001 2.77214e-001 -2.37747e-002 -7.92350e-002 3.97673e-002 -1.08301e+000 -1.7164441e+000
W3----- B3-----
8.9515629e-001 -5.4986567e-001 -2.9025182e-001 4.9095984e-001 -1.7090102e-002 -1.1526936e+000 8.0361902e-001 -3.2623316e-002

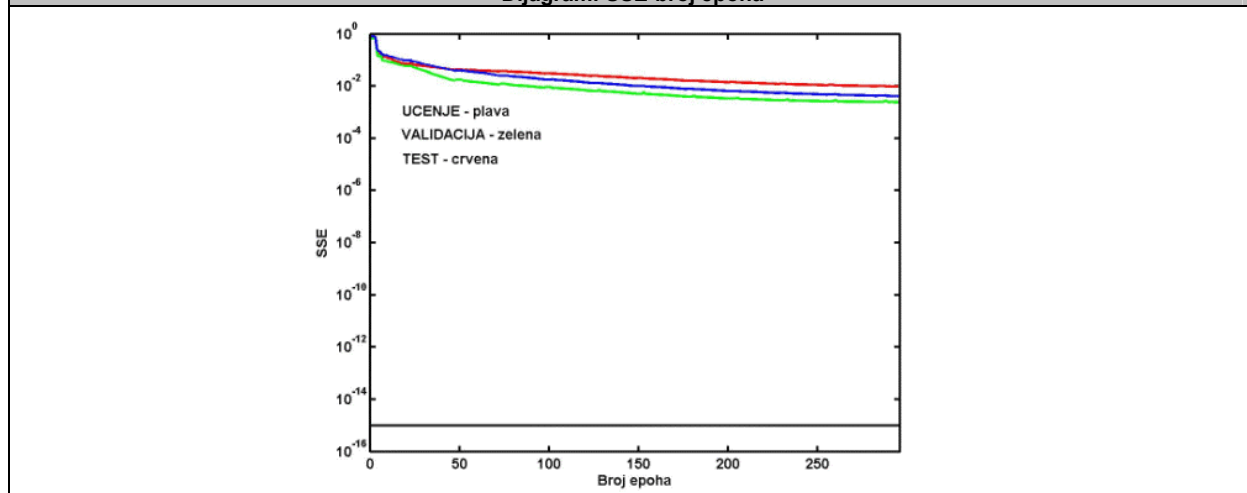
Nastavak: Tablica 4.29. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju visokolegiranih alatnih čelika za hladni rad

Naziv mreže: NNHRCVI		Procjena izlaza						Algoritam: NNLM					
Skup za učenje						Skup za testiranje							
<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p> 						<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p> 							
Indeksi uspješnosti													
Skup za učenje						Skup za testiranje							
Tvrdoća	R	SSE	MSE	RMSE	NRMSE	Tvrdoća	R	SSE	MSE	RMSE	NRMSE		
HRC	1.0000	0.1758	0.0043	0.0655	0.0081	HRC	0.9822	62.4120	3.1206	1.7665	0.2093		

Tablica 4.30. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanju alatnih čelika za topli rad

Naziv mreže: NNHRCTR			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrctr_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	10	2.	alg_selekcije	0
3.	izlaz_dat	'hrctr_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				9
7.	br_neuro_lay2				4
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig'
10.	fun_lay3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.844554
15.	lr_inc	1.050000			
16.	lr_dec	0.700000			
17.	err_ratio	1.04			
18.	momentum				0.402753
19.	W1_dat	'HTRW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HTRW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HTRW3.txt'	10.	selectio_press	1
22.	B1_dat	'HTRB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HTRB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HTRB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1.....	B1.....
6.18836e-001 -3.69601e-001 7.70272e-001 8.86822e-001 8.26350e-002 2.05707e-001 8.86598e-001 -8.55147e-001 0.00000e+000 -3.59324e-003 -1.6193540e+000	
-1.78229e-002 -5.43558e-001 5.37192e-001 -1.15893e+000 8.07190e-001 -1.77045e-001 7.86839e-001 9.85627e-002 0.00000e+000 2.04460e-001 1.2898689e+000	
6.38702e-001 5.37916e-001 1.68328e-001 -1.45170e-001 -3.53556e-001 2.48447e-001 1.14496e-001 -3.48128e-001 0.00000e+000 1.18247e+000 -1.3314777e+000	
-4.57405e-001 3.77275e-001 -5.95899e-001 7.34562e-001 -5.23237e-001 -7.43557e-001 -6.14046e-001 4.46349e-001 0.00000e+000 -7.36590e-001 4.3235701e-001	
-1.42269e-002 -5.06266e-001 3.25990e-001 -6.20998e-001 5.93402e-001 -6.38231e-001 -6.80702e-001 -1.04191e+000 0.00000e+000 -7.76945e-002 1.0448811e-001	
-4.86618e-001 4.52892e-001 -6.23778e-001 5.78334e-001 5.41382e-001 -2.33140e-001 -7.57838e-001 2.14471e-001 0.00000e+000 -1.49376e+000 -4.7465750e-001	
-4.83379e-002 8.95716e-001 7.80862e-001 -4.52149e-003 5.01150e-001 -1.11797e-001 -9.96151e-001 -1.02191e+000 0.00000e+000 2.60056e-001 -6.1612574e-001	
-3.55546e-001 -3.41276e-001 -7.57920e-001 -1.52365e-001 5.38337e-001 2.75827e-001 8.38896e-002 5.21331e-001 0.00000e+000 9.66535e-001 -1.4253571e+000	
1.09122e+000 4.35831e-001 -4.97080e-002 4.19703e-001 7.54871e-001 6.50544e-001 6.82444e-001 1.91528e-001 0.00000e+000 7.95025e-001 1.7592962e+000	
W2.....	B2.....
-8.0307273e-001 -6.2738244e-001 -5.8431111e-001 2.1297935e-001 5.9246167e-001 5.0377754e-001 -3.0529674e-001 1.7961672e-001 6.3939091e-001 1.8868747e+000	
6.8274157e-001 7.5270934e-001 -6.4500026e-001 1.6896503e-001 2.9044176e-001 -8.2956750e-001 -5.1496558e-001 4.0206763e-001 -6.4206128e-001 -4.7632530e-001	
-3.1343133e-001 7.8899257e-001 4.9919609e-001 -8.8819613e-001 -2.9859043e-001 -2.6748779e-001 -2.9059248e-001 -4.5035289e-001 4.9348038e-001 -5.4760235e-001	
-7.8924086e-001 -1.1701671e-001 9.6400798e-001 1.1497129e-001 1.5541809e-001 -1.3255337e+000 6.2838841e-001 1.1229170e+000 8.0870101e-001 -1.7339891e+000	
W3.....	B3.....
-8.7127354e-001 -3.6684576e-001 3.1132574e-001 -1.2572823e+000 1.6753455e-001	

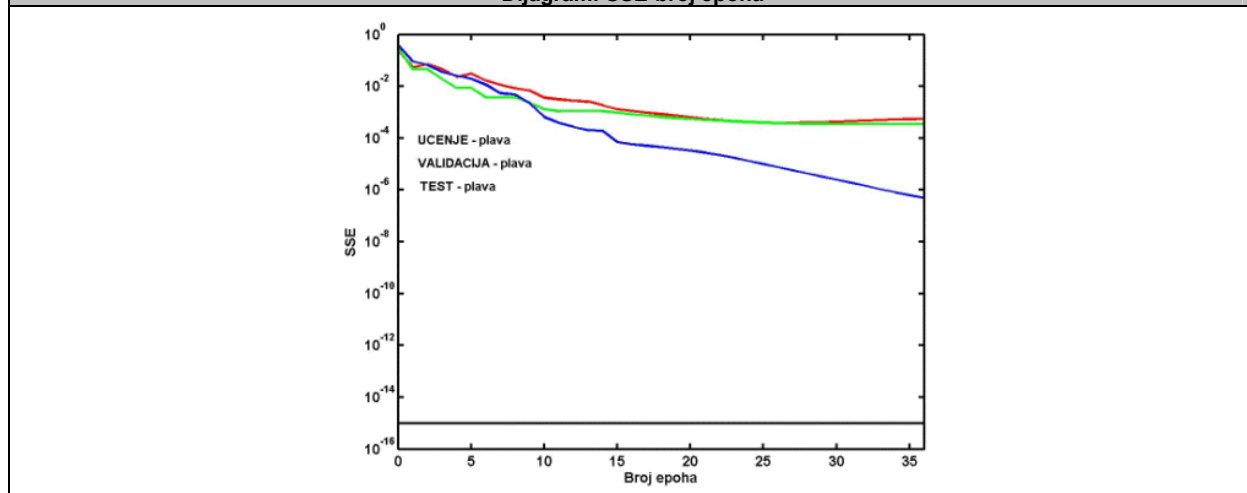
Nastavak: Tablica 4.30. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanjem alatnih čelika za topli rad

Naziv mreže: NNHRCTR		Procjena izlaza					Algoritam: NNBMA				
Skup za učenje						Skup za testiranje					
<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p>						<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p>					
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Tvrdća	R	SSE	MSE	RMSE	NRMSE	Tvrdća	R	SSE	MSE	RMSE	NRMSE
HRC	0.9889	41.2952	0.9832	0.9916	0.1478	HRC	0.9719	48.4389	2.3066	1.5188	0.2332

Tablica 4.31. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju alatnih čelika za topli rad

Naziv mreže: NNHRCTR			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrctr_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	10	2.	alg_selekcije	0
3.	izlaz_dat	'hrctr_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				8
7.	br_neuro_lay2				7
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig'
10.	fun_lay3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad				0.000100
15.	mu				0.644146
16.	mu_inc				10.000000
17.	mu_dec				0.100000
18.	mu_max				1000000000
19.	W1_dat	'HTRW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HTRW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HTRW3.txt'	10.	selectio_press	1
22.	B1_dat	'HTRB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HTRB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HTRB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

```

W1-----
-4.51444e-001 5.91402e-001 3.12272e-001 2.69577e-001 -1.18541e+000 5.18289e-001 5.72571e-001 2.74636e-001 0.00000e+000 7.47340e-001 1.9284092e+000
-2.73420e-001 -8.09061e-003 -8.50859e-002 7.52241e-001 1.06725e-001 -1.14239e+000 -1.78216e-001 -1.05492e+000 0.00000e+000 5.74090e-001 1.4942532e+000
3.52597e-001 2.23598e-001 -7.42365e-001 1.17766e+000 3.23896e-001 9.29887e-001 8.82224e-001 -4.12035e-001 0.00000e+000 1.31363e+000 -8.0170826e-001
4.48272e-001 -3.66433e-003 2.96683e-001 -1.08140e+000 8.14549e-001 4.83018e-001 -5.73952e-001 1.19171e-001 0.00000e+000 5.40087e-001 -2.9765044e-001
-4.49899e-001 -6.97293e-001 -7.42444e-001 -6.64388e-001 8.20447e-001 2.36667e-001 -4.63440e-002 2.37012e-002 0.00000e+000 7.11424e-001 -2.1606803e-001
-4.70269e-001 4.61368e-001 -1.26708e+000 -3.05236e-002 3.74495e-001 -9.04659e-001 -4.15195e-001 4.12890e-001 0.00000e+000 -1.21825e+000 -4.5008893e-001
1.40030e-001 1.72922e-001 4.18955e-001 -5.34695e-001 -2.90823e-001 7.93287e-001 8.67674e-001 1.99913e-002 0.00000e+000 -2.22635e+000 2.1182360e+000
2.66546e-001 4.97791e-001 1.17709e+000 3.84257e-002 6.65398e-001 -1.97690e-001 -1.57774e-001 -1.29080e+000 0.00000e+000 6.06722e-001 1.4637315e+000
W2-----
2.6659557e-001 7.1553958e-001 -5.7722990e-002 -2.2102527e-001 1.5643927e+000 -8.9897423e-001 -9.0009981e-001 -1.4261620e-001 -1.3750279e+000
-6.5195456e-001 -3.0974134e-001 -1.1065907e+000 -8.4482217e-001 6.8041250e-001 -7.5970849e-001 2.7586290e-001 5.2513443e-001 1.3482510e+000
-1.1469581e+000 -2.4564601e-001 2.8092986e-001 1.0332942e+000 2.3849407e-001 -1.3746893e-001 -6.9178018e-001 7.9242885e-001 3.8577242e-001
-4.8184448e-001 5.4080510e-001 4.8482128e-001 7.9766364e-001 5.4334055e-001 -4.7773732e-001 3.7313181e-001 -8.1638152e-001 1.6179930e-001
-3.9420556e-001 -1.0749020e+000 1.0899029e+000 -2.2687508e-001 1.1106223e+000 1.4655765e-002 -2.2604715e+000 3.3204566e-001 -8.2354234e-001
2.0671146e-001 5.2605768e-001 -1.0937172e+000 9.9274251e-001 8.2917471e-001 5.5747245e-001 5.0876475e-001 -5.3174175e-001 -1.2986229e+000
9.3483731e-001 8.1571001e-001 -6.1128232e-002 -8.1939131e-001 -7.2819459e-001 -6.7624486e-001 1.6084856e-001 -2.7258067e-001 1.6948626e+000
W3-----
-6.9506969e-001 6.9694035e-001 -2.3652288e-001 8.1804545e-001 -8.2075273e-001 -8.3150353e-001 -7.8568655e-001 -5.2492808e-001
B1-----
B2-----
B3-----

```

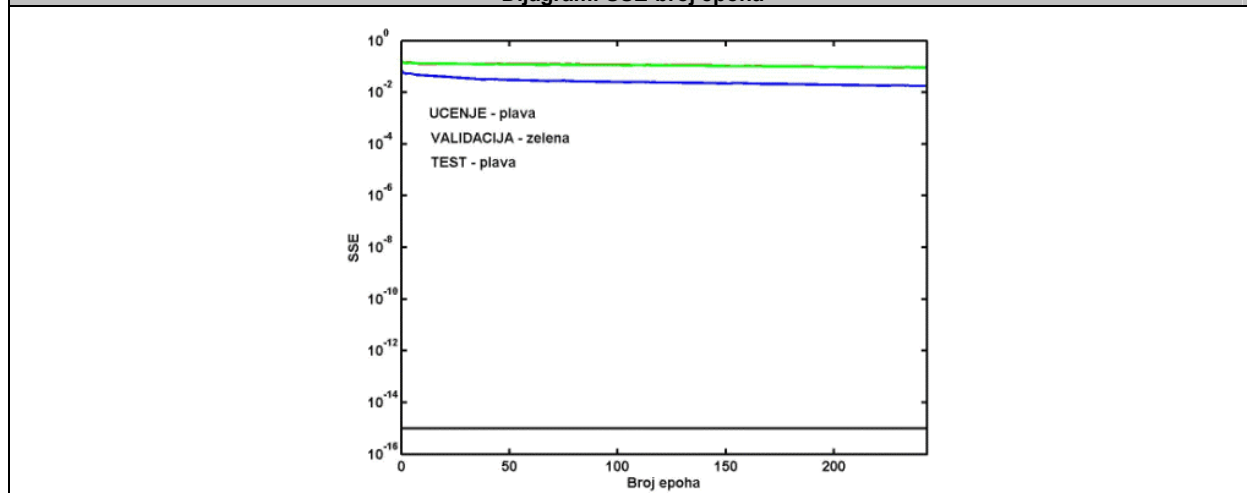
Nastavak: Tablica 4.31. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju alatnih čelika za topli rad

Naziv mreže: NNHRCTR		Procjena izlaza				Algoritam: NNLM					
Skup za učenje			Skup za testiranje								
<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p>			<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p>								
Indeksi uspješnosti											
Skup za učenje			Skup za testiranje								
Tvrdoća	R	SSE	MSE	RMSE	NRMSE	Tvrdoća	R	SSE	MSE	RMSE	NRMSE
HRC	1.0000	0.0244	0.0006	0.0241	0.0036	HRC	0.9989	2.1199	0.1009	0.3177	0.0488

Tablica 4.32. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanju brzoreznih čelika

Naziv mreže: NNHRCBC			Algoritam: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrcbc_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	7	2.	alg_selekcije	0
3.	izlaz_dat	'hrcbc_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				10
7.	br_neuro_lay2				9
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig '
10.	fun_lay3				'logsig'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.821345
15.	lr_inc	1.050000			
16.	lr_dec	0.700000			
17.	err_ratio	1.04			
18.	momentum				0.572843
19.	W1_dat	'HBCW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HBCW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HBCW3.txt'	10.	selectio_press	1
22.	B1_dat	'HBCB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HBCB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HBCB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

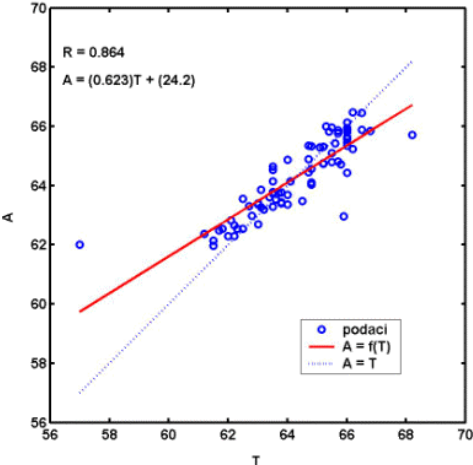
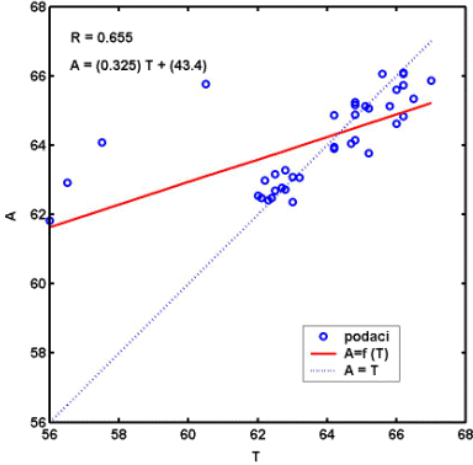
Dijagram: SSE-broj epoha



Matrice težina (*W*) i bias vektori (*B*)

W1-----	B1-----
8.5172405e-001 3.5645897e-002 6.8020194e-001 1.0895337e+000 1.0251199e+000 3.6468302e-001 8.9312482e-001 -2.0460075e+000	-2.0460075e+000
1.3466672e+000 1.8158727e-001 -1.1517365e+000 -9.1835447e-001 6.9193937e-001 1.8303815e-001 -6.0162871e-001 -1.5528735e+000	-1.5528735e+000
5.6761229e-001 -1.4322941e-001 -6.3122971e-001 -3.1999460e-001 1.3472580e+000 7.8186627e-001 -1.2227144e+000 -1.1774290e+000	-1.1774290e+000
5.3313654e-001 2.2385063e-002 7.8784930e-001 1.0558727e+000 3.7506934e-001 -1.0027727e+000 1.4750591e+000 -6.7937673e-001	-6.7937673e-001
-1.1490814e+000 2.2376773e-001 -8.6371096e-001 -6.4603991e-001 -5.1810893e-001 6.4040672e-001 1.5577051e+000 2.8426626e-001	2.8426626e-001
3.5134663e-001 9.2090726e-003 1.9378885e-001 -3.1332892e-001 7.5713871e-001 4.8886374e-001 1.9171593e+000 2.3062660e-001	2.3062660e-001
9.4448961e-002 1.8210688e-001 -5.3523741e-001 -5.4109945e-001 -1.3361537e+000 1.1209988e+000 9.1050636e-001 6.3944627e-001	6.3944627e-001
-1.0109366e+000 -1.6139591e-002 -7.2294755e-001 -1.0015417e+000 -3.8816326e-001 6.4427867e-001 -1.0648713e+000 -1.1456566e+000	-1.1456566e+000
4.1749935e-001 -2.4878578e-001 8.9503580e-001 6.9736813e-001 -5.3495662e-001 1.4157852e+000 4.5947966e-001 1.5360739e+000	1.5360739e+000
-1.1632012e+000 -7.7738410e-002 -8.5930709e-002 -1.1242972e+000 7.7472938e-001 -9.1847857e-001 5.1258805e-001 -2.0743536e+000	-2.0743536e+000
W2-----	B2-----
-1.58687e-001 -9.16929e-001 8.93276e-001 -8.60299e-001 -1.08162e+000 4.73628e-001 4.67224e-001 -9.54765e-002 8.94220e-002 -4.86059e-002	1.6158638e+000
6.28620e-001 7.02667e-001 -4.56851e-001 -9.85309e-001 2.21801e-001 -8.57630e-001 -3.50064e-001 -3.18992e-001 -2.86050e-001 -2.16872e-001	-1.3717394e+000
-6.95676e-001 -7.21081e-001 -6.59638e-001 6.14147e-001 -3.05601e-002 -4.06028e-001 2.21517e-001 6.61573e-001 1.73588e-001 -8.07776e-001	8.6320896e-001
-1.26054e-001 -4.68032e-001 -4.52125e-001 -7.94519e-004 4.53471e-001 1.05666e+000 -5.07519e-001 -9.83770e-001 3.94368e-001 8.21309e-001	5.1548828e-001
-9.12201e-001 -1.01361e-001 -7.25123e-001 -6.97421e-001 8.08130e-002 6.92990e-002 -9.50851e-002 6.88300e-001 5.45787e-001 -6.43158e-001	-1.7368606e-002
5.88902e-001 -1.66482e-001 -4.06992e-001 -1.01124e+000 4.77124e-001 -1.60081e+000 -1.00126e+000 1.07968e+000 2.21569e-001 1.47032e-001	1.2218011e-001
-5.15636e-001 7.72032e-002 -4.96389e-001 -1.08275e+000 1.11185e+000 -8.16675e-001 -5.75273e-001 -3.93449e-001 2.45536e-001 -3.10263e-001	-9.6435356e-001
9.69347e-001 8.69907e-002 7.66656e-001 -1.67764e-001 -4.79814e-001 1.17296e-001 -3.47001e-001 9.79937e-001 1.89569e-001 -4.74242e-002	1.3710278e+000
3.86926e-001 -1.01764e+000 -3.68395e-001 1.01574e+000 -3.61066e-001 -7.44953e-001 -4.40734e-001 3.57844e-001 3.38346e-001 9.89373e-001	1.6369612e+000
W3-----	B3-----
-1.2346559e+000 9.6908362e-001 4.3689557e-001 -1.3672409e+000 4.7670226e-001 -1.9386055e+000 1.6855690e+000 1.2563592e+000 -4.1691720e-001	-1.1473917e-001

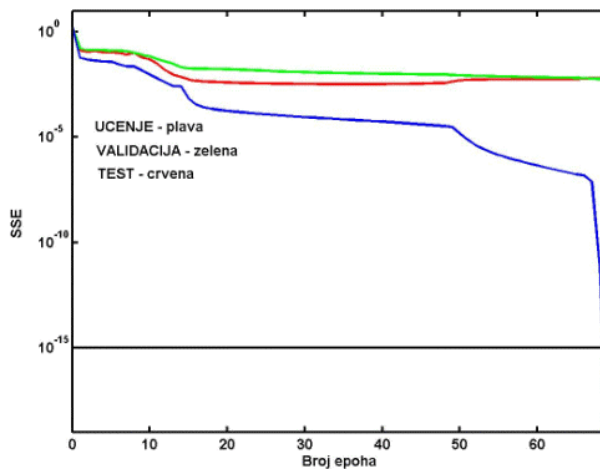
Nastavak: Tablica 4.32. Parametri i rezultati učenja *NNBMA* mreže za procjenu otpornosti popuštanju brzoreznih čelika

Naziv mreže: NNHRCBC		Procjena izlaza					Algorithm: NNBMA				
Skup za učenje						Skup za testiranje					
Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.						Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.					
											
Indeksi uspješnosti											
Skup za učenje						Skup za testiranje					
Tvrdoća	R	SSE	MSE	RMSE	NRMSE	Tvrdoća	R	SSE	MSE	RMSE	NRMSE
HRC	0.8643	63.8097	0.8396	0.9163	0.5196	HRC	0.6550	159.7189	4.2031	2.0502	0.7839

Tablica 4.33. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju brzoreznih čelika

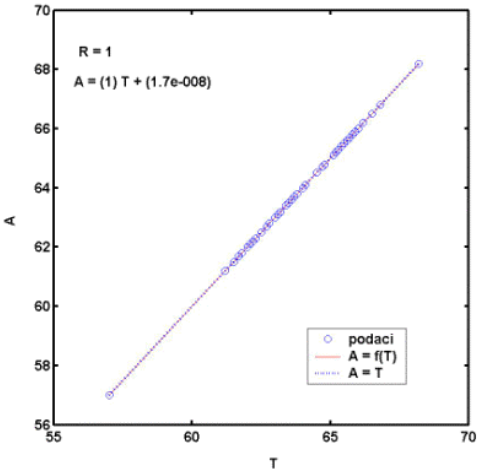
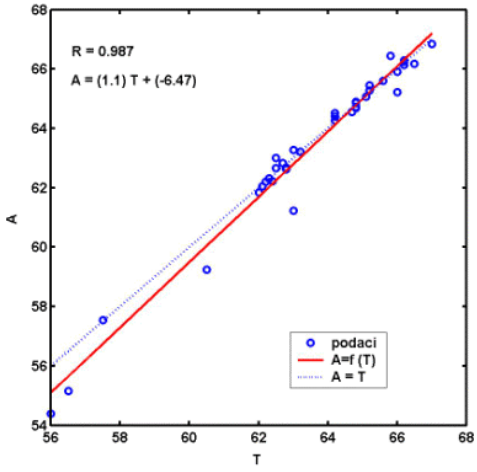
Naziv mreže: NNHRCBC			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'hrcbc_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	7	2.	alg_selekcije	0
3.	izlaz_dat	'hrcbc_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	1	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_lay1				10
7.	br_neuro_lay2				6
8.	fun_lay1				'tansig'
9.	fun_lay2				'tansig '
10.	fun_lay3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad				0.000100
15.	mu				0.447066
16.	mu_inc				10.000000
17.	mu_dec				0.100000
18.	mu_max				10000000000
19.	W1_dat	'HBCW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'HBCW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'HBCW3.txt'	10.	selectio_press	1
22.	B1_dat	'HBCB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'HBCB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'HBCB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1-----	B1-----
1.4271272e+000 1.5389133e-001 9.3429456e-001 -1.1792690e+000 6.7027709e-001 -4.1419976e-001 1.4095110e+000	-2.0164461e+000
4.1287398e-001 1.9253045e-001 8.5524817e-001 1.0011337e+000 -1.2951163e-001 -3.8014773e-001 1.7855624e+000	-1.5501377e+000
-1.849893e+000 -2.1583920e-001 1.5873254e-001 5.9108274e-001 -3.6190731e-001 1.1263781e+000 5.7329148e-001	1.0876619e+000
1.5134482e+000 -9.6727514e-003 -9.5368536e-001 4.4212721e-001 -8.8514671e-001 -1.2278561e+000 7.8410708e-001	-6.8739118e-001
-6.4077700e-001 -1.5161406e-001 -7.1739714e-001 1.1076221e+000 -8.7795264e-001 1.4391550e+000 -4.5471888e-001	-2.6622784e-001
7.7692317e-001 1.7606834e-001 -6.5946967e-001 1.3790248e-001 -1.4259927e+000 1.7544102e+000 1.4875182e+000	2.7234142e-001
4.4005174e-001 1.2536003e-003 -4.3325711e-001 -5.4798812e-001 8.7412736e-001 -8.3053360e-001 1.8690288e+000	6.8528639e-001
1.0788178e+000 -1.8130325e-001 8.5146882e-001 -1.0527654e+000 -5.1829440e-002 8.2449701e-001 -6.3499377e-001	1.0962958e+000
-2.2572202e-001 -5.3961881e-002 -1.6578416e+000 7.1202218e-001 -5.1251471e-003 1.2553859e+000 1.5031276e+000	1.5847798e+000
-8.2675768e-001 -1.6823104e-001 -1.0786464e-001 -1.5297459e-001 8.0800327e-001 2.8907983e-001 2.7918121e+000	-2.0969767e+000
W2-----	B2-----
-3.57697e-001 9.59377e-001 2.02726e+000 5.97700e-002 1.19541e+000 -9.98130e-001 -7.39269e-001 -4.39251e-001 -5.53090e-001 -6.36920e-001	-1.3312556e+000
1.09696e+000 -5.39481e-001 8.77147e-001 1.21617e+000 3.57770e-001 5.02227e-002 7.54837e-001 -1.18109e-002 -1.80033e-001 1.20764e+000	-1.7290639e-001
5.95820e-001 5.79891e-001 8.34679e-001 2.71823e-001 -1.56883e-001 2.57408e-001 5.09764e-003 -1.13636e-001 1.55712e-003 -9.24284e-002	-1.1678286e-001
6.59512e-001 7.41841e-002 -8.19973e-001 -4.98983e-001 -9.70972e-001 -4.16666e-001 -6.49735e-001 -2.39213e-001 8.57289e-001 1.48047e-001	-2.4389059e-001
1.91749e+000 1.79179e-001 -2.36187e-001 5.23747e-002 -5.43105e-001 -3.74196e-001 3.82829e-001 -3.76695e-001 -4.38376e-001 7.05175e-001	1.1360987e+000
-5.62615e-001 3.22512e-001 -6.70481e-001 3.56488e-001 3.25743e-001 -1.03820e+000 1.32983e+000 3.35890e-001 -4.31668e-001 4.91153e-001	-1.4429396e+000
W3-----	B3-----
6.8129685e-001 -1.8146673e+000 1.4784512e+000 1.2723062e+000 -5.9898846e-001 8.4449222e-001 5.0690432e-001	

Nastavak: Tablica 4.33. Parametri i rezultati učenja *NNLM* mreže za procjenu otpornosti popuštanju brzoreznih čelika

Naziv mreže: NNHRCBC		Procjena izlaza						Algoritam: NNLM					
Skup za učenje						Skup za testiranje							
<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p> 						<p><i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.</p> 							
Indeksi uspješnosti													
Skup za učenje						Skup za testiranje							
Tvrdoća	R	SSE	MSE	RMSE	NRMSE	Tvrdoća	R	SSE	MSE	RMSE	NRMSE		
HRC	1.0000	0.0000	0.0000	0.0000	0.0000	HRC	0.9875	11.0623	0.2911	0.5395	0.2063		

4.4.11. Procjena mehaničkih svojstava alatnih čelika pri povišenim temperaturama

Za čelike za rad pri povišenim temperaturama (alatni čelici za topli rad, brzorezni čelici) treba proširiti pristup otpornosti popuštanju, zbog toga što je važno kako će se oni ponašati pri povišenim temperaturama, a ne nakon hlađenja s tih temperatura. Prema tome, pod otpornošću prema popuštanju u širem smislu podrazumijevaju sljedeće otpornosti pri povišenim temperaturama:

1. Otpornost na pad R_m , R_e (ili $R_{p0,2}$) i HV
2. Otpornost na trošenje
3. Otpornost na oksidaciju
4. Otpornost na promjenu mjera
5. Otpornost na toplinski umor

Svi čelici imaju pri povišenim temperaturama više ili manje (ovisno o stupnju legiranosti), niže R_m , R_e (ili $R_{p0,2}$) i HV nego pri 20°C dok im je žilavost KV u pravilu viša. Prema dostupnim literaturnim podacima [45] u tablici P1.42 u prilogu I u radu su razmatrane promjene mehaničkih svojstava R_m , $R_{p0,2}$ i A_5 alatnih čelika za topli rad Č9750, Č5742, Č4751, Č4753, Č7450, Č6451 (izvod dijela podataka prikazan je na slici 4.28) u zavisnosti od kemijskog sastava i temperature popuštanja T_p .

%C	%Si	%Mn	%Cr	%Ni	%Mo	%W	%V	%Co	T_p °C	R_m N/mm ²	$R_{p0,2}$ N/mm ²	A_5 %
C 5742												
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	250	1430	1210	8,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	300	1400	1190	8,2
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	350	1330	1100	7,9
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	400	1250	990	8,2
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	450	1120	800	10,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	500	950	540	15,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	550	700	360	20,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	600	450	250	29,0
C 4751												
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	250	1420	1190	8,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	300	1410	1180	9,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	350	1400	1130	9,0

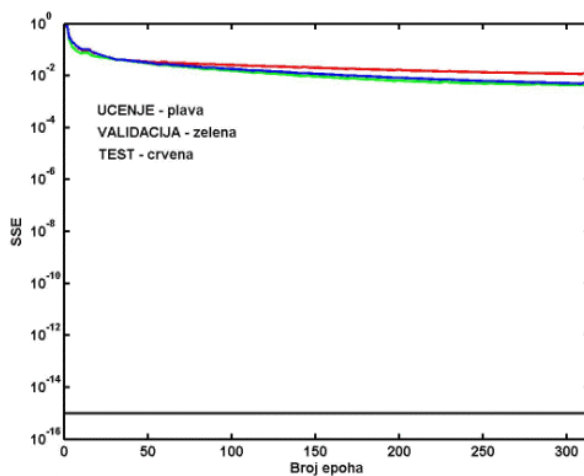
Slika 4.28. Mehanička svojstva R_m , $R_{p0,2}$ i A_5 alatnih čelika za topli rad pri povišenim temperaturama (izvod iz tablice P1.42 u prilogu I)

U tablicama 4.34 i 4.35 prikazani su parametri učenja dvaju algoritama (*NNBMA* i *NNLM*) neuronskih mreža za procjenu mehaničkih svojstava alatnih čelika za topli rad pri povišenim temperaturama sa indeksima uspješnosti učenja. Parametri obaju algoritama dobiveni su pomoću *GA*-algoritama, a ciklus ponavljanja učenja sa istim parametrima za svaki algoritam izveden je sto puta. Usvojene su matrice težina i bias vektor za onaj ciklus koji je postigao najmanji *SSE*.

Tablica 4.34. Parametri i rezultati učenja *NNBMA* mreže za procjenu mehaničkih svojstva alatnih čelika za rad na povišenim temperaturama

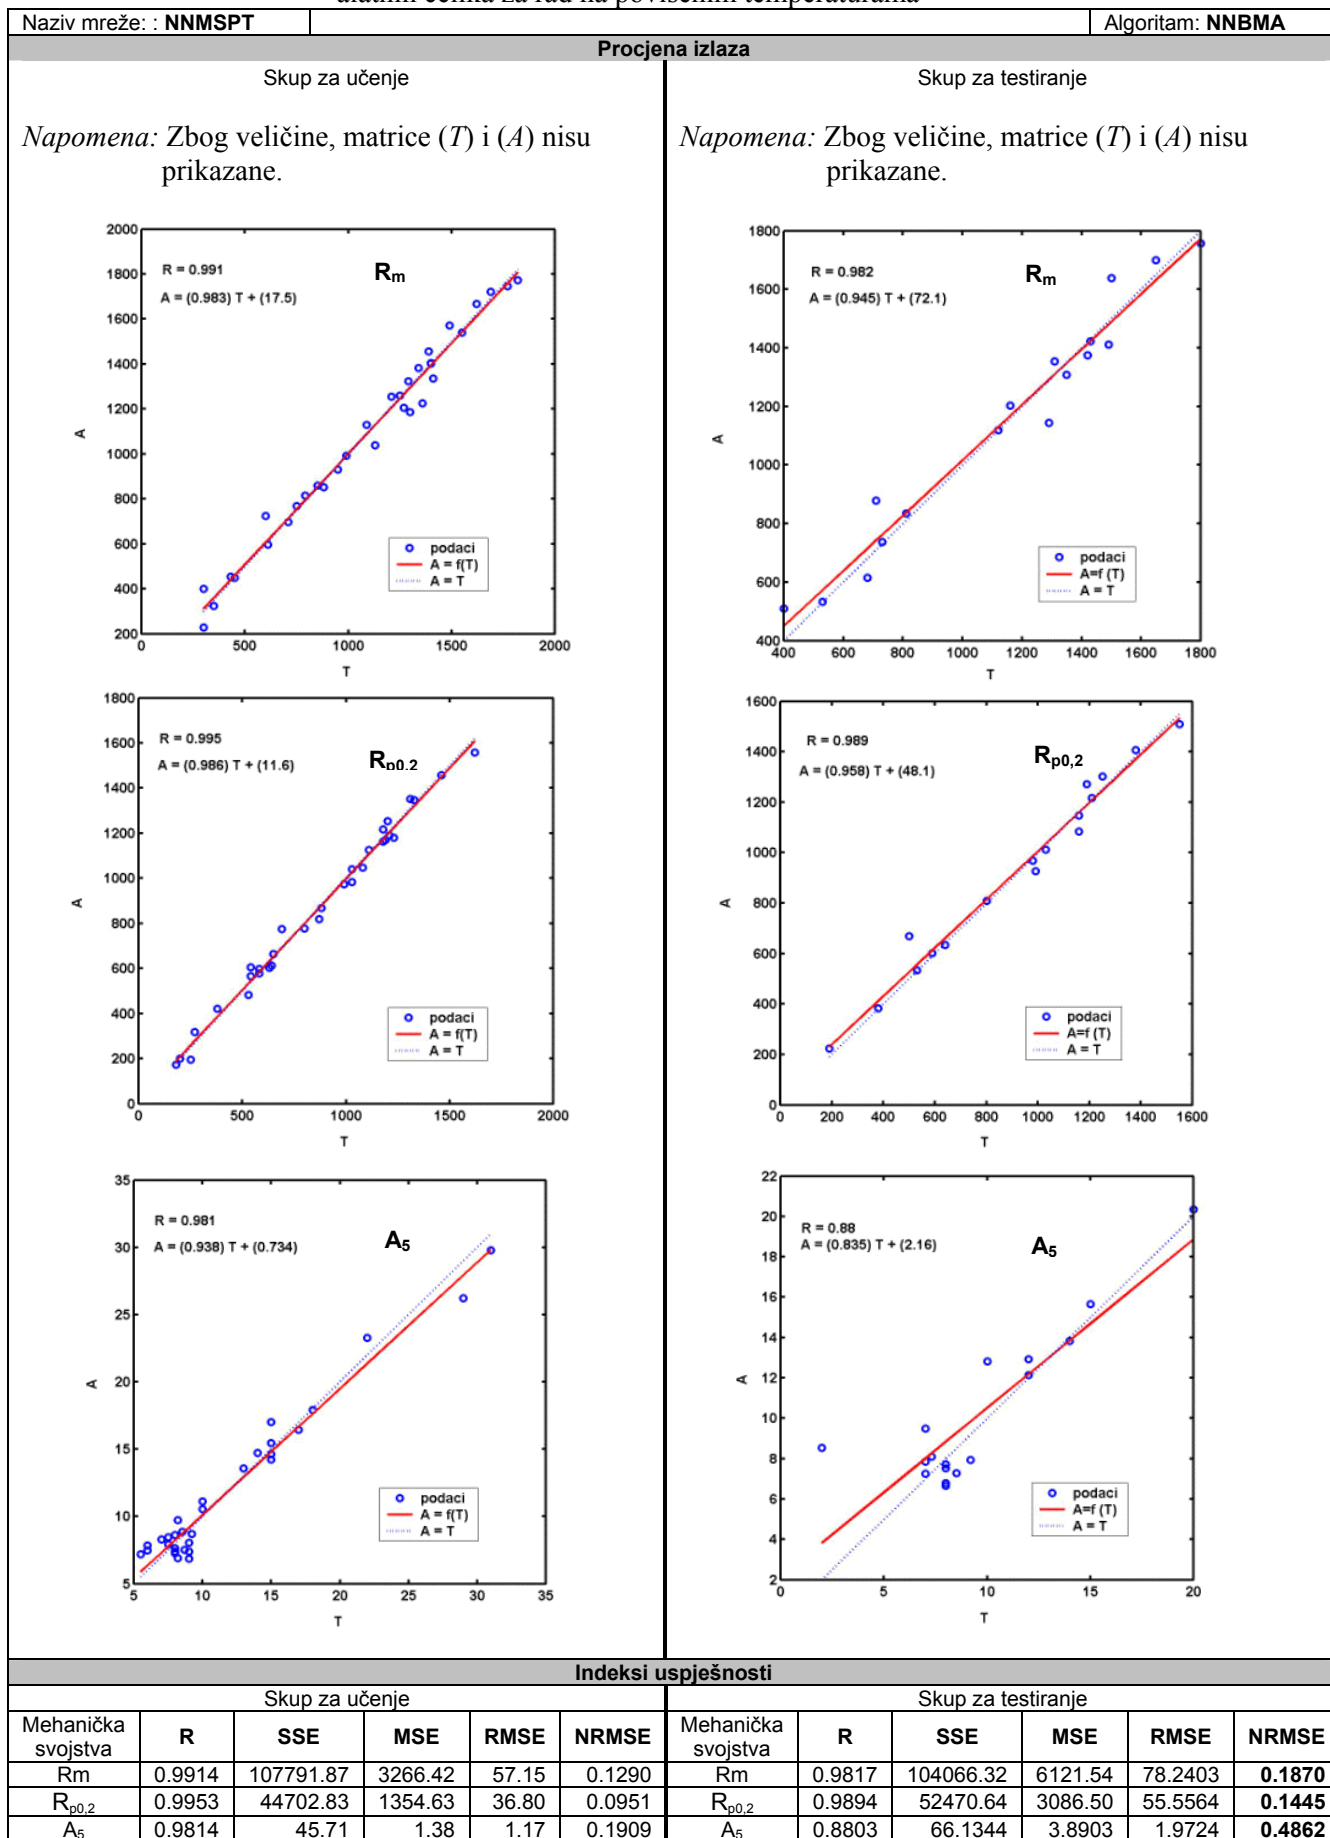
Naziv mreže: NNMSPT			Algorithm: NNBMA		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'mst_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	10	2.	alg_selekcije	0
3.	izlaz_dat	'mst_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	3	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_layer1				10
7.	br_neuro_layer2				9
8.	fun_layer1				'tansig'
9.	fun_layer2				'tansig'
10.	fun_layer3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	lr				0.849036
15.	lr_inc	1.050000			
16.	lr_dec	0.700000			
17.	err_ratio	1.04			
18.	momentum				0.395684
19.	W1_dat	'MSTW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'MSTW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'MSTW3.txt'	10.	selectio_press	1
22.	B1_dat	'MSTB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'MSTB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'MSTB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1-----	B1-----
-1.30320e-001 5.25610e-001 4.55437e-001 7.90848e-002 -2.61099e-001 6.89226e-001 7.85781e-001 -8.11486e-001 1.85533e-001 5.64249e-001	1.9295020e+000
-4.70287e-002 -9.76380e-001 2.65199e-001 -7.62760e-001 -6.30538e-002 3.41108e-001 1.66565e-001 5.80970e-001 -4.36036e-001 6.76142e-001	1.3365727e+000
7.30024e-001 2.20684e-001 4.37401e-002 2.57886e-001 -7.51735e-001 3.53839e-001 -1.09984e+000 4.76610e-001 -3.34511e-001 -7.53393e-001	-8.1211729e-001
4.01542e-001 -7.30994e-001 -4.66650e-001 1.31810e-001 -1.92256e-001 4.48226e-001 9.04556e-001 -1.97882e-001 -6.59333e-001 1.29299e+000	-6.0943701e-001
-6.77498e-002 -5.82126e-001 -2.43527e-002 -6.36730e-001 9.26346e-001 6.28660e-001 -9.58771e-001 1.21545e-001 -5.94954e-001 6.66762e-001	-1.9324156e-002
8.64135e-001 6.05151e-001 4.19041e-001 5.45672e-001 -6.11854e-001 7.12462e-001 3.00189e-001 5.49772e-001 7.46544e-001 -4.37140e-001	1.4215173e-001
-2.91461e-001 8.33881e-001 -5.80432e-002 -5.96196e-001 3.42344e-001 4.25475e-001 8.10712e-002 7.21661e-001 6.19306e-001 9.40733e-001	-4.8034350e-001
9.51637e-001 8.11311e-001 -7.98304e-001 8.59044e-001 2.20469e-001 -2.96796e-001 6.33884e-001 -4.34808e-001 8.54628e-002 9.76535e-001	9.0721200e-001
7.66135e-001 -4.61958e-001 -1.52526e-001 6.08101e-001 -5.66206e-001 6.51431e-001 -1.72622e-001 5.64444e-001 -8.63613e-001 1.88472e-001	1.4481741e+000
7.66065e-003 -5.21358e-001 -2.07510e-001 -3.08582e-001 -7.25307e-001 7.14083e-001 8.42780e-002 6.97959e-001 -5.30502e-001 -7.02208e-001	-1.9058457e+000
W2-----	B2-----
4.42781e-001 -6.62247e-001 -8.24123e-001 -6.15610e-001 -1.98270e-001 3.35692e-001 -4.67099e-001 -4.41481e-001 1.55008e-001 6.50097e-001	-1.8768721e+000
5.27125e-001 3.95639e-001 -7.31665e-001 3.98604e-001 6.32413e-002 3.47321e-001 6.69098e-001 7.36608e-001 1.60540e-001 7.05770e-001	-1.4815829e+000
-3.74986e-001 -7.41738e-001 8.30401e-001 6.77095e-001 -4.18455e-001 8.56443e-002 -5.32844e-001 5.62227e-001 6.38726e-001 4.33071e-001	8.4587635e-001
2.62470e-001 1.99395e-001 -4.93026e-001 -7.20775e-001 -1.09309e+000 3.10018e-002 4.85045e-002 -8.51286e-001 2.91921e-001 -4.10247e-001	-6.4690767e-001
3.38481e-001 -5.71081e-001 6.17966e-001 -5.40109e-001 2.23401e-001 9.81761e-001 -5.72417e-001 -9.37395e-001 5.10606e-001 -3.17621e-001	1.8353285e-001
-1.02218e+000 2.74081e-002 -5.49781e-001 7.93763e-001 7.67852e-001 6.15075e-002 -8.11784e-002 -5.08691e-001 -4.85715e-002 -3.82861e-001	-5.5182042e-001
6.03404e-001 -1.01475e-001 -2.00342e-001 -1.24105e-001 -9.21445e-001 1.13178e-000 -5.72078e-001 -8.87014e-001 -2.56854e-001 -3.73804e-001	8.8860481e-001
-7.16186e-001 3.94327e-001 -5.03206e-001 9.09298e-001 8.30921e-001 -5.20314e-001 -4.57092e-001 1.70266e-001 6.25751e-001 -2.55084e-001	-1.3752793e+000
-2.21606e-001 -4.79893e-001 -2.87687e-001 7.09883e-001 2.78904e-001 -3.91161e-001 1.08351e+000 5.63181e-001 8.07579e-001 -9.38390e-001	-1.7003522e+000
W3-----	B3-----
8.38367e-001 -1.02572e-002 -1.65196e-001 2.64048e-001 3.99358e-002 -3.81793e-001 8.46441e-001 3.25433e-001 -7.09733e-001	-2.9778029e-001
-8.67676e-002 4.02533e-001 3.45623e-001 9.87136e-001 3.01196e-001 2.60880e-001 1.10058e-001 9.29979e-002 -5.72491e-001	-2.9178557e-001
5.81523e-001 -3.90212e-001 -5.23094e-002 -1.16954e-001 -7.49480e-001 5.12042e-001 -1.14395e+000 -7.93145e-001 -2.72922e-001	8.5948037e-001

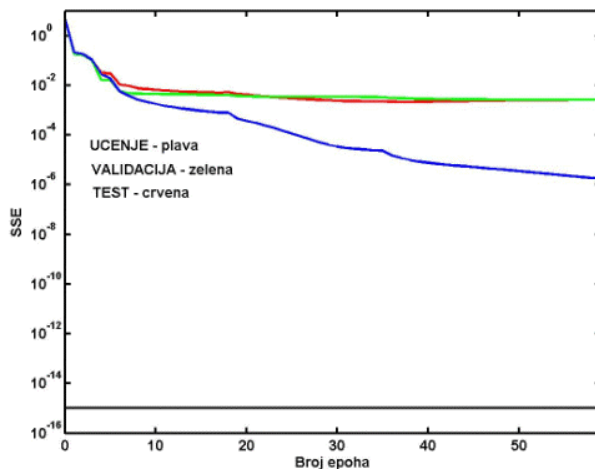
Nastavak: Tablica 4.34. Parametri i rezultati učenja *NNBMA* mreže za procjenu mehaničkih svojstva alatnih čelika za rad na povišenim temperaturama



Tablica 4.35. Parametri i rezultati učenja *NNLM* mreže za procjenu mehaničkih svojstva alatnih čelika za rad na povišenim temperaturama

Naziv mreže: NNMSPT			Algoritam: NNLM		
Red.broj	NN - parametri		Red.broj	GA - parametri	
1.	ulaz_dat	'mst_ul.txt'	1.	ispis_grafike	2
2.	br_kol_ulaz	10	2.	alg_selekcije	0
3.	izlaz_dat	'mst_iz.txt'	3.	alg_mutacije	21
4.	br_kol_izlaz	3	4.	alg_rekombinacije	14
5.	br_layera				3
6.	br_neuro_layer1				10
7.	br_neuro_layer2				9
8.	fun_layer1				'tansig'
9.	fun_layer2				'tansig'
10.	fun_layer3				'purelin'
11.	disp_freq	100	5.	broj_generacija	50
12.	max_epoch	10000	6.	real_var_iznos	0
13.	err_goal	1e-15	7.	broj_individua	22
14.	min_grad				0.000100
15.	mu				0.300376
16.	mu_inc				10.000000
17.	mu_dec				0.100000
18.	mu_max				10000000000
19.	W1_dat	'MSTW1.txt'	8.	broj_subpopulacija	3
20.	W2_dat	'MSTW2.txt'	9.	generatio_gap	0.8
21.	W3_dat	'MSTW3.txt'	10.	selectio_press	1
22.	B1_dat	'MSTB1.txt'	11.	strukt_selekt	0
23.	B2_dat	'MSTB2.txt'	12.	migration_rate	0.25
24.	B3_dat	'MSTB3.txt'	13.	migration_strukt	0
25.	norm_ulaz	1	14.	inicijalizacija	0
26.	norm_izlaz	1			
27.	chek_early_stopping	1			
28.	chek_val_data	1			
29.	chek_test_data	1			

Dijagram: SSE-broj epoha

Matrice težina (*W*) i bias vektori (*B*)

W1-----	B1-----
-2.10510e-001 3.58800e-001 -3.95513e-001 -1.16761e-001 -2.39899e-001 1.56722e-001 1.72859e-001 -8.26231e-001 -1.19123e+000 1.19821e+000	1.8941320e+000
-4.44737e-001 -4.03597e-001 -7.05984e-001 1.11477e+000 -8.88379e-001 -3.68768e-001 9.57803e-001 4.46154e-002 -3.17900e-001 -2.22769e+000	9.2515289e-001
2.96362e-001 -6.21736e-001 7.52664e-001 1.64165e-001 -2.65553e-002 -1.28681e+000 5.39590e-001 -5.84478e-001 -1.82662e-001 -9.38025e-001	-1.2327998e+000
6.11177e-001 6.29093e-001 2.63408e-001 8.70376e-001 -1.07091e+000 7.05562e-001 -4.11060e-001 2.80117e-004 6.13809e-001 -6.68025e-001	-3.7664819e-001
4.40122e-001 -5.40743e-001 -1.09164e-001 2.06584e-001 -6.16752e-001 -1.61508e-001 -1.45598e-001 -3.83385e-001 -9.10918e-001 1.93875e+000	3.5128225e-002
-4.83008e-001 -3.90226e-001 -3.29280e-001 -1.19847e+000 4.25967e-001 6.64047e-001 6.74498e-001 -3.41897e-001 -3.76977e-001 -1.79731e+000	-4.2316313e-001
5.80790e-001 9.69597e-001 6.59045e-001 4.06167e-001 3.01531e-001 2.99981e-001 -8.10336e-001 4.95074e-001 1.34835e+000 -6.36558e-001	8.4133868e-001
-3.64421e-001 8.19694e-001 8.43511e-001 2.49290e-001 3.03760e-001 -6.90726e-001 -3.05748e-001 -6.25772e-001 8.34954e-003 -9.74532e-001	-1.0761638e+000
3.62791e-001 -2.10126e-001 -2.32476e-001 9.98998e-001 2.06326e-001 -1.23590e+000 8.80250e-001 7.94514e-001 8.88272e-001 4.04444e-002	8.8974126e-001
8.33373e-001 -9.07087e-001 -4.50147e-001 2.66050e-001 6.30865e-001 5.42171e-001 6.09628e-001 -7.19832e-002 -3.22899e-001 -1.64222e+000	1.7067846e+000
W2-----	B2-----
-3.75711e-001 1.04461e+000 -7.59781e-001 8.45416e-001 -1.01948e+000 9.15426e-002 1.37931e-001 -1.11883e-002 2.68370e-001 -6.26087e-002	1.4804786e+000
-8.89192e-002 -5.09045e-002 7.85447e-001 -2.47744e-001 1.19314e+000 1.17566e+000 1.26576e+000 1.65838e-001 1.45148e+000 -2.68480e-001	1.4437114e+000
-5.17477e-001 7.10906e-001 6.38523e-001 8.17209e-001 6.36956e-002 -1.49491e-001 9.62918e-001 2.08782e-001 5.16901e-001 1.21685e+000	5.8504700e-001
4.14116e-001 -4.35335e-001 -7.41364e-001 -4.04219e-001 5.07223e-001 1.16521e+000 -2.82888e-001 -2.10351e-001 -8.40469e-002 -9.32038e-001	-5.0830120e-001
-7.75712e-001 -1.21389e+000 7.07160e-002 6.20736e-001 2.81442e-001 -9.48689e-001 -5.52023e-001 6.90724e-001 1.41038e+000 -1.36991e-001	1.2299099e-001
7.39985e-001 -4.72869e-001 -5.02581e-001 1.17170e+000 -1.30100e-001 -9.85096e-001 -6.34045e-001 -1.53430e-001 6.25278e-001 -2.15172e-001	1.8845147e-001
-2.13496e-001 -3.79929e-001 6.51188e-001 4.80351e-001 4.77346e-001 9.87943e-001 -7.02969e-001 -9.96000e-002 -6.79802e-002 -1.25493e-001	-7.9962504e-001
6.74324e-001 1.32578e+000 -2.58218e-001 5.71460e-001 -2.32616e-001 1.81741e+000 6.12767e-001 -4.78989e-001 -5.92453e-001 -1.34980e-001	1.5413933e+000
6.41643e-002 -6.19895e-001 8.05713e-001 -5.31315e-002 1.06580e+000 1.33172e+000 -1.32593e-001 1.17595e+000 5.07940e-002 -2.02997e-001	-1.4071676e+000
W3-----	B3-----
1.6637197e-001 1.6436735e-001 7.6910833e-001 9.3633459e-002 -1.2246477e+000 -2.1042223e-001 -4.2593688e-001 -3.8525302e-001 4.7800814e-001 -7.3616728e-001	-7.3616728e-001
-3.6012801e-001 -1.2947978e-001 1.3865077e-001 -9.0599167e-001 -2.8746566e-001 -5.2345904e-001 3.5374317e-001 9.8551481e-001 -3.9004581e-001 -9.2703364e-001	-9.2703364e-001
-1.1127318e+000 -8.7942928e-001 2.2999712e-001 -2.7094617e-002 1.3040981e+000 -1.2068668e-001 1.4542672e-001 4.8857510e-001 -7.7349074e-001 5.6035934e-001	5.6035934e-001

Nastavak: Tablica 4.35. Parametri i rezultati učenja *NNLM* mreže za procjenu mehaničkih svojstva alatnih čelika za rad na povišenim temperaturama

Naziv mreže: NNMSPT		Procjena izlaza					Algoritam: NNLM				
Skup za učenje						Skup za testiranje					
<p><i>Napomena:</i> Zbog veličine, matrice (<i>T</i>) i (<i>A</i>) nisu prikazane.</p>						<p><i>Napomena:</i> Zbog veličine, matrice (<i>T</i>) i (<i>A</i>) nisu prikazane.</p>					
Indeksi uspješnosti						Indeksi uspješnosti					
Skup za učenje						Skup za testiranje					
Mehanička svojstva	R	SSE	MSE	RMSE	NRMSE	Mehanička svojstva	R	SSE	MSE	RMSE	NRMSE
R _m	1.0000	65.3552	1.9805	1.4073	0.0032	R _m	0.9969	21890.5231	1287.6778	35.8842	0.0858
R _{p0.2}	1.0000	50.6616	1.5352	1.2390	0.0032	R _{p0.2}	0.9989	5178.8657	304.6392	17.4539	0.0454
A ₅	1.0000	0.0130	0.0004	0.0199	0.0032	A ₅	0.9720	17.4979	1.0293	1.0145	0.2501

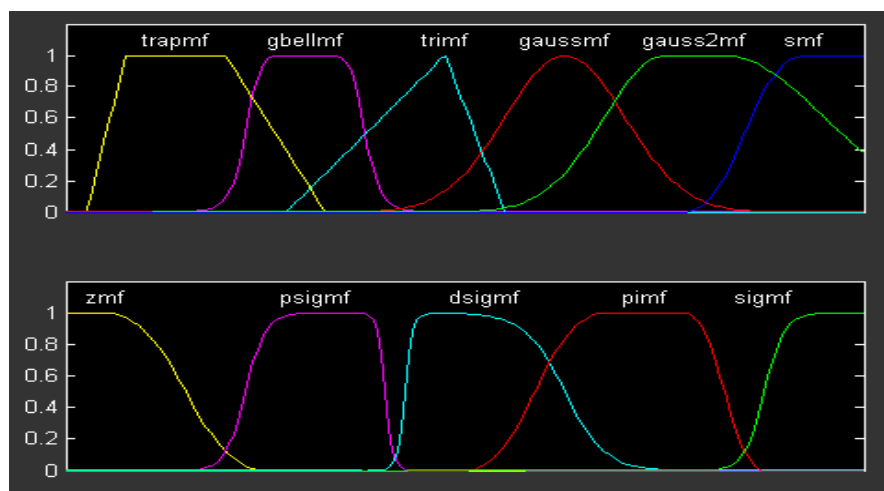
4.5. Definicije ulazno-izlaznih skupova neizrazite logike

Mehanička svojstva koja se procjenjuju metodama neizrazite logike jesu: vlačna čvrstoća- R_m , granica razvlačenja- R_e , tvrdoća po *Vickers-u*- H_V , istezljivost- A_5 i otpornost trošenju. Za sva nabrojana mehanička svojstva zasebno su definirani *fuzzy* mehanizmi zaključivanja (*FIS*-ovi) za kaljeno i za poboljšano stanje na temelju podataka iz tablica P1.30, P1.31, P1.32, P1.33 u prilogu I. S obzirom da su ulazno-izlazni skupovi podataka o mehaničkim svojstvima numeričkog tipa, primjenjen je *Sugeno* model, a za optimiranje tipa funkcija pripadnosti te njihovog položaja (pronalaženja tipičnih vrijednosti) unutar *univerzalnog skupa* (engl. *universe of discourse*) primjenjen je hibridni algoritam učenja - *ANFIS* (engl. *adaptive network fuzzy inference system*). *Sugeno* model, kao model za procjenu mehaničkog svojstva, primjenjen je u slučajevima 'dovoljnog' broja ulaznih skupova podataka, dok je za procjenu mehaničkih svojstva sa 'relativno malim' brojem ulaznih skupova podataka kao model procjene, primjenjen *Mamdani* model. Pri modeliranju *FIS*-ova primjenjeni su standardni operatori i metode kako je prikazano u tablici 4.36.

Tablica 4.36. Prikaz operatora i metoda *fuzzy* zaključivanja [17]

Faza	Operator	Metoda	Fuzzy model
Fazifikacija	AND	min	Mamdami, Sugeno
	OR	max	
Implikacija		min	Mamdami
Agregacija		max	Mamdami
Defazifikacija		CoM	Mamdami
		wtaver	Sugeno

Na slici 4.29 prikazani su standardni oblici ulazno-izlaznih funkcija pripadnosti s kojima je eksperimentirano pri modeliranju pojedinih *FIS*-ova za procjenu mehaničkih svojstava. Za *Sugeno* model izlazne funkcije pripadnosti mogu biti linearnog (*linear*) tipa i tipa konstante (*constant*).



Slika 4.29. Standardni oblici funkcija pripadnosti [17]

U cilju smanjenja broja pravila, kod *ANFIS* modela učenja pojedinih *FIS*-ova, primjenjena je 'sub.clustering' metoda klasteriranja ulazno-izlaznih skupova podataka. Standardni parametri ove metode prikazani su u tablici 4.37.

Tablica 4.37. Prikaz standardnih *ANFIS* parametara [17]

BP+LSQ parametri	Iznos	Klaster parametari	Iznos
koef. brzine učenja - <i>ss</i>	0.01	Range of influence - <i>Rofi</i>	0.50
koef. povećanja <i>ss</i> - <i>ssinc</i>	1.10	Squash factor - <i>Sf</i>	1.25
koef. smanjenja <i>ss</i> - <i>ssdec</i>	0.90	Accept ratio - <i>Ar</i>	0.50
		Reject ratio - <i>Rr</i>	0.15

4.5.1. Ulazno-izlazni skupovi za procjenu R_m , R_e , HV i A_5 u kaljenom stanju

Ulazni skup za procjenu R_m i HV čine podaci o kemijskom sastavu: (C , Si , Mn , Cr , Ni , Mo), a izlazni skup čine podaci za R_m i HV . Primjenjen je *Sugeno* model, a podaci su podijeljeni na dva skupa: skup za učenje i skup za testiranje. Zbog relativno malog skupa podataka, umjesto generatorom slučajnih brojeva, izuzimanje podataka za testiranje napravljeno je 'ručno'. Pri izuzimanju podataka za testiranje, vodilo se računa o tome da podaci skupa za učenje pokrivaju *univerzalni skup* podataka za testiranje. Na slikama 4.30 i 4.31 prikazane su ulazno-izlazne matrice za učenje i testiranje procjena R_m i HV . Prikaz parametara, struktura *FIS*-a, oblik funkcija pripadnosti, pravila, dijagrami zaljučivanja, rezultati procjene sa indeksima uspješnosti dano je u tablicama 4.38, 4.39, 4.40 i 4.41.

ULAZNI SKUP						A	IZLAZNI SKUP						
0.12	1.50	0.00	18.00	9.00	0.00	540.00	0.04	1.00	0.00	27.00	6.00	3.50	800.00
0.50	2.50	1.30	18.00	9.00	0.00	880.00	0.15	1.00	1.00	12.50	0.00	0.00	1030.00
0.21	1.00	1.00	13.00	0.00	0.000	1570.00	0.18	1.00	1.00	16.50	2.00	0.00	950.00
0.63	1.00	2.00	26.50	5.30	1.65	700.00							

Slika 4.30. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene R_m u kaljenom stanju

ULAZNI SKUP						A	IZLAZNI SKUP						
0.04	1.0	0.0	27.0	6.0	3.5	255	0.12	1.5	0.0	18.0	9.0	0.00	165
0.15	1.0	1.0	12.5	0.0	0.0	305	0.21	1.0	1.0	13.0	0.0	0.00	450
0.18	1.0	1.0	16.5	2.0	0.0	295	0.63	1.0	2.0	26.5	5.3	1.65	210

Slika 4.31. Ulazno-izlazna matrice za učenje (A) i za testiranje (B) procjene HV u kaljenom stanju

Za procjenu R_e u kaljenom stanju primjenjen je *Mamdani* model zbog vrlo malog broja skupa ulazno-izlaznih podataka. Prema tablici P1.30 u prilogi I ukupno su na raspolaganju tri sloga. Za razliku od procjene R_m gdje su kao ulazni skup podaci o kemijskom sastavu, ovdje je ulazni skup stupanj legiranosti Le (zbroj kemijskih elemenata pojedinog materijala) i procjena za R_m . U ovom slučaju varijabla R_m uvedena kao varijabla indirektnog zaključivanja, što znači, da se poznaje iznos R_m , može se indirektno zaključiti o iznosu R_e . Analizom podataka iz tablica P1.30 i P1.31 u prilogu I, zaključuje se, da se sa povećanjem R_m povećava i R_e . Slično pravilo vrijedi i za stupanj legiranosti Le . Što je viši stupanj legiranosti to je viša R_e . Na temelju ovih zaključaka modelirane su funkcije pripadnosti i pravila *FIS*-a za procjenu R_e i to na sljedeći način:

- Zbrajanjem iznosa kemijskih elemenata pojedinih materijala dobiven je vektor stupnja legiranosti Le :
 $Le=[28.62, 37.54, 31.3, 14.65, 15.21, 20.68, 37.08]$
- Definiran je vektor R_m :
 $R_m=[540, 800, 880, 1030, 1570, 950, 700]$
- Definiran je vektor R_e :
 $R_e=[175, 640, 390]$
- Za svaki od vektora Le , R_m i R_e definirana su tri područja vrijednosti, tako da svaki od elemenata vektora ulazi u jedno područje vrijednosti. Prvom području iznosa dodijeljeno je lingvističko značenje 'nisko', drugom 'srednje', a trećem 'visoko':
 $Le_{nisko}=[10...20]$, $Le_{srednje}=[21...30]$, $Le_{visoko}=[31...40]$
 $Rm_{nisko}=[500...800]$, $Rm_{srednje}=[801...1100]$, $Rm_{visoko}=[1101...1600]$
 $Re_{nisko}=[100...200]$, $Re_{srednje}=[201...400]$, $Re_{visoko}=[401...600]$
- Univerzalni skup za svaki od vektora dijeljen je na tri dijela funkcijama pripadnosti trokutastog oblika, a funkcijama su dodijeljene lingvistička značenja: *nisko*, *srednje* i *visoko*. Pravila *FIS*-a tada glase:

If $Le=srednje$ (28.62) **and** $Rm=nisko$ (540) **then** $Re=nisko$ (175) (P1)
If $Le=visoko$ (37.54) **and** $Rm=nisko$ (800) **then** $Re=visoko$ (640) (P2)
If $Le=visoko$ (31.30) **and** $Rm=srednje$ (880) **then** $Re=srednje$ (390) (P3)

Kod ove procjene, zbog nedostatka podataka nije bilo moguće definirati skup za testiranje, te je skup podataka za učenje istodobno i skup za testiranje. Prikaz parametara, struktura *FIS*-a, oblik funkcija pripadnosti, pravila, dijagrami zaljučivanja, rezultati procjene sa indeksima uspješnosti dano je u tablici 4.39.

Za procjenu A_5 u kaljenom stanju primjenjen je *Mamdani* model zbog vrlo malog broja skupa ulazno-izlaznih podataka. Prema tablici P1.30 u prilogi I ukupno su na raspolaganju četiri sloga. I u ovom je slučaju, kao i kod procjene R_m , varijabla R_m uvedena kao varijabla indirektnog zaljučivanja, što znači, da ako poznajemo iznos R_m možemo indirektno zaključiti o iznosu A_5 . Analizom podataka iz tablice P1.30 može se zaključiti, da se sa povećanjem R_m povećava i A_5 . Slično pravilo vrijedi i za stupanj legiranosti Le . Što je viši stupanj legiranosti to je viša A_5 . Na temelju ovih zaključaka modelirane su funkcije pripadnosti i pravila *FIS*-a za procjenu A_5 i to na sljedeći način:

1. Zbrajanjem iznosa kemijskih elemenata pojedinih materijala dobiven je vektor stupnja legiranosti Le :

$$Le=[28.62, 37.54, 31.3, 14.65, 15.21, 20.68, 37.08]$$

2. Definiran je vektor R_m :

$$R_m=[540, 800, 880, 1030, 1570, 950, 700]$$

3. Definiran je vektor Re :

$$A_5=[20, 25, 25, 20]$$

4. Za svaki od vektora Le , R_m i A_5 definirana su tri područja vrijednosti, tako da svaki od elemenata vektora ulazi u jedno područje vrijednosti. Prvom području iznosa dodijeljeno je lingvističko značenje 'nisko', drugom 'srednje', a trećem 'visoko':

$$\begin{array}{lll} Le_{nisko}=[10...20], & Le_{srednje}=[21...30], & Le_{visoko}=[31...40] \\ R_{m_{nisko}}=[500...800], & R_{m_{srednje}}=[801...1100], & R_{m_{visoko}}=[1101...1600] \\ A_{5_{nisko}}=[20...21,5], & A_{5_{srednje}}=[21,6...23,2], & A_{5_{visoko}}=[23,3...25] \end{array}$$

5. Univerzalni skup za svaki od vektora dijeljen je na tri dijela funkcijama pripadnosti trokutastog oblika, a funkcijama su dodijeljene lingvistička značenja: *nisko*, *srednje* i *visoko*. Pravila *FIS*-a tada glase:

$$\text{If } Le=srednje \text{ (28.62) and } R_m=nisko \text{ (540) then } A_5=nisko \text{ (20) (P1)}$$

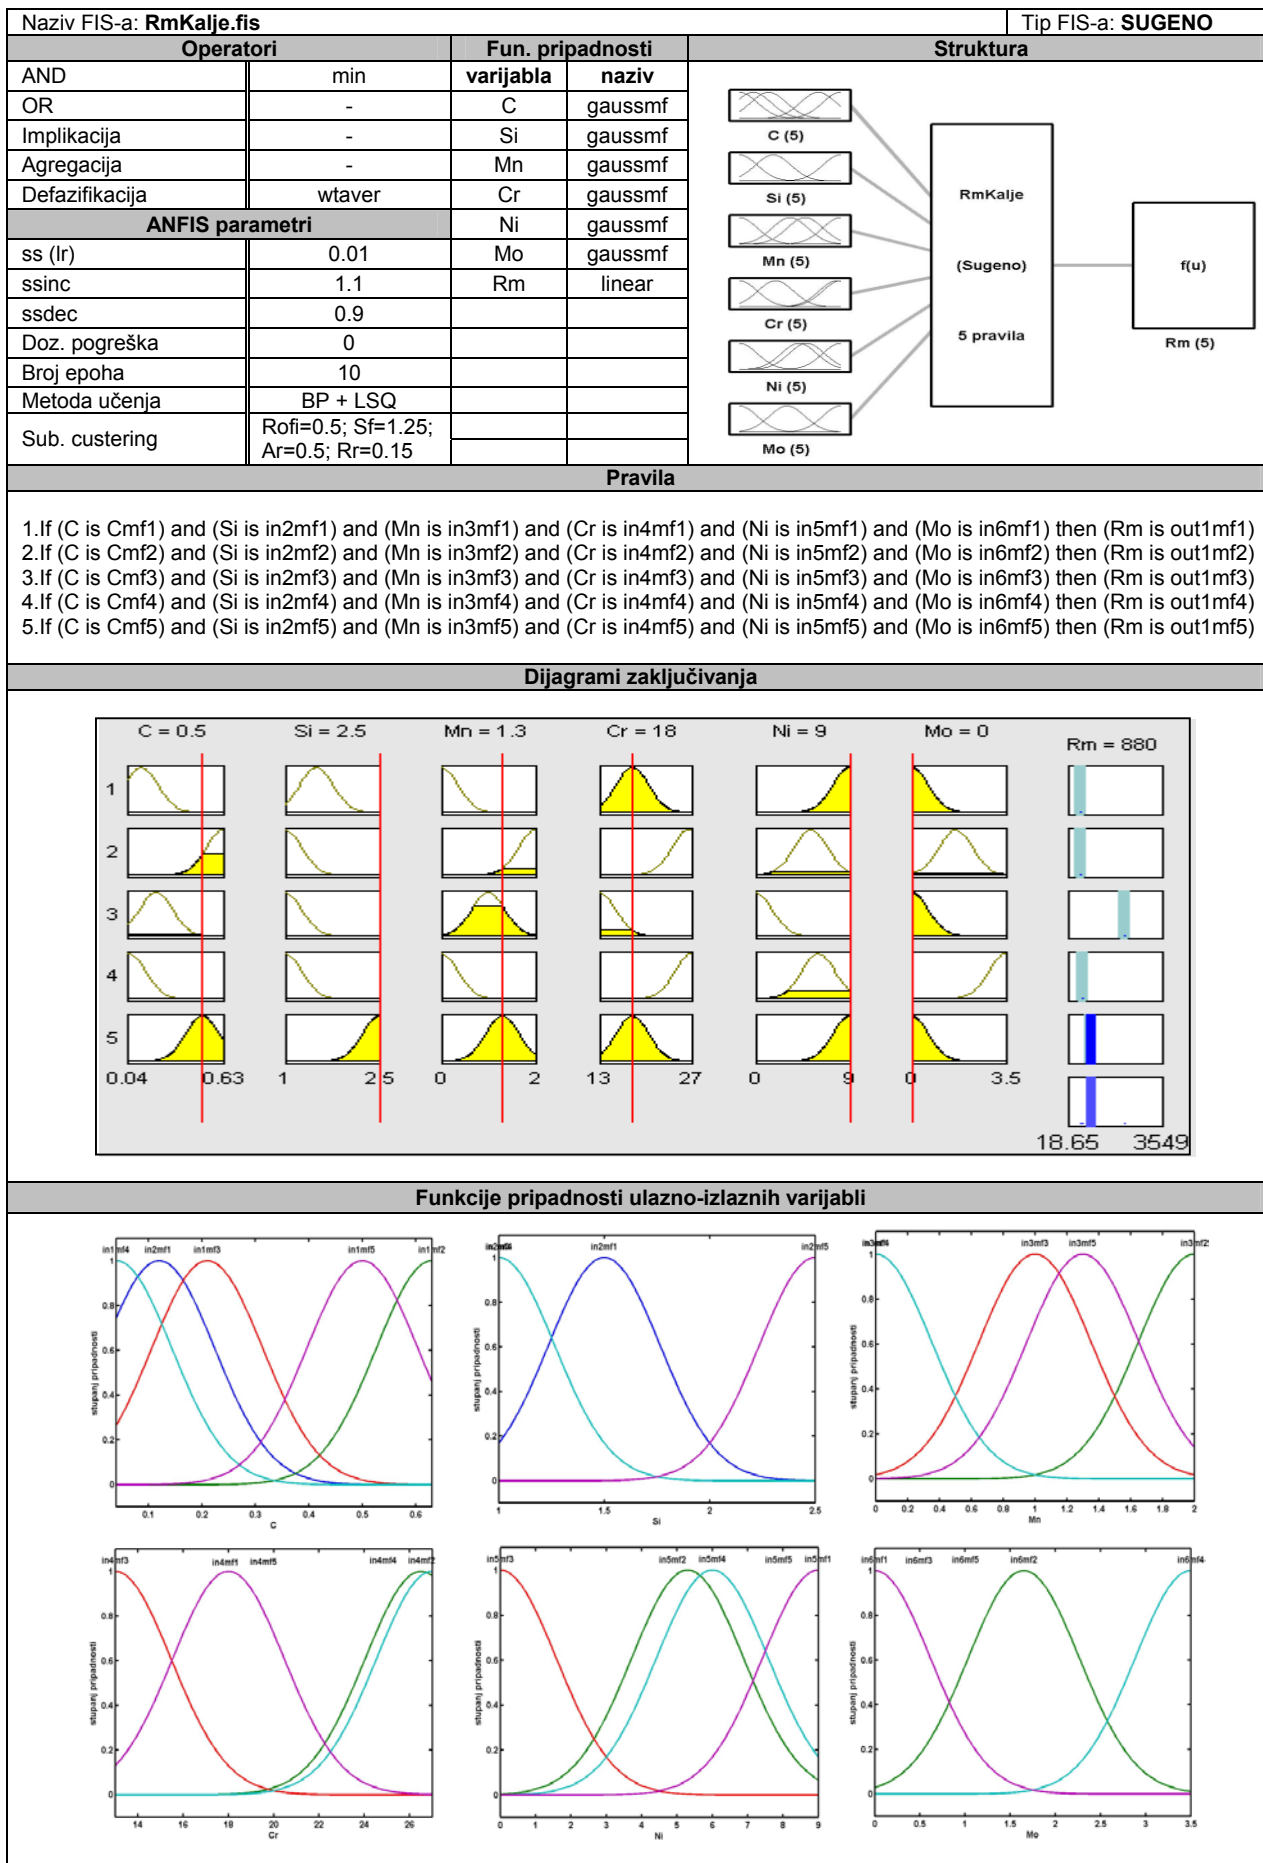
$$\text{If } Le=visoko \text{ (37.54) and } R_m=nisko \text{ (800) then } A_5=visoko \text{ (25) (P2)}$$

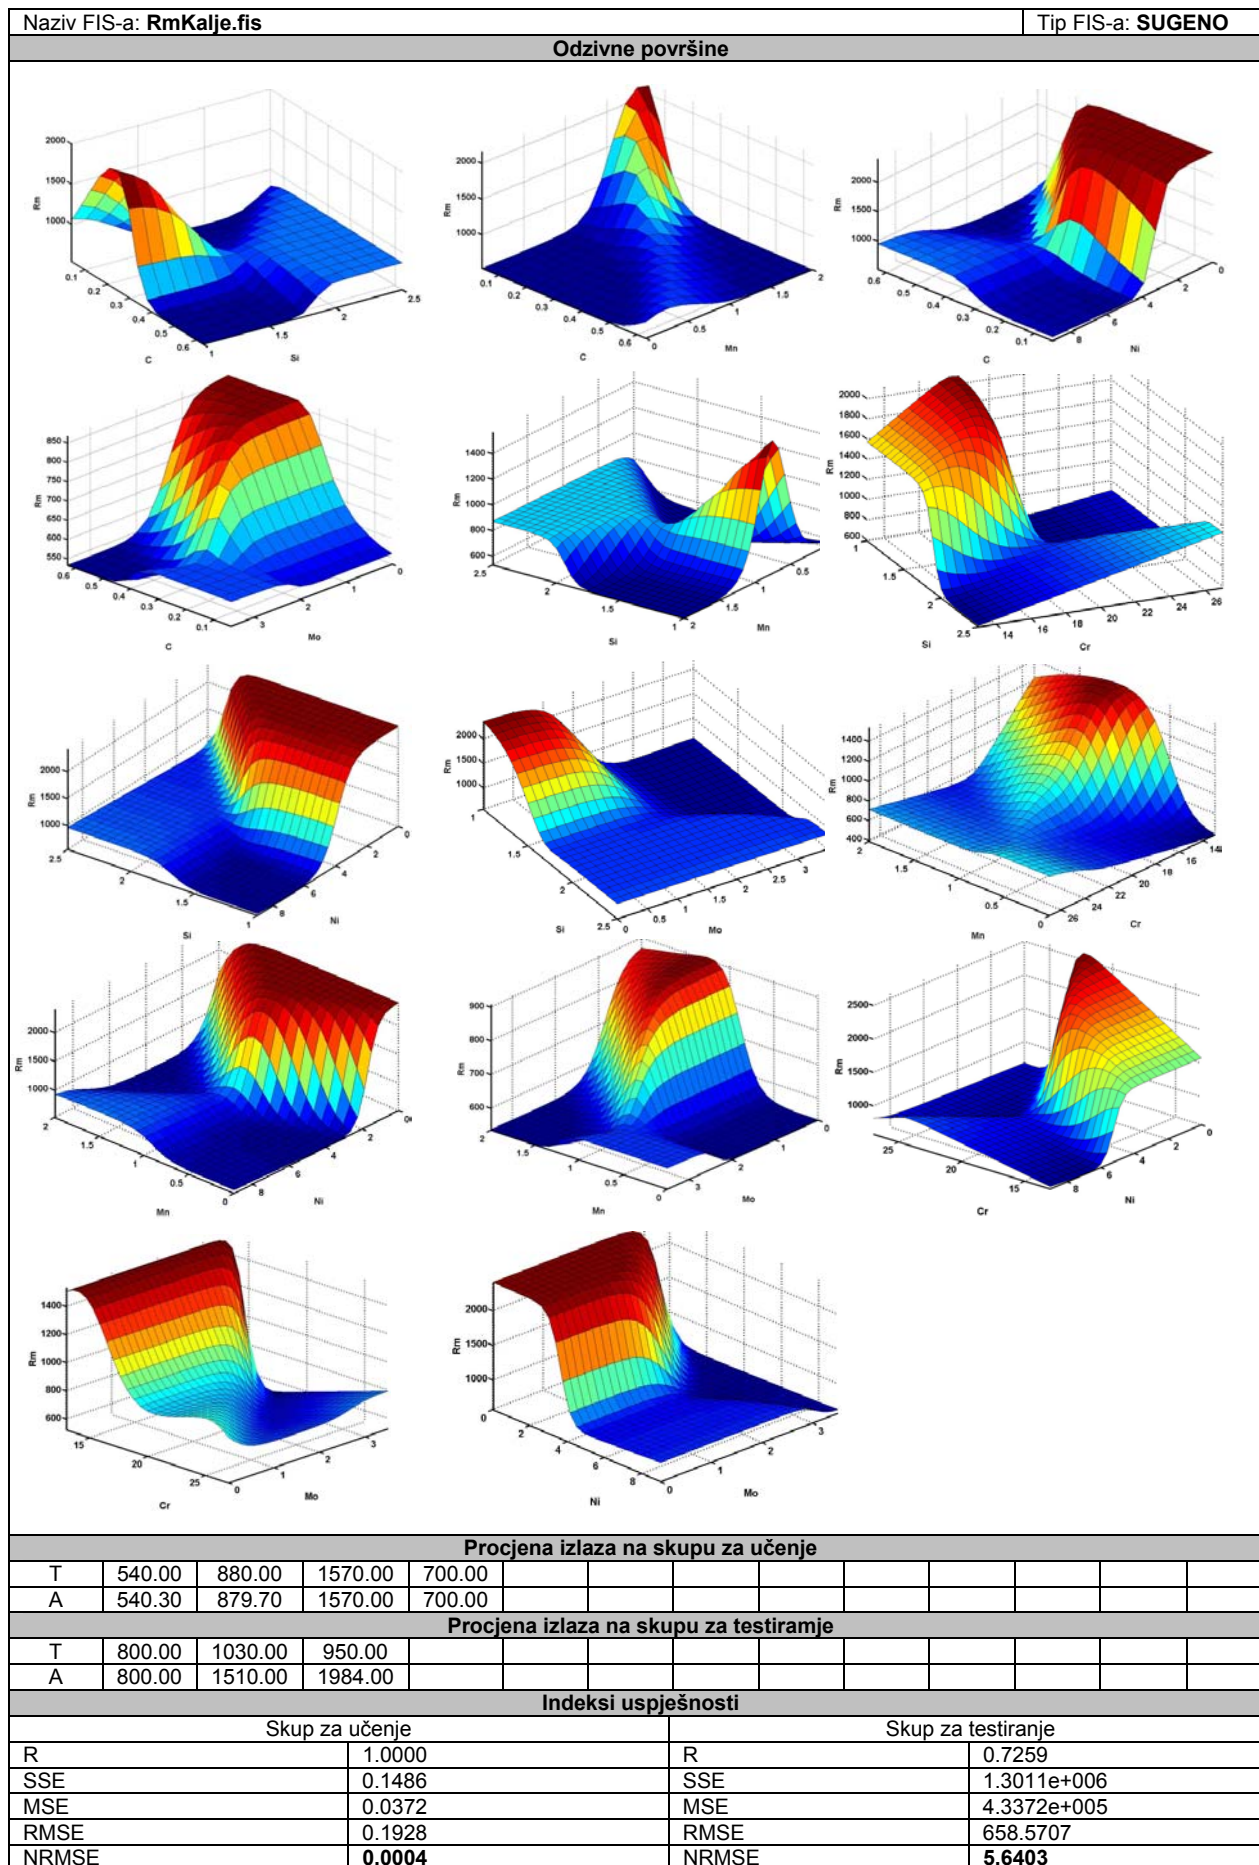
$$\text{If } Le=visoko \text{ (31.30) and } R_m=srednje \text{ (880) then } A_5=visoko \text{ (25) (P3)}$$

$$\text{If } Le=visoko \text{ (37.08) and } R_m=nisko \text{ (700) then } A_5=nisko \text{ (20) (P4)}$$

Kod ove procjene, zbog nedostatka podataka nije bilo moguće kreirati skup za testiranje te je skup podataka za učenje istodobno i skup za testiranje. Prikaz parametara, struktura *FIS*-a, oblik funkcija pripadnosti, pravila, dijagrami zaljučivanja, rezultati procjene sa indeksima uspješnosti dano je u tablici 4.41.

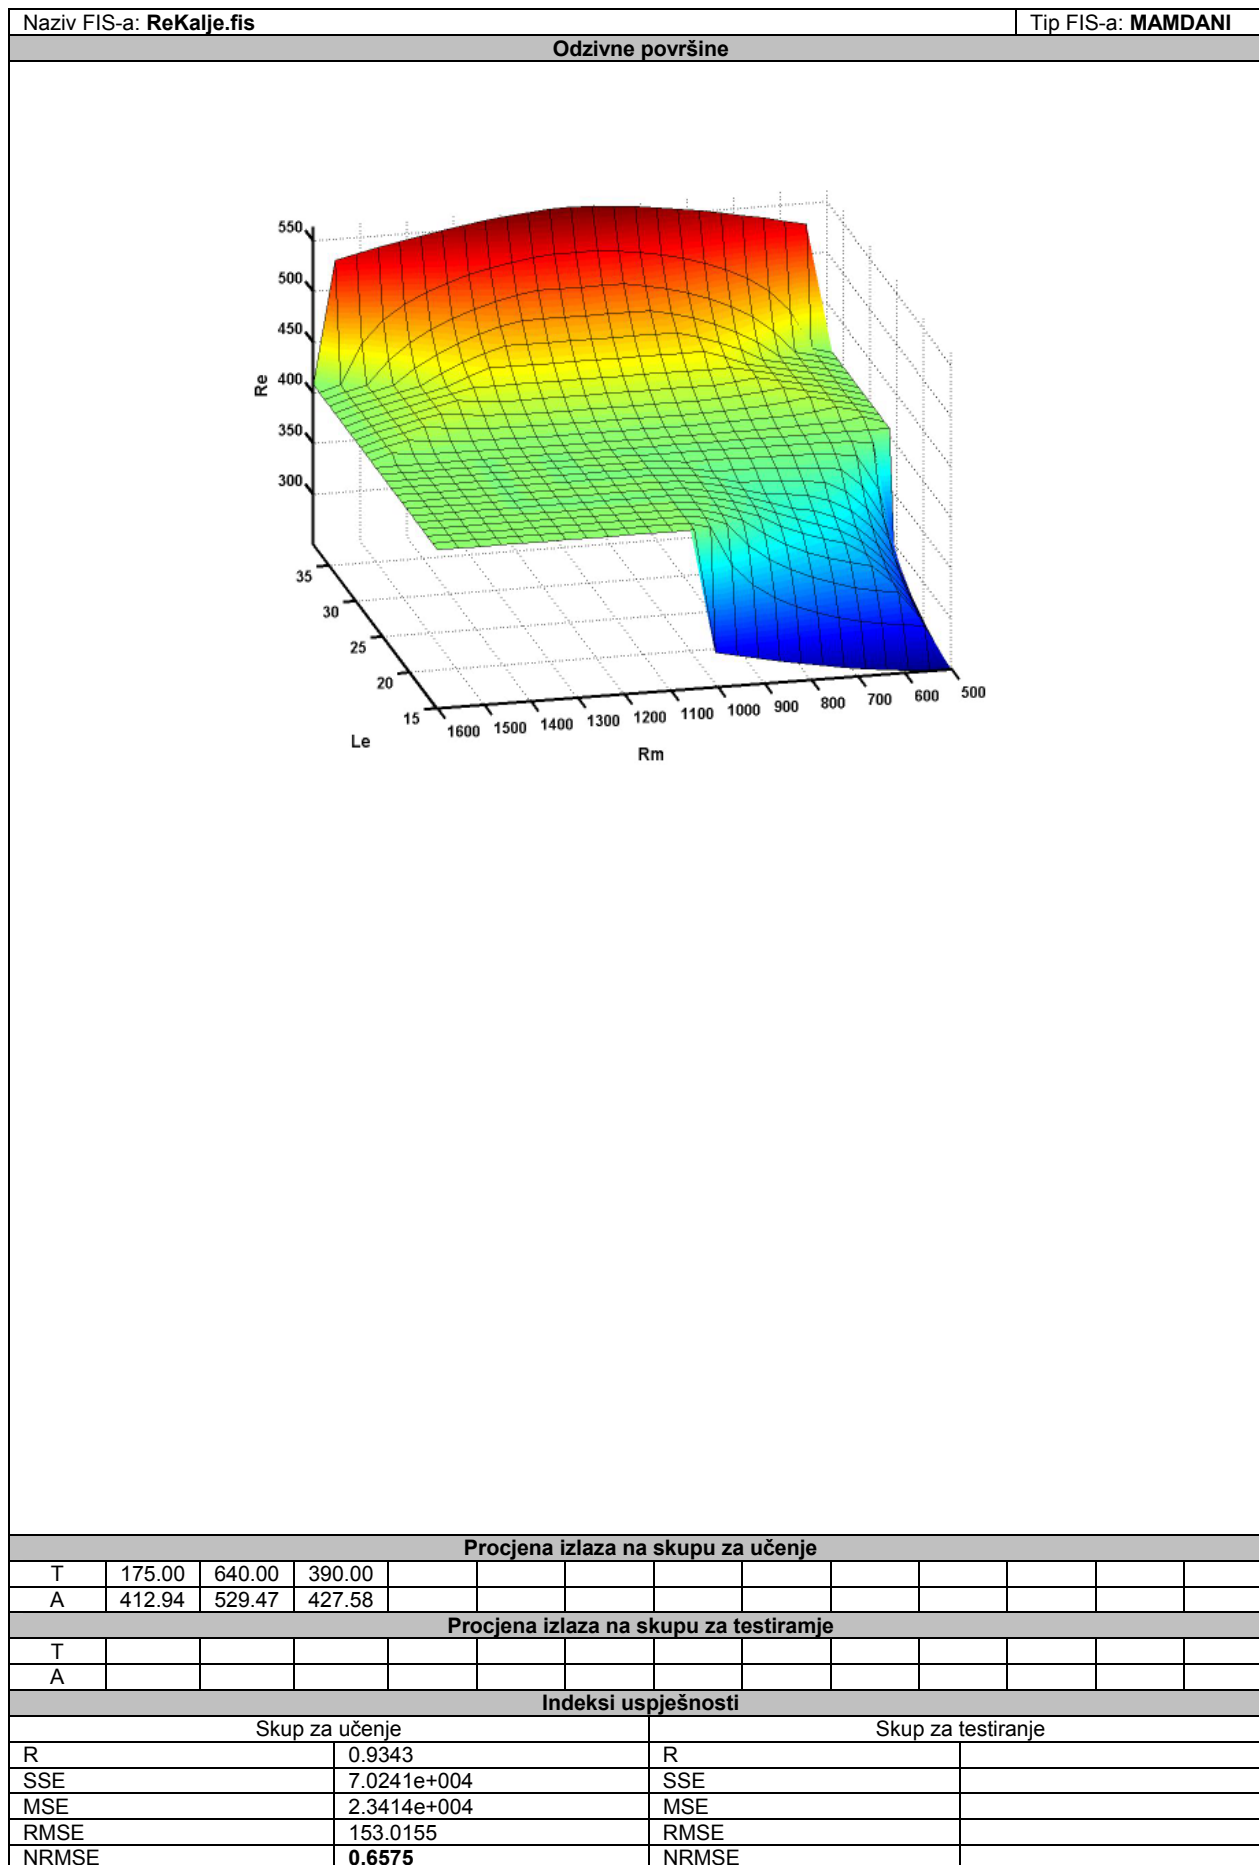
Tablica 4.38. Parametri, struktura i rezultati FIS-a za procjenu Rm u kaljenom stanju



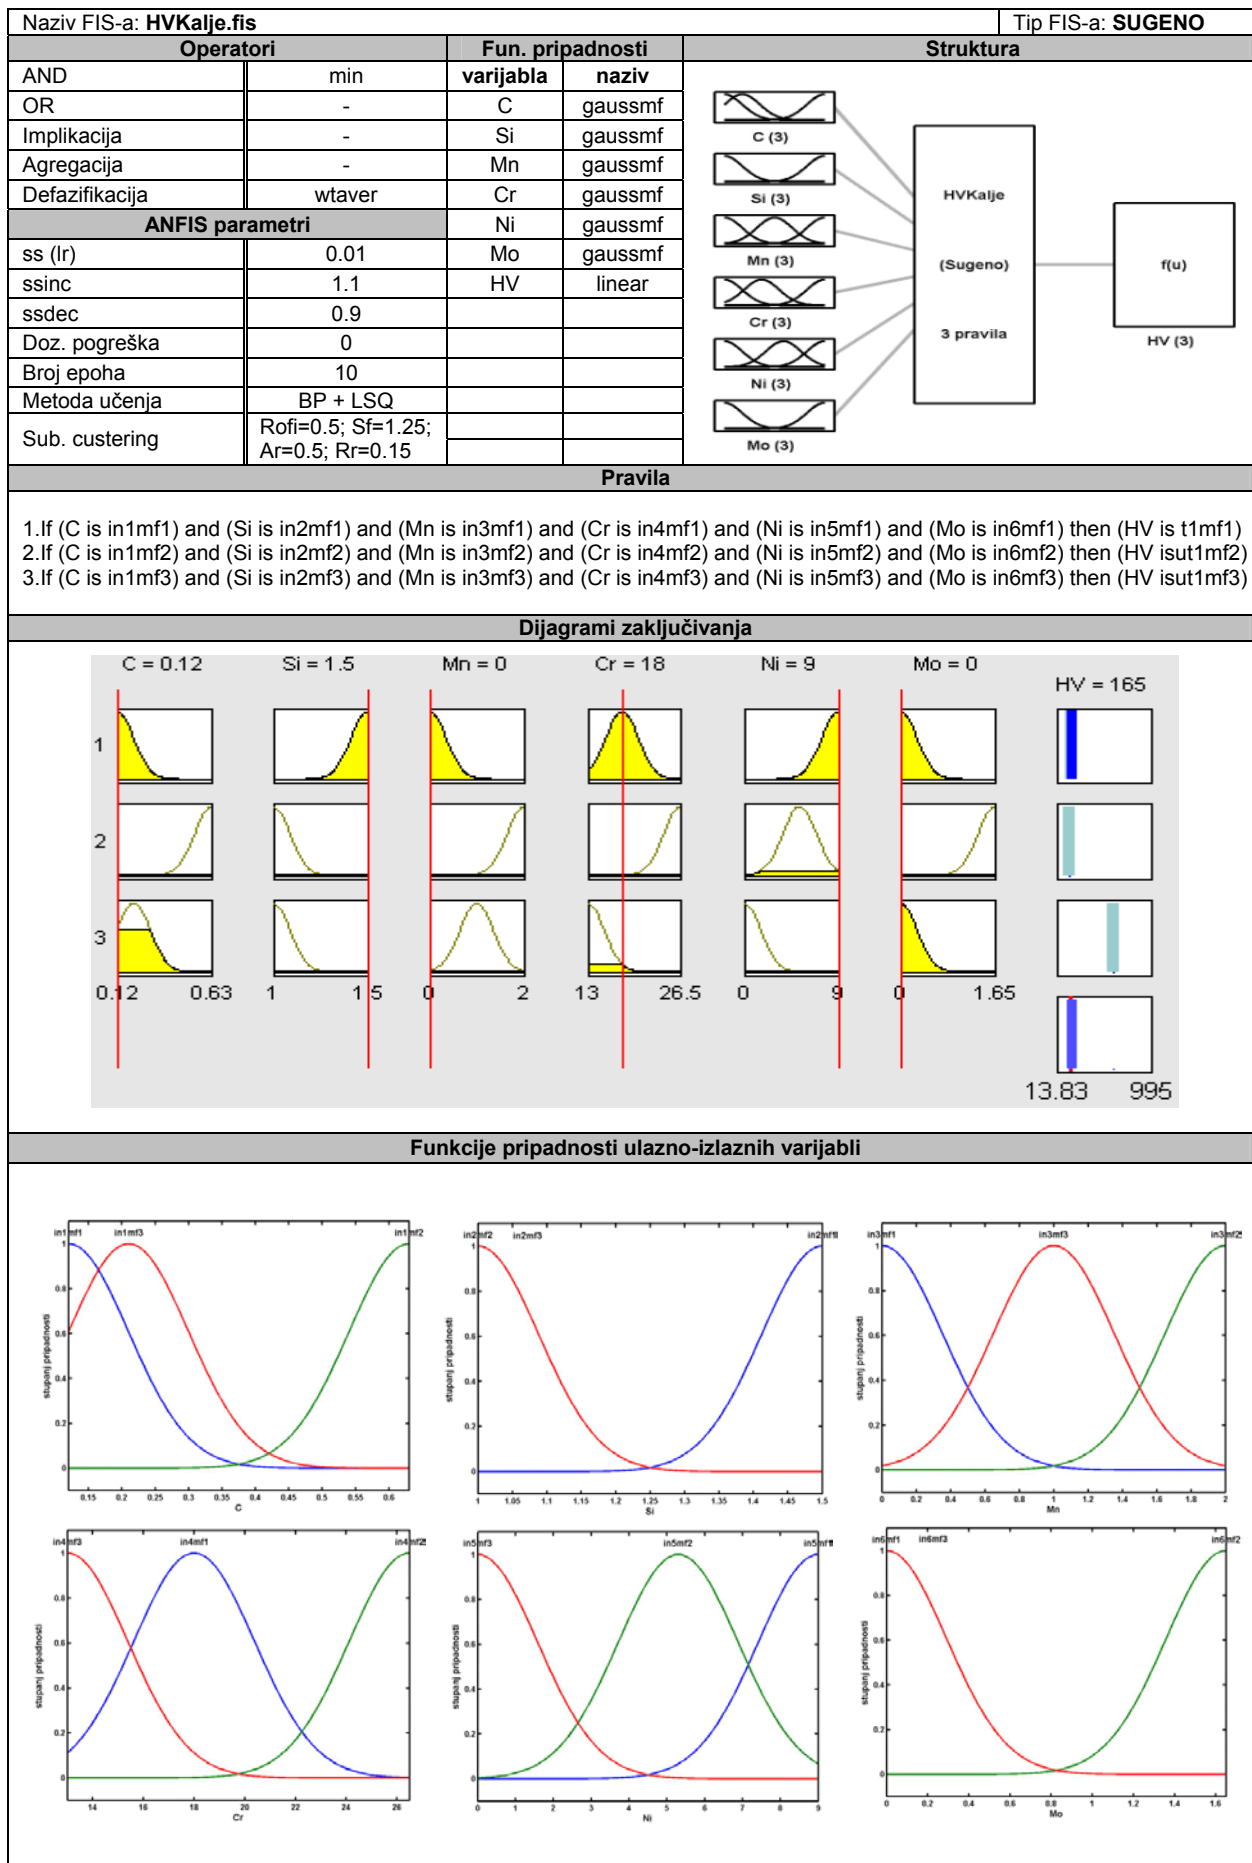
Nastavak: Tablica 4.38. Parametri, struktura i rezultati *FIS*-a za procjenu *Rm* u kaljenom stanju

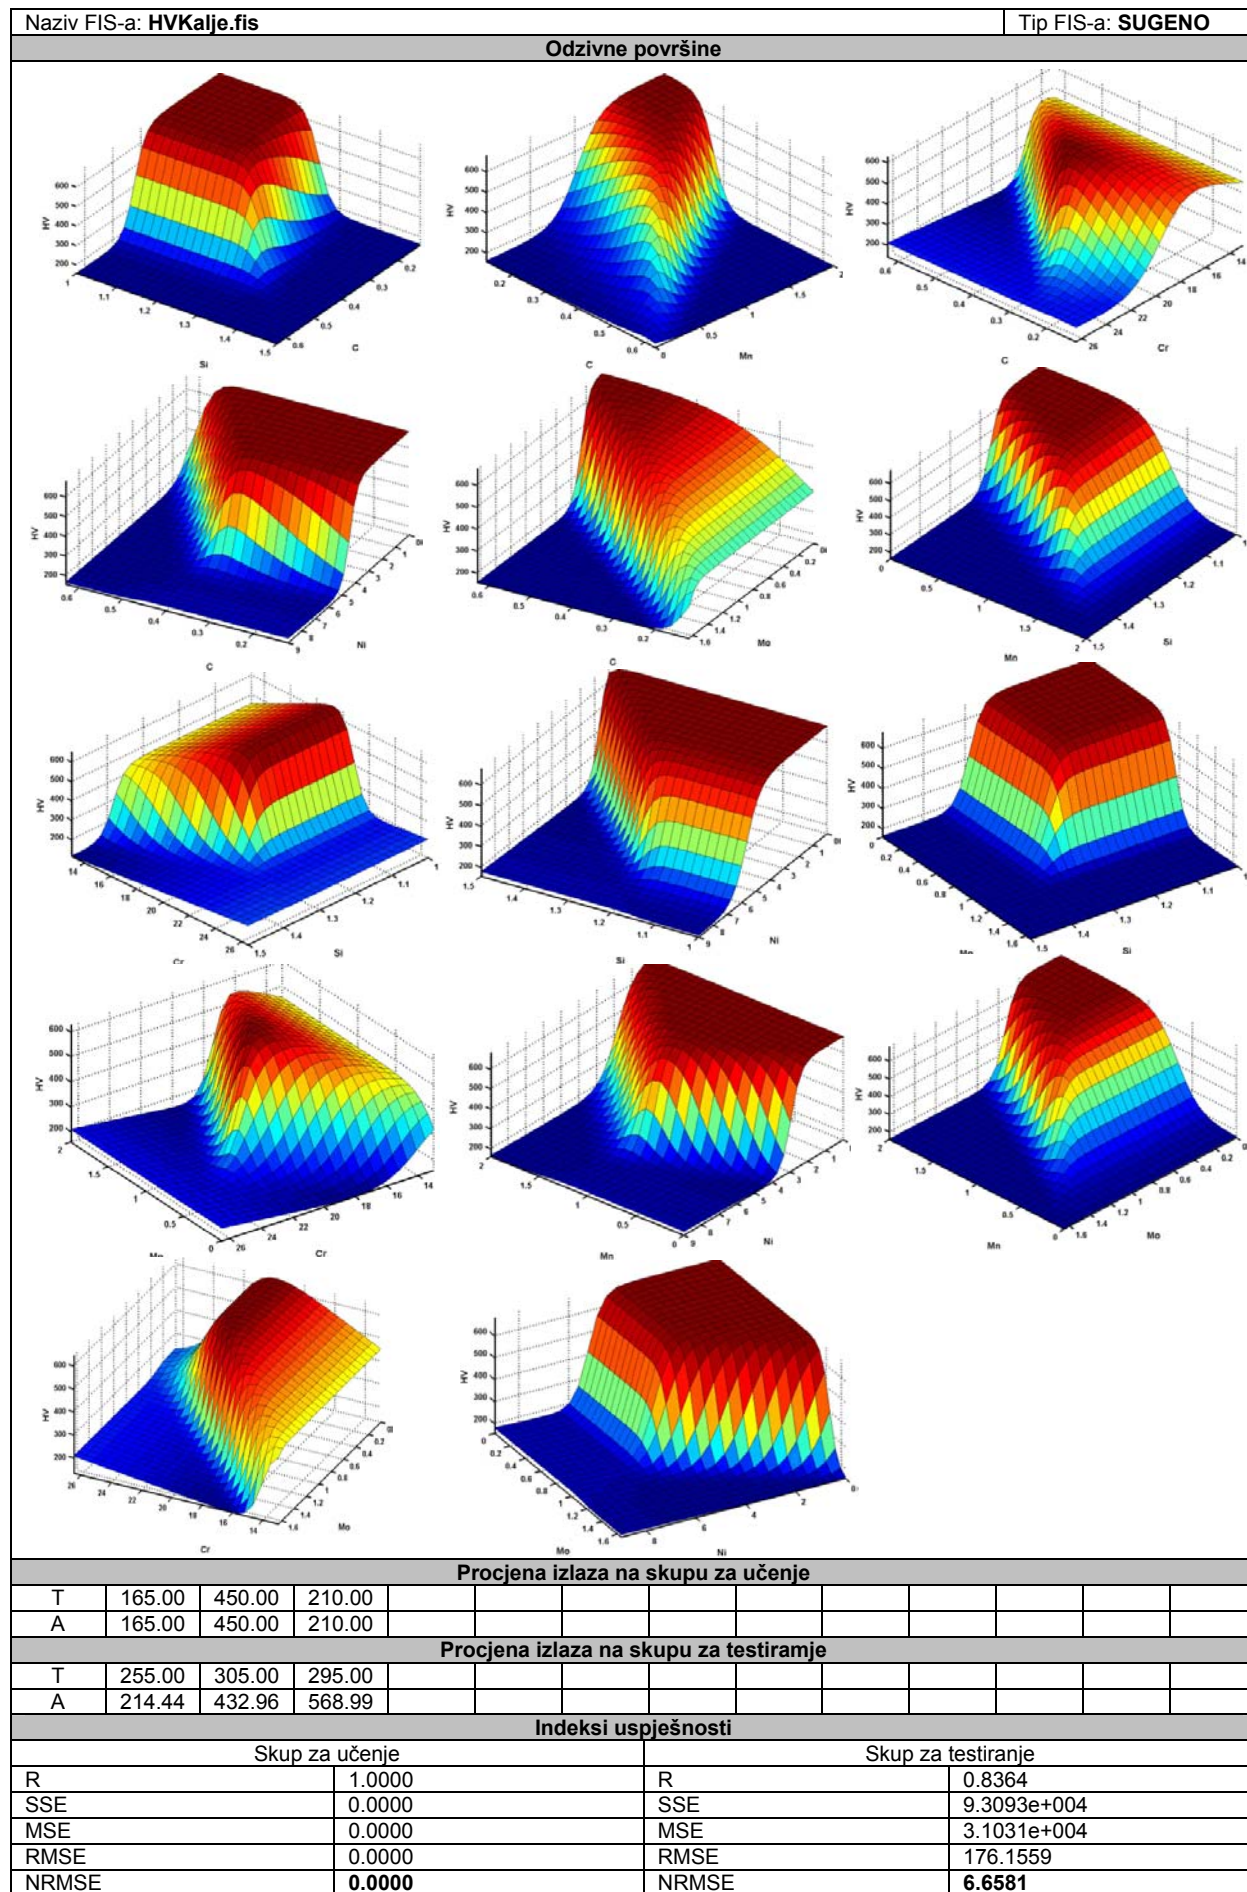
Tablica 4.39. Parametri, struktura i rezultati FIS-a za procjenu Re u kaljenom stanju

Naziv FIS-a: ReKalje.fis				Tip FIS-a: MAMDANI
Operatori		Fun. pripadnosti		Struktura
		varijabla	naziv	
AND	min	Le	trimf	
OR	max	Le	trimf	
Implikacija	min	Rm	trimf	
Agregacija	max	Re	trimf	
Defazifikacija	CoM			
ANFIS parametri				
ss (lr)				
ssinc				
ssdec				
Doz. pogreška				
Broj epoha				
Metoda učenja				
Sub. clustering				
Pravila				
1. If (Le is Nisko) and (Rm is Nisko) then (Re is Nisko) 2. If (Le is Visoko) and (Rm is Srednje) then (Re is Visoko) 3. If (Le is Srednje) and (Rm is Srednje) then (Re is Srednje)				
Dijagrami zaključivanja				
Funkcije pripadnosti ulazno-izlaznih varijabli				

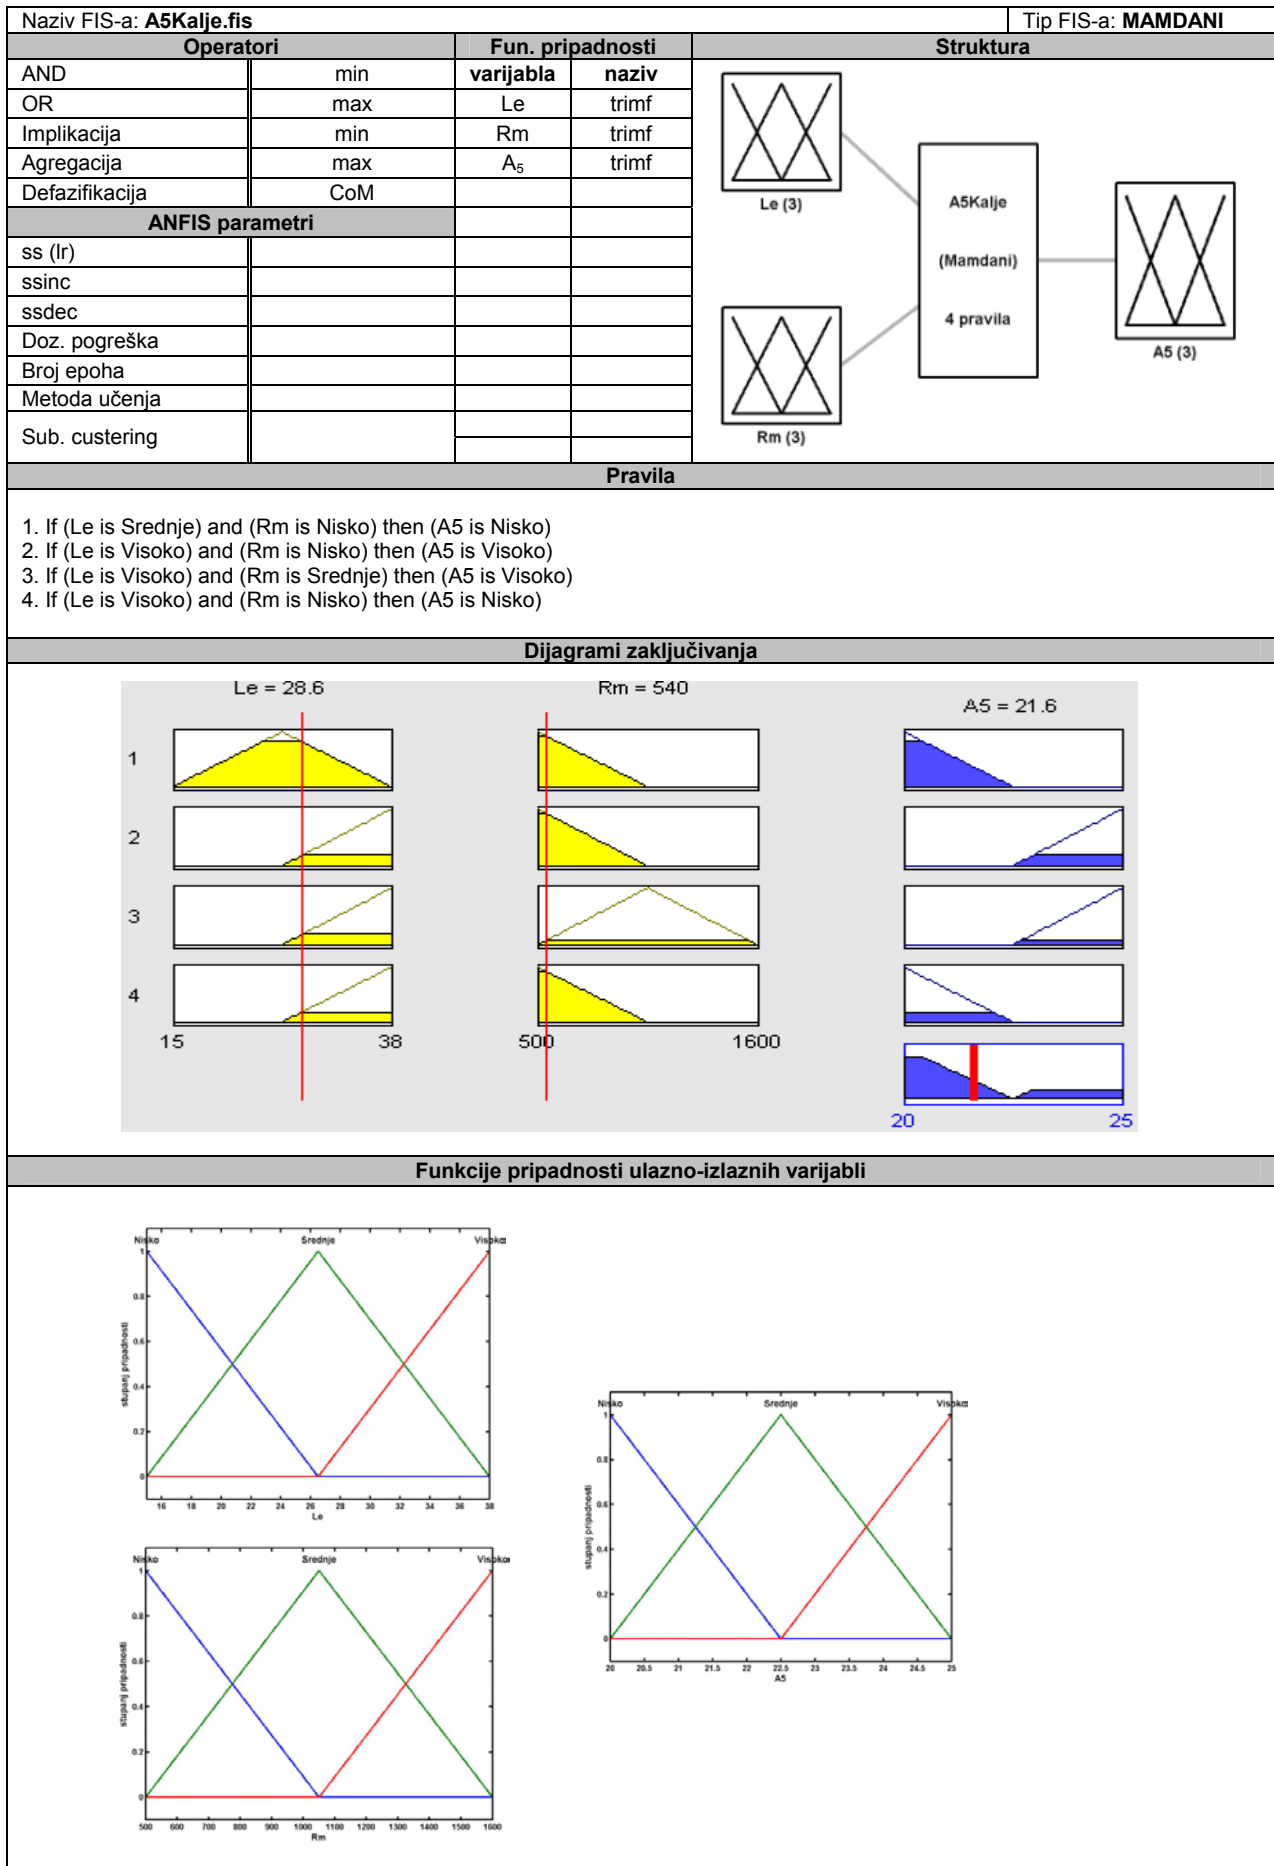
Nastavak: Tablica 4.39. Parametri, struktura i rezultati *FIS*-a za procjenu *Re* u kaljenom stanju

Tablica 4.40. Parametri, struktura i rezultati FIS-a za procjenu HV u kaljenom stanju

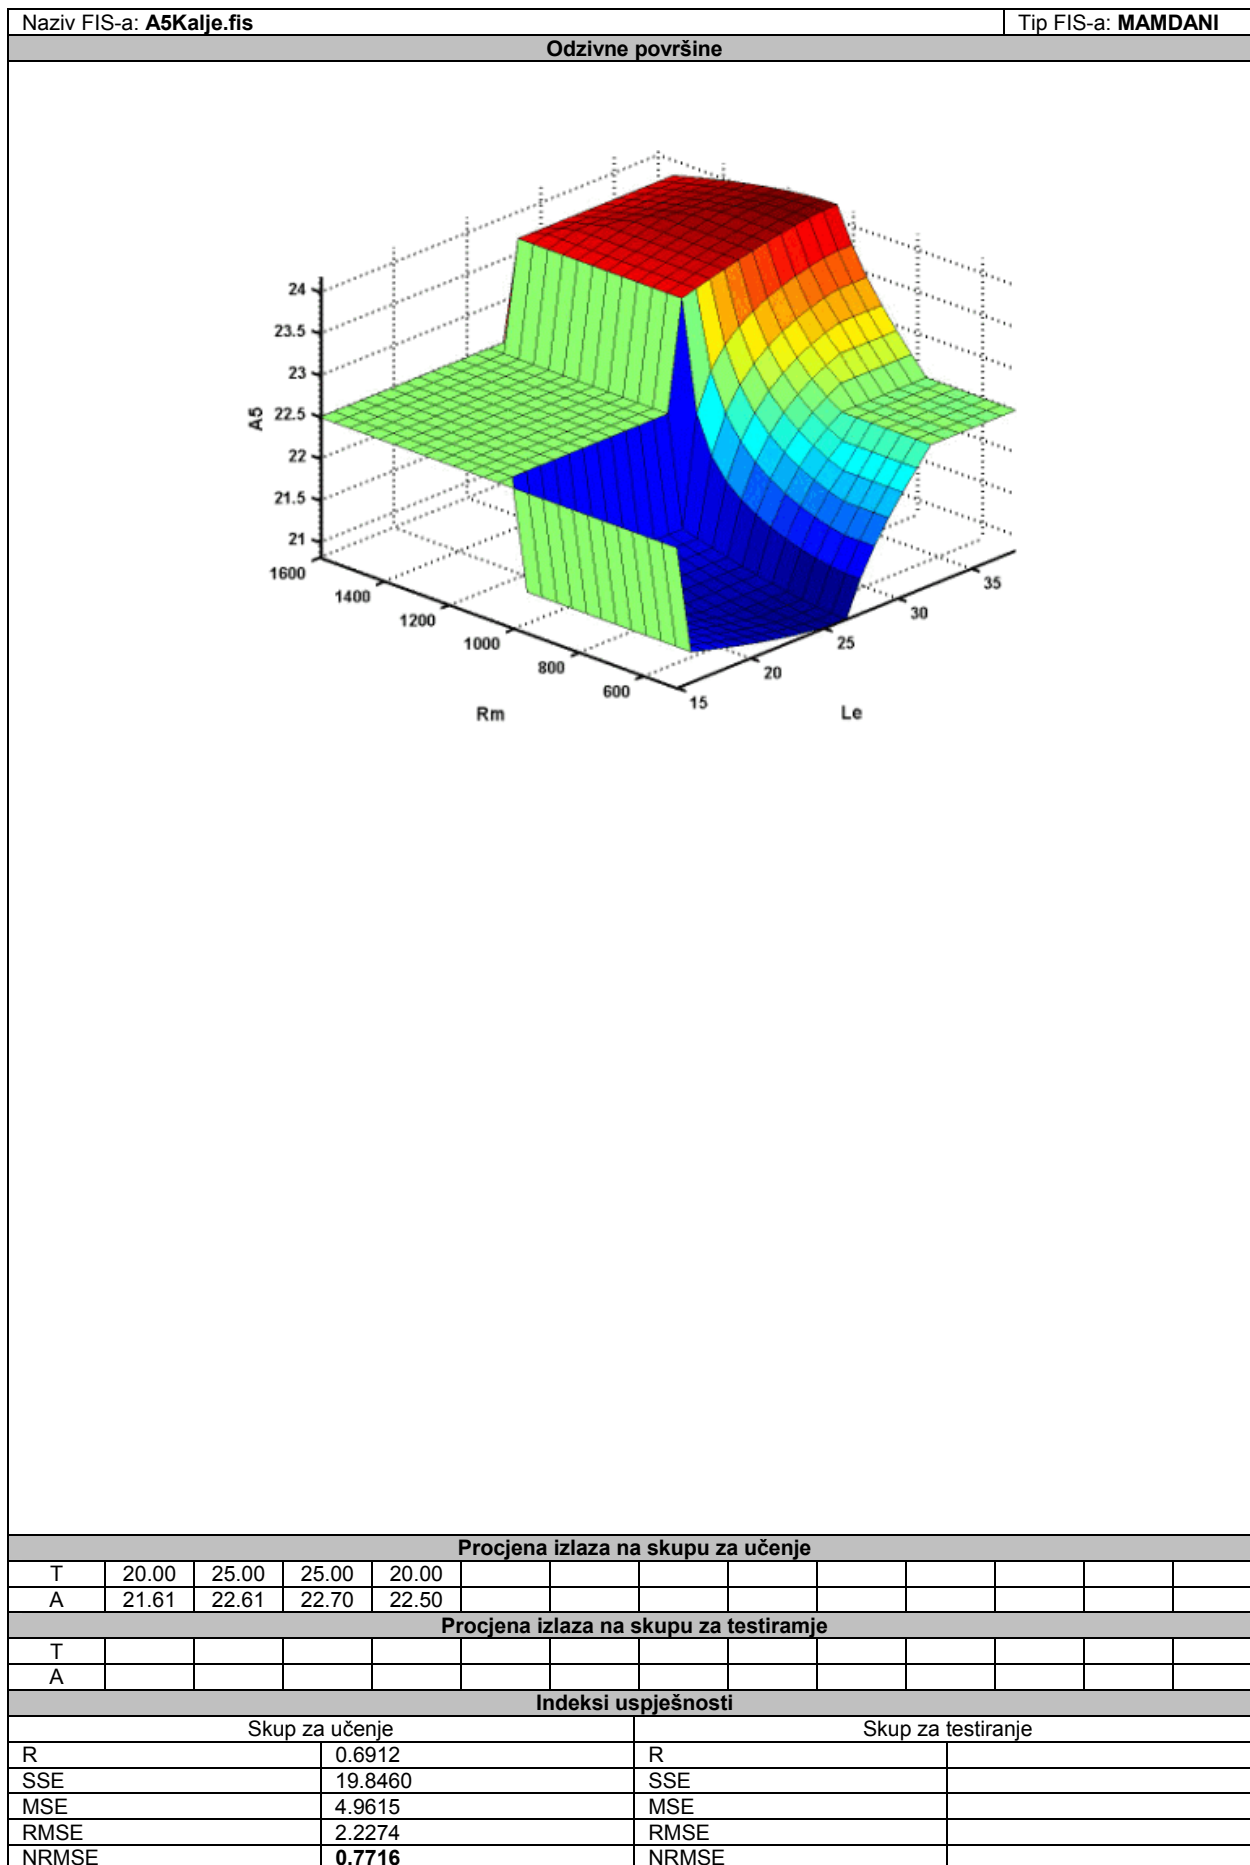


Nastavak: Tablica 4.40. Parametri, struktura i rezultati *FIS*-a za procjenu *HV* u kaljenom stanju

Tablica 4.41. Parametri, struktura i rezultati FIS-a za procjenu A_5 u kaljenom stanju



Nastavak: Tablica 4.41. Parametri, struktura i rezultati FIS-a za procjenu A_3 u kaljenom stanju



4.5.2. Ulazno-izlazni skupovi za procjenu R_m , R_e , HV i A_5 u poboljšanom stanju

Ulazni skupovi za procjenu R_m, R_e, HV , i A_5 čine podaci o kemijskom sastavu: (C, Si, Mn, Cr, Ni, Mo), a izlazne skupove čine podaci za R_m, R_e, HV , i A_5 . Za sve procjene primjenjen je *Sugeno* model, a podaci su za svaku procjenu podijeljeni na dva skupa: skup za učenje i skup za testiranje. Izuzimanje podataka za testiranje također je napravljeno 'ručno'. Pri izuzimanju podataka za testiranje, vodilo se računa o tome da podaci skupa za učenje pokrivaju *univerzalni skup* podataka za testiranje. Na slikama 4.32, 4.33, 4.34, i 4.35 prikazane su ulazno-izlazne matrice za učenje i testiranje nabrojanih procjena. Prikaz parametara, strukture *FIS*-a, oblika funkcija pripadnosti, pravila, dijagrami zaljučivanja, rezultati procjene sa indeksima uspješnosti dano je u tablicama 4.42, 4.43, 4.44, 4.45, 4.46, 4.47.

ULAZNI SKUP						A	IZLAZNI SKUP
0.20	0.00	0.00	0.00	0.00	0.00	0.00	515
0.42	0.00	0.00	1.00	0.00	0.25	0.25	955
0.18	0.00	0.00	1.30	0.00	0.50	0.50	565
0.28	0.45	1.50	0.70	0.00	0.50	1550	
0.20	0.00	0.00	13.50	0.00	0.00	690	
0.12	1.50	0.00	18.00	9.00	0.00	540	
0.34	0.35	0.65	1.15	1.00	0.20	880	

ULAZNI SKUP						B	IZLAZNI SKUP
0.20	0.00	1.15	0.00	0.0	0.0	0.0	525
0.21	0.00	0.00	0.00	0.0	0.4	0.4	515
0.34	0.28	0.56	1.70	1.0	0.2	0.2	880

Slika 4.32. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene R_m u poboljšanom stanju

ULAZNI SKUP						A	IZLAZNI SKUP
0.20	0.00	0.00	0.00	0.00	0.00	0.00	245
0.42	0.00	0.00	1.00	0.00	0.25	0.25	390
0.18	0.00	0.00	1.30	0.00	0.50	0.50	315
0.28	0.45	1.50	0.70	0.00	0.50	1240	
0.20	0.00	0.00	13.50	0.00	0.00	440	
0.12	1.50	0.00	18.00	9.00	0.00	175	
0.34	0.35	0.65	1.15	1.00	0.20	590	

ULAZNI SKUP						B	IZLAZNI SKUP
0.20	0.00	1.15	0.00	0.0	0.0	0.0	280
0.21	0.00	0.00	0.00	0.0	0.4	0.4	245
0.34	0.28	0.56	1.70	1.0	0.2	0.2	590

Slika 4.33. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene R_e u poboljšanom stanju

ULAZNI SKUP						A	IZLAZNI SKUP
0.20	0.00	0.00	0.00	0.00	0.00	0.00	155
0.42	0.00	0.00	1.00	0.00	0.25	0.25	280
0.18	0.00	0.00	1.30	0.00	0.50	0.50	170
0.28	0.45	1.50	0.70	0.00	0.50	470	
0.20	0.00	0.00	13.50	0.00	0.00	205	
0.12	1.50	0.00	18.00	9.00	0.00	165	
0.34	0.35	0.65	1.15	1.00	0.20	950	

ULAZNI SKUP						B	IZLAZNI SKUP
0.20	0.00	1.15	0.00	0.0	0.0	0.0	155
0.21	0.00	0.00	0.00	0.0	0.4	0.4	153
0.34	0.28	0.56	1.70	1.0	0.2	0.2	950

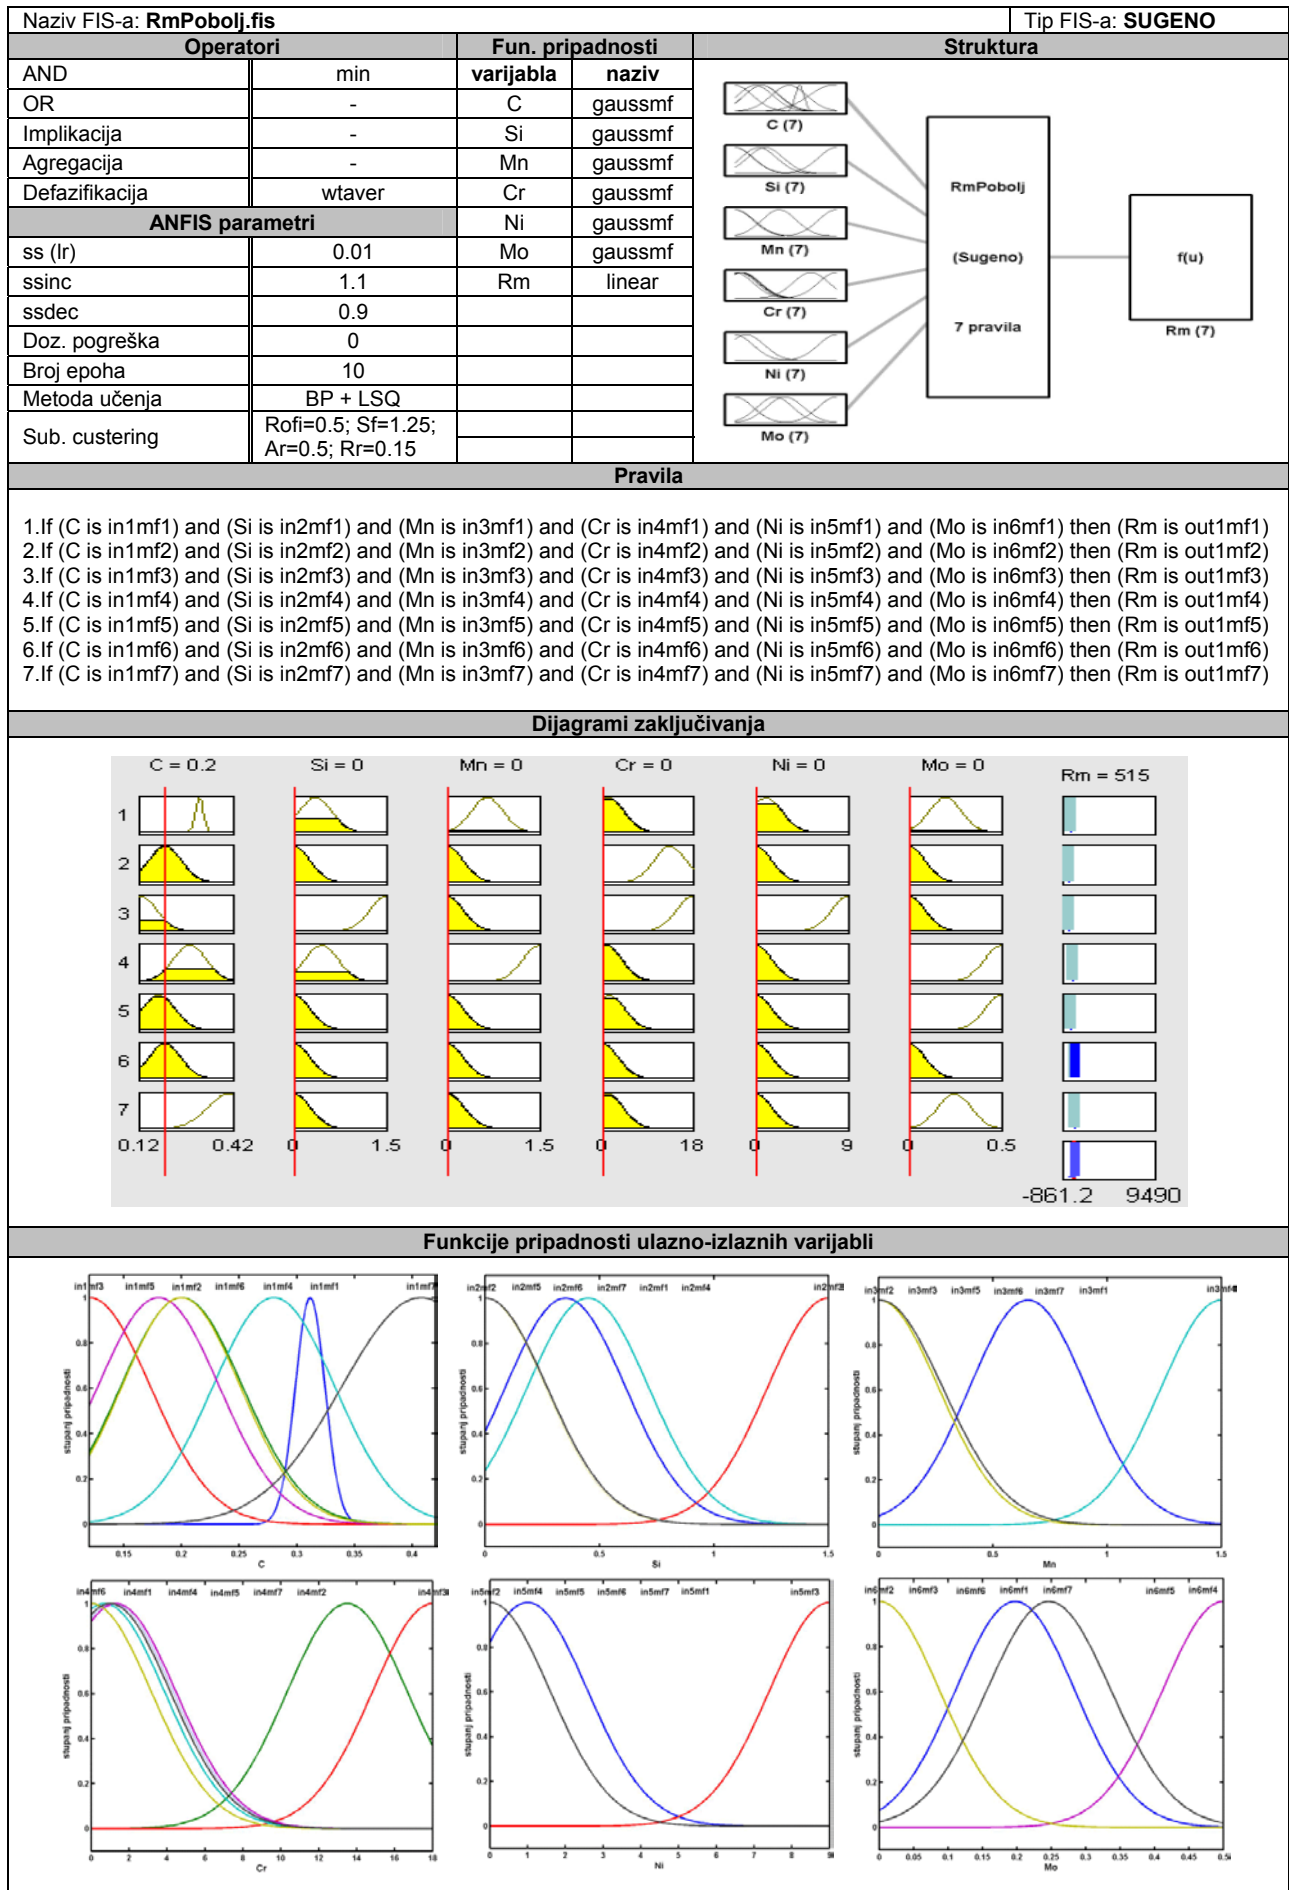
Slika 4.34. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene HV u poboljšanom stanju

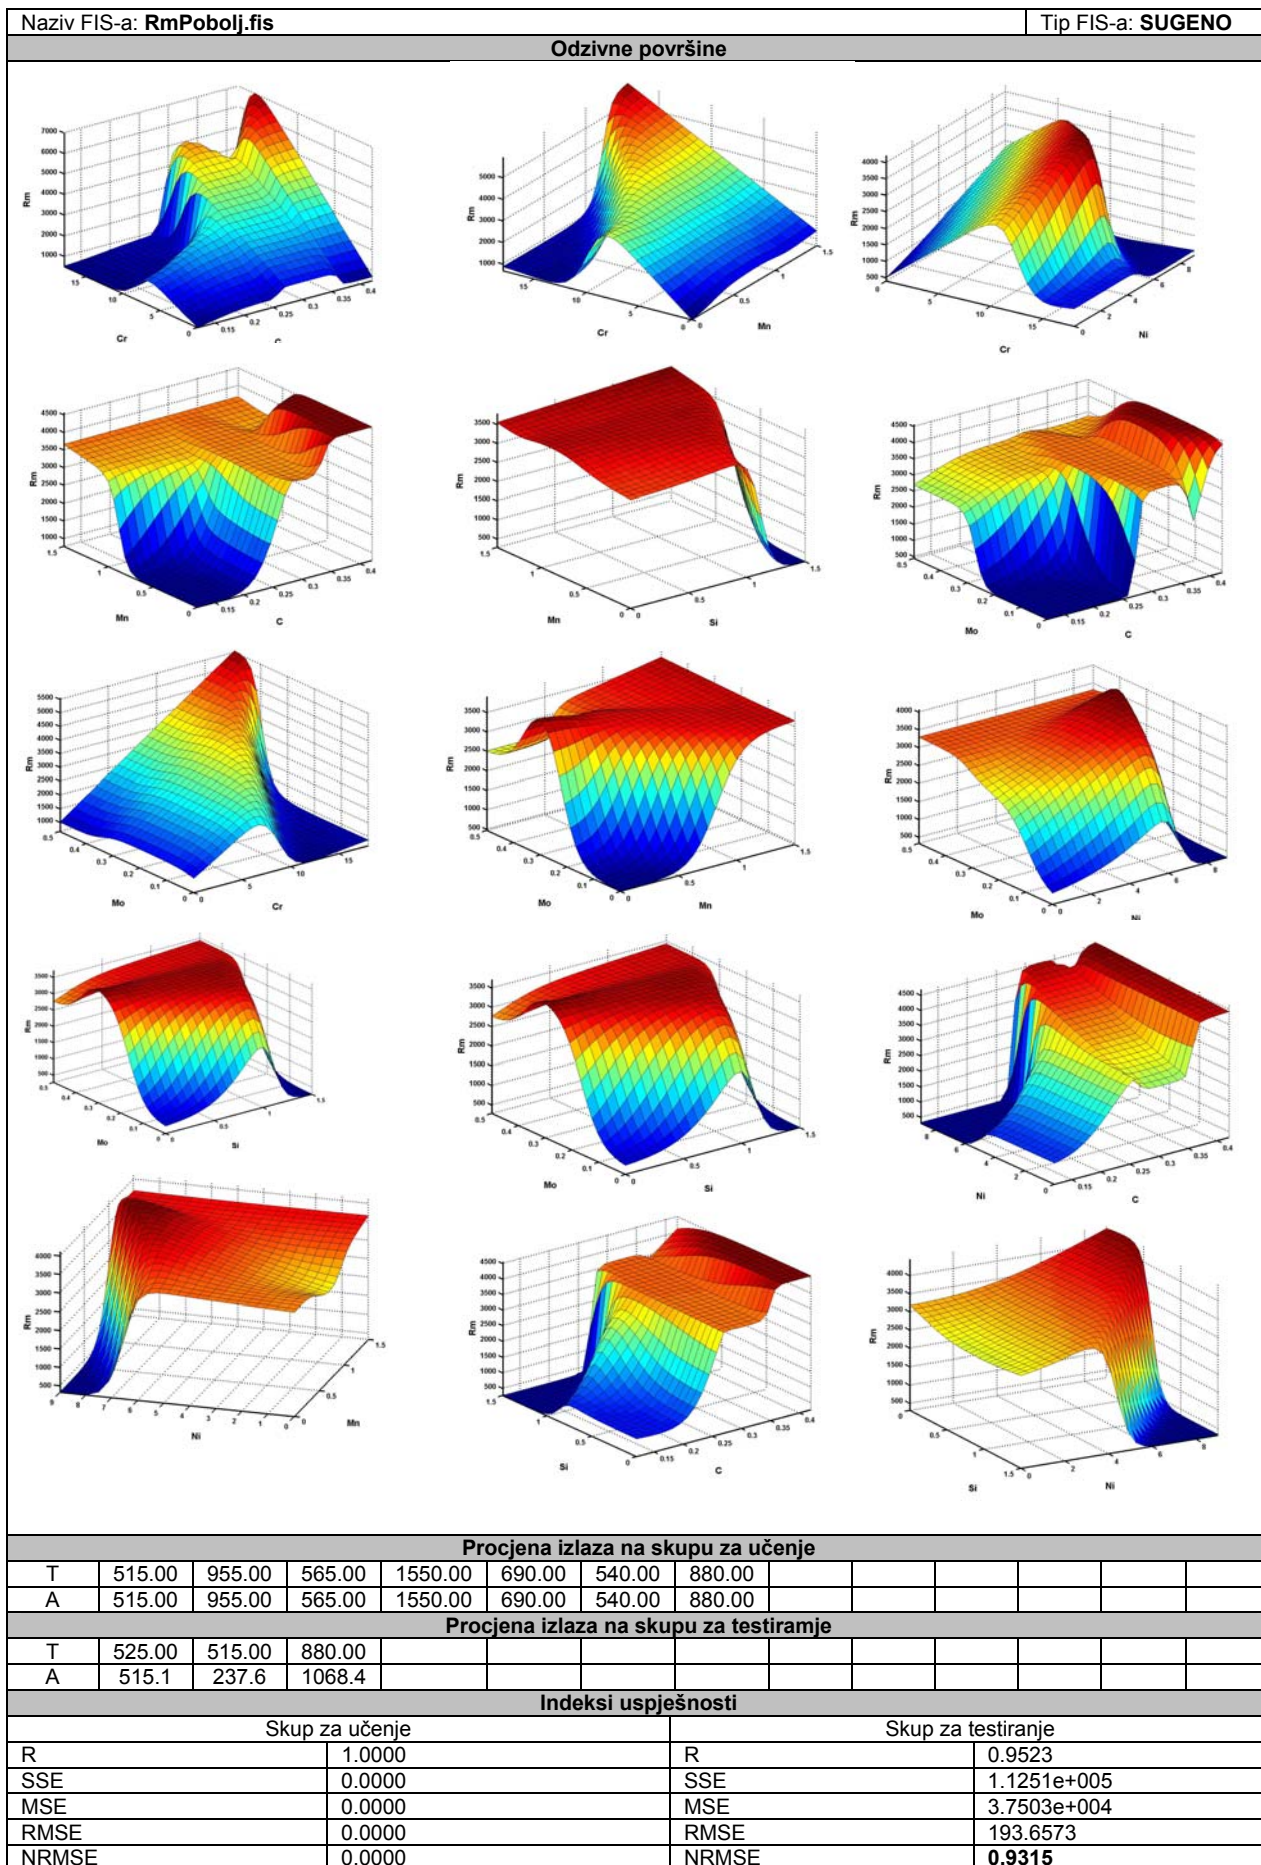
ULAZNI SKUP						A	IZLAZNI SKUP
0.20	0.00	0.00	0.00	0.00	0.00	0.00	22
0.42	0.00	0.00	1.00	0.00	0.25	0.25	9
0.18	0.00	0.00	1.30	0.00	0.50	0.50	20
0.28	0.45	1.50	0.70	0.00	0.50	3	
0.20	0.00	0.00	13.50	0.00	0.00	12	
0.12	1.50	0.00	18.00	9.00	0.00	20	
0.34	0.35	0.65	1.15	1.00	0.20	14	

ULAZNI SKUP						B	IZLAZNI SKUP
0.20	0.00	1.15	0.00	0.0	0.0	0.0	20
0.21	0.00	0.00	0.00	0.0	0.4	0.4	9
0.34	0.28	0.56	1.70	1.0	0.2	0.2	14

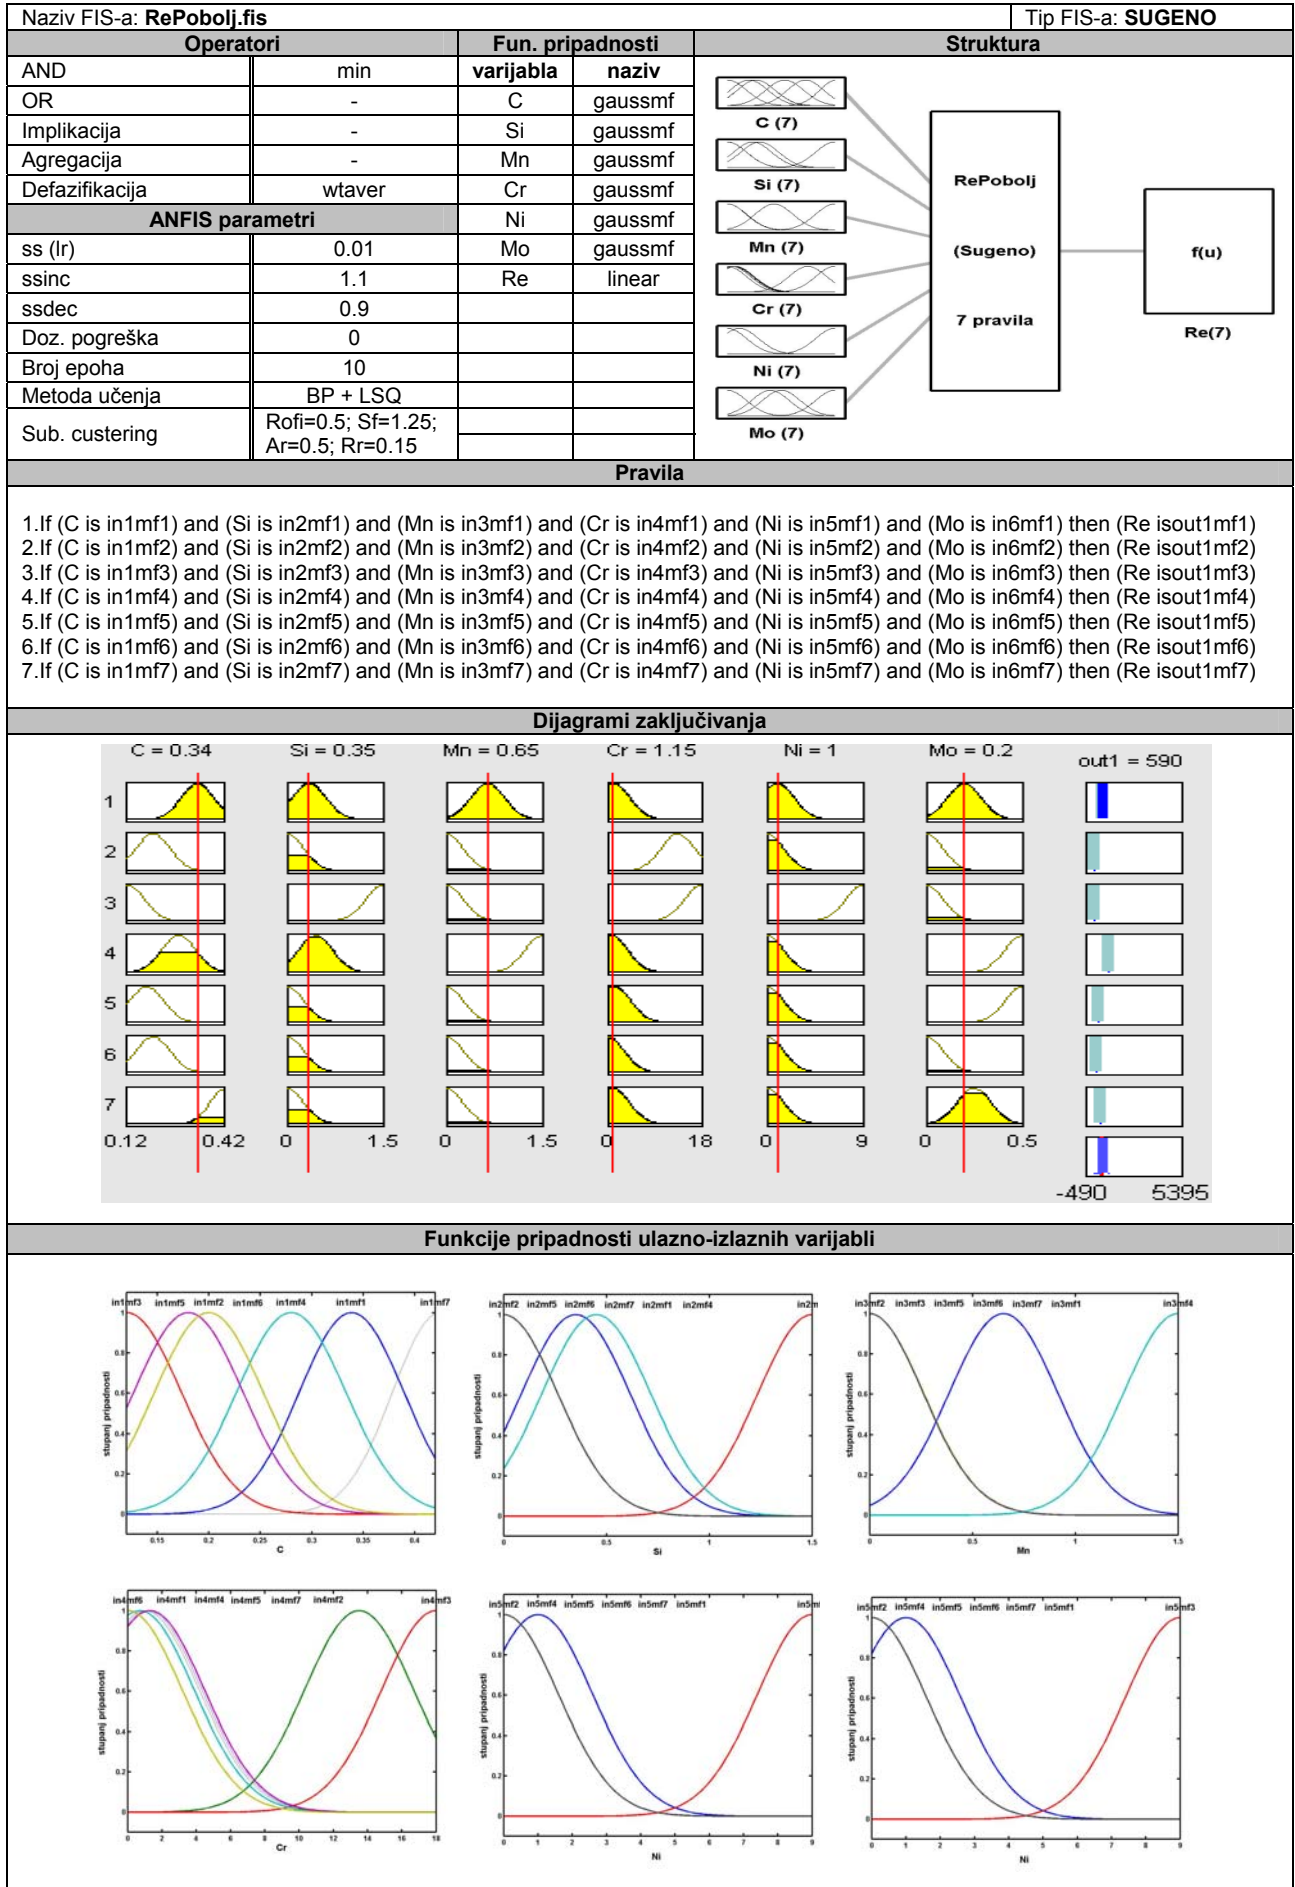
Slika 4.35. Ulazno-izlazna matrice za učenje (A) i testiranje (B) procjene A_5 u poboljšanom stanju

Tablica 4.42. Parametri, struktura i rezultati FIS-a za procjenu Rm u poboljšanom stanju

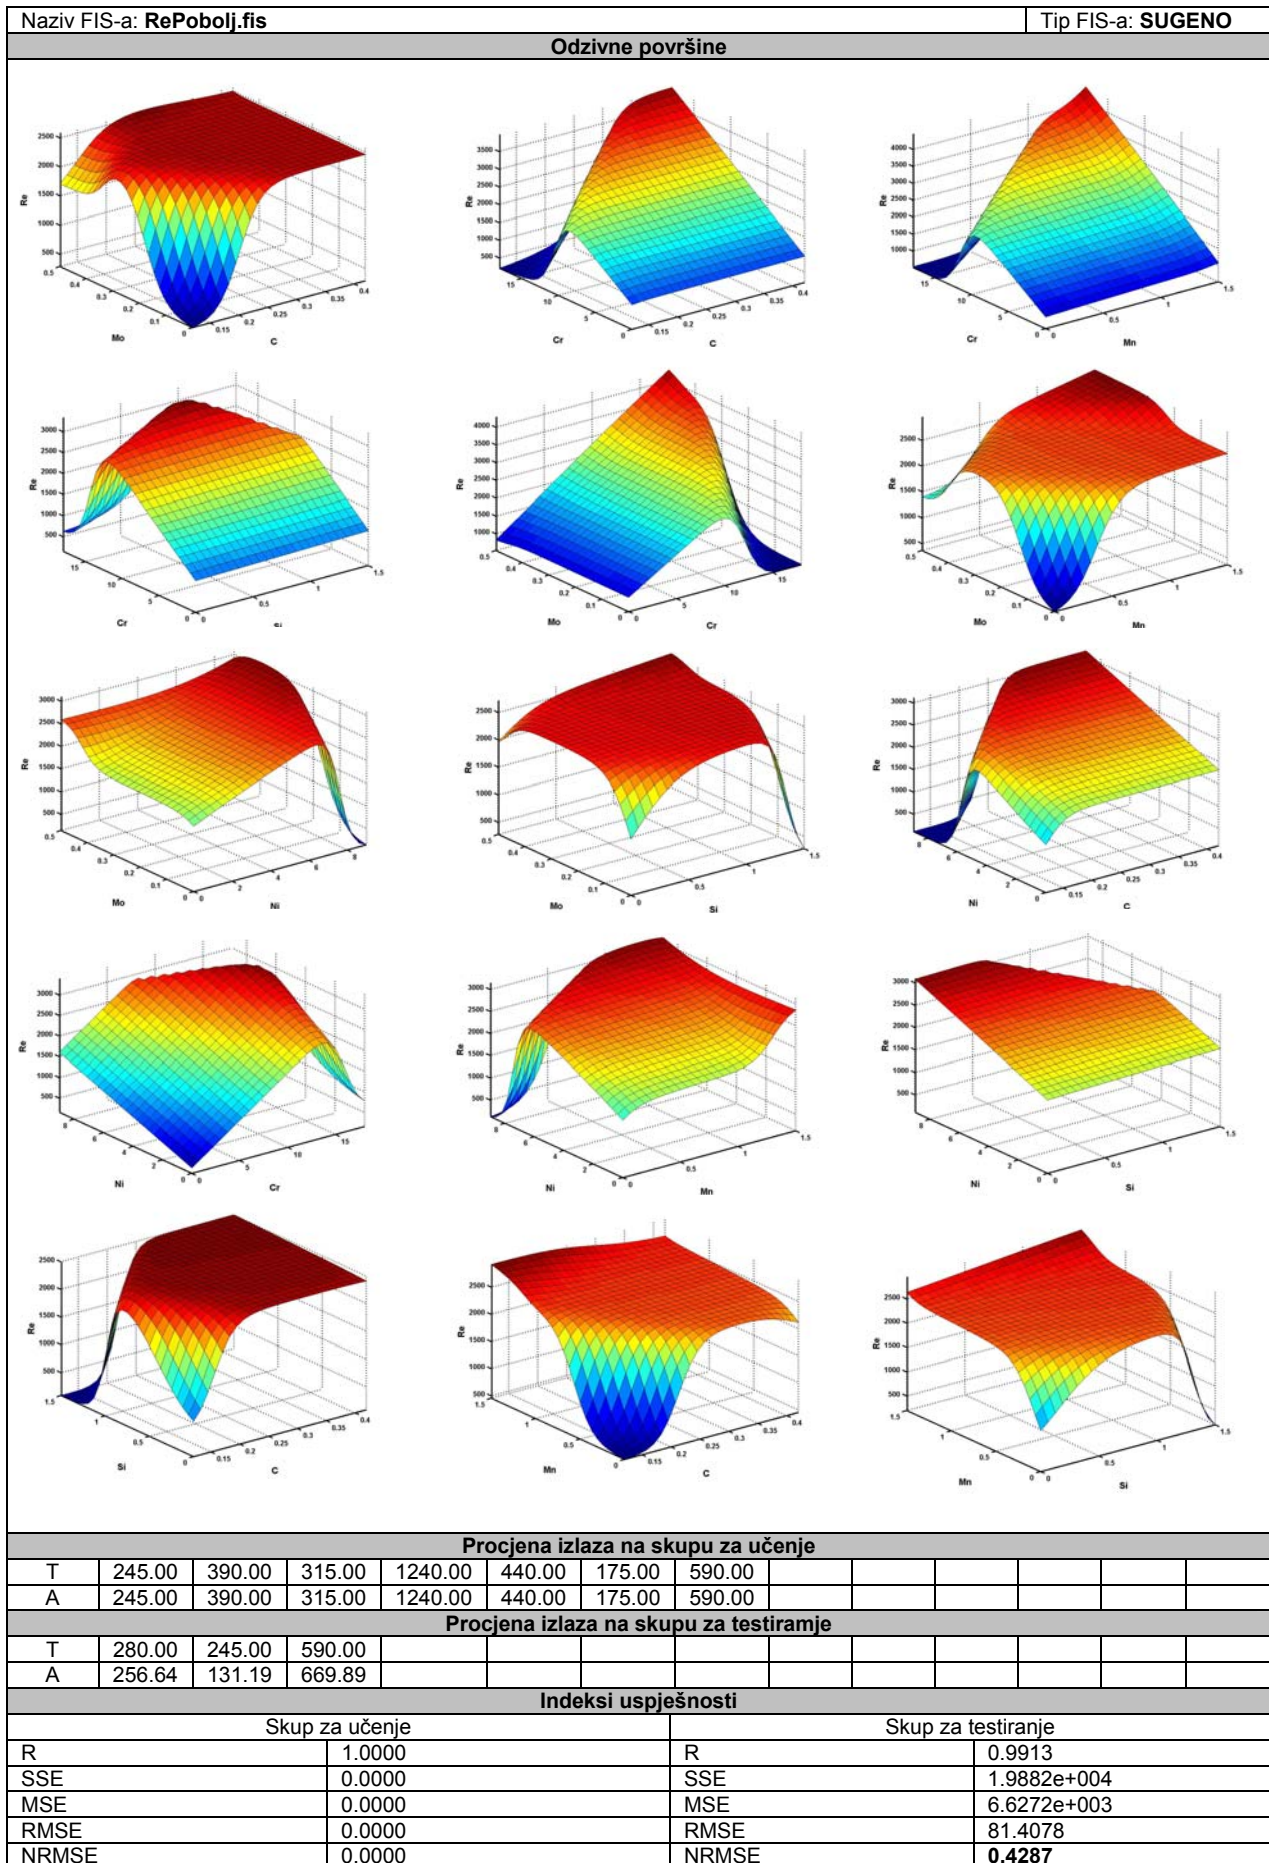


Nastavak: Tablica 4.42. Parametri, struktura i rezultati *FIS*-a za procjenu *Rm* u poboljšanom stanju

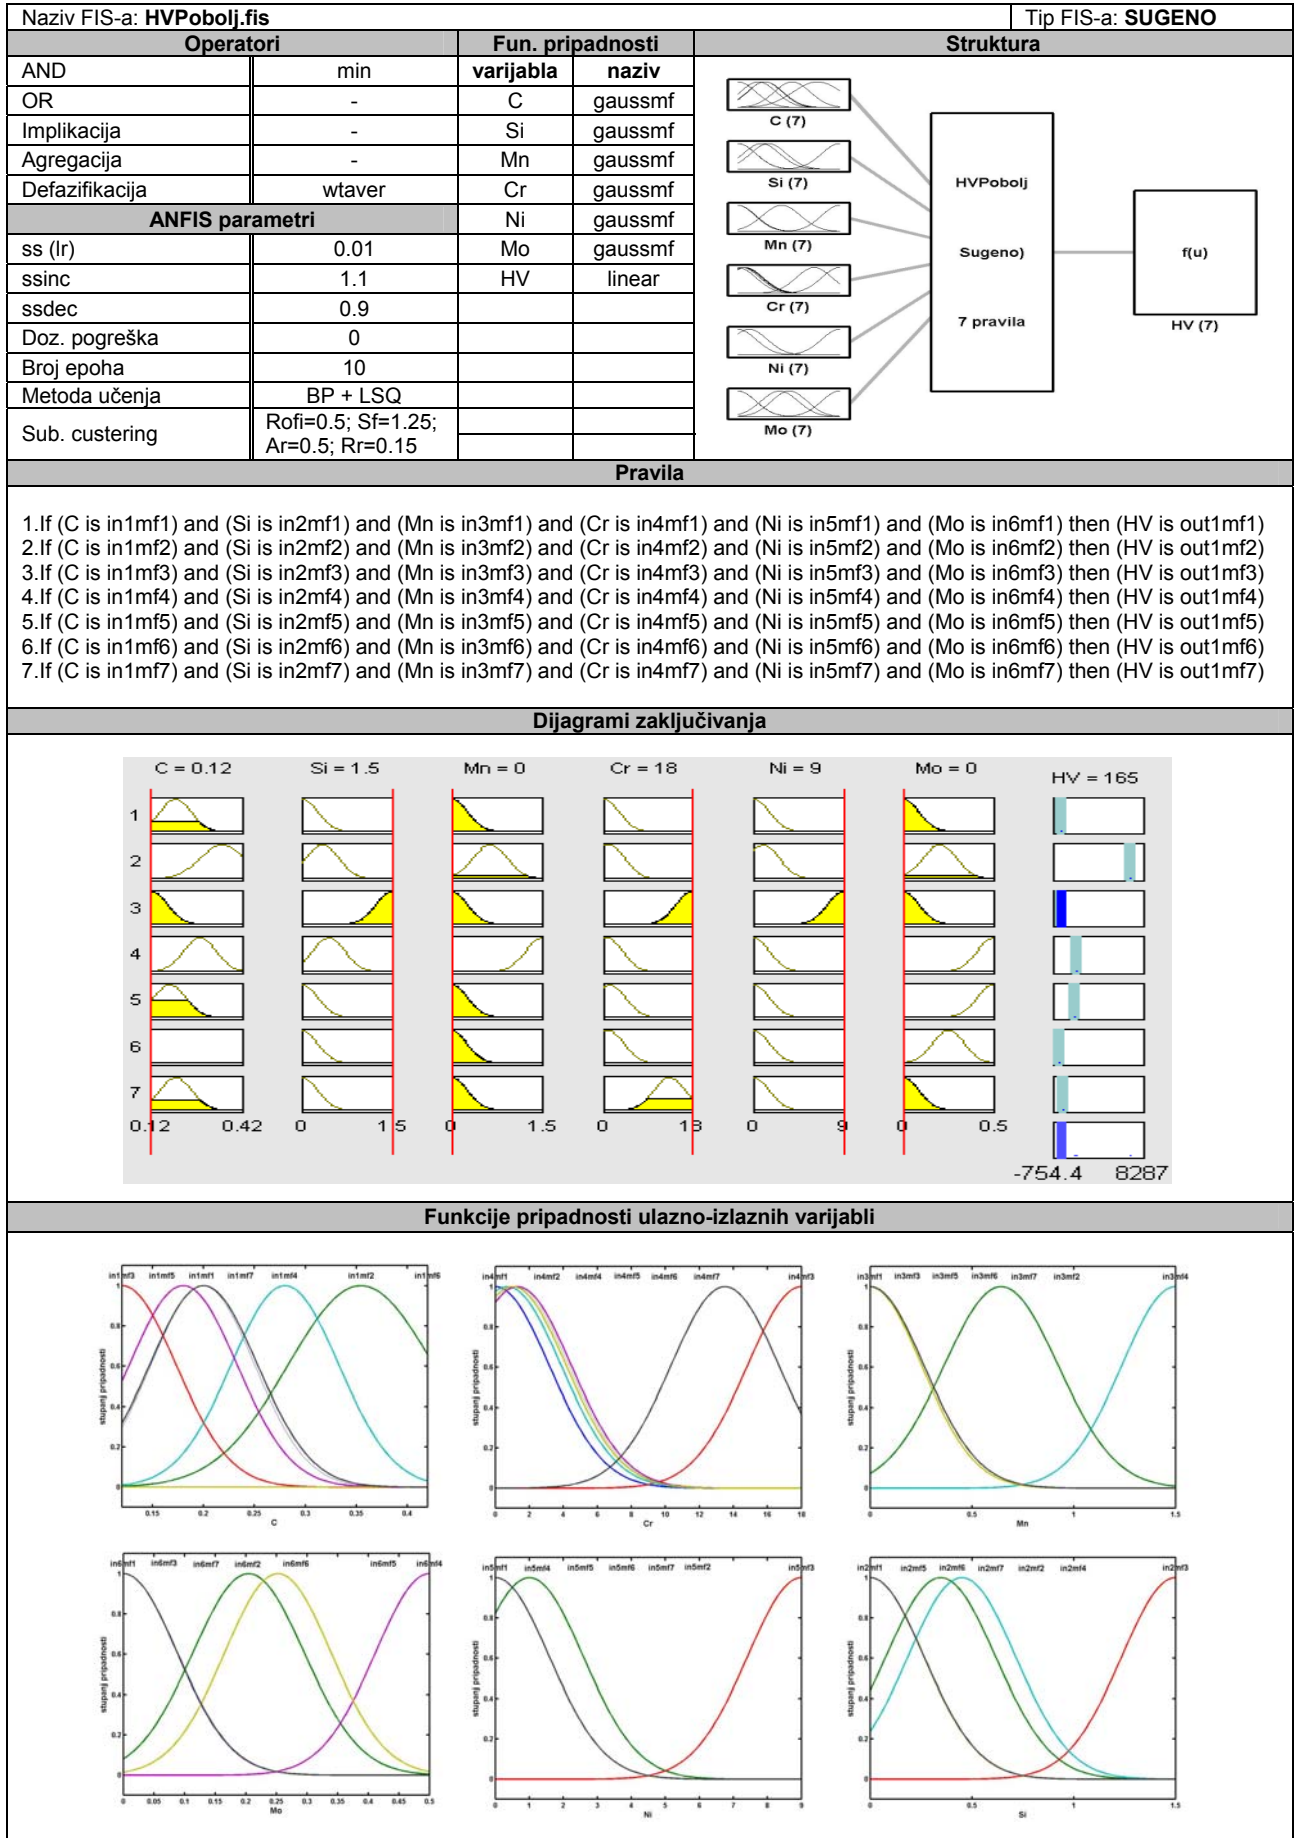
Tablica 4.43. Parametri, struktura i rezultati FIS-a za procjenu *Re* u poboljšanom stanju



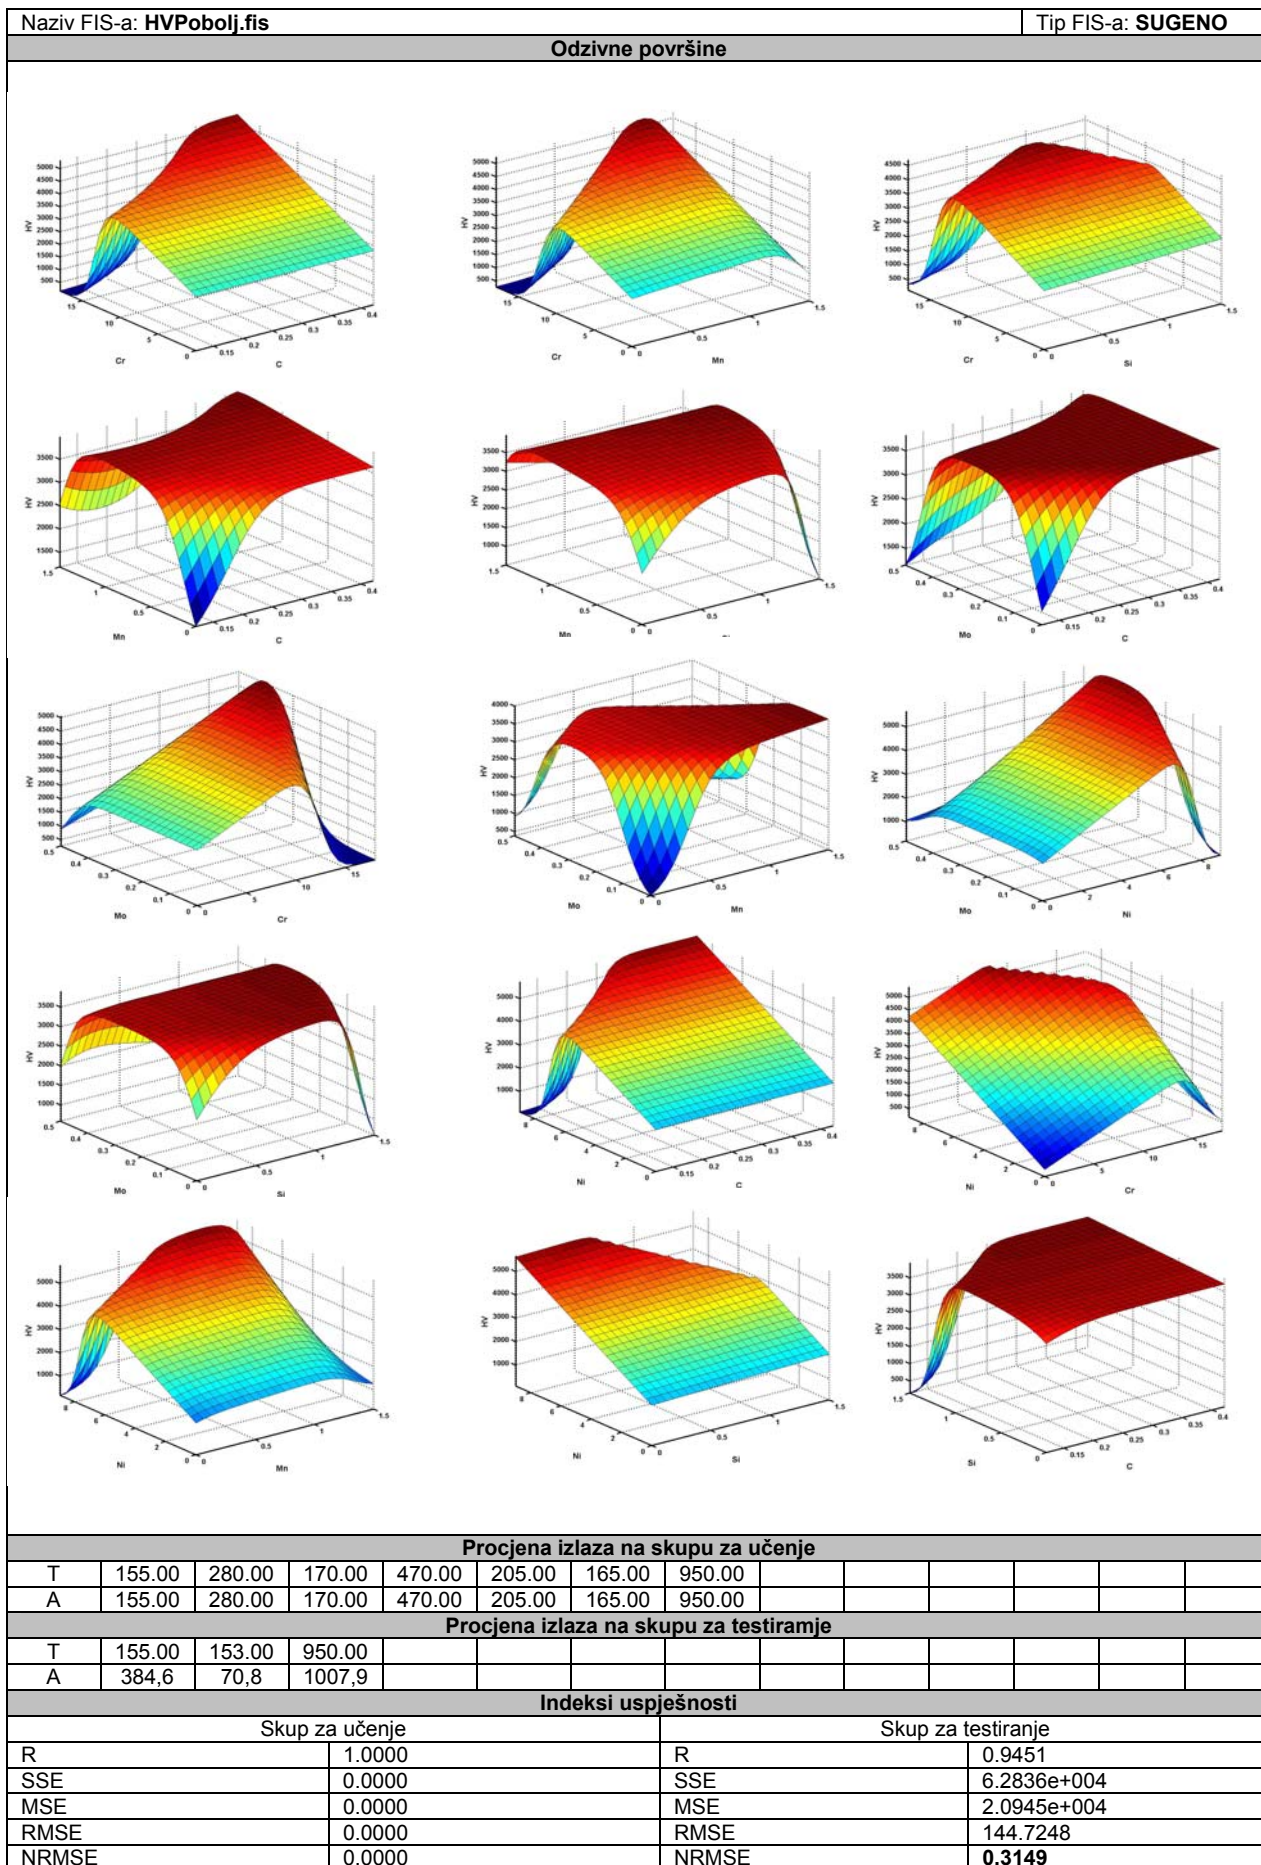
Nastavak: Tablica 4.43. Parametri, struktura i rezultati FIS-a za procjenu *Re* u poboljšanom stanju



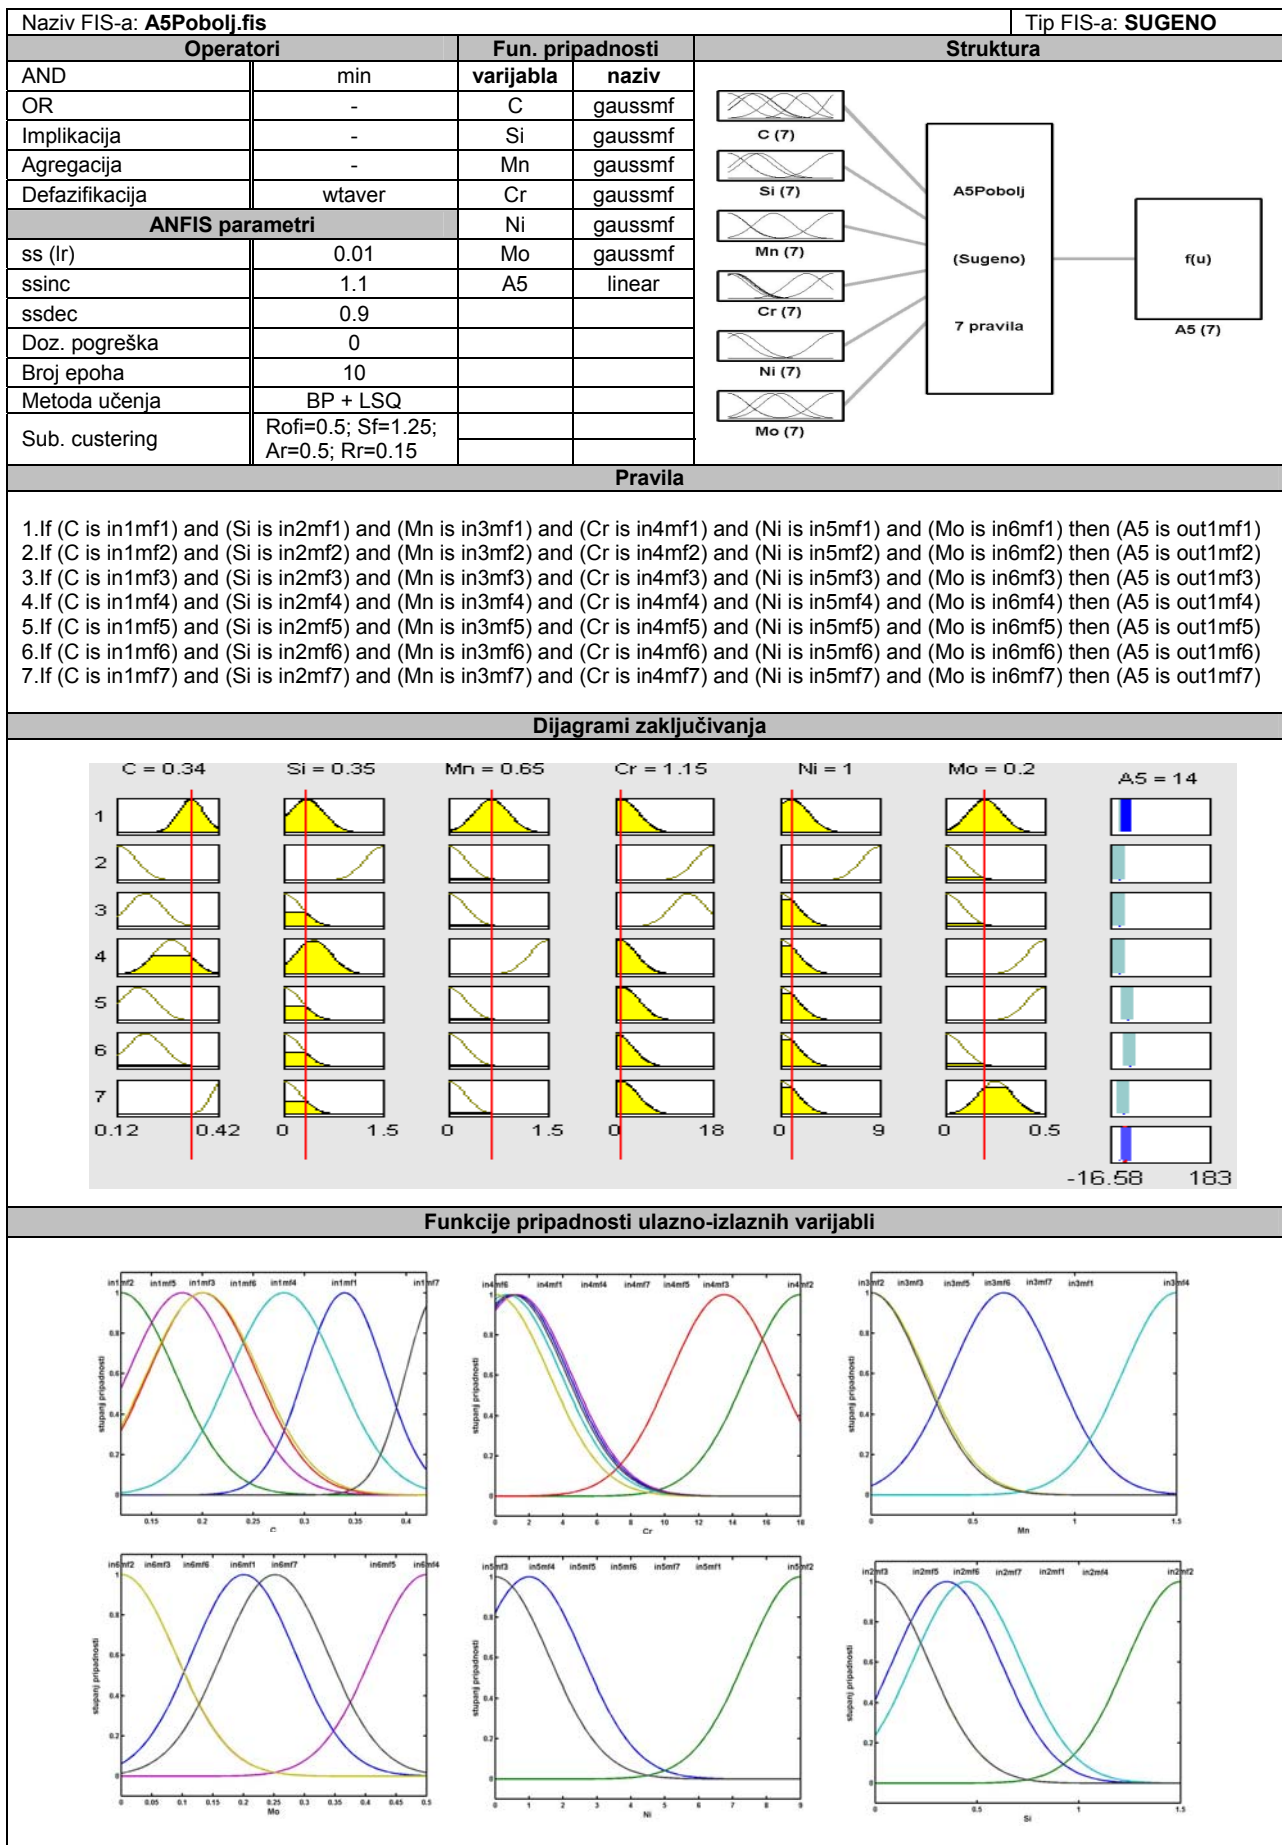
Tablica 4.44. Parametri, struktura i rezultati FIS-a za procjenu HV u poboljšanom stanju



Nastavak: Tablica 4.44. Parametri, struktura i rezultati FIS-a za procjenu HV u poboljšanom stanju



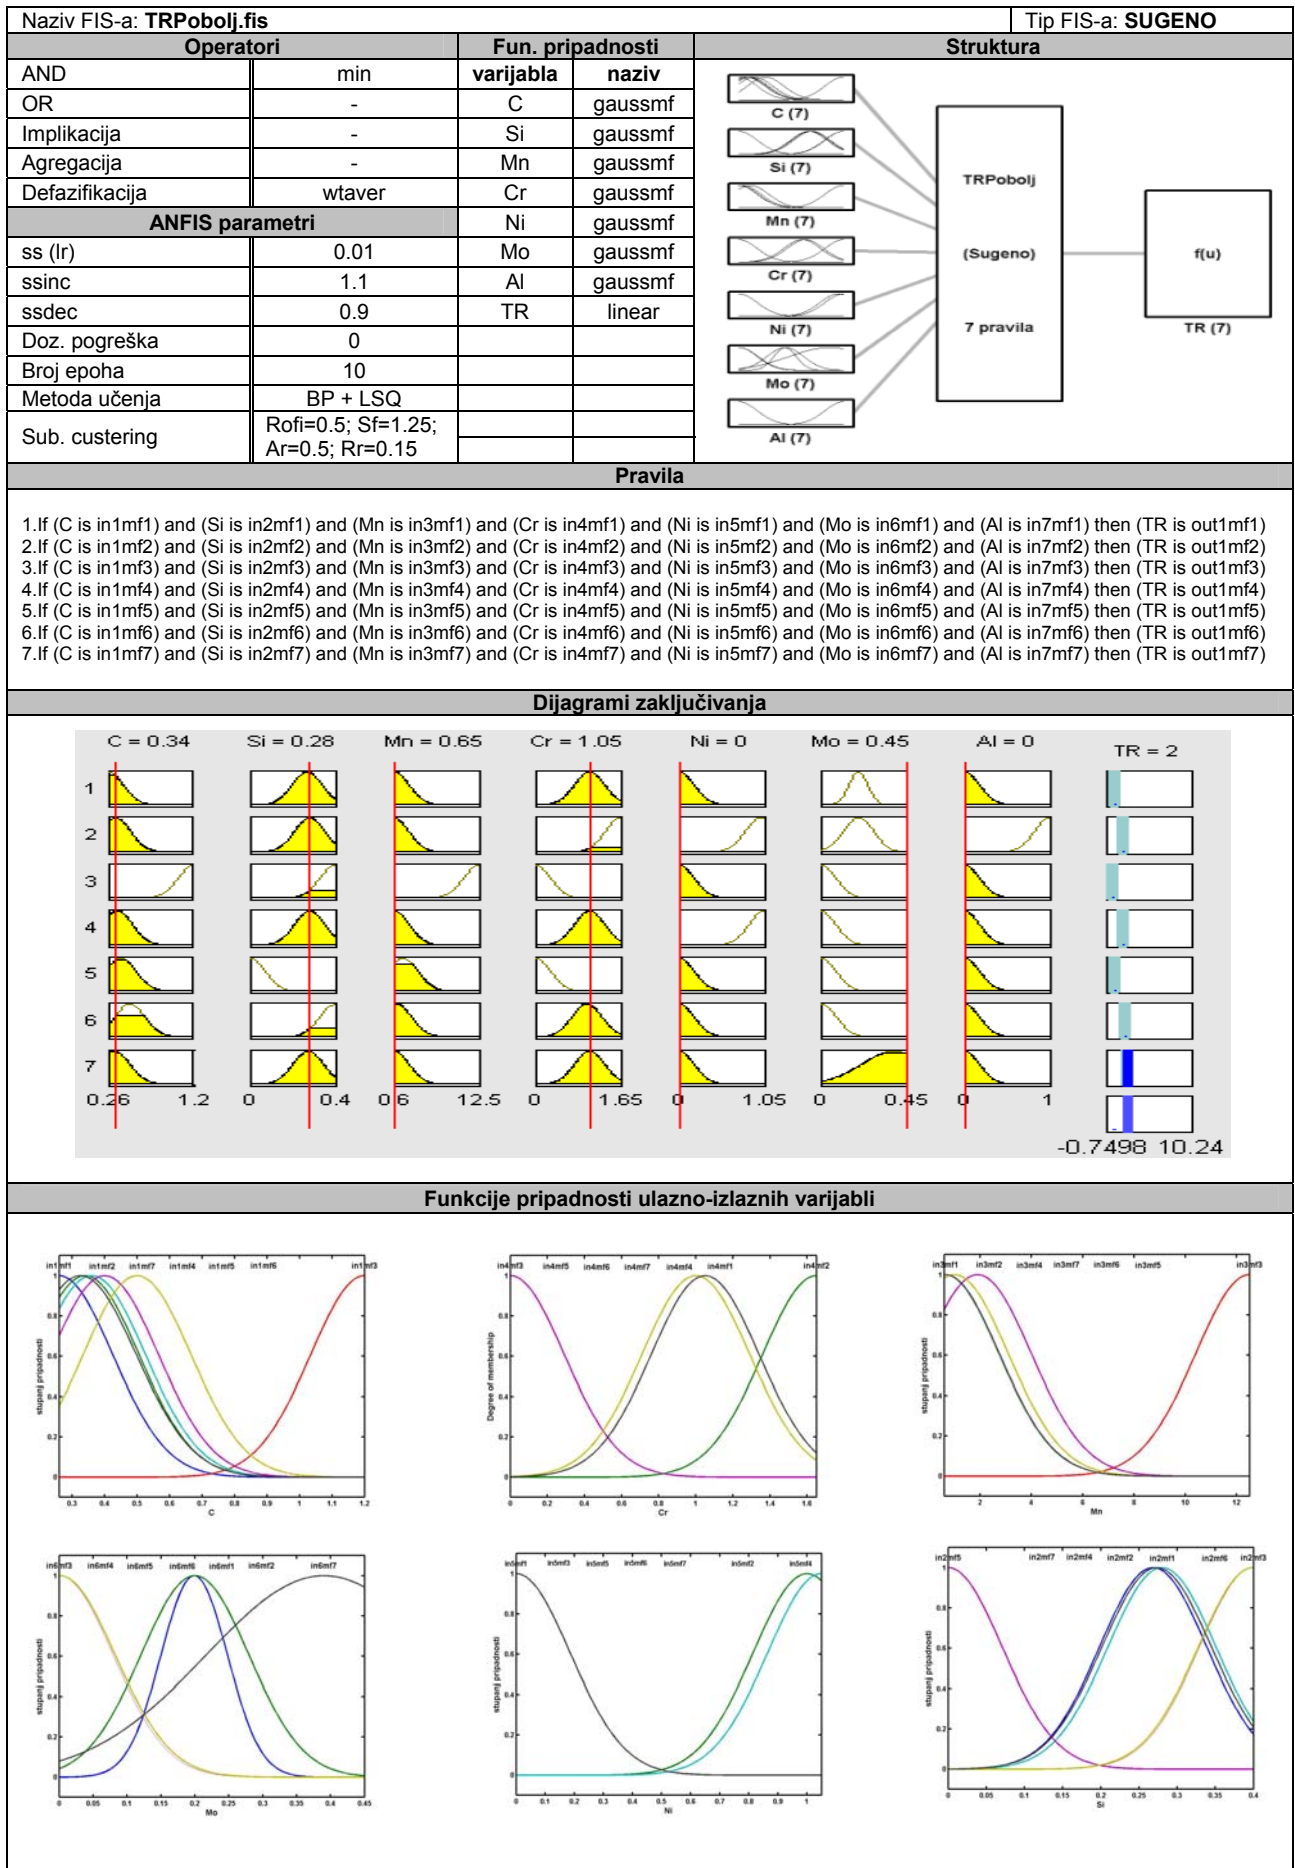
Tablica 4.45. Parametri, struktura i rezultati FIS-a za procjenu A5 u poboljšanom stanju



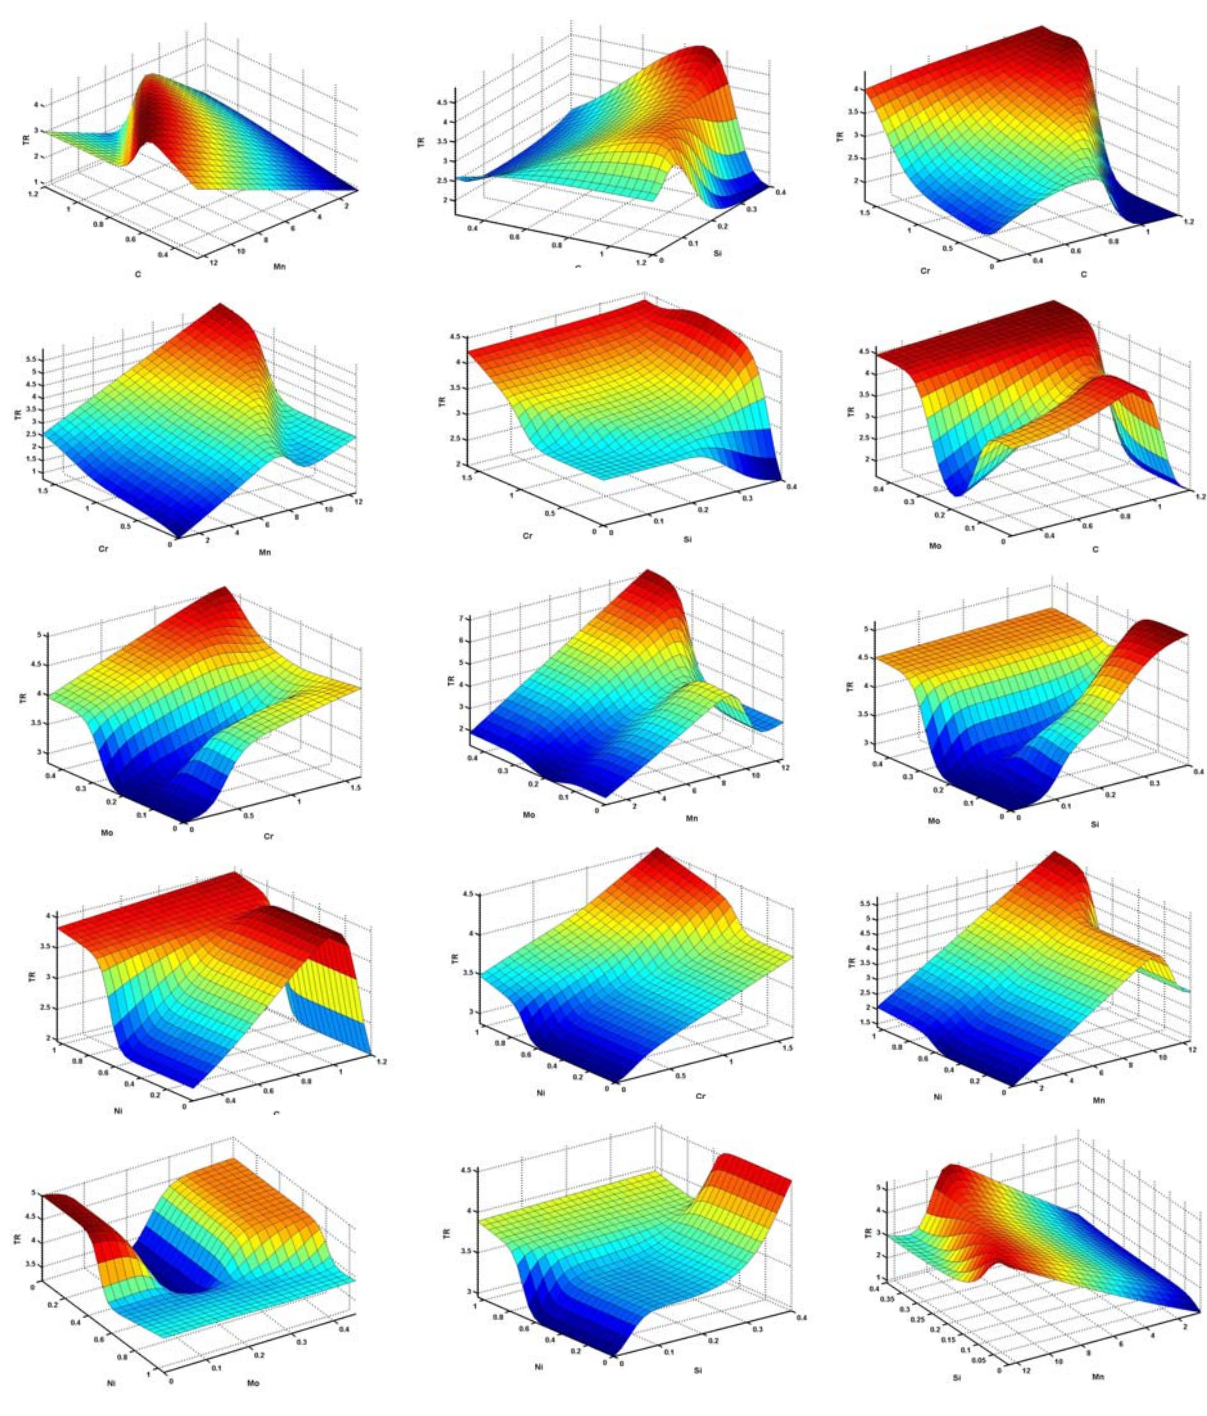
Nastavak: Tablica 4.45. Parametri, struktura i rezultati FIS-a za procjenu A5 u poboljšanom stanju

Naziv FIS-a: A5Pobolj.fis										Tip FIS-a: SUGENO									
Odzivne površine																			
Procjena izlaza na skupu za učenje																			
T	22.00	9.00	20.00	3.00	12.00	20.00	14.00												
A	22.00	9.00	20.00	3.00	12.00	20.00	14.00												
Procjena izlaza na skupu za testiranje																			
T	20.00	9.00	14.00																
A	20.96	8.33	15.91																
Indeksi uspješnosti																			
Skup za učenje										Skup za testiranje									
R	1.0000									R	0.9860								
SSE	0.0000									SSE	5.0424								
MSE	0.0000									MSE	1.6808								
RMSE	0.0000									RMSE	1.2965								
NRMSE	0.0000									NRMSE	0.2354								

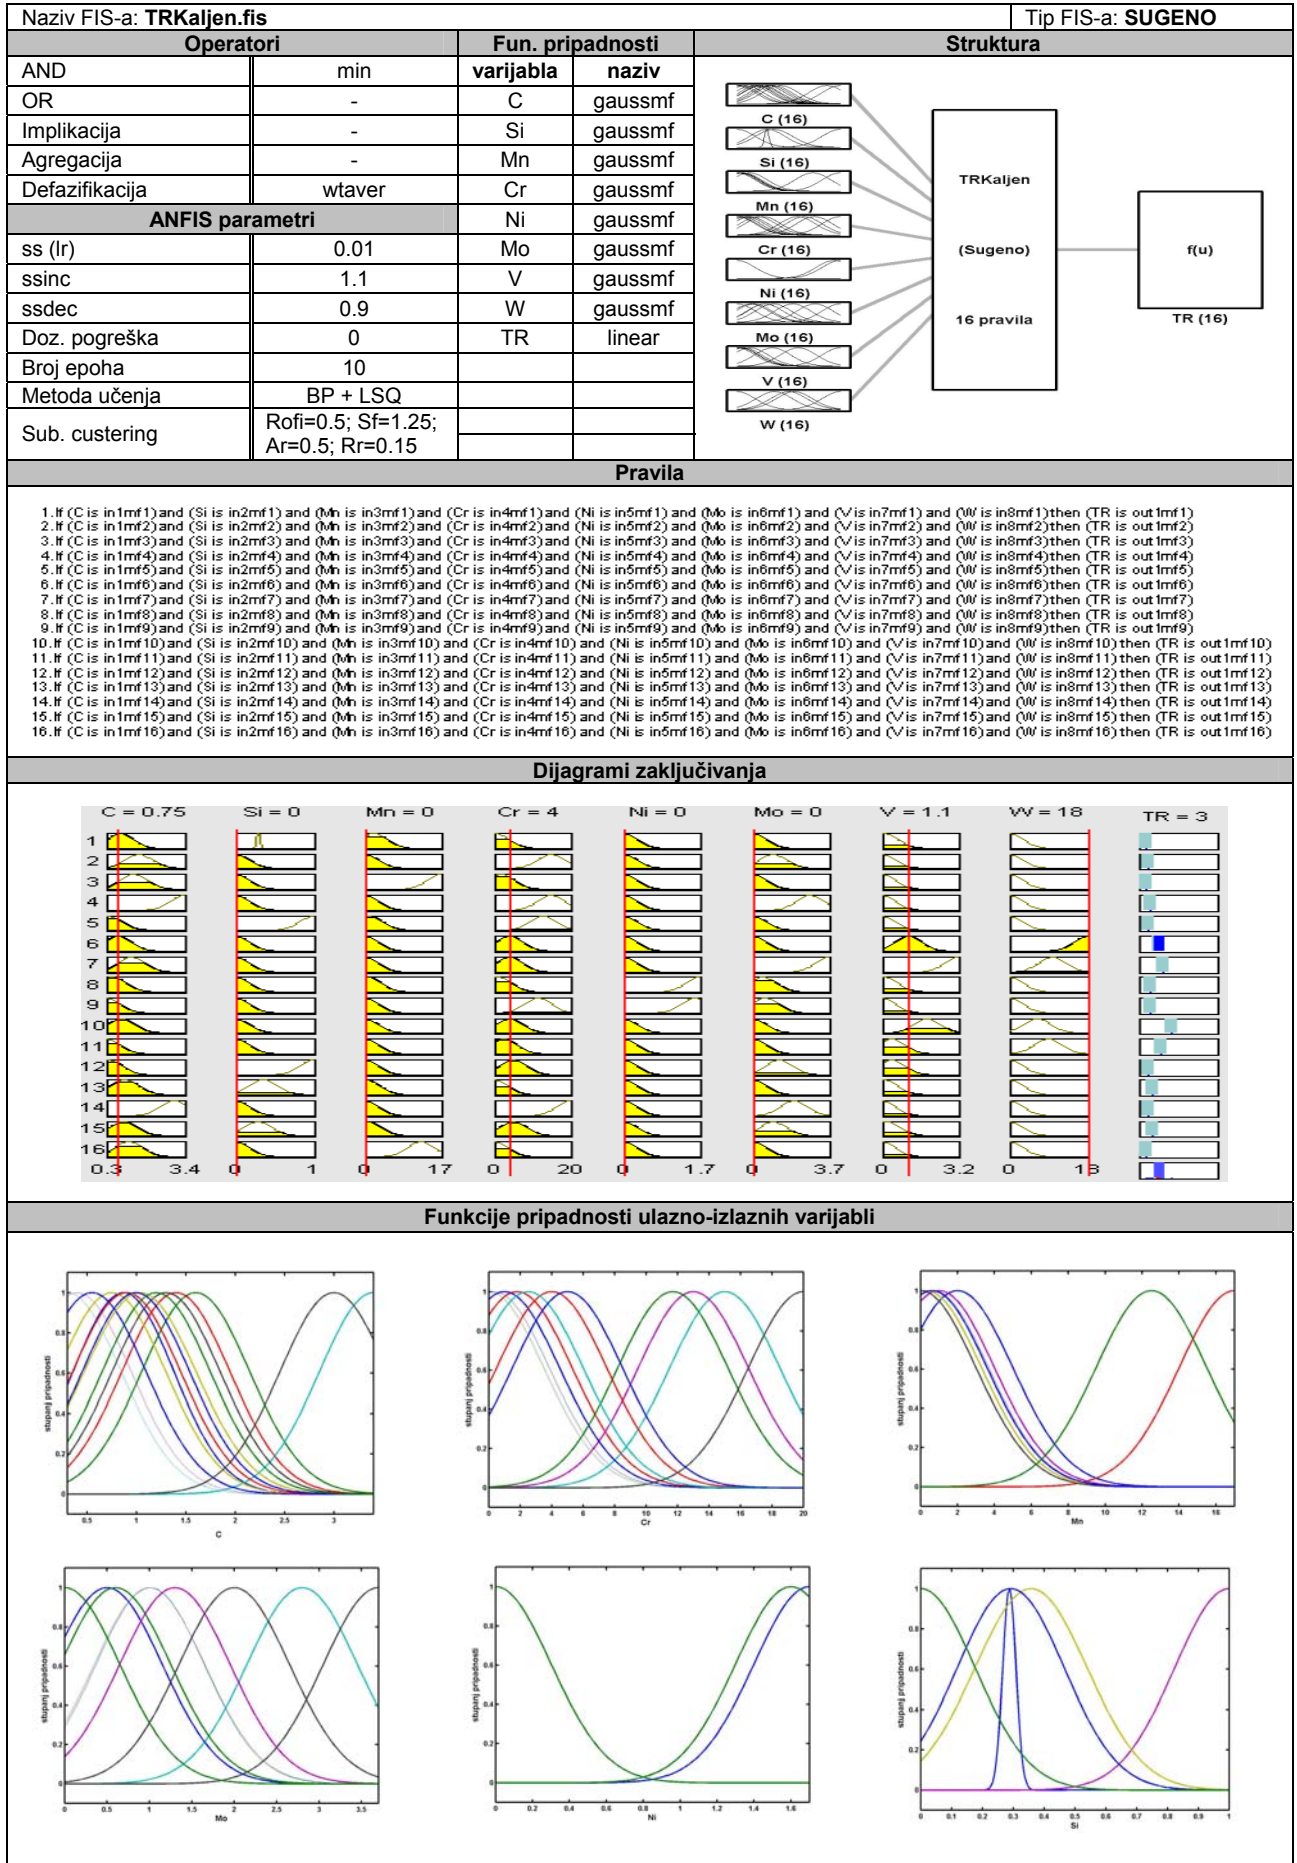
Tablica 4.46. Parametri, struktura i rezultati FIS-a za procjenu otpornosti trošenju u poboljšanom stanju



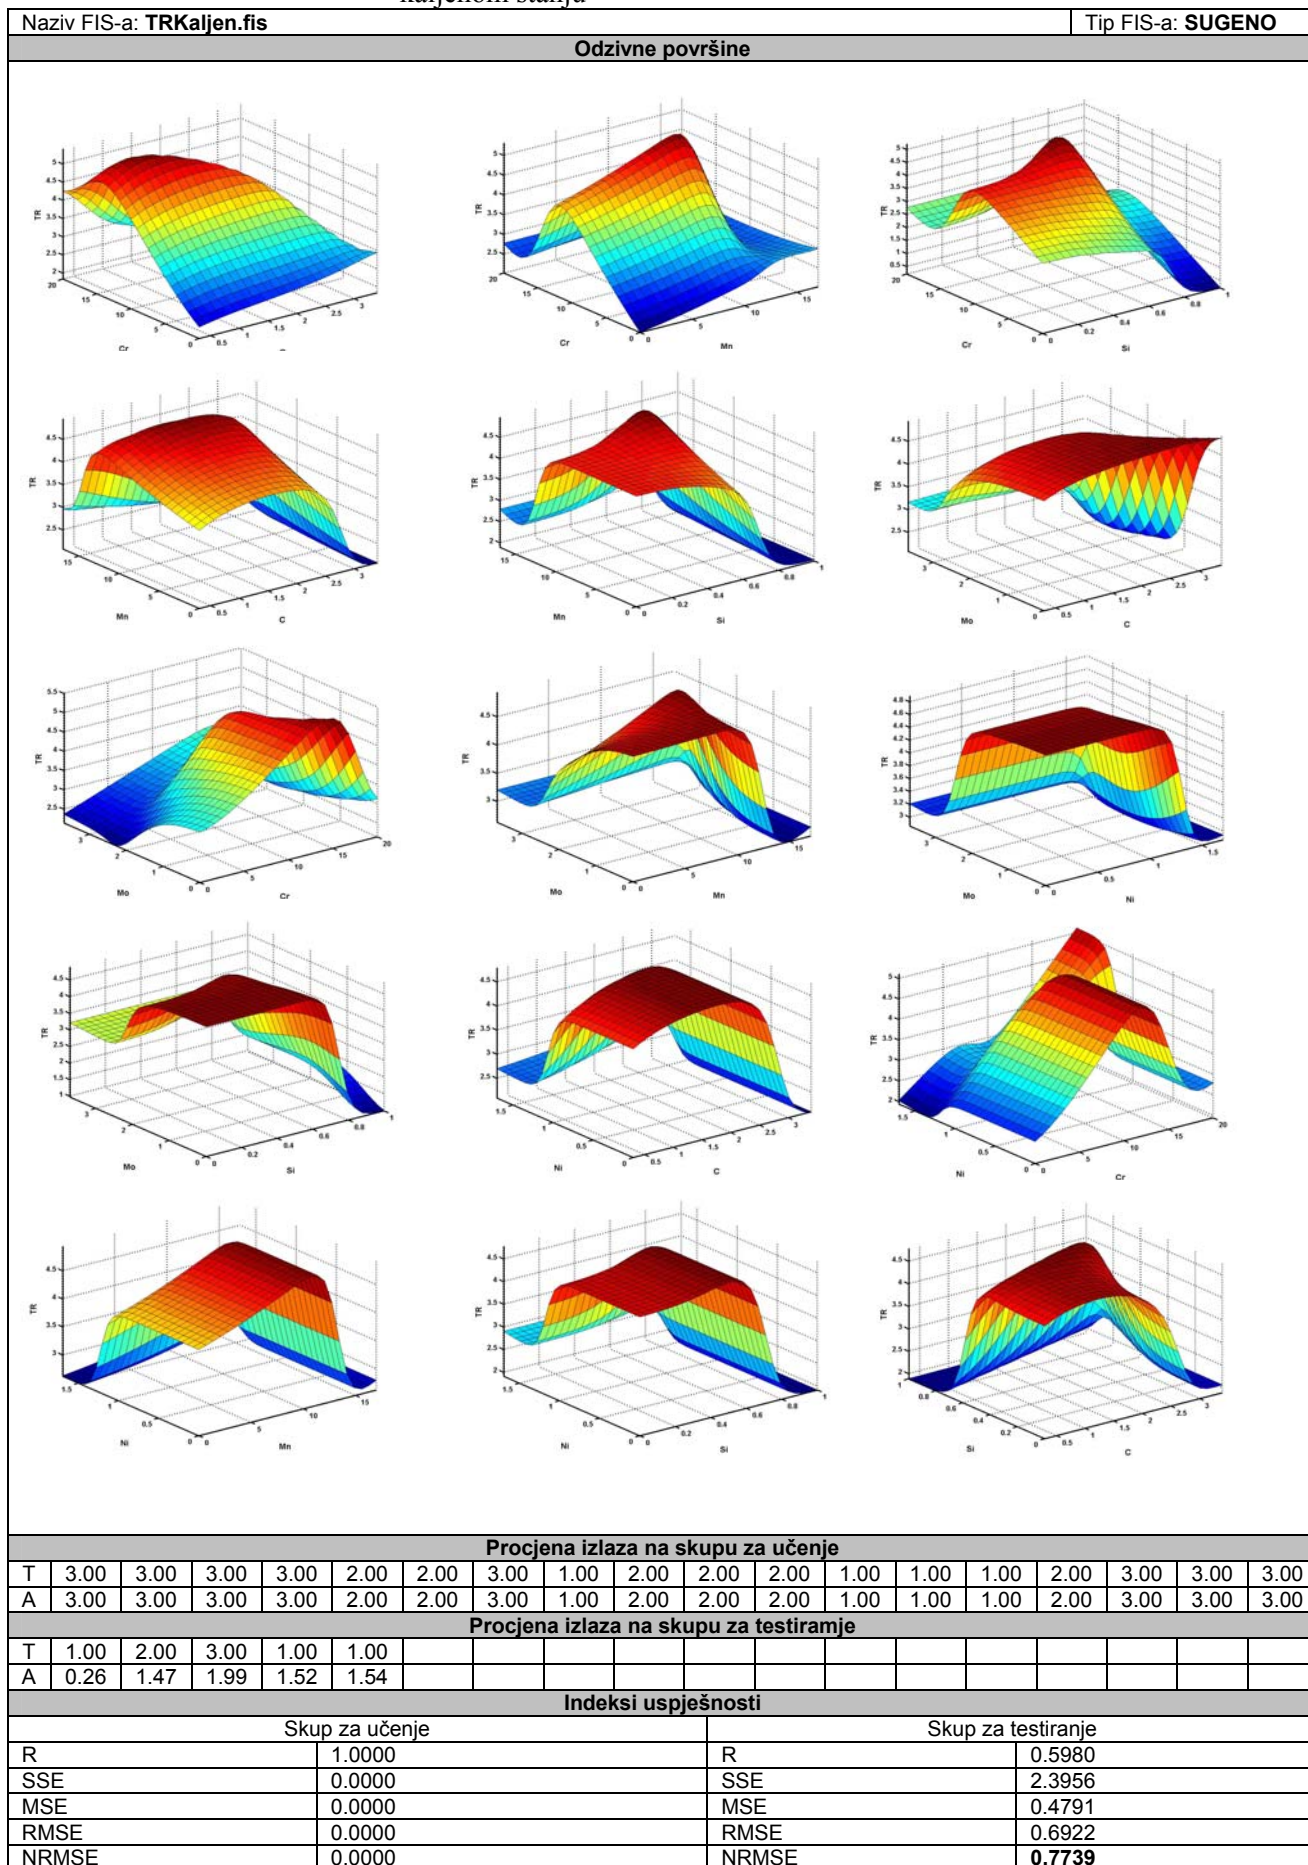
Nastavak: Tablica 4.46. Parametri, struktura i rezultati *FIS*-a za procjenu otpornosti trošenju u poboljšanom stanju

Naziv FIS-a: TRPobolj.fis										Tip FIS-a: SUGENO									
Odzivne površine																			
																			
Procjena izlaza na skupu za učenje																			
T	1.00	2.00	1.00	2.00	2.00	3.00	3.00												
A	1.00	2.00	1.00	2.00	2.00	3.00	3.00												
Procjena izlaza na skupu za testiranje																			
T	2.00	2.00	3.00																
A	1.93	1.91	1.54																
Indeksi uspješnosti																			
Skup za učenje										Skup za testiranje									
R	1.0000									R	0.9981								
SSE	0.0000									SSE	2.1146								
MSE	0.0000									MSE	0.7049								
RMSE	0.0000									RMSE	0.8396								
NRMSE	0.0000									NRMSE	1.4542								

Tablica 4.47. Parametri, struktura i rezultati FIS-a za procjenu otpornosti trošenju u kaljenom stanju



Nastavak: Tablica 4.47. Parametri, struktura i rezultati *FIS*-a za procjenu otpornosti trošenju u kaljenom stanju



4.5.3. Iskustvene procjene primarnih zahtjeva na alatne čelike s obzirom na utjecaj karbidotvoraca

Zbog specifičnih uvjeta u eksploataciji (visoka toplinska i mehanička opterećenja) primarni zahtjevi na alatne čelike jesu: otpornost na trošenje, otpornost na popuštanje i žilavost. U praksi se predizbor alatnih čelika s obzirom na primarne zahtjeve temelji na metodi iskustvenog ocjenjivanja od 1 do 9 prema *Roberts-Hamaker-Johnson*-u [47]. 1 predstavlja najnižu ocjenu, a 9 najvišu. Prema tablicama P1.34, P1.35 i P1.36 u prilogu I, ulazne skupove za procjenu primarnih zahtjeva čine podaci o karbidotvorcima tj. kemijski sastav elemenata *Cr, W, V, Mo*, a izlazne skupove podaci (ocjene) primarnih svojstava: *TR-otpornost trošenju, PO-otpornost popuštanju, i ZI-žilavost*. S obzirom da su ulazno-izlazni skupovi podataka numeričkog tipa, primjenjen je *Sugeno* model, a za optimiranje tipa funkcija pripadnosti te njihovog položaja (pronalaženja tipičnih vrijednosti) unutar *univerzalnog skupa* (engl. *universe of discourse*) primjenjen je hibridni algoritam učenja - *ANFIS* (engl. *adaptive network fuzzy inference system*). Pri modeliranju *FIS*-ova primjenjeni standardni operatori i metode. Za procjenu svakog od primarnih svojstava podaci su slučajnim izborom podijeljeni na dva skupa: skup za učenje i skup za testiranje. Na slikama 4.36, 4.37, i 4.38 prikazane su ulazno-izlazne matrice za učenje i testiranje nabrojanih procjena. Prikaz parametara, strukture *FIS*-a, oblika funkcija pripadnosti, pravila, dijagrami zaljučivanja, rezultati procjene sa indeksima uspješnosti dano je u tablicama 4.48, 4.49, i 4.50.

A				B				
ULAZNI SKUP				IZLAZNI SKUP				
0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.1000	0.0000	3.0000
0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	1.0000	0.0000	4.0000
0.2000	1.0000	0.1000	0.0000	0.0000	0.0000	0.0000	0.0000	3.0000
0.7000	0.0000	0.7000	0.0000	0.0000	0.0000	1.2000	0.0000	4.0000
1.0000	2.0000	0.2000	0.0000	0.0000	0.0000	0.0000	0.0000	4.0000
12.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.2500	1.0000	6.0000
13.0000	0.0000	0.0000	0.0000	0.0000	0.0000	1.0000	0.9000	8.0000
0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.4000	3.0000
5.0000	0.0000	0.4000	1.3000	3.0000	0.0000	0.5000	3.0000	4.0000
5.0000	0.0000	0.4000	1.3000	4.0000	0.0000	4.0000	0.0000	4.0000
4.0000	12.5000	2.0000	1.2000	8.0000	18.0000	1.5000	0.7000	7.0000
4.0000	10.0000	3.2000	3.7000	9.0000	4.0000	12.5000	2.0000	1.2000
0.0000	0.0000	0.0000	0.0000	4.0000	4.0000	1.7000	1.2000	8.5000
0.0000	0.0000	0.0000	0.0000	4.0000	0.0000	0.0000	0.0000	0.0000
0.5000	4.5000	0.2500	0.0000	7.0000	0.0000	0.0000	0.0000	4.0000
0.3500	0.0000	0.1000	0.0000	4.0000	0.6000	1.5000	0.1000	0.0000
1.0000	2.0000	0.3000	0.0000	5.0000	0.7000	0.0000	0.0000	0.0000
0.0000	0.5000	0.1000	0.6000	8.0000	0.7000	0.0000	0.0000	0.0000
0.0000	0.0000	0.0000	0.0000	3.0000	13.0000	0.0000	0.0000	2.0000
0.7000	0.0000	0.1000	0.3000	2.0000	1.1000	0.0000	0.1000	0.5000
5.0000	0.0000	1.0000	1.5000	4.0000	5.0000	0.0000	1.0000	1.3000
4.0000	18.0000	1.5000	0.7000	7.0000	4.0000	18.0000	1.1000	0.0000
4.0000	12.0000	2.5000	0.8000	7.0000	4.0000	12.0000	3.7000	0.8000
4.0000	6.5000	1.9000	5.0000	7.0000	4.0000	6.5000	1.9000	5.0000

Slika 4.36. Ulazno-izlazna matrice za učenje (A) i za testiranje (B) procjene otpornosti trošenju alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo)

A				IZLAZNI SKUP
ULAZNI SKUP				
0.0000	0.0000	0.0000	0.0000	1.0000
0.0000	0.0000	0.0000	0.0000	1.0000
0.2000	1.0000	0.1000	0.0000	2.0000
0.7000	0.0000	0.7000	0.0000	2.0000
1.0000	2.0000	0.2000	0.0000	5.0000
12.0000	0.0000	0.0000	0.0000	6.0000
13.0000	0.0000	0.0000	0.0000	6.0000
0.0000	0.0000	0.0000	0.0000	6.0000
5.0000	0.0000	0.4000	1.3000	6.0000
0.5000	0.0000	0.4000	1.3000	8.0000
4.0000	12.5000	2.0000	1.2000	8.0000
4.0000	10.0000	3.2000	3.7000	9.0000
0.0000	0.0000	0.0000	0.0000	1.0000
0.0000	0.0000	0.0000	0.0000	1.0000
0.5000	4.5000	0.2500	0.0000	3.0000
0.3500	0.0000	0.1000	0.0000	3.0000
1.0000	2.0000	0.3000	0.0000	5.0000
0.0000	0.5000	0.1000	0.6000	6.0000
0.0000	0.0000	0.0000	0.0000	6.0000
0.7000	0.0000	0.1000	0.3000	3.0000
5.0000	0.0000	1.0000	1.5000	6.0000
4.0000	18.0000	1.5000	0.7000	8.0000
4.0000	12.0000	2.5000	0.8000	8.0000
4.0000	6.5000	1.9000	5.0000	8.0000

B				IZLAZNI SKUP
ULAZNI SKUP				
0.0000	0.0000	0.1000	0.0000	1.0000
0.0000	1.0000	0.2000	0.0000	3.0000
1.5000	0.0000	0.0000	0.0000	2.0000
1.0000	1.2000	0.0000	0.0000	3.0000
5.0000	0.0000	0.2500	1.0000	5.0000
12.0000	0.0000	1.0000	0.9000	7.0000
14.0000	0.0000	0.0000	0.4000	6.0000
3.0000	0.0000	0.5000	3.0000	8.0000
1.0000	4.0000	0.2000	0.0000	7.0000
4.0000	18.0000	1.5000	0.7000	9.0000
4.0000	12.5000	2.0000	1.2000	9.0000
4.0000	1.7000	1.2000	8.5000	8.0000

Slika 4.37. Ulazno-izlazna matrice za učenje (A) i za testiranje (B) procjene otpornosti popuštanjalu alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo)

A				IZLAZNI SKUP
ULAZNI SKUP				
0.0000	0.0000	0.0000	0.0000	8.0000
0.0000	0.0000	0.0000	0.0000	4.0000
0.2000	1.0000	0.1000	0.0000	3.0000
0.7000	0.0000	0.7000	0.0000	4.0000
1.0000	2.0000	0.2000	0.0000	5.0000
12.0000	0.0000	0.0000	0.0000	1.0000
13.0000	0.0000	0.0000	0.0000	8.0000
0.0000	0.0000	0.0000	0.0000	4.0000
5.0000	0.0000	0.4000	1.3000	9.0000
5.0000	0.0000	0.4000	1.3000	4.0000
4.0000	12.5000	2.0000	1.2000	2.0000
4.0000	10.0000	3.2000	3.7000	1.0000
0.0000	0.0000	0.0000	0.0000	4.0000
0.0000	0.0000	0.0000	0.0000	3.0000
0.5000	4.5000	0.2500	0.0000	2.0000
0.3500	0.0000	0.1000	0.0000	3.0000
1.0000	2.0000	0.3000	0.0000	3.0000
0.0000	0.5000	0.1000	0.6000	2.0000
0.0000	0.0000	0.0000	0.0000	6.0000
0.7000	0.0000	0.1000	0.3000	7.0000
5.0000	0.0000	1.0000	1.5000	8.0000
4.0000	18.0000	1.5000	0.7000	2.0000
4.0000	12.0000	2.5000	0.8000	2.0000
4.0000	6.5000	1.9000	5.0000	2.0000

B				IZLAZNI SKUP
ULAZNI SKUP				
0.0000	0.0000	0.1000	0.0000	5.0000
0.0000	1.0000	0.2000	0.0000	3.0000
1.5000	0.0000	0.0000	0.0000	4.0000
1.0000	1.2000	0.0000	0.0000	3.0000
5.0000	0.0000	0.2500	1.0000	4.0000
12.0000	0.0000	1.0000	0.9000	2.0000
14.0000	0.0000	0.0000	0.4000	6.0000
3.0000	0.0000	0.5000	3.0000	4.0000
1.0000	4.0000	0.2000	0.0000	7.0000
4.0000	18.0000	1.5000	0.7000	1.0000
4.0000	12.5000	2.0000	1.2000	1.0000
4.0000	1.7000	1.2000	8.5000	3.0000

S

Slika 4.38. Ulazno-izlazna matrice za učenje (A) i za testiranje (B) procjene žilavosti alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo)

Tablica 4.48. Parametri, struktura i rezultati FIS-a za procjenu otpornosti trošenju alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo)

Naziv FIS-a: TRAlatni.fis				Tip FIS-a: SUGENO	
Operatori		Fun. pripadnosti		Struktura	
		varijabla	naziv		
AND	min	Cr	gaussmf		
OR	-	Cr	gaussmf		
Implikacija	prod	W	gaussmf		
Agregacija	max	V	gaussmf		
Defazifikacija	wtaver	Mo	gaussmf		
ANFIS parametri				TR	linear
ss (lr)	0.01				
ssinc	1.1				
ssdec	0.9				
Doz. pogreška	0				
Broj epoha	10				
Metoda učenja	BP + LSQ				
Fcm clustering	Br. ul. mf: 3 3 3 3				
Pravila					
1. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf1) then (TR is out1mf1) 2. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf2) then (TR is out1mf2) 3. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf3) then (TR is out1mf3) ... 81. If (Cr is in1mf3) and (V is in2mf3) and (W is in3mf3) and (Mo is in4mf3) then (TR is out1mf81)					
Napomena: Zbog velikog broja, prikazan je dio pravila zaključivanja.					
Dijagrami zaključivanja					
Napomena: Zbog velikog broja pravila, prikazan je dio dijagrama zaključivanja.					
Funkcije pripadnosti ulazno-izlaznih varijabli					

Nastavak: Tablica 4.48. Parametri, struktura i rezultati *FIS*-a za procjenu otpornosti trošenju alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr, W, V, Mo)

Naziv FIS-a: TRAlatni.fis		Tip FIS-a: SUGENO	
Odzivne površine			
Procjena izlaza na skupu za učenje			
T			
A	<i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.		
Procjena izlaza na skupu za testiranje			
T			
A	<i>Napomena:</i> Zbog veličine, matrice (T) i (A) nisu prikazane.		
Indeksi uspješnosti			
Skup za učenje		Skup za testiranje	
R	0.9569	R	0.4946
SSE	10.0000	SSE	290.5238
MSE	0.4167	MSE	12.1052
RMSE	0.6455	RMSE	3.4792
NRMSE	0.2842	NRMSE	1.5985

Tablica 4.49. Parametri, struktura i rezultati FIS-a za procjenu otpornosti popuštanju alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo)

Naziv FIS-a: POAlatni.fis				Tip FIS-a: SUGENO	
Operatori		Fun. pripadnosti		Struktura	
AND	min	varijabla	naziv		
OR	-	Cr	gaussmf		
Implikacija	prod	W	gaussmf		
Agregacija	max	V	gaussmf		
Defazifikacija	wtaver	Mo	gaussmf		
ANFIS parametri			PO	linear	
ss (lr)	0.01				
Ssinc	1.1				
ssdec	0.9				
Doz. pogreška	0				
Broj epoha	10				
Metoda učenja	BP + LSQ				
Fcm clustering	Br. ul. mf: 3 3 3 3				
Pravila					
1. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf1) then (PO is out1mf1) 2. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf2) then (PO is out1mf2) 3. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf3) then (PO is out1mf3) ... 81. If (Cr is in1mf3) and (V is in2mf3) and (W is in3mf3) and (Mo is in4mf3) then (PO is out1mf81)					
<i>Napomena:</i> Zbog velikog broja, prikazan je dio pravila zaključivanja.					
Dijagrami zaključivanja					
<i>Napomena:</i> Zbog velikog broja pravila, prikazan je dio dijagrama zaključivanja.					
Funkcije pripadnosti ulazno-izlaznih varijabli					

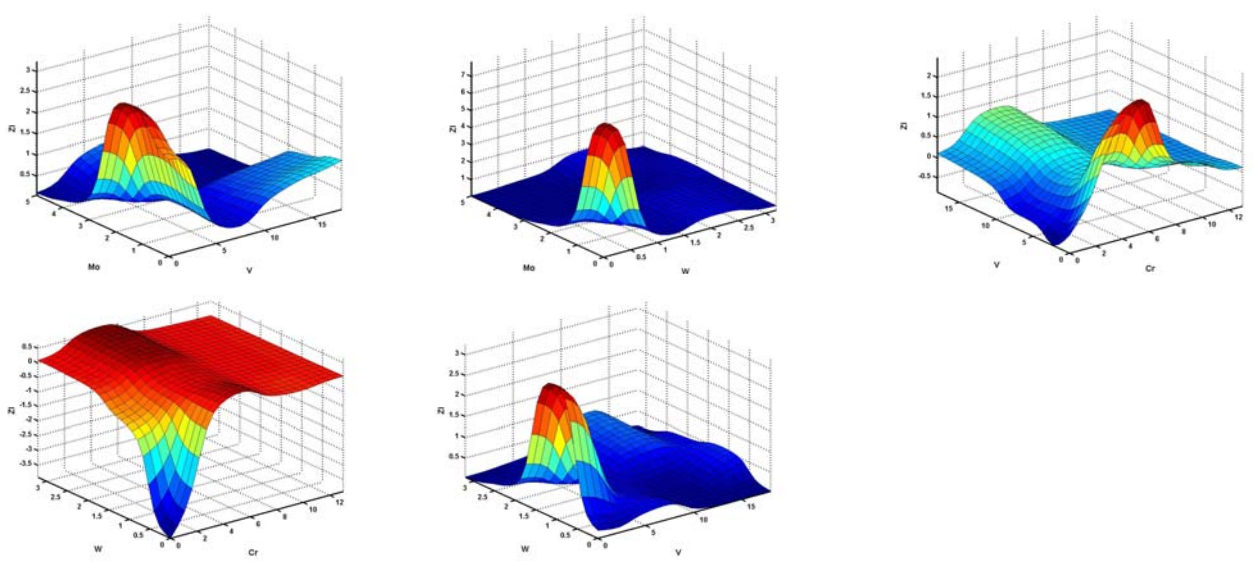
Nastavak: Tablica 4.49. Parametri, struktura i rezultati *FIS*-a za procjenu otpornosti popuštanju alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo)

Naziv FIS-a: POAlatni.fis		Tip FIS-a: SUGENO		
Odzivne površine				
Procjena izlaza na skupu za učenje				
T				
A	<i>Napomena:</i> Zbog veličine, matrice (<i>T</i>) i (<i>A</i>) nisu prikazane.			
Procjena izlaza na skupu za testiranje				
T				
A	<i>Napomena:</i> Zbog veličine, matrice (<i>T</i>) i (<i>A</i>) nisu prikazane.			
Indeksi uspješnosti				
	Skup za učenje		Skup za testiranje	
R	0.8841	R	0.7107	
SSE	35.3333	SSE	48.8228	
MSE	1.4722	MSE	4.0686	
RMSE	1.2134	RMSE	2.0171	
NRMSE	0.4574	NRMSE	0.7186	

Tablica 4.50. Parametri, struktura i rezultati FIS-a za procjenu žilavosti alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr, W, V, Mo)

Naziv FIS-a: ZIAlatni.fis				Tip FIS-a: SUGENO	
Operatori		Fun. pripadnosti		Struktura	
AND	min	varijabla	naziv		
OR	-	Cr	gaussmf		
Implikacija	prod	W	gaussmf		
Agregacija	max	V	gaussmf		
Defazifikacija	wtaver	Mo	gaussmf		
ANFIS parametri			ZI	linear	
ss (lr)	0.01				
ssinc	1.1				
ssdec	0.9				
Doz. pogreška	0				
Broj epoha	10				
Metoda učenja	BP + LSQ				
Fcm clustering	Br. ul. mf: 3 3 3 3				
Pravila					
1. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf1) then (PO is out1mf1) 2. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf2) then (PO is out1mf2) 3. If (Cr is in1mf1) and (V is in2mf1) and (W is in3mf1) and (Mo is in4mf3) then (PO is out1mf3) ... 256. If (Cr is in1mf4) and (V is in2mf4) and (W is in3mf4) and (Mo is in4mf4) then (ZI is out1mf256)					
<i>Napomena:</i> Zbog velikog broja, prikazan je dio pravila zaključivanja.					
Dijagrami zaključivanja					
<i>Napomena:</i> Zbog velikog broja pravila, prikazan je dio dijagrama zaključivanja.					
Funkcije pripadnosti ulazno-izlaznih varijabli					

Nastavak: Tablica 4.50. Parametri, struktura i rezultati *FIS*-a za procjenu žilavosti alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo)

Naziv FIS-a: ZIAlatni.fis		Tip FIS-a: SUGENO		
Odzivne površine				
				
Procjena izlaza na skupu za učenje				
T				
A	<i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i>			
Procjena izlaza na skupu za testiranje				
T				
A	<i>Napomena: Zbog veličine, matrice (T) i (A) nisu prikazane.</i>			
Indeksi uspješnosti				
	Skup za učenje		Skup za testiranje	
R	0.8828	R	0.4715	
SSE	29.3333	SSE	165.9933	
MSE	1.2222	MSE	13.8328	
RMSE	1.1055	RMSE	3.7192	
NRMSE	0.4598	NRMSE	2.0302	

4.6. Definicije ulazno-izlaznih skupova asocijativnih neuronskih mreža

4.6.1. Procjene vremenskom asocijativnom matricom

Asocijativnu memoriju (mrežu), mehanizam zaključivanja *ES*-a poziva za one varijable koje u sustavu nisu dobile vrijednost u tijeku konverzacije. U takvim slučajevima, mehanizam zaključivanja aktivira *stimulacijski vektor*, koji svojim djelovanjem na vremensku asocijativnu memoriju proizvede *vremenski asocijativni vektor*. Vremenski asocijativni vektor zapravo predstavlja 'sjećanje' ili 'iskustvenu spoznaju' o vrijednostima varijabli čije vrijednosti trenutno nisu poznate. Mehanizam za učenje, omogućava obnavljanje asocijativnih memorija i to svaki put nakon što korisnik prihvati rješenje koje donosi mehanizam za zaključivanje. Rezultat asocijativne memorija je bolji ili lošiji, što zavisi od iskustva ili neiskustva korisnika koji potvrđuje rješenje mehanizma zaključivanja. To znači da je moguća i takva prilagodba asocijativnih memorija unutar *ES*-a, tako da mehanizam zaključivanja daje potpuno pogrešno rješenje. Zbog toga je poželjno da se učenje *ES*-a određeno vrijeme prepusti stručnjaku/stručnjacima iz područja problema. Postojećim asocijativnim memorijama moguće je donijeti procjene o:

- elementima sustava,
- agresivnosti okoliša,
- agresivnoj otopini
- koncentraciji agresivne otopine,
- radne temperature,
- mehaničkih svojstava,
 - R_m
 - R_e
 - A_5
 - HV
 - otpornosti trošenju
 - otpornosti popuštanju
 - žilavosti
- masi funkcionalnog dijela.

Na temelju razmatranja u točki 4.2.2 i rezultata prema tablici 4.5, za sve slučajeve procjena primjenjen je *HEBBSU* algoritam učenja sa sljedećim parametrima:

- ulazna matrica.....početna i vremenska asocijativna matrica
- izlazna matrica.....početna i vremenska asocijativna matrica
- broj slojeva.....1
- prijenosna funkcija.....'hardlims'
- koeficijent brzine učenja.....0,5
- koeficijent brzine zaboravljanja.....0,05
- princip mapiranja.....1-od-C

Zbog toga što vremenske asocijativne matrice nisu konstantne veličine, već se tijekom vremena mijenjaju te podvrgavaju se novim ciklusima učenja, nisu prikazane matrice težina i *bias* vektori kao što je to bio slučaj kod neuronskih mreža iz prethodnog poglavlja.

Kao što se vidi u tablicama u nastavku, svaku procjenu karakteriziraju: vrijednosti varijable procjene svrstane u razrede, stimulacijski vektor, početna asocijativna matrica, vremenska asocijativna matrica i vremenski asocijativni vektor. Vrijednosti elemenata početne asocijativne matrice postavljene su tako da čine kombinacije svih razreda mogućih vrijednosti varijable čiji se iznos procjenjuje, osim kod procjene elemenata sustava gdje su vrijednosti iskustvene. Zbog pretpostavke da će se vremenom *ES* prilagoditi u rješavanju samo određenih vrsta problema trošenja, namjerno su vrijednosti elemenata vremenske asocijativne matrice postavljene tako da stimulacijski vektor proizvede 'iskustveni' ili 'uobičajeni u praksi' vremenski asocijativni vektor. Iako će se tijekom vremena za neku od procjena vremenska asocijativna matrica povećavati, vremenski asocijativni vektor inicijalizirati će onaj razred vrijednosti varijable procjene, koji je najčešće bio potvrđivan unutar predloženog rješenja od strane mehanizma zaključivanja.

4.6.2. Procjena elemenata tribosustava vremenskom asocijativnom matricom

U tablici 4.51 prikazan je primjer dobivanja asocijativnog vektora za procjenu elemenata tribosustava na temelju početne i dijelom vremenske asocijativne matrice. Vrijednosti elemenata početne asocijativne matrice su iz tablice P1.3 u prilogu I, dok su vrijednosti elemenata vremenske asocijativne matrice dobivene, konverzacijom *ES-korisnik* u određenom vremenskom razdoblju.

Tablica 4.51. Primjer dobivanja vremenskog asocijativnog vektora za procjenu elemenata sustava sa zadanom početnom i vremenskom asocijativnom matricom

		Elementi sustava									
		f1	f2	č	p	t	F	v	ω	o	α
Stimulacijski vektor		1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Početna asocijativna matrica	Broj prihvaćenih rješenja										
	1	1	1	-1	-1	1	1	-1	1	-1	-1
	2	1	1	-1	-1	-1	1	1	-1	-1	-1
	3	1	1	-1	-1	-1	1	-1	1	-1	-1
	4	1	1	-1	-1	-1	1	-1	1	1	-1
	5	1	1	-1	-1	-1	1	-1	-1	-1	-1
	6	1	-1	1	-1	-1	1	-1	-1	-1	-1
	7	1	-1	1	-1	-1	1	1	-1	-1	-1
	8	1	1	1	-1	-1	1	1	-1	-1	-1
	9	1	1	1	-1	-1	1	1	-1	-1	-1
	10	1	1	1	-1	-1	1	-1	-1	-1	-1
	11	1	-1	1	-1	1	-1	1	-1	-1	1
	12	1	-1	1	-1	1	-1	1	-1	-1	-1
	13	1	-1	1	1	-1	-1	1	-1	-1	1
	14	1	-1	-1	-1	1	-1	1	-1	-1	-1
	15	1	-1	-1	1	-1	-1	1	-1	-1	1
	16	1	-1	-1	-1	1	-1	1	-1	-1	1
Vremenska asocijativna matrica	17	1	-1	-1	1	-1	-1	1	-1	-1	-1
	18	1	1	1	-1	-1	1	1	-1	-1	-1
	19	1	1	1	-1	-1	1	1	-1	-1	-1
	20	1	1	1	-1	-1	1	1	-1	-1	-1
	21	1	1	1	-1	-1	1	1	-1	-1	-1
	22	1	1	1	-1	-1	1	1	-1	-1	-1
	23	1	1	1	-1	-1	1	1	-1	-1	-1
	24	1	1	1	-1	-1	1	1	-1	-1	-1
	25	1	1	1	-1	-1	1	1	-1	-1	-1
	26	1	1	1	-1	-1	1	1	-1	-1	-1
	27	1	1	1	-1	-1	1	1	-1	-1	-1
	28	1	1	1	-1	-1	1	1	-1	-1	-1
	29	1	1	1	-1	-1	1	1	-1	-1	-1
	30	1	1	1	-1	-1	1	1	-1	-1	-1
	31	1	1	1	-1	-1	1	1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		1	1	1	-1	-1	1	1	-1	-1	-1

Kao što se vidi iz tablice 4.51, stimulacijski vektor $[1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$ pomoću početne i dijelom vremenske asocijativne matrice daje vremenski asocijativni vektor $[1 \ 1 \ 1 \ -1 \ -1 \ 1 \ 1 \ -1 \ -1 \ -1]$. Vrijednost prvog elementa stimulacijskog vektora je +1, što proizlazi iz činjenice da sustav početno mora imati barem jedan funkcionalni dio. Ova činjenica također je ugrađena u mehanizam logike davanja odgovora *ES-a*.

U tablici 4.52 prikazan je primjer dobivanja vremenskog asocijativnog vektora bez početne asocijativne matrice, a vremenska se asocijativna matrica sastoji od tri različita vektora: $v_1=[1 \ 1 \ 1 \ -1 \ -1 \ 1 \ 1 \ -1 \ -1 \ -1]$; $v_2=[1 \ 1 \ -1 \ -1 \ 1 \ 1 \ -1 \ 1 \ -1 \ -1]$; $v_3=[1 \ -1 \ -1 \ 1 \ -1 \ -1 \ 1 \ -1 \ -1 \ -1]$. Za očekivati je da će zbog učestalosti pojavljivanja vektora v_1 , stimulacijski vektor $[1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$, dati vremenski asocijativni vektor $v_1=[1 \ 1 \ 1 \ -1 \ -1 \ 1 \ 1 \ -1 \ -1 \ -1]$.

Tablica 4.52. Primjer dobivanja vremenskog asocijativnog vektora za procjenu elemenata sustava bez početne asocijativne matrice

		Elementi sustava									
		f1	f2	č	p	t	F	v	ω	o	α
Stimulacijski vektor		1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenska asocijativna matrica	Broj prihvaćenih rješenja										
	1	1	1	1	-1	-1	1	1	-1	-1	-1
	2	1	1	1	-1	-1	1	1	-1	-1	-1
	3	1	1	1	-1	-1	1	1	-1	-1	-1
	4	1	1	-1	-1	1	1	-1	1	-1	-1
	5	1	1	1	-1	-1	1	1	-1	-1	-1
	6	1	1	1	-1	-1	1	1	-1	-1	-1
	7	1	1	1	-1	-1	1	1	-1	-1	-1
	8	1	1	-1	-1	1	1	-1	1	-1	-1
	9	1	1	1	-1	-1	1	1	-1	-1	-1
	10	1	1	-1	-1	1	1	-1	1	-1	-1
	11	1	1	1	-1	-1	1	1	-1	-1	-1
	12	1	1	1	-1	-1	1	1	-1	-1	-1
	13	1	1	1	-1	-1	1	1	-1	-1	-1
	14	1	-1	-1	1	-1	-1	1	-1	-1	-1
	15	1	1	1	-1	-1	1	1	-1	-1	-1
	16	1	-1	-1	1	-1	-1	1	-1	-1	-1
	17	1	1	1	-1	-1	1	1	-1	-1	-1
	18	1	1	1	-1	-1	1	1	-1	-1	-1
	19	1	1	1	-1	-1	1	1	-1	-1	-1
	20	1	1	-1	-1	1	1	-1	1	-1	-1
	21	1	1	1	-1	-1	1	1	-1	-1	-1
22	1	1	1	-1	-1	1	1	-1	-1	-1	
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		1	1	1	-1	-1	1	1	-1	-1	-1



4.6.3. Procjena agresivnosti otopine vremenskom asocijativnom matricom

U konverzaciji *ES-korisnik*, varijabla 'agresivnost otopine' poprima sljedeće simboličke vrijednosti: *slaba*, *srednja*, *velika*, *jako velika*. Zbog toga što spomenuta varijabla poprima simboličke iznose koje algoritmi neuronskih mreža ne mogu obrađivati, primjenjen je princip *1-of-C* (engl. *1-of-C coding*) mapiranja. Simboličke vrijednosti mapirane su kako slijedi:

slaba.....[**1** -1 -1 -1]
srednja.....[-1 **1** -1 -1]
velika.....[-1 -1 **1** -1]
jako velika..... [-1 -1 -1 **1**]

Kao što se vidi u tablici 4.53 početnu asocijativnu matricu čine moguće vrijednosti varijable *agresivnost otopine*, dok vremensku asocijativnu matricu čine vektori: $v_1 = [-1 \ -1 \ 1 \ -1]$; $v_2 = [-1 \ 1 \ -1 \ -1]$. S obzirom da vektor v_2 , nadjačava ostale vektore, tada sasvim očekivano stimulacijski vektor $[-1 \ -1 \ -1 \ -1]$ daje vremenski asocijativni vektor $[-1 \ 1 \ -1 \ -1]$ tj. v_2 .

Tablica 4.53. Primjer dobivanja vremenskog asocijativnog vektora za procjenu agresivnosti otopine

		Agresivnost otopine			
		slaba	srednja	velika	jako velika
Stimulacijski vektor		-1	-1	-1	-1
Ulaz u asocijativnu mrežu 		↓	↓	↓	↓
	Broj prihvaćenih rješenja				
Početna asocijativna matrica	1	1	-1	-1	-1
	2	-1	1	-1	-1
	3	-1	-1	1	-1
	4	-1	-1	-1	1
Vremenska asocijativna matrica	5	-1	-1	1	-1
	6	-1	1	-1	-1
	7	-1	1	-1	-1
	8	-1	1	-1	-1
	9	-1	1	-1	-1
	10	-1	1	-1	-1
	11	-1	1	-1	-1
	12	-1	1	-1	-1
	13	-1	1	-1	-1
	14	-1	1	-1	-1
	15	-1	-1	1	-1
	16	-1	-1	1	-1
Izlaz iz asocijativne mreže 		↓	↓	↓	↓
Vremenski asocijativni vektor		-1	1	-1	-1

4.6.4. Procjena koncentracije agresivne otopine vremenskom asocijativnom matricom

Kao što se vidi iz tablice 4.54 koncentracije agresivne otopine podijeljene su u deset intervala. Također je primjenjen princip *1-of-C* (engl. *1-of-C coding*) mapiranja. U početnu asocijativnu matricu uključene su vrijednosti koncentracija iz svih intervala, dok je vremenska asocijativna matrica namjerno popunjena vrijednostima elemenata tako da stimulacijski vektor $[-1 \ 1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$ daje vremenski asocijativni vektor $[-1 \ 1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$, odnosno koncentracije agresivne otopine između 11 i 20%.

Tablica 4.54. Primjer dobivanja vremenskog asocijativnog vektora za procjenu koncentracije agresivne otopine

		Koncentracija agresivne otopine u %									
		0	11	21	31	41	51	61	71	81	91
		10	20	30	40	50	60	70	80	90	100
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
	Broj prihvaćenih rješenja										
Početna asocijativna matrica	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	1	-1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	1	-1
	10	-1	-1	-1	-1	-1	-1	-1	-1	-1	1
Vremenska asocijativna matrica	11	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	12	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	13	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	14	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	15	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	16	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	17	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	18	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		-1	1	-1	-1	-1	-1	-1	-1	-1	-1

4.6.5. Procjena radne temperature vremenskom asocijativnom matricom

Na istovjetan način kao i kod procjene koncentracije agresivne otopine, radne temperature koje se mogu pojaviti unutar sustava, svrstane su u petnaest intervala uz primjenu *1-od-C* (engl. *1-of-C coding*) principa mapiranja. Vrijednosti za radnu temperaturu koje korisnik može unijeti su u granicama od 0 do 1500 °C. U početnu asocijativnu matricu uključene su vrijednosti temperatura iz svih petnaest intervala, dok su u vremensku asocijativnu matricu namjerno uključene vrijednosti elemenata tako da stimulacijski vektor [-1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1] daje vremenski asocijativni vektor [-1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1], tj. procjenu radne temperature unutar intervala 301 do 400 °C.

Tablica 4.55. Primjer dobivanja vremenskog asocijativnog vektora za procjenu radne temperature

		Radna temperatura u °C														
		0	101	201	301	401	501	601	701	801	901	1001	1101	1201	1301	1401
		100	200	300	400	500	600	700	800	900	1000	1100	1200	1300	1400	1500
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Početna asocijativna matrica	Broj prihvaćenih rješenja															
	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
	10	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
	11	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
	12	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
	13	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1
	14	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1
15	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	
Vremenska asocijativna matrica	16	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	17	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	18	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	19	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	20	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	21	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	22	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	23	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	24	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	25	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	26	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	27	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1

4.6.6. Procjena mehaničkih svojstava vremenskom asocijativnom matricom

Pomoću početne i asocijativne matrice procjenjuju se sljedeća mehanička svojstva:

- Rm* -vlačna čvrstoća u N/mm²
- Re* -granice razvlačenja u N/mm²
- A₅* -istezljivost (kratke epruvete) u %
- HV* -tvrdoća po Vickers-u
- TR* -otpornost trošenju (relativne ocjene: 1-9)
- PO* -otpornost popuštanju (relativne ocjene: 1-9)
- ZI* -žilavost (relativne ocjene: 1-9)

Kod svih procjena mehaničkih svojstava primjenjen je *I-od-C* (engl. *I-of-C coding*) princip mapiranja. Vrijednosti za *Rm* i *Re* koje korisnik može unijeti, su u granicama od 0 do 1300 N/mm², a iste se svrstavaju unutar trinaest intervala kao što se vidi iz tablice 4.56. Vrijednosti elemenata vremenske asocijativne matrice namjerno su postavljene tako da stimulacijski vektor [-1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1] daje vremenski asocijativni vektor [-1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1], tj. procjene *Rm* i *Re* unutar intervala 301 do 400 N/mm².

Tablica 4.56. Primjer dobivanja vremenskog asocijativnog vektora za procjenu R_m i R_e

		R_m i R_e u N/mm^2												
		0	101	201	301	401	501	601	701	801	901	1001	1101	1201
		100	200	300	400	500	600	700	800	900	1000	1100	1200	1300
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
	Broj prihvaćenih rješenja													
Početna asocijativna matrica	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
	10	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
	11	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1
	12	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1
	13	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1
Vremenska asocijativna matrica	14	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	15	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	16	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	17	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	18	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	19	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	20	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	21	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	22	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	23	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1

Vrijednosti za A_5 koje korisnik može unijeti, su u granicama od 0 do 30 %, a svrstane su unutar šest intervala kao što se vidi iz tablice 4.57. Vrijednosti elemenata vremenske asocijativne matrice namjerno su postavljene tako da stimulacijski vektor $[-1 \ -1 \ -1 \ -1 \ -1 \ -1]$ daje vremenski asocijativni vektor $[-1 \ -1 \ 1 \ -1 \ -1 \ -1]$, tj. procjene A_5 unutar intervala 11 do 15 %.

Tablica 4.57. Primjer dobivanja vremenskog asocijativnog vektora za procjenu A_5

		A_5 u %					
		0	6	11	16	21	26
		5	10	15	20	25	30
Stimulacijski vektor		-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓
	Broj prihvaćenih rješenja						
Početna asocijativna matrica	1	1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1
	5	-1	-1	-1	-1	1	-1
	6	-1	-1	-1	-1	-1	1
Vremenska asocijativna matrica	7	-1	-1	1	-1	-1	-1
	8	-1	-1	1	-1	-1	-1
	9	-1	-1	1	-1	-1	-1
	10	-1	-1	1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		-1	-1	1	-1	-1	-1

Vrijednosti za HV koje korisnik može unijeti, su u granicama od 0 do 900, a svrstane su unutar devet intervala kao što se vidi iz tablice 4.58. Vrijednosti elemenata vremenske asocijativne matrice namjerno su postavljene tako da stimulacijski vektor $[-1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$ daje vremenski asocijativni vektor $[-1 \ -1 \ -1 \ 1 \ -1 \ -1 \ -1 \ -1 \ -1]$, tj. procjene HV unutar intervala 301 do 400.

Tablica 4.58. Primjer dobivanja vremenskog asocijativnog vektora za procjenu HV

		HV								
		0	101	201	301	401	501	601	701	801
		100	200	300	400	500	600	700	800	900
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓
Početna asocijativna matrica	Broj prihvaćenih rješenja									
	1	1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	1	-1
9	-1	-1	-1	-1	-1	-1	-1	-1	1	
Vremenska asocijativna matrica	10	-1	-1	-1	1	-1	-1	-1	-1	-1
	11	-1	-1	-1	1	-1	-1	-1	-1	-1
	12	-1	-1	-1	1	-1	-1	-1	-1	-1
	13	-1	-1	-1	1	-1	-1	-1	-1	-1
	14	-1	-1	-1	1	-1	-1	-1	-1	-1
	15	-1	-1	-1	1	-1	-1	-1	-1	-1
	16	-1	-1	-1	1	-1	-1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	
Vremenski asocijativni vektor		-1	-1	-1	1	-1	-1	-1	-1	-1

Vrijednosti za procjenu otpornosti trošenju TR koje korisnik može unijeti, su relativne ocjene od 1 do 9, kao što se vidi iz tablice 4.59. Vrijednosti elemenata vremenske asocijativne matrice namjerno su postavljene tako da stimulacijski vektor $[-1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$ daje vremenski asocijativni vektor $[-1 \ -1 \ -1 \ 1 \ -1 \ -1 \ -1 \ -1 \ -1]$, tj. procjenu otpornosti trošenju $TR=4$. Da bi usporedba materijala s obzirom na otpornost trošenju bila moguća, format vrijednosti za procjenu otpornosti trošenju TR koju daje vremenski asocijativni vektor, mora biti u skladu sa vrijednošću koje daje FIS na temelju kemijskog sastava, i to prema sljedećim pravilima:

1. Slučaj alatnih čelika:

- varijabla TR poprima vrijednost pozicije ili lokacije na kojoj se nalazi pozitivna vrijednost unutar vremenskog asocijativnog vektora. Tako je prema tablici 4.59 $TR=4$.

2. Slučaj čelika iz ostalih grupa:

- ako je pozitivni iznos vremenskog asocijativnog vektora unutar intervala $[1...3]$ tada je $TR=1$,
- ako je pozitivni iznos vremenskog asocijativnog vektora unutar intervala $[4...6]$ tada je $TR=2$,
- ako je pozitivni iznos vremenskog asocijativnog vektora unutar intervala $[7...9]$ tada je $TR=3$.

Tablica 4.59. Primjer dobivanja vremenskog asocijativnog vektora za procjenu TR

		Ocjena otpornosti trošenju (TR)								
		NISKA			SREDNJA			VISOKA		
		1	2	3	4	5	6	7	8	9
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓
	Broj prihvaćenih rješenja									
Početna asocijativna matrica	1	1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	1
Vremenska asocijativna matrica	10	-1	-1	-1	1	-1	-1	-1	-1	-1
	11	-1	-1	-1	1	-1	-1	-1	-1	-1
	12	-1	-1	-1	1	-1	-1	-1	-1	-1
	13	-1	-1	-1	1	-1	-1	-1	-1	-1
	14	-1	-1	-1	1	-1	-1	-1	-1	-1
	15	-1	-1	-1	1	-1	-1	-1	-1	-1
	16	-1	-1	-1	1	-1	-1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		-1	-1	-1	1	-1	-1	-1	-1	-1

Vrijednosti za procjenu otpornosti popuštanju PO koje korisnik može unijeti, su relativne ocjene od 1 do 9, kao što se vidi iz tablice 4.60. Vrijednosti elemenata vremenske asocijativne matrice namjerno su postavljene tako da stimulacijski vektor $[-1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$ daje vremenski asocijativni vektor $[-1 \ -1 \ -1 \ 1 \ -1 \ -1 \ -1 \ -1 \ -1]$, tj. procjenu otpornosti popuštanju $PO=4$.

Kao što se vidi iz tablice 4.61, analogno procjeni otpornosti popuštanju PO , vrijedi i za procjenu žilavosti ZI . Korisnik može unijeti relativne ocjene od 1 do 9, a stimulacijski vektor $[-1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$ na temelju vremenske asocijativne matrice daje vremenski asocijativni vektor $[-1 \ -1 \ -1 \ 1 \ -1 \ -1 \ -1 \ -1 \ -1]$, tj. procjenu žilavosti $ZI=4$.

Tablica 4.60. Primjer dobivanja vremenskog asocijativnog vektora za procjenu popuštanja *PO*

		Ocjena popuštanju (PO)								
		NISKA			SREDNJA			VISOKA		
		1	2	3	4	5	6	7	8	9
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓
	Broj prihvaćenih rješenja									
Početna asocijativna matrica	1	1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	1
Vremenska asocijativna matrica	10	-1	-1	-1	1	-1	-1	-1	-1	-1
	11	-1	-1	-1	1	-1	-1	-1	-1	-1
	12	-1	-1	-1	1	-1	-1	-1	-1	-1
	13	-1	-1	-1	1	-1	-1	-1	-1	-1
	14	-1	-1	-1	1	-1	-1	-1	-1	-1
	15	-1	-1	-1	1	-1	-1	-1	-1	-1
	16	-1	-1	-1	1	-1	-1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		-1	-1	-1	1	-1	-1	-1	-1	-1

Tablica 4.61. Primjer dobivanja vremenskog asocijativnog vektora za procjenu žilavosti *ZI*

		Ocjena žilavosti (ŽI)								
		NISKA			SREDNJA			VISOKA		
		1	2	3	4	5	6	7	8	9
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓
	Broj prihvaćenih rješenja									
Početna asocijativna matrica	1	1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	1
Vremenska asocijativna matrica	10	-1	-1	-1	1	-1	-1	-1	-1	-1
	11	-1	-1	-1	1	-1	-1	-1	-1	-1
	12	-1	-1	-1	1	-1	-1	-1	-1	-1
	13	-1	-1	-1	1	-1	-1	-1	-1	-1
	14	-1	-1	-1	1	-1	-1	-1	-1	-1
	15	-1	-1	-1	1	-1	-1	-1	-1	-1
	16	-1	-1	-1	1	-1	-1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		-1	-1	-1	1	-1	-1	-1	-1	-1

4.6.7. Procjena mase vremenskom asocijativnom matricom

S obzirom da su u bazu znanja pohranjene simboličke vrijednosti (*mala*, *srednja*, *velika*) za masu, kvantifikacija iste provedena je prema sljedećim pravilima:

male mase: 0...300 kg
 srednja mase: 301...600 kg
 velike mase: > 600 kg

Pomoću unošanih vrijednosti za dužinu (*duz*) sirinu (*sir*) i visinu (*vis*) funkcionalnog dijela približno se određuje volumen dijela V :

$$V = \text{duz} * \text{sir} * \text{vis}, \text{ m}^3 \quad (3.6)$$

Masa m približno se određuje na temelju volumena V i specifične težine čelika $\rho = 7850 \text{ kg/m}^3$:

$$m = \rho * V, \quad \text{kg} \quad (3.7)$$

Vrijednosti za m koje korisnik može unijeti, su u granicama od 0 do 1000 kg, a svrstane su unutar deset intervala kao što se vidi iz tablice 4.62. Vrijednosti elemenata vremenske asocijativne matrice namjerno su postavljene tako da stimulacijski vektor $[-1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$ daje vremenski asocijativni vektor $[-1 \ -1 \ 1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1 \ -1]$, tj. procjenu m unutar intervala 201 do 300.

Tablica 4.62. Primjer dobivanja vremenskog asocijativnog vektora za procjenu mase

		masa u kg									
		MALA			SREDNJA			VELIKA			
		0	101	201	301	401	501	601	701	801	901
		100	200	300	400	500	600	700	800	900	1000
Stimulacijski vektor		-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
Ulaz u asocijativnu mrežu		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Početna asocijativna matrica	Broj prihvaćenih rješenja										
	1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	1	-1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	1	-1
Vremenska asocijativna matrica	10	-1	-1	-1	-1	-1	-1	-1	-1	-1	1
	14	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	15	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	16	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
Vremenska asocijativna matrica	17	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	18	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
Izlaz iz asocijativne mreže		↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Vremenski asocijativni vektor		-1	-1	1	-1	-1	-1	-1	-1	-1	-1

5. PROVJERA RADA SUSTAVA

5.1. Primjer načina rada mehanizama zaključivanja

5.1.1. Primjer načina rada mehanizma za obradu konverzacije

Na slikama 5.1 i 5.2 prikaza su sva pitanja koja mehanizam za obradu konverzacije postavlja korisniku. Kao što se vidi, pitanja su svrstana unutar četiri skupine, te sustavu daju spoznanju o:

1. Elementima sustava i njihovim interakcijama;
2. Uvjetima okoline;
3. Zahtjevima na materijal;
4. Općim zahtjevima.

AI - CAMS
Analiza Slucajevi Slojevi
-> ANALIZA SUSTAVA

--> MEHANIZAM ZA OBRADU KONVERZACIJE

Da li u promatranom sustavu postoji **Funkcionalni dio -1?**
 DA NE NE ZNAM

Da li u promatranom sustavu postoji **Funkcionalni dio -2?** ①
 DA NE NE ZNAM

Da li u promatranom sustavu postoje **Cestice?**
 DA NE NE ZNAM

Da li u promatranom sustavu postoji **Plin?**
 DA NE NE ZNAM

Da li u promatranom sustavu postoji **Tekucina?**
 DA NE NE ZNAM

Da li u promatranom sustavu djeluje **Sila?**
 DA NE NE ZNAM

Da li u promatranom sustavu jedan od funkcionalnih dijelova giba odredjenom **Brzinom** u odnosu na drugi dio?
 DA NE NE ZNAM

Da li u promatranom sustavu jedan od funkcionalnih dijelova giba odredjenom **Kutnom brzinom** u odnosu na drugi dio?
 DA NE NE ZNAM

Da li u promatranom sustavu jedan od funkcionalnih dijelova **Oscilira** u odnosu na drugi dio?
 DA NE NE ZNAM

Da li u promatranom sustavu cestice **Nastrujavaju** na funkcionalni dio pod nekim kutem?
 DA NE NE ZNAM

Kako procjenjujete **Agresivnost okolisa** u promatranom sustavu?
 SLABA SREDNJA VELIKA JAKO VELIKA NE ZNAM

Koj su od nize nabrojanih **Agresivnih otopina** izloženi funkcionalni dijelovi?
 HNO3 H3PO4 CH3CO2H HCl H2SO4 NE ZNAM

Kolika je procjena masene **Koncentracije agresivne otopine** u %?

Kolika je procjena radne **Temperature** u sustavu u C?
 ②

③ ④ ⑤

ELEMENTI SUSTAVA

UVJETI OKOLINE

Start! Sto ako? Zasto? Kako? Rjesenjel Kraj!

Slika 5.1. Primjeri odgovora na pitanja pri konverzaciji sustav-korisnik

Unutar mehanizma za konverzaciju, slika 5.1, ugrađeni su sljedeći mehanizmi za objašnjavanje i analizu rada sustava:

1. Mehanizam *hiperteksta* 1
2. Mehanizam *ŠTO AKO?* 2
3. Mehanizam *ZAŠTO?* 3
4. Mehanizam *KAKO?* 4
5. Mehanizam *RJEŠENJE?* 5

MEHANIZAM ZA OBRADU KONVERZACIJE

Koliki je procjenjeni iznos **Rm**?
 ← 1

Koliki je procjenjeni iznos **Re**?

Koliki je procjenjeni iznos **A5**?

Koliki je procjenjeni iznos **HV**?
 ← 2

Koliki je procjenjeni iznos **Otpornosti trosenju**?

Koliki je procjenjeni iznos **Zilavosti**?
 ← 3

Koliki je procjenjeni iznos **Otpornosti popustanju**?

Koliki je procjenjeni iznos **Sirine dijela**?

Koliki je procjenjeni iznos **Duzine dijela**?

Koliki je procjenjeni iznos **Visine dijela**?

Koja je primjena **Funkcionalnog dijela**?
 ← 4

Kako procjenjujete **Slozenost funkcionalnog dijela**?
 MALA VELIKA NE ZNAM

ZAHTJEVI NA MATERIJAL

OPĆI ZAHTJEVI

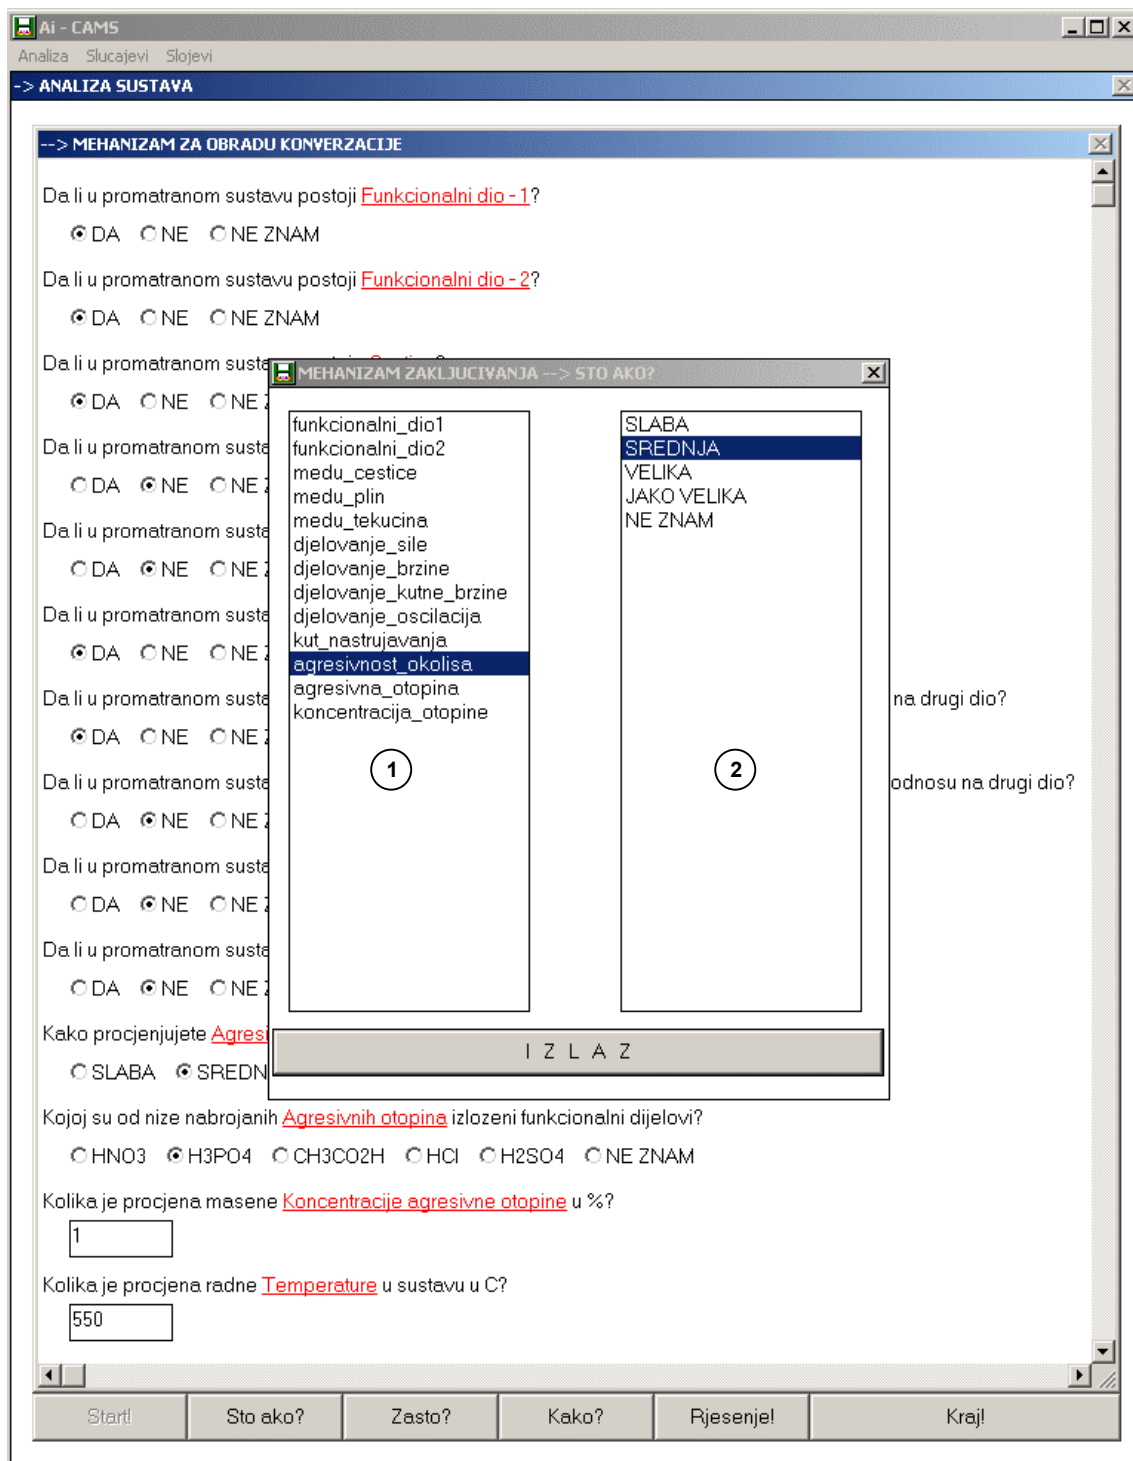
Start! Sto ako? Zasto? Kako? Rjesenjel Kraj!

Slika 5.2. Primjeri odgovora na pitanja pri konverzaciji sustav-korisnik

Na slici 5.2 prikazani su magući načini odgovora koje korisnik daje sustavu:

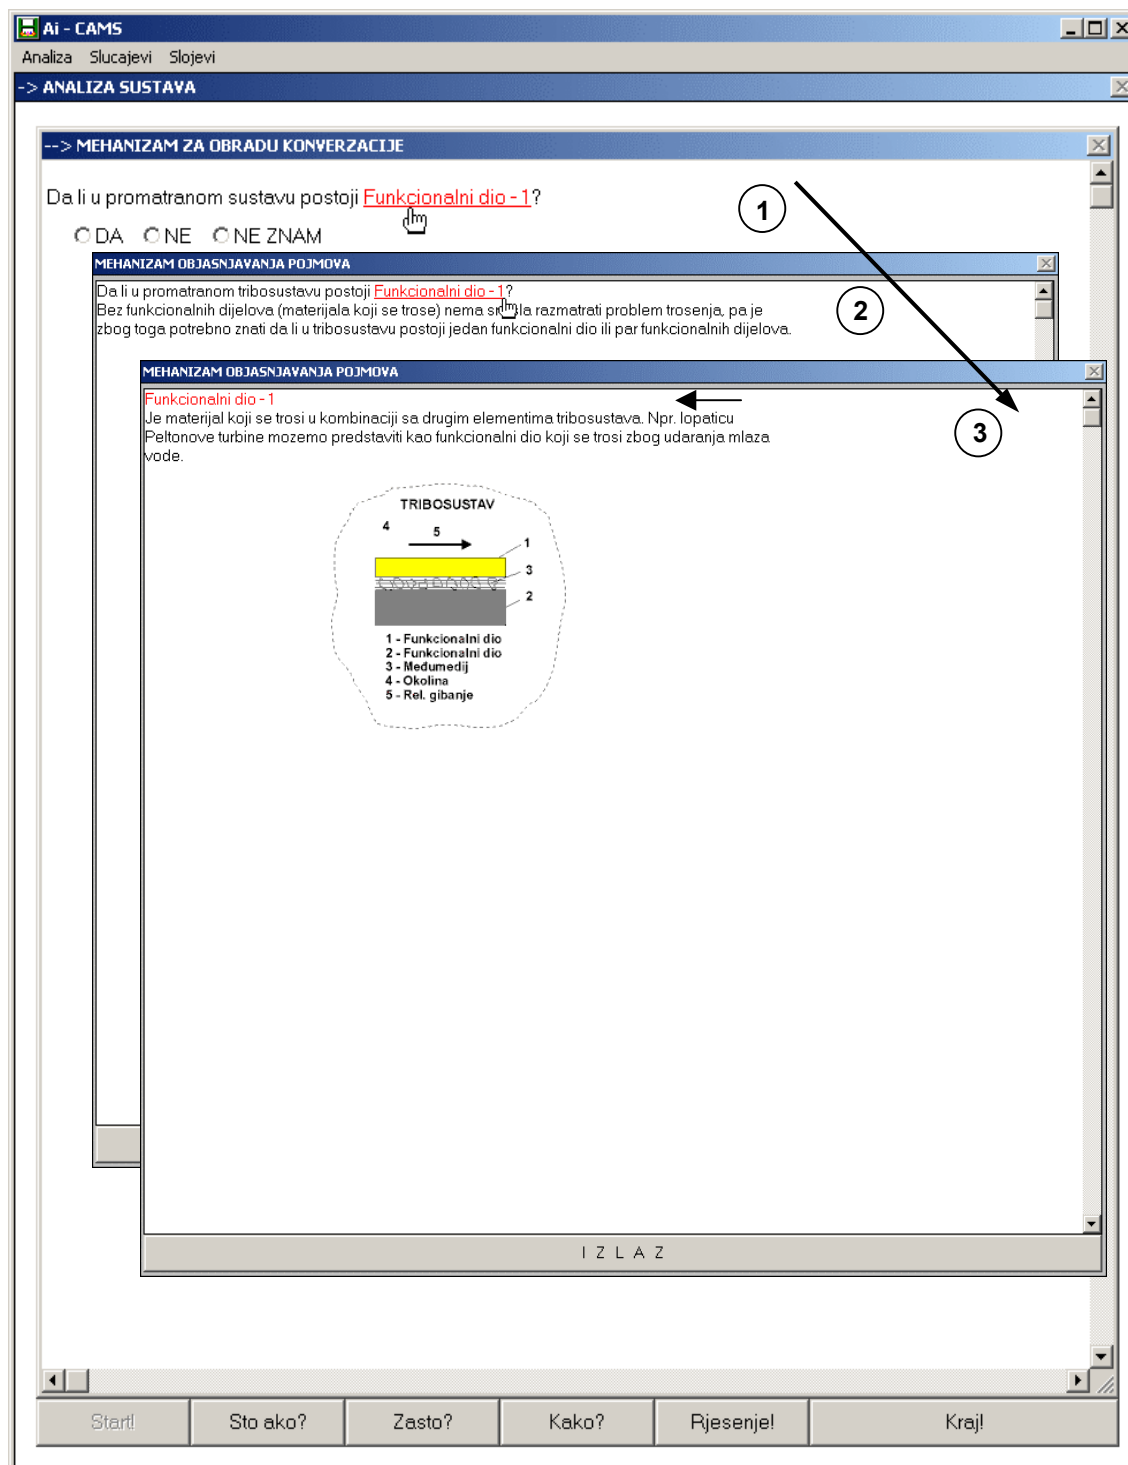
1. Eksplicitno 1
2. Nesigurno 2 i 3
3. Opisno 4

Na slici 5.3 prikazan je načina rada mehanizma *ŠTO AKO?* koji omogućava pregled pregled svih ispaljenih pravila sa pripadnim vrijednostima. Moguće je mijenjati vrijednosti ispaljenih pravila u tijeku ili na kraju sprovedene konverzacije. U takvim slučajevima, sustav ponovno analizira problem ispočetka uzimajući pri tome u obzir promjenu vrijednosti jednog ili više pravila.



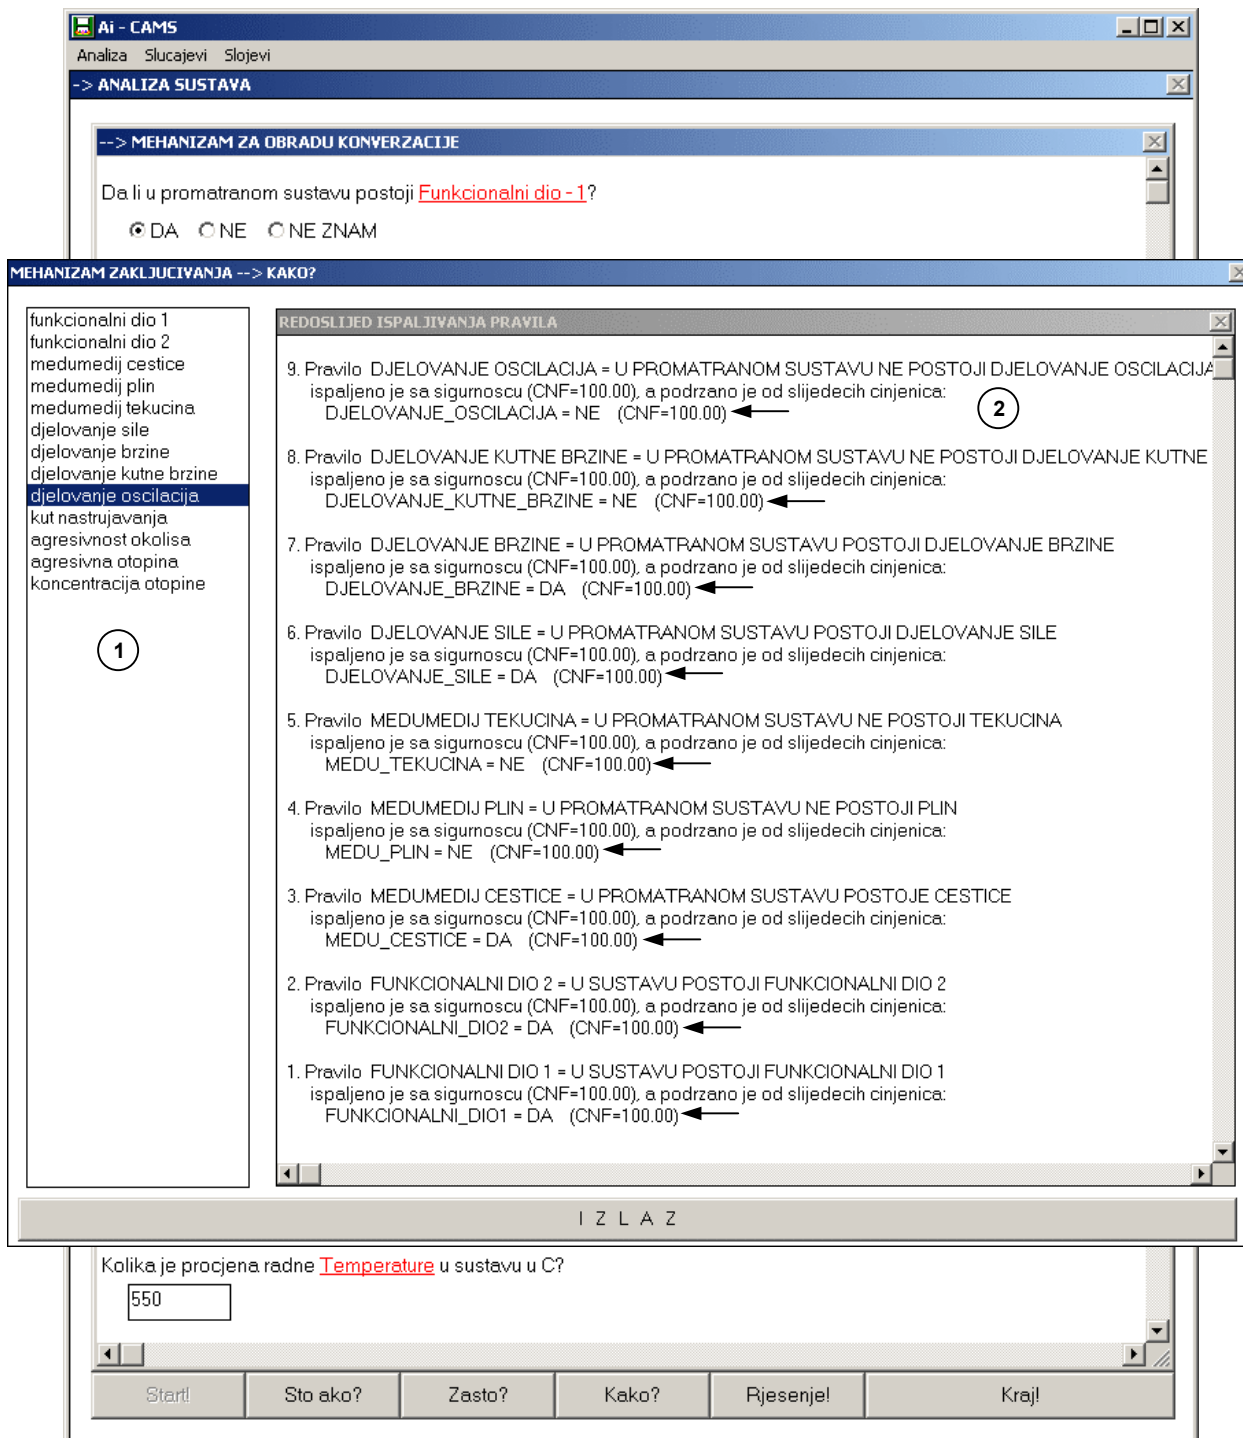
Slika 5.3. Primjer načina rada mehanizma 'ŠTO AKO?'

Kao što je već spomenuto u opisu sustava, mehanizam ZAŠTO? ima zadatak objašnjavanja pitanja koja sustav postavlja korisniku. Na slici 5.4 prikazan je primjer objašnjenja prvog pitanja (1) koje sustav postavlja korisniku. Također je prikazana primjena *hiperteksta* za objašnjavanje pojmova koji se nalaze unutar pitanja (2) i (3).



Slika 5.4. Primjer načina rada mehanizma 'ZAŠTO?'

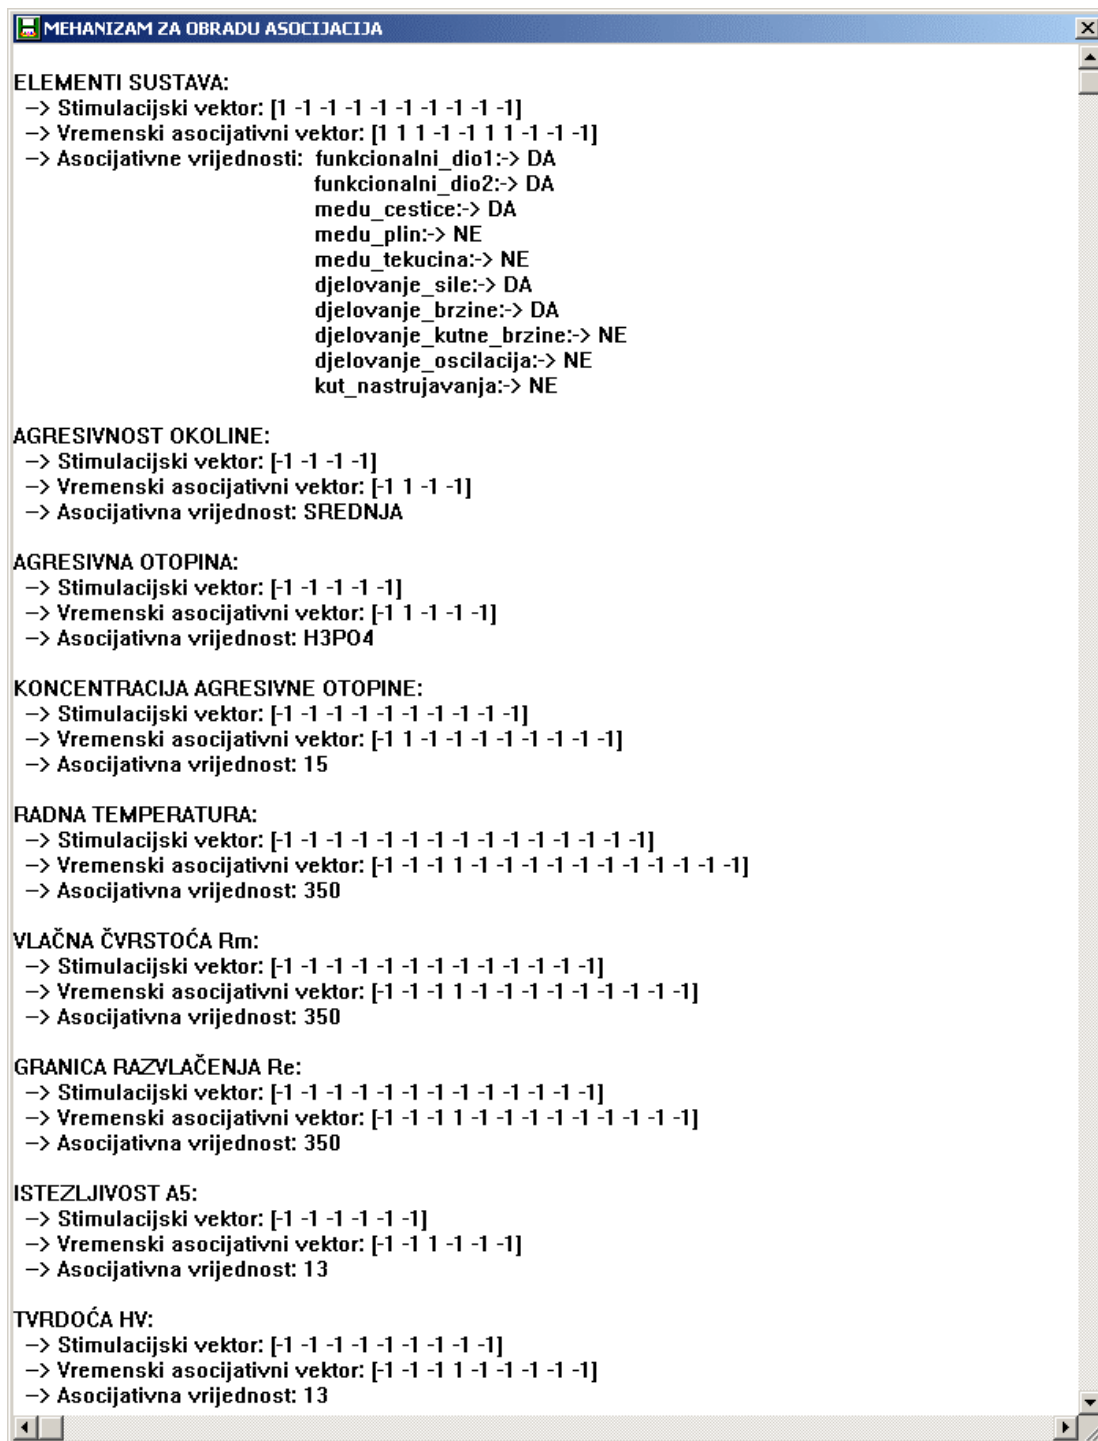
Primjer načina rada mehanizma 'KAKO?' prikazan je na slici 5.5 Zadatak je ovog mehanizma, objasniti redosljed ispaljivanja pravila. Na slici se vidi da je prije ispaljenja pravila 'djelovanje oscilacija', bilo ispaljeno osam pravila. Također su prikazani (vidi strelice!) faktori sigurnosti (CNF) ispaljenih pravila.



Slika 5.5. Primjer načina rada mehanizma 'KAKO?'

5.1.2. Primjer načina rada mehanizma za obradu asocijacija

Mehanizam za obradu asocijacija temelji se na radu algoritama asocijativnih neuronskih mreža. U radu je modelirano ukupno trinaest asocijativnih mreža, a rezultati jednog dijela prikazani su na slici 5.6. Kao što je već objašnjeno, asocijacije se inicijaliziraju na temelju *težina* unutar vremenskih asocijativnih matrica koje se formiraju tijekom određenog vremena rada sustava te ponavljanje procesa učenja. Za određivanje asocijativne vrijednosti potrebno je na ulaz naučene asocijativne mreže dovesti stimulacijski vektor čiji je izlaz vremenski asocijativni vektor. Svaki od elemenata vremenskog asocijativnog vektora, se pomoću posebno razvijenih procedura prevodi u realne simboličke ili brojčane vrijednosti. Tako npr. kod određivanja asocijativne vrijednosti elemenata sustava, '+' vrijednost elementa vremenskog asocijativnog vektora ima simboličko značenje 'DA', a '-' vrijednost značenje 'NE'.



Slika 5.6. Primjer dijela asocijativnih procjena

U nastavku je na slici 5.7 prikazan primjer programskog koda za asocijativnu procjenu elemenata sustava s naznakom tipa algoritma asocijativne neuronske mreže.

```

(**** Asocijativna procjena elemenata sustava ****)
IF HAS_VALUE(funkcionalni_dio1)=F AND HAS_VALUE(funkcionalni_dio2)=F AND HAS_VALUE(medu_cestice)=F AND
HAS_VALUE(medu_plin)=F AND HAS_VALUE(medu_tekucina)=F AND
HAS_VALUE(djelovanje_sile)=F AND HAS_VALUE(djelovanje_brzine)=F AND HAS_VALUE(djelovanje_kutne_brzine)=F AND
HAS_VALUE(djelovanje_oscilacija)=F AND HAS_VALUE(kut_nastrujavanja)=F
THEN :stimuli_dat='NNPEUL.TXT' AND
:stimuli_vektor=[1,-1,-1,-1,-1,-1,-1,-1,-1,-1] AND
:rezult_dat='NNRPE.TXT' AND
:naz_asoc_mreze='nn_pe_associative' AND
asoc_eng:kreiraj_asoc_vektor(?stimuli_dat,?stimuli_vektor,?rezult_dat,?naz_asoc_mreze).
:vav=READ(?stimuli_dat).
CLOSE(?stimuli_dat).
TEXT('ELEMENTI SUSTAVA:').
:vav=STRING_TO_LIST(?vav).
:vav=REPLACE(?vav,'1.0000','1',100).
:vav=REPLACE(?vav,'-1.0000','-1',100).
TEXT(,CONCAT(' --> Stimulacijski vektor: ',LIST_TO_STRING(?stimuli_vektor,' '),')).
TEXT(,CONCAT(' --> Vremenski asocijativni vektor: ',LIST_TO_STRING(?vav,' '),')).
nnpeul(?vav).

TOPIC nnpeul(asoc_vek).
IF ELEMENT(?asoc_vek,1)=1 THEN funkcionalni_dio1=DA ELSE funkcionalni_dio1=NE.
IF ELEMENT(?asoc_vek,2)=1 THEN funkcionalni_dio2=DA ELSE funkcionalni_dio2=NE.
IF ELEMENT(?asoc_vek,3)=1 THEN medu_cestice=DA ELSE medu_cestice=NE.
IF ELEMENT(?asoc_vek,4)=1 THEN medu_plin=DA ELSE medu_plin=NE.
IF ELEMENT(?asoc_vek,5)=1 THEN medu_tekucina=DA ELSE medu_tekucina=NE.
IF ELEMENT(?asoc_vek,6)=1 THEN djelovanje_sile=DA ELSE djelovanje_sile=NE.
IF ELEMENT(?asoc_vek,7)=1 THEN djelovanje_brzine=DA ELSE djelovanje_brzine=NE.
IF ELEMENT(?asoc_vek,8)=1 THEN djelovanje_kutne_brzine=DA ELSE djelovanje_kutne_brzine=NE.
IF ELEMENT(?asoc_vek,9)=1 THEN djelovanje_oscilacija=DA ELSE djelovanje_oscilacija=NE.
IF ELEMENT(?asoc_vek,10)=1 THEN kut_nastrujavanja=DA ELSE kut_nastrujavanja=NE.
TEXT(,CONCAT(' --> Asocijativne vrijednosti: ',funkcionalni_dio1:-> ',?funkcionalni_dio1)).
TEXT(,CONCAT(' ',funkcionalni_dio2:-> ',?funkcionalni_dio2)).
TEXT(,CONCAT(' ',medu_cestice:-> ',?medu_cestice)).
TEXT(,CONCAT(' ',medu_plin:-> ',?medu_plin)).
TEXT(,CONCAT(' ',medu_tekucina:-> ',?medu_tekucina)).
TEXT(,CONCAT(' ',djelovanje_sile:-> ',?djelovanje_sile)).
TEXT(,CONCAT(' ',djelovanje_brzine:-> ',?djelovanje_brzine)).
TEXT(,CONCAT(' ',djelovanje_kutne_brzine:-> ',?djelovanje_kutne_brzine)).
TEXT(,CONCAT(' ',djelovanje_oscilacija:-> ',?djelovanje_oscilacija)).
TEXT(,CONCAT(' ',kut_nastrujavanja:-> ',?kut_nastrujavanja)).
END.

TOPIC nn_pe_associative.
ulaz_dat='NNPEUL.TXT'.
br_kol_ulaz=10.
izlaz_dat='Z_IZLAZ.TXT'.
zeljeni_izlaz_dat=?ulaz_dat.
br_kol_izlaz=10.
br_layera=1.
br_neuro_layer1=10.
br_neuro_layer2=15.
fun_layer1='hardlims'.
fun_layer2='logsig'.
fun_layer3='purelin'.
tip_mreze=9.
rezisdat='NNRPE.TXT'.
W1_dat='PEW1.TXT'.
W2_dat='PEW2.TXT'.
W3_dat='PEW3.TXT'.
B1_dat='PEB1.TXT'.
B2_dat='PEB2.TXT'.
B3_dat='PEB3.TXT'.
minP_dat='PEminP.txt'.
maxP_dat='PEmaxP.txt'.
minT_dat='PEminT.txt'.
maxT_dat='PEmaxT.txt'.
norm_ulaz=0.
norm_izlaz=0.
chek_plot_R=0.
NNSPRPAR(?nn_radni_direktorij,?nnparam). (* Spremanje parametra mreže *)
NNISTREN(?nn_radni_direktorij,?nnparam). (* Poziv naučene mreže *)

(**** Ucitavanje rezultata neuronske mreže *)
:A=nnrezult_A(?rezisdat,'A','R').

nn_pe_associative=?A.

END.

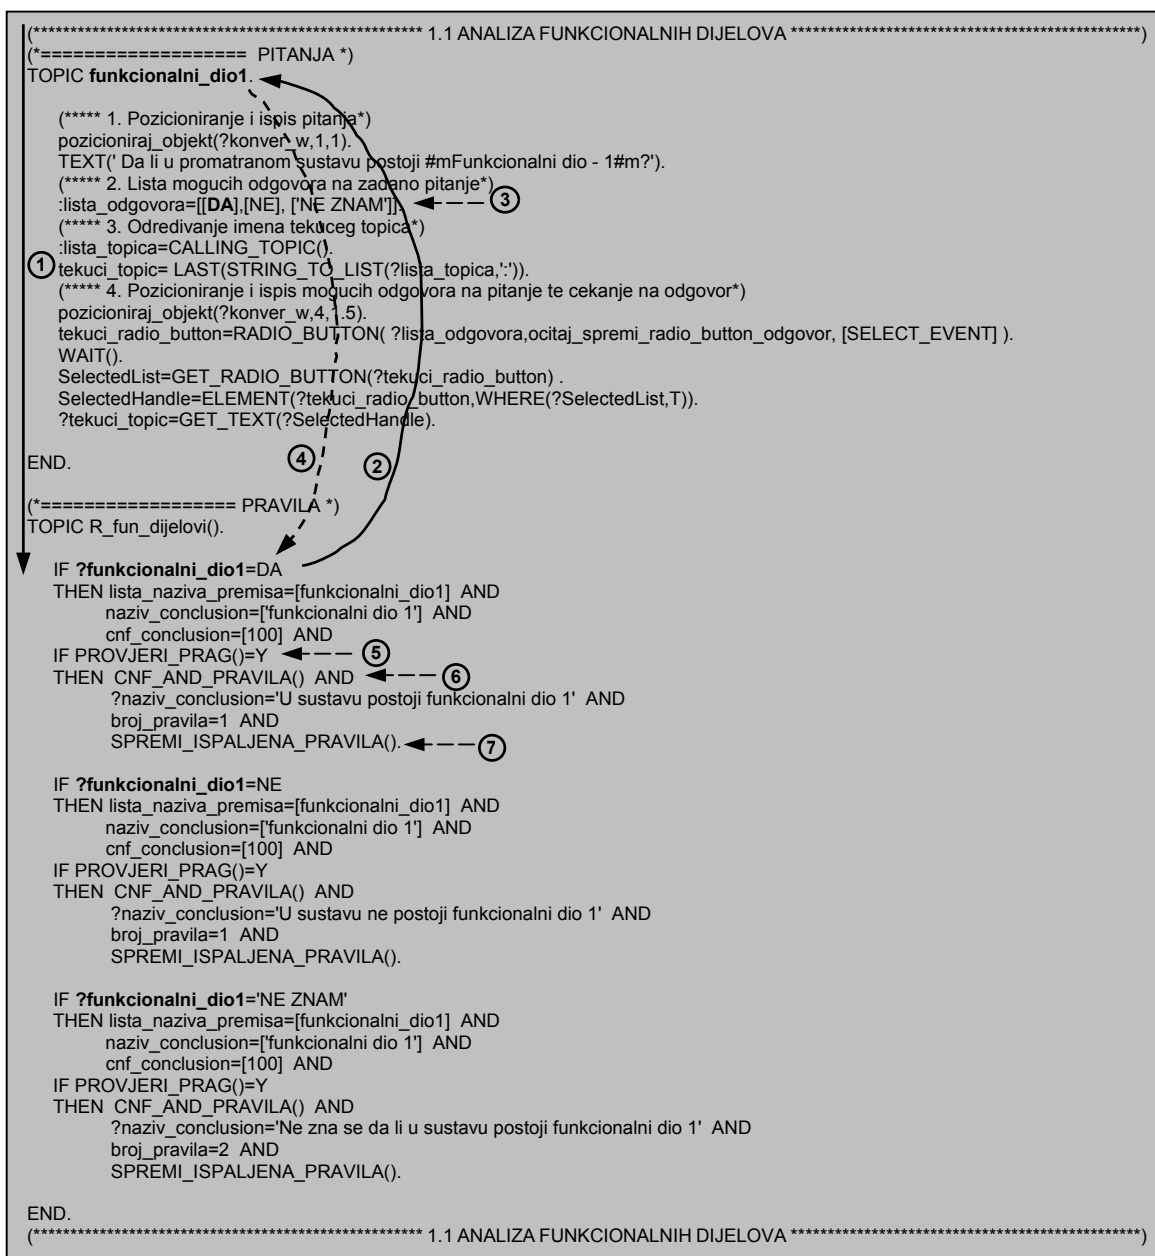
```

ASOCIJATIVNA NEURONSKA MREŽA
'NNHEBBSU'

Slika 5.7. Primjer programskog koda za asocijativnu procjenu elemenata sustava

5.1.3. Primjer načina rada mehanizma za obradu pravila

Pravila su modelirana tako da *premise* poprimaju vrijednosti ili od strane korisnika, ili su predefiniране kao činjenice (znanje) unutar baze pravila na koje korisnik nema utjecaja. Svaka premisa zapravo predstavlja jedno pravilo, koje će se ispaliti samo u slučaju kada je udovoljeno globalnom pragu sigurnosti. Redoslijed pisanja pravila unutar sustava nema utjecaja na krajnji rezultat koji sustav daje. Premise poprimaju vrijednosti primjenom metode *ulančavanja unazad* kao što je prikazano na slici 5.8. Metoda se unutar prikazanog programskog koda aktivira tako što mehanizam za konverzaciju pozove funkciju za određivanje funkcionalnih dijelova `R_fun_dijelovi()` (1). Nakon toga mehanizam za obradu pravila pokušava pronaći vrijednost premise funkcionalni_dio1. U određenoj fazi konverzacije vrijednosti te premise ne postoji, te se aktivira mehanizam *ulančavanja unazad* (2). Potraga unutar prostora pravila traje tako dugo dok se vrijednost premise ne pronađe. Ako vrijednost nije pronađena unutar baze činjenica, tada se korisniku postavlja pitanje za unose vrijednosti iste. Nakon unošenja vrijednosti, (3) mehanizam vraća kontrolu na premisu za koju traži vrijednost (4) te se njena vrijednost uspoređuje sa uvjetnom vrijednošću. Ukoliko se vrijednosti podudaraju, provjerava se globalni prag sigurnosti (5), te ukoliko i on odgovara, izračunava se faktor sigurnosti pravila (6) te se na kraju pravilo ispaljuje (7). Cijeli proces se nastavlja do kraja predviđene konverzacije ili do prekida zbog traženja rješenja od strane korisnika.



Slika 5.8. Primjer programskog koda mehanizma ulančavanja unazad

Kod baze pravila koja sadrži predefinirane činjenice primjenjena je metoda *ulančavanja unaprijed* što zapravo predstavlja klasičnu tehniku dodjeljivanja vrijednosti varijabli unutar sustava, te je nadalje nije potrebno detaljnije razmatrati. Ta je metoda primjenjena kod pravila za dodjeljivanje kriterija tj. zahtjeva na izbor materijala, a koristi je mehanizam za obradu kriterija kao što će u nastavku biti detaljnije objašnjeno.

```

TOPIC izracunaj_AND_CNF.

(**** 1. Određivanje poz i CNF-a conclusiona sa 'lista_premisa' i 'lista_cnf_premisa' *)
:poz_conclusion =WHERE(?lista_premisa,ELEMENT(?naziv_conclusion,1),32000).

(**** 2. Pocetan minimalna vrijednost *)
:premisa_sa_min_cnf=ELEMENT(?lista_naziva_premisa,1).
:poz_premise_sa_min_cnf=WHERE(?lista_premisa, ?premisa_sa_min_cnf,32000).
:iznos_min_cnf_premise=ELEMENT(?lista_cnf_premisa,?poz_premise_sa_min_cnf).

(**** 3. Određivanje premise koja ima najmanji CNF *)
:broj_premisa=LIST_LENGTH(?lista_naziva_premisa).
:i=0.
REPEAT
:i=?i+1 AND
:poz_premise_sa_min_cnf=WHERE(?lista_premisa, ELEMENT(?lista_naziva_premisa,?i),32000) AND
:stari_cnf_premise=ELEMENT(?lista_cnf_premisa,?poz_premise_sa_min_cnf) AND

IF (?stari_cnf_premise) <= (?iznos_min_cnf_premise)
THEN :premisa_sa_min_cnf= ELEMENT(?lista_naziva_premisa,?i) AND
:iznos_min_cnf_premise=?stari_cnf_premise
UNTIL ?i=?broj_premisa.

(**** 4. Izračunavanje CNF-a pravila prema formuli *)
:poz_premise_sa_min_cnf=WHERE(?lista_premisa, ?premisa_sa_min_cnf,32000).
:stari_cnf_premise=ELEMENT(?lista_cnf_premisa,?poz_premise_sa_min_cnf).
novi_cnf_pravila=((?stari_cnf_premise/100) * (?cnf_conclusion/100)) *100 ).

(**** 5. Ubacivanje nove vrijednosti CNF-a conclusiona na listu 'lista_cnf_premisa' *)
lista_cnf_premisa=REPLACE_ELEMENTS(?lista_cnf_premisa,?poz_conclusion,?novi_cnf_pravila).

END.

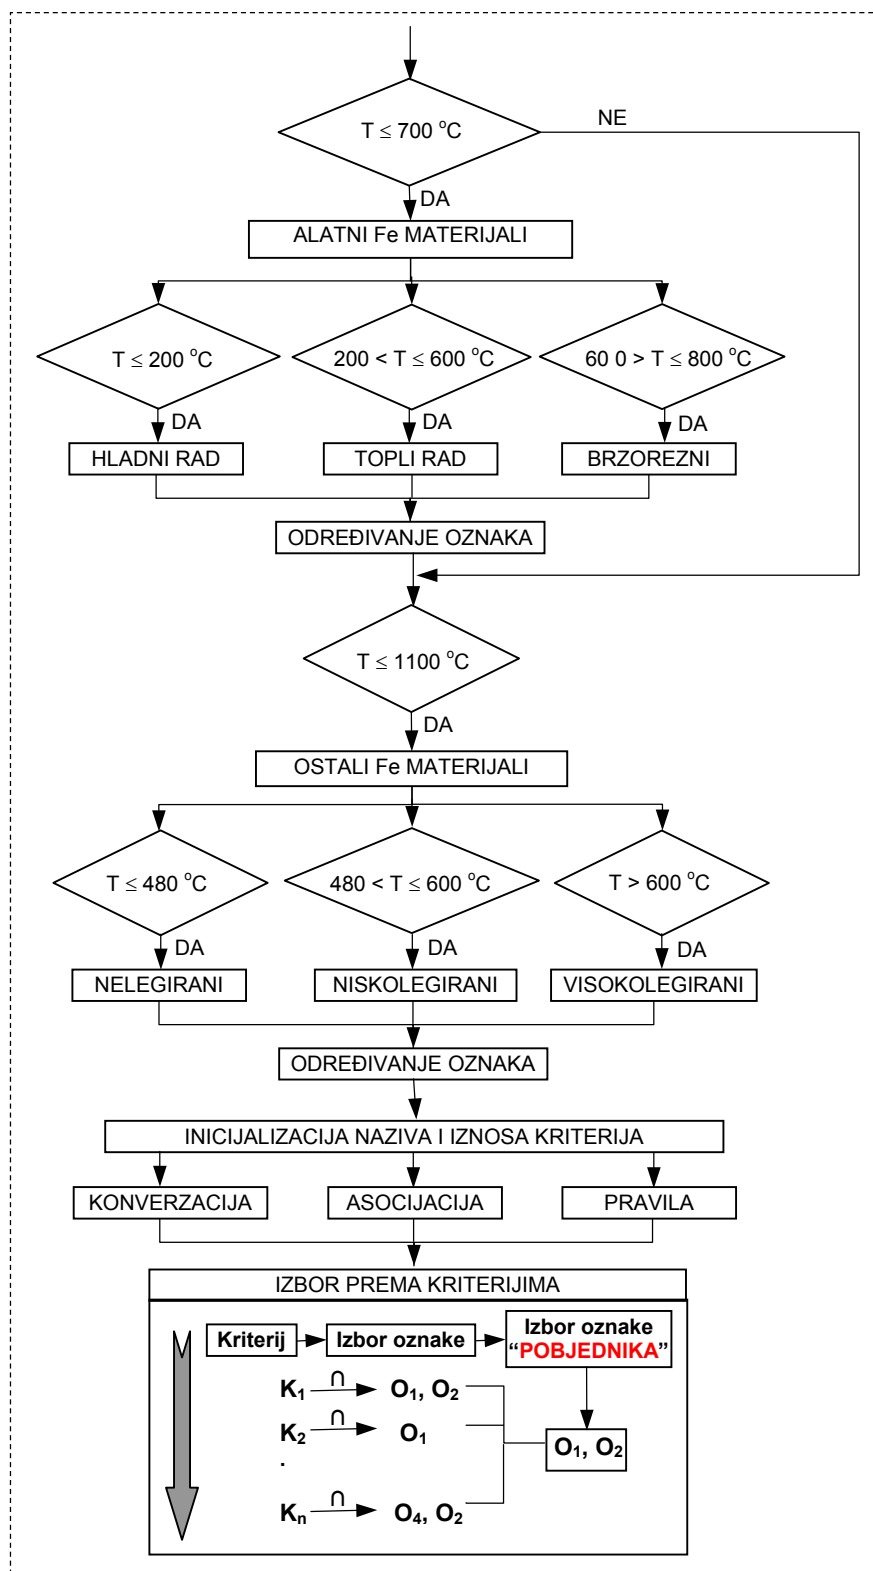
```

Slika 5.9. Prikaz programskog koda za izračunavanje *faktora sigurnosti (CNF)* pravila

Izračunavanje faktora sigurnosti unutar sustava izvedeno je prema pravilu za *AND* operator, kao što je detaljnije pojašnjeno kod opisa sustava. Programski kod za izračun prikazan je slikom 5.9. Vrijednosti faktora sigurnosti kreću se u granici od 1 do 100, dok je globalni prag sigurnosti postavljen na 50.

5.1.4. Princip rada mehanizma za obradu kriterija za izbor materijala

Princip dodjeljivanja kriterija za izbor prikladnog materijala sloja prikazan je na slici 5.10. Sa slike je vidljivo da se u prvoj fazi na temelju pravila za iznos radne temperature, određuju standardne oznake iz dviju grupa materijala: *alatni Fe materijali* i *ostali Fe materijali*. Nakon toga se u drugoj fazi, inicijaliziraju nazivi i iznosi kriterija na tri načina: konverzacijom, asocijacijama i pravilima. Treća faza predstavlja izbor prema postavljenim kriterijima. Za određene oznake iz obje grupe materijala, zasebno se razmatra svaki kriterij, te se za isti *metodom presjeka* odabiru prikladne oznake. Na kraju se metodom 'pobjednika' odredi oznaka ili oznake koje su udovoljile najvećem broju kriterija.



Slika 5.10. Princip rada mehanizma za dodjelu kriterija izbora materijala

5.1.5. Primjer načina rada mehanizma za procjenu postupaka modificiranja površina

Kao što je već rečeno u opisu sustava u 3. dijelu rada, procjena postupka modificiranja površina ovisi o radu neuronske mreže unutar mehanizma za procjenu tipa tj. mehanizma trošenja. Izlazni skup vrijednosti koji daje ta mreža, je ulazni skup u neuronske mrežu za procjenu prikladnog postupka modificiranja površina. Na slici 5.11 prikazan je kod funkcije *nn_ppmp_bacprop* za izbor tj. procjenu prikladnog postupka modificiranja površina. Rezultat procjene tipa/mehanizma trošenja spremljen je u ulaznoj datoteci *NNPPSUL.TXT*. Funkcija sprema parametre mreže, a funkcijom *nnistren* poziva izvršni modul naučene neuronske mreže *NNISTREN.EXE* koji rezultat procjene sprema u datoteku *NNRPPS.TXT*.

```

TOPIC nn_ppmp_bacprop.

(**** 1. DEFINICIJA PARAMETARA I POZIV NN ALGORITMA *)
ulaz_dat='NNPPSUL.TXT'.
br_kol_ulaz=5.
izlaz_dat='Z_IZLAZ.TXT'.
zeljeni_izlaz_dat='Z_IZLAZ.TXT'.
br_kol_izlaz=31.
br_layera=2.
br_neuro_lay1=26.
br_neuro_lay2=31.
fun_lay1='tansig'.
fun_lay2='purelin'.
fun_lay3='purelin'.
tip_mreze=6.
rezisdat='NNRPPS.TXT'.
W1_dat='MPPW1.TXT'.
W2_dat='MPPW2.TXT'.
W3_dat='MPPW3.TXT'.
B1_dat='MPPB1.TXT'.
B2_dat='MPPB2.TXT'.
B3_dat='MPPB3.TXT'.
minP_dat='MPPminP.txt'.
maxP_dat='MPPmaxP.txt'.
minT_dat='MPPminT.txt'.
maxT_dat='MPPmaxT.txt'.
norm_ulaz=1.
norm_izlaz=0.
chek_plot_R=0.

(** Pomocna datoteka za definiciju vektora zeljenog izlaza *)
:duzina_liste=?br_kol_izlaz.
:lista=[].
:i=0.
REPEAT
:i=?i+1 AND
:nova_lista=REPLACE_ELEMENTS(?lista,[],-1) AND
:lista=?nova_lista
UNTIL ?i >= ?duzina_liste.
NEW_LISTA_TO_MATRICA('Z_IZLAZ.TXT',?lista).

nnsrpar(?nn_radni_direktorij,?nnparam).
nnistren(?nn_radni_direktorij,?nnparam).

(** Delay potreban da NNISTREN formira datoteku ?rezisdat *)
REPEAT
:fe=FileExists(CONCAT(?nn_radni_direktorij,?rezisdat))
UNTIL ?fe=T.

(**** 2. UCITAVANJE REZULTATA NEURONSKE MREZE *)
:A=nnrezult_A(?rezisdat,'A','R').
nn_ppmp_bacprop=?A.

END.

TOPIC nnistren(radni_direktorij,nnparam).
RUN(CONCAT(?radni_direktorij, 'NNISTREN.EXE',",", ?radni_direktorij, ", ", ?nnparam),0).
WAIT(,3).
END.

```

Slika 5.11. Prikaz koda funkcije *nn_ppmp_bacprop* za procjenu prikladnih postupaka modificiranja površina

Kao izlaz, funkcija *nn_ppmp_bacprop* daje jednodimenzionalni vektor koji se sastoji od 31 elementa što predstavlja broj postupaka modificiranja površina koje je moguće procijeniti. Elementi vektora su npr. [1,1,-1,-1,1,1,1,-1...]. Prema digitalnom principu mapiranja, svaka pozicija elementa predstavlja jedan od postupaka modificiranja površina. Kada je vrijednost elementa npr. 1, tada broj pozicije tog elementa unutar vektora predstavlja broj određenog postupka modificiranja površine.

Na slici 5.12 prikazan je primjer izbora prikladnih postupaka modificiranja površina za 8. slučaj trošenja prema DIN-50320, te za zadanu 'srednju' agresivnost okoline. U ovom slučaju, zbog jednostavnosti prikaza ulazni skup podataka (tip i mehanizam trošenja, agresivnost okoliša) nije procijenjen neuronskom mrežom, već je zadan 'ručno' kao liste elemenata: *lista_tip_trosenja*, *lista_meh_trosenja*, i *lista_agre_okoline*. Elementi lista mapirani su prema principima kako je veće objašnjeno. Zadane liste funkcija *NEW_LISTA_TO_MATRICA* sprema u određene datoteke kao matrice. U prvom koraku (funkcija: *procijeni_prikladni_sloj*) procjenjuju se slojevi s obzirom na tip i mehanizam trošenja, a izabranima se u drugom koraku (funkcija: *procijeni_koroziji_prikladni_sloj*) procjenjuje otpornost koroziji.

Kako procjenjujete **Agresivnost okoliša** u promatranom sustavu?

SLABA SREDNJA VELIKA JAKO VELIKA

ULAZNI SKUP					
Tip	Meh. trošenja				
	AD	AB	UP	TK	
8	3	1	1	2	
9	2	1	1	2	

```

.lista_tip_trosenja=[0,0,0,0,0,0,0,1,0,0,0,0,0,0]. (* Tip trošenja *)
NEW_LISTA_TO_MATRICA('NNTT.TXT',?lista_tip_trosenja).
.lista_meh_trosenja=[3,1,1,2]. (* Mehanizam trošenja *)
NEW_LISTA_TO_MATRICA('NNMT.TXT',?lista_meh_trosenja).
:p=procijeni_prikladni_sloj(). (* Poziv funkcije za procjenu prikladnog postupaka *)
TEXT(, '1. Prikladni slojevi otporni trošenju:',?p).
.lista_agre_okoline=[-1,1,-1,-1]. (* Agresivnost okoline *)
NEW_LISTA_TO_MATRICA('NNAGOKUL.TXT',?lista_agre_okoline).
:p=procijeni_koroziji_prikladni_sloj(). (* Poziv funkcije za procjenu prikladnih postupaka
otpornih koroziji *)
TEXT(, '2. Prikladni i alternativni slojevi otporni trošenju i koroziji:').
TEXT(, ' Prikladni:',?lista_ppok_podobno).
TEXT(, ' Alternativni:',?lista_ppok_moguće).

```

MEHANIZAM IZBORA POSTUPKA MODIFICIRANJA POVRŠINA: Procjena prikladnog sloja

1. Prikladni slojevi otporni trošenju:

BORIRANI SLOJEVI
SLOJEVI SAMOTEKUCIJIH LEGURA
SLOJEVI METALNIH KARBIDA
SLOJEVI METALNIH OKSIDA
SLOJEVI LEGURA
CVD-SLOJEVI NA TI OSNOVI
CVD-SLOJEVI NA AI2O3 OSNOVI
CVD-SLOJEVI NA TI(C,N) OSNOVI
NAVARENI SLOJEVI SLICNIH CELICIMA
NAVARENI DISPERGIRANI I LEGIRANI SLOJEVI

2. Prikladni i alternativni slojevi otporni trošenju i koroziji:

Prikladni:
SLOJEVI METALNIH KARBIDA
SLOJEVI METALNIH OKSIDA
SLOJEVI LEGURA
CVD-SLOJEVI NA TI(C,N) OSNOVI

Alternativni:
BORIRANI SLOJEVI

Slika 5.12. Primjer izbora prikladnih postupaka modificiranja površina otpornih trošenju i koroziji

5.1.6. Primjer načina rada mehanizma izbora materijala procjenama

Grupe materijala sa pripadnim podgrupama čija svojstva je moguće procjenjivati metodama umjetne inteligencije prikazane su u tablici 5.1. Procjene se odnose na sljedeće grupe materijala: *čelični lijev, tvrdi lijev, čelici za cementiranje, čelici za poboljšavanje, čelici za nitriranje, čelici otporni trošenju, čelici za rad pri povišenim temperaturama, čelici za ventile motora, vatrootporni čelici, čelici za kotrljajuće ležajeve, čelici otporni na djelovanje korozije i kiselina i alatni čelici*. Predviđene procjene svojstava razvrstane su unutar dviju grupa procjena:

1. Procjene temeljene na kemijskom sastavu;
2. Procjene temeljene na činjenicama.

Većinom su rezultati procjena pod rednim brojem 1., temeljeni na procjenama neuronskih mreža i neizrazite logike, dok su rezultati procjena pod rednim brojem 2. temeljeni na pravilima.

Tablica 5.1. Prikaz grupa materijala za izbor procjenama

OZNAKA	NAZIV GRUPA
2.0	ČELIČNI LIJEV
2.1	Nelegirani i legirani čelični lijev za poboljšanje
2.2	Nehrđajući i kemijski otporni čelični lijev
2.3	Vatrootporni čelični lijev
2.4	Niskolegirani čelični lijev otporan trošenju
2.5	Visokolegirani čelik legiran manganom otporan trošenju
2.6	Visokolegirani čelik legiran kromom otporan trošenju
2.7	Legirani niklov čelični lijev otporan trošenju
3.0	TVRDI LIJEV
3.2	Martenzitni tvrdi lijev
3.3	Visokolegirani kromov karbidni tvrdi lijev
6.0	ČELICI ZA CEMENTIRANJE
6.1	Nelegirani čelici za cementiranje
6.2	Legirani Cr-čelici za cementiranje
6.3	Legirani Cr-Mn čelici za cementiranje
6.4	Legirani Cr-Ni čelici za cementiranje
6.5	Legirani Cr-Mo čelici za cementiranje
6.6	Legirani Mo-Cr čelici za cementiranje
7.0	ČELICI ZA POBOLJŠAVANJE
7.1	Nelegirani čelici za poboljšavanje
7.2	Mn-legirani čelici za poboljšavanje
7.3	Cr-Mo legirani čelici za poboljšavanje
7.4	Ni-Cr-Mo legirani čelici za poboljšavanje
8.0	ČELICI ZA NITRIRANJE
8.1	Cr-Ni čelici za nitriranje
8.2	Cr-Al čelici za nitriranje
9.0	ČELICI OTPORNI TROŠENJU
9.1	Mn-čelici otporni trošenju
10.0	ČELICI ZA RAD PRI POVIŠENIM TEMPERATURAMA
11.0	ČELICI ZA VENTILE MOTORA
11.1	Cr-Si čelici za poboljšavanje
11.2	Cr-Ni-W Austenitni čelici
12.0	VATROOTPORNI ČELICI
13.0	ČELICI ZA KOTRLJAJUĆE LEŽAJEVE
14.0	ČELICI OTPORNI NA DJELOVANJE KOROZIJE I KISELINA
14.1	Cr-Ni-Mo čelici
14.2	Precipitacijski očvrnuti čelici
15.0	ALATNI ČELICI
15.1	Nelegirani alatni čelici za rad u hladnom stanju
15.2	Niskolegirani alatni čelici za rad u hladnom stanju
15.3	Visokolegirani alatni čelici za rad u hladnom stanju
15.4	Niskolegirani alatni čelici za rad u toplom stanju
15.5	Visokolegirani alatni čelici za rad u toplom stanju
15.6	Brzorezni alatni čelici

Svakoj grupi i podgrupi materijala iz tablice 5.1 dodijeljena je oznaka koja služi za povezivanje sa prikladnim postupkom modificiranja površina kao što je prikazano u tablici 5.1. Prema tablici 5.2 gornje oznake materijala svrstane su unutar šest grupa slojeva dobivenih modificiranjem površina: *martenzitni slojevi*, *rubni slojevi dobiveni promjenom kemijskog sastava*, *toplinski naštrecani slojevi*, *CVD-slojevi*, *PVD-slojevi* i *navareni slojevi*.

Tablica 5.2. Prikaz oznaka materijala prikladnih za nanošenje postupcima modificiranja površina

Postupci modificiranja	Oznake materijala
GRUPA 1: MARTENZITNI	
1.1 PROKALJENI SLOJEVI 1.2 PLAMENO KALJENI SLOJEVI 1.3 INDUKCIJSKI KALJENI SLOJEVI 1.4 LASERSKI KALJENI SLOJEVI 1.5 ELEKTRONSKIM SNOPOM KALJENI SLOJEVI 1.6 CEMENTIRANI SLOJEVI	[7.1,7.2,7.3,7.4,11.1,15.1,15.2,2.1,2.2,2.3,2.4,2.5,2.6,2.7] [7.1,7.2,7.3,7.4,11.1,15.1,15.2,2.1,2.2,2.3,2.4,2.5,2.6,2.7] [7.1,7.2,7.3,7.4,11.1,15.1,15.2,2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.1,2.2,2.3,2.4,2.5,2.6,2.7] [6.1,6.2,6.3,6.4,6.5,6.6,3.2,3.3,2.1,2.2,2.3,2.4,2.5,2.6,2.7]
GRUPA 2: RUBNI S PROMJENOM KEM. SASTAVA	
2.1. NITRIRANI/NITROKARBURIRANI SLOJEVI 2.2. BORIRANI SLOJEVI 2.3. VANADIRANI SLOJEVI	[6.1,6.2,6.3,6.4,6.5,6.6,3.2,3.3,2.1,2.2,2.3,2.4,2.5,2.6,2.7] [6.1,6.2,6.3,6.4,6.5,6.6, 7.1,7.2,7.3,7.4,11.1,14.1,15.1,15.2,15.3,15.4,15.5, 2.1,2.2,2.3,2.4,2.5,2.6,2.7] [6.1,6.2,6.3,6.4,6.5,6.6, 7.1,7.2,7.3,7.4,11.1,14.0,15.1,15.2,15.3,15.4,15.5, 2.1,2.2,2.3,2.4,2.5,2.6,2.7]
GRUPA 3: TOPLINSKI NAŠTRCANI	
3.1 SLOJEVI SAMOTEKUĆIH LEGURA 3.2 SLOJEVI ČISTIH METALA 3.3 SLOJEVI METALNIH KARBIDA 3.4 SLOJEVI METALNIH OKSIDA 3.5 SLOJEVI LEGURA NA BAZI Fe	[2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.1,2.2,2.3,2.4,2.5,2.6,2.7]
GRUPA 4: CVD	
4.1 CVD SLOJEVI NA BAZI Ti 4.2 CVD SLOJEVI NA BAZI Al ₂ O ₃ 4.3 CVD SLOJEVI NA BAZI Ti(C,N)	[2.1,2.2,2.3,2.4,2.5,2.6,2.7,15.1,15.2,15.3,15.4,15.5,15.6] [2.1,2.2,2.3,2.4,2.5,2.6,2.7,15.1,15.2,15.3,15.4,15.5,15.6] [2.1,2.2,2.3,2.4,2.5,2.6,2.7,15.1,15.2,15.3,15.4,15.5,15.6]
GRUPA 5: PVD	
5.1 PVD TITANNITRIDNI SLOJEVI 5.2 PVD TITANKARBONITRIDNI SLOJEVI 5.3 PVD TITANALUMINIJNITRIDNI SLOJEVI 5.4 PVD KROMNITRIDNI SLOJEVI	[2.1,2.2,2.3,2.4,2.5,2.6,2.7,15.1,15.2,15.3,15.4,15.5,15.6] [2.1,2.2,2.3,2.4,2.5,2.6,2.7,15.1,15.2,15.3,15.4,15.5,15.6] [2.1,2.2,2.3,2.4,2.5,2.6,2.7,15.1,15.2,15.3,15.4,15.5,15.6] [2.1,2.2,2.3,2.4,2.5,2.6,2.7,15.1,15.2,15.3,15.4,15.5,15.6]
GRUPA 6: NAVARENI	
6.1 NAVARENI SLOJEVI OTPORNI TROŠENJU NA OSNOVI MATERIJALA 6.2 NAVARENI SLOJEVI SLIČNIH ČELIKU 6.3 NAVARENI SLOJEVI S VISOKIM UDJELOM TVRDIH KARBIDA 6.4 NAVARENI SLOJEVI OTPORNI KOROZIJI 6.5 NAVARENI SLOJEVI OTPORNI KOROZIJI I TROŠENJU	[2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.1,2.2,2.3,2.4,2.5,2.6,2.7,14.1] [2.1,2.2,2.3,2.4,2.5,2.6,2.7] [2.6,2.7,3.3]

U nastavku slijedi opis načina rada funkcija za pretraživanje, opis procjena svojstava neuronskom mrežom, opis procjena svojstava neizravnom logikom, te opis strategije za izbor prikladnog materijala sloja.

a) Opis funkcija za pretraživanje

Na slici 5.13 prikazan je kod *ENG_PRET* funkcije koja izvodi pretraživanje prostora *okvir* baze znanja na temelju zadanog skupa kriterija (svojstva materijala) prosljeđenih od mehanizma za obradu kriterija. Kao što se u kodu vidi, funkcija poziva funkciju *GET_SLOT_VAL_FRAME* koja se nalazi unutar *okvir* mehanizma zaključivanja, a koja iz baze izdvaja zahtijevana svojstva sa vrijednostima.

Iz već ranije opisanog rada funkcije *GET_SLOT_VAL_FRAME* slijedi, da izdvojene vrijednosti kriterija mogu biti zadane (engl. *default*) ili naslijeđene od roditelja. Kao što je opisano u 3. dijelu rada, na ovaj način je izbjegnuto nedostatak klasičnog pretraživanja, da svojstva koja nemaju početne vrijednosti budu izuzeta iz daljnjeg razmatranja kao potencijalno prikladna za primjenu. Nakon dodjeljivanja operatora vrijednostima kriterija, izdvajaju se oznake materijala koje udovoljavaju pojedinačnim vrijednostima kriterija, a zatim oznake koje udovoljavaju svim postavljenim kriterijima. Dozvoljena su sve kombinacije postavljanja operatora (>, <, =, *min*, *max*, *like*) za svaki od kriterija unutar skupa.

```

TOPIC ENG_PRET(lista_kriterija,lista_vrijednosti_kriterija,lista_operatora_kriterija).

(** 1. Pridruzivanje svakom kriteriju sa liste liste vrijednosti recorda*)
:lista_frame=GET_FRAME_KB(?baza_v).
:br_frame=LIST_LENGTH(?lista_frame).
:i=0.
REPEAT
  :i=?i+1 AND
  :frame=ELEMENT(?lista_frame,?i) AND
  :lista_vrijednosti=GET_SLOT_VAL_FRAME(?baza_v,?baza_d,?baza_c,?frame,?lista_kriterija) AND
  ?lista_kriterija GETS_C ?lista_vrijednosti (* npr. Rm_Kaljeno=[1010,19]; Rm_Pobolj=[1010,515]*)
  (* vrijednosti recorda npr. CL=1010;CL1330=19*)
UNTIL ?i=?br_frame.

(** 2. Pridruzivanje svakom kriteriju sa liste samo onih recorda sa liste vrijednosti recorda koji odgovaraju postavljenom
operatoru iz liste kriterija*)
:br_kriterija=LIST_LENGTH(?lista_kriterija).
:lista_naz_kriterija=?lista_kriterija.
:j=0.
REPEAT
  :j=?j+1 AND
  :lista_iznosa=(ELEMENT(?lista_kriterija,?j)) AND
  :operator=ELEMENT(?lista_operatora_kriterija,?j) AND
  IF ?operator='>'
  THEN :lista_od=ELEMENT(?lista_vrijednosti_kriterija,?j) AND
        :t=TRAZI_MAX_OD_IZNOS(?lista_frame,?lista_iznosa,?lista_od) AND
        ELEMENT(?lista_naz_kriterija,?j)=[] AND
        ELEMENT(?lista_naz_kriterija,?j) GETS ?t
  ELSE
  IF ?operator='<'
  THEN :lista_od=ELEMENT(?lista_vrijednosti_kriterija,?j) AND
        :t=TRAZI_MIN_OD_IZNOS(?lista_frame,?lista_iznosa,?lista_od) AND
        ELEMENT(?lista_naz_kriterija,?j)=[] AND
        ELEMENT(?lista_naz_kriterija,?j) GETS ?t
  ELSE
  IF ?operator='='
  THEN :lista_od=ELEMENT(?lista_vrijednosti_kriterija,?j) AND
        :t=TRAZI_IZNOS(?lista_frame,?lista_iznosa,?lista_od) AND
        ELEMENT(?lista_naz_kriterija,?j)=[] AND
        ELEMENT(?lista_naz_kriterija,?j) GETS ?t
  ELSE
  IF ?operator='min'
  THEN :t=TRAZI_MIN_IZNOS(?lista_frame,?lista_iznosa) AND
        ELEMENT(?lista_naz_kriterija,?j)=[] AND
        ELEMENT(?lista_naz_kriterija,?j) GETS ?t
  ELSE
  IF ?operator='max'
  THEN :t=TRAZI_MAX_IZNOS(?lista_frame,?lista_iznosa) AND
        ELEMENT(?lista_naz_kriterija,?j)=[] AND
        ELEMENT(?lista_naz_kriterija,?j) GETS ?t
  ELSE
  IF ?operator='like'
  THEN :t=TRAZI_LIKE_IZNOS(?baza_d,ELEMENT(?lista_kriterija,?j),ELEMENT(?lista_vrijednosti_kriterija,?j)) AND
        ELEMENT(?lista_naz_kriterija,?j)=[] AND
        ELEMENT(?lista_naz_kriterija,?j) GETS ?t
UNTIL ?j=?br_kriterija.

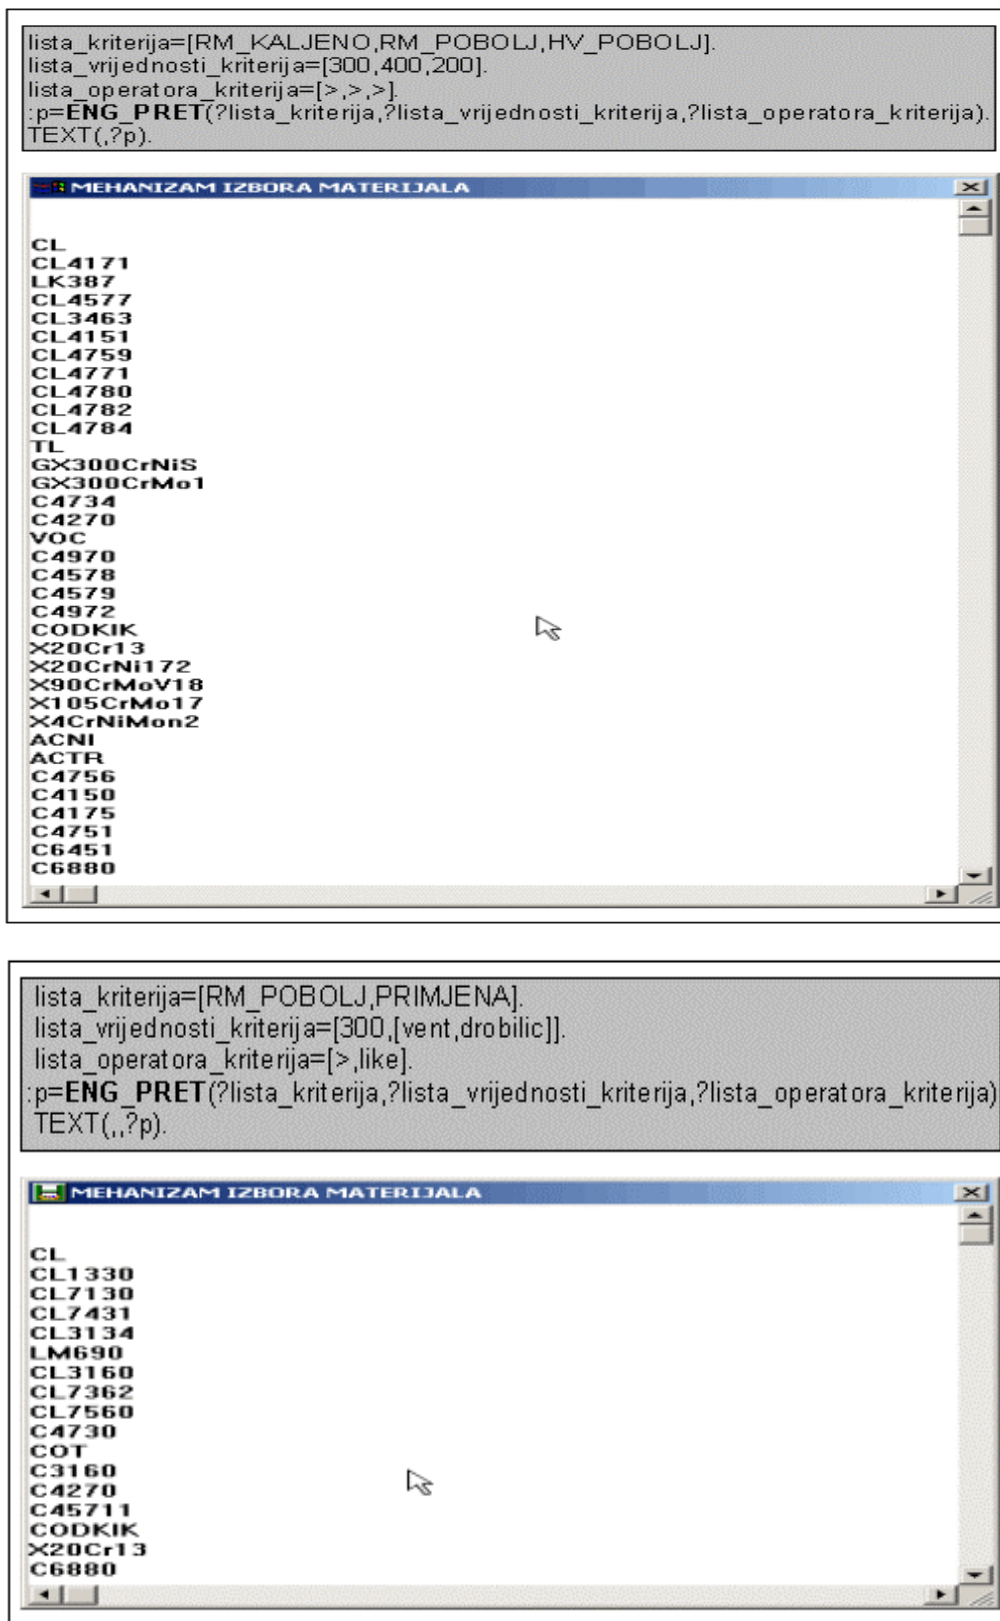
(** 3. Trazenje presjeka *)
IF ?br_kriterija <= 20
THEN :p=engpret0120_mat(?lista_naz_kriterija,?br_kriterija).
IF ?br_kriterija >= 21
THEN :p=engpret2130_mat(?lista_naz_kriterija,?br_kriterija).
eng_pret=?p.

END.

```

Slika 5.13. Prikaz programskog koda funkcije *ENG_PRET* mehanizma izbora materijala procjenama

Na slici 5.14 dana su dva karakteristična primjera postavljanja listi parametara funkcije *ENG_PRET*. U prvom slučaju traženi kriteriji su mehanička svojstva *RM_KALJENO*, *RM_POBOLJ* i *HV_POBOLJ* sa iznosima 300, 400 i 200. U drugom slučaju su to svojstva *RM_POBOLJ* i *PRIMJENA*. U ovom su slučaju zadane vrijednosti kriterija *PRIMJENA* (*vent,drobilic*), namjerno zadane nepotpuno (ispravno je: *ventili,drobilice*) zbog prikaza rada operatora *like*. Dakle, operator *like* izdvaja samo one oznake materijala čije su vrijednosti kriterija *PRIMJENA* 'slične' zadanim vrijednostima, u ovom slučaju *vent, drobilic*.



Slika 5.14. Primjeri izbora prikladnog materijala sloja materijala procjenama

b) Opis načina procjene svojstava materijala neuronskom mrežom

Neuronskom mrežom procjenjuju se svojstva materijala koja u *DEF* pretincu *okvir* baze nemaju vrijednost. Kao što je veće objašnjeno, mehanizam zaključivanja tada poziva funkciju za izračunavanje vrijednosti koja se nalazi u *CALC* pretincu. Vrijednost svojstva se izračunava tj. procjenjuje, naučenom neuronskom mrežom. Ulaz u naučenu neuronsku mrežu, u većini slučajeva su podaci o kemijskom sastavu materijala. U tablici 5.3 dan je prikaz svih funkcija za procjenu svojstava materijala na bazi *Fe*. U slučaju kada svojstvo nema eksplicitno zadanu vrijednost, a od strane mehanizma za obradu kriterija procijenjeno je kao svojstvo važno za izbor materijala, tada se nakon dobivanja vrijednosti neuronskom mrežom, izbor materijala temelji na primjeni operatora *max* ili *min* prema pravilima u tablici 5.3. Na slici 5.15 prikazan je kod funkcije za procjenu kemijske postojanosti čelika H_2SO_4 . U prikazanom kodu funkcija **NNISTREN** poziva naučenu neuronsku mrežu.

```
(**** PROCJENA KEMIJSKE POSTJANOSTI CELIKA – H2SO4 *)
TOPIC nn_hso_postojanost(uldat,izdat).

(**** 1. DEFINICIJA PARAMETARA I POZIV NN ALGORITMA *)
ulaz_dat=?uldat.
br_kol_ulaz=8.
izlaz_dat='Z_IZLAZ.TXT'.
zeljeni_izlaz_dat='Z_IZLAZ.TXT'.
br_kol_izlaz=1.
reztrdat='REZTRDAT.TXT'.
br_layera=3.
br_neuro_lay1=9.
br_neuro_lay2=7.
fun_lay1='tansig'.
fun_lay2='tansig'.
fun_lay3='tansig'.
tip_mreze=6.
rezisdat=?izdat.
W1_dat='HSOW1.TXT'.
W2_dat='HSOW2.TXT'.
W3_dat='HSOW3.TXT'.
B1_dat='HSOB1.TXT'.
B2_dat='HSOB2.TXT'.
B3_dat='HSOB3.TXT'.
minP_dat='HSOminP.txt'.
maxP_dat='HSOmaxP.txt'.
minT_dat='HSOminT.txt'.
maxT_dat='HSOmaxT.txt'.
norm_ulaz=1.
norm_izlaz=1.
chek_plot_R=0.

(** Pomocna datoteka za definiciju vektora zeljenog izlaza *)
:duzina_liste=?br_kol_izlaz.
:lista=[].
:i=0.
REPEAT
:i=?i+1 AND
:nova_lista=REPLACE_ELEMENTS(?lista,[],-1) AND
:lista=?nova_lista
UNTIL ?i >= ?duzina_liste.
NEW_LISTA_TO_MATRICA('Z_IZLAZ.TXT',?lista).

NNSPRPAR(?nn_radni_direktorij,?nnparam).
NNISTREN(?nn_radni_direktorij,?nnparam).

(** Delay potreban da NNISTREN formira datoteku ?rezisdat *)
REPEAT
:fe=FileExists(CONCAT(?nn_radni_direktorij,?rezisdat))
UNTIL ?fe=T.

(**** 2. UCITAVANJA REZULTATA NEURONSKE MREZE *)
:A=nnrezult_A(?rezisdat,'A','R').

END.
```

Slika 5.15. Prikaz koda funkcije *nn_hso_postojanost* za procjenu kemijske postojanosti čelika H_2SO_4

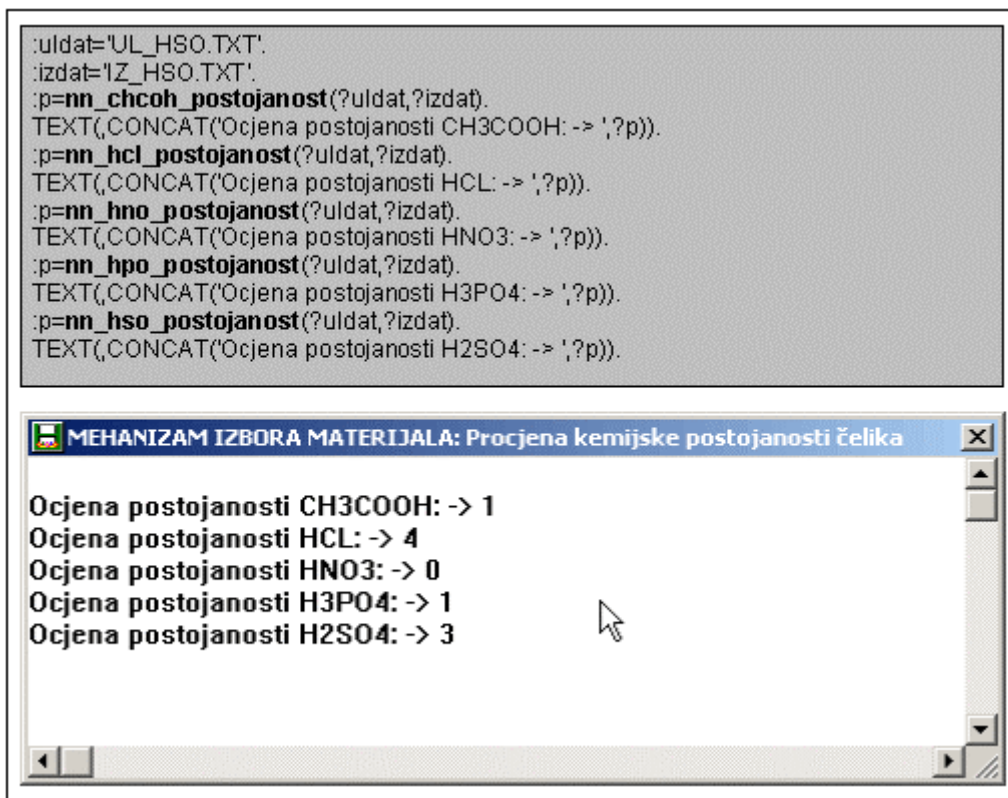
Tablica 5.3. Prikaz funkcija mehanizma za obradu procjenu svojstava materijala na bazi *Fe*

Naziv procjene materijala P	Vrijednost funkcije x	AKO JE x	TADA JE P
Procjena mehaničkih svojstava materijala pri normalnim temperaturama	x= Rm_kaljeno_stanje(baza,frame)	>	bolje
	x= Rm_poboljsano_stanje(baza,frame)	>	bolje
	x= Re_kaljeno_stanje(baza,frame)	>	bolje
	x= Re_poboljsano_stanje(baza,frame)	>	bolje
	x= HV_kaljeno_stanje(baza,frame)	>	bolje
	x= HV_poboljsano_stanje(baza,frame)	>	bolje
	x= A5_kaljeno_stanje(baza,frame)	>	bolje
	x= A5_poboljsano_stanje(baza,frame)	>	bolje
	x= TR_kaljeno_stanje(baza,frame)	>	bolje
Procjena kemijske postojanosti otopinama kiselina	x= chcoh_postojanost(baza,frame,koncentracija_otopine,temp_otopine)	<	bolje
	x= hcl_postojanost(baza,frame,koncentracija_otopine,temp_otopine)	<	bolje
	x= hno_postojanost(baza,frame,koncentracija_otopine,temp_otopine)	<	bolje
	x= hpo_postojanost(baza,frame,koncentracija_otopine,temp_otopine)	<	bolje
	x= hso_postojanost(baza,frame,koncentracija_otopine,temp_otopine)	<	bolje
Procjena otpornosti trošenja abraziji gubitkom volumena	x= gv_abrazija(baza,frame,temp_popustanja)	<	bolje
Procjena otpornosti popuštanju alatnih čelika	x= ne_otppop(baza,frame)	>	bolje
	x= ni_otppop(baza,frame)	>	bolje
	x= vi_otppop(baza,frame)	>	bolje
	x= tr_otppop(baza,frame)	>	bolje
	x= bc_otppop(baza,frame)	>	bolje
Procjena mehaničkih svojstava alatnih čelika pri povišenim temperaturama	x= Rm_ms_temp(baza,frame)	<	bolje
	x= Rp02_ms_temp(baza,frame)	<	bolje
	x= A5_ms_temp(baza,frame)	<	bolje
Procjena obradljivosti	x= proc_obr(baza,frame)	nelegiran	visoka
		niskolegiran	niska,srednja
		visokolegiran	niska
Procjena zavarljivosti	x= proc_zav(baza,frame)	<	bolje
Procjena žilavosti	x= proc_zi(baza,frame)	>	bolje
Procjena osjetljivosti na zarezno djelovanje	x= proc_zardje(baza,frame)	<	bolje
Procjena legiranosti	x= proc_leg(baza,frame)	< 0.05	nelegiran
		≤ 5	niskolegiran
		> 5	visokolegiran
Procjena oblikovljivosti	x= proc_oblikovljivosti(lista_mat,lista_Re_iznosa)	<	bolje
Procjena relativno visoke tvrdoće	x= proc_visoke_tvrdoce(lista_mat,lista_HV_iznosa)	≥ 390	visoka
Procjena radne temperature	x= proc_radne_temp(radna_temperatura)	≤ 180	niska
		180 > x ≤ 450	srednja
		450 > x	visoka
Procjena primjene grupe materijala na temelju radne temperature	x= proc_grup_mat_rad_temp(radna_temperatura)	≤ 480	nelegiran
		480 > x ≤ 600	niskolegiran
		600 > x ≤ 800	visokolegiran
		800 > x	vatrootporni
Procjena primjene grupe alatnih čelika na temelju radne temperature	x=proc_alat_cel_rad_temp(radna_temperatura)	≤ 200	hladni rad
		200 > x ≤ 600	topli rad
		600 > x ≤ 800	brzorezni
Procjena nastajanja oksidacije na temelju radne temperature	x= proc_nast_oxid(radna_temperatura)	>550	nastaje
Procjena uspješnosti sprečavanja oksidacije na temelju sadržaja Ni	x= proc_sprec_oxid(lista_mat,lista_Ni_iznosa)	≥ 25	bolje

Na slici 5.16 prikazane su funkcije za određivanje kemijske postojanosti čelika Č4171 (X15Cr13). Ulazni podaci za neuronsku mrežu su:

- kemijski sastav čelika: 0,15%C; 1%Si; 1%Mn; 13%Cr;
- koncentracija otopine 1%;
- temperatura otopine 20°C.

Ulazni podaci za neuronsku mrežu spremljeni su u obliku matrice u datoteku 'UL_HSO.TXT', a rezultat procjene mreže spremljen je u datoteku 'IZ_HSO.TXT'. Prema slici 5.16 zadani čelik je potpuno postojan HNO₃ (ocjena 0) i potpuno nepostojan H₂SO₄ (ocjena 3). Ocjena 4 označava 'nepoznatu' postojanost.



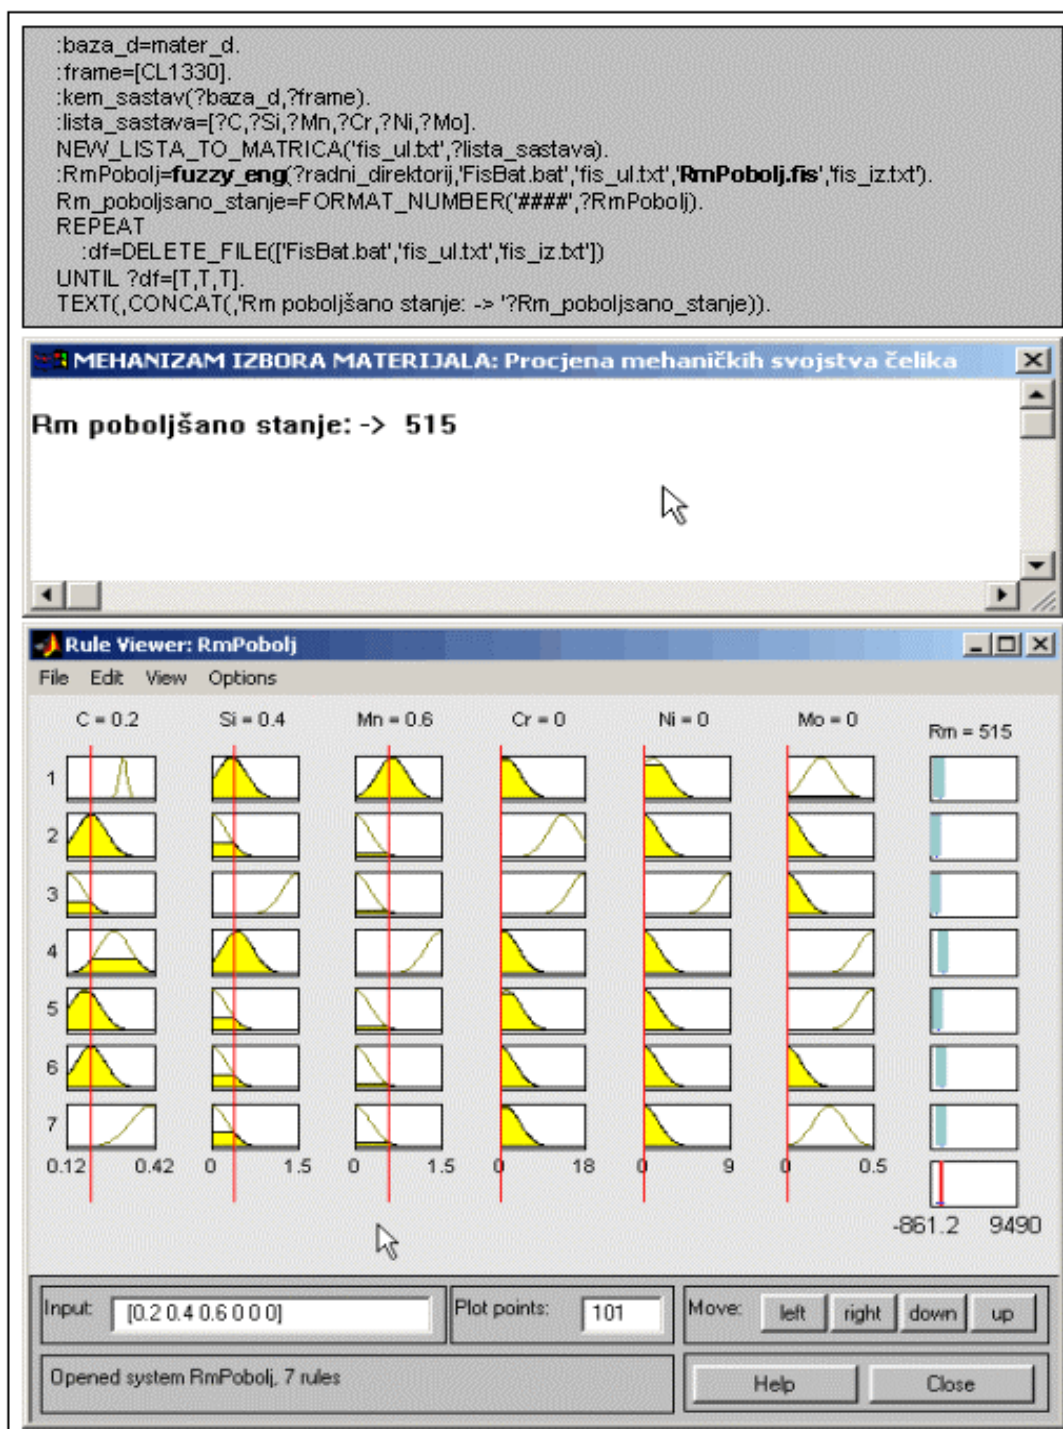
Slika 5.16. Primjer određivanja kemijske postojanosti čelika Č4171 (X15Cr13)

c) Opis načina procjene svojstava materijala neizrazitom ili *fuzzy* logikom

Pretpostavljeno je, a zbog relativnog malog broja dostupnih podataka za ulazne skupove, da će se bolja generalizacija tj. procjena nekih svojstava materijala postići modeliranjem procjena neizrazitom logikom, jer korišteni alat za modeliranje *FIS-a* dozvoljava visok stupanj ručnog ugađanja funkcija pripadnosti (vrsta, oblik) i pravila (naknadni ispravci). Uglavnom se neizrazitom logikom procjenjuju mehanička svojstva materijala (Tablica 4.65), pozivom predefimirane funkcije u *CALC* pretincu *okvir* baze znanja, koja pak poziva naučeni *FIS* određenog svojstva materijala. U većini slučajeva, kao i kod procjena neuronskom mrežom, ulaz u naučeni *FIS* su podaci o kemijskom sastavu. Od modela (*Mamdami*, *Sugeno*) najčešće je primjenjivan *neurofuzzy* model *Sugeno* zbog pogodnosti automatskom ugađanja (neuronskom mrežom) funkcija pripadnosti.

```

TOPIC fuzzy_eng(radni_direktorij,fuzzy_bat,ulaz_dat,fis_dat,izlaz_dat).
NEW_FILE(CONCAT(?radni_direktorij,?fuzzy_bat)).
WRITE(CONCAT(?radni_direktorij,?fuzzy_bat),CONCAT(?radni_direktorij,'FISMAIN.EXE',',',?ulaz_dat,',',?fis_dat,',
?izlaz_dat)).
CLOSE(CONCAT(?radni_direktorij,?fuzzy_bat)).
RUN(?fuzzy_bat,0).
:frezult=READ_LINE(?izlaz_dat,1).
CLOSE(?izlaz_dat).
fuzzy_eng=?frezult.
END.
  
```

Slika 5.17. Prikaz koda funkcije *FUZZY_ENG* za procjenu svojstava materijala neizrazitom logikomSlika 5.18. Primjer određivanja R_m u poboljšanom stanju za ČL1330 neizrazitom logikom

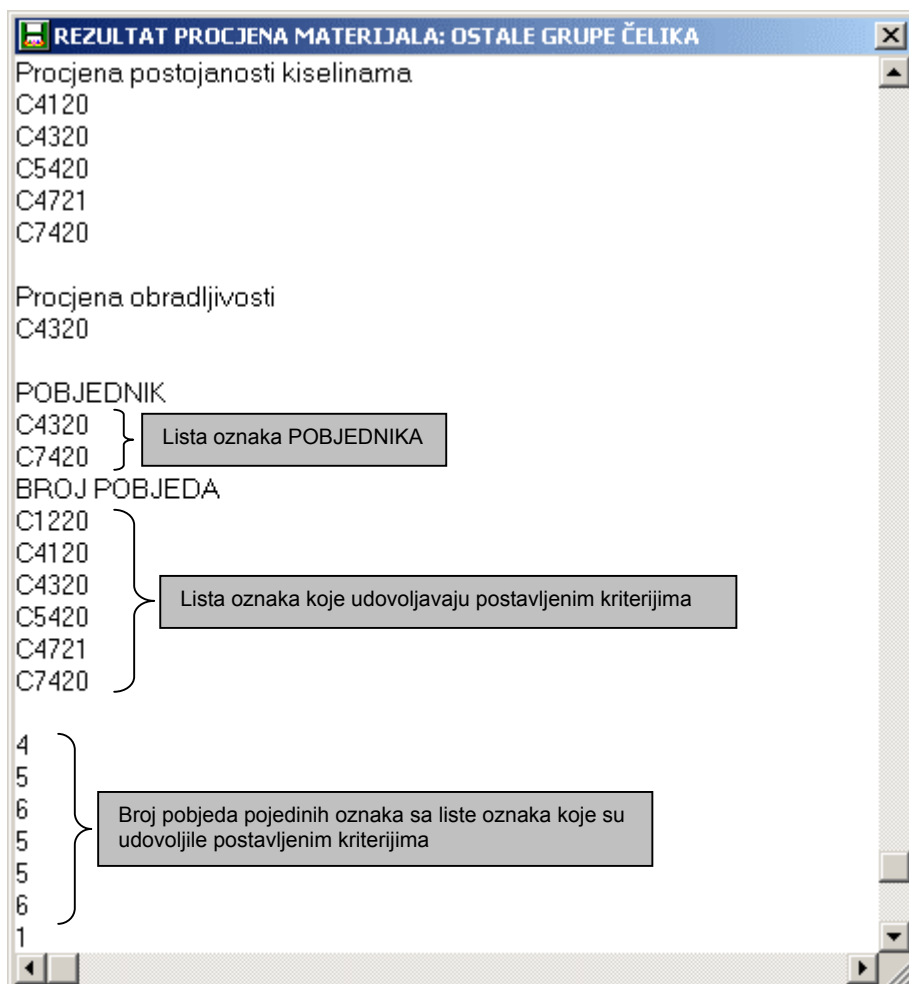
Na slici 5.18 prikazan je primjer određivanja R_m u poboljšanom stanju za ČL1330 (0,2%C, 0,4%Si, 0,6%Mn) neizrazitom logikom. Unutar slike prikazan je kod funkcije u kojem se vidi poziv modeliranog FIS-a 'RmPobolj.fis', pomoću *fuzzy_eng* funkcije. Za konkretni materijal procjena R_m u poboljšanom stanju je $R_m = 515 \text{ N/mm}^2$. Također je na slici prikazana i grafička prezentacija pravila zaključivanja tj. dijagrami zaključivanja.

d) Opis načina izbora materijala

Kao metoda izbora prikladnog materijala sloja, primjenjena je metoda 'pobjednika', koja određuje oznaku koja se najviše puta pojavila kao rezultat pretraživanja po zadanim kriterijima. Programski kod metode prikazan je na slici 5.19. Varijable lista_pret_1, lista_pret_2, lista_pret_3, itd., predstavljaju liste tj. vektore čiji su elementi oznake materijale koje udovoljavaju pojedinim kriterijima.

```
(** 15. ODREĐIVANJE 'POBJEDNIKA' -> OZNAKE KOJA JE NAJVIŠE PUTA POJAVILA KAO REZULTAT PRETRAŽIVANJA*)
:lista_pret_skupno=COMBINE(?lista_pret_1,?lista_pret_2,?lista_pret_3,?lista_pret_4,?lista_pret_5,?lista_pret_6,?lista_pret_7).
:lista_pret_skraceno=UNION(?lista_pret_1,?lista_pret_2,?lista_pret_3,?lista_pret_4,?lista_pret_5,?lista_pret_6,?lista_pret_7).
:duz=LIST_LENGTH(?lista_pret_skraceno).
:lista_max_iznosa=[].
:i=0.
REPEAT
:i=?i+1 AND
:broj_poz=LIST_LENGTH(WHERE(?lista_pret_skupno,ELEMENT(?lista_pret_skraceno,?),32000)) AND
:lista_max_iznosa GETS ?broj_poz
UNTIL ?i=?duz.
:lista_pobjednika=trazi_max_iznos(?lista_pret_skraceno,?lista_max_iznosa).
```

Slika 5.19. Programski kod funkcije za određivanje 'pobjednika' pri izboru materijala sloja

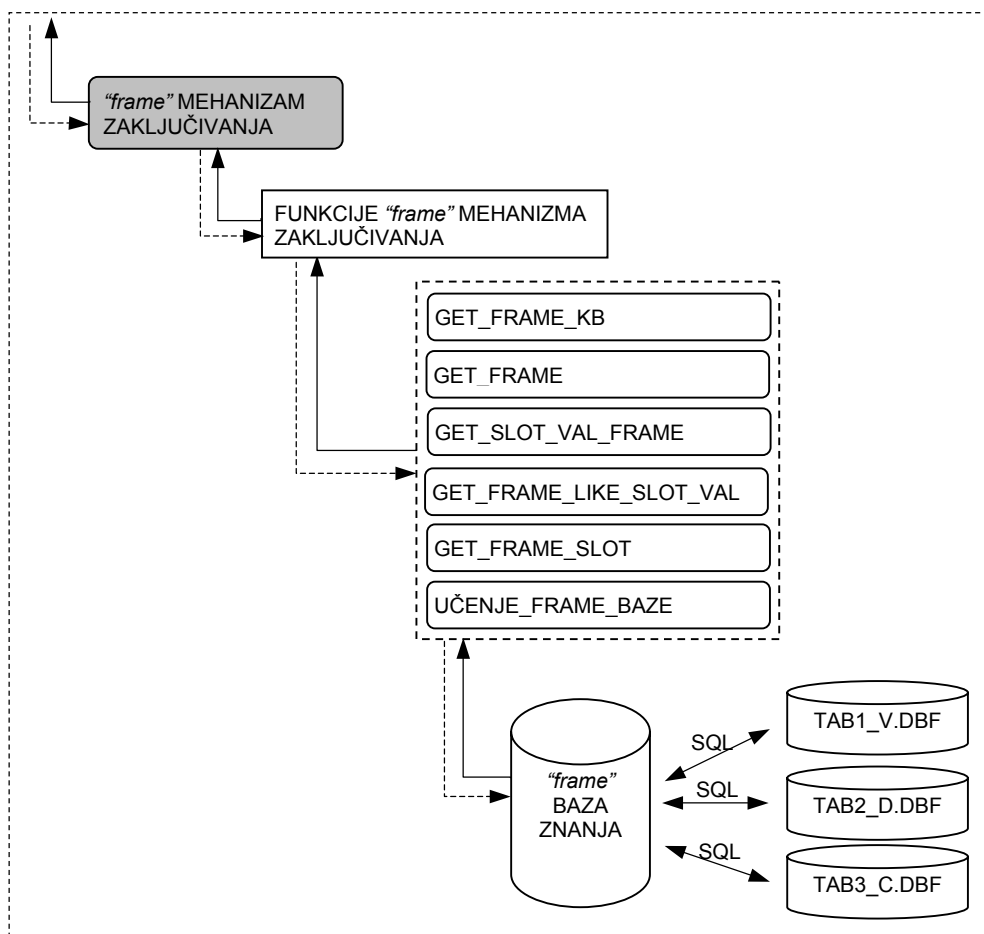


Slika 5.20. Primjer rezultata izbora materijala metodom 'pobjednika'

Na slici 5.20. prikazan je primjer rezultata izbora materijala metodom 'pobjednika'. Na slici je vidljivo da su se oznake C4320 i C7420 na listi broja pobjeda pojavljivale jednaki broj puta (6), a ujedno najveći broj puta prema postavljenim kriterijima. Slijede oznake C4120, C5420 i C4721.

5.1.7. Primjer načina rada *okvir* mehanizma zaključivanja

Na slici 5.21. dana je detaljnja blok-shema *okvir* mehanizma zaključivanja sa prikazom funkcija i načina pristupa bazi znanja. Kao što se vidi baza znanja sastoji se od više baza-tablica standardnog DBF-formata. Umjesto 'velikih' relacijskih baza (MS SQL-server, Oracle), a zbog relativno male količine podataka i jednostavnosti korištenja, izabran je upravo DBF-format baza-tablica. Pristupi (čitanje/pisanje) DBF bazama-tablicama izvedeni su pomoću *KPWIN++ SQLKIT* alata koji daje mogućnost izvođenja SQL-upita na DBF bazi. Svi SQL-upiti kreiraju se *dinamički*, što odrađuje *okvir* mehanizam zaključivanja. Pod dinamičkim kreiranjem SQL-upita, podrazumijeva se stvaranje upita promjenljive dužine i promjenljivog sadržaja. Zbog *okvir* koncepcije, baza znanja se sastoji od tri tablice: **TAB_V.DBF**, **TAB_D.DBF** i **TAB_C.DBF**. Sve tri tablice su iste strukture, a oznake **_V**, **_D**, **_C** zapravo predstavljaju pretince (engl. *facete*). Prema tome, početne se vrijednosti (DEF-vrijednosti) *okvira*, spremaju u **TAB_D.DBF**. U tablici 5.4 dan je popis razvijenih funkcija *okvir* mehanizma zaključivanja sa parametrima i opisom načina rada.



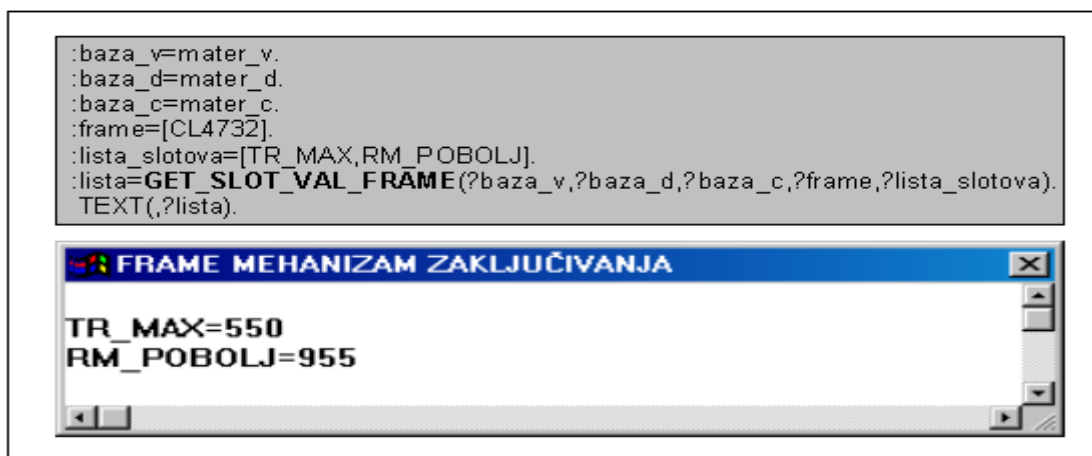
Slika 5.21. Blok-shema *okvir* mehanizma zaključivanja

Najvažnija funkcija koja 'inteligentno' pretražuje prostor baze znanja je *GET_SLOT_VAL_FRAME* funkcija. Ova je funkcija preko poziva uključena i u sljedeće funkcije: *GET_FRAME* i *GET_FRAME_LIKE_SLOT_VAL*. Prva tri parametra funkcije *baza_v*, *baza_d* i *baza_c* predstavljaju nazive VAL, DEF i CALC baza-tablica, npr. baze-tablice za procjenu materijala *mater_v.dbf*, *mater_d.dbf*, *mater_c.dbf*. Parametar *okvir* je naziv tekućeg *okvira* koji se obrađuje, npr. ČL4732. Peti parametar je lista slotova za koje se traži vrijednost. Npr. traže se vrijednosti; vlačna čvrstoća Rm u poboljšanom stanju, iznos tvrdoće HV, itd. Na slici 5.22. je prikazan programski kod ove funkcije u sintaksi *KPWIN++* programskog jezika.

Tablica 5.4. Popis funkcija za pristup *okvir* mehanizma zaključivanja

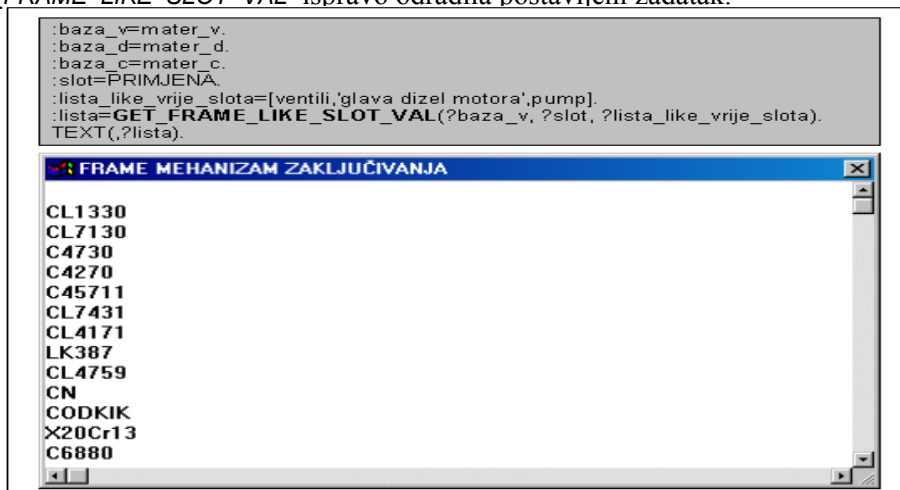
Naziv funkcije	Opis
GET_FRAME_KB (baza)	Funkcija vraća listu framea iz zadane baze znanja
GET_FRAME (baza,lista_slotova,lista_traz_vrije_slot)	Funkcija vraća listu frame-a koji imaju zadanu listu slotova i zadanu listu vrijednosti slotova. Funkcija ima sposobnost nasljeđivanja vrijednosti od frame-a roditelja.
GET_SLOT_VAL_FRAME (baza_v,baza_d,baza_c,frame,lista_slotova)	Funkcija iz zadane baze znanja, za zadani frame i zadanu listu slotova vraća listu vrijednosti zadanih slotova. Funkcija ima sposobnost nasljeđivanja vrijednosti od frame-a roditelja.
GET_FRAME_LIKE_SLOT_VAL (baza, slot, lista_like_vrije_slot)	Funkcija iz zadane frame baze, za zadani slot i zadanu <i>LIKE</i> listu vrijednosti slotova vraća frame.
INSERT_FRAME_SLOT (baza,frame,slot,slot_iznos)	Funkcija u zadanu frame bazu, za zadani frame i zadani slot insertira novu vrijednost slotova.
UCENJE_FRAME_BAZE (baza,lista_slotova)	Funkcija puni VAL facets baze_v sa vrijednošću koju vraća funkcija upisan u CALC slot iz zadane liste slotova.

Od važnijih funkcija je i *GET_FRAME_LIKE_SLOT_VAL* koja u dinamički kreiranom *SQL* izrazu sadrži *SQL* operator **LIKE**. Specifičnost ovog operatora je njegova primjena kod pretraživanja slotova baze znanja kod kojih postoji mogućnost pogrešnog upisa vrijednosti kao npr., slotovi koji sadrže tekstualne opise pojedinih svojstava. Ova specifičnost, primjenjena je kod pretraživanja materijala prema primjeni pri čemu je korisniku u tijeku konverzacije sa sustavom dozvoljen slobodan unos primjene materijala. Npr., pretpostavimo da se traži materijal za izradu ventila. Funkcija će ispravno pronaći sve one *frame* kod kojih je u opisnom slotu *primjena* upisano npr.: *ventili, entili, enti, tili*, itd.

Slika 5.22. Primjer primjene *GET_SLOT_VAL_FRAME* funkcije

Na slikama 5.23. i 5.24. prikazani su primjeri primjene gornje opisanih funkcija. Na slici 5.23. vidi se primjer pretraživanja maksimalne radna temperatura (*TR_MAX*) do koje je zadani materijal ČL4732 otporan oksidaciji, te vlačna vlačna čvrstoća u poboljšanom stanju (*RM_POBOLJ*). U konkretnom slučaju iznos *TR_MAX=550* naslijeđen je od *okvira* roditelja (grupe materijala) čelični lijev (CL), dok se iznos za *RM_POBOLJ=955* izračunao pozivom funkcije upisane u CALC pretinac traženog svojstva u bazi-tablici *mater_c*, koja pak pozivom naučenog algoritma neuronske mreže izračunava (procjenjuje) traženi slot tj.svojstvo materijala. Na slici 5.23 prikazana je tražena *LIKE* lista vrijednosti slotova PRIMJENA iz *okvir* baze znanja o materijalima. U listi je namjerno pogrešno napisana riječ *ump* umjesto *pumpi* ili *pumpe*. Pregledom baze-tablice *mater_d*, ustanovljeno je da ČL4171 u polju PRIMJENA ima upisano: *dijelovi*

pumpi, dijelovi vodenih turbina. Pojavljivanjem čelika ČL4171 na listi prikladnih materijala, znači da je funkcija `GET_FRAME_LIKE_SLOT_VAL` ispravno odradila postavljene zadatke.



Slika 5.23. Primjer primjene `GET_FRAME_LIKE_SLOT_VAL` funkcije

FRAME BAZA ZNANJA: > MATERIJALI <					
RODITELJ OKVIRI CL 2.0					
Pretinac	VAL	DEF	CALC	ADD	DEL
FRAME	CL4732				
AKO	CL				
C		0.42			
SI		0.4			
MN		0.6			
CR		1.0			
NI		0			
MO		0.25			
V		0			
W		0			
AL		0			
P		0			
TR_MIN					
TR_MAX					
CO		0			
RM_KALJENO				Rm_kaljeno_stanje.	
RM_POBOLJ		955		Rm_poboljsano_sta	
RE_KALJENO				Re_kaljeno_stanje.	
RE_POBOLJ		390		Re_poboljsano_sta	
HV_KALJENO				HV_kaljeno_stanje.	
HV_POBOLJ		280		HV_poboljsano_sta	
A5_KALJENO:				A5_kaljeno_stanje.	
A5_POBOLJ		9		A5_poboljsano_sta	
TR_KALJENO				TR_kaljeno_stanje.	
TR_POBOLJ				TR_poboljsano_sta	
CHCOH				chcoh_postojanost.	
GV				gv_abrazija.baza_d	
HCL				hcl_postojanost.ba	
HNO				hno_postojanost.be	
HPO				hpo_postojanost.be	
HSO				hso_postojanost.ba	

Record: 1 of 1

Slika 5.24. Primjer unosa i ispravka *okvir* baze znanja

Na slici 5.25. prikaz je primjer dijela forme za unos znanja u *okvir* bazu materijala. Prikazani slučaj forme je unos-ispravak podataka za lijev ČL4732. Vidljivo je da prikazani čelik pripada roditelju okviru *čelični lijev* i to preko vrijednosti sadržaja AKO slota. Vrijednosti svojstava `RM_KALJENO` i `RM_POBOLJ` u VAL-pretincu, dobivene su učenjem frame baze pomoću naučene neuronske mreže za ta svojstva. Zbog toga

što je vrijednosti za *RM_POBOLJ* zadana u DEF pretincu, VAL vrijednost u ovom slučaju nije potrebno procjenjivati neuronskom mrežom.

```

TOPIC GET_SLOT_VAL_FRAME(baza_v,baza_d,baza_c,frame,lista_slotova).
:lista_slot=LIST_TO_STRING(?lista_slotova,')
:sql_izraz=CONCAT('SELECT ', 'FRAME','AKO','PODGRUPA','?lista_slot, ' FROM ', ?baza_v, ' WHERE ', FRAME,
'=',CONCAT(NUMBER_TO_CHAR(39),?frame,NUMBER_TO_CHAR(39)))
:hdbc=qcConnect('DRV=QEDBF')
:hstmt=qcExecSQL(?hdbc,?sql_izraz)
WHILE qcFetchNext(?hstmt)=0
THEN :ako_iznos=GET_STRING(qcValChar(?hstmt, 2, '' , 0)) AND
:br_slotova=LIST_LENGTH(?lista_slotova) AND
:=0 AND
:br_kol=3 AND
:lista_vrijednosti_slot= [] AND
REPEAT
:=?i+1 AND
:br_slot= ?br_kol+?i AND
:v_naziv_slot=GET_STRING(qcColName(?hstmt,?br_slot)) AND
:v_iznos_slot=GET_STRING(qcValChar(?hstmt,?br_slot, '' , 0)) AND
:v_iznos_slot=STRING_REPLACE(?v_iznos_slot, ',',32767) AND (* brisanje blankova u stringu*)
:d_iznos_slot=GET_SLOT_DEF_FRAME(?baza_d,?frame,?v_naziv_slot) AND
:d_iznos_slot=STRING_REPLACE(?d_iznos_slot, ',',32767) AND (* brisanje blankova u stringu*)
:c_iznos_slot=GET_SLOT_CALC_FRAME(?baza_c,?frame,?v_naziv_slot) AND
:c_iznos_slot=STRING_REPLACE(?c_iznos_slot, ',',32767) AND (* brisanje blankova u stringu*)
(** 1. Vrijednost slota pronađena kod roditelj frame-a *)
IF STRING_LENGTH(?v_iznos_slot) = 0 AND ?ako_iznos <> '' AND ?d_iznos_slot = '' AND ?c_iznos_slot = ''
THEN :v_iznos_slot=GET_SLOT_FROM_PARENTS(?baza_v,?ako_iznos,?v_naziv_slot) AND
:lista_vrijednosti_slot=REPLACE_ELEMENTS(?lista_vrijednosti_slot,[],?v_iznos_slot)
ELSE (** 2. Vrijednost slota pronađena u baza_v *)
IF STRING_LENGTH(?v_iznos_slot) > 0
THEN :lista_vrijednosti_slot=REPLACE_ELEMENTS(?lista_vrijednosti_slot,[],?v_iznos_slot)
ELSE (** 3. Vrijednost slota pronađena u baza_d *)
IF ?d_iznos_slot <> ''
THEN :lista_vrijednosti_slot=REPLACE_ELEMENTS(?lista_vrijednosti_slot,[],?d_iznos_slot)
ELSE (** 4. Vrijednost slota pronađena u baza_c *)
IF ?c_iznos_slot <> ''
THEN :lista_vrijednosti_slot=REPLACE_ELEMENTS(?lista_vrijednosti_slot,[],?c_iznos_slot)
ELSE (** 5. Vrijednost slota nije pronađena u frame bazi *)
IF STRING_LENGTH(?v_iznos_slot) = 0 AND ?ako_iznos = '' AND ?d_iznos_slot = '' AND ?c_iznos_slot = ''
THEN :lista_vrijednosti_slot=REPLACE_ELEMENTS(?lista_vrijednosti_slot,[],'-')
UNTIL ?i=?br_slotova.
:zatvori_sql=qcEndSQL(?hstmt)
:zatvori_kon=qcDisconnect(?hdbc) AND
GET_SLOT_VAL_FRAME=?lista_vrijednosti_slot.

(** PRETRAŽIVANJE DEF PRETINCA **)
TOPIC GET_SLOT_DEF_FRAME(baza,frame,slot).
:sql_izraz=CONCAT('SELECT ', 'FRAME','AKO','PODGRUPA','?slot, ' FROM ', ?baza, ' WHERE ', FRAME, '=',CONCAT(NUMBER_TO_CHAR(39),?frame,NUMBER_TO_CHAR(39)))
:hdbc=qcConnect('DRV=QEDBF')
:hstmt=qcExecSQL(?hdbc,?sql_izraz)
WHILE qcFetchNext(?hstmt)=0
THEN :=1 AND
:br_kol=3 AND
:br_slot= ?br_kol+?i AND
:iznos_slot=GET_STRING(qcValChar(?hstmt,?br_slot, '' , 0))
:iznos_slot=STRING_REPLACE(?iznos_slot, ',',32767). (* brisanje blankova u stringu*)
:zatvori_sql=qcEndSQL(?hstmt)
:zatvori_kon=qcDisconnect(?hdbc)
IF STRING_LENGTH(?iznos_slot) > 0 (* 1. Iznos slot je različit od nule -> završeno pretraživanje def slot *)
THEN :iznos_def_slot=?iznos_slot
ELSE :iznos_def_slot='-'.
GET_SLOT_DEF_FRAME=?iznos_def_slot.
END.

(** PRETRAŽIVANJE CALC PRETINCA **)
TOPIC GET_SLOT_CALC_FRAME(baza_c,frame,slot).
:sql_izraz=CONCAT('SELECT ', 'FRAME','AKO','PODGRUPA','?slot, ' FROM ', ?baza_c, ' WHERE ', FRAME, '=',CONCAT(NUMBER_TO_CHAR(39),?frame,NUMBER_TO_CHAR(39)))
:hdbc=qcConnect('DRV=QEDBF')
:hstmt=qcExecSQL(?hdbc,?sql_izraz)
WHILE qcFetchNext(?hstmt)=0
THEN :=1 AND
:br_kol=3 AND
:br_slot= ?br_kol+?i AND
:iznos_slot=GET_STRING(qcValChar(?hstmt,?br_slot, '' , 0))
:iznos_slot=STRING_REPLACE(?iznos_slot, ',',32767). (* brisanje blankova u stringu*)
:zatvori_sql=qcEndSQL(?hstmt)
:zatvori_kon=qcDisconnect(?hdbc)
IF STRING_LENGTH(?iznos_slot) > 0 (* 1. Iznos slot je različit od nule -> završeno pretraživanje calc slot *)
THEN :lista=STRING_TO_LIST(?iznos_slot,') AND
:br_argumenata=LIST_LENGTH(?lista)-1 AND (* bez naziva funkcije *)
:naziv_fun=ELEMENT(?lista,1) AND (* naziv funkcije npr. NN_Procjena_RM_kaljeno *)
:lp= [] AND
:=0 AND
IF ?br_argumenata > 0
THEN REPEAT
:=?i+1 AND
:lp= REPLACE_ELEMENTS(?lp,[],ELEMENT(?lista,?i+1)) (* stavljanje varijabli iz liste u listu parametara, npr. lista moze biti lp=[mater_v, frame] *)
UNTIL ?i=?br_argumenata.
IF STRING_LENGTH(?iznos_slot)=0
THEN :iznos_calc_slot='-'.
IF STRING_LENGTH(?iznos_slot) > 0
THEN :iznos_calc_slot=DO(?naziv_fun,ELEMENT(?lp,1),ELEMENT(?lp,2),ELEMENT(?lp,3),ELEMENT(?lp,4),ELEMENT(?lp,5),ELEMENT(?lp,6)).
GET_SLOT_CALC_FRAME=?iznos_calc_slot.
END.

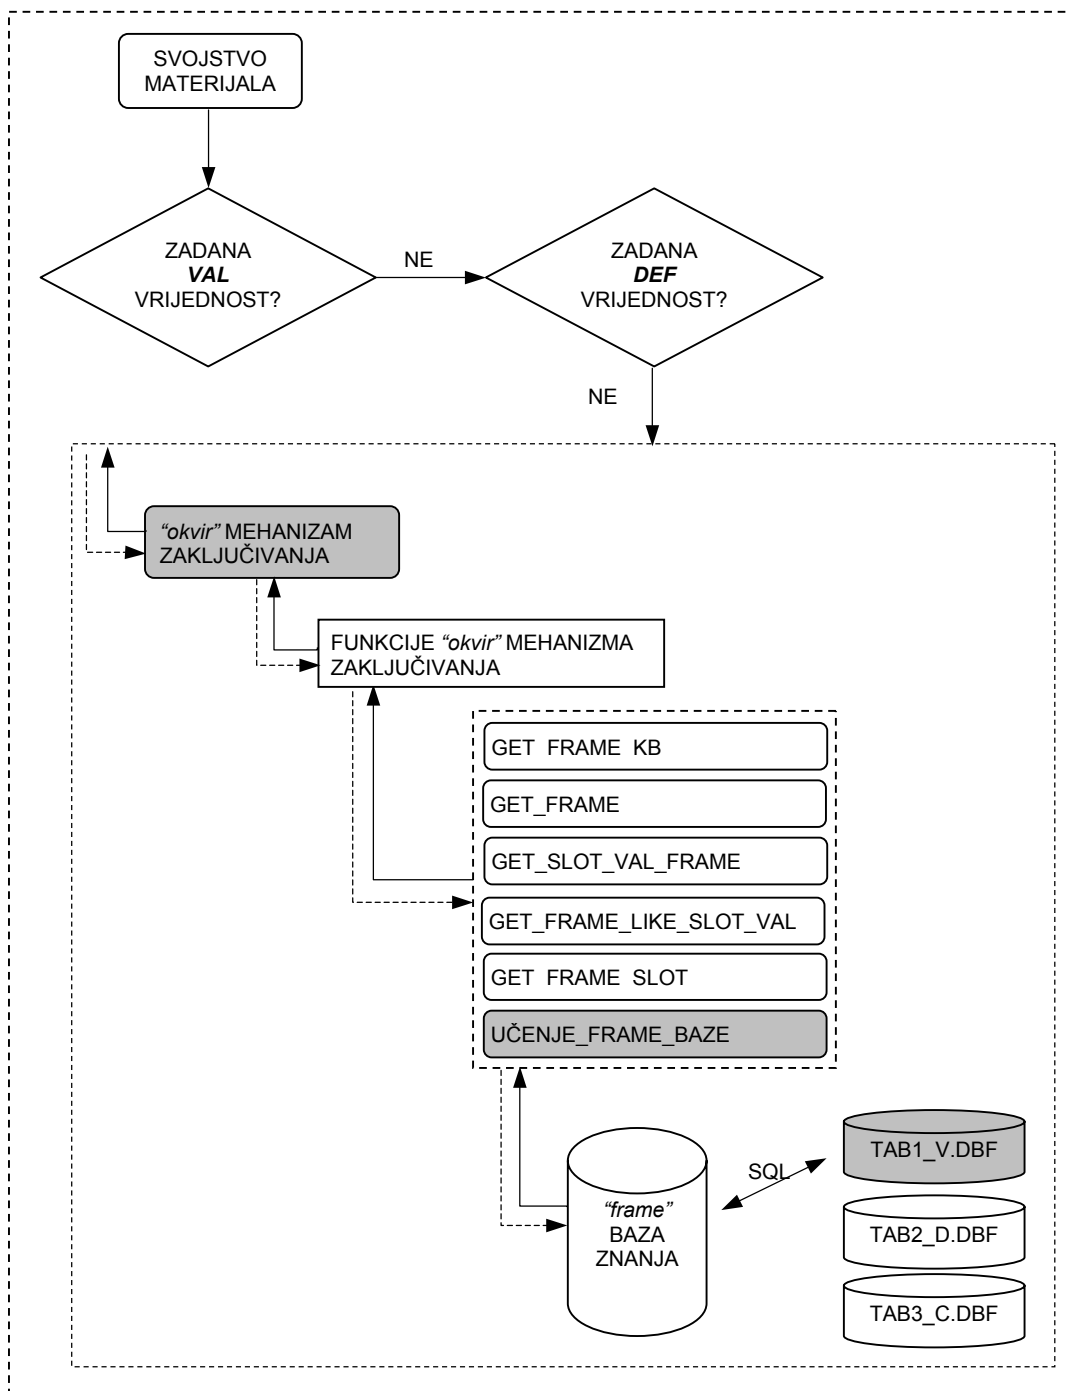
(** PRETRAŽIVANJE RODITELJ FRAME-ova **)
TOPIC GET_SLOT_FROM_PARENTS(baza,frame,slot).
:sql_izraz=CONCAT('SELECT ', 'FRAME','AKO','PODGRUPA','?slot, ' FROM ', ?baza, ' WHERE ', FRAME, '=',CONCAT(NUMBER_TO_CHAR(39),?frame,NUMBER_TO_CHAR(39)))
:hdbc=qcConnect('DRV=QEDBF')
:hstmt=qcExecSQL(?hdbc,?sql_izraz)
WHILE qcFetchNext(?hstmt)=0
THEN :ako_iznos=GET_STRING(qcValChar(?hstmt, 2, '' , 0)) AND
:=1 AND
:br_kol=3 AND
:br_slot= ?br_kol+?i AND
:naziv_slot=GET_STRING(qcColName(?hstmt,?br_slot)) AND
:iznos_slot=GET_STRING(qcValChar(?hstmt,?br_slot, '' , 0))
:iznos_slot=STRING_REPLACE(?iznos_slot, ',',32767). (* brisanje blankova u stringu*)
:zatvori_sql=qcEndSQL(?hstmt)
:zatvori_kon=qcDisconnect(?hdbc)
IF STRING_LENGTH(?iznos_slot) > 0 (* 1. Iznos slot je različit od nule -> završeno pretraživanje roditelj frame-a *)
THEN GET_SLOT_FROM_PARENTS=?iznos_slot
ELSE IF STRING_LENGTH(?iznos_slot)=0 AND ?ako_iznos <> '' (* 2. Iznos slot jednak je nuli -> pretraživanje se radi na temelju iznosa ako slot *)
THEN :iznos_slot=GET_SLOT_FROM_PARENTS(?baza,?ako_iznos,?naziv_slot) (* Rekurzivni poziv ove funkcije *)
ELSE IF STRING_LENGTH(?iznos_slot)=0 AND ?ako_iznos="" (* 3. Slučaj kada nije pronađen iznos zadanog slot preko roditelj frame-a *)
THEN :iznos_slot='-'.
GET_SLOT_FROM_PARENTS=?iznos_slot.
END.
END.

```

Slika 5.25. Prikaz koda funkcije `GET_SLOT_VAL_FRAME`

5.1.8. Princip učenja *okvir* baze znanja

U tijeku eksperimentiranja zamijećena je relativna sporost u radu mehanizma zaključivanja što je posljedica velikog broja operacija računanja, a posebno kod poziva naučene neuronske mreže pomoću funkcija predefiniраниh u CALC pretincu *okvir* baze. Ovaj problema riješen je modeliranjem nezavisnog izvršnog modula koji koristi funkciju `UCENJE_FRAME_BAZE` iz *okvir* mehanizma zaključivanja za unaprijedno izračunavanje procjena svojstva materijala koja nemaju `DEF` vrijednost, a imaju predefiniranu funkciju u CALC pretincu. Na slici 5.26. principiijelna shema opisanog načina učenja *okvir* baze znanja. Prednost je ovog načina učenja *okvir* baze, transparentnost korištenja iste u bilo kojem klasičnom (*'neintelligentnom'*) sustavu.

Slika 5.26. Blok-shema učenja *okvir* baze znanja

Na slici 5.27. prikazan je programski kod funkcije *UCENJE_FRAME_BAZE*.

```

TOPIC UCENJE_FRAME_BAZE.

:hw=WINDOW(,,,100,40,'UČENJE FRAME BAZE ZNANJA MATERILA').
:baza_v=mater_v.
:baza_d=mater_d.
:baza_c=mater_c.
:lista_slotova=[Rm_Kaljeno,Rm_Pobolj,Re_Kaljeno,Re_pobolj,HV_Kaljeno,HV_Pobolj,A5_Kaljeno,
                A5_Pobolj,TR_Kaljeno,TR_Pobolj,CHCOH,HCL,HNO,HPO,HSO,GV,NE_OTPPPOP,NI_OTPPPOP,
                VI_OTPPPOP,TR_OTPPPOP,BC_OTPPPOP,RM_PT,RP02_PT,A5_PT,OBRADLJIVO,ZAVARLJIVO,
                ZILAVOST,ZARDJELOVA,LEGIRANOST].
:lista_framea=GET_FRAME_KB(?baza_v).
:br_framea=LIST_LENGTH(?lista_framea).
:ifr=0.

:br_slotova=LIST_LENGTH(?lista_slotova).
REPEAT
:ifr=?ifr+1 AND
:frame=ELEMENT(?lista_framea,?ifr) AND
:is=0 AND
REPEAT
:is=?is+1 AND
:slot=ELEMENT(?lista_slotova,?is) AND
:slot_iznos=GET_SLOT_VAL_FRAME(?baza_v,?baza_d,?baza_c,?frame,?slot) AND
:INSERT_FRAME_SLOT(?baza_v,?frame,?slot,?slot_iznos) AND
TEXT(CONCAT('FRAME:-> ',?frame),CONCAT('SLOT:-> ',?slot),CONCAT('IZNOS:-> ',?slot_iznos),)
UNTIL ?is=?br_slotova
UNTIL ?ifr=?br_framea.
CLOSE_WINDOW(?hw).
WAIT(,3).

END.

```

Slika 5.27. Prikaz programskog koda funkcije za učenje *okvir* baze znanja

```

UČENJE FRAME BAZE ZNANJA MATERILA
FRAME:-> CL4732
SLOT:-> Rm_Kaljeno
IZNOS:-> 138

FRAME:-> CL4732
SLOT:-> Rm_Pobolj
IZNOS:-> 955

FRAME:-> CL4732
SLOT:-> Re_Kaljeno
IZNOS:-> 408

FRAME:-> CL4732
SLOT:-> Re_pobolj
IZNOS:-> 390

FRAME:-> CL4732
SLOT:-> HV_Kaljeno
IZNOS:-> 39

FRAME:-> CL4732
SLOT:-> HV_Pobolj
IZNOS:-> 280

FRAME:-> CL4732
SLOT:-> A5_Kaljeno
IZNOS:-> 23

FRAME:-> CL4732
SLOT:-> A5_Pobolj
IZNOS:-> 9

FRAME:-> CL4732
SLOT:-> TR_Kaljeno
IZNOS:-> 1

```

Slika 4.28. Primjer učenja *okvir* baze znanja materijala

Na slici 5.28. prikazane je primjer izvođenja učenja *okvir* baze materijala za oznaku ČL4732. Dobiveni iznosi ili procjene pojedinih slotova (svojstava materijala), spremaju se u VAL pretince baze-tablice *mater_v.dbf*.

5.1.9. Primjer načina rada mehanizma za učenje asocijacija

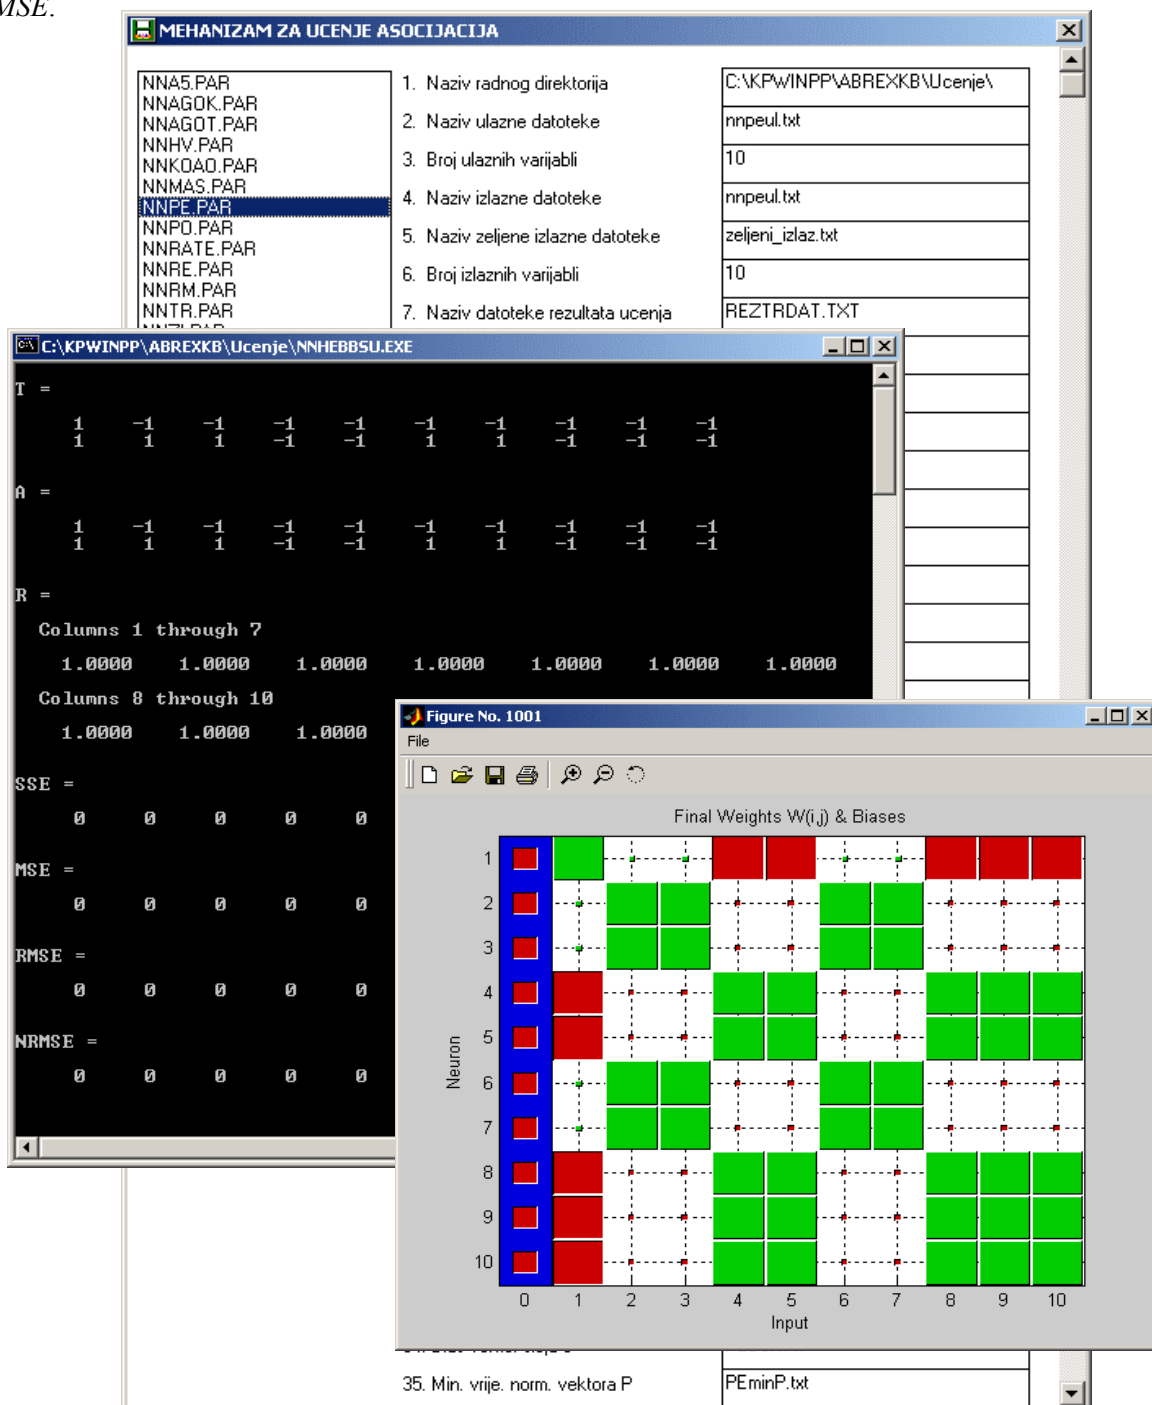
Nakon što je rješenje razmatranog problema od strane korisnika potvrđeno kao zadovoljavajuće sustav sprema vrijednosti vektora potrebnih za učenje asocijacija u tzv. vremenske asocijativne matrice. Na temelju njih moguće je nakon određenog vremena '*osvježiti pamćenje*' sustava, pokretanjem novog procesa učenja pojedinih logičkih dijelova. Na slici 5.29. prikazana je forma mehanizma za učenje asocijacija. Nakon odabira logičke cjeline (neuronske mreže) ① za koju se želi obnoviti asocijacija, potrebno je podesiti parametre ② željenog tipa mreže, spremiti parametre učenja, te pokrenuti proceduru 'Učenje mreže'.

Model	Parametar	Vrijednost
①	1. Naziv radnog direktorija	C:\KPF\WINPP\ABRE\KB\Ucenje\
	2. Naziv ulazne datoteke	nnpeul.txt
	3. Broj ulaznih varijabli	10
	4. Naziv izlazne datoteke	nnpeul.txt
	5. Naziv zeljene izlazne datoteke	zeljeni_izlaz.txt
	6. Broj izlaznih varijabli	10
	7. Naziv datoteke rezultata ucenja	REZTRDAT.TXT
	8. Broj slojeva	1
	9. Broj neurona u prvom sloju	10
	10. Broj neurona u drugom sloju	15
	11. Prijenosna funkcija sloja 1	hardlims
	12. Prijenosna funkcija sloja 2	logsig
	13. Prijenosna funkcija sloja 3	purelin
	14. TIP MREZE	9
	15. Broj epoha između prikaza	25
16. Maksimalni broj epoha	1000	
17. Performance err_goal	1e-15	
18. Learning rate	0.1	
19. Ratio to increase learning rate	1.05	
20. Ratio to decrease learning rate	0.7	
21. Err ratio	1.04	
22. Momentum	0.01	
23. Minimum gradient	1e-10	
24. Initial value for MU	0.050269	
25. Multiplier for increasing MU	10	
26. Multiplier for decreasing MU	0.1	
27. Maximum value for MU	1e10	
28. Datoteka rezultata procjena	REZISDAT.TXT	
29. Matrica tezina sloja 1	PEW1.TXT	
30. Matrica tezina sloja 2	PEW2.TXT	
31. Matrica tezina sloja 3	PEW3.TXT	
32. Bias vektor sloja 1	PEB1.TXT	
33. Bias vektor sloja 2	PEB2.TXT	
34. Bias vektor sloja 3	PEB3.TXT	
35. Min. vrije. norm. vektora P	PEminP.txt	

Slika 5.29. Primjer podešavanja parametara mehanizma za učenje asocijacija

Ako je proces učenja dao zadovoljavajuće rezultate potrebno je stare asocijacije (matrice težina) zamijeniti novim asocijacijama pokretanjem procedure 'Zamjena matrica'. Ugrađena je i mogućnost vraćanja izvornih (početnih) asocijacija pokretanjem procedure 'Vraćanje izvornih matrica'.

Primjer rezultata učenja asocijativne neuronske mreže za procjenu elemenata sustava prikazan je na slici 5.30. Vidljiva je mogućnost nadgledanja vrijednosti indeksa uspješnosti učenja: *SSE*, *MSE*, *RMSE* i *NRMSE*.



Slika 5.30. Prikaz rezultat učenja asocijativne neuronske mreže za procjenu elemenata sustava

5.1.10. Primjer načina rada mehanizma za objašnjavanje rješenja

Zadatak sustava je procjena prikladnih postupaka (slojeva) modificiranja površina te prikladnih materijala za nanošenje slojeva za zadane radne uvjete. Kvaliteta objašnjenja rješenja ovisiti će u prvome redu o kvaliteti odgovora koje sustav dobiva u tijeku konverzacije sa korisnikom. Najkvalitetnije objašnjenje rješenje problema dobiva se u slučajevima kada je konverzacija sa korisnikom sprovedena do kraja. Lošija kvalitete dobiva se ako je konverzacija nakon određenog vremena prekinuta, dok se nalošije objašnjenje

dobiva u slučaju kada konverzacija uopće nije sprovedena, a zbog potrebe inicijalizacije asocijacija koje mogu bit pogrešne, posebice u početnim stadijima rada sustava.

MEHANIZAM ZA OBJASNJAVANJE RJESENJA

PRIKUPljeni SU SVI RELEVANTNI PODACI OD OD KORISNIKA TE SE ZAKLJUČUJE SLJEDEĆE:

TIP TROŠENJA JE: **ABRAZIVNO-TROTIJELNO**

MEHANIZMI TROŠENJA POREDANI PO VAŽNOSTI SU SLJEDEĆI:

1-ABRAZIJA
1-UMOR POVRŠINE
2-TRIBOKOROZIJA
3-ADHEZIJA

PRIMJER FOTOGRAFIJA ISTROŠENIH POVRŠINA:

Tip i dominantni mehanizam trošenja

Primjer istrošenih dijelova

S OBZIROM DA JE TIP TROŠENJA **ABRAZIVNO-TROTIJELNO** A DOMINANTNI MECHANIZAM TROŠENJA **1-ABRAZIJA** PREDLAŽU SE SLJEDEĆI POVRŠINSKI SLOJEVI:

BORIRANI SLOJEVI
SLOJEVI SAMOTEKUCIH LEGURA
SLOJEVI METALNIH KARBIDA
SLOJEVI METALNIH OKSIDA
SLOJEVI LEGURA NA BAZI Fe
CVD-SLOJEVI NA BAZI Ti
CVD-SLOJEVI NA BAZI Al₂O₃
CVD-SLOJEVI NA BAZI Ti(C,N)
SLOJEVI MATERIJALA SLIČNIH ČELIKU
NAVARENI DISPERGIRANI I LEGIRANI SLOJEVI

S OBZIROM DA JE AGRESIVNOST OKOLIŠA **SREDNJA** OD PREDLOŽENIH POVRŠINSKIH SLOJEVA, SLOJEVI OTPORNI DJELOVANJE KOROZIJE SU:

SLOJEVI METALNIH KARBIDA
SLOJEVI METALNIH OKSIDA
SLOJEVI LEGURA NA BAZI Fe

Prikladni slojevi i postupci modificiranja

MEHANIZAM ZA OBJASNJAVANJE RJESENJA

CVD-SLOJEVI NA BAZI Ti
CVD-SLOJEVI NA BAZI Al₂O₃
CVD-SLOJEVI NA BAZI Ti(C,N)
SLOJEVI MATERIJALA SLIČNIH ČELIKU
NAVARENI DISPERGIRANI I LEGIRANI SLOJEVI

S OBZIROM DA JE AGRESIVNOST OKOLIŠA **SREDNJA** OD PREDLOŽENIH POVRŠINSKIH SLOJEVA, SLOJEVI OTPORNI DJELOVANJE KOROZIJE SU:

SLOJEVI METALNIH KARBIDA
SLOJEVI METALNIH OKSIDA
SLOJEVI LEGURA NA BAZI Fe
CVD-SLOJEVI NA BAZI Ti(C,N)

DOK SU ALTERNATIVNI SLOJEVI:

BORIRANI SLOJEVI

OTPORNOST PREDLOŽENIH POVRŠINSKIH SLOJEVA POJEDINIM MECHANIZMIMA TIPOVIMA TROŠENJA JE SLJEDEĆA:

SLOJEVI METALNIH KARBIDA
Pogodna primjena: ABRAZIJA-slaba, IZJEDANJE
Moguća primjena: ADHEZIJA-slaba, ABRAZIJA-jaka

SLOJEVI METALNIH OKSIDA
Pogodna primjena: ABRAZIJA-slaba, IZJEDANJE
Moguća primjena: ADHEZIJA-slaba, ABRAZIJA-jaka

SLOJEVI LEGURA
Pogodna primjena: ABRAZIJA-slaba, ABRAZIJA-jaka, IZJEDANJE
Moguća primjena: ADHEZIJA-slaba, ADHEZIJA-jaka, EROZIJA-cesticama

CVD-SLOJEVI NA Ti(C,N) OSNOVI
Pogodna primjena:
Moguća primjena:

PREDLAŽU SE SLJEDEĆE STANDARDNE OZNAKE MATERIJALA KAO OSNOVA ZA NANOŠENJE SLOJA:

BORIRANI SLOJEVI
ČELIČNI LIJEV: CL3160 ,CL4150
ČELICI ZA CEMENTIRANJE: C4320 ,C7420
ČELICI ZA POBOLJŠAVANJE: C3135 ,C4730 ,C5430
ALATNI ČELICI: C5742

Prikladni nosivi materijali sloja

A S OBZIROM NA UNEŠENI NAZIV PRIMJENE, PREDLAŽU SE SLJEDEĆE STANDARDNE OZNAKE:

CL
LM690
CL4780
CL4782

Slika 5.31. Primjer objašnjenja rješenja problema

MEHANIZAM ZA OBJASNJAVANJE RJESENJA

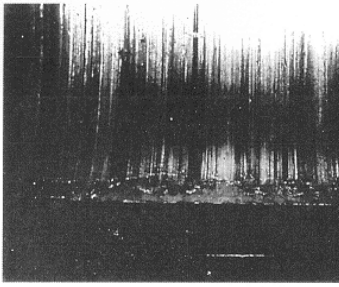
PRIKUPLJENI SU SVI RELEVANTNI PODACI OD OD KORISNIKA TE SE ZAKLJUČUJE SLJEDEĆE:

TIP TROŠENJA JE: **ABRAZIVNO-TROTIJELNO**

MEHANIZMI TROŠENJA POREDANI PO VAŽNOSTI SU SLJEDEĆI:

1-ABRAZIJA
1-UMOR POVRŠINE
2-TRIBOKOROZIJA
3-ADHEZIJA

PRIMJER FOTOGRAFIJA ISTROŠENIH POVRŠINA



S OBZIROM DA JE TIP TROŠENJA ABRAZIVNO-PREDLAŽU SE SLJEDEĆI POVRŠINSKI SLOJEVI

BORIRANI SLOJEVI
SLOJEVI SAMOTEKUCIJSKIH LEGURA
SLOJEVI METALNIH KARBIDA
SLOJEVI METALNIH OKSIDA
SLOJEVI LEGURA NA BAZI Fe
CVD-SLOJEVI NA BAZI Ti
CVD-SLOJEVI NA BAZI Al₂O₃
CVD-SLOJEVI NA BAZI Ti(C,N)
SLOJEVI MATERIJALA SLIČNIH CELIKU
NAVARENI DISPERGIRANI I LEGIRANI SLOJEVI

S OBZIROM DA JE AGRESIVNOST OKOLIŠA SR POVRŠINSKIH SLOJEVA, SLOJEVI OTPORNI DJ

SLOJEVI METALNIH KARBIDA
SLOJEVI METALNIH OKSIDA
SLOJEVI LEGURA NA BAZI Fe

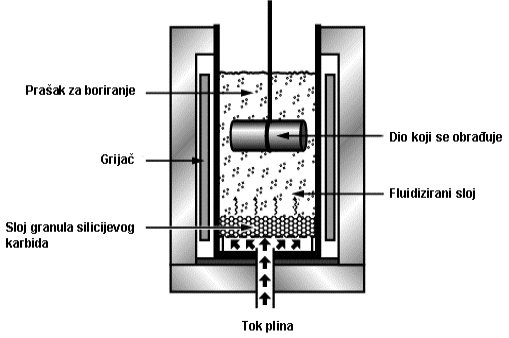
MEHANIZAM OBJASNJAVANJA POJMOVA

2.2 BORIRANI SLOJEVI

1. **Zahtjev za primjenom**
Ekstremni uvjeti trošenja u eksploataciji: abrazija, adhezija, umor površine.

2. **Definicija postupka**
Boriranje je postupak toplinsko-kemijske obradbe kojim se u površinu celika difundira kemijski element bor (B). Struktura površinskog sloja sastoji se od Fe-borida (Fe₂B ili FeB).

3. **Karakteristike i shema postupka**
Na slici je prikazan shema postupka boriranja u prasku koji se provodi na temperaturi od 800 - 1100 °C. Boriranje je razmjerno skup postupak visokih troškova ručnog rada (pakiranje-raspakiranje dijelova, podmazivanje pastom, čišćenje itd.). Provodi se u pravilu kada jeftinije udovoljava zahtjevima trošenja.



4. **Zahtjevi uvjetovani konstrukcijom obradka**
-obradci koji se boriraju ne smiju imati oštrih ivica te ih treba ih skositi, jer može doći do pucanja istih zbog porasta volumena.
-djelomično boriranje se ne preporučuje i skuplje je u odnosu na cjelovito boriranje zbog troškova prekrivanja zona boriranja.

5. **Troškovi**

5.1. Cijena postupka:
-visoka, zbog troškova ručnih radova (pakiranje i raspakiranje dijelova, premazivanje pastom, čišćenje itd.).

5.2. Cijena u odnosu na druge postupke:
-nitiranje, boriranje.

6. **Materijali obradka**

I Z L A Z

Slika 5.32. Primjer opisa procijenjenog postupka modificiranja površina

Na slici 5.32 prikazan primjer objašnjenja rješenja problema za slučaj kada konverzacija uopće nije sprovedena, što znači da od strane korisnika nije dan odgovor niti na jedno pitanje. Međutim, zbog početnih realnih vrijednosti ulaznih varijabli uključenih u vremenske asocijativne matrice, sustav daje suvislo objašnjenje rješenja problema. Također treba napomenuti, da kvaliteta objašnjenja problema unatoč sprovedenoj konverzaciji, ovisi i o količini ispravaka koje sustav mora učiniti ukoliko korisnik unosi (namjerno ili nenamjerno!) pogrešne odgovore ili nesigurne odgovore.

Nakon procjene prikladnog postupka modificiranja površina, korisnik pomoću mehanizma za objašnjavanje pojmova može iz baze znanja dobiti cjelokupan opis i karakteristike postupka, kao što je prikazano na slici na slici 5.32.

6. RASPRAVA O REZULTATIMA ISTRAŽIVANJA

6.1. Rasprava o rezultatima istraživanja

6.1.1. Osvrt na primjenu softverskih alata

U radu su korišteni sljedeći softverski alati umjetne inteligencije:

1. Alat za ekspertne sustave: **KnowledgePro[®] for Windows**, Ver. 3.0, američke firme *The Knowledge Garden Inc.*
2. Alat za neuronske mreže: **Neural Network Toolbox** for use with Matlab[®], Ver. 4.0, američke firme *The Mathworks Inc.*
3. Alat za *fuzzy logic* i *NeuroFuzzy*: **Fuzzy Logic Toolbox** for use with Matlab[®], Ver. 2.0, američke firme *The Mathworks Inc.*
4. Alat za genetičke algoritme: **Genetic Search Toolbox** for use with Matlab[®], Ver. 1.01, američke firme *The Optimal Synthesis Inc.*

KnowledgePro[®] for Windows – s ovim alatom uspješno je postignut glavni cilj rada, a to je izgradnja poboljšanog mehanizma zaključivanja inteligentnog sustava za izbor materijala. Pomoću njega izgrađeni su sljedeći glavni mehanizmi zaključivanja: mehanizam za konverzaciju s korisnikom, mehanizam za objašnjavanje pitanja i pojmova pri konverzaciji, mehanizam za donošenje rješenja, mehanizam za objašnjavanje rješenja, mehanizam za kontrolu poziva naučenih neuronskim mreža i naučenih mehanizama zaključivanja neizrazite logike. Glavni problem u radu s ovim alatom predstavljao je nedostatak tzv. *stack* memorije. Alat je izvorno namijenjen razvoju inteligentnih aplikacija u nešto starijoj 16-bitnoj razvojnoj okolini koja alocira manje memorije za deklaraciju varijabli za razliku od današnjih 32-bitnih okolina. Ovaj nedostatak alata značajno dolazi do izražaja kod izgradnje hibridnih inteligentnih sustava kod kojih postoji veliki broj interakcija između modula. Ovaj problem je riješen pisanjem (programiranjem) tzv. optimiziranog koda ali uz znatno produljenje vremena razvoja.

Neural Network Toolbox – eksperimentirano je sa tri grupe neuronskih mreža koje su integrirane unutar ovog alata: perceptronska, *backpropagation* i asocijativna neuronska mreža. Ukupni broj algoritama s kojima se eksperimentiralo je jedanaest:

Algoritmi perceptronske mreže:

- perceptron (*NNP*),
- Widrow-Hoff algoritam (*NNWH*).

Algoritmi backpropagation mreže:

- klasičan *backpropagation* algoritam ili algoritam najstrmijeg pada (*NNB*),
- *backpropagation* algoritam sa momentumom (*NNBM*),
- *backpropagation* algoritam sa adaptivnim koeficijentom brzine učenja (*NNBA*),
- *backpropagation* algoritam sa adaptivnim momentumom i adaptivnim koeficijentom brzine učenja (*NNBMA*).
- Levenberg-Marquardt algoritam (*NNLM*).

Algoritmi asocijativne mreže:

- nenadzirani Hebb-ov algoritam sa koeficijentom brzine učenja i faktorom zaboravljanja (*NNHEBBUN*),
- nadzirani Hebb-ov algoritam sa koeficijentom brzine učenja i faktorom zaboravljanja (*NNHEBBSU*),
- Grossbergov *instar* nadzirani algoritam sa koeficijentom brzine učenja (*NNINSSU*),
- Grossbergov *outstar* nadzirani algoritam sa koeficijentom brzine učenja (*NNOUTSU*).

Zbog problema sa ‘*net*’ objektom opisanog u točki 4.3.1, svi navedeni algoritmi iznova su prekodirani i prekompilirani u nove algoritme bez ‘*net*’ objekta. Kompilirane ili tzv. ‘*EXE*’ verzije algoritama potrebne su zbog integracije u mehanizam zaključivanja zamišljenog sustava.

Rad ‘novih’ algoritama bez ‘*net*’ objekta, provjeren je na primjerima iz stručne literaturne te nisu uočena značajnija odstupanja.

Fuzzy Logic Toolbox – u radu je eksperimentirano sa klasičnim *Mamdani* algoritmom, te *Sugeno* algoritmom koji uključuje *backpropagation* neuronsku mrežu za optimiranje *fuzzy* skupova. Rezultat modeliranja neizrazitog sustava unutar razvojne okoline alata je tzv. *FIS* –*fuzzy* mehanizma zaključivanja. *FIS* je samostalni modul kojeg je moguće uključivati te pozivati (pomoću *fismain.exe* modula) iz drugih modula. Prilikom eksperimentiranja sa navedenom verzijom alata, uočen je problem u radu *fismain.exe* modula nakon što bi uslijedio prvi zahtjev za ispravkom i spremanjem promjena već modeliranog *FIS*-a. Zbog pogreške u nekoj od procedura u razvojnoj okolini alata, ne dolazi pravilnog spremanja vrijednosti varijable koja sadrži podatak o eksplicitno zadanoj metodi defazifikacije, već se kao zadana vrijednost sprema predefinirana vrijednost. Nakon dojave pogreške proizvođaču alata, ista je ispravljena u novoj verziji alata.

Genetic Search Toolbox – Nakon podosta vremena provedenog u ‘ručnom’ ugađanju parametara i učenja neuronske mreže te dobivanja loše generalizacije rješavanog problema, zaključeno je da je prijeko potrebna primjena ‘automatiziranog’ ugađanja parametara. Zbog toga je glavna svrha primjene ovog alata ugađanje parametara algoritama nabrojanih neuronskih mreža. Nakon integracije alata sa algoritmima neuronskih mreža generalizacija problema se značajno poboljšala. Nisu uočene nepravilnosti ili pogreške u radu alata.

6.1.2. Osvrt na procjene *backpropagation* neuronskih mreža

1. Procjena elemenata tribosustava

Procjena elemenata sustava najvažnija je procjena u nizu, jer od njezina rezultata ovise rezultati procjena koje slijede. Ulazno-izlazni skup podataka čini matrica od 10x17 elemenata sa mapiranim vrijednostima unutar intervala [-1, 1]. Primjenjena je asocijativna neuronska mreža sa *HEBBUN*, *HEBBSU* i *NNINSU* algoritmina. Izvršena je optimalizacija parametara algoritama primjenom *GA* (tablice 4.1., 4.2., i 4.3.). Prema tablici 4.3. uočljiv je nizak *NRMSE* kod svih ulazno-izlaznih varijabli iz skupa za učenje. Prema razmatranjima o stabilnosti asocijativnih algoritama u točki 4.4.2, te prema rezultatima (najviša *p*-vrijednost pri točnosti $\mu_o=99\%$) u tablici 4.5., izabran je *HEBBSU* asocijativni algoritam za procjenu elemenata sustava.

2. Procjena tipa trošenja

Ulazni skup za učenje za procjenu tipa trošenja čine podaci o elementima sustava te relativnom gibanju tj. matrica od 10x17 elemenata mapiranih unutar intervala [-1, 1]. Izlazni skup čine podaci o tipu trošenja tj. matrica 15x17 elemenata mapiranih po principu *I-od-C*. Primjenjena je perceptronska neuronska mreža sa *NNP* algoritmom. U ovom slučaju nije izvršena optimalizacija parametara mreže, jer se *NNP* algoritam u kombinaciji sa *I-od-C* principom mapiranja pokazao kao vrlo dobar. U slučaju pravilne procjene elemenata sustava očekuje se 100% točnost procjene tipa trošenja. To potvrđuje *NRMSE* indeks u tablici 4.6. koji za sve tipove trošenja ima vrijednost 0.

3. Procjena mehanizma trošenja

Kao i kod procjene tipa trošenja, ulazni skup za procjenu mehanizma trošenja čine podaci o elementima sustava te relativnom gibanju tj. matrica od 10x17 elemenata mapiranih unutar intervala [-1, 1]. Izlazni skup čini matrica od 4x17 elemenata koji predstavljaju ocjene dominantnosti pojedinih mehanizama trošenja. Primjenjena je *backpropagation* neuronska mreža sa *NNBMA* i *NNLM* algoritmima. Prije procesa učenja izvedena je normalizacija izlazne matrice prema izrazu (2.101). Također nije potrebno optimalizirati parametare mreže, jer su niske vrijednosti *NRMSE* indeksa (tablica 4.8.) postignute ‘ručnim’ ugađanjem parametara. U ovom slučaju bolja generalizacija skupa za učenje postiže se primjenom *NNLM* algoritma.

4. Procjena prikladnog površinskog sloja

Ulazni skup podataka za učenje procjene prikladnog površinskog sloja čini matrica od 5x15 elemenata. Elementi prve kolone matrice predstavljaju tip trošenja, dok preostale četiri kolone predstavljaju ocjene dominantnosti pojedinih mehanizama trošenja. Izlazni skup podataka čini matrica od 31x15 elemenata sa mapiranim vrijednostima unutar intervala [-1, 1]. Kolone matrice izlaznog skupa podataka predstavljaju vrste površinskih slojeva. U ovom slučaju mapiranje izlaznog skupa podataka izvedeno je po digitalnom principu (+1=DA, -1=NE), zbog toga što jednom tipu trošenja odgovara više prikladnih površinskih slojeva tj. postupaka modificiranja površina. Također se od ove procjene očekuje 100% točnost određivanja prikladnih površinskih slojeva, uz uvjet prethodne 100% točnosti procjene tipa trošenja i 100% točnosti

određivanja procjene dominantnosti pojedinih mehanizama trošenja. Kao što se vidi u tablici 4.9., izabrana aktivacijska funkcija prvog sloja je ‘*tansig*’, zbog čega je i izvedena normalizacija elemenata ulazne matrice. Iz tablice 4.9. vidljivo je, da je uključivanjem metode ‘*ranog zaustavljanja*’ kao metode za poboljšanje generalizacije izlaznog skupa podataka, postignuta pretpostavljena 100% točnost procjene prikladnih površinskih slojeva. $NRMSE=0$, postignut je izborom adaptivnog *NNBMA* algoritma bez optimalizacije parametara *GA*-algoritmima.

5. Procjena prikladnog površinskog sloja otpornog koroziji

Ulazni skup podataka čini matrica od 4x4 elemenata čije vrijednosti po principu *1-od-C* mapiranja, predstavljaju razrede otpornosti koroziji. Izlazni skup podataka čini matrica od 13x4 elemenata. Kolone izlazne matrice čine ocjene otpornosti razredima korozije pojedinih površinskih slojeva. Zbog načina mapiranja ulaznog skupa, izabrana aktivacijska funkcija prvog sloja je ‘*logsig*’. Izvedena je normalizacija izlaznog skupa podataka, te je izabrana ‘*purelin*’ kao aktivacijska funkcija izlaznog sloja. $NRMSE=0$, postignut je izborom adaptivnog *NNBMA* algoritma bez optimalizacije parametara *GA*-algoritmima i uključivanja metode za poboljšanje generalizacije (tablica 4.10.).

6. Procjena prikladnog površinskog sloja otpornog trošenju

Ulazni skup podataka čini matrica od 13x13 elemenata čije vrijednosti po principu *1-od-C* mapiranja, predstavljaju prikladne površinske slojeve otporne trošenju. Izlazni skup podataka čini matrica od 6x13 elemenata. Kolone ove matrice predstavljaju ocjene podobnosti primjene pojedinog tipa trošenja pojedinim mehanizmima trošenja. Zbog načina mapiranja ulaznog skupa, izabrana aktivacijska funkcija prvog sloja je ‘*logsig*’. Izvedena je normalizacija izlaznog skupa podataka, te je izabrana ‘*purelin*’ kao aktivacijska funkcija izlaznog sloja. $NRMSE=0$, postignut je izborom adaptivnog *NNBMA* algoritma bez optimalizacije parametara *GA*-algoritmima i uključivanja metode za poboljšanje generalizacije (tablica 4.11.).

7. Grupa procjena kemijske postojanosti čelika

Ulazni skup podataka za procjenu kemijske postojanosti čelika temelji se na tri grupe podataka: kemijskom sastavu, masenom udjelu otopine i temperaturi otopine. Izlazni skup podataka predstavljaju ocjene postojanosti određenoj kemijskoj otopini. Određivane su procjene za sljedeće kemijske čiste otopine: nitratna (HNO_3), fosfatna (H_3PO_4), octena (CH_3COOH) i kloridna (HCl). U ovom slučaju nije potrebno mapiranje ulazno-izlaznih skupova podataka. U tablici 6.1 prikazane su veličine ulazno-izlaznih matrica za učenje i testiranje procjena kemijske postojanosti čelika.

Tablica 6.1. Veličine ulazno-izlaznih matrica za procjenu kemijske postojanosti čelika

Vrsta otopine	Učenje		Validacija/Testiranje	
	ulaz	izlaz	ulaz	izlaz
HNO_3	8x133	1x133	8x67	1x67
H_3PO_4	8x70	1x70	8x32	1x32
CH_3COOH	8x42	1x42	8x21	1x21
HCl	8x56	1x56	8x28	1x28
H_2SO_4	8x210	1x210	8x105	1x105

Treba napomenuti da je pri određivanju ovih procjena na raspolaganju dovoljna količina podataka za definiciju ulazno-izlaznih skupova, tako da je od raspoložive količine 50% podataka izuzeto za učenje, 25% za validaciju i 25% za testiranje neuronske mreže. U svim slučajevima procjena izvedena je normalizacija ulazno-izlaznih podataka, te je primjenjena metoda ‘*ranog zaustavljanja*’ za poboljšanje generalizacije. Također su u svim slučajevima primjenjeni *GA*-algoritmi za optimalizaciju parametara algoritama neuronskih mreža. Kao što se vidi prema tablicama 4.12. do 4.21., rezultat je vrlo niski *NRMSE* indeks kako na skupovima za učenje, tako i na skupovima za testiranje, te se zaključuje da je postignuta vrlo dobra generalizacija. U većini slučajeva ove grupe procjena, najbolji rezultati postižu se primjenom *NNBMA* algoritma.

8. Procjena otpornosti abraziji gubitkom volumena

Kao i kod prethodne procjene, i kod ove procjene ulazno-izlazni podaci podijeljeni su na podatke za učenje, validaciju i podatke za testiranje u omjerima 50:25:25. Ulazni skup podataka za učenje čini matrica od 10x26 elemenata koji predstavljaju kemijski sastav i temperaturu popuštanja, a izlazni skup za učenje čini matrica od 1x26 elemenata koji predstavljaju gubitak volumena. Ulazni skup podataka za

testiranje čini matrica od 10x13 elemenata, a izlazni skup za testiranje čini matrica od 1x13 elemenata. Značenje elemenata matrica kod skupa za testiranje je kao kod skupa za učenje. Izvedena je normalizacija ulazno-izlaznih podataka, te je primjenjena metoda ‘*ranog zaustavljanja*’ za poboljšanje generalizacije. Također su primjenjeni GA-algoritmi za optimalizaciju parametra algoritama neuronskih mreža. Prema tablici 4.23., prema *NRMSE* indeksu za testni skup podataka, najbolja se generalizacija postiže *NNLM* algoritmom.

9. Grupa procjena otpornosti popuštanju alatnih čelika na temelju parametara popuštanja

Ulazni skup podataka za ovu grupu procjena čine podaci o kemijskom sastavu i parametru popuštanja, a izlazni skup čine iznosi HRC tvrdoća. Također su ulazno-izlazni podaci podijeljeni su na podatke za učenje, validaciju i podatke za testiranje u omjerima 50:25:25. U tablici 6.2. prikazane su veličine ulazno-izlaznih matrica za učenje i testiranje za pojedine grupe alatnih čelika.

Tablica 6.2. Veličine ulazno-izlaznih matrica za procjenu otpornosti popuštanju alatnih čelika

Grupa alatnih čelika	Učenje		Validacija/Testiranje	
	ulaz	izlaz	ulaz	izlaz
Nelegirani alatni čelici za hladni rad	6x23	1x23	6x11	1x11
Niskolegirani alatni čelici za hladni rad	6x57	1x57	6x28	1x28
Visokolegirani alatni čelici za hladni rad	6x41	1x41	6x20	1x20
Alatni čelici za topli rad	6x42	1x42	6x21	1x21
Brzorezni čelici	6x76	1x76	6x38	1x38

U svim slučajevima procjena izvedena je normalizacija ulazno-izlaznih podataka, te je primjenjena metoda ‘*ranog zaustavljanja*’ za poboljšanje generalizacije. Također su u svim slučajevim primjenjeni GA-algoritmi za optimalizaciju parametra algoritama neuronskih mreža. Kao što se vidi prema tablicama 4.24. do 4.33., rezultat je vrlo niski *NRMSE* indeks kako na skupovima za učenje, tako i na skupovima za testiranje, te se zaključuje da je postignuta vrlo dobra generalizacija. U većini slučajeva ove grupe procjena, najbolji rezultati postižu se primjenom *NNLM* algoritma.

10. Procjena mehaničkih svojstava alatnih čelika pri povišenim temperaturama

Ulazno-izlazni podaci podijeljeni su na podatke za učenje, validaciju i podatke za testiranje u omjerima 50:25:25. Ulazni skup za učenje čini matrica od 10x33 elemenata koji predstavljaju kemijski sastav. Izlazni skup čini matrica od 3x33 elemenata čije kolone predstavljaju sljedeća mehanička svojstva: R_m , $R_{p0,2}$ i A_5 . Ulazni skup za validaciju i testiranje čini matrica 10x16 elemenata, a izlazni skup matrica od 3x16 elemenata. Izvedena je normalizacija ulazno-izlaznih podataka, te je primjenjena metoda ‘*ranog zaustavljanja*’ za poboljšanje generalizacije. Također su primjenjeni GA-algoritmi za optimalizaciju parametra algoritama neuronskih mreža. Prema tablici 4.35., prema *NRMSE* indeksu za testni skup podataka najbolja se generalizacija postiže *NNLM* algoritmom.

6.1.3. Rekapitulacija parametara procjena *backpropagation* neuronskih mreža

U tablici 6.3. prikazana je rekapitulacija parametara procjena dobivenih neuronskim mrežama na temelju kojih se za problematiku razmatranu ovim radom može zaključiti:

1. Podjednako su uspješni *NNBMA* i *NNLM backpropagation* algoritmi neuronskih mreža.
2. Od asocijativnih algoritama najuspješniji je *HEBBSU* algoritam.
3. Broj slojeva uobičajeno iznosi 3, čime je dokazana tvrdnja iz već naveden literature da su tri sloja neurona dovoljna za rešavanje većine nelinearnosti tehničkih sustava.
4. Broj neurona u 1. sloju kreće se od 4 do 26, a u 2. sloju od 6 do 31.
5. Koeficijent brzine učenja kreće se približno od 0,1 do 0,7.
6. Momentum se kreće približno od 0,01 do 0,9.
7. μ koeficijent *NNLM* algoritma kreće se približno od 0,01 do 0,9.
8. U prvom i drugom sloju aktivacijske funkcije su većinom *sigmoidalno*, a u vanjskom sloju *linearnog* tipa.
9. Maksimalni broj epoha učenja uz primjenu *GA* optimalizacije parametara mreže je 100000, a u većini slučajeva iznosi 10000.
10. Primjenom *GA* optimalizacije parametara neuronske mreže, uz normalizaciju ulazno-izlaznih skupova, dijeljenja raspoloživog skupa podataka na skup za učenje, validaciju i testiranje, te uz primjenu metode ‘*ranog zaustavljanja*’ dobiva se vrlo dobra generalizacija procjena označenih rednim brojevima od 7 do 18 u tablici 6.3.

Tablica 6.3. Rekapitulacija parametara procjena *backpropagation* neuronskih mreža

Red. broj	Tablica	Naziv procjene	Tip mreže	bs	bns1	bns2	bns3	lr	mc	mu	afs1	afs2	afs3	Broj epoha	GA optimalizacija	Normalizacija	Rano zaustavljanje
1.	4.2.	Procjena elemenata sustava	HEBBSU	1	10	10	-	-	-	0.05	hardlims	-	-	100000	da	ne	ne
2.	4.6.	Procjena tipa trošenja	NNP	1	15	-	-	-	-	-	hardlim	-	-	5000	ne	ne	ne
3.	4.8.	Procjena mehanizma trošenja	NNLM	3	4	8	4	-	-	0.01	tansig	tansig	purelin	10000	ne	izlaz	ne
4.	4.9.	Procjena prikladnog površinskog sloja	NNBMA	2	26	31	-	0.1	0.9	-	tansig	purelin	-	5000	ne	ulaz	da
5.	4.10.	Procjena prikladnog površinskog sloja otpornog koroziji	NNBMA	2	8	13	-	0.01	0.9	-	logsig	purelin	-	5000	ne	izlaz	ne
6.	4.11.	Procjena prikladnog površinskog sloja otpornog trošenju	NNBMA	2	8	6	-	0.01	0.9	-	logsig	purelin	-	5000	ne	izlaz	ne
		Procjena kemijske postojanosti čelika															
7.	4.13.	- CH ₃ COOH	NNLM	3	9	10	1	-	-	0.910468	tansig	tansig	purelin	10000	da	ulaz-izlaz	da
8.	4.15.	- HCl	NNLM	3	8	8	-	-	-	0.507515	tansig	tansig	purelin	10000	da	ulaz-izlaz	da
9.	4.16.	- HNO ₃	NNBMA	3	9	7	1	0.105833	0.494056	-	tansig	tansig	tansig	10000	da	ulaz-izlaz	da
10.	4.18.	- H ₃ PO ₄	NNBMA	3	9	8	1	0.789554	0.244581	-	tansig	tansig	tansig	10000	da	ulaz-izlaz	da
11.	4.20.	- H ₂ SO ₄	NNBMA	3	9	7	1	0.291655	0.607293	-	tansig	tansig	tansig	10000	da	ulaz-izlaz	da
12.	4.23.	Procjena otpornosti trošenju abraziji gubitkom volumena	NNLM	3	9	9	1	-	-	0.300376	tansig	tansig	tansig	10000	da	ulaz-izlaz	da
		Procjena otpornosti popuštanju alatnih čelika na temelju parametara popuštanja															
13.	4.24.	- Nelegirani alatni čelici za hladni rad	NNBMA	3	7	8	1	0.205578	0.292776	-	tansig	tansig	purelin	10000	da	ulaz-izlaz	da
14.	4.27.	- Niskolegirani alatni čelici za hladni rad	NNLM	3	9	5	1	-	-	0.161733	tansig	logsig	purelin	10000	da	ulaz-izlaz	da
15.	4.28.	- Visokolegirani alatni čelici za hladni rad	NNBMA	3	8	9	1	0.726780	0.254535	-	purelin	tansig	purelin	10000	da	ulaz-izlaz	da
16.	4.31.	- Alatni čelici za topli rad	NNLM	3	8	7	1	-	-	0.644146	tansig	tansig	purelin	10000	da	ulaz-izlaz	da
17.	4.33.	- Brzorezni čelici	NNLM	3	10	6	1	-	-	0.447066	tansig	tansig	purelin	10000	da	ulaz-izlaz	da
		Procjena mehaničkih svojstava alatnih čelika pri povišenim temperaturama															
18.	4.35.	- R _m - R _{p0,2} - A ₅	NNLM	3	10	9	3	-	-	0.300376	tansig	tansig	purelin	10000	da	ulaz-izlaz	da

Legenda:

- bs** -broj slojeva
- bns_x** -broj neurona sloja x
- lr** -koeficijent brzine učenja
- mc** -momentum
- mu** -koeficijent adaptacije kod *NNLM* ili koeficijent zaboravljanja kod *HEBBSU*
- afs_x** -aktivacijska funkcija sloja x
- NNP** -Perceptronska mreža
- HEBBSU** -*Hebb*-ova mreža uz nadzor učitelja
- NNBMA** -*Backpropagation* mreža sa adaptivnim učenjem
- NNLM** -Levenberg-Marquardt mreža

6.1.4. Osvrt na procjene neizrazite logike

Neizrazitom logikom procjenjuju se mehanička svojstva čelika i čeličnog lijeva u kaljenom i poboljšanom stanju. Modelirani su FIS-ovi za procjenu sljedećih svojstava: vlačna čvrstoća- R_m , granica razvlačenja- R_e , tvrdoća po *Vickers-u-HV*, istezljivost- A_5 i otpornost trošenju. Također su modelirani FIS-ovi za procjenu primarnih zahtjeva na alatne čelike: otpornost trošenju, otpornost popuštanju i žilavost. Glavni razlog primjene metoda neizrazite logike je relativno mali broj ulazno-izlaznih skupova (slogova) podataka za učenje i testiranje, zbog čega primjena metoda neuronskih mreža nije moguća zbog pojave 'overfittinga'. Izveden je zaključak da je problem malog skupa podataka ('overfittinga') primjenom neizrazite logike moguće uspješnije riješiti, nego primjenom neuronske mreže, a zbog mogućnosti ugađanja oblika i položaja funkcija pripadnosti unutar univerzalnog skupa, te mogućnosti ispravljanja pravila unutar baze pravila fuzzy mehanizma zaključivanja. Prema iznosima *NRMSE* indeksa na skupovima za testiranje u tablicama 4.38. do 4.50., gornji zaključak ne vrijedi za većinu slučajeva procjena mehaničkih svojstava čelika i čeličnog lijeva. Razlog tome je mali broj i visoka nehomogenost ulazno-izlaznih podataka. Npr. prema slikama 4.27. do 4.32., uočljiva su velika odstupanja u vrijednostima pojedinih kemijskih elemenata, te odstupanja vrijednosti pojedinih mehaničkih svojstava. Za razliku od procjena mehaničkih svojstava čelika i čeličnog lijeva, bolji rezultati postižu se kod procjena primarnih zahtjeva na alatne čelike, zbog većeg broja i veće homogenosti ulazno-izlaznih skupova. U tablici 6.4. prikazana je rekapitulacija parametara procjena neizrazite logike. Vidljive su sljedeće činjenice:

1. Iz tablice je vidljivo da je većina FIS-eva *Sugeno* tipa sa *ANFIS* algoritmom. *ANFIS* algoritam primjenjen je zbog prirode problema (znanje je skriveno unutar eksperimentalnih podataka), a omogućava automatsko podešavanje položaja funkcija pripadnosti unutar univerzalnog skupa lingvističke varijable.
2. Za sve slučajeve procjena i tipove FIS-eva primjenjen je *min - AND* operator.
3. Za slučajeve procjena sa *Mamdani* tipom FIS-a primjenjen je *max-OR* operator.
4. Za procjene kod kojih nije primjenjeno klasteriranje ulaznih podataka kao operator agregaciju primjenjen je *prod* operator, dok je za procjene sa *Mamdani* tipom FIS-a primjenjen *min* operator.
5. Za procjene kod kojih nije primjenjeno klasteriranje ulaznih podataka, operator implikacije je *max* operator.
6. Za slučajeve procjena sa *Sugeno* tipom FIS-a primjenjen metoda defazifikacije je *wtaver*, a za *Mamdani* tip FIS-a *CoM* metoda defazifikacije.
7. Za slučajeve procjena sa *Sugeno* tipom FIS-a i *ANFIS* algoritmom, koeficijent brzine učenja (*ss*) iznosi 1,1.
8. Faktor povećanja (*ssinc*) koeficijenta brzine učenja u slučaju smanjenja pogreške u procesu učenja, u svim slučajevima procjena iznosi 1,1.
9. Faktor smanjenja (*ssdec*) koeficijenta brzine učenja u slučaju povećanja pogreške u procesu učenja, u svim slučajevima procjena iznosi 0,9.
10. Broj epoha učenja u svim slučajevima iznos 10.
11. Za slučajeve procjena sa *Sugeno* tipom FIS-a primjenjena metoda učenja *ANFIS* algoritma je *BP+LSQ*.
12. Za slučajeve procjena sa *Sugeno* tipom FIS-a ulazne funkcije pripadnosti su sigmoidalnog *gaussmf* oblika.
13. Za slučajeve procjena sa *Mamdani* tipom FIS-a ulazne funkcije pripadnosti su trokutastog *trimf* oblika.
14. Za slučajeve procjena sa *Sugeno* tipom FIS-a izlazne funkcije pripadnosti su lineranog *liner* oblika.
15. Za slučajeve procjena sa *Mamdani* tipom FIS-a izlazne funkcije pripadnosti su trokutastog *trimf* oblika.
16. Za slučajeve procjena sa klasteriranim ulazno-izlaznim skupovima podataka primjenjeni su sljedeći parametri klasteriranja: $Rofl=0.5$; $Sf=1.25$; $Ar=0.5$; $Rr=0.15$.

Tablica 6.4. Rekapitulacija parametara procjena neizrazite logike

Red. broj	Tablica	Naziv procjene	Tip FIS-a	Operatori					ANFIS – parametri						Parametri klasteriranja				Funkcije pripadnosti		Naziv FIS datoteke
				AND	OR	Agre.	Impli.	Defaz.	ss(lr)	ssinc	ssdec	greska	Broj epoha	Metoda učenja	Rofi	Sf	Ar	Rr	mf_ul	mf_iz	
1.	4.38	Procjena Rm u kaljenom stanju	Sugeno	min	-	-	-	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	0.5	1.25	0.5	0.15	gaussmf	linear	RmKalje.fis
2.	4.39	Procjena Re u kaljenom stanju	Mamdani	min	max	min	max	CoM	-	-	-	-	-	-	-	-	-	-	trimf	trimf	ReKalje.fis
3.	4.40	Procjena HV u kaljenom stanju	Sugeno	min	-	-	-	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	0.5	1.25	0.5	0.15	gaussmf	linear	HVKalje.fis
4.	4.41	Procjena A ₅ u kaljenom stanju	Mamdani	min	max	min	max	CoM	-	-	-	-	-	-	-	-	-	-	trimf	trimf	A5Kalje.fis
5.	4.42	Procjena Rm u poboljšanom stanju	Sugeno	min	-	-	-	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	0.5	1.25	0.5	0.15	gaussmf	linear	RmPobolj.fis
6.	4.43	Procjena Re u poboljšanom stanju	Sugeno	min	-	-	-	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	0.5	1.25	0.5	0.15	gaussmf	linear	RePobolj.fis
7.	4.44	Procjena HV u poboljšanom stanju	Sugeno	min	-	-	-	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	0.5	1.25	0.5	0.15	gaussmf	linear	HVPobolj.fis
8.	4.45	Procjena A ₅ u poboljšanom stanju	Sugeno	min	-	-	-	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	0.5	1.25	0.5	0.15	gaussmf	linear	A5Pobolj.fis
9.	4.46	Procjena otpornosti trošenju u poboljšanom stanju	Sugeno	min	-	-	-	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	0.5	1.25	0.5	0.15	gaussmf	linear	TRPobolj.fis
10.	4.47	Procjena otpornosti trošenju u kaljenom stanju	Sugeno	min	-	-	-	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	0.5	1.25	0.5	0.15	gaussmf	linear	TRKaljen.fis
11.	4.48	Procjena otpornosti trošenju alatnih čelika s obzirom na utjecaj karbidotvoraca	Sugeno	min	-	prod	max	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	-	-	-	-	gaussmf	linear	TRAlatni.fis
12.	4.49	Procjena otpornosti popuštanju alatnih čelika s obzirom na utjecaj karbidotvoraca	Sugeno	min	-	prod	max	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	-	-	-	-	gaussmf	linear	POAlatni.fis
13.	4.50	Procjena žilavosti alatnih čelika s obzirom na utjecaj karbidotvoraca	Sugeno	min	-	prod	max	wtaver	0.01	1.1	0.9	0.0	10	BP+LSQ	-	-	-	-	gaussmf	linear	ZIAlatni.fis

Legenda:

ss(lr) -koeficijent brzine učenja
ssinc -koeficijent povećanja ss
ssdec -koeficijent smanjenja ss
Rofi -Range of influence
Sf -Squash factor
Ar -Accept ratio
Rr -Reject ratio
mf_ul -Ulazna funkcija pripadnosti
mf_iz -Izlazna funkcija pripadnosti

6.1.5. Osvrt na procjene asocijativnih neuronskih mreža

1. Procjena elemenata tribosustava vremenskom asocijativnom matricom

Prema tablici 4.51. ulazni početni ('default') stimulacijski vektor je [1 -1 -1 -1 -1 -1 -1 -1 -1 -1]. Elementi vektora predstavljaju elemente tribosustava. Sve vrijednosti elemenata stimulacijskog vektora iznose -1 osim prvog elementa čija je vrijednosti +1. Ovakva postavka vrijednosti elemenata početnog stimulacijskog vektora proizlazi iz činjenice da sustav mora imati barem jedan funkcionalni dio. U tablici 4.52. prikazana je simulacija formiranja vremenske asocijativne matrice tijekom određenog vremena. Vidljivo je, da nakon prihvatanja 22. različita rješenja početni stimulacijski vektor asociira vremenski asocijativni vektor [1 1 1 -1 -1 1 1 -1 -1 -1]. Preslikavanjem numeričkih vrijednosti elemenata vremenskog asocijativnog vektora u lingvističke vrijednosti dobiva se 9. slučaj trošenja prema tablici P1.3. u prilogu I. Može se zaključiti da će se sustav nakon izvođenja 22. konverzacije s korisnikom prilagoditi tj. 'specijalizirati' za rješavanje 9. slučaja trošenja. Gornje razmatranje vrijedi u slučajevima kada korisnik ne odgovori niti na jedno pitanje koje je postavio sustav, tj. kada se već na samom početku rada od sustava zatraži rješenje problema. U slučajevima kada je ulazni stimulacijski vektor različit od početnog, što znači da je korisnik odgovorio na određeni broj pitanja, sustav će pravilno odrediti pripadne elemente na način razmatran u točkama 4.4.1. i 4.4.2., te će pravilno odrediti npr. tip trošenja. Dokaz toga dan je u točki 5.1.1. Za ovaj slučaj procjene primjenjen je *HEBBSU* algoritam sa parametrima navedenim u točki 4.6.1.

2. Procjena agresivnosti otopine vremenskom asocijativnom matricom

Prema tablici 4.53. stimulacijski vektor za procjenu za procjenu agresivnosti otopine je [-1 -1 -1 -1], a početna vremenska asocijativna matrica modelirana je tako da asociira vremenski asocijativni vektor [-1 1 -1 -1]. Preslikavanjem vrijednosti elemenata u lingvističku vrijednost daje početnu srednju agresivnost otopine. Za ovaj slučaj procjene primjenjen je *HEBBSU* algoritam sa parametrima navedenim u točki 4.6.1.

3. Procjena koncentracije agresivne otopine vremenskom asocijativnom matricom

Prema tablici 4.54. koncentracije su razvrstane unutar 10 razreda. Minimalna vrijednost koncentracije je 0% a maksimalna 100%. Početna asocijativna matrica modelirana je tako da stimulacijski vektor [-1 -1 -1 -1 -1 -1 -1 -1 -1 -1] daje vremenski asocijativni vektor [-1 1 -1 -1 -1 -1 -1 -1 -1 -1], odnosno koncentraciju agresivne otopine između 11 i 20%. Za ovaj slučaj procjene primjenjen je *HEBBSU* algoritam sa parametrima navedenim u točki 4.6.1.

4. Procjena radne temperature vremenskom asocijativnom matricom

Prema tablici 4.55. radne temperature razvrstane su unutar 15 razreda. Minimalna vrijednost koncentracije je 0 °C a maksimalna 1500 °C. Početna asocijativna matrica modelirana je tako da stimulacijski vektor [-1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1] daje vremenski asocijativni vektor [-1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1], odnosno radnu temperaturu između 301 i 400 °C. Za ovaj slučaj procjene primjenjen je *HEBBSU* algoritam sa parametrima navedenim u točki 4.6.1.

5. Procjena mehaničkih svojstava vremenskom asocijativnom matricom

Prema tablici 4.56. vrijednosti svojstava za R_m i R_e razvrstane su unutar 13 razreda. Minimalna vrijednosti svojstava je 0 a maksimalna 1300 N/mm². Početna asocijativna matrica modelirana je tako da stimulacijski vektor [-1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1] daje vremenski asocijativni vektor [-1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1], odnosno R_m ili R_e između 301 i 400 °C. Za ovaj slučaj procjene primjenjen je *HEBBSU* algoritam sa parametrima navedenim u točki 4.6.1.

Prema tablici 4.57. vrijednosti A_5 razvrstane su unutar 6 razreda. Minimalna vrijednosti A_5 svojstva je 0 a maksimalna 30%. Početna asocijativna matrica modelirana je tako da stimulacijski vektor [-1 -1 -1 -1 -1 -1] daje vremenski asocijativni vektor [-1 -1 1 -1 -1 -1], odnosno A_5 između 11 i 15%. Za ovaj slučaj procjene primjenjen je *HEBBSU* algoritam sa parametrima navedenim u točki 4.6.1.

Prema tablici 4.58. vrijednosti HV razvrstane su unutar 9 razreda. Minimalna vrijednosti HV svojstva je 0 a maksimalna 900. Početna asocijativna matrica modelirana je tako da stimulacijski vektor $[-1 -1 -1 -1 -1 -1 -1 -1 -1]$ daje vremenski asocijativni vektor $[-1 -1 -1 \mathbf{1} -1 -1 -1 -1 -1]$, odnosno HV između 301 i 400. Za ovaj slučaj procjene primjenjen je $HEBBSU$ algoritam sa parametrima navedenim u točki 4.6.1.

Prema tablici 4.59. vrijednosti TR razvrstane su unutar 9 grupa. Minimalna vrijednosti TR svojstva je 1 a maksimalna 9. Početna asocijativna matrica modelirana je tako da stimulacijski vektor $[-1 -1 -1 -1 -1 -1 -1 -1 -1]$ daje vremenski asocijativni vektor $[-1 -1 -1 \mathbf{1} -1 -1 -1 -1 -1]$, odnosno $TR=4$. Za ovaj slučaj procjene primjenjen je $HEBBSU$ algoritam sa parametrima navedenim u točki 4.6.1.

Prema tablici 4.60. vrijednosti PO razvrstane su unutar 9 grupa. Minimalna vrijednosti PO svojstva je 1 a maksimalna 9. Početna asocijativna matrica modelirana je tako da stimulacijski vektor $[-1 -1 -1 -1 -1 -1 -1 -1 -1]$ daje vremenski asocijativni vektor $[-1 -1 -1 \mathbf{1} -1 -1 -1 -1 -1]$, odnosno $PO=4$. Za ovaj slučaj procjene primjenjen je $HEBBSU$ algoritam sa parametrima navedenim u točki 4.6.1.

Prema tablici 4.61. vrijednosti ZI razvrstane su unutar 9 grupa. Minimalna vrijednosti ZI svojstva je 1 a maksimalna 9. Početna asocijativna matrica modelirana je tako da stimulacijski vektor $[-1 -1 -1 -1 -1 -1 -1 -1 -1]$ daje vremenski asocijativni vektor $[-1 -1 -1 \mathbf{1} -1 -1 -1 -1 -1]$, odnosno $ZI=4$. Za ovaj slučaj procjene primjenjen je $HEBBSU$ algoritam sa parametrima navedenim u točki 4.6.1.

6. Procjena mase vremenskom asocijativnom matricom

Ova procjena uvedena je zbog toga što masa dijela predstavlja jedan od kriterija izbora materijala pri određivanju potencijalnih grupa materijala. Pojmovima *mala*, *srednja* i *velika* masa, dodijeljene su prema tablici 4.62. konkretne vrijednosti razvrstane unutar 10 razreda. Vrijednosti za male mase kreću se u rasponu od 0 do 300 kg, srednje mase od 301 do 600 kg i za velike mase više od 600 kg. Početna asocijativna matrica modelirana je tako da stimulacijski vektor $[-1 -1 -1 -1 -1 -1 -1 -1 -1]$ daje vremenski asocijativni vektor $[-1 -1 \mathbf{1} -1 -1 -1 -1 -1 -1]$, odnosno procjenu mase između 201 i 300kg.

6.1.6. Osvrt na način rada mehanizma zaključivanja

U točki 5.1. detaljno je opisan način rada mehanizma zaključivanja inteligentnog sustava za izbor materijala na konkretnom primjeru. Prije kratkog osvrta na sam način rada mehanizma, potrebno je razmotriti još neka razmišljanja. Prilikom zamišljanja, modeliranja te izgradnje sustava opisanog u radu, nije se težilo izgradnji takvog sustava u koji će biti pohranjeni svi poznati primjeri riješenih problema iz prakse, jer se smatra da je takav pristup prikladniji za rješavanje primjenom klasičnih baza podataka. Zbog toga su postavljeni sljedeći ciljevi pri modeliranju te izgradnji sustava:

1. Modelirati i izgraditi takav sustav koji početno ništa ne zna o problemu, te da ima pogrešno ili ispravno saznanje o problemu.
2. Modelirati i izgraditi takav sustav koji će znati ispravljati namjerno ili nenamjerno pogrešne odgovore pri konverzaciji sa korisnikom,
3. Modelirati i izgraditi takav sustav koji će, nakon što ga se tijekom vremena pravilno nauči rješavati probleme, biti sposoban donijeti suvislo rješenje i objašnjenje problema, bez postavljanja velikog broja pitanja korisniku.

Prvi cilj postignut je primjenom modela asocijativnih i *backpropagation* neuronskih mreža, jer vrijednosti njihovih matrica težina sadrže saznanja o problemu. Vrijednosti matrica težina mogu sadržavati točne, netočne ili uopće ne moraju sadržavati informacije o problemu. Potrebna saznanja o problemu stječu se pokretanjem procesa učenja.

Za postizanje drugog cilja primijenjena je konverzacija *sustav-korisnik* kao oblik prikupljanja informacija. Taj je način najbliži radu čovjeka eksperta prilikom intervjua korisnika. Sustav analizira podatke u smislu jesu li oni ili nisu u skladu sa trenutnim saznanjima, a ako nisu ispravljaju ih. U ovom slučaju primjenjeni su modeli asocijativnih neuronskih mreža uključenih unutar mehanizma za obradu konverzacije.

Treći cilj postiže se ponavljanjem postupka parcijalnog učenja logičkih cjelina sustava koje sadrže određena znanja o problemu. Te cjeline čine matrice težina ili baza *fuzzy* pravila o npr. mehaničkim svojstvima materijala. Simulacija nastajanja (točka 4.6.) vremenskih asocijativnih matrica pokazuje da se sustav tijekom vremena prilagođava (specijalizira se) za rješavanje samo određenih vrsta problema kao npr., za analizu nekolicine tipova trošenja.

U sukladnosti s navedenim razmišljanjima, u nastavku će se dati kratki osvrt na praktički najvažniju komponentu mehanizma zaključivanja inteligentnog sustava, a to je mehanizam za obradu konverzacije. O radu mehanizma za obradu konverzacije u najvećoj mjeri ovisi suvislost rješenja problema.

Pretpostavka je da sustav započinje rad sa pravilno naučenim matricama težina, koje sadrže realna parcijalna znanja o problemu. Na slici 5.1. i 5.2. prikazan je primjer konverzacije sustava sa korisnikom. Kao što se vidi korisnik odgovara na tri grupe pitanja: o elementima sustava, o uvjetima okoline, o zahtjevima na materijal i o općim zahtjevima. U danom primjeru značajno je za razmotriti kako mehanizam za obradu konverzacije tumači odgovore tipa 'NE ZNAM' ili tipa ' ' (prazno polje). Varijable koje u tijeku konverzacije poprime vrijednost 'NE ZNAM', znači da im sustav svakako mora dodijeliti kvantitativnu vrijednost, jer korisnik vrijednost te varijable trenutno ne zna, a ista predstavlja važni kriterij. Kvantitativne vrijednosti takvim varijablama, mehanizam za obradu konverzacije dodjeljuje na temelju vremenskih asocijativnih matrica kao što je objašnjeno u točki 4.6. Varijable sa vrijednostima tipa ' ' (prazno polje) imaju značenje kao 'nevažne', jer je korisnik sasvim siguran da one ne služe kao jedan od kriterija izbora. Iznimku čini varijabla radne temperature, koja je važan kriterij za određivanje potencijalnih grupa nosivih materijala sloja, kao što je prikazano na slici 5.10. Bez obzira što će korisnik na pitanje o temperaturi smatrati nevažnim, mehanizam za obradu konverzacije će joj ipak dodijeliti kvantitativnu vrijednost pomoću vremenske asocijativne matrice, i to na način kako je već objašnjeno u točki 4.6.5.

Rješenje problema od sustava korisnik može zatražiti bez da je odgovorio na ijedno pitanje. U tom slučaju mehanizam za obradu asocijacija dodjeljuje asocijativne vrijednosti svim varijablama sustava, prosljeđuje ih ostalim mehanizmima zaključivanja, te rješenje problema u konačnici ovisi o vrijednostima vremenskih asocijativnih matrica. Već je napomenuto da je sustav moguće naučiti dobrim ili pogrešnim asocijacijama. U slučaju djelomično sprovedene konverzacije sa korisnikom, mehanizam za obradu konverzacije dodjeljuje kvantitativne vrijednosti svim varijablama koje imaju trenutnu vrijednost tipa 'prazno polje' na temelju vremenskih asocijativnih matrica. Simulacija načina rada mehanizma za obradu konverzacije prikazana na slici 5.6. Na slici su za pojedine logičke cjeline prikazani rezultati procjena asocijativnom neuronskom mrežom. Vidljivo je, da se za svaki stimulacijski vektor proizvodi ili inicira asocijativnom vremenskom matricom vremenski asocijativni vektor, pomoću kojeg se preslikavanjem dobivaju realne asocijativne vrijednosti.

ZAKLJUČAK

ZAKLJUČAK

Na temelju provedenog eksperimentalnog istraživanja te provjere rezultata proizlaze sljedeći zaključci:

1. Dokaz postavljene hipoteza disertacije:

Kombinacijom primjene aktualnih metoda umjetne inteligencije (*ekspertni sustavi, neuronske mreže, neizrazita logika, neurofuzzy, genetički algoritmi*) pri izgradnji inteligentnog sustava za izbor materijala, dokazano je poboljšanje glavne komponente sustava- mehanizma zaključivanja, čime se značajno utječe na brzinu donošenja i pouzdanost rješenja.

2. Postignuti ciljevi disertacije:

- razvijen je hibridni ekspertni sustav (*ES*) koji na temelju postavljenog skupa pitanja donosi suvisle zaključke primjenom aktualnih metoda umjetne inteligencije;
- razvijena je vlastita školjka *ES-a*, u koju su prema dostupnoj literaturi, ugrađeni svi poznati mehanizmi za donošenje zaključaka: *ulančavanje unazad, ulančavanje unaprijed, deamon procedure, pravila sa ugrađenim faktorima sigurnosti, mehanizmima objašnjavanja kako?, zašto? i što ako?*. Razvijena školjka posjeduje funkcije za poziv algoritama neuronskih mreža i algoritama neizrazite logike;
- razvijena je struktura i funkcije za pristup *okvir* bazama znanja o postupcima modificiranja površina te prikladnim materijalima sloja;
- razvijena je metoda '*pobjednika*' kao metoda izbora prikladnog materijala sloja;
- razvijene su tzv. '*vremenske asocijativne matrice*' kao način inicijalizacije varijabli koje imaju *nesigurne vrijednosti*;
- razvijene su procedure za povezivanje i optimalizaciju parametara neuronskih mreža sa genetičkim algoritmima.

3. Izbor materijala aktualnim metodama umjetne inteligencije:

- primjenom aktualnih metoda umjetne inteligencije, posebice neuronskih mreža i neizrazite logike, a zbog iznalaženja nepoznatih interakcija za procjenu mehaničkih svojstava materijala, izbjegnuta je kombinatorna eksplozija koja se javlja primjenom *IF-THEN* pravila;
- u većini slučajeva procjena mehaničkih svojstava materijala primjenom neizrazite logike, prikladniji je adaptivni *NeuroFuzzy Sugeno* model, za razliku od *Mamdani* modela. Razlog leži u prirodi razmatranog problema (iskustveno znanje '*sakriveno*' unutar mjerenih podataka), te mogućnost adaptivnog podešavanja broja i oblika funkcija pripadnosti neizrazitog skupa primjenom *Sugeno* modela;
- od 8 primjenjenih modela neuronskih mreža s povratnim prostiranjem pogreške podjednako dobri rezultati postižu se adaptivnim modelima *NNBMA* i *NNLM*;
- od 4 primjenjena modela asocijativnih neuronskih mreža najbolje rezultate postiže *HEBBSSU* model, koji za 30% unešenog šuma unutar izvornog vektora vraća isti bez sadržaja šuma;
- optimalizacija strukture i parametara algoritama neuronskih mreža (broj slojeva, broj neurona, oblik prijenosnih funkcija, parametri učenja) uspješno je riješeno primjenom genetičkih algoritama.

4. Nedostaci i ograničenja

- uočeni nedostatak primjenjenih metoda (neuronske mreže, neizrazita logika) je loša generalizacija onih svojstava materijala za koja su dostupni bili relativno mali ulazno-izlazni skupovi podataka potrebnih za proces učenja. Taj nedostatak djelomično je ispravljen kod nekih mehaničkih svojstava materijala primjenom *Mamdani* modela neizrazite logike i to '*ručnim*' ugađanjem baze *fuzzy* pravila i *tipičnih vrijednosti* funkcija pripadnosti;

- prijedlog rješenja koje daje sustav, ovisan je o asocijativnim matricama za kontrolu konverzacije tj. o njihovoj prilagođenosti za ispravljanjem pogrešnih odgovora;
- u sustav nisu ugrađena pravila za obradu konstrukcijskih ograničenja koja utječu na izbor prikladnog postupka modificiranja površina;
- upitna primjena ANFIS kod većeg broja ulazno-izlaznih varijabli;
- relativna sporost sustava zbog 16-bitne inačice školjke ekspertnog sustava.

5. Smjernice za daljni rad

- prikupljanje što je moguće kvalitetnijih ulazno-izlaznih skupova podataka potrebnih za učenje modela neuronskih mreža i mehanizama zaključivanja neizrazite logike;
- daljnje istraživanje mogućnosti i primjene asocijativnih memorija;
- istraživanje i izbor naprednije 32-bitne razvojne školjke ekspertnog sustava .

L I T E R A T U R A

- [1] D. Lisjak, T. Filetin, 'ABRex - Description of the Abrasion Wear Expert System', Database and Expert Systems Applications', Eighth International Workshop on Database and Expert Systems Applications, IEEE Computer Society, Los Alamitos, CA 90720-1314, 1997, str. 576-581.
- [2] L.A. Dobrazanski, J.Trzaska, W. Sitek, 'Application of Neural Networks for Prediction of Structural Steels Properties', Proceedings of the 8th Seminar of International Federation for Heat Treatment and surface Engineering, Cavtat, Croatia, 2001, str. 393-398.
- [3] J. Galinec, M. Široki, D. Lisjak, 'Recognition of Materials Microstructure by means of Neural Network', 1st Interantional Conference: Development, Testing and Application of Materials, Opatija, Croatia, 1996, str. 97-105.
- [4] H.K.D.H. Bhadeshia. 'Neural Networks in Materials Science', ISIJ International, 39, 1999.
- [5] T. Filetin, I. Žmak, D. Novak, 'Prediction of the nitriding parameters by Neural Networks and Genetic Algorithm', Proceedings of the 2th International Conference on Thermal Process Modelling and Computer Simulation, Nancy, France, March 2003.
- [6] I. Žmak, 'Predviđanje svojstava materijala neuronskim mrežama', Magistarski rad, FSB-Zagreb, Zagreb, 2003.
- [7] J.L. Koning, 'Techniques and Applications of Fuzzy Theory to Material Selection in Mechanical Design Problems', Fuzzy Theory Systems: Techniques and Application, 2, 1999.
- [8] B. Novaković, D. Majetić, M. Široki, 'Umjetne neuronske mreže', FSB-Zagreb, tisak X-Press, Zagreb, 1998.
- [9] Martin T. Hagan, Howard B. Demuth, Mark H. Beale, 'Neural Network Design', PWS Publishing Company, Boston, 1996.
- [10] K. A. Stroud, 'Engineering Mathematics', Macmillan Press Ltd, London, 1995
- [11] G.B. Orr, K. R. Mueller, 'Neural Networks: Tricks of the Trade', Springer-Verlag, 1998
- [12] J. Wesley Hines, 'Matlab Supplement to Fuzzy and Neural Approaches in Engineering', John Wiley & Sons, Inc., New York, 1997.
- [13] Constantin von Altrock, 'Fuzzy Logic and Neurofuzzy Applications Explained', Prentice-Hall Inc., 1995.
- [14] Kohonen T., 'Self-Organization and Associative Memory', Springer-Verlag, Berlin, 1984.
- [15] Adeli H., Hung S.L., 'Machine Learning-Neural Networks, Genetic Algorithms and Fuzzy Systems', John Wiley & Sons, New York, 1995.
- [16] Jang J.S., Sun C.T., 'Neuro-fuzzy Modeling and Control', Proceedings of the IEEE, Vol. 83, No. 3, 1995.
- [17] Jang J.S., Gulley N., 'Fuzzy Logic Toolbox for Use with MATLAB', The MathWorks Inc., Natick, MA, 1995.
- [18] Sugeno M., 'Industrial applications of fuzzy control', Elsevier Science Pub. Co., 1985.
- [19] Donald A. Waterman, 'A Guide to Expert Systems', Addison-Wesley Publishing Company, 1986.

-
- [20] Patrick H. Winston, 'Artificial Intelligence', Addison-Wesley Publishing Company, 1992.
- [21] M. Minsky, 'A Framework for Representing Knowledge', u P. Winston: The Psychology of Computer Vision, McGraw-Hill, 1975.
- [22] D. Lisjak, 'Primjena okvira kao načina predstavljanja znanja u ekspertnim sustavima', MATEST '97, Međunarodno savjetovanje, Rovinj, 1997.
- [23] M. Negnevitsky, 'Artificial Intelligence: A Guide to Intelligent Systems', Addison Wesley, Harlow, England, 2002.
- [24] Anna Hart, 'Knowledge Acquisition for Expert Systems', McGraw Hill, 2nd edition, 1992.
- [25] Zhengxin Chen, 'Computational Intelligence for Decision Support', CRC Press, New York, 2000.
- [26] Shortliffe E.H., 'Computer-Based Medical Consultations: MYCIN', Elsevier, New York, 1976.
- [27] <ftp://ftp.sas.com/pub/neural/FAQ.html>, Maintainer: saswss@unx.sas.com (Warren S. Sarle), Copyright 1997, 1998, 1999, 2000, 2001, 2002 by Warren S. Sarle, Cary, NC, USA.
- [28] The MathWorks, Neural Network Toolbox, Release 4.0.1, www.mathworks.com, Inc. 2003.
- [29] B. Iglewicz, 'Robust scale estimators and confidence intervals for location', in Hoglian, D.C., Mosteller, M. and Tukey, J.W., eds., Understanding Robust and Exploratory Data Analysis, NY: Wiley.
- [30] McCullagh, P. and Nelder, J.A. 'Generalized Linear Models', 2nd ed., Chapman & Hall, London, 1989.
- [31] <ftp://ftp.sas.com/pub/neural/illcond/illcond.html>, Warren S. Sarle, 'Ill-Conditioning in Neural Networks', SAS Institute Inc., Cary, NC, USA, 1999.
- [32] Sarle W.S., 'Stopped training and other remedies for overfitting', Proceedings of the 27th Symposium on the Interface of Computing Science and Statistics', SAS Institute Inc., Cary, NC, USA, 1995.
- [33] Bishop C.M., 'Neural Networks for Pattern Recognition', Oxford University Press, Oxford, 1995.
- [34] R.G. Song, 'Heat treatment optimization for 7175 aluminum alloy by genetic algorithm', Materials Science & Engineering C 17, Elsevier Science B.V., 2001.
- [35] D. Lisjak, B. Matijević, 'Determining of steel carburizing parameters using neural networks', 8th Seminar of the International federation for heat treatment and surface engineering-IFHTSE, Dubrovnik, 2001.
- [36] Mamdani E.H., S. Assilian, 'An experiment in linguistic synthesis with a fuzzy logic controller', International Journal of Man-Machine Studies, Vol. 7, No.1, 1975.
- [37] B. Kosko, 'Neural Networks and fuzzy systems', Prentice-Hall, Inc. New Jersey, 1992.
- [38] [Hans-Jurgen Zimmerman](#), 'Fuzzy Sets, Decision Making and Expert Systems', Kluwer Academic Publishers, Boston, 1987.
- [39] M. Novosel F. Cajner, D. Krumes, 'Alatni materijali', Sveučilište Josipa Jurja Strossmayera u Osijeku, Strojarski fakultet u Slavonskom Brodu, Slavonski Brod, 1996.
- [40] K. Holmberg, A. Mathews, 'Coatings Tribology-Properties, Technique and Applications in Surface Engineering', Elsevier, New York, 1994.
-

-
- [41] Đ.Lončar, V. Bezjak: Priručnik za zavarivanje, Elektroda Zagreb, 1987.
- [42] M. Novosel, 'Kalupni materijali za preradu polimera', Društvo plastičara i gumaraca, Biblioteka polimerstvo, Zagreb, 1987.
- [43] Judge G.G., R.C. Hill, W.E. Griffiths, 'Introduction to the Theory and Practice of Econometrics', Wiley, New York.
- [44] V. Ivušić, 'Čelici i površine postojani istodobno koroziji i trošenju', Tehnički vjesnik 4, 1997.
- [45] Željezara Ravne, 'Naši proizvodi I, II, III', Ravne na Koroškem, 1979.
- [46] D. Lisjak, 'Razvoj ekspertnog sustava za rješavanje problema abrazijskog trošenja', Magistarski rad, FSB-Zagreb, Zagreb, 1998.
- [47] T. Filetin, F. Kovačiček, J. Indof, 'Svojstva i primjena materijala', Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zagreb, 2002.
- [48] M. Stupnišek, B. Matijević, 'Pregled postupaka modificiranja i prevlačenja', Zbornik radova Znanstveno stručnog skupa s međunarodnim učešćem: Toplinska obradba metala i inženjerstvo površina, Zagreb, 2000.
- [49] H. Kunst, 'Verschleißschutz - Ein Ratgeber für die Anwendung verschleißhemmender Schichten', Arbeitsgemeinschaft Wärmebehandlung and Werkstofftechnik (AWT), Wiesbaden, 1997.
- [50] T. Filetin, D. Lisjak, 'Podloge za izbor postupka modificiranja površina', Međunarodno savjetovanje MATRIB '99, Trogir, Hrvatsko društvo za materijale i tribologiju, 1999.
- [51] D. Grundler, 'Genetičkim algoritmom optimirano neizravno višerazinsko vođenje procesa', Doktorska disertacija, FER, 1997.
- [52] D. Krumes, 'Toplinska obradba', Udžbenik, Sveučilište Josipa Jurja Strossmayera u Osijeku, Strojarski fakultet u Slavonskom Brodu, Slavonski Brod, 2000.
- [53] Granta Design Limited, The *Cambridge Engineering Selector*, Version 4.0, Oxford, 2002.
- [54] Grupa autora, 'Materijali u strojarstvu', Hrvatsko za materijale i tribologiju, Zagreb, 1993.
- [55] 'Metalbiro', Termokemijski postupci, Zagreb, 1981.
- [56] K. Grilec, 'Otpornost na abrazijsko trošenje triboloških prevlaka', Magistarski rad, FSB-Zagreb, 1998.
- [57] B. Liščić, M. Stupnišek, F. Cajner, T. Filetin, 'Toplinska obrada - praktikum', Sveučilište u Zagrebu, Fakultet
- [58] Karbach, Linster, 'Wissens-akquisition für Expertensysteme-Techniken, Modelle und Softwarewerkzeuge', Hanser, 1990.
- [59] Svetsaren, 'A welding review published by The Esab Group', Vol. 50, No. 2, Göteborg, 1995.
- [60] Elektroda Zagreb, d.d., 'Reparaturno zavarivanje', Katalog.

ŽIVOTOPIS

DRAGUTIN LISJAK rođen je 28.11.1962. u Čakovcu gdje je završio osnovnu školu. Srednju školu završio je u Zagrebu. Diplomirao je 1989. godine na Fakultetu strojarstva i brodogradnje u Zagrebu, usmjerenje Materijali. Do 1991. godine radi u tvornici "Končar - Alati i strojevi" na poslovima tehnologije izrade alata za tlačni lijev aluminijski. Iste godine zaposlio se kao znanstveni novak u Zavodu za materijale. Magistarski rad pod naslovom "Razvoj ekspertnog sustava za rješavanje problema abrazijskog trošenja" obranio je na Fakultetu strojarstva i brodogradnje, Sveučilišta u Zagrebu, 1998. godine. Trenutno radi kao asistent. Aktivno sudjeluje u radu na znanstvenom projektu pod naslovom "Računalne simulacije i razvoj materijala", čiji je voditelj prof.dr.sc. Tomislav Filetin. Voditelj je dvaju projekata informacijskih tehnologija pod naslovima: "Identifikacija čelika prema kemijskom sastavu i standardnim oznakama" i "Identifikacija aluminijskih legura prema kemijskom sastavu i standardnim oznakama". Član je Hrvatskog društva za materijale i tribologiju, Hrvatskog društva za tehniku zavarivanja, američke asocijacije za materijale, te američke asocijacije za umjetnu inteligenciju. Aktivno se služi engleskim, a pasivno njemačkim jezikom. Oženjen je i otac dvojice sinova.

PRILOG I

DEFINICIJE SKUPOVA PODATAKA

Tablica P1.1. Tablica klasifikacije trošenja [49,50]

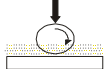
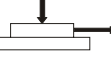
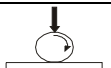
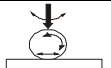
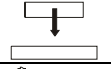


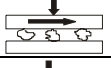
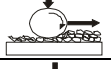
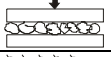

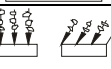
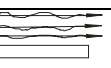



ELEMENTI TRIBOSU STAVA	RELATIVNO GIBANJE		TIP TROŠENJA	MEHANIZAM TROŠENJA				ŠIFRE PRIKLADNIH POSTUPAKA MODIFICIRANJA POVRŠINA	
	Naziv	Schema	Naziv	AD	AB	UP	TK	Prikladno	Uvjetno prikladno
KRU TO TIJELO MEĐU MEDIJ KRU TO TIJELO	Klizanje		Hidrodinam.			●	○	1.1-1.5 2.2 7.2-7.4	2.2 6.5
KRU TO TIJELO KRU TO TIJELO Kod suhog, graničnog i mješovitog trenja	Klizanje		Sklizno	●	○	○	●	2.1-2.2 3.2-3.4 5.1-5.4 7.2 7.4	1.1-1.5 3.5 4.1-4.3 6.5 7.3
	Kotrljanje		Kotrljajuće	○	○	●	○	1.1-1.5 2.2 7.3	2.1 6.5 7.5
	Udaci		Udamo	○	○	●	○	4.1-4.3 5.1-5.4 6.1 7.2	2.1 2.2 6.5 7.1 7.3
	Vibriranje		Izjedanje (FRETING)	●	●	●	●	1.1-1.5 7.2 7.4	2.1-2.2 3.1 3.3 6.1 7.3
KRU TO TIJELO ČESTICE	Udaci		Abrazija udamo		●	●	○	1.1-1.5 6.1	2.1-2.2 3.1 3.3 6.5
	Klizanje		Abrazija sklizno		●		○	2.1-2.2 3.1-3.5 7.1 7.3	1.1-1.5 6.1
KRU TO TIJELO ČESTICE KRU TO TIJELO	Klizanje		Abrazija trdije	○	●	●	○	2.2 3.1 3.3-3.5 4.1-4.3 6.2 7.1	2.1 3.2 5.1-5.4 6.1 7.2
	Vajanje		Abrazija trdije	○	●	●	○		
	Udaci		Abrazija trdije	○	○	●	○		
KRU TO TIJELO ČESTICE TEKUĆINA	Strujanje		Erozija hidrodinamička		●	●	○	3.1 3.3 3.4 6.4 7.2-7.3	2.2 3.5.1 3.5.2 6.5 7.4
KRU TO TIJELO ČESTICE PLIN	Strujanje		Erozija sklizno	○	●	●	○	2.2 3.1 3.3-3.4 6.2 7.1	6.1 7.3
	Strujanje		Erozija strujanjem	○	●	●	○	2.2 3.1 3.3 6.2 7.3	6.1
KRU TO TIJELO TEKUĆINA	Strujanje Njihanje		Erozija kavitacija			●	○	6.5	2.2 3.3 3.5.1 3.5.2 6.4
	Udaci		Erozija udarno			●	○	3.5 6.5	3.1 6.1 7.4
	Strujanje		Erozija kapljevitom			○	●	3.1 3.3 3.4 6.4	2.2 3.5.2 6.1 7.3
KRU TO TIJELO PLIN	Erozija plinom		Erozija plinom				●	3.5.4 6.4	2.2 3.1 3.3 3.5.2 6.5 7.3

● glavnom prevladava ○ manje značajno

Tablica P1.2. Shema mapiranja varijabli tablice klasifikacije trošenja

Elementi sustava Relativno gibanje	Map. vrije.	Tip trošenja	Map vrije.	Mehanizam trošenja	Map. vrije.
1	2	3	4	5	6
f1 -funkcionalni dio 1 f2 -funkcionalni dio 2 č -čestice p -plin t -tekućina F -djelovanje sile v -djelovanje brzine ω -djelovanje kutne brzine o -oscilacije α -kut nastrujavanja	(-1,1) (-1,1) (-1,1) (-1,1) (-1,1) (-1,1) (-1,1) (-1,1) (-1,1) (-1,1) (-1,1)	1. Hidrodinamičko 2. Sklizno 3. Kotrljajuće 4. Izjedanje (fretting) 5. Udarno 6. Abrazija-udarno 7. Abrazija-sklizno 8. Abrazija-trotijelno 9. Erozijsko-hidroabrazija 10. Erozijsko-sklizno 11. Erozijsko-strujanjem 12. Erozijsko-kavitacija 13. Erozijsko-udarno 14. Erozijsko-kapljevinom 15. Erozijsko-plinom	(1000000000000000) (0100000000000000) (0010000000000000) (0001000000000000) (0000100000000000) (0000010000000000) (0000001000000000) (0000000100000000) (0000000010000000) (0000000001000000) (0000000000100000) (0000000000010000) (0000000000001000) (0000000000000100) (0000000000000010) (0000000000000001)	AD - Adhezija AB - Abrazija UP – Umor površ. TK - Tribokorozija	(1,2,3) (1,2,3) (1,2,3) (1,2,3)

Tablica P1.3. Mapirana tablica klasifikacije trošenja

Slučajevi trošenja	ULAZNI SKUP											IZLAZNI SKUP				
	Elementi sustava					Relativno gibanje						Tip Troše.	Mehanizam trošenja			
	f1	f2	č	p	t	F	v	ω	o	α	AD		AB	UP	TK	
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
1		1	1	-1	-1	1	1	-1	1	-1	-1	10000000 0000000	3	3	1	2
2		1	1	-1	-1	-1	1	1	-1	-1	-1	01000000 0000000	1	2	2	1
3		1	1	-1	-1	-1	1	-1	1	-1	-1	00100000 0000000	2	2	1	2
4		1	1	-1	-1	-1	1	-1	1	1	-1	00010000 0000000	1	1	1	1
5		1	1	-1	-1	-1	1	-1	-1	-1	-1	00001000 0000000	2	2	1	2
6		1	-1	1	-1	-1	1	-1	-1	-1	-1	00000100 0000000	3	1	1	2
7		1	-1	1	-1	-1	1	1	-1	-1	-1	00000010 0000000	3	1	3	2
8		1	1	1	-1	-1	1	1	-1	-1	-1	00000001 0000000	3	1	1	2
9		1	1	1	-1	-1	1	1	-1	-1	-1	00000001 0000000	2	1	1	2
10		1	1	1	-1	-1	1	-1	-1	-1	-1	00000001 0000000	2	2	1	2
11		1	-1	1	-1	1	-1	1	-1	-1	1	00000000 1000000	3	1	1	2
12		1	-1	1	-1	1	-1	1	-1	-1	-1	00000000 0100000	2	1	1	2
13		1	-1	1	1	-1	-1	1	-1	-1	1	00000000 0010000	2	1	1	2
14		1	-1	-1	-1	1	-1	1	-1	-1	-1	00000000 0001000	3	3	1	2
15		1	-1	-1	1	-1	-1	1	-1	-1	1	00000000 0000100	3	3	1	2
16		1	-1	-1	-1	1	-1	1	-1	-1	1	00000000 0000010	3	3	2	1

17		1	-1	-1	1	-1	-1	1	-1	-1	-1	00000000	00000001	3	3	3	1
----	--	---	----	----	---	----	----	---	----	----	----	----------	----------	---	---	---	---

Tablica P1.4. Pad točnosti asocijativnih algoritama u zavisnosti od iznosa unešenog šuma

Tip trošenja	Šum %	Željeni izlaz - T Novi ulaz - P	Elementi sustava										Točnost %
		Procjenjeni izlaz - A	f1	f2	č	p	t	F	v	ω	o	α	
			1	2	3	4	5	6	7	8	9	10	
HEBBUN													
1	0	T	1	1	-1	-1	1	1	-1	1	-1	-1	90
		A	1	1	-1	-1	-1	1	-1	1	-1	-1	
	10	P	1	-1	-1	-1	1	1	-1	1	-1	-1	90
		A	1	1	-1	-1	-1	1	-1	1	-1	-1	
	20	P	1	1	-1	-1	-1	1	-1	-1	-1	-1	70
		A	1	1	-1	-1	-1	1	1	-1	-1	-1	
	30	P	-1	-1	-1	-1	1	1	-1	1	1	-1	70
		A	-1	1	-1	1	1	1	-1	1	1	-1	
	40	P	1	-1	-1	1	-1	-1	-1	1	-1	-1	50
		A	1	-1	-1	-1	-1	-1	1	-1	-1	-1	
	50	P	-1	-1	-1	-1	-1	1	-1	-1	-1	1	70
		A	1	1	-1	-1	-1	1	1	-1	-1	-1	
	90	P	-1	-1	1	1	-1	-1	-1	-1	1	1	20
		A	-1	-1	1	1	1	-1	1	1	1	1	
HEBBSU													
2	0	T	1	1	-1	-1	-1	1	1	-1	-1	-1	100
		A	1	1	-1	-1	-1	1	1	-1	-1	-1	
	10	P	1	1	-1	-1	-1	1	1	1	-1	-1	90
		A	1	1	-1	-1	-1	1	-1	-1	-1	-1	
	20	P	1	1	-1	-1	1	-1	1	-1	-1	-1	80
		A	1	-1	-1	-1	-1	-1	1	-1	-1	-1	
	30	P	-1	1	-1	1	1	1	1	-1	-1	-1	90
		A	-1	1	-1	-1	-1	1	1	-1	-1	-1	
	40	P	-1	1	1	-1	-1	-1	1	-1	1	-1	70
		A	-1	1	1	-1	-1	-1	1	-1	-1	-1	
	50	P	1	1	-1	1	-1	1	1	1	1	1	40
		A	-1	1	-1	1	-1	1	-1	1	1	1	
	90	P	-1	-1	1	1	1	-1	-1	-1	1	1	0
		A	-1	-1	1	1	1	-1	-1	1	1	1	
INSSU													
3	0	T	1	1	-1	-1	-1	1	-1	1	-1	-1	100
		A	1	1	-1	-1	-1	1	-1	1	-1	-1	
	10	P	1	1	-1	-1	-1	1	-1	-1	-1	-1	90
		A	1	1	-1	-1	-1	1	-1	-1	-1	-1	
	20	P	1	-1	-1	-1	1	1	-1	1	-1	-1	100
		A	1	-1	-1	-1	1	1	-1	1	-1	-1	
	30	P	1	1	-1	-1	-1	1	-1	1	-1	-1	100
		A	1	1	-1	-1	-1	1	-1	1	-1	-1	
	40	P	-1	-1	-1	1	-1	1	-1	1	1	-1	70
		A	-1	1	-1	1	-1	1	-1	1	1	-1	
	50	P	1	-1	-1	1	1	-1	-1	1	-1	-1	40
		A	-1	-1	-1	1	1	-1	-1	1	-1	1	
	90	P	-1	-1	1	1	1	-1	-1	-1	1	1	10
		A	-1	-1	1	1	1	-1	1	1	1	1	

Tablica P1.5. Procjene točnosti *HEBBUN* algoritma za 0% i 50% šuma

Red broj	Tip Troš.	Šum	Željeni izlaz - T Novi ulaz - P	Elementi sustava										Točnost HEBBUN algoritma %
			Procjenjeni izlaz - A	f1	f2	č	p	t	F	v	ω	o	α	
				1	2	3	4	5	6	7	8	9	10	
1	5	0%	T	1	1	-1	-1	-1	1	-1	-1	-1	-1	90
			A	1	1	-1	-1	-1	1	1	-1	-1	-1	
		50%	P	1	1	1	-1	1	-1	1	-1	1	-1	50
			A	1	-1	1	-1	1	-1	1	-1	-1	-1	
2	17	0%	T	1	-1	-1	1	-1	-1	1	-1	-1	-1	90
			A	1	-1	-1	-1	-1	-1	1	-1	-1	-1	
		50%	P	1	1	-1	1	-1	1	1	1	1	-1	40
			A	1	1	-1	-1	-1	1	-1	1	1	-1	
3	2	0%	T	1	1	-1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	-1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	60
			A	1	-1	-1	-1	1	-1	1	-1	-1	1	
4	1	0%	T	1	1	-1	-1	1	1	-1	1	-1	-1	90
			A	1	1	-1	-1	-1	1	-1	1	-1	-1	
		50%	P	1	-1	1	1	1	-1	-1	-1	-1	-1	50
			A	1	-1	1	-1	1	-1	1	-1	-1	-1	
5	6	0%	T	1	-1	1	-1	-1	1	-1	-1	-1	-1	80
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	1	1	1	-1	1	-1	-1	-1	1	1	40
			A	-1	-1	1	-1	1	-1	1	-1	1	1	
6	16	0%	T	1	-1	-1	-1	1	-1	1	-1	-1	1	100
			A	1	-1	-1	-1	1	-1	1	-1	-1	1	
		50%	P	-1	-1	1	1	1	-1	-1	-1	-1	-1	70
			A	-1	-1	1	1	1	-1	1	-1	-1	1	
7	8	0%	T	1	1	1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	1	-1	1	-1	-1	-1	-1	-1	-1	80
			A	1	1	-1	-1	-1	1	-1	-1	-1	-1	
8	2	0%	T	1	1	-1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	-1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	-1	-1	-1	1	1	-1	-1	1	-1	50
			A	-1	1	-1	-1	1	1	-1	1	1	-1	
9	6	0%	T	1	-1	1	-1	-1	1	-1	-1	-1	-1	80
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	1	1	1	-1	1	1	1	1	1	-1	80
			A	1	1	1	-1	-1	1	-1	1	-1	-1	
10	13	0%	T	1	-1	1	1	-1	-1	1	-1	-1	1	100
			A	1	-1	1	1	-1	-1	1	-1	-1	1	
		50%	P	-1	-1	1	1	1	1	1	-1	1	-1	70
			A	-1	-1	1	1	1	-1	1	-1	1	1	
11	16	0%	T	1	-1	-1	-1	1	-1	1	-1	-1	1	100
			A	1	-1	-1	-1	1	-1	1	-1	-1	1	
		50%	P	-1	-1	-1	1	1	1	1	1	1	1	50
			A	-1	-1	-1	1	1	-1	-1	1	1	1	
12	8	0%	T	1	1	1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	1	-1	1	-1	-1	1	-1	1	-1	10
			A	-1	-1	-1	1	-1	-1	-1	1	1	1	
13	7	0%	T	1	-1	1	-1	-1	1	1	-1	-1	-1	90
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	1	-1	1	1	-1	-1	-1	1	1	-1	30

			A	-1	-1	1	1	-1	-1	-1	1	1	1
--	--	--	---	----	----	---	---	----	----	----	---	---	---

Tablica P1.6. Procjene točnosti *HEBBSU* algoritma za 0% i 50% šuma

Red broj	Tip Troš.	Šum	Željeni izlaz - T Novi ulaz - P	Elementi sustava										Točnost <i>HEBBSU</i> algoritma %
			Procjenjeni izlaz - A	f1	f2	č	p	t	F	v	ω	o	α	
				1	2	3	4	5	6	7	8	9	10	
1	5	0%	T	1	1	-1	-1	-1	1	-1	-1	-1	-1	90
			A	1	1	-1	-1	-1	1	-1	-1	-1	1	
		50%	P	1	1	1	-1	1	-1	1	-1	1	-1	60
			A	1	-1	1	-1	1	-1	1	-1	-1	-1	
2	17	0%	T	1	-1	-1	1	-1	-1	1	-1	-1	-1	100
			A	1	-1	-1	1	-1	-1	1	-1	-1	-1	
		50%	P	1	1	-1	1	-1	1	1	1	1	-1	50
			A	1	1	-1	1	-1	1	-1	1	1	-1	
3	2	0%	T	1	1	-1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	-1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	50
			A	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	
4	1	0%	T	1	1	-1	-1	1	1	-1	1	-1	-1	90
			A	1	1	-1	-1	-1	1	-1	1	-1	-1	
		50%	P	1	-1	1	1	1	-1	-1	-1	-1	-1	50
			A	1	-1	1	-1	1	-1	1	-1	-1	-1	
5	6	0%	T	1	-1	1	-1	-1	1	-1	-1	-1	-1	100
			A	1	-1	1	-1	-1	1	-1	-1	-1	-1	
		50%	P	1	1	1	-1	1	-1	-1	-1	1	1	50
			A	1	1	1	-1	1	-1	-1	-1	1	1	
6	16	0%	T	1	-1	-1	-1	1	-1	1	-1	-1	1	100
			A	1	-1	-1	-1	1	-1	1	-1	-1	1	
		50%	P	-1	-1	1	1	1	-1	-1	-1	-1	-1	70
			A	-1	-1	1	1	1	-1	1	-1	-1	1	
7	8	0%	T	1	1	1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	1	-1	1	-1	-1	-1	-1	-1	-1	50
			A	-1	1	-1	1	-1	-1	-1	-1	-1	-1	
8	2	0%	T	1	1	-1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	-1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	-1	-1	-1	1	1	-1	-1	1	-1	40
			A	-1	-1	-1	-1	1	1	-1	1	1	-1	
9	6	0%	T	1	-1	1	-1	-1	1	-1	-1	-1	-1	100
			A	1	-1	1	-1	-1	1	-1	-1	-1	-1	
		50%	P	1	1	1	-1	1	1	1	1	1	-1	70
			A	1	1	1	-1	-1	1	-1	1	1	-1	
10	13	0%	T	1	-1	1	1	-1	-1	1	-1	-1	1	100
			A	1	-1	1	1	-1	-1	1	-1	-1	1	
		50%	P	-1	-1	1	1	1	1	1	-1	1	-1	70
			A	-1	-1	1	1	1	-1	1	-1	1	-1	
11	16	0%	T	1	-1	-1	-1	1	-1	1	-1	-1	1	100
			A	1	-1	-1	-1	1	-1	1	-1	-1	1	
		50%	P	-1	-1	-1	1	1	1	1	1	1	1	60
			A	-1	-1	-1	1	1	-1	1	1	1	1	
12	8	0%	T	1	1	1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	1	-1	1	-1	-1	1	-1	1	-1	50
			A	-1	1	-1	1	-1	-1	1	-1	1	-1	
13	7	0%	T	1	-1	1	-1	-1	1	1	-1	-1	-1	90
			A	1	-1	1	-1	-1	1	1	-1	-1	1	
		50%	P	1	-1	1	1	-1	-1	-1	-1	1	-1	40
			A	1	-1	1	1	-1	-1	-1	1	1	-1	

			A	-1	-1	1	1	-1	-1	-1	1	1	-1	
--	--	--	---	----	----	---	---	----	----	----	---	---	----	--

Tablica P1.7. Procjene točnosti INSSU algoritma za 0% i 50% šuma

Red broj	Tip Troš.	Šum	Željeni izlaz - T Novi ulaz - P	Elementi sustava										Točnost INSSU algoritma %
			Procijenjeni, izlaz - A	f1	f2	č	p	t	F	v	ω	o	α	
				1	2	3	4	5	6	7	8	9	10	
1	5	0%	T	1	1	-1	-1	-1	1	-1	-1	-1	-1	100
			A	1	1	-1	-1	-1	1	-1	-1	-1	-1	
		50%	P	1	1	1	-1	1	-1	1	-1	1	-1	50
			A	1	-1	1	-1	1	-1	1	-1	-1	-1	
2	17	0%	T	1	-1	-1	1	-1	-1	1	-1	-1	-1	90
			A	1	-1	-1	-1	-1	-1	1	-1	-1	-1	
		50%	P	1	1	-1	1	-1	1	1	1	1	-1	30
			A	-1	1	-1	-1	-1	1	-1	1	1	-1	
3	2	0%	T	1	1	-1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	-1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	60
			A	1	-1	-1	1	-1	-1	1	-1	-1	1	
4	1	0%	T	1	1	-1	-1	1	1	-1	1	-1	-1	90
			A	1	1	-1	-1	-1	1	-1	1	-1	-1	
		50%	P	1	-1	1	1	1	-1	-1	-1	-1	-1	50
			A	1	-1	1	-1	1	-1	1	-1	-1	-1	
5	6	0%	T	1	-1	1	-1	-1	1	-1	-1	-1	-1	80
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	1	1	1	-1	1	-1	-1	-1	1	1	50
			A	-1	-1	1	-1	1	-1	-1	-1	1	1	
6	16	0%	T	1	-1	-1	-1	1	-1	1	-1	-1	1	100
			A	1	-1	-1	-1	1	-1	1	-1	-1	1	
		50%	P	-1	-1	1	1	1	-1	-1	-1	-1	-1	70
			A	-1	-1	1	1	1	-1	1	-1	-1	1	
7	8	0%	T	1	1	1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	1	-1	1	-1	-1	-1	-1	-1	-1	60
			A	-1	1	-1	1	-1	1	-1	-1	-1	-1	
8	2	0%	T	1	1	-1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	-1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	-1	-1	-1	1	1	-1	-1	1	-1	50
			A	-1	1	-1	-1	1	1	-1	1	1	-1	
9	6	0%	T	1	-1	1	-1	-1	1	-1	-1	-1	-1	80
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	1	1	1	-1	1	1	1	1	1	-1	80
			A	1	1	1	-1	-1	1	-1	1	-1	-1	
10	13	0%	T	1	-1	1	1	-1	-1	1	-1	-1	1	100
			A	1	-1	1	1	-1	-1	1	-1	-1	1	
		50%	P	-1	-1	1	1	1	1	1	-1	1	-1	70
			A	-1	-1	1	1	1	-1	1	-1	1	1	
11	16	0%	T	1	-1	-1	-1	1	-1	1	-1	-1	1	100
			A	1	-1	-1	-1	1	-1	1	-1	-1	1	
		50%	P	-1	-1	-1	1	1	1	1	1	1	1	50
			A	-1	-1	-1	1	1	-1	-1	1	1	1	
12	8	0%	T	1	1	1	-1	-1	1	1	-1	-1	-1	100
			A	1	1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	-1	1	-1	1	-1	-1	1	-1	1	-1	30
			A	-1	1	-1	1	-1	-1	1	1	1	1	
13	7	0%	T	1	-1	1	-1	-1	1	1	-1	-1	-1	100
			A	1	-1	1	-1	-1	1	1	-1	-1	-1	
		50%	P	1	-1	1	1	-1	-1	-1	1	1	-1	30
			A	1	-1	1	1	-1	-1	-1	1	1	-1	

			A	-1	-1	1	1	-1	-1	-1	1	1	1	
--	--	--	---	----	----	---	---	----	----	----	---	---	---	--

Tablica P1.8. Shema mapiranja postupaka modificiranja površina [49,50]

Šifre/Nazivi slojeva	Map. vrij.
GRUPA 1: MARTENZITNI	
1.1 PROKALJENI SLOJEVI	(-1,1)
1.2 PLAMENO KALJENI SLOJEVI	(-1,1)
1.3 INDUKCIJSKI KALJENI SLOJEVI	(-1,1)
1.4 LASERSKI KALJENI SLOJEVI	(-1,1)
1.5 ELEKTRONSKIM SNOPOM KALJENI SLOJEVI	(-1,1)
1.6 CEMENTIRANI SLOJEVI	(-1,1)
GRUPA 2: RUBNI S PROMJENOM KEM. SASTAVA	
2.1. NITRIRANI/NITROKARBURIRANI SLOJEVI	(-1,1)
2.2. BORIRANI SLOJEVI	(-1,1)
2.3 VANADIRANI SLOJEVI	(-1,1)
GRUPA 3: TOPLINSKI NAŠTRCANI	
3.1 SLOJEVI SAMOTEKUĆIH LEGURA	(-1,1)
3.2 SLOJEVI ČISTIH METALA	(-1,1)
3.3 SLOJEVI METALNIH KARBIDA	(-1,1)
3.4 SLOJEVI METALNIH OKSIDA	(-1,1)
3.5 SLOJEVI LEGURA NA BAZI Fe	(-1,1)
3.6 SLOJEVI POSEBNIH MATERIJALA	(-1,1)
GRUPA 4: CVD	
4.1 CVD SLOJEVI NA BAZI Ti (ISOKOTEMPERATURNI)	(-1,1)
4.2 CVD SLOJEVI NA BAZI Al ₂ O ₃ (VISOKOTEMPERATURNI)	(-1,1)
4.3 CVD SLOJEVI NA BAZI Ti(C,N) (SREDNJETEMPERATURNI)	(-1,1)
GRUPA 5: PVD	
5.1 PVD TITANNITRIDNI SLOJEVI	(-1,1)
5.2 PVD TITANKARBONITRIDNI SLOJEVI	(-1,1)
5.3 PVD TITANALUMINIJNITRIDNI SLOJEVI	(-1,1)
5.4 PVD KROMNITRIDNI SLOJEVI	(-1,1)
GRUPA 6: NAVARENI	
6.1 NAVARENI SLOJEVI OTPORNI TROŠENJU NA OSNOVI MATERIJALA	(-1,1)
6.2 NAVARENI SLOJEVI SLIČNIH ČELIKU	(-1,1)
6.3 NAVARENI SLOJEVI S VISOKIM UDJELOM TVRDIH KARBIDA	(-1,1)
6.4 NAVARENI SLOJEVI OTPORNI KOROZIJI	(-1,1)
6.5 NAVARENI SLOJEVI OTPORNI KOROZIJI I TROŠENJU	(-1,1)
6.6 NAVARENI DISPERGIRANI I LEGIRANI SLOJEVI	(-1,1)
GRUPA 7: SLOJEVI DOBIVENI LASERSKIM RASTALJIVANJEM	
7.1 LASERSKI RUBNI SLOJEVI S DISPERGIRANO ULEŽIŠTENIM ČESTICAMA	(-1,1)
7.2 LASERSKI LEGIRANI RUBNI SLOJEVI	(-1,1)
7.3 LASERSKO OSLOJAVANJE	(-1,1)
7.4 LASERSKO OSLOJAVANJE PRETALJIVANJEM	(-1,1)

Tablica P1.10. Usporedba površinskih slojeva otpornih koroziji [44]

Oznake sloja prema tab.3.7	Površinski sloj (postupak)	Tip korozije			
		M0/M1	M2	M3	M4
2.1	Nitrirani/Nitrokarburirani slojevi (Nitriranje/Karbonitriranje)	2	2	1	0
a) .2	b) orirani slojevi (Boriranje)	2	1	0	0
c) .2	d) lojevi čistih metala Molibden (Naštrcavanje)	2	2	1	1
e) .3	f) lojevi metalnih karbida (Naštrcavanje)	2	2	1	0
g) .4	h) lojevi metalnih oksida (Naštrcavanje)	2	2	1	0
j) .5	k) lojevi legura (Naštrcavanje)	2	2	2	2
3.6	Slojevi posebnih materijala Koroz. postojani čelici (Naštrcavanje)	2	2	1	1
6.3	Korozijski otporni slojevi Visoko leg. čelici (Navarivanje)	2	2	1	0
4.3	Srednjetemperaturni CVD slojevi na Ti(C,N) osnovi (CVD)	2	2	1	0
l) .1	m) itannitridni slojevi (PVD)	2	2	2	1
5.2	Titankarbonitridni slojevi (PVD)	2	2	2	1
5.3	Titanaluminijnitridni slojevi (PVD)	2	2	2	1

n) 4	o) romnitridni slojevi (PVD)	K	2	2	2	1
---------	------------------------------------	---	---	---	---	---

Tablica P1.11. Mapirane vrijednosti površinskih slojeva otpornih koroziji

Tip korozije	ULAZNI SKUP Mapirane vrijednosti	IZLAZNI SKUP Oznake slojeva												
		2.1	2.2	3.2	3.3	3.4	3.5	3.6	6.3	4.3	5.1	5.2	5.3	5.4
		M0/M1	(1 0 0 0)	2	2	2	2	2	2	2	2	2	2	2
M2	(0 1 0 0)	2	1	2	2	2	2	2	2	2	2	2	2	2
M3	(0 0 1 0)	1	0	1	1	1	2	1	1	1	2	2	2	2
M4	(0 0 0 1)	0	0	1	0	0	2	1	0	0	1	1	1	1

Tablica P1.12. Usporedba površinskih slojeva otpornih trošenju [44]

Oznake sloja prema tab.3.7	Površinski sloj (postupak)	Mehanizam/Tip trošenja					
		Adhezija		Abrazija		Erozija česticama	Izjedanje
		slaba	jaka	slaba	jaka		
2.1	Nitrirani/Nitrokarburirani slojevi (Nitriranje/Karbonitriranje)	2	1	1	1	0	1

p)	q)	B						
.2	orirani slojevi (Boriranje)		2	1	2	1	0	2
r)	s)	S						
.2	lojevi čistih metala Molibden (Naštrcavanje)		2	2	2	1	1	2
t)	u)	S						
.3	lojevi metalnih karbida (Naštrcavanje)		1	0	2	1	0	2
v)	w)	S						
.4	lojevi metalnih oksida x) (Naštrcavanje)	(1	0	2	1	0	2
y)	z)	S						
.5	lojevi legura (Naštrcavanje)		1	1	2	2	1	2
3.6	Slojevi posebnih materijala Koroz. postojani čelici (Naštrcavanje)		1	0	1	1	0	1
6.3	Korozijski otporni slojevi Visoko leg. čelici (Navarivanje)		1	1	2	2	1	1
4.3	Srednjetemperaturni CVD slojevi na Ti(C,N) osnovi (CVD)		2	2	2	1	0	2
aa)	bb)	T						
.1	itannitridni slojevi (PVD)		1	1	2	1	0	2
5.2	Titankarbonitridni slojevi (PVD)		1	1	2	1	0	2
5.3	Titanaluminijnitridni slojevi (PVD)		1	1	2	1	0	2
cc)	dd)	K						
.4	romnitridni slojevi (PVD)		1	1	2	1	0	2
Legenda: 0=Nepodobno, 1=Moguće, 2=Podobno								

Tablica P1.13. Mapirane vrijednosti površinskih slojeva otpornih trošenju

Oznake slojeva prema tab.3.7	ULAZNI SKUP Mapirane vrijednosti	IZLAZNI SKUP					
		Adhezija		Abrazija		Erozija česticama	Izjedanje
		slaba	jaka	slaba	jaka		
2.1	(10000000000000)	2	1	1	1	0	1
ee) .2	(01000000000000)	2	1	2	1	0	2
ff) .2	(00100000000000)	2	2	2	1	1	2
gg) .3	(00010000000000)	1	0	2	1	0	2
hh) .4	(00001000000000)	1	0	2	1	0	2
ii) .5	(00000100000000)	1	1	2	2	1	2
3.6	(00000010000000)	1	0	1	1	0	1
6.3	(00000001000000)	1	1	2	2	1	1
4.3	(00000000100000)	2	2	2	1	0	2
jj) .1	(00000000010000)	1	1	2	1	0	2
5.2	(00000000001000)	1	1	2	1	0	2
5.3	(00000000000010)	1	1	2	1	0	2
kk) .4	(00000000000001)	1	1	2	1	0	2

Tablica P1.14. Kem. postojanost nehrđajućih i kemijski postojanih čelika u kem. čistim otopinama [45]

Otopina	Maseni udio w %	Temp. °C	Oznaka čelika			
			Č4170	Č4750	Č4571	Č4573
			Č4171		Č4572	Č4574
			Č4172		Č4580	Č4583
			Č4173		Č4582	
			Č4175			
			Č4770			
			Ocjena postojanosti			
Nitratna HNO ₃	1	20	0	0	0	0
		100	1	0	0	0

	5	20	0	0	0	0	
		100	1	0	0	0	
	10	20	0	0	0	0	
		100	1	1	0	0	
	25	20	4	0	0	0	
		100	4	1	0	0	
	40	20	4	0	0	0	
		100	4	1	0	0	
	50	20	4	0	0	0	
		100	4	1	1	1	
	65	20	4	0	0	0	
		100	4	3	0	2	
	90	20	4	0	0	0	
		100	4	3	2	2	
	99	20	4	2	1	2	
		100	4	3	3	3	
	Fosfatna H ₃ PO ₄	1	20	1	0	0	0
			100	2	1	0	0
10		20	2	1	0	0	
		100	2	2	0	0	
50		20	4	4	0	0	
		100	3	3	2	1	
80		20	4	4	1	0	
		100	3	3	3	2	
koncentr.		20	2	2	1	0	
		100	3	3	3	3	
Octena CH ₃ COOH	10	20	1	0	1	0	
		100	3	2	0	0	
	50	20	2	1	0	0	
		100	3	2	2	0	
	Koncentr.	20	1	0	0	0	
		100	2	1	1	1	
Kloridna HCl	0,2	20	4	2	1	1	
		50	4	2	2	1	
	0,5	20	4	3	1	1	
		50	4	3	3	2	
	1,0	20	4	3	2	1	
		50	4	3	3	3	
	2,0	20	4	3	3	3	
		50	4	3	3	3	

Nastavak-Tablica P1.13. Kem. postojanost nehrđajućih i kemijski postojanih čelika u kem. čistim otopinama [45]

Otopina	Maseni udio w %	Temp. °C	Oznaka čelika			
			Č4170 Č4171 Č4172 Č4173 Č4175 Č4770	Č4750	Č4571 Č4572 Č4580 Č4582	Č4573 Č4574 Č4583
Ocjena postojanosti						
Sulfatna	1	20	3	1	1	0

H ₂ SO ₄		70	3	3	1	0
			100	3	3	1
2,5	20	3	3	1	0	
	70	3	3	1	0	
	100	3	3	2	2	
5	20	3	3	1	0	
	70	3	3	1	1	
	100	3	3	1	2	
7,5	20	3	3	1	0	
	70	3	3	1	1	
	100	3	3	2	2	
10	20	3	3	2	1	
	70	3	3	2	2	
	100	3	3	3	2	
20	20	3	3	1	1	
	70	3	3	2	2	
	100	3	3	3	3	
40	20	3	3	1	1	
	70	3	3	2	2	
	100	3	3	3	3	
60	20	3	3	3	2	
	70	3	3	3	3	
	100	3	3	3	3	
80	20	3	3	1	1	
	70	3	3	3	2	
	100	3	3	3	3	
98	20	4	0	0	0	
	70	2	2	2	2	
	100	3	3	3	3	

Legenda: 0=Potpuno postojan, 1=Manje postojan, 2=Slabo postojan, 3=Nepostojan, 4=Nepoznata postojanost

Tablica P1.15. Ulazno-izlazna matrica za učenje postojanosti čelika djelovanju CH₃COOH

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(CH ₃ COOH),%	T, °C	postojanost
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	1.0000
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	1.0000
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	20.0000	0.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	20.0000	0.0000
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	3.0000
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	10.0000	100.0000	2.0000

0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	100.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	2.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	20.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	50.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	100.0000	2.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	1.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	99.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	100.0000	2.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	99.0000	100.0000	1.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	99.0000	100.0000	1.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	1.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	10.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	2.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	50.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	1.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	99.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	99.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	100.0000	2.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	99.0000	100.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	100.0000	1.0000	
\bar{X}	0.1685	1.0000	1.4285	15.6428	4.8571	0.2857	53.0000	60.0000	1.1667
min	0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	0.0000
max	0.4000	1.0000	2.0000	18.0000	12.0000	2.0000	99.0000	100.0000	3.0000
σ_x	0.1064	0.0000	0.5008	2.3381	5.1729	0.7083	36.8371	40.4848	1.0801

Tablica P1.16. Ulazno-izlazna matrica za validaciju postojanosti čelika djelovanju CH₃COOH

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(CH ₃ COOH),%	T, °C	postojanost
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	10.0000	20.0000	1.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	20.0000	0.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	20.0000	0.0000
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	3.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	10.0000	100.0000	3.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	100.0000	0.0000

0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	50.0000	20.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	50.0000	100.0000	3.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	99.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	100.0000	2.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	99.0000	100.0000	2.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	100.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	100.0000	1.0000	
\bar{x}	0.1857	0.9285	1.5714	15.9285	6.0000	0.6285	53.0000	65.7142	1.1426
Min	0.0700	0.5000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	0.0000
Max	0.5000	1.0000	2.0000	18.0000	12.0000	2.0000	99.0000	100.0000	3.0000
σ_x	0.1511	0.1792	0.5070	2.1810	5.4497	0.8995	37.2947	40.5674	1.1952

Tablica P1.17. Ulazno-izlazna matrica za test postojanosti čelika djelovanju CH₃COOH

ULAZNI SKUP								IZLAZNI SKUP	
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(CH ₃ COOH),%	T, °C	postojanost	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	1.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	10.0000	20.0000	1.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	10.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	100.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	2.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	50.0000	20.0000	2.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	100.0000	2.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	1.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	99.0000	20.0000	1.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	99.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	100.0000	1.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	100.0000	1.0000	
\bar{x}	0.1857	0.9285	1.5714	15.9285	6.0000	0.6285	53.0000	54.2857	0.9523
min	0.0700	0.5000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	0.0000
max	0.5000	1.0000	2.0000	18.0000	12.0000	2.0000	99.0000	100.0000	3.0000
σ_x	0.1511	0.1792	0.5070	2.1810	5.4497	0.8995	37.2947	40.5674	1.0235

Tablica P1.18. Ulazno-izlazna matrica za učenje postojanosti čelika djelovanju HCl

ULAZNI SKUP							IZLAZNI SKUP	
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	20.0000	4.0000
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	20.0000	4.0000
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	0.2000	20.0000	1.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	0.2000	20.0000	1.0000
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	50.0000	4.0000
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	0.2000	50.0000	2.0000

0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	0.2000	50.0000	2.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	0.5000	20.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	0.5000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	0.5000	20.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	0.5000	20.0000	1.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	0.5000	50.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	0.5000	50.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	0.5000	50.0000	3.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	20.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	1.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	50.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	1.0000	50.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	50.0000	3.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	2.0000	20.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	2.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	2.0000	20.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	2.0000	20.0000	3.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	2.0000	50.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	2.0000	50.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	2.0000	50.0000	3.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	0.2000	20.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	0.2000	20.0000	1.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	50.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	50.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	0.2000	50.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	0.2000	50.0000	1.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	0.5000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	0.5000	20.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	0.5000	20.0000	1.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	0.5000	50.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	0.5000	50.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	0.5000	50.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	0.5000	50.0000	2.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	1.0000	20.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	20.0000	2.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	50.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	50.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	2.0000	20.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	2.0000	50.0000	3.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	2.0000	50.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	2.0000	50.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	2.0000	50.0000	3.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	2.0000	50.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	2.0000	50.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	2.0000	50.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	2.0000	50.0000	3.0000	
\bar{X}	0.1685	1.0000	1.4258	15.6428	4.8571	0.2857	0.9250	35.0000	3.0178
min	0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	20.0000	1.0000
max	0.4000	1.0000	2.0000	18.0000	12.0000	2.0000	2.0000	50.0000	4.0000
σ_x	0.1061	0.0000	0.4993	2.3310	5.1572	0.7061	0.6894	15.1357	1.0701

Tablica P1.19. Ulazno-izlazna matrica za validaciju postojanosti čelika djelovanju HCl

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	0.2000	20.0000	4.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	0.2000	20.0000	1.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	0.2000	20.0000	1.0000
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	50.0000	4.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	0.2000	50.0000	4.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	0.2000	50.0000	2.0000

0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	0.2000	50.0000	1.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	0.5000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	0.5000	20.0000	1.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	0.5000	20.0000	1.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	0.5000	50.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	0.5000	50.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	0.5000	50.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	0.5000	50.0000	2.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	20.0000	2.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	1.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	50.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	50.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	50.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	50.0000	3.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	2.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	2.0000	20.0000	3.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	2.0000	20.0000	3.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	2.0000	50.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	2.0000	50.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	2.0000	50.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	2.0000	50.0000	3.0000	
\bar{X}	0.1857	0.9285	1.5714	15.9285	6.0000	0.6285	0.9250	37.1428	2.8928
Min	0.0700	0.5000	1.0000	13.0000	0.0000	0.0000	0.2000	20.0000	1.0000
Max	0.5000	1.0000	2.0000	18.0000	12.0000	2.0000	2.0000	50.0000	4.0000
σ_x	0.1502	0.1781	0.5039	2.1675	5.4160	0.8939	0.6958	15.1185	1.1968

Tablica P1.20. Ulazno-izlazna matrica za test postojanosti čelika djelovanju HCl

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	20.0000	4.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	0.2000	20.0000	4.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	0.2000	20.0000	1.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	0.2000	20.0000	1.0000
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	0.2000	50.0000	4.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	0.2000	50.0000	2.0000

0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	0.2000	50.0000	1.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	0.5000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	0.5000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	0.5000	20.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	0.5000	20.0000	1.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	0.5000	50.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	0.5000	50.0000	3.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	0.5000	50.0000	2.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	20.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	1.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	50.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	50.0000	3.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	50.0000	3.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	2.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	2.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	2.0000	20.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	2.0000	20.0000	3.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	2.0000	50.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	2.0000	50.0000	3.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	2.0000	50.0000	3.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	0.2000	20.0000	4.0000	
\bar{X}	0.1857	0.9285	1.5714	15.9285	6.0000	0.6285	0.9250	32.8571	2.8928
Min	0.0700	0.5000	1.0000	13.0000	0.0000	0.0000	0.2000	20.0000	1.0000
Max	0.5000	1.0000	2.0000	18.0000	12.0000	2.0000	2.0000	50.0000	4.0000
σ_x	0.1502	0.1781	0.5039	2.1675	5.4160	0.8939	0.6958	15.1185	1.1968

Tablica P1.21. Ulazno-izlazna matrica za učenje postojanosti čelika djelovanju HNO₃

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	0.0000
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	0.0000
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	20.0000	0.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	1.0000
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	1.0000	100.0000	0.0000

0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	10.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	1.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	1.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	25.0000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	25.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	25.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	25.0000	100.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	25.0000	100.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	25.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	25.0000	100.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	40.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	40.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	100.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	100.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	40.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	40.0000	100.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	50.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	100.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	1.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	65.0000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	65.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	65.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	65.0000	80.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	65.0000	80.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	65.0000	80.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	65.0000	80.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	65.0000	100.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	65.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	65.0000	100.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	90.0000	20.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	90.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	90.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	90.0000	20.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	90.0000	100.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	90.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	90.0000	100.0000	2.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	99.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	2.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	100.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	99.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	99.0000	100.0000	3.0000	
\bar{X}	0,1685	1,0000	1,4285	15,6428	4,8571	0,2857	43,9473	61,0526	1,5338
Min	0,0800	1,0000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,4000	1,0000	2,0000	18,0000	12,0000	2,0000	99,0000	100,0000	4,0000
σ_x	0,1056	0,0000	0,4967	2,3188	5,1303	0,7025	33,7527	39,3366	1,7561

Tablica P1.22. Ulazno-izlazna matrica za validaciju postojanosti čelika djelovanju HNO₃

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T,°C	postojanost
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	20.0000	0.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	20.0000	0.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	1.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	100.0000	1.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	100.0000	0.0000

0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	100.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	5.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	5.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	5.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	5.0000	100.0000	1.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	5.0000	100.0000	1.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	5.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	5.0000	100.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	10.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	1.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	10.0000	100.0000	1.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	25.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	25.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	25.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	25.0000	100.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	25.0000	100.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	25.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	25.0000	100.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	40.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	40.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	40.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	100.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	40.0000	100.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	40.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	40.0000	100.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	50.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	50.0000	100.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	100.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	1.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	65.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	65.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	65.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	65.0000	80.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	65.0000	80.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	65.0000	80.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	65.0000	80.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	65.0000	100.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	65.0000	100.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	65.0000	100.0000	2.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	90.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	90.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	90.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	90.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	90.0000	100.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	90.0000	100.0000	2.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	90.0000	100.0000	2.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	99.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	2.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	99.0000	100.0000	4.0000	
\bar{x}	0,1845	0,9318	1,5757	15,9469	6,0454	0,6303	43,7878	63,6363	1,5000
Min	0,0700	0,5000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,5000	1,0000	2,0000	18,0000	12,0000	2,0000	99,0000	100,0000	4,0000
σ_x	0,1469	0,1729	0,4980	2,1414	5,3534	0,8876	33,9608	39,2089	1,7475

Tablica P1.23. Ulazno-izlazna matrica za test postojanosti čelika djelovanju HNO₃

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	0.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	20.0000	0.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	20.0000	0.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	100.0000	1.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	100.0000	0.0000

0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	100.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	5.0000	20.0000	0.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	5.0000	20.0000	0.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	5.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	5.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	5.0000	100.0000	1.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	5.0000	100.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	5.0000	100.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	0.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	10.0000	20.0000	0.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	10.0000	100.0000	1.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	100.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	25.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	25.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	25.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	25.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	25.0000	100.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	25.0000	100.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	25.0000	100.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	40.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	40.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	40.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	40.0000	100.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	40.0000	100.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	40.0000	100.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	50.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	50.0000	100.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	100.0000	1.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	1.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	65.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	65.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	65.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	65.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	65.0000	80.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	65.0000	80.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	65.0000	80.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	65.0000	100.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	65.0000	100.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	65.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	65.0000	100.0000	2.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	90.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	90.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	90.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	90.0000	100.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	90.0000	100.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	90.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	90.0000	100.0000	2.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	99.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	20.0000	1.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	2.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	100.0000	4.0000	
\bar{X}	0,1868	0,9253	1,5671	15,9104	5,9552	0,6268	44,1044	58,5074	1,4925
Min	0,0700	0,5000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,5000	1,0000	2,0000	18,0000	12,0000	2,0000	99,0000	100,0000	4,0000
σ_x	0,1503	0,1795	0,4992	2,1478	5,3638	0,8813	33,8020	39,5908	1,7869

Tablica P1.24. Ulazno-izlazna matrica za učenje postojanosti čelika djelovanju H₃PO₄

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	1.0000
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	1.0000
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	20.0000	0.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	2.0000
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	1.0000	100.0000	1.0000
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	100.0000	0.0000

0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	2.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	20.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	2.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	10.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	100.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	20.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	50.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	100.0000	2.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	20.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	80.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	20.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	80.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	80.0000	100.0000	3.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	2.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	99.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	99.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	99.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	1.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	1.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	2.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	100.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	2.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	10.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	2.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	10.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	50.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	20.0000	0.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	50.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	1.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	20.0000	4.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	80.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	80.0000	20.0000	1.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	100.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	80.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	100.0000	2.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	2.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	99.0000	20.0000	2.0000	
\bar{x}	0,1685	1,0000	1,4285	15,6428	4,8571	0,2857	48,0000	60,0000	1,8142
Min	0,0800	1,0000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,4000	1,0000	2,0000	18,0000	12,0000	2,0000	99,0000	100,0000	4,0000
σ_x	0,1059	0,0000	0,4984	2,3268	5,1479	0,7049	38,4383	40,2888	1,3651

Tablica P1.25. Ulazno-izlazna matrica za validaciju postojanosti čelika djelovanju H₃PO₄

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	20.0000	1.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	20.0000	0.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	2.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	100.0000	2.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	100.0000	0.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	100.0000	0.0000

0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	10.0000	20.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	100.0000	2.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	10.0000	100.0000	2.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	100.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	50.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	50.0000	100.0000	3.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	1.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	80.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	80.0000	20.0000	1.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	100.0000	3.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	80.0000	100.0000	3.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	80.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	100.0000	2.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	99.0000	20.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	20.0000	1.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	100.0000	3.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	99.0000	100.0000	3.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	100.0000	3.0000	
\bar{x}	0,1857	0,9285	1,5714	15,9285	6,0000	0,6285	48,0000	65,7142	1,5714
Min	0,0700	0,5000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,5000	1,0000	2,0000	18,0000	12,0000	2,0000	99,0000	100,0000	4,0000
σ_x	0,1496	0,1775	0,5021	2,1596	5,3960	0,8906	38,7199	40,1677	1,3565

Tablica P1.26. Ulazno-izlazna matrica za test postojanosti čelika djelovanju H₃PO₄

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	1.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	20.0000	1.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	20.0000	0.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	100.0000	2.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	100.0000	0.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	100.0000	0.0000
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	10.0000	20.0000	2.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	10.0000	20.0000	2.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	20.0000	0.0000

0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	10.0000	100.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	10.0000	100.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	10.0000	100.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	50.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	50.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	50.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	50.0000	100.0000	2.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	50.0000	100.0000	1.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	80.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	80.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	80.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	80.0000	100.0000	3.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	100.0000	2.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	99.0000	20.0000	2.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	99.0000	20.0000	2.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	20.0000	1.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	99.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	99.0000	100.0000	3.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	99.0000	100.0000	3.0000	
\bar{X}	0,1857	0,9285	1,5714	15,9285	6,0000	0,6285	48,0000	54,2857	1,5714
Min	0,0700	0,5000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,5000	1,0000	2,0000	18,0000	12,0000	2,0000	99,0000	100,0000	4,0000
σ_x	0,1496	0,1775	0,5021	2,1596	5,3960	0,8906	38,7199	40,1677	1,4201

Tablica P1.27. Ulazno-izlazna matrica za učenje postojanosti čelika djelovanju H₂SO₄

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	20.0000	1.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	70.0000	3.0000
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	1.0000	70.0000	3.0000
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	70.0000	1.0000
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	3.0000
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	3.0000
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	1.0000	100.0000	1.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	100.0000	1.0000
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	2.5000	20.0000	3.0000

0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	20.0000	100.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	20.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	20.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	20.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	20.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	40.0000	20.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	40.0000	20.0000	1.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	70.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	70.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	40.0000	70.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	40.0000	70.0000	2.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	40.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	40.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	40.0000	100.0000	3.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	60.0000	20.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	60.0000	20.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	60.0000	20.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	60.0000	20.0000	2.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	60.0000	70.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	60.0000	70.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	60.0000	70.0000	3.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	60.0000	100.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	60.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	60.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	60.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	20.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	80.0000	20.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	80.0000	20.0000	1.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	70.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	70.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	80.0000	70.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	70.0000	2.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	100.0000	3.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	80.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	80.0000	100.0000	3.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	98.0000	20.0000	4.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	98.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	98.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	98.0000	20.0000	0.0000	
0.2000	1.0000	1.0000	13.0000	0.0000	0.0000	98.0000	70.0000	2.0000	
0.2000	1.0000	1.0000	17.0000	2.0000	0.0000	98.0000	70.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	98.0000	70.0000	2.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	98.0000	100.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	98.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	10.0000	0.0000	98.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	98.0000	100.0000	3.0000	
0.0800	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000	
0.4000	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000	
\bar{X}	0,1685	1,0000	1,4285	15,6428	4,8571	0,2857	32,4000	63,3333	2,4238
Min	0,0800	1,0000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,4000	1,0000	2,0000	18,0000	12,0000	2,0000	98,0000	100,0000	4,0000
σ_x	0,1054	0,0000	0,4960	2,3156	5,1232	0,7015	33,6881	33,0771	0,9364

Tablica P1.28. Ulazno-izlazna matrica za validaciju postojanosti čelika djelovanju H₂SO₄

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T, °C	postojanost
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	20.0000	3.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	20.0000	1.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	70.0000	3.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	70.0000	3.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	70.0000	1.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	70.0000	0.0000
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	100.0000	3.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	100.0000	1.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	100.0000	1.0000
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	2.5000	20.0000	3.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	2.5000	20.0000	3.0000

0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	80.0000	70.0000	3.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	80.0000	70.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	70.0000	2.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	80.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	80.0000	100.0000	3.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	100.0000	3.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	98.0000	20.0000	4.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	98.0000	20.0000	4.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	98.0000	20.0000	0.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	98.0000	20.0000	0.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	98.0000	70.0000	2.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	98.0000	70.0000	2.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	98.0000	70.0000	2.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	98.0000	100.0000	3.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	98.0000	100.0000	3.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	98.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	98.0000	100.0000	3.0000	
\bar{X}	0,1857	0,9285	1,5714	15,9285	6,0000	0,6285	32,6476	63,3333	2,2381
Min	0,0700	0,5000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,5000	1,0000	2,0000	18,0000	12,0000	2,0000	98,0000	100,0000	4,0000
σ_x	0,1482	0,1758	0,4972	2,1387	5,3439	0,8820	33,9223	33,1565	1,0333

Tablica P1.29. Ulazno-izlazna matrica za test postojanosti čelika djelovanju H₂SO₄

ULAZNI SKUP								IZLAZNI SKUP
%C	%Si	%Mn	%Cr	%Ni	%Mo	w(HCl),%	T,°C	postojanost
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	20.0000	3.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	20.0000	3.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	20.0000	1.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	20.0000	0.0000
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	1.0000	70.0000	3.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	70.0000	1.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	70.0000	0.0000
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	1.0000	100.0000	3.0000
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	1.0000	100.0000	3.0000
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	1.0000	100.0000	1.0000
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	1.0000	100.0000	1.0000
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	2.5000	20.0000	3.0000
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	2.5000	20.0000	1.0000
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	2.5000	20.0000	0.0000

0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	70.0000	2.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	80.0000	100.0000	3.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	80.0000	100.0000	3.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	80.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	80.0000	100.0000	3.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	98.0000	20.0000	4.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	98.0000	20.0000	0.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	98.0000	20.0000	0.0000	
0.1500	1.0000	1.0000	13.0000	0.0000	0.0000	98.0000	70.0000	2.0000	
0.5000	0.5000	1.0000	14.0000	0.0000	0.4000	98.0000	70.0000	2.0000	
0.0700	1.0000	2.0000	18.0000	9.0000	0.0000	98.0000	70.0000	2.0000	
0.1000	1.0000	2.0000	17.5000	12.0000	2.0000	98.0000	70.0000	2.0000	
0.3000	1.0000	1.0000	13.5000	0.0000	0.0000	98.0000	100.0000	3.0000	
0.1000	1.0000	2.0000	18.0000	9.0000	0.0000	98.0000	100.0000	3.0000	
0.0800	1.0000	2.0000	17.5000	12.0000	2.0000	98.0000	100.0000	3.0000	
\bar{X}	0,1857	0,9285	1,5714	15,9285	6,0000	0,6285	32,1523	63,3333	2,2190
Min	0,0700	0,5000	1,0000	13,0000	0,0000	0,0000	1,0000	20,0000	0,0000
Max	0,5000	1,0000	2,0000	18,0000	12,0000	2,0000	98,0000	100,0000	4,0000
σ_x	0,1482	0,1758	0,4972	2,1387	5,3439	0,8820	33,6132	33,1565	1,0188

Tablica P1.30. Mehanička svojstva materijala u zavisnosti od kemijskog sastava u kaljenom stanju [46]

i	%Mo	%W	II) %Le	mm)	Rm, mm)	Re, oo)
				N/mm ²	N/mm ²	
0	0,0	0,0	28,62		540	175
0	3,5	0,0	37,54		800	640
0	0,0	1,1	31,3		880	390
0	0,0	0,0	14,65		1030	
0	0,0	0,0	15,21		1570	
0	0,0	0,0	20,68		950	

1,65	0,0	37,08	700		
0,74	0,2		924	119	
0	0		540	175	
3,5	1,1		1570	640	
1,37	0,4		328	233	

¹Unešene su prosječne vrijednosti kemijskog sastava i mehaničkih svojstava

Tablica P1.31. Mehanička svojstva materijala u zavisnosti od kemijskog sastava u poboljšanom stanju [46]

n	%Cr	%Ni	%Mo	%Al	qq)	Rm,	rr)	Re,	ss)	HV	As, %	tt)
						N/mm ²		N/mm ²				
0	0,0	0,0	0,0	0,0		515		245		155	22	
5	0,0	0,0	0,0	0,0		525		280		155	20	
0	1,0	0,0	0,25	0,0		955		390		280	9	
0	0,0	0,0	0,4	0,0		515		245		153	9	
0	1,3	0,0	0,5	0,0		565		315		170	20	
0	0,70	0,0	0,5	0,0		1550		1240		470	3	
0	13,5	0,0	0,0	0,0		690		440		205	12	
0	18,0	9,0	0,0	0,0		540		175		165	20	
5	1,7	1,0	0,2	1,0		880		590		950	14	
5	1,15	1,0	0,2	1,0		880		590		950	14	
9	3,74	1,1	0,21	0,2		761,5		451		365,3	14,3	
0	0	0	0	0		515		175		153	3	
5	18	9	0,5	1		1550		1240		950	22	
5	6,45	2,81	0,21	0,42		326,2		311,6		323,1	6,2	

¹Unešene su prosječne vrijednosti kemijskog sastava i mehaničkih svojstava

Tablica P1.32. Kvantifikacija iskustvenih ocjena otpornosti trošenju čelika i čeličnog lijeva kaljenom stanju [46]

Oznaka HRN/DIN ¹	%C	%Si	%Mn	%Cr	%Ni	%Mo	%V	%W	ΣLe	Iskustvena ocjena	Kvantitativna ocjena
ČL3160 GX120Mn12	1,2	0,0	12,5	0,0	0,0	0,0	0,0	0,0	13,5	visoka	3
ČL3463 17MnCrL	1,4	0,0	17	1,8	0,0	0,0	0,0	0,0	20,2	visoka	3
ČL4150 -	2,0	0,0	0,0	10,0	0,0	0,0	0,0	0,0	12,0	srednja	2
ČL4759	3,4	0,0	0,0	15,0	0,0	2,8	0,0	0,0	21,2	visoka	3

-												
ČL4771	0,3	0,0	0,0	11,7	1,6	0,6	0,0	0,0	14,2	visoka	3	
ČL4780	2,0	0,0	0,0	15,0	0,0	0,5	0,0	0,0	17,5	srednja	2	
ČL4782	1,6	0,0	0,0	15,0	0,0	1,0	0,0	0,0	17,6	srednja	2	
ČL4784	3,0	0,0	0,0	20,0	0,0	2,0	0,0	0,0	25,0	visoka	3	
Č1531 C45W	0,45	0,35	0,80	0,0	0,0	0,0	0,0	0,0	1,6	1 ²	1	
Č1941 100V1	1,0	0,30	0,30	0,0	0,0	0,0	0,1	0,0	1,7	1	1	
Č1948 C135W	1,3	0,35	0,35	0,0	0,0	0,0	0,0	0,0	2,0	4	2	
Č4145 100Cr6	1,0	0,25	0,35	1,5	0,0	0,0	0,0	0,0	3,1	3	1	
Č3840 90MnCrV	0,9	0,25	2,0	0,35	0,0	0,0	0,1	0,0	3,6	4	2	
Č6443 45WCrV7	0,45	1,0	0,3	1,0	0,0	0,0	0,2	2,0	4,95	3	1	
Č4756 X100CrMoV51	1,0	0,3	0,6	5,0	0,0	1,0	0,2	0,0	8,1	6	2	
Č4150 X210Cr12	2,1	0,3	0,3	12,0	0,0	0,0	0,0	0,0	14,7	8	3	
Č4175 X42Cr13	0,4	1,0	1,0	13,0	0,0	0,0	0,0	0,0	15,4	2	1	
Č5742 56NiCrMoV7	0,55	0,0	0,7	1,0	1,7	0,5	0,1	0,0	4,55	2	1	
Č4751 X38CrMoV51	0,4	1,0	0,0	5,0	0,0	1,3	0,4	0,0	8,1	3	1	
Č6451 X30WCrV93	0,3	0,0	0,0	2,5	0,0	0,0	0,4	9,0	12,2	4	2	
Č6880 S18-0-1	0,75	0,0	0,0	4,0	0,0	0,0	1,1	18,0	23,8	7	3	
Č7680 S6-5-2	0,9	0,0	0,0	4,0	0,0	0,0	1,9	6,5	18,3	7	3	
Č9683 S10-4-3-10	1,3	0,0	0,0	4,0	0,0	3,7	3,2	10,0	32,7	7	3	
\bar{x}	1,20	0,22	1,57	6,17	0,14	0,58	0,33	1,98			2,1	
Min	0,3	0	0	0	0	0	0	0			1	
Max	3,4	1	17	20	1,7	3,7	3,2	18			3	
σ_x	0,84	0,34	4,24	6,26	0,48	1,01	0,77	4,58			0,8	

¹Unešene su prosječne vrijednosti kemijskog sastava

²Kvantitativno značenje iskustvenih brojičnih oznaka: 1-3=1; 4-6=2; 7-9=3

Tablica P1.33. Kvantifikacija iskustvenih ocjena otpornosti trošenju čelika i čeličnog lijeva u poboljšanom stanju [46]

Oznaka HRN/DIN*	%C	%Si	%Mn	%Cr	%Ni	%Mo	%V	%Al	ΣLe	Iskustvena ocjena	Kvantitativna ocjena
ČL3134 2ML	0,4	0,0	1,9	0,0	0,0	0,0	0,0	0,0	2,3	niska	1
- LM690	0,5	0,4	1,0	1,0	0,0	0,0	0,0	0,0	2,9	srednja	2
- LM691	0,28	0,45	1,0	0,7	0,0	0,5	0,0	0,0	2,93	srednja	2

Č4730 25CrMo4	0,26	0,27	0,65	1,05	0,0	0,23	0,0	0,0	2,69	niska	1
Č4731 34CrMo4	0,34	0,28	0,65	1,05	0,0	0,45	0,0	0,0	2,77	srednja	2
Č4734 30CrMoV9	0,6	0,28	0,55	2,5	0,0	0,2	0,15	0,0	4,28	srednja	2
Č5430 36CrNiMo4	0,36	0,28	0,65	1,05	1,05	0,0	0,0	0,0	3,39	srednja	2
Č4531 36CrAlNi7	0,34	0,28	0,6	1,65	1,0	0,2	0,0	1,0	5,07	visoka	3
Č4739 34CrAlMo6	0,34	0,35	0,65	1,15	0,0	0,2	0,0	1,0	3,69	visoka	3
Č3160 X120Mn12	1,20	0,4	12,5	0,0	0,0	0,0	0,0	0,0	14,1	visoka	3
\bar{x}	0,46	0,33	2,02	1,27	1,03	0,29	0,15	1			2,1
Min	0,26	0,27	0,55	0,7	1	0,2	0,15	1			1
Max	1,2	0,45	12,5	2,5	1,05	0,45	0,15	1			3
σ_x	0,28	0,07	3,71	0,56	0,04	0,14		0			0,77

* Unešene su prosječne vrijednosti kemijskog sastava

Tablica P1.34. Iskustvene ocjene **otpornosti trošenju** alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo) [46]

Oznaka HRN/DIN*	%Cr	%W	%V	%Mo	Iskustvena ocjena
Č1531 C45W	0,0	0,0	0,0	0,0	1
Č1731 C70W2	0,0	0,0	0,0	0,0	2
Č1940 C105W1	0,0	0,0	0,0	0,0	4

Č1941 100W1	0,0	0,0	0,1	0,0	3
Č1946 C110W	0,0	0,0	0,0	0,0	4
Č1943 C125W	0,0	0,0	0,0	0,0	4
Č1948 C135W	0,0	0,0	0,0	0,0	4
Č6842 C100WV4	0,0	1,0	0,2	0,0	4
Č6840 120WV4	0,2	1,0	0,1	0,0	5
Č6441 110WCrV5	0,6	1,5	0,1	0,0	5
Č6850 142WV13	0,5	4,5	0,25	0,0	7
Č4145 100Cr6	1,5	0,0	0,0	0,0	3
C4141 115CrV3	0,7	0,0	0,7	0,0	4
Č4143 140Cr	0,7	0,0	0,0	0,0	5
Č3840 90MnCrV8	0,35	0,0	0,1	0,0	4
Č6440 105WCr6	1,0	1,2	0,0	0,0	4
Č6443 45WCrV7	1,0	2,0	0,2	0,0	3
Č6444 60WCrV7	1,0	2,0	0,2	0,0	4
Č6445 80WCrV8	1,0	2,0	0,3	0,0	5
Č4756 X100CrMoV5 1	5,0	0,0	0,25	1,0	6
Č4150 X210Cr12	12,0	0,0	0,0	0,0	8
Č4650 X210CrW12	0,0	0,7	0,0	0,0	8
Č4750 X165CrMoV12	0,0	0,5	0,1	0,6	8
Č4850 X155CrVMo12 1	12,0	0,0	1,0	0,9	8
Č4172 X20Cr13	13,0	0,0	0,0	0,0	1
Č4175 X42Cr13	13,0	0,0	0,0	0,0	2
- X36CrMo17	0,0	0,0	0,0	0,0	3
Č4770 X45CrMoV15	14,0	0,0	0,0	0,4	3
- X91CrMoV18	0,0	0,0	0,0	0,0	5
Č5742 56NiCrMoV7	1,1	0,0	0,1	0,5	2

Nastavak-Tablica P1.34. Iskustvene ocjene **otpornosti trošenju** alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo) [46]

Oznaka HRN/DIN*	%Cr	%W	%V	%Mo	Iskustvena ocjena
Č5741 55NiCrMoV6	0,7	0,0	0,1	0,3	2
Č7450 X32CrMoV33	3,0	0,0	0,5	3,0	4
Č4751	5,0	0,0	0,4	1,3	3

X38CrMoV51					
Č4753 X40CrMoV51	5,0	0,0	1,0	1,3	3
Č4757 X50CrVMo51	5,0	0,0	1,0	1,5	4
Č6450 X30WCrV41	1,0	4,0	0,2	0,0	4
Č6451 X30WCrV93	5,0	0,0	0,4	1,3	4
Č6880 S18-0-1	4,0	18,0	1,1	0,0	7
Č6980 S18-1-2-5	4,0	18,0	1,5	0,7	7
Č9682 S18-1-2-10	4,0	18,0	1,5	0,7	7
Č6981 S12-1-2-5	4,0	12,5	2,0	1,2	8
Č6881 S12-12-1-4	4,0	12,0	3,7	0,8	8
Č6882 S12-1-2	4,0	12,0	2,5	0,8	7
Č9681 S12-1-4-5	4,0	12,5	2,0	1,2	9
Č9683 S10-4-3-10	4,0	10,0	3,2	3,7	9
Č7680 S6-5-2	4,0	6,5	1,9	5,0	7
Č9780 S6-5-2-5	4,0	6,5	1,9	5,0	7
Č7880 S2-9-1	4,0	1,7	1,2	8,5	7
\bar{x}	3,07	3,09	0,62	0,83	4,92
Min	0	0	0	0	1
Max	14	18	3,7	8,5	9
σ_x	3,83	5,37	0,91	1,65	2,20

* Unešene su prosječne vrijednosti kemijskog sastava

Tablica P1.35. Iskustvene ocjene **otpornosti popuštanju** alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo) [46]

Oznaka HRN/DIN*	%Cr	%W	%V	%Mo	Iskustvena ocjena
Č1531 C45W	0,0	0,0	0,0	0,0	1
Č1731 C70W2	0,0	0,0	0,0	0,0	1

Č1940 C105W1	0,0	0,0	0,0	0,0	1
Č1941 100W1	0,0	0,0	0,1	0,0	1
Č1946 C110W	0,0	0,0	0,0	0,0	1
Č1943 C125W	0,0	0,0	0,0	0,0	1
Č1948 C135W	0,0	0,0	0,0	0,0	1
Č6842 C100WV4	0,0	1,0	0,2	0,0	3
Č6840 120WV4	0,2	1,0	0,1	0,0	2
Č6441 110WCrV5	0,6	1,5	0,1	0,0	3
Č6850 142WV13	0,5	4,5	0,25	0,0	3
Č4145 100Cr6	1,5	0,0	0,0	0,0	2
Č4141 115CrV3	0,7	0,0	0,7	0,0	2
Č4143 140Cr	0,7	0,0	0,0	0,0	2
Č3840 90MnCrV8	0,35	0,0	0,1	0,0	3
Č6440 105WCr6	1,0	1,2	0,0	0,0	3
Č6443 45WCrV7	1,0	2,0	0,2	0,0	5
Č6444 60WCrV7	1,0	2,0	0,2	0,0	5
Č6445 80WCrV8	1,0	2,0	0,3	0,0	5
Č4756 X100CrMoV5 1	5,0	0,0	0,25	1,0	5
Č4150 X210Cr12	12,0	0,0	0,0	0,0	6
Č4650 X210CrW12	0,0	0,7	0,0	0,0	6
Č4750 X165CrMoV12	0,0	0,5	0,1	0,6	6
Č4850 X155CrVMo12 1	12,0	0,0	1,0	0,9	7
Č4172 X20Cr13	13,0	0,0	0,0	0,0	6
Č4175 X42Cr13	13,0	0,0	0,0	0,0	6
- X36CrMo17	0,0	0,0	0,0	0,0	6
Č4770 X45CrMoV15	14,0	0,0	0,0	0,4	6
- X91CrMoV18	0,0	0,0	0,0	0,0	6
Č5742 56NiCrMoV7	1,1	0,0	0,1	0,5	3

Nastavak-Tablica P1.35. Iskustvene ocjene **otpornosti popuštanju** alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo) [46]

Oznaka HRN/DIN*	%Cr	%W	%V	%Mo	Iskustvena ocjena
Č5741 55NiCrMoV6	0,7	0,0	0,1	0,3	3
Č7450 X32CrMoV33	3,0	0,0	0,5	3,0	8

Č4751 X38CrMoV51	5,0	0,0	0,4	1,3	6
Č4753 X40CrMoV51	5,0	0,0	1,0	1,3	6
Č4757 X50CrVMo51	5,0	0,0	1,0	1,5	6
Č6450 X30WCrV41	1,0	4,0	0,2	0,0	7
Č6451 X30WCrV93	5,0	0,0	0,4	1,3	8
Č6880 S18-0-1	4,0	18,0	1,1	0,0	8
Č6980 S18-1-2-5	4,0	18,0	1,5	0,7	8
Č9682 S18-1-2-10	4,0	18,0	1,5	0,7	9
Č6981 S12-1-2-5	4,0	12,5	2,0	1,2	8
Č6881 S12-12-1-4	4,0	12,0	3,7	0,8	8
Č6882 S12-1-2	4,0	12,0	2,5	0,8	8
Č9681 S12-1-4-5	4,0	12,5	2,0	1,2	9
Č9683 S10-4-3-10	4,0	10,0	3,2	3,7	9
Č7680 S6-5-2	4,0	6,5	1,9	5,0	8
Č9780 S6-5-2-5	4,0	6,5	1,9	5,0	8
Č7880 S2-9-1	4,0	1,7	1,2	8,5	8
\bar{x}	3,07	3,09	0,62	0,83	5,06
Min	0	0	0	0	1
Max	14	18	3,7	8,5	9
σ_x	3,83	5,37	0,91	1,65	2,66

* Unešene su prosječne vrijednosti kemijskog sastava

Tablica P1.36. Iskustvene ocjene **žilavosti** alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo) [46]

Oznaka HRN/DIN*	%Cr	%W	%V	%Mo	Iskustvena ocjena
Č1531 C45W	0,0	0,0	0,0	0,0	8
Č1731 C70W2	0,0	0,0	0,0	0,0	7

Č1940 C105W1	0,0	0,0	0,0	0,0	4
Č1941 100W1	0,0	0,0	0,1	0,0	5
Č1946 C110W	0,0	0,0	0,0	0,0	4
Č1943 C125W	0,0	0,0	0,0	0,0	4
Č1948 C135W	0,0	0,0	0,0	0,0	3
Č6842 C100WV4	0,0	1,0	0,2	0,0	3
Č6840 120WV4	0,2	1,0	0,1	0,0	3
Č6441 110WCrV5	0,6	1,5	0,1	0,0	3
Č6850 142WV13	0,5	4,5	0,25	0,0	2
Č4145 100Cr6	1,5	0,0	0,0	0,0	4
Č4141 115CrV3	0,7	0,0	0,7	0,0	4
Č4143 140Cr	0,7	0,0	0,0	0,0	4
Č3840 90MnCrV8	0,35	0,0	0,1	0,0	3
Č6440 105WCr6	1,0	1,2	0,0	0,0	3
Č6443 45WCrV7	1,0	2,0	0,2	0,0	5
Č6444 60WCrV7	1,0	2,0	0,2	0,0	4
Č6445 80WCrV8	1,0	2,0	0,3	0,0	3
Č4756 X100CrMoV5 1	5,0	0,0	0,25	1,0	4
Č4150 X210Cr12	12,0	0,0	0,0	0,0	1
Č4650 X210CrW12	0,0	0,7	0,0	0,0	1
Č4750 X165CrMoV12	0,0	0,5	0,1	0,6	2
Č4850 X155CrVMo12 1	12,0	0,0	1,0	0,9	2
Č4172 X20Cr13	13,0	0,0	0,0	0,0	8
Č4175 X42Cr13	13,0	0,0	0,0	0,0	6
- X36CrMo17	0,0	0,0	0,0	0,0	6
Č4770 X45CrMoV15	14,0	0,0	0,0	0,4	6
- X91CrMoV18	0,0	0,0	0,0	0,0	4
Č5742 56NiCrMoV7	1,1	0,0	0,1	0,5	7

Nastavak-Tablica P1.36. Iskustvene ocjene žilavosti alatnih čelika s obzirom na utjecaj karbidotvoraca (Cr,W,V,Mo) [46]

Oznaka HRN/DIN*	%Cr	%W	%V	%Mo	Iskustvena ocjena
Č5741 55NiCrMoV6	0,7	0,0	0,1	0,3	7
Č7450	3,0	0,0	0,5	3,0	4

X32CrMoV33					
Č4751 X38CrMoV51	5,0	0,0	0,4	1,3	9
Č4753 X40CrMoV51	5,0	0,0	1,0	1,3	9
Č4757 X50CrVMo51	5,0	0,0	1,0	1,5	8
Č6450 X30WCrV41	1,0	4,0	0,2	0,0	7
Č6451 X30WCrV93	5,0	0,0	0,4	1,3	4
Č6880 S18-0-1	4,0	18,0	1,1	0,0	3
Č6980 S18-1-2-5	4,0	18,0	1,5	0,7	2
Č9682 S18-1-2-10	4,0	18,0	1,5	0,7	1
Č6981 S12-1-2-5	4,0	12,5	2,0	1,2	2
Č6881 S12-12-1-4	4,0	12,0	3,7	0,8	1
Č6882 S12-1-2	4,0	12,0	2,5	0,8	2
Č9681 S12-1-4-5	4,0	12,5	2,0	1,2	1
Č9683 S10-4-3-10	4,0	10,0	3,2	3,7	1
Č7680 S6-5-2	4,0	6,5	1,9	5,0	3
Č9780 S6-5-2-5	4,0	6,5	1,9	5,0	2
Č7880 S2-9-1	4,0	1,7	1,2	8,5	3
\bar{X}	3,07	3,08	0,62	0,83	4
Min	0	0	0	0	1
Max	14	18	3,7	8,5	9
σ_x	3,83	5,37	0,91	1,65	2,26

* Unešene su prosječne vrijednosti kemijskog sastava

Tablica P1.37. Tvrdća nelegiranih alatnih čelika za hladni rad (Č 1941, Č 1840, Č 1940, Č 1943, Č 1948) u zavisnosti od kemijskog sastava i parametra popuštanja P [45]

%C	%Si	%Mn	%V	P	HRC
Č1941					
1,00	0,30	0,30	0,10	6000	67,8
1,00	0,30	0,30	0,10	7000	67,8
1,00	0,30	0,30	0,10	8000	67,0

1,00	0,30	0,30	0,10	9000	65,5	
1,00	0,30	0,30	0,10	10000	63,0	
1,00	0,30	0,30	0,10	11000	59,0	
1,00	0,30	0,30	0,10	12000	54,0	
1,00	0,30	0,30	0,10	13000	50,0	
1,00	0,30	0,30	0,10	14000	47,0	
Č 1840						
0,80	0,25	0,25	0,00	6000	67,7	
0,80	0,25	0,25	0,00	7000	67,7	
0,80	0,25	0,25	0,00	8000	67,0	
0,80	0,25	0,25	0,00	9000	65,1	
0,80	0,25	0,25	0,00	10000	62,0	
0,80	0,25	0,25	0,00	11000	58,0	
0,80	0,25	0,25	0,00	12000	52,2	
0,80	0,25	0,25	0,00	13000	48,0	
0,80	0,25	0,25	0,00	14000	43,5	
Č 1940						
1,00	0,25	0,25	0,00	600	67,8	
1,00	0,25	0,25	0,00	7000	67,8	
1,00	0,25	0,25	0,00	8000	67,0	
1,00	0,25	0,25	0,00	9000	65,7	
1,00	0,25	0,25	0,00	10000	63,0	
1,00	0,25	0,25	0,00	11000	58,7	
1,00	0,25	0,25	0,00	12000	54,0	
1,00	0,25	0,25	0,00	13000	50,0	
1,00	0,25	0,25	0,00	14000	46,3	
Č 1943						
1,20	0,30	0,30	0,00	600	68,2	
1,20	0,30	0,30	0,00	7000	68,0	
1,20	0,30	0,30	0,00	8000	67,8	
1,20	0,30	0,30	0,00	9000	66,5	
1,20	0,30	0,30	0,00	10000	64,0	
1,20	0,30	0,30	0,00	11000	60,0	
1,20	0,30	0,30	0,00	12000	55,0	
1,20	0,30	0,30	0,00	13000	50,0	
1,20	0,30	0,30	0,00	14000	47,2	
Č 1948						
1,30	0,35	0,35	0,00	600	69,0	
1,30	0,35	0,35	0,00	7000	68,9	
1,30	0,35	0,35	0,00	8000	68,0	
1,30	0,35	0,35	0,00	9000	67,0	
1,30	0,35	0,35	0,00	10000	64,9	
1,30	0,35	0,35	0,00	11000	61,5	
1,30	0,35	0,35	0,00	12000	56,0	
1,30	0,35	0,35	0,00	13000	51,8	
1,30	0,35	0,35	0,00	14000	48,8	
\bar{x}	1,06	0,29	0,29	0,02	9640	60,3
Min	0,8	0,25	0,25	0	600	43,5
Max	1,3	0,35	0,35	0,1	14000	69
σ_x	0,18	0,04	0,04	0,04	3408,71	7,94

Tablica P1.38. Tvrdća niskolegiranih alatnih čelika za hladni rad (Č 4141, Č 4143, Č 4145, Č 6840, Č 6441, Č 6850, Č 3840, Č 6440, Č 6443, Č 6444) u zavisnosti od kemijskog sastava i parametra popuštanja P [45]

%C	%Si	%Mn	%Cr	%W	%Mo	%V	P	HRC
Č 4141								
1,15	0,25	0,30	0,70	0,00	0,00	0,10	6000	64,7
1,15	0,25	0,30	0,70	0,00	0,00	0,10	7000	64,3
1,15	0,25	0,30	0,70	0,00	0,00	0,10	8000	64,0
1,15	0,25	0,30	0,70	0,00	0,00	0,10	9000	63,5
1,15	0,25	0,30	0,70	0,00	0,00	0,10	10000	62,2
1,15	0,25	0,30	0,70	0,00	0,00	0,10	11000	60,1
1,15	0,25	0,30	0,70	0,00	0,00	0,10	12000	57,8
1,15	0,25	0,30	0,70	0,00	0,00	0,10	13000	55,1
1,15	0,25	0,30	0,70	0,00	0,00	0,10	14000	52,0
1,15	0,25	0,30	0,70	0,00	0,00	0,10	15000	49,0
Č 4143								
1,40	0,25	0,30	0,70	0,00	0,00	0,00	6000	67,0
1,40	0,25	0,30	0,70	0,00	0,00	0,00	7000	66,5
1,40	0,25	0,30	0,70	0,00	0,00	0,00	8000	65,8
1,40	0,25	0,30	0,70	0,00	0,00	0,00	9000	64,5
1,40	0,25	0,30	0,70	0,00	0,00	0,00	10000	62,5
1,40	0,25	0,30	0,70	0,00	0,00	0,00	11000	60,0
1,40	0,25	0,30	0,70	0,00	0,00	0,00	12000	57,0
1,40	0,25	0,30	0,70	0,00	0,00	0,00	13000	53,1
1,40	0,25	0,30	0,70	0,00	0,00	0,00	14000	49,1
1,40	0,25	0,30	0,70	0,00	0,00	0,00	15000	45,0
Č 4145								
1,00	0,25	0,35	1,50	0,00	0,00	0,00	6000	65,2
1,00	0,25	0,35	1,50	0,00	0,00	0,00	7000	65,0
1,00	0,25	0,35	1,50	0,00	0,00	0,00	8000	64,1
1,00	0,25	0,35	1,50	0,00	0,00	0,00	9000	62,0
1,00	0,25	0,35	1,50	0,00	0,00	0,00	10000	59,8
1,00	0,25	0,35	1,50	0,00	0,00	0,00	11000	58,5
1,00	0,25	0,35	1,50	0,00	0,00	0,00	12000	57,2
1,00	0,25	0,35	1,50	0,00	0,00	0,00	13000	55,0
1,00	0,25	0,35	1,50	0,00	0,00	0,00	14000	51,8
1,00	0,25	0,35	1,50	0,00	0,00	0,00	15000	47,5
1,00	0,25	0,35	1,50	0,00	0,00	0,00	16000	42,8
1,00	0,25	0,35	1,50	0,00	0,00	0,00	17000	37,8
1,00	0,25	0,35	1,50	0,00	0,00	0,00	18000	32,2
Č 6840								
1,20	0,20	0,30	0,20	1,00	0,00	0,10	6000	67,5
1,20	0,20	0,30	0,20	1,00	0,00	0,10	7000	67,2
1,20	0,20	0,30	0,20	1,00	0,00	0,10	8000	66,8
1,20	0,20	0,30	0,20	1,00	0,00	0,10	9000	65,8
1,20	0,20	0,30	0,20	1,00	0,00	0,10	10000	64,0
1,20	0,20	0,30	0,20	1,00	0,00	0,10	11000	61,0
1,20	0,20	0,30	0,20	1,00	0,00	0,10	12000	58,0
1,20	0,20	0,30	0,20	1,00	0,00	0,10	13000	55,0
1,20	0,20	0,30	0,20	1,00	0,00	0,10	14000	52,5
1,20	0,20	0,30	0,20	1,00	0,00	0,10	15000	50,4
Č 6441								
1,10	0,25	0,25	0,60	1,50	0,00	0,10	6000	68,0
1,10	0,25	0,25	0,60	1,50	0,00	0,10	7000	67,8
1,10	0,25	0,25	0,60	1,50	0,00	0,10	8000	67,0
1,10	0,25	0,25	0,60	1,50	0,00	0,10	9000	65,2
1,10	0,25	0,25	0,60	1,50	0,00	0,10	10000	63,0
1,10	0,25	0,25	0,60	1,50	0,00	0,10	11000	60,8
1,10	0,25	0,25	0,60	1,50	0,00	0,10	12000	58,5
1,10	0,25	0,25	0,60	1,50	0,00	0,10	13000	56,2
1,10	0,25	0,25	0,60	1,50	0,00	0,10	14000	54,0
1,10	0,25	0,25	0,60	1,50	0,00	0,10	15000	52,0
Č 6850								
1,40	0,20	0,30	0,50	4,50	0,00	0,25	6000	66,2
1,40	0,20	0,30	0,50	4,50	0,00	0,25	7000	66,0
1,40	0,20	0,30	0,50	4,50	0,00	0,25	8000	65,5
1,40	0,20	0,30	0,50	4,50	0,00	0,25	9000	64,5
1,40	0,20	0,30	0,50	4,50	0,00	0,25	10000	63,0
1,40	0,20	0,30	0,50	4,50	0,00	0,25	11000	60,8
Č 3840								
0,90	0,25	2,00	0,35	0,00	0,00	0,10	6000	65,0
0,90	0,25	2,00	0,35	0,00	0,00	0,10	7000	65,1
0,90	0,25	2,00	0,35	0,00	0,00	0,10	8000	64,0
0,90	0,25	2,00	0,35	0,00	0,00	0,10	9000	62,0

0,90	0,25	2,00	0,35	0,00	0,00	0,10	10000	60,0
0,90	0,25	2,00	0,35	0,00	0,00	0,10	11000	58,8
0,90	0,25	2,00	0,35	0,00	0,00	0,10	12000	57,0
0,90	0,25	2,00	0,35	0,00	0,00	0,10	13000	55,0
0,90	0,25	2,00	0,35	0,00	0,00	0,10	14000	53,0
0,90	0,25	2,00	0,35	0,00	0,00	0,10	15000	49,3
0,90	0,25	2,00	0,35	0,00	0,00	0,10	16000	45,2
0,90	0,25	2,00	0,35	0,00	0,00	0,10	17000	41,0
0,90	0,25	2,00	0,35	0,00	0,00	0,10	18000	32,0
Č 6440								
1,05	0,25	1,00	1,00	1,20	0,00	0,00	6000	66,0
1,05	0,25	1,00	1,00	1,20	0,00	0,00	7000	65,8
1,05	0,25	1,00	1,00	1,20	0,00	0,00	8000	65,0
1,05	0,25	1,00	1,00	1,20	0,00	0,00	9000	64,1
1,05	0,25	1,00	1,00	1,20	0,00	0,00	10000	62,8
1,05	0,25	1,00	1,00	1,20	0,00	0,00	11000	61,0
1,05	0,25	1,00	1,00	1,20	0,00	0,00	12000	59,2
1,05	0,25	1,00	1,00	1,20	0,00	0,00	13000	57,0
1,05	0,25	1,00	1,00	1,20	0,00	0,00	14000	55,0
1,05	0,25	1,00	1,00	1,20	0,00	0,00	15000	52,2
1,05	0,25	1,00	1,00	1,20	0,00	0,00	16000	49,5
1,05	0,25	1,00	1,00	1,20	0,00	0,00	17000	46,0
1,05	0,25	1,00	1,00	1,20	0,00	0,00	18000	42,0
1,05	0,25	1,00	1,00	1,20	0,00	0,00	19000	36,5
Č 6443								
0,45	1,00	0,30	1,00	2,00	0,00	0,20	6000	64,5
0,45	1,00	0,30	1,00	2,00	0,00	0,20	7000	64,0
0,45	1,00	0,30	1,00	2,00	0,00	0,20	8000	64,0
0,45	1,00	0,30	1,00	2,00	0,00	0,20	9000	64,0
0,45	1,00	0,30	1,00	2,00	0,00	0,20	10000	63,0
0,45	1,00	0,30	1,00	2,00	0,00	0,20	11000	61,5
0,45	1,00	0,30	1,00	2,00	0,00	0,20	12000	59,2
0,45	1,00	0,30	1,00	2,00	0,00	0,20	13000	57,2
0,45	1,00	0,30	1,00	2,00	0,00	0,20	14000	55,0
0,45	1,00	0,30	1,00	2,00	0,00	0,20	15000	53,0
0,45	1,00	0,30	1,00	2,00	0,00	0,20	16000	51,5
0,45	1,00	0,30	1,00	2,00	0,00	0,20	17000	50,2
0,45	1,00	0,30	1,00	2,00	0,00	0,20	18000	49,0
0,45	1,00	0,30	1,00	2,00	0,00	0,20	19000	43,0
Č 6444								
0,60	0,60	0,30	1,00	2,00	0,00	0,20	6000	62,2
0,60	0,60	0,30	1,00	2,00	0,00	0,20	7000	62,1
0,60	0,60	0,30	1,00	2,00	0,00	0,20	8000	61,8
0,60	0,60	0,30	1,00	2,00	0,00	0,20	9000	60,9
0,60	0,60	0,30	1,00	2,00	0,00	0,20	10000	59,8
0,60	0,60	0,30	1,00	2,00	0,00	0,20	11000	58,8
0,60	0,60	0,30	1,00	2,00	0,00	0,20	12000	57,0
0,60	0,60	0,30	1,00	2,00	0,00	0,20	13000	55,0
0,60	0,60	0,30	1,00	2,00	0,00	0,20	14000	53,1
0,60	0,60	0,30	1,00	2,00	0,00	0,20	15000	51,1
0,60	0,60	0,30	1,00	2,00	0,00	0,20	16000	49,5
0,60	0,60	0,30	1,00	2,00	0,00	0,20	17000	48,1
0,60	0,60	0,30	1,00	2,00	0,00	0,20	18000	45,1
0,60	0,60	0,30	1,00	2,00	0,00	0,20	19000	38,0
\bar{x}	0,97	0,38	0,58	0,80	1,09	0	11473,7	57,37
Min	0,45	0,2	0,25	0,2	0	0	6000	32
Max	1,4	1	2	1,5	4,5	0	19000	68
σ_x	0,29	0,26	0,56	0,37	1,15	0	3687,4	8,25

Tablica P1.39. Tvrdoća visokolegiranih alatnih čelika za hladni rad (Č 4150, Č 4650, Č 4750, Č 4850, Č 4172, Č 4770) u zavisnosti od kemijskog sastava i parametra popuštanja P [45]

%C	%Si	%Mn	%Cr	%W	%Mo	%V	P	HRC
Č 4150								
2,10	0,30	0,30	12,0	0,00	0,00	0,00	6000	65,0
2,10	0,30	0,30	12,0	0,00	0,00	0,00	7000	64,9
2,10	0,30	0,30	12,0	0,00	0,00	0,00	8000	64,0
2,10	0,30	0,30	12,0	0,00	0,00	0,00	9000	62,5
2,10	0,30	0,30	12,0	0,00	0,00	0,00	10000	61,0
2,10	0,30	0,30	12,0	0,00	0,00	0,00	11000	59,5
2,10	0,30	0,30	12,0	0,00	0,00	0,00	12000	59,0
2,10	0,30	0,30	12,0	0,00	0,00	0,00	13000	58,5
2,10	0,30	0,30	12,0	0,00	0,00	0,00	14000	57,5
2,10	0,30	0,30	12,0	0,00	0,00	0,00	15000	55,0
2,10	0,30	0,30	12,0	0,00	0,00	0,00	16000	50,5
2,10	0,30	0,30	12,0	0,00	0,00	0,00	17000	42,5
2,10	0,30	0,30	12,0	0,00	0,00	0,00	18000	37,5
2,10	0,30	0,30	12,0	0,00	0,00	0,00	19000	34,5
Č 4650								
2,10	0,30	0,30	12,0	0,70	0,00	0,00	6000	66,0
2,10	0,30	0,30	12,0	0,70	0,00	0,00	7000	65,8
2,10	0,30	0,30	12,0	0,70	0,00	0,00	8000	64,9
2,10	0,30	0,30	12,0	0,70	0,00	0,00	9000	63,3
2,10	0,30	0,30	12,0	0,70	0,00	0,00	10000	61,5
2,10	0,30	0,30	12,0	0,70	0,00	0,00	11000	60,1
2,10	0,30	0,30	12,0	0,70	0,00	0,00	12000	59,0
2,10	0,30	0,30	12,0	0,70	0,00	0,00	13000	58,8
2,10	0,30	0,30	12,0	0,70	0,00	0,00	14000	58,2
2,10	0,30	0,30	12,0	0,70	0,00	0,00	15000	58,0
2,10	0,30	0,30	12,0	0,70	0,00	0,00	16000	56,0
2,10	0,30	0,30	12,0	0,70	0,00	0,00	17000	46,0
2,10	0,30	0,30	12,0	0,70	0,00	0,00	18000	39,0
2,10	0,30	0,30	12,0	0,70	0,00	0,00	19000	35,0
Č 4750								
1,65	0,30	0,30	12,0	0,50	0,60	0,10	6000	64,1
1,65	0,30	0,30	12,0	0,50	0,60	0,10	7000	63,9
1,65	0,30	0,30	12,0	0,50	0,60	0,10	8000	62,9
1,65	0,30	0,30	12,0	0,50	0,60	0,10	9000	61,2
1,65	0,30	0,30	12,0	0,50	0,60	0,10	10000	59,4
1,65	0,30	0,30	12,0	0,50	0,60	0,10	11000	58,6
1,65	0,30	0,30	12,0	0,50	0,60	0,10	12000	57,5
1,65	0,30	0,30	12,0	0,50	0,60	0,10	13000	57,0
1,65	0,30	0,30	12,0	0,50	0,60	0,10	14000	57,5
1,65	0,30	0,30	12,0	0,50	0,60	0,10	15000	58,0
1,65	0,30	0,30	12,0	0,50	0,60	0,10	16000	56,5
1,65	0,30	0,30	12,0	0,50	0,60	0,10	17000	50,2
1,65	0,30	0,30	12,0	0,50	0,60	0,10	18000	40,5
1,65	0,30	0,30	12,0	0,50	0,60	0,10	19000	36,5
Č 4850								
1,55	0,30	0,30	12,0	0,00	0,90	1,00	6000	63,5
1,55	0,30	0,30	12,0	0,00	0,90	1,00	7000	64,0
1,55	0,30	0,30	12,0	0,00	0,90	1,00	8000	63,9
1,55	0,30	0,30	12,0	0,00	0,90	1,00	9000	62,7
1,55	0,30	0,30	12,0	0,00	0,90	1,00	10000	60,7
1,55	0,30	0,30	12,0	0,00	0,90	1,00	11000	59,1
1,55	0,30	0,30	12,0	0,00	0,90	1,00	12000	58,5
1,55	0,30	0,30	12,0	0,00	0,90	1,00	13000	58,1
1,55	0,30	0,30	12,0	0,00	0,90	1,00	14000	58,2
1,55	0,30	0,30	12,0	0,00	0,90	1,00	15000	59,0
1,55	0,30	0,30	12,0	0,00	0,90	1,00	16000	59,0
1,55	0,30	0,30	12,0	0,00	0,90	1,00	17000	50,1
1,55	0,30	0,30	12,0	0,00	0,90	1,00	18000	44,0
1,55	0,30	0,30	12,0	0,00	0,90	1,00	19000	38,0
Č 4172								
0,20	1,00	1,00	13,0	0,00	0,00	0,00	6000	53,7
0,20	1,00	1,00	13,0	0,00	0,00	0,00	7000	53,8
0,20	1,00	1,00	13,0	0,00	0,00	0,00	8000	53,0
0,20	1,00	1,00	13,0	0,00	0,00	0,00	9000	51,0
0,20	1,00	1,00	13,0	0,00	0,00	0,00	10000	49,0
0,20	1,00	1,00	13,0	0,00	0,00	0,00	11000	46,9
0,20	1,00	1,00	13,0	0,00	0,00	0,00	12000	45,8
0,20	1,00	1,00	13,0	0,00	0,00	0,00	13000	46,7
0,20	1,00	1,00	13,0	0,00	0,00	0,00	14000	48,0
0,20	1,00	1,00	13,0	0,00	0,00	0,00	15000	49,5

0,20	1,00	1,00	13,0	0,00	0,00	0,00	16000	47,0	
0,20	1,00	1,00	13,0	0,00	0,00	0,00	17000	36,5	
Č 4770									
0,50	0,50	1,00	14,0	0,00	0,40	0,00	6000	60,0	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	7000	59,5	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	8000	58,8	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	9000	58,0	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	10000	56,9	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	11000	55,9	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	12000	55,2	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	13000	55,7	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	14000	56,0	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	15000	55,5	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	16000	50,5	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	17000	38,6	
0,50	0,50	1,00	14,0	0,00	0,40	0,00	18000	32,8	
\bar{X}	1,39	0,436	0,52	12,47	0,21	0,32	0,19	12271,6	54,6
Min	0,2	0,3	0,3	12	0	0	0	6000	32,8
Max	2,1	1	1	14	0,7	0,9	1	19000	66
σ_x	0,73	0,25	0,33	0,76	0,29	0,35	0,37	3946,6	8,61

Tablica P1.40. Tvrdća alatnih čelika za topli rad (Č 5741, Č 5742, Č 4751, Č 4753, Č 6450, Č 6451) u zavisnosti od kemijskog sastava i parametra popuštanja P [45]

%C	%Si	%Mn	%Cr	%Ni	%Mo	%W	%V	%Co	P	HRC
Č 5741										
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	6000	59,2
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	7000	59,0
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	8000	58,2
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	9000	57,0
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	10000	55,5
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	11000	53,8
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	12000	51,8
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	13000	49,5
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	14000	47,2
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	15000	45,3
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	16000	43,0
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	17000	40,0
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	18000	35,2
0,55	0,25	0,60	0,70	1,70	0,30	0,00	0,10	0,00	19000	29,5
Č 5742										
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	6000	60,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	7000	59,8
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	8000	58,8
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	9000	57,8
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	10000	56,3
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	11000	55,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	12000	53,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	13000	51,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	14000	48,8
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	15000	46,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	16000	43,6
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	17000	41,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	18000	38,5
Č 4751										
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	6000	55,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	7000	55,2
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	8000	55,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	9000	54,2
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	10000	53,8
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	11000	53,2
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	12000	53,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	13000	53,6
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	14000	54,2
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	15000	54,4
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	16000	53,8
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	17000	50,2
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	18000	42,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	19000	31,0
Č 4753										
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	6000	55,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	7000	54,8
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	8000	54,2
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	9000	53,8
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	10000	53,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	11000	52,8
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	12000	53,5
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	13000	54,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	14000	55,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	15000	56,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	16000	56,2
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	17000	55,8
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	18000	50,5
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	19000	42,2
Č 6450										
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	6000	51,5
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	7000	51,7
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	8000	51,5
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	9000	51,2
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	10000	51,0
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	11000	50,2
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	12000	50,0
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	13000	49,0
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	14000	48,4
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	15000	48,6
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	16000	48,2

0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	17000	47,2	
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	18000	43,8	
0,30	1,00	0,00	1,00	0,00	0,0	4,00	0,20	0,00	19000	37,0	
Č 6451											
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	6000	45,5	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	7000	45,8	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	8000	46,0	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	9000	46,0	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	10000	46,0	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	11000	46,0	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	12000	45,9	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	13000	45,8	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	14000	45,7	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	15000	46,0	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	16000	47,0	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	17000	49,8	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	18000	50,0	
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	19000	41,0	
\bar{X}	0,42	0,51	0,21	2,55	0,55	0,60	2,19	0,37	0	12421,7	49,94
Min	0,3	0	0	0,7	0	0	0	0,1	0	6000	29,5
Max	0,55	1	0,7	5	1,7	1,5	9	1	0	19000	60
σ_x	0,10	0,50	0,31	1,86	0,80	0,60	3,42	0,31	0	4015,6	6,31

Tablica P1.41. Tvrdoća brzoreznih čelika (Č 6880, Č 6880, Č 9682, Č 6981, Č 6881, Č 6882, Č 9681, Č 9683, Č 7680, Č 9780, Č 7880) u zavisnosti od kemijskog sastava i parametra popuštanja P [45]

%C	%Cr	%W	%Mo	%V	%Co	P	HRC
Č 6880							
0,75	4,00	18,0	0,00	1,10	0,00	6000	66,0
0,75	4,00	18,0	0,00	1,10	0,00	7000	66,0
0,75	4,00	18,0	0,00	1,10	0,00	8000	65,5
0,75	4,00	18,0	0,00	1,10	0,00	9000	64,8
0,75	4,00	18,0	0,00	1,10	0,00	10000	63,5
0,75	4,00	18,0	0,00	1,10	0,00	11000	62,2
0,75	4,00	18,0	0,00	1,10	0,00	12000	61,2
0,75	4,00	18,0	0,00	1,10	0,00	13000	60,9
0,75	4,00	18,0	0,00	1,10	0,00	14000	61,5
0,75	4,00	18,0	0,00	1,10	0,00	15000	62,5
0,75	4,00	18,0	0,00	1,10	0,00	16000	64,5
0,75	4,00	18,0	0,00	1,10	0,00	17000	64,4
0,75	4,00	18,0	0,00	1,10	0,00	18000	61,5
0,75	4,00	18,0	0,00	1,10	0,00	19000	56,0
Č 6980							
0,80	4,00	18,0	0,70	1,50	5,00	6000	66,0
0,80	4,00	18,0	0,70	1,50	5,00	7000	65,8
0,80	4,00	18,0	0,70	1,50	5,00	8000	65,5
0,80	4,00	18,0	0,70	1,50	5,00	9000	64,8
0,80	4,00	18,0	0,70	1,50	5,00	10000	64,0
0,80	4,00	18,0	0,70	1,50	5,00	11000	63,0
0,80	4,00	18,0	0,70	1,50	5,00	12000	62,2
0,80	4,00	18,0	0,70	1,50	5,00	13000	62,3
0,80	4,00	18,0	0,70	1,50	5,00	14000	63,4
0,80	4,00	18,0	0,70	1,50	5,00	15000	65,0
0,80	4,00	18,0	0,70	1,50	5,00	16000	66,2
0,80	4,00	18,0	0,70	1,50	5,00	17000	66,2
0,80	4,00	18,0	0,70	1,50	5,00	18000	64,8
0,80	4,00	18,0	0,70	1,50	5,00	19000	58,0
Č 9682							
0,76	4,00	18,0	0,70	1,50	9,50	6000	64,8
0,76	4,00	18,0	0,70	1,50	9,50	7000	64,8
0,76	4,00	18,0	0,70	1,50	9,50	8000	64,7
0,76	4,00	18,0	0,70	1,50	9,50	9000	64,3
0,76	4,00	18,0	0,70	1,50	9,50	10000	63,8
0,76	4,00	18,0	0,70	1,50	9,50	11000	63,0
0,76	4,00	18,0	0,70	1,50	9,50	12000	63,0
0,76	4,00	18,0	0,70	1,50	9,50	13000	63,2
0,76	4,00	18,0	0,70	1,50	9,50	14000	63,7
0,76	4,00	18,0	0,70	1,50	9,50	15000	64,8
0,76	4,00	18,0	0,70	1,50	9,50	16000	66,0
0,76	4,00	18,0	0,70	1,50	9,50	17000	66,8
0,76	4,00	18,0	0,70	1,50	9,50	18000	65,5
0,76	4,00	18,0	0,70	1,50	9,50	19000	60,5
Č 6981							
0,80	4,00	12,5	1,20	2,00	5,00	6000	66,2
0,80	4,00	12,5	1,20	2,00	5,00	7000	66,3
0,80	4,00	12,5	1,20	2,00	5,00	8000	66,0
0,80	4,00	12,5	1,20	2,00	5,00	9000	65,1
0,80	4,00	12,5	1,20	2,00	5,00	10000	63,5
0,80	4,00	12,5	1,20	2,00	5,00	11000	61,8
0,80	4,00	12,5	1,20	2,00	5,00	12000	61,7
0,80	4,00	12,5	1,20	2,00	5,00	13000	62,1
0,80	4,00	12,5	1,20	2,00	5,00	14000	63,0
0,80	4,00	12,5	1,20	2,00	5,00	15000	64,5
0,80	4,00	12,5	1,20	2,00	5,00	16000	66,0
0,80	4,00	12,5	1,20	2,00	5,00	17000	65,8
0,80	4,00	12,5	1,20	2,00	5,00	18000	63,5
0,80	4,00	12,5	1,20	2,00	5,00	19000	57,2
Č 6881							
1,25	4,00	12,0	0,80	3,70	0,00	6000	66,5
1,25	4,00	12,0	0,80	3,70	0,00	7000	66,2
1,25	4,00	12,0	0,80	3,70	0,00	8000	65,7
1,25	4,00	12,0	0,80	3,70	0,00	9000	65,9
1,25	4,00	12,0	0,80	3,70	0,00	10000	63,8
1,25	4,00	12,0	0,80	3,70	0,00	11000	62,7
1,25	4,00	12,0	0,80	3,70	0,00	12000	62,2
1,25	4,00	12,0	0,80	3,70	0,00	13000	62,3
1,25	4,00	12,0	0,80	3,70	0,00	14000	63,0

1,25	4,00	12,0	0,80	3,70	0,00	15000	64,2
1,25	4,00	12,0	0,80	3,70	0,00	16000	66,0
1,25	4,00	12,0	0,80	3,70	0,00	17000	66,2
1,25	4,00	12,0	0,80	3,70	0,00	18000	64,0
Č 6882							
0,88	4,00	12,0	0,80	2,50	0,00	6000	65,6
0,88	4,00	12,0	0,80	2,50	0,00	7000	65,2
0,88	4,00	12,0	0,80	2,50	0,00	8000	64,8
0,88	4,00	12,0	0,80	2,50	0,00	9000	64,0
0,88	4,00	12,0	0,80	2,50	0,00	10000	63,2
0,88	4,00	12,0	0,80	2,50	0,00	11000	62,5
0,88	4,00	12,0	0,80	2,50	0,00	12000	61,9
0,88	4,00	12,0	0,80	2,50	0,00	13000	62,0
0,88	4,00	12,0	0,80	2,50	0,00	14000	62,8
0,88	4,00	12,0	0,80	2,50	0,00	15000	64,1
0,88	4,00	12,0	0,80	2,50	0,00	16000	65,6
0,88	4,00	12,0	0,80	2,50	0,00	17000	65,9
0,88	4,00	12,0	0,80	2,50	0,00	18000	63,0
0,88	4,00	12,0	0,80	2,50	0,00	19000	57,0
Č 9681							
1,35	4,00	12,0	0,90	3,70	5,00	6000	65,5
1,35	4,00	12,0	0,90	3,70	5,00	7000	65,3
1,35	4,00	12,0	0,90	3,70	5,00	8000	65,2
1,35	4,00	12,0	0,90	3,70	5,00	9000	64,8
1,35	4,00	12,0	0,90	3,70	5,00	10000	64,2
1,35	4,00	12,0	0,90	3,70	5,00	11000	63,2
1,35	4,00	12,0	0,90	3,70	5,00	12000	62,5
1,35	4,00	12,0	0,90	3,70	5,00	13000	62,7
1,35	4,00	12,0	0,90	3,70	5,00	14000	63,2
1,35	4,00	12,0	0,90	3,70	5,00	15000	64,7
1,35	4,00	12,0	0,90	3,70	5,00	16000	66,5
1,35	4,00	12,0	0,90	3,70	5,00	17000	66,8
1,35	4,00	12,0	0,90	3,70	5,00	18000	65,2
Č 9683							
1,25	4,00	10,0	3,70	3,20	10,5	6000	66,0
1,25	4,00	10,0	3,70	3,20	10,5	7000	66,2
1,25	4,00	10,0	3,70	3,20	10,5	8000	66,0
1,25	4,00	10,0	3,70	3,20	10,5	9000	65,8
1,25	4,00	10,0	3,70	3,20	10,5	10000	65,1
1,25	4,00	10,0	3,70	3,20	10,5	11000	64,8
1,25	4,00	10,0	3,70	3,20	10,5	12000	64,7
1,25	4,00	10,0	3,70	3,20	10,5	13000	65,0
1,25	4,00	10,0	3,70	3,20	10,5	14000	65,7
1,25	4,00	10,0	3,70	3,20	10,5	15000	67,0
1,25	4,00	10,0	3,70	3,20	10,5	16000	68,2
1,25	4,00	10,0	3,70	3,20	10,5	17000	67,5
1,25	4,00	10,0	3,70	3,20	10,5	18000	63,5
1,25	4,00	10,0	3,70	3,20	10,5	19000	57,5
Č 7680							
0,90	4,00	6,50	5,00	1,90	0,00	6000	66,0
0,90	4,00	6,50	5,00	1,90	0,00	7000	65,8
0,90	4,00	6,50	5,00	1,90	0,00	8000	65,2
0,90	4,00	6,50	5,00	1,90	0,00	9000	64,7
0,90	4,00	6,50	5,00	1,90	0,00	10000	63,8
0,90	4,00	6,50	5,00	1,90	0,00	11000	62,9
0,90	4,00	6,50	5,00	1,90	0,00	12000	62,3
0,90	4,00	6,50	5,00	1,90	0,00	13000	62,4
0,90	4,00	6,50	5,00	1,90	0,00	14000	63,1
0,90	4,00	6,50	5,00	1,90	0,00	15000	64,2
0,90	4,00	6,50	5,00	1,90	0,00	16000	65,8
0,90	4,00	6,50	5,00	1,90	0,00	17000	65,2
0,90	4,00	6,50	5,00	1,90	0,00	18000	62,1
0,90	4,00	6,50	5,00	1,90	0,00	19000	54,5
Č 9780							
0,92	4,00	6,50	5,00	1,90	5,00	6000	66,5
0,92	4,00	6,50	5,00	1,90	5,00	7000	66,2
0,92	4,00	6,50	5,00	1,90	5,00	8000	65,6
0,92	4,00	6,50	5,00	1,90	5,00	9000	64,8
0,92	4,00	6,50	5,00	1,90	5,00	10000	63,6
0,92	4,00	6,50	5,00	1,90	5,00	11000	62,8
0,92	4,00	6,50	5,00	1,90	5,00	12000	62,2
0,92	4,00	6,50	5,00	1,90	5,00	13000	62,5
0,92	4,00	6,50	5,00	1,90	5,00	14000	63,1
0,92	4,00	6,50	5,00	1,90	5,00	15000	64,2
0,92	4,00	6,50	5,00	1,90	5,00	16000	65,7
0,92	4,00	6,50	5,00	1,90	5,00	17000	66,2

	0,92	4,00	6,50	5,00	1,90	5,00	18000	62,5
	0,92	4,00	6,50	5,00	1,90	5,00	19000	56,5
	C 7880							
	0,82	4,00	1,70	8,50	1,20	0,00	6000	65,4
	0,82	4,00	1,70	8,50	1,20	0,00	7000	65,2
	0,82	4,00	1,70	8,50	1,20	0,00	8000	64,8
	0,82	4,00	1,70	8,50	1,20	0,00	9000	64,2
	0,82	4,00	1,70	8,50	1,20	0,00	10000	63,5
	0,82	4,00	1,70	8,50	1,20	0,00	11000	62,7
	0,82	4,00	1,70	8,50	1,20	0,00	12000	61,8
	0,82	4,00	1,70	8,50	1,20	0,00	13000	62,0
	0,82	4,00	1,70	8,50	1,20	0,00	14000	62,8
	0,82	4,00	1,70	8,50	1,20	0,00	15000	64,0
	0,82	4,00	1,70	8,50	1,20	0,00	16000	65,2
	0,82	4,00	1,70	8,50	1,20	0,00	17000	66,0
	0,82	4,00	1,70	8,50	1,20	0,00	18000	63,5
\bar{X}	0,95	4	11,62	2,46	2,187	3,68	12370,8	63,97
Min	0,75	4	1,7	0	1,1	0	6000	54,5
Max	1,35	4	18	8,5	3,7	10,5	19000	68,2
σ_x	0,21	0	5,02	2,55	0,90	3,78	3977,63	2,25

Tablica P1.42. Mehanička svojstva R_m , $R_{p0,2}$ i A_5 alatnih čelika za topli rad (Č 9750, Č 5742, Č 4751, Č 4753, Č 7450, Č 6451) u zavisnosti od kemijskog sastava i temperature popuštanja T_P [45]

%C	%Si	%Mn	%Cr	%Ni	%Mo	%W	%V	%Co	T_P °C	R_m N/mm ²	$R_{p0,2}$ N/mm ²	A_5 %
Č 9750												
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	50	1820	1620	7,0
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	100	1800	1550	7,3
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	150	1770	1460	7,5
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	200	1720	1390	8,0
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	250	1690	1310	8,0
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	300	1650	1250	8,0
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	350	1620	1200	8,0
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	400	1580	1160	8,0
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	450	1550	1110	8,0
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	500	1490	1030	8,0
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	550	1300	870	8,5
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	600	800	500	9,5
0,30	0,00	0,00	3,00	0,00	3,00	0,00	0,50	3,00	650	300	200	15,0
Č 5742												
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	250	1430	1210	8,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	300	1400	1190	8,2
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	350	1330	1100	7,9
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	400	1250	990	8,2
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	450	1120	800	10,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	500	950	540	15,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	550	700	360	20,0
0,55	0,25	0,70	1,00	1,70	0,50	0,00	0,10	0,00	600	450	250	29,0
Č 4751												
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	250	1420	1190	8,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	300	1410	1180	9,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	350	1400	1130	9,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	400	1360	1080	9,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	450	1290	990	9,2
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	500	1130	800	9,2
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	550	840	600	9,5
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	600	600	380	10,0
0,40	1,00	0,00	5,00	0,00	1,30	0,00	0,40	0,00	650	400	190	12,0
Č 4753												
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	50	1390	1210	9,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	100	1380	1200	9,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	150	1340	1180	8,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	200	1310	1160	7,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	250	1290	1110	5,5
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	300	1250	1090	5,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	350	1210	1030	6,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	400	1160	980	7,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	450	1090	880	7,5
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	500	900	740	9,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	550	880	580	10,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	600	680	380	12,0
0,40	1,00	0,00	5,00	0,00	1,50	0,00	1,00	0,00	650	350	180	15,0
Č 7450												
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	50	880	660	18
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	100	850	650	17
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	150	810	640	15
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	200	790	640	14
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	250	780	640	13
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	300	750	630	13
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	350	730	590	14
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	400	710	580	15
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	450	680	580	16
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	500	610	540	18
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	550	530	530	20
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	600	430	530	22
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	650	370	360	28
0,32	0,00	0,00	3,0	0,00	3,0	0,00	0,5	0,00	700	300	270	31
Č 6451												
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	250	1500	1380	7,0
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	300	1490	1330	8,0
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	350	1460	1300	8,5
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	400	1400	1230	8,7
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	450	1350	1160	8,5
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	500	1270	1030	8,0
0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	550	1190	900	7,5

	0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	600	990	690	6,0
	0,30	0,00	0,00	2,50	0,00	0,0	9,00	0,40	0,00	650	710	500	2,0
\bar{X}	0,37	0,33	0,08	3,35	0,20	1,78	1,21	0,52	0,63	391,7	1096,7	874,4	11,06
Min	0,3	0	0	1	0	0	0	0,1	0	50	300	180	2
Max	0,55	1	0,7	5	1,7	3	9	1	3	700	1820	1620	31
σ_x	0,80	0,47	0,23	1,31	0,56	1,14	3,09	0,27	1,23	175,5	417,4	370,8	5,64

Tablica P1.43. Rezultati ispitivanja gubitka volumena (GV) po ASTM G65 [46]

Oznaka	C	Si	Mn	Cr	Ni	Mo	W	V	%Le	T _A °C	T _{pop} °C	GV mm ³
6.1.7. 6.1.8. Č 1940 C105W1	1,0	0,2	0,3	0,0	0,0	0,0	0,0	0,0	0,45	788	0	61,05
											149	64,35
											177	66,55
											316	93,20
											371	104,60
440	116,60											
6.1.9. Č 3840 90MnV8	0,9	0,0	2,0	0,3	0,0	0,0	0,0	0,1	2,40	802	0	59,50
											204	70,60
											316	98,55
											371	104,60
											468	118,65
6.1.10. Č 4150 X210Cr12	2,1	0,0	0,0	11,5	0,0	0,0	0,0	0,1	11,60	969	0	24,65
											149	23,95
											204	28,95
											316	30,15
											482	31,70
											552	39,10
											593	48,25
649	64,35											
6.1.11. Č 4753 X40CrMoV 51	0,4	0,0	0,0	5,0	0,0	1,3	0,0	1,0	7,30	1024	0	128,40
											593	127,00
											538	136,05
											627	144,70
											649	186,05
6.1.12. Č 4756 X100CrMo V51	1,0	0,0	0,0	5,0	0,0	0,0	0,0	0,25	5,25	969	0	57,75
											204	61,25
											232	62,25
											552	75,75
											593	83,40
649	107,70											
Č4850	1,6			12,0		0,9		1,0	13,90	1010	0	59,90
Č7680 S 6-5-2	0,9	0,0	0,0	4,0	0,0	5,0	0,0	2,0	11,00	1218	552	23,30
											149	25,80
											521	27,95
											663	41,55
											677	66,70
690	77,75											
6.1.13. - F2	1,3	0,0	0,5	0,3	0,0	0,0	3,75	0,0	4,55	843	0	39,35
											177	36,15
											316	47,25
											371	56,85
											454	57,40
427	57,80											
6.1.14. - A6	0,7	0,5	2,2	1,05	0,30	1,15	0,0	0,0	1,4	843	0	73,80
											177	75,23
											343	106,30
											482	118,10
593	130,75											
6.1.15. - S2	0,5	1,05	0,4	0,0	0,30	0,45	0,0	0,50	1,15	857	0	81,70
											145	81,30
											288	113,75
											427	137,30

PRILOG II

ZNAČAJKE POSTUPAKA MODIFICIRANJA POVRŠINA

1.1 PROKALJENI SLOJEVI [49,51]

1. Zahtjev za primjenom

Od strojnog dijela zahtijeva se visoka otpornost na trošenje i visoka žilavost, a često uz istovremeno opterećenje na savijanje i udarce.

2. Definicija postupka

Prokaljeni slojevi dobivaju se ugrijavanjem cijelog presjeka na temperaturu austenitizacije, držanja na temperaturi austenitizacije, naglog ohlađivanja, te naknadnog niskog popuštanja.

3. Karakteristike i shema postupka

Prokaljeni martenzitni slojevi postižu se konvencionalnim kaljenjem i niskim popuštanjem do temperature 300°C. Strojni dijelovi ugrijavaju se u pećima (ako su malih dimenzija i u solnim kupkama) do temperature austenitizacije, držanja na toj temperaturi i nakon toga gašenja. Pri ugrijavanju i držanju treba spriječiti stvaranje okujine i razugljičenja npr. zaštitnim plinovima, pastama, solnim kupkama itd. Kao sredstvo za gašenje najčešće se koristi voda u cilju postizanja željene dubine prokaljenja. Kod tankih ili dijelova složenih oblika primjenjuje se kaljenje u ulju ili toploj kupki.

4. Zahtjevi uvjetovani konstrukcijom obradka

-treba računati na dodatak za obradu u odnosu na dubinu prokaljenja zbog promjene oblika i dimenzija .

-za ovu vrstu obrade čelik mora imati > 0,3%C.

5. Troškovi

5.1 Cijena postupka

-zavisno od primjene.

5.2 Cijena u odnosu na druge postupke

-prokaljeni slojevi, plameno kaljenje, indukcijsko kaljenje, cementiranje.

5.3 Investicijski troškovi

6. Materijali obradka

6.1 Legure na bazi Fe

-Konstrukcijski čelici:

-Preporuka sastava: 0,3%C

-Grupe: -za poboljšavanje.

-Alatni čelici:

-Zahtjevi na sastav: 0,6-1,4 %Cr; 0,5 %V; 0,7 %Ni,

-Grupe: niskolegirani za hladni rad, nelegirani,
-Preporuka: 145V33; 85Cr6; 90Cr3; 95Cr4; 100Cr6.

6.2 Fe-ljevovi

7. Materijali-Struktura sloja

-martenzit.

8. Poželjna toplinska obradba obradka prije modificiranja

-normalizacija, meko žarenje (kod povišenih sadržaja C).

9. Poželjno stanje površine obradka prije modificiranja

9.1 Hrapavost površine

-nema posebnih zahtjeva.

10. Varijante procesa

10.1 Konvencionalno kaljenje

11. Praktične debljine slojeva

-2 - 10 mm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -visoka,

-promjena oblika: -visoka.

13. Naknadna obrada sloja

13.1 Toplinska

-popuštanje: 100-300 °C.

13.2 Mehanička

-tokarenje, brušenje, poliranje.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

15. Otpornost trošenju sloja

-abrazija, umor površine.

16. Ostala svojstva sloja

16.1 Korozija

-zavisno od nosivog materijala sloja.

16.2 Mehanička: -tvrdoća: 500-700 HV.

17. Primjena slojeva

17.1 Područje primjene

-Alatničarstvo.

17.2 Praktične primjene

-Alati jednostavnije oblika i manjih presjeka: dljetka, čekići, svrdla za drvo, klijesta, ručne škare, sjekire, mesarski noževi, srpovi kose, nareznice, razvrtala, probijači, sjekači, pile za drvo, turpije.

-Alati opterećeni udarno uz istovremeno trošenje: narezna svrdla, glodala, razvrtala, žigovi, rezne ploče za toplo i hladno štancanje limova, dljetka za udarne alate, noževi za obrezivanje limova, probijači za kožu, alati za izradu dijelova kotrljajućih ležajeva, valjčići, kuglice i prstenovi kotrljajućih ležajeva, ukovnji za hladno kovanje novca, noževi za papir, glodala za drvo itd.

18. Fotografija mikrostrukture - Primjer primjene

1.2 PLAMENO KALJENI SLOJEVI [49,51,52]

1. Zahtjev za primjenom

Od strojnog dijela zahtijeva se povišena otpornost trošenju i dinamička izdržljivost, a sam strojni dio je velikih dimenzija i teško se njime rukuje.

2. Definicija postupka

Plameno kaljeni slojevi dobivaju se ugrijavanjem plamenom dijela presjeka strojnog elementa na temperaturu austenitizacije, držanja na temperaturi austenitizacije, naglog ohlađivanja, te

-Fe-ljevovi:

-Grupe: čelični ljev, sivi ljev, nodularni ljev

-Preporuka: GG20, GG30, GGG50 i GGG60.

7. Materijali-Struktura sloja

-martenzit.

8. Poželjna toplinska obradba obradka prije modificiranja

-poboljšavanje.

9. Poželjno stanje površine obradka prije modificiranja

9.1 Hrapavost površine

-nema posebnih zahtjeva.

9.2 Očišćenost površine

-odmaščivanje.

10. Varijante procesa

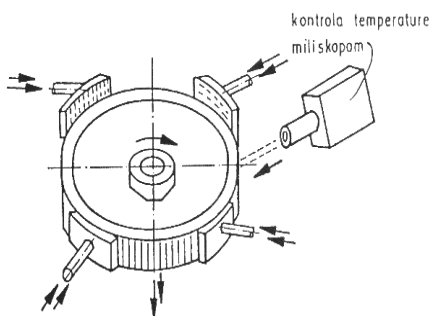
10.1 Statičko

-plamenik i obradak miruju do završetka zagrijavanja. Nakon toga se plamenik zamjenjuje prskalicom za gašenje ili se obradak

naknadnog niskog popuštanja.

3. Karakteristike i shema postupka

Kod kaljenja plamenom izvor energije (topline) je izgaranje jednog od plinova (metan, propan ili acetilen) pomiješan s kisikom pri čemu se na izlazu iz plamenika postižu temperature od 2800 do 3200 °C i time postiže veliki pad temperature između temperature plamena i temperature samog predmeta koji se ugrijava. To pogoduje nagomilavanju topline u relativno tankom površinskom sloju predmeta, je je dovod topline znatno veći u jedinici vremena, nego što je odvođenje topline od površine prema jezgri. Strojni dio je nakon plamenog kaljenja potrebno popuštat na 150 – 200 °C.



Slika P2.1. Shema postupka rotacijskog plamenog kaljenja [52]

4. Zahtjevi uvjetovani konstrukcijom obradka

- u pravilu za parcijalnu obradu,
- urezi, provrti, utori djeluju negativno na zarezno djelovanje.

5. Troškovi

5.1 Cijena postupka

- ovisi o broju komada, veličini i masi obradka.

5.2 Cijena u odnosu na druge postupke

- plameno kaljenje ima prednosti u pogledu troškova, kod obrade pojedinačnih komada i malih serija, kao i kod većih obradaka ili dijelova kojima je teško rukovati.

6. Materijali obradka

6.1 Legure na bazi Fe

- Konstrukcijski čelici:

-Preporuka sastava: 0,3 do 0,6 %C,

- Grupe: nelegirani, niskolegirani za poboljšavanje,
- Preporuka: C35G, C45G, C53G, 46Cr2, 42CrMo4.

- Alatni čelici:

- Grupe: nelegirani i niskolegirani za hladni rad,
- Preporuka: 85Cr7, 85CrMo7, Cr6.

uranja u kadu za gašenje,

- primjer obrade: kaljenje manjih površina, serijska obrada.

10.2 Kružno

- obradak rotira tijekom zagrijavanja i kaljenja,
- primjer obrade: cijevi, valjci, kuglični ležajevi.

10.3 Kružno posmično

- cilindrični se dijelovi zagrijevaju posmičnim prstenastim ili segmentnim plamenikom, a odmah iza njega dolazi prskalica istog oblika koja obavlja gašenje.

- primjer obrade: radna kola kranova, krivuljni kolutovi, pogonski valjci.

11. Praktične debljine slojeva

- 2-20 mm.

12. Promjena dimenzija i oblika obradka

- promjena dimenzija: -visoka,
- promjena oblika: -visoka.

13. Naknadna obrada sloja

13.1 Toplinska

- popuštanje: 150-250°C.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

- visoka.

15. Otpornost trošenju sloja

- abrazija, umor površine.

16. Ostala svojstva sloja

- 16.1 Korozija: -zavisno od nosivog materijala.

- 16.2 Mehanička: -tvrdoća: 800 HV,

- otpornost umoru: visoka (70% povišenje u odnosu na poboljšano stanje),

- otpornost tlačnim napetostima: visoka.

17. Primjena slojeva

17.1 Područje primjene

- industrija motora.

17.2 Praktične primjene

- svornjaci, prirubnice spojki, različite poluge, rukavci, križevi diferencijala, koljenaste i bregaste, osovine, košuljice cilindara, zupčanika velikih promjera i modula.

18. Fotografija mikrostrukture - Primjer primjene

1.3 INDUKCIJSKI KALJENI SLOJEVI [49,51,52]

1. Zahtjev za primjenom

Strojni dio je relativno kompliciranog oblika a od njega se zahtijeva visoka otpornost trošenju, visoka dinamička izdržljivost, otpornost pritiscima i udarcima.

2. Definicija postupka

Indukcijsko kaljenje je postupak površinske

7. Materijali-Struktura sloja

- martenzit.

8. Poželjna toplinska obradba obradka prije modifikiranja

- poboljšano, normalizacija.

9. Poželjno stanje površine obradka prije modifikiranja

- 9.1 Očišćenost površine

- odmaščivanje.

10. Varijante procesa

- 10.1 Statičko

- 10.2 Rotacijsko

<p>toplinske obradbe pri kojem se prvo elektromagnetskom indukcijom vrtložnih struja ostvaruje brzo i lokalno ugrijavanje površinskog sloja čelika ili željeznog lijeva na temperaturu austenitizacije.</p> <p>3. Karakteristike i shema postupka Kod indukcijskog ugrijavanja toplina se stvara u samome površinskom sloju obrađivanog predmeta, a temperature ugrijavanja dosežu u austenitno područje dotičnog predmeta. Trajanje ugrijavanja sa gašenjem je 0,5-10 s. Nakon postupka potrebno je provesti nisko popuštanje na 150-250°C.</p> <p>4. Zahtjevi uvjetovani konstrukcijom obradka -oblik kondutora podešava se prema obliku obrađivanog obradka.</p> <p>5. Troškovi 5.1 <u>Cijena postupka</u> -srednja, visoka – zavisno od kompliciranosti induktora. 5.2 <u>Cijena u odnosu na druge postupke</u> -indukcijsko kajeenje, termokemijski postupci. 5.3 <u>Investicijski troškovi</u> -visoki.</p> <p>6. Materijali obradka 6.1 <u>Legure na bazi Fe</u> -Konstrukcijski čelici: -Grupe: niskolegirani za poboljšavanje, -Preporuka: C35G, C45G, C53G, 46Cr2, 42CrMo4. -Alatni čelici: -Grupe: nelegirani i niskolegirani za hladni rad, -Preporuka: 100Cr6. -Fe-ljevovi: -Grupe: čelični lijev, sivi lijev, nodularni lijev, -Preporuka: GGG60, GGG80.</p>	<p>10.3 <u>Rotacijsko-posmično</u></p> <p>11. <u>Praktične debljine slojeva</u> -0,3 – 30 mm.</p> <p>12. <u>Promjena dimenzija i oblika obradka</u> -promjena dimenzija: -niska, -promjena oblika: -niska.</p> <p>13. <u>Naknadna obrada sloja</u> 13.1 <u>Toplinska</u> -žarenje za redukciju napetosti: 150-250 °C. 13.2 <u>Mehanička</u> -brušenje, tokarenje, glodanje.</p> <p>14. <u>Ravnomjernost debljine površinskog sloja i održanje konture sloja</u> -visoka.</p> <p>15. <u>Otpornost trošenju sloja</u> -abrazija, umor površine.</p> <p>16. <u>Ostala svojstva sloja</u> 16.1 <u>Korozija</u>: -zavisno od nosivog materijala. 16.2 <u>Mehanička</u>: -tvrdoća: 420-720 HV. -dinamička izdržljivost: 1200-1400 N/mm².</p> <p>17. <u>Primjena slojeva</u> 17.1 <u>Područje primjene</u> -industrija alatnih strojeva. 17.2 <u>Praktične primjene</u> -dugačke osovine, vodilice alatnih strojeva, vretena, svornjaci, stapajce, valjci, zupčanici, zupčasta vretena. 17.3 <u>Dimenzije obradka</u> -zupčanici: -modul 60, promjer 5500 mm. 17.4 <u>Masa obradka</u> -13 t.</p> <p>18. <u>Fotografija mikrostrukture - Primjer primjene</u></p>
<p>1.4 LASERSKI KALJENI SLOJEVI [49,53,54]</p>	

1. Zahtjev za primjenom

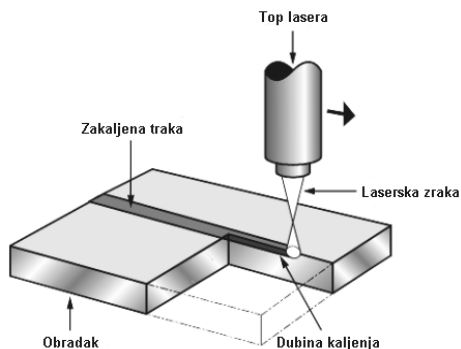
Strojni dio je relativno kompliciranog oblika a kaljenje zbog zahtjeva visoke otpornosti trošenju treba provesti na teško pristupačnim mjestima.

2. Definicija postupka

Lasersko kaljenje je postupak vrlo brzog zagrijavanja površine na na temperaturu austenitizacije te brzog samozakalivanja odvođenjem topline u hladniju jezgru obradka.

3. Karakteristike i shema postupka

Kod laserskog kaljenja brzina zagrijavanja površine iznosi više od 1000 K/s. Temperatura procesa kreće se u iznosima 1000 do 1300°C. U usporedbi sa drugim postupcima, prednosti površinske obradbe laserom su u manjoj količini topline i u kraćem vremenu trajanja, što rezultira minimalnim naprezanjima obradka i nepostojanju deformacija. Nakon postupka posebno je provesti nisko popuštanje na 180-220°C



Slika P2.3. Shema postupka laserskog kaljenja [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

- za obradu dijelova srednje veličine s razmjerno malim visoko opterećenim područjima,
- za manje dijelove složenih oblika osjetljivih na deformaciju,
- površina koja se obrađuje mora biti dostupna za elektronski snop i na njoj ne smije biti otvora,
- za unutarnju obradu promjer obradka mora biti > 20mm.

5. Troškovi

5.1 Cijena postupka

- orijentacijska veličina za procjenu troškova koristi se brzina obrade površine u određenom vremenu, a približno iznosi 15 cm²/minKW.

6. Materijali obradka

6.1 Legure na bazi Fe

-Čelici:

- Preporuka: C45W, C60W, 50NiCr13, 56NiCrMoV7, 90MnCrV8, 100Cr6, X38CrMoV51, X155CrVMo121, X210Cr12, X210CrW12.

-Fe-ljevovi:

7. Materijali-Struktura sloja

-martenzit.

8. Poželjna toplinska obradba obradka prije modifikiranja

- poboljšavanje, meko žarenje, normalizacija,
- Preporuka: kaljenje laserskim snopom.

9. Poželjno stanje površine obradka prije modifikiranja

9.1 Oksidacija

- kod primjene CO₂ – lasera zbog poboljšanja apsorpcije laserskog zračenja na obrađivanu površinu se nanose oksidne ili grafitne prevlake.

10. Varijante procesa

10.1 Površinsko kaljenje laserskim snopom kontrolirane snage

- izlazna je snaga lasera točno određena, a temperatura kaljenja treba podešava se variranjem brzine posmaka,
- negativnost ove varijante je nedovoljna austenitizacija ili pregrijavanje.

10.2 Temperaturno kontrolirano površinsko kaljenje laserskim snopom

- izlazna snaga lasera regulira se tako da se zadana temperatura održi konstantnom,
- pozitivnost ove varijante su manje neravnomjernosti površine.

11. Praktične debljine slojeva

-0,1 – 2 mm.

12. Promjena dimenzija i oblika obradka

- promjena dimenzija: -niska,
- promjena oblika: -niska.

13. Naknadna obrada sloja

13.1 Toplinska

-popuštanje: 180-220 °C.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-visoka.

15. Otpornost trošenju sloja

-adhezija, umor površine.

16. Ostala svojstva sloja

16.1 Korozija: -zavisno od nosivog materijala.

16.2 Mehanička: -tvrdoća: 420-720 HV.

-dinamička izdržljivost: 1200-1400 N/mm².

-tlačne napetosti: 400 N/mm²

17. Primjena slojeva

17.1 Područje primjene

17.2 Praktične primjene

-kontaktne i brtvene površine ventila i armatura, površine izložene visokim kontaktnim pritiscima (zubi i uzubine zupčanika, lančanici, dijelovi spojki).

-površine odljevaka od željeznih ljevova izložene intenzivnom adhezijskom trošenju, kao što su: valjne staze ležajeva, košiljice cilindara motora s unutrašnjim izgaranjem.

-površine utora za karike na klipu i košuljice cilindra motora s unutrašnjim izgaranjem, gdje je potrebna strogo ograničena zona kaljenja.

18. Fotografija mikrostrukture - Primjer primjene

1.5 ELEKTRONSKIM SNOPI KALJENI SLOJEVI [49,54]

1. Zahtjev za primjenom

-Strojni dio je srednjih dimenzija s razmjerno malim ali visoko opterećenim područjima na trošenje.

-Strojni dio je malih dimenzija složenog oblika osjetljiv na deformaciju.

2. Definicija postupka

Kaljenje elektronskim snopom (struja negativno nabijenih elektrona ubrzanih u električkom polju) je postupak vrlo brzog zagrijavanja, površine predmeta na temperaturu austenitizacije te brzog samozakalijavanja odvođenjem topline u hladniju jezgru obradka.

3. Karakteristike i shema postupka

Kod kaljenja elektronskim snopom kaljenja brzina zagrijavanja površine iznosi više od 1000 do 10000 K/s. Temperatura procesa kreće se u iznosima 200 do 1200°C. Za razliku od laserskog snopa je u tome što laserski snop djeluje slobodno u atmosferi i neovisno o udaljenosti izvora snopa od obrađivanog predmeta, dok elektronski top kao izvor snopa elektrona mora zajedno sa predmetom kojeg se obrađuje biti smješten u vakuumiranom prostoru. Nakon postupka porebno je provesti nisko popuštanje na 180-220°C.

4. Zahtjevi uvjetovani konstrukcijom obradka

-za obradu dijelova srednje veličine s razmjerno malim visoko opterećenim područjima,

-za manje dijelove složenih oblika osjetljivih na deformaciju,

-površina koja se obrađuje mora biti dostupna za elektronski snop i na njoj ne smije biti otvora.

5. Troškovi

5.1 Cijena postupka

-orijentacijska veličina za procjenu troškova koristi se brzina obrade površine u određenom vremenu, a približno iznosi 25 cm²/minKW.

6. Materijali obradka

6.1 Legure na bazi Fe

-Čelici:

-Fe-ljevovi:

7. Materijali-Struktura sloja

-martenzit.

8. Poželjna toplinska obradba obradka prije modificiranja

-poboljšavanje, žarenje, normalizacija,

9. Poželjno stanje površine obradka prije modificiranja

9.1 Čišćenje površine

-odmaščivanje.

10. Varijante procesa

10.1 Izotermički prijenos energije

-cilj je, da se programiranim snopom elektrona postigne približno ista temperatura svake točke obrađivane površine.

10.2 Uvjetovan prijenos energije

-geometrijom: -gubici zbog ulaznog kuta snopa elektrona,

-posebnim zahtjevima: -prevlačenje toplinski neobrađenih dijelova.

11. Praktične debljine slojeva

-0,1 – 2 mm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -niska,

-promjena oblika: -niska.

13. Naknadna obrada sloja

13.1 Toplinska

-popuštanje: 180-220 °C.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-visoka.

15. Otpornost trošenju sloja

-adhezija, umor površine.

16. Ostala svojstva sloja

16.1 Korozija: -zavisno od nosivog materijala.

16.2 Mehanička: -tvrdoća: 420-720 HV.

17. Primjena slojeva

17.1 Područje primjene

17.2 Praktične primjene

-zbog izvanredne preciznosti računalom upravljanog elektronskog snopa, ovim postupkom omogućava se lokalno površinsko kaljenje pojedinih točaka, krivulja ili kompaktnih dijelova površine.

18. Fotografija mikrostrukture - Primjer primjene

1.6 CEMENTIRANI SLOJEVI [48,49,51,52,53,55,56,57]

1. Zahtjev za primjenom

Od strojnog dijela zahtijeva se otpornost na površinsko trošenje

10. Varijante procesa

10.1 Poučlićavanje u kapljevitim, čvrstim ili plinovitim

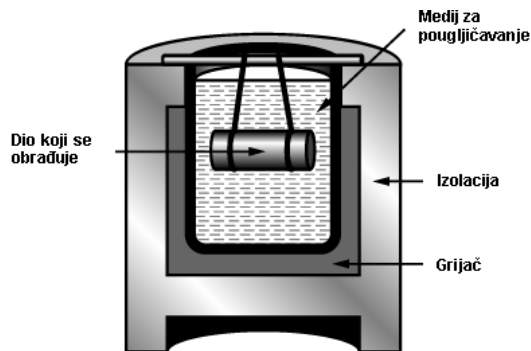
zbog umora površine uslijed visokih specifičnih pritisaka, te visoka dinamička izdržljivost (žilavost) jezgre.

2. Definicija postupka

Pouglicavanje je postupak toplinsko-kemijske obradbe kojom se u površinu čelika difundira kemijski element ugljik (C) (pouglicenje), te se naknadno kali i popušta.

3. Karakteristike i shema postupka

Termodifuzijska obradba pouglicavanjem ima za cilj da se u površinskom sloju povisi sadržaj ugljika na oko 0.75 do 1.2 %C, a najpovoljniji sadržaj je od 0.8 do 0.9 %C. Obradba se provodi na temperaturama od 800 do 1050°C. Struktura površinskog sloja sastavljena je od martenzita.



Slika P2.4. Shema postupka pouglicavanja [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

-oko su tolerancije dijela koji se pouglicava u uskim granicama, potrebno je promjenu oblika i dimenzija koje nastaje pri pouglicavanju uzeti u obzir pri strojnoj obradi,

-zbog konkavnih dijelova obradka treba računati sa manjom dubinom cementiranja u odnosu

na ravne dijelove,

-kod dimenzija većih od 25 mm primjenjuju se legirani čelici.

5. Troškovi

5.1 Cijena postupka

-ovisno o primjeni.

6. Materijali obradka

6.1 Legure na bazi Fe

-Čelici: -čelici za cementiranje, čelici za automate.

-Fe-ljevovi: -čelični ljev, bijeli temper ljev.

7. Materijali-Struktura sloja

-martenzit.

8. Poželjna toplinska obradba obradka prije modificiranja

-toplinski neobrađeno.

9. Poželjno stanje površine obradka prije modificiranja

9.1 Čišćenje površine

-odmaščivanje.

sredstvima

-temperatura: 800 – 900 °C.

11. Praktične debljine slojeva

-0.1 - 3 mm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -visoka,

-promjena oblika: -visoka.

13. Naknadna obrada sloja

13.1 Toplinska

-Popuštanje

-temperatura: -180 °C,

-vrijeme: -1h.

-Duboko hlađenje

-u svrhu smanjivanja zaostalog austenita.

13.2 Mehanička

-brušenje, lepanje, poliranje.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-visoka.

15. Otpornost trošenju sloja

-umor površine, abrazija, erozija (kavitacijom), tribokorozija.

16. Ostala svojstva sloja

16.1 Korozija: -zavisno od nosivog materijala.

16.2 Mehanička: -tvrdoća: 700 –1000 HV.

17. Primjena slojeva

17.1 Područje primjene

17.2 Praktične primjene

-strojni dijelovi malih presjeka: osovince, zupčanci, poluge, svornjaci, čahure, poluosovine, bregaste osovine, osovince klipa, osovine kotača vozila.

-strojni dijelovi srednjih presjeka: zupčanci, vretena i osovine alatnih strojeva, bregaste osovine, stapajice motora, kardanski zglobovi, zupčanci mjenjačkih kutija.

-strojni dijelovi velikih presjeka: visoko opterećeni zupčanci i vratila, koljenaste osovine.

18. Fotografija mikrostrukture - Primjer primjene



Slika P2.5. Slika mikrostrukture pouglicenog čelika [56]

2.1 NITRIRANI NITROKARBURIRANI SLOJEVI [48,49,51,52,53,55,56,57]

1. Zahtjev za primjenom

-velika otpornost na adhezijsko trošenje
-povećana dinamička izdržljivost kod promjenjivog dinamičkog opterećenja (savijanje, torzija)

-visoka površinska tvrdoća i određena dubina sloja radi otpornosti na visoki lokalni pritisak

-otpornost padu tvrdoće pri povišenim temperaturama

-antikoroziivnost (prvenstveno kod nelegiranih čelika)

-masivnost dijela (zbog niske cijene postupka)

2. Definicija postupka

Nitriranje je postupak toplinsko-kemijske obradbe kojom se u površinu čelika difundira kemijski element dušik (N).

9. Poželjno stanje površine obradka prije modificiranja

9.1 Hrapavost površine

-polirano.

9.2 Čišćenje površine

-odmaščivanje, četkanje.

10. Varijante procesa

10.1 Solno nitriranje

10.2 Plinsko nitriranje

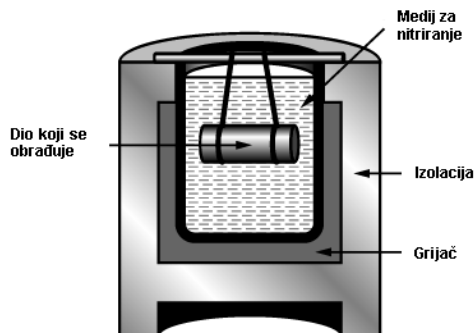
10.3 Plazma nitriranje

-pogodan postupak za: -

denasivizaciju čelika otpornih na koroziju i

3. Karakteristike i shema postupka

Termodifuzijska obradba nitiranja provodi se na temperaturama od 400 do 580 °C. Struktura površinskog sloja sastoji se od ϵ ili γ tipova nitrida što ovisi od vrste nitiranja (plinsko ili u kupkama) i koncentracije N. ϵ karbidi uz dobru tvrdoću posjeduju i dobru žilavost.



Slika P2.6: Shema postupka nitiranja [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

-moguća je obrada na ograničenom području obradka.

5. Troškovi

5.1 Cijena postupka

-niska.

5.2 Cijena u odnosu na druge postupke

-površinsko kaljenje, nitiranje, boriranje, PVD, CVD.

5.3 Investicijski troškovi

-visoki.

6. Materijali obradka

6.1 Legure na bazi Fe

-Čelici: -čelici za cementiranje, čelici za automate.

-Fe-lijevovi: -čelični ljev, bijeli ljev.

6.2 Legure na bazi Ti

7. Materijali-Struktura sloja

-nitridi (ϵ -Fe₂N, Fe₃N; γ -Fe₄N).

8. Poželjna toplinska obradba obradka prije modifikiranja

-poboljšavanje (temp. poboljšavanja 10–20% veća od temp. nitiranja).

depasivizaciju čelika otpornih na koroziju i kiseline, za dobivanje slojeva promjenljive debljine.

11. Praktične debljine slojeva

-10 – 1500 μ m.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -niska – zbog niskih temperatura na kojima se odvija proces.

-promjena oblika: -niska – zbog niskih temperatura na kojima se odvija proces.

13. Naknadna obrada sloja

13.1 Toplinska

-oksidacija u cilju poboljšanja otpornosti koroziji.

13.2 Mehanička

-poliranje, lepanje, superfiniš.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-srednja (na ravnomjernost sloja utječu: čišćenje, ulazna hrapavost, postupak obrade i osnovni materijal).

15. Otpornost trošenju sloja

-adhezija (niski koeficijent trenja), abrazija, tribokorozija, umor površine.

16. Ostala svojstva sloja

16.1 Korozija: -otpornost: solima, kiselinama, fosforu ili voćnim kiselinama.

16.2 Mehanička: -tvrdoća: 450 - 1200 HV.

16.3 Umor materijala: -srednja otpornost.

17. Primjena slojeva

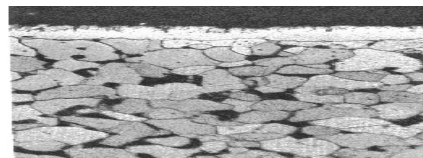
17.1 Područje primjene

-automobilska industrija.

17.2 Praktične primjene

-vodilice, dijelovi izloženi povišenim temperaturama do 480°C, dijelovi poljoprivrednih strojeva, dijelovi stapnih pumpi, visokoturažni zupčanici, koljenasta vratila, bregaste osovine, ojnice, vitke, stožni zupčanici.

18. Fotografija mikrostrukture - Primjer primjene



Slika P2.7. Slika mikrostrukture nitiranog sloja čelika [55]

2.2 BORIRANI SLOJEVI [49,48,52,53,55,56,57]

1. Zahtjev za primjenom

-ekstremni uvjeti trošenja u eksploataciji: abrazija, adhezija, umor površine, visoki površinski pritisci,

-kada jeftiniji nitirani slojevi ne odgovaraju zahtjevima trošenja.

2. Definicija postupka

Boriranje je postupak toplinsko-kemijske obradbe kojim se u površinu čelika difundira kemijski element bor (B). Struktura površinskog sloja sastoji se od Fe-borida (Fe₂B ili FeB).

3. Karakteristike i shema postupka

Na slici je prikazan shema postupka boriranja u prašku koji se provodi na temperaturi od 800 – 1100 °C. Boriranje je razmjerno skup postupak uslijed visokih troškova ručnog rada (pakiranje-raspakiranje dijelova, podmazivanje pastom, čišćenje itd.). Provodi se u pravilu kada jeftinije nitiranje ne udovoljava zahtjevima trošenja.

7. Materijali-Struktura sloja

-boridi

8. Poželjna toplinska obradba obradka prije modifikiranja

8.1 Toplinski neobrađeno

-zbog toga što se postupak provodi na temperaturi od 900 °C što može imati štetan utjecaj na ranije postignutu kaljenu ili poboljšanu strukturu.

8.2 Toplinski obrađeno

-žarenje za redukciju napetosti – zbog unutarnjih naprezanja površinskih slojeva zbog mehaničke obrade

-rekristalizacijsko žarenje – zbog

unutarnjih naprezanja površinskih slojeva zbog

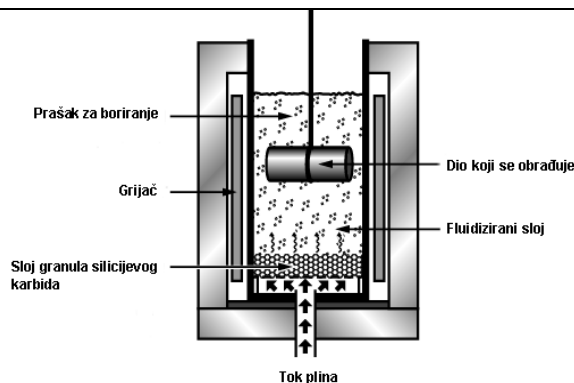
mehaničke obrade.

9. Poželjno stanje površine obradka prije modifikiranja

9.1 Hrapavost površine

-polirano.

9.2 Čišćenje površine



Slika P2.8. Shema postupka boriranja [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

-obradci koji se boriraju ne smiju imati oštih ivica te ih treba ih skositi, jer može doći do pucanja istih zbog porasta volumena,
-djelomično boriranje se ne preporučuje i skuplje je u odnosu na cjelovito boriranje zbog troškova prekrivanja zona boriranja.

5. Troškovi

5.1 Cijena postupka

-visoka, zbog troškova ručnih radova (pakiranje i raspakiranje dijelova, premazivanje

5.2 Cijena u odnosu na druge postupke

-nitiranje, boriranje.

6. Materijali obradka

6.1 Legure na bazi Fe: -nisu pogodni čelici koji sadrže 0.8%Si
-Konstruktivski čelici: čelici za cementiranje, čelici za poboljšavanje, korozivski postojani čelici,
-Alatni čelici: čelici za hladni rad, čelici za topli rad,
-Fe-ljevovi.

6.2 Legure na bazi Ni

6.3 Legure na bazi Ti

6.4 Tvrdi metali

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-visoka.

15. Otpornost trošenju sloja

-visoka otpornost abrazivskom trošenju,
-visoka otpornost adhezijskom trošenju (niska sklonost hladnom zaribanju).

16. Ostala svojstva sloja

16.1 Korozija: -zavisno od nosivog materijala.

16.2 Mehanička: -tvrdoća: 1300 – 2100 HV (zavisno od vrste borida: Fe₂B –

nelegirani/niskolegirani čelici ili FeB-

visokolegirani čelici).

-obradljivost: niska

-zavarljivost: niska (zbog oštećenja boridnog

sloja)

-dinamička izdržljivost: mali porast

-savojna čvrstoća: -kod opterećenja na

savijanje, boridni slojevi u

području istezanja pucaju,

ali se ne ljušte,

-u tlačnom je području

moгуće podnošenje većih

opterećenja bez oštećenja.

16.3 Toplinska postojanost: 600°C - 900°C (kombinacija boriranja-alitiranja)

17. Primjena slojeva

17.1 Područje primjene

-industriji stakla, industrija vozila, strojeva, uređaja i aparata.

17.2 Praktične primjene

-puževi ekstrudera, kugle ventila, valjci za žicu i staklo, trnovi i žigovi za

duboko izvlačenje, dijelovi mjenjača, valjci za graviranje,

dijelovi za oblikovanje betona,

-odmaščivanje, četkanje, sačmarenje.

10. Varijante procesa

10.1 Boriranje u prašku

-boriranje cijelog obradka.

10.2 Boriranje u granulatu

-boriranje cijelog obradka.

10.3 Boriranje u pastama

-boriranje dijela obradka premazivanjem pastom, a ostalo se prekriva.

11. Praktične debljine slojeva

-20 – 200 μm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -niska

-promjena oblika: -visoka -zbog visokih temperatura na kojima se proces boriranja odvija.

13. Naknadna obrada sloja

13.1 Toplinska

-Naknadna difuzija

-kod povišenih sadržaja legiranih elemenata u obradku dolazi do pada brzine difuzije bora u unutrašnjost obradka, pa zbog toga u gornjem sloju nastaje faza bogata borom

FeB, dok u donjem sloju nastaje Fe₂B faza koja je

siromašnija borom. Pri ohlađivanju s temperature boriranja zbog različitog koeficijenta istezanja nastaju visoke napetosti

između FeB i Fe₂B faze koje izazivaju ljuštenje sloja. Naknadnom difuzijom se odvodi


višak bora iz FeB faze te tako smanjuju napetosti.

-Poboljšavanje

-izvodi se u zaštitnoj atmosferi ili vakuumu te ne utječe na svojstva sloja.

kalupi za prešanje, sapnice za lijevanje, dijelovi ventila, dijelovi pumpi, pneumatski transportni sustavi, jedinice za plastificiranje u obradi plastike, dijelovi mlina, armaturni dijelovi.

18. Fotografija mikrostrukture - Primjer primjene



Slika P2.9. Slika mikrostrukture boriranog čelika [56]

2.3 VANADIRANI SLOJEVI [48,49,55,56]

1. Zahtjev za primjenom

-Ekstremni uvjeti trošenja u eksploataciji: abrazija, adhezija
-Uvjeti eksploatacije zahtijevaju povišenu sigurnost strojnih dijelova,
-Otežana mogućnost održavanja strojnih dijelova.

2. Definicija postupka

Vanadiranje je postupak toplinsko-kemijske obradbe kojim se u površinu čelika difundira kemijski element vanadij (V). Struktura površinskog sloja sastoji se od V-karbida (VC).

3. Karakteristike i shema postupka

Postupak se provodi na temperaturi od 1000 – 1200 °C.

4. Zahtjevi uvjetovani konstrukcijom obradka

-

5. Troškovi

5.1 Cijena postupka

5.2 Cijena u odnosu na druge postupke

5.3 Investicijski troškovi

6. Materijali obradka

6.1 Legure na bazi Fe

-Konstrukcijski čelici: za cementiranje, za poboljšavanje

-Alatni čelici: za hladni rad, za topli rad

-Fe-ljevovi:

7. Materijali-Struktura sloja

-vanadij-karbidi.

8. Poželjna toplinska obradba obradka prije modificiranja

-pougljičavanje.

9. Poželjno stanje površine obradka prije modificiranja

10. Varijante procesa

11. Praktične debljine slojeva

-20 μm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija:-niska

-promjena oblika: -visoka -zbog visokih temperatura na kojima se proces vanadiranja odvija.

13. Naknadna obrada sloja

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

15. Otpornost trošenju sloja

-abrazija, adhezija.

16. Ostala svojstva sloja


16.1 Korozija: -zavisno od nosivog materijala.

16.2 Mehanička: -tvrdoća: 2500 – 1800 HV

17. Primjena slojeva

17.1 Područje primjene

18. Fotografija mikrostrukture - Primjer primjene



Slika P2.10. Slika mikrostrukture vanadiranog čelika [56]

17.2 Praktične primjene

- ležajevi za specijalne instrumente za rad u uvjetima ultravisokog vakuuma
- osovine specijalnih instrumenata koje trebaju biti posebno žilave koje trebaju biti posebno žilave zbog osiguranja od eventualnih potresa ili udara.
- ležaji i osovine u uvjetima rada atomskih reaktora.
- ležajevi i osovine u korodirajućoj atmosferi u procesnoj industriji.

3.1 SLOJEVI SAMOTEKUĆIH LEGURA [49,53]

1. Zahtjev za primjenom

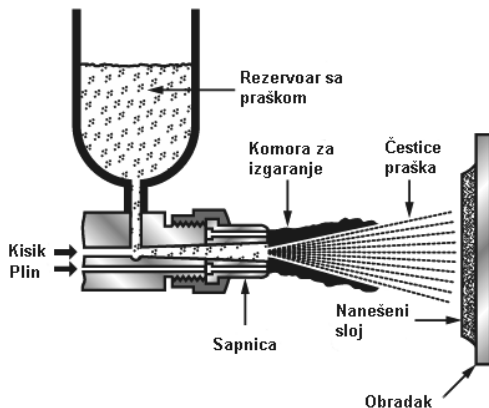
Od strojnog dijela traži se dobra otpornost na trošenje abrazijom, erozijom uz istovremenu dobru otpornost na koroziju.

2. Definicija postupka

Slojevi samotekućih legura spadaju u postupke toplinskog naštrcavanja čestica žice ili praška određenog kemijskog sastava rastaljivanjem u gorivoj smjesi plina (acetilen, propan, vodik) i kisika na površinu obrađivanog predmeta.

3. Karakteristike i shema postupka

Samotekuće legure najčešće se dobivaju postupkom plamenog naštrcavanja praška. Pod samotekućim legurama podrazumijevaju se materijali na bazi NiCrBSi ili CoCrBSi, koji se kod 1020-1040 °C rastaljuju. Temperatura procesa iznosi od 1020 do 1200°C, brzina čestica do 90 m/s, a veličina čestica manja od 106 μm. Temperatura plamena iznosi 3160 °C, a brzina gorenja plamena 11,6 m/s.



Slika P2.11. Shema postupka plamenog naštrcavanja samotekuće legure u obliku praška [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

5. Troškovi

5.1 Cijena postupka

-niska

5.2 Cijena u odnosu na druge postupke

-plameno, visokobrzinsko.

5.3 Investicijski troškovi

-niski.

6. Materijali obradka

6.1 Legure na bazi Fe

-Konstrukcijski čelici

-Fe-ljevovi

7. Materijali-Struktura sloja

-NiCrBSi legura: C=0,1-1,00%; Cr=0,0-30,00%; B=0,9- 4,00%; Si=0,6-4,25%; Fe=0,2-4,75%; Ni-ostatak.

-Dodavanjem bora i silicija i kroma, tijekom procesa naštrcavanja dolazi do stvaranja tvrdih l

15. Otpornost trošenju sloja

-visoka otpornost na abraziju i eroziju.

16. Ostala svojstva sloja

16.1 Korozija: visoka.

16.2 Mehanička: -tvrdoća: 220 – 800 HV,

na trošenje otpornih borida, silicida i karbida:

- nikl-borid (Ni₃B),
- krom-boridi (Cr₃B₃, Cr₂₃C₆),
- krom-karbidi (Cr₂₃C₆),
- silicidi (Ni₃Si),
- boridi (Cr₃B₄ i CrB₂).

8. Poželjna toplinska obradba obradka prije modificiranja

-toplinski obrada nije poželjna, zbog toga što se bi se postignuta svojstva toplinskom obradom izgubila zbog visoke temperature naštrcavanja koja rastaljuje površinu obradka,
-potrebno je predgrijavanje obradka neposredno prije modificiranja.

9. Poželjno stanje površine obradka prije modificiranja

-površina mora biti ohrapavljena (postupkom pjeskarenja) u cilju poboljšanja adhezije između sloja i obradka.

10. Varijante procesa

10.1 Plameno naštrcavanje praška:

-kod niskih zahtjeva na sloj (otpornost trošenju, adhezijska čvrstoća, homogenost, poroznost).

10.2 Naštrcavanje praška plazmom:

-kod srednjih zahtjeva na sloj (otpornost trošenju, adhezijska čvrstoća, homogenost, poroznost).

10.3 Visokobrzinsko naštrcavanje praška

11. Praktične debljine slojeva

-10 – 1600 μm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -niska
-promjena oblika: -niska – kada nema naknadne obrade rastaljivanjem (kod plamenog naštrcavanja zbog niskog toplinskog i mehaničkog opterećenja),
-srednja -kada nema naknadne obrade rastaljivanjem (tankostijeni obradci kod visokobrzinskog naštrcavanja, potrebno je osigurati hlađenje),
-visoka - nakon naknadne obrade sloja rastaljivanjem kod obradaka velikih dimenzija i masa.

13. Naknadna obrada sloja

13.1 Stalivanje:

-provodi se neposredno nakon naštrcavanja a zbog poboljšanja adhezije, poroziteta, tvrdoće, otpornosti na trošenje i gustoću,
-proces se provodi: -autogenim plamenikom, -induktivno (kod rotacijskih i simetričnih obradaka velike mase i dimenzija, zbog skin-efekta koji zagrijava samo površinski dio),
-u vakumskoj peći,
-nakon obrade rastaljivanjem dijelovi se zbog izbjegavanja vlastitih napetosti kontrolirano sporo hlade u peći.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-pri upotrebi plamenog naštrcavanja s automatskim posmakom mogu se postići debljine i konture u uskom tolerancijskom području (+/-20 μm).

-savojna čvrstoća: visoka,
 -žilavost: visoka,
 -dinamička izdržljivost: -sloj nema utjecaja na din. izdržljivost sloja.

16.3 Tehnološka: -zavarljivost: visoka.
 16.4 Toplinska: -otpornost promjeni temperature: visoka,
 -otpornost oksidaciji: visoka.

17. Primjena slojeva
 17.1 Područje primjene
 -područje proizvodnje motora,
 -zaštita od korozije,
 -zaštita od visokotemperaturne oksidacije i korozije.

17.2 Praktične primjene
 -reparaturna naštrcavanje strojnih dijelova kao što su: dijelovi pumpi, prsteni cilindara, sinhroni prsteni, ventili, itd.

17.3 Dimenzije obradka
 -dužina: do 4 m.

17.4 Masa obradka
 -velika.

18. Fotografija mikrostrukture - Primjer primjene

-naknadna obrada sloja rastaljivanjem može negativno djelovati na dimenzije obradka, posebno na ivicama.

3.2 SLOJEVI ČISTIH METALA [49,53]

1. Zahtjev za primjenom

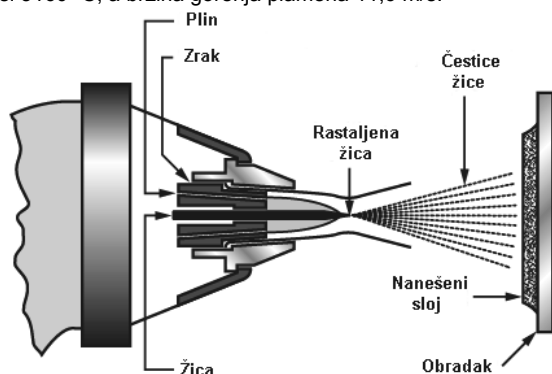
Od strojnoj dijela traži se dobra otpornost na trošenje abrazijom i adhezijom.

2. Definicija postupka

Slojevi čistih metala spadaju u postupke toplinskog naštrcavanja čestica žice ili praška određenog metala (najčešće Mo) rastaljivanjem u gorivoj smjesi plina (acetilen) i kisika na površinu obrađivanog predmeta.

3. Karakteristike i shema postupka

Slojevi čistih metala najčešće se dobivaju postupkom plamenog naštrcavanja žicom. Pod čistim metalima uglavnom se podrazumijevaju Al, Cu, Ti i Mo. Temperatura procesa iznosi od 1020 do 1200°C, a brzina čestica do 90 m/s. Temperatura plamena iznosi 3160 °C, a brzina gorenja plamena 11,6 m/s.



Slika P2.12. Shema postupka plamenog naštrcavanja čistog metala

9. Poželjno stanje površine obradka prije modifikiranja

-površina mora biti ohrapvljena (postupkom sačmarenja korundom) u cilju poboljšanja adhezije između sloja i obradka.

10. Varijante procesa

10.1 Plameno naštrcavanje žice:

-kod niskih zahtjeva na sloj (otpornost trošenju, adhezijska čvrstoća, homogenost, poroznost).

10.2 Naštrcavanje praška plazmom:

-kod srednjih zahtjeva na sloj (otpornost trošenju, adhezijska čvrstoća, homogenost, poroznost).

11. Praktične debljine slojeva

-15 – 3000µm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -niska
 -promjena oblika: -niska – kod plamenog naštrcavanja - zbog niskog toplinskog i

mehaničkog opterećenja,
 -srednja – tankostijeni obradci kod visokobrzinskog naštrcavanja, potrebno osigurati hlađenje).

13. Naknadna obrada sloja

13.1 Toplinska:

-nije uobičajena zbog opasnosti rastaljivanja sloja.

13.2 Mehanička:

-zbog postizanje određene hrapavosti sloj se može obrađivati brušenjem.

u obliku žice [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

5. Troškovi

5.1 Cijena postupka

5.2 Cijena u odnosu na druge postupke

-elektrolučno, plameno, plazma,

visokobrzinsko.

5.3 Investicijski troškovi

6. Materijali obradka

6.1 Legure na bazi Fe

-Čelici

-Fe-ljevovi

6.2 Ni-legure

6.3 Al-legure

7. Materijali-Struktura sloja

-Mo -zaštita od trošenja (najčešće se primjenjuje),

-Al -zaštita od korozije i poboljšanje toplinske vodljivosti,

-Cu -poboljšanje električne vodljivosti,

-Ti -zaštita implantata.

8. Poželjna toplinska obradba obradka prije modifikiranja

-toplinski neobrađeno, kaljeno, poboljšano,

-difuzijski slojevi ne mogu se naštrcavati.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-pri upotrebi plamenog naštrcavanja s automatskim posmakom mogu se postići debljine i konture u uskom tolerancijskom području (+/-20 μm).

15. Otpornost trošenju sloja

-visoka otpornost na adheziju, abraziju.

16. Ostala svojstva sloja

16.1 Korozija:

16.2 Mehanička: -tvrdoća: 390 – 700 HV,

-dinamička izdržljivost:-sloj nema

utjecaja na din. izdržljivost sloja.

16.3 Tehnološka:

16.4 Toplinska: -otpornost promjeni temperature: 350-550 °C,

-otpornost oksidaciji: do 350 °C.

17. Primjena slojeva

17.1 Područje primjene

17.2 Praktične primjene

-reparaturna naštrcavanje strojnih dijelova kao što su: dijelovi pumpi, prsteni cilindara, sinhroni prsteni, ventili, itd.

17.3 Dimenzije obradka

17.4 Masa obradka

18. Fotografija mikrostrukture - Primjer primjene

3.3 SLOJEVI METALNIH KARBIDA [49,53]

1. Zahtjev za primjenom

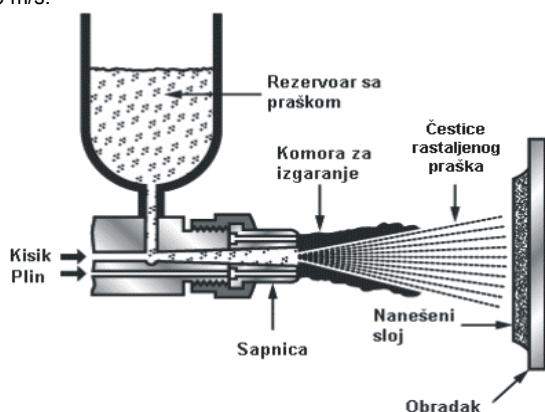
Od strojnog dijela traži se dobra otpornost na trošenje adhezijom, abrazijom, erozijom uz istovremenu otpornost koroziji.

2. Definicija postupka

Slojevi metalnih karbida spadaju u postupke toplinskog naštrcavanja čestica karbida u obliku žice ili praška određenog kemijskog sastava rastaljivanjem u gorivoj smjesi plina (acetilen, propan, vodik) i kisika na površinu obrađivanog predmeta.

3. Karakteristike i shema postupka

Slojevi metalnih karbida najčešće se dobivaju postupkom visokobrzinskog plamenog naštrcavanja praška. Pod metalnim karbidima podrazumijevamo volframove ili krom karbide u niklenoj ili niki-krom matrici. Temperatura procesa iznosi od 1020 do 1200°C, brzina čestica do 800 m/s, a veličina čestica manja od 106 μm. Temperatura plamena iznosi 3200 °C, a brzina gorenja plamena 2100 m/s.



Slika P2.13. Shema postupka visokobrzinskog plam. naštrc. metalnih karbida u obliku praška [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

5. Troškovi

5.1 Cijena postupka

5.2 Cijena u odnosu na druge postupke

-oksidnokeramički slojevi, slojevi čistih metala, slojevi metalnih karbida

5.3 Investicijski troškovi

6. Materijali obradka

6.1 Legure na bazi Fe

-Čelici

8. Poželjna toplinska obradba obradka prije modifikiranja

-metalni oksidi naštrcavaju se na toplinski obrađene obradke, -pri visokobrzinskom naštrcavanju obradak se predgrijava iznad 100°C.

9. Poželjno stanje površine obradka prije modifikiranja

-površina mora biti ohrapavljena (postupkom sačmarenja korundom) u cilju poboljšanja adhezije između sloja i obradka,

10. Varijante procesa

10.1 Plameno naštrcavanje praška:

-kod niskih zahtjeva na sloj

(otpornost trošenju, adhezijska čvrstoća, homogenost,

poroznost),

10.2 Naštrcavanje praška plazmom:

-kod srednjih zahtjeva na sloj (otpornost trošenju, adhezijska čvrstoća, homogenost, poroznost).

10.3 Visokobrzinsko plameno naštrcavanje praška:

-kod visokih zahtjeva na sloj (otpornost trošenju, adhezijska čvrstoća, homogenost, poroznost).

11. Praktične debljine slojeva

-100 – 500μm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -niska

-promjena oblika: -niska – zbog niskog toplinskog i mehaničkog opterećenja,

-srednja – tankostijeni obradci kod visokobrzinskog naštrcavanja, potrebno osigurati hlađenje).

13. Naknadna obrada sloja

13.1 Toplinska:

-nije uobičajena zbog opasnosti rastaljivanja sloja.

13.2 Mehanička:

-zbog postizanje određene hrapavosti sloj se može obrađivati brušenjem.

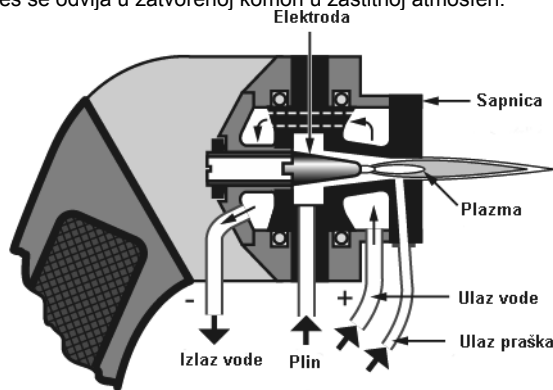
14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-pri upotrebi naštrcavanja s automatskim posmakom

<p>-Fe-ljevovi</p> <p>7. Materijali-Struktura sloja</p> <p>7.1 <u>Volfram karbidi</u>: WC-Co88-12 i WC-Co83-17 -otpornost na abraziju pri temperaturama do 500 °C.</p> <p>7.2 <u>Krom karbidi</u>: WC-Co-Cr 86-10-4 i Cr₃C₂-NiCr75-25 -otpornost na abraziju i koroziju temperaturama do 900 °C.</p>	<p>moгу se postići debljine i konture u uskom tolerancijsom području (+/-20 μm).</p> <p>15. <u>Otpornost trošenju sloja</u> -visoka otpornost na abraziju, adheziju, umoru površine (zbog induciranja vlastitih tlačnih naprezanja).</p> <p>16. <u>Ostala svojstva sloja</u></p> <p>16.1 <u>Korozija</u>: visoka otpornost</p> <p>16.2 <u>Mehanička</u>: -tvrdoća: min. 800 HV, -dinamička izdržljivost:-sloj nema utjecaja na din. izdržljivost sloja.</p> <p>16.3 <u>Tehnološka</u>:</p> <p>16.4 <u>Toplinska</u>:</p> <p>17. <u>Primjena slojeva</u></p> <p>17.1 <u>Područje primjene</u> -industrija papira, tekstilna industrija, kemijska industrija, prehrambena industrija, procesna industrija, autoindustrija, prerada čelika.</p> <p>17.2 <u>Praktične primjene</u></p> <p>17.3 <u>Dimenzije obradka</u></p> <p>18. <u>Fotografija mikrostrukture - Primjer primjene</u></p>
---	--

3.4 SLOJEVI METALNIH OKSIDA [49,51,53]

<p>1. <u>Zahtjev za primjenom</u> Od strojnog dijela traži se dobra otpornost na trošenje adhezijom, abrazijom, erozijom uz istovremenu otpornost koroziji i oksidaciji pri povišenim temperaturama.</p> <p>2. <u>Definicija postupka</u> Slojevi metalnih oksida spadaju u postupke toplinskog naštrcavanja čestica oksidno-keramičkih materijala u obliku praška rastaljivanjem u ioniziranom plinu na površinu obrađivanog predmeta.</p> <p>3. <u>Karakteristike i shema postupka</u> Slojevi metalnih oksida najčešće se dobivaju postupkom naštrcavanja plazmom. Kod naštrcavanja plazmom se između elektrode i mlaznice, koja je istovremeno i anoda, prolaskom struje pali električni luk. Kroz taj električni luk struji plazmatski plin (argon, helij ili vodik) te se ionizira. Temperature u plazmi iznose do 20000 K. Materijal za prskanje ubrizgava se u plazmu gdje se rastaljuje. Proces se odvija u zatvorenoj komori u zaštitnoj atmosferi.</p>	<p>8. <u>Poželjna toplinska obradba obradka prije modificiranja</u> -metalni oksidi naštrcavaju se na toplinski neobrađene obradke, -nitrirane i pougličene površine ne mogu se naštrcavati metalnim oksidima.</p> <p>9. <u>Poželjno stanje površine obradka prije modificiranja</u> -površina mora biti ohrapavljena (postupkom sačmarenja korundom) u cilju poboljšanja adhezije između sloja i obradka, -nakon toga nanosi se metalni (Ni-Al ili Ni-Cr legure) adhezijski međusloj zbog zaštite površine od korozije.</p> <p>10. <u>Varijante procesa</u></p> <p>10.1 <u>Plameno naštrcavanje praška</u>: -kod niskih zahtjeva na sloj (homogenost i poroznost),</p> <p>10.2 <u>Naštrcavanje praška plazmom</u>: -kod viših zahtjeva na sloj (homogenost i poroznost).</p> <p>11. <u>Praktične debljine slojeva</u> -10μm – 3000μm</p> <p>12. <u>Promjena dimenzija i oblika obradka</u> -promjena dimenzija: -niska -promjena oblika: -niska – kod tankostijenih obradaka može doći do deformacije oblika i dimenzija te je potrebno osigurati hlađenje.</p> <p>13. <u>Naknadna obrada sloja</u></p> <p>13.1 <u>Toplinska</u>:</p> <p>13.2 <u>Mehanička</u>: -zbog postizanje određene hrapavosti sloj se može obrađivati brušenjem.</p> <p>14. <u>Ravnomjernost debljine površinskog sloja i održanje konture sloja</u> -pri upotrebi naštrcavanja s automatskim posmakom mogu se postići debljine i konture u uskom tolerancijsom području (+/-20 μm).</p> <p>15. <u>Otpornost trošenju sloja</u> -visoka otpornost na adheziju, abraziju, eroziju, niska otpornost umoru površine.</p> <p>16. <u>Ostala svojstva sloja</u></p> <p>16.1 <u>Korozija</u>: -visoka, -strojni dijelovi koji nisu otporni na koroziju i malih debljina sloja (<0,5 mm),</p>
--	---



Slika P2.14. Shema postupka plazmom naštrcanih metalnih oksida [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

5. Troškovi

5.2 Cijena u odnosu na druge postupke

-oksidnokeramički slojevi, slojevi čistih metala, slojevi metalnih karbida

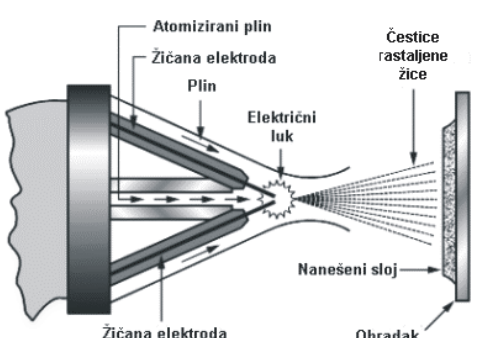
6. Materijali obradka

6.1 Legure na bazi Fe

- Čelici
- Fe-ljevovi

7. Materijali-Struktura sloja

- Al₂O₃ -zaštita od trošenja i električka izolacija,
- Al₂O₃ -TiO₂ -zaštita od trošenja,
- Al₂O₃ -SiO₂ -zaštita od trošenja i električka izolacija,

<p>-Cr₂O₃ -zaštita od trošenja, zaštita od korozije, -Cr₂O₃-SiO₂-TiO₂ -zaštita od trošenja, niski koeficijent trenja, -TiO₂ -umjerena zaštita od trošenja, niska električna vodljivost, -TiO₂-Cr₂O₃ -zaštita od trošenja i korozije, otpornost na povišenu temperaturu, -ZrO₂-Y₂O₃ -toplinska izolacija, otpornost na visoke temperature, otpornost na eroziju, -ZrO₂-TiO₂-Y₂O₃ -otpornost na koroziju uslijed visoke temperature i na koroziju uslijed vrućih toplinska izolacija, plinova, otpornost na promjene temperature, -ZrO₂-MgO -toplinska izolacija, otpornost na abraziju.</p>	<p>slojeve je potrebno dodatno premazivati organskim tvarima u cilju zatvaranja pora. 16.2 <u>Mehanička</u>: -tvrdoća: 300-800 HV, -dinamička izdržljivost: -sloj nema utjecaja na din. izdržljivost sloja. 16.3 <u>Tehnološka</u>: 16.4 <u>Toplinska</u>: 16.5 <u>Medicinska</u>: -visoka biokompatibilna svojstva. 17. Primjena slojeva 17.1 <u>Područje primjene</u> -industrija papira, tekstilna industrija, kemijska industrija, prehrambena industrija, procesna industrija, autoindustrija 17.2 Praktične primjene - transportni valjci, valjci za prešanje i tisak, kuglični i klizni ležajevi, mlaznice, brtveni prstenovi, vodilice, rezni alati, dijelovi motora: ventili, rotor turbopunjača, komora izgaranja. 18. Fotografija mikrostrukture - Primjer primjene</p>
3.5 SLOJEVI LEGURA NA BAZI ŽELJEZA [49,53]	
<p>1. Zahtjev za primjenom Dimenzijska reparatura strojnih dijelova, dobra otpornost na abraziju, eroziju i koroziju.</p> <p>2. Definicija postupka Slojevi legura na bazi željeza spadaju u postupke toplinskog naštrcavanja čestica Fe-materijala u obliku žice rastaljanjem u atomiziranom plinu na površinu obrađivanog predmeta.</p> <p>3. Karakteristike i shema postupka Slojevi legura na bazi željeza najčešće se dobivaju postupkom elektrolučnog naštrcavanja žicom. Kod elektrolučnog naštrcavanja, izvor topline je električni luk. Električni luk rastaljuje krajeve žica a rastaljeni tekući materijal se atomiziranim plinom ubrzava u smjeru površine obradka. Kontinuiranim dovođenjem obiju žica uspostavlja se i održava stabilan proces naštrcavanja. Temperatura procesa je od 4000 -6000 °C.</p>  <p>Slika P2.15. Shema postupka elektrolučnog naštrcavanja žicom legura na bazi Fe [53]</p> <p>4. Zahtjevi uvjetovani konstrukcijom obradka</p> <p>5. Troškovi 5.1 <u>Cijena u odnosu na druge postupke</u> -plameno, elektrolučno, visokobrzinsko, plazma.</p> <p>6. Materijali obradka</p>	<p>adhezije između sloja i obradka, -površina mora biti odmašćena, -kratko predgrijavanje prije modifikiranja.</p> <p>10. Varijante procesa 10.1 <u>Plameno i elektrolučno naštrcavanje žice</u>: -kod slojeva debljine nekoliko mm, -kod dimenzijskog reparaturnog naštrcavanja, -slojevi su srednje otporni abraziji, eroziji i kavitaciji, -najniži investicijski troškovi.</p> <p>10.2 <u>Plameno, visokobrzinsko i plazmom naštrcavanje praška</u>: -dobivaju se najkvalitetniji slojevi u pogledu debljine, udjela oksida, gubitka legiranih elemenata -slojevi su otporni kombinaciji trošenja (abraziji, eroziji i kavitaciji) i korozije ili čiste korozije</p> <p>11. Praktične debljine slojeva 11.1 <u>Plameno i elektrolučno naštrcavanje</u>: -od nekoliko μm do nekoliko mma odnosno cm. 11.2 <u>Visokobrzinsko i naštrcavanje plazmom</u>: -zbog ekonomskih razloga nanose se tanki slojevi od nekoliko μm do maksimalno 2 mm.</p> <p>12. Promjena dimenzija i oblika obradka -promjena dimenzija: -niska, -promjena oblika: -srednja – kod tankostijenih obradaka može doći do deformacije oblika i dimenzija te je potrebno osigurati hlađenje.</p> <p>13. Naknadna obrada sloja</p>

<p>6.1 <u>Legure na bazi Fe</u> -Čelici -Fe-ljevovi</p> <p>6.2 <u>Ni-Legure</u></p> <p>7. <u>Materijali-Struktura sloja</u> -Cr, -Cr-Ni, -Fe-Mo, -Fe-Mo-Al.</p> <p>8. <u>Poželjna toplinska obradba obradka prije modificiranja</u> -prije modificiranja nije potrebna toplinska obradba, a mogu se naštrecavati i poboljšane površine ako se iste mogu ohrapaviti (hrapavljenje je moguće ukoliko tvrdoća površine materijala na koji se naštrecava nije viša od 600HV),</p> <p>-termokemijski obrađene površine ne mogu se naštrecavati legurama na bazi željeza.</p> <p>9. <u>Poželjno stanje površine obradka prije modificiranja</u> -površina mora biti ohrapavljena (postupkom sačmarenja korundom) u cilju poboljšanja</p> <p>16.2 <u>Mehanička</u>: -tvrdoća: 230-520 HV, -dinamička izdržljivost:-sloj nema utjecaja na din. izdržljivost sloja.</p> <p>16.3 <u>Tehnološka</u>: -obradljivost: visoka.</p> <p>16.4 <u>Toplinska</u>: -otpornost oksidaciji: do 800 °C.</p> <p>16.5 <u>Medicinska</u>:</p> <p>17. <u>Primjena slojeva</u> 17.1 <u>Područje primjene</u> -procesna industrija, strojogradnja.</p> <p>17.2 <u>Praktične primjene</u> -reparatura vodovodnih postrojenja, dimenzijska reparacija koljenastih vratila (Fe-Mo-Al slojevi).</p> <p>18. <u>Fotografija mikrostrukture - Primjer primjene</u></p>	<p>13.1 <u>Toplinska</u>: -nije uobičajena zbog opasnosti rastaljivanja sloja.</p> <p>13.2 <u>Mehanička</u>: -zbog postizanje određene hrapavosti sloj se može obrađivati brušenjem.</p> <p>14. <u>Ravnomjernost debljine površinskog sloja i održanje konture sloja</u> -pri upotrebi plamenog naštrecavanja s automatskim posmakom mogu se postići debljine i konture u uskom tolerancijsom području.</p> <p>15. <u>Otpornost trošenju sloja</u> 15.1 <u>Slojevi legura na bazi Fe-Cr i Fe-Cr-Ni</u>: -imaju srednju otpornost na abraziju, kavitaciju, a djelomično i na eroziju.</p> <p>15.2 <u>Slojevi legura na bazi Fe-Mo</u>: -odlikuju se niskim koeficijentima trenja i upotrebljavaju se za zaštitu od trošenja tvrdih ležajnih površina i za zaštitu protiv zaribavanja.</p> <p>16. <u>Ostala svojstva sloja</u> 16.1 <u>Korozija</u>: -Fe-Cr, a poglavito Fe-Cr-Ni čelici imaju dobru otpornost na koroziju, posebice u vodenim i u srednje agresivnim medijima, ukoliko su dovoljno debeli ili ako se nanose visokobrzinskim plamenim naštrecavanjem, -strojni dijelovi koji nisu otporni na koroziju i malih debljina sloja (<0,5 mm), slojeve je potrebno dodatno premazivati organskim tvarima u cilju zatvaranja pora, -slojevi Fe-Cr-Al-Mo imaju dobru otpornost prema sumpornim atmosferama i otporni su na oksidaciju, otporni su na trošenje abrazijom, adhezijom i erozijom te za reparaciju istrošenih strojnih dijelova.</p>
--	--

4. CVD SLOJEVI [49,53,54,57,58]

1. Zahtjev za primjenom

-Od strojnog dijela zahtijeva se najviša otpornost trošenju adheziji i abraziji.

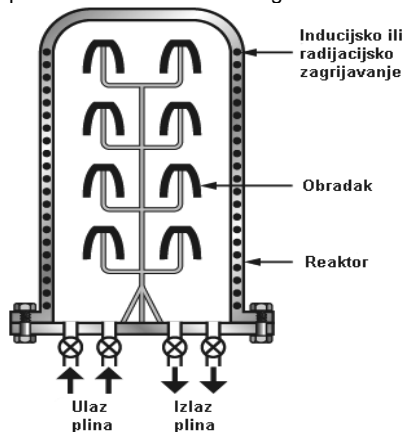
-Ovim postupkom mogu se proizvesti tvrdoće slojeva ≈ 5000 HV što je polovica tvrdoće prirodnog dijamanta.

2. Definicija postupka

CVD (Chemical Vapour Deposition) je proces izdvajanja (taloženja) krute tvari iz parne faze pri kojem ishodna supstanca mora pri odgovarajućoj temperaturi imati dovoljno visok pritisak para.

3. Karakteristike i shema postupka

CDV postupak izvodi se u reaktoru pri temperaturi $800 - 1000^{\circ}\text{C}$ u struji reakcijskog plina, a ovisno o njegovu sastavu moguće je postići slojeve karbida, nitrida ili karbonitrda. Zbog visoke temperature CVD postupka te vremena trajanja ($\approx 5\text{h}$) nužno je naknadno izvođenje uobičajene toplinske obradbe obrađivanog čelika.



Slika P2.16: Shema CVD-postupka [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

-obradak mora biti obrađen na konačnu mjeru prije nanošenja.

-prednost imaju čelici čija je temperatura austenitizacije $900 - 1000^{\circ}\text{C}$.

5. Troškovi

5.1 Cijena postupka

-niska.

5.2 Cijena u odnosu na druge postupke

5.3 Investicijski troškovi

-visoki

6. Materijali obradka

6.1 Legure na bazi Fe

-Konstrukcijski čelici:

-Alatni čelici

-Fe-ljevovi

6.2 Tvrđi metali

7. Materijali-Struktura sloja

-TiC – titan karbidi,

-TiN – titan nitridi.

8. Poželjna toplinska obradba obradka prije modifikiranja

-žarenje za redukciju napetosti: $\approx 600^{\circ}\text{C}$

9. Poželjno stanje površine obradka prije modifikiranja

9.1 Hrapavost površine

-propisana konstrukcijom.

9.2 Čišćenje površine

-odmaščivanje.

10. Varijante procesa

10.1 Toplinski CVD

-potrebno je naknadno kaljenje.

10.2 Plazmatski CVD

-niža temperatura postupka u odnosu na toplinski CVD,

-nije potrebno naknadno kaljenje,

-temperatura: $< 500^{\circ}\text{C}$.

11. Praktične debljine slojeva

-1 – 20 μm .

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -visoka,

-promjena oblika: -visoka.

13. Naknadna obrada sloja

13.1 Toplinska:

-kaljenje, popuštanje.

13.2 Mehanička:

-poliranje.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-visoka.

15. Otpornost trošenju sloja

-adhezija, abrazija.

16. Ostala svojstva sloja

16.1 Mehanička: -tvrdoća: -TiC: 3400 – 5200 HV,

-TiN: 1500 – 2700 HV.

16.2 Tehnološka: -zavarljivost: niska.

17. Primjena slojeva

17.1 Područje primjene

-rezni alati, alati za oblikovanje

metala i keramičkih materijala.

17.2 Praktične primjene

-pločice od sinteriranog tvrdog

metala.

17.3 Dimenzije obradka

17.4 Masa obradka

18. Fotografija mikrostrukture - Primjer primjene

5. PVD SLOJEVI [49,53,54,57,58]

1. Zahtjev za primjenom

Od strojnog dijela zahtijeva se najviša otpornost trošenju adheziji i abraziji, dobra oksidacijska

-Ti(Al,N): -dobra oksidacijska postojanost, i otpornost koroziji,

-prikladan za prevlačenje alata za obradu Cu,

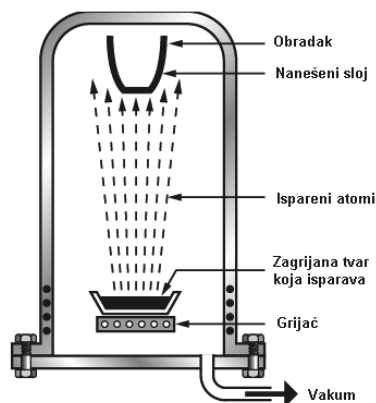
postojanost, dobra korozivna postojanost.

2. Definicija postupka

PVD (Physical Vapour Deposition) je proces izdvajanja (taloženja) krute tvari iz parne faze pri kojem je ishodna supstanca u krutom stanju.

3. Karakteristike i shema postupka

PVD postupak izvodi se pri temperaturama < 500 °C u atmosferi reakcijskog plina (dušika ili ugljikovodika) u razmjerno visokom vakumu (10^{-2} do 10^{-4} bara) u koji se iz isparivača uvode pare (npr. titana, koji isparuje pri $T > 6000$ K). U slučaju reakcijskog plina dušika i isparenoga titana stvoriti će se na katodno spojenim alatu ili strojnom dijelu, zlatno-žuti sloj titanova nitrida (TiN).



Slika P2.17. Shema PVD-postupka [53]

4. Zahtjevi uvjetovani konstrukcijom obradka

- obradak mora biti obrađen na konačnu mjeru prije nanošenja,
- niklani, brunirani ili fosfatirani obradci ne obrađuju se PVD-postupkom,
- površine moraju biti glatke i bez srha.

5. Troškovi

5.1 Cijena postupka

-niska.

5.2 Cijena u odnosu na druge postupke

-martenizirni, termokemijski, toplinsko

naštrcavanje, CVD, PVD.

5.3 Investicijski troškovi

-visoki

6. Materijali obradka

6.1 Legure na bazi Fe

-Konstrukcijski čelici:

-Alatni čelici

-Fe-ljevovi

6.2 Tvrdi metali

7. Materijali-Struktura sloja

-TiN,

-Ti(C,N) –otpornost abraziji

Ti i Al.

8. Poželjna toplinska obradba obradka prije modifikiranja

-poboljšavanje.

9. Poželjno stanje površine obradka prije modifikiranja

9.1 Hrapavost površine

-propisana konstrukcijom.

9.2 Čišćenje površine

-odmaščivanje.

10. Varijante procesa

11. Praktične debljine slojeva

-1 – 8 μm .

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -niska,

-promjena oblika: -niska.

13. Naknadna obrada sloja

13.1 Toplinska:

-nije potrebna.

13.2 Mehanička:

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-visoka.

15. Otpornost trošenju sloja

-adhezija, abrazija.

16. Ostala svojstva sloja

16.1 Korozija: povišena

16.2 Mehanička: -tvrdoća: -TiN: 2100 – 2600 HV,
-Ti(C,N): 2800 – 3200 HV,
-Ti(AlN): 2600 – 3000 HV.

16.3 Toplinska:

-TiN: -u zraku do 450 °C,

-Ti(C,N): -u zraku do 350 °C

-Ti(AlN): -u zraku do 700 °C.

17. Primjena slojeva

17.1 Područje primjene

-rezni alati, alati za oblikovanje, alati za preradbu polimera.

17.2 Praktične primjene

-glodala, svrdla, dijelovi malih strojeva, matrice i žigovi kalupa za preradbu plastičnih masa, dijelovi malih kokila.

17.3 Dimenzije obradka

-male dimenzije.

17.4 Masa obradka

-male mase.

18. Fotografija mikrostrukture - Primjer primjene

6.1 MATERIJALI SLIČNI ČELIKU [49,59,60]

1. Zahtjev za primjenom

-Od parcijalnih površina strojnih dijelova zahtijeva se visoka otpornost trošenju na abraziju i umor površine, adheziju opterećenju na vlak i tlak.

9. Poželjno stanje površine obradka prije modifikiranja

9.1 Hrapavost površine

9.2 Čišćenje površine

-odmaščivanje.

10. Varijante procesa

10.1 Strujno

-veliki dijelovi: EPP, EPT.

10.2 Elektrolučno


-srednji dijelovi: MIG/MAG, TIG.

<p>-Strojni dijelovi su skupi i velikog volumena kod kojih je jeftinije parcijalno reparaturno navarivanje nego izrada novog dijela.</p> <p>2. Definicija postupka Navarivanje je postupak prekrivanja površine materijala postupkom zavarivanja pri čemu se kod starih obradaka površina reparira, a kod novih obradaka navarivanjem nastaje nova površina željenih svojstava.</p> <p>3. Karakteristike i shema postupka Kod navarivanja uslijed usmjerenog upravljanja toplinom dolazi do lokacijski ograničenog rastaljivanja nosivog materijala, čime se stvara čvrsta veza između sloja i nosivog materijala. Najčešće primjenjivani materijali za zaštitu od trošenja su na bazi željeza, kobalta, nikla, a kao tvrdi materijali pretežito se primjenjuju karbidi (krom-karbidi, volframovi karbidi te niobijevi i vanadijevi karbidi), ali i silicidi, boridi i nitridi koji su uloženi u matricu. Za zaštitu od korozije osim čistih metala primjenjuju se legure otporne na koroziju. Postupci koji se primjenjuju su kao i kod zavarivanja: elektrolučno, pod praškom, pod troškom, TIG/MIG/MAG, elektrolučno u plazmi.</p> <p>4. Zahtjevi uvjetovani konstrukcijom obradka -površine kao što su ivice i kutevi moraju biti dostupne plameniku s kojim se navarivanje obavlja, -minimalni unutarnji promjer cijevi mora biti 50 mm, -u pravilu površine obradaka koje se navaruju moraju biti u vodoravnom položaju.</p> <p>5. Troškovi 5.1 <u>Cijena postupka</u> -Povećani troškovi za prethodnu i naknadnu obradu obradaka u pravilu se kompenziraju uštedom na troškovima nosivog materijala, koji mora ispuniti samo zahtjeve na čvrstoću i stoga može biti niskolegirani, odnosno nelegirani. -Ušteda se također ostvaruje kod obradaka velikog volumena čije su površine modificiranja male.</p> <p>5.2 <u>Cijena u odnosu na druge postupke</u> 5.3 <u>Investicijski troškovi</u></p> <p>6. Materijali obradka 6.1 <u>Legure na bazi Fe</u> -Čelici: konstrukcijski.</p> <p>7. Materijali-Struktura sloja 7.1 <u>Visokolegirani čelici za hladni rad</u> -materijali sa niskim sadržajem kroma (<13%), -materijali sa visokim sadržajem kroma (>13%) –korozijski otporna na organske kiseline, atmosferilije. 7.2 <u>Visokolegirani čelici za topli rad</u> -legura Fe-Cr-V -sadrži: 13%Cr, 18% V, -visoka otpornost na trošenje, -korozijski otporna na organske kiseline, atmosferilije.</p> <p>8. Poželjna toplinska obradba obradka prije modificiranja -kaljenje, poboljšavanje.</p> <p>16.3 <u>Tehnološka:</u> 16.4 <u>Toplinska:</u> -postojanost: 20 – 700 °C.</p> <p>17. Primjena slojeva 17.1 <u>Područje primjene</u> -građevinarstvo, rudarstvo.</p> <p>17.2 <u>Praktične primjene</u> -kotači vagona i vagoneta, kranova,</p>	<p>10.3 <u>Elektrolučno-plazma</u> -mali dijelovi: elektrolučno plazma-prašak.</p> <p>11. Praktične debljine slojeva -Općenito: -minimalna debljina samonosivih slojeva: 2 mm, -kod obradaka visoke čvrstoće: 1 mm, -kod reparaturnih slojeva debljina ovisi o volumenu odnešenog materijala. -S obzirom na varijante: -Strujno: 2-6 mm, -Elektrolučno: 2-6 mm, -Elektrolučno-plazma postupak: 1-4 mm.</p> <p>12. Promjena dimenzija i oblika obradka -promjena dimenzija: -visoka -promjena oblika: -visoka.</p> <p>13. Naknadna obrada sloja 13.1 <u>Toplinska</u> -nakon navarivanja i gašenja (kaljenja s temperature zavarivanja) provodi se popuštanje obradka, -ukoliko se od navarenog obradka zahtijeva sloj bez zone utjecaja topline, provodi se cjelokupna toplinska obradba, -temperatura austenitizacije materijala obradka i materijala sloja moraju biti usklađene zbog izbjegavanja pregrijavanja materijala obradka, odnosno nedovoljnog zagrijavanja materijala sloja.</p> <p>13.2 <u>Mehanička</u> -tokarenje, glodanje, brušenje.</p> <p>14. Ravnomjernost debljine površinskog sloja i održanje konture sloja -niska.</p> <p>15. Otpornost trošenju sloja -abrazija, umor površine, adhezija -ako je sastav materijala sloja sličan sastavu materijalu obradka tada je i stupanj otpornosti trošenju sloja i obradka sličan, -neki sastavi praška ili žice su takvi (visoki sadržaj vanadija ili kroma) da se nakon navarivanja dobiju slojevi koji uvelike premašuju iznose otpornosti trošenju konvencionalnih čelika otpornih trošenju.</p> <p>16. Ostala svojstva sloja 16.1 <u>Korozija:</u> -ako sloj sadrži > 13%Cr otporan je na organske kiseline i atmosferilije. 16.2 <u>Mehanička:</u> -tvrdoća: 700 - 800 HV, -dinamička izdržljivost:-niska, zbog mrežaste strukture sloja -tvrdoća abraziva:100 – 500 HV.</p>
--	---

tračnica,

- Preporučeni sastav sloja: 0,15-0,20%C; 1,0%Si; 1,6%Mn.
 - zubi bagera, čeljusti drobilica, čekići mlinova za ugljen,
 - Preporučeni sastav sloja: 0,15-1,1%C; 0,8-1,4%Si; 2,0-13,0%Mn; 6,0%Cr.
 - navarivanje potisnih pužnica,
 - Preporučeni sastav sloja: 0,3-0,5%C; 1,0-1,4%Si; 2,0-3,0%Mn; 2,0-6,0%Cr; 0,6%Mo.
 - drobilice za užareni ugljen, koks i trosku,
 - Preporučeni sastav sloja: 4,5%C; 2,5%Si; 23,0%Cr; 5,0%Mo; 5,0%Nb; 3,5%W, 1,0%V.
- 17.3 Dimenzije obradka
-velike dimenzije.
- 17.4 Masa obradka
-velike mase.

18. Fotografija mikrostrukture - Primjer primjene



Slika P2.18. Primjer presjeka navarenog sloja tračnice [59]

6.2 NAVARENI SLOJEVI S VISOKIM UDJELOM KARBIDA [49,59,60]

1. Zahtjev za primjenom

Od parcijalnih površina strojnog dijela zahtijeva se visoka otpornost trošenju na abraziju.

2. Definicija postupka

Navarivanje je postupak prekrivanja površine materijala postupkom zavarivanja pri čemu se kod

starih obradaka površina reparira, a kod novih obradaka navarivanjem nastaje nova površina željenih svojstava.

3. Karakteristike i shema postupka

Kod navarivanja uslijed usmjerenog upravljanja toplinom dolazi do lokacijski ograničenog rastaljivanja nosivog materijala, čime se stvara čvrsta veza između sloja i nosivog materijala. Najčešće primjenjivani materijali za zaštitu od trošenja su na bazi željeza, kobalta, nikla, a kao tvrdi materijali pretežito se primjenjuju karbidi (krom-karbidi, volframovi karbidi te niobijevi i

-veliki dijelovi: EPP, EPT.

10.2 Elektrolučno

-srednji dijelovi: MIG/MAG, TIG.

10.3 Elektrolučno-plazma

-mali dijelovi: elektrolučno plazma-prašak.

11. Praktične debljine slojeva

-2-4 mm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -visoka

-promjena oblika: -vsoka.

13. Naknadna obrada sloja

13.1 Toplinska

-popuštanje.

13.2 Mehanička

-brušenje.

14. Ravnomjernost debljine površinskog sloja i održanje konture sloja

-niska.

15. Otpornost trošenju sloja

-abrazija.

16. Ostala svojstva sloja

16.1 Korozija: -visoka.

16.2 Mehanička: -tvrdoća: 900 - 3000 HV,

-dinamička izdržljivost:-niska, zbog

mrežaste strukture,


-žilavost: niska

-otpornost stvaranju pukotina: -visoka

(ako je udio karbida < 50%).

16.3 Tehnološka: -obradljivost: niska.

16.4 Toplinska: -postojanost: 20 – 700 °C.

<p>vanadijevi karbidi), ali i silicidi, boridi i nitridi koji su uloženi u matricu. Za zaštitu od korozije osim čistih metala primjenjuuu se legure otporne na koroziju. Postupci koji se primjenjuju su kao i kod zavarivanja: elektrolučno, pod praškom, pod troskom, TIG/MIG/MAG, elektrolučno u plazmi.</p> <p>4. Zahtjevi uvjetovani konstrukcijom obradka - površine kao što su ivice i kutevi moraju biti dostupne plameniku s kojim se navarivanje obavlja, - minimalni unutarnji promjer cijevi mora biti 50 mm, - površine obradka koje se obrađuju ne moraju biti u vodoravnom položaju, već mogu biti i pod kutem zbog lošeg tečenja materijala sloja, - mogu se prevlačiti obradci kompliciranih geometrija i površine malih dimenzija, - ovi slojevi nanose se na obradke koji nisu previše udarno ili savojno opterećeni zbog krstosti nanešenog sloja, - slojevi se ne nanose na ivice zbog opasnosti pucanja krugog sloja, - postupak je ograničen na deblostijene obradke, zbog unošenja velike količine topline.</p> <p>5. Troškovi 5.1 <u>Cijena postupka</u> - visoki, zbog skupog karbidnog praška.</p> <p>5.2 <u>Cijena u odnosu na druge postupke</u> 5.3 <u>Investicijski troškovi</u></p> <p>6. Materijali obradka 6.1 <u>Legure na bazi Fe</u> - Čelici: konstrukcijski (materijali niže tvrdoće, zbog izbjegavanja pucanja nanešenog sloja).</p> <p>7. Materijali-Struktura sloja - Naziv - Fe-Cr-V legura. - Kemijski sastav - 5,0%Cr; 10,0% V. - Udio karbida - kod materijala na bazi željeza optimalan udio karbida u sloju je 30%, - kod mekanih materijala (legure kobalta i nikla) udio karbida može biti veći od 30%.</p> <p>8. Poželjna toplinska obradba obradka prije modifikiranja - kaljenje, popuštanje.</p> <p>9. Poželjno stanje površine obradka prije modifikiranja 9.1 <u>Hrapavost površine</u> 9.2 <u>Čišćenje površine</u> - odmaščivanje.</p> <p>10. Varijante procesa 10.1 <u>Strujino</u></p>	<p>17. Primjena slojeva 17.1 <u>Područje primjene</u> - građevinarstvo, rudarstvo.</p> <p>17.2 <u>Praktične primjene</u> - zubi bagera, čeljusti drobilica, čekići mlinova za ugljen.</p> <p>- Preporučeni sastav sloja: 0,15-1,1%C; 0,8-1,4%Si; 2,0-13,0%Mn; 6,0%Cr. - navarivanje potisnih pužnica, drobilice za užareni ugljen, koks i trosku.</p> <p>- Preporučeni sastav sloja: 4,5%C; 2,5%Si; 23,0%Cr; 5,0%Mo; 5,0%Nb; 3,5%W, 1,0%V.</p> <p>17.3 <u>Dimenzije obradka</u>: - velike dimenzije. 17.4 <u>Masa obradka</u> - velike mase.</p> <p>18. Fotografija mikrostrukture - Primjer primjene</p>  <p>Slika P2.19. Primjer primjene navarenih slojeva s visokim udjelom karbida [60]</p>
6.3 NAVARENI SLOJEVI OTPORNI KOROZIJI [49,59,60]	
<p>1. Zahtjev za primjenom - Od strojnog dijela zahtijeva se visoka čvrstoća i visoka otpornost koroziji nekih dijelova izloženih agresivnim medijima, - Površine prevlaka su velike, - Skupa primjena antikorozivnih čelika zbog mase, - Sloj mora biti nepropusan, - Obradak na kojemu se nanosi sloj najčešće je poluproizvod.</p> <p>2. Definicija postupka Navarivanje je postupak prekrivanja površine materijala postupkom zavarivanja pri čemu se kod starih obradaka površina reparira, a kod novih obradaka navarivanjem nastaje nova površina željenih svojstava.</p> <p>3. Karakteristike i shema postupka Kod navarivanja uslijed usmjerenog upravljanja toplinom dolazi do lokacijski ograničenog rastaljivanja nosivog materijala, čime se stvara čvrsta veza između sloja i nosivog materijala</p>	<p>10.3 <u>Elektrolučno-plazma</u> - ne.</p> <p>11. Praktične debljine slojeva - 10 mm.</p> <p>12. Promjena dimenzija i oblika obradka - promjena dimenzija: - visoka - promjena oblika: - vsoka. - <u>Napomena</u>: - promjena dimenzija nije toliko važna jer se većina obradaka sa antikorozivnim slojem naknadno mehanički može obraditi postupcima odvajanja čestica.</p> <p>13. Naknadna obrada sloja 13.1 <u>Toplinska</u> - žarenje za uklanjanje unutarnjih napetosti. 13.2 <u>Mehanička</u> - tokarenje, glodanje, brušenje.</p> <p>14. Ravnomjernost debljine površinskog sloja i održanje konture sloja - srednja.</p> <p>15. Otpornost trošenju sloja - <u>Općenito</u>: - niska.</p>

čvrsta veza između sloja i nosivog materijala. Najčešće primjenjivani materijali za zaštitu od trošenja su na bazi željeza, kobalta, nikla, a kao tvrdi materijali pretežito se primjenjuju karbidi (krom-karbidi, volframovi karbidi te niobijevi i vanadijevi karbidi), ali i silicidi, boridi i nitridi koji su uloženi u matricu. Za zaštitu od korozije osim čistih metala primjenjuju se legure otporne na koroziju. Postupci koji se primjenjuju su kao i kod

zavarivanja: elektrolučno, pod praškom, pod troskom, TIG/MIG/MAG, elektrolučno u plazmi.

4. Zahtjevi uvjetovani konstrukcijom obradka

-površine kao što su ivice i kutevi moraju biti dostupne plameniku s kojim se navarivanje obavlja,
-površine obradka koje se obrađuju moraju biti u vodoravnom položaju,
-za velike obradke potrebne su naprave za navarivanje.

5. Troškovi

5.1 Cijena postupka

-niska.

5.2 Cijena u odnosu na druge postupke

5.3 Investicijski troškovi

6. Materijali obradka

6.1 Legure na bazi Fe

-Čelici: konstrukcijski.

7. Materijali-Struktura sloja

-Korozijsko postojani čelici: -austenitni, austenitno-feritni (duplex),
-Legure na bazi Ni,
-Superlegure na bazi Co i Ni.

8. Poželjna toplinska obradba obradka prije modifikiranja

-normalizacija, žarenje, poboljšavanje,

-preporuka: poboljšavanje.

9. Poželjno stanje površine obradka prije modifikiranja

9.1 Hrapavost površine

9.2 Čišćenje površine

-odmašćivanje.

10. Varijante procesa

10.1 Strujno

-veliki dijelovi: EPP, EPT.

10.2 Elektrolučno

-ne.

-Napomena: -ako se pored zahtjeva na koroziju postavlja i zahtjev na otpornost trošenju u predizbor ulaze čelici istodobno otporni koroziji i trošenju.

16. Ostala svojstva sloja

16.1 Korozija: -visoka:- od slojeva na bazi nikla i kobalta u vrućim plinovima.

16.2 Mehanička: -tvrdoća: 180 – 190HB.

-dinamička izdržljivost: niska,

-žilavost: visoka,

-savojna čvrstoća: niska,

-otpornost stvaranju pukotina:niska,

osim austenitnih i slojeva na bazi nikla.

16.3 Tehnološka: -obradljivost: visoka,

-zavarljivost: visoka.

16.4 Toplinska: -postojanost: 400 °C.

17. Primjena slojeva

17.1 Područje primjene

-prehrambena industrija, industrija papira, industrija tekstila, industrija umjetnih vlakana, procesno-kemijska industrija, petrokemijska industrija, brodogradnja.

17.2 Praktične primjene

-tlačni spremnici, kućanski aparati, uređaji u mljekarnama i pivovarima, dijelovi izloženi morskim utjecajima.

-Preporučeni sastav sloja: <15%C; >18%Cr; >8%Ni; 0,2-0,4%N.

17.3 Dimenzije obradka: -velike dimenzije.

17.4 Masa obradka -velike mase.

18. Fotografija mikrostrukture - Primjer primjene

6.4 NAVARENI SLOJEVI OTPORNI KOROZIJI I TROŠENJU [49,59,60]

1. Zahtjev za primjenom

-Od strojnog dijela zahtijeva se istovremeno visoka otpornost trošenju (abrazija, erozija) i koroziji

nekih dijelova izloženih agresivnim medijima,

-Površine prevlaka su velike,

-Skupa primjena antikorozivnih čelika zbog mase,

-Obradak na kojeg se nanosi sloj najčešće je poluproizvod.

2. Definicija postupka

Navarivanje je postupak prekrivanja površine materijala postupkom zavarivanja pri čemu se kod starih obradaka površina reparira, a kod novih obradaka navarivanjem nastaje nova površina željenih svojstava.

3. Karakteristike i shema postupka

Kod navarivanja uslijed usmjerenog upravljanja toplinom dolazi do lokacijski ograničenog

10. Varijante procesa

10.1 Strujno

-veliki dijelovi: EPP, EPT,

-nedostatak – visok stupanj miješanja materijala sloja i obradka (velika snaga EPP/EPT postupka), zbog čega se smanjuje otpornost trošenju, te je potrebno višeslojno navarivanje.

10.2 Elektrolučno

-ne.

10.3 Elektrolučno-plazma

-ne.

11. Praktične debljine slojeva

-0,5 –4 mm.

12. Promjena dimenzija i oblika obradka

-promjena dimenzija: -visoka

-promjena oblika: -visoka.

-s obzirom na varijantu: -prvenstveno treba primjenjivati postupke navarivanja s visokom gustoćom energije, kod kojih je unos topline u obradak razmjerno malen (npr. plazma).

13. Naknadna obrada sloja

<p>rastaljivanja nosivog materijala, čime se stvara čvrsta veza između sloja i nosivog materijala. Najčešće primjenjivani materijali za zaštitu od trošenja su na bazi željeza, kobalta, nikla, a kao tvrdi materijali pretežito se primjenjuju karbidi (krom-karbidi, volframovi karbidi te niobijevi i vanadijevi karbidi), ali i silicidi, boridi i nitridi koji su uloženi u matricu. Za zaštitu od korozije osim čistih metala primjenjuuu se legure otporne na koroziju. Postupci koji se primjenjuju su kao i kod zavarivanja: elektrolučno, pod praškom, pod troskom, TIG/MIG/MAG, elektrolučno u plazmi.</p> <p>4. <u>Zahtjevi uvjetovani konstrukcijom obradka</u> -površine kao što su ivice i kutevi moraju biti dostupne plameniku s kojim se navarivanje obavlja, -površine obradka koje se obrađuju moraju biti u vodoravnom položaju, -za velike obradke potrebne su naprave za navarivanje.</p> <p>5. <u>Troškovi</u> 5.1 <u>Cijena postupka</u> -niska: -ručni postupci elektrodom ili plamenom, -visoka: -TIG, plazma. 5.2 <u>Cijena u odnosu na druge postupke</u> 5.3 <u>Investicijski troškovi</u></p> <p>6. <u>Materijali obradka</u> 6.1 <u>Legure na bazi Fe</u> -Čelici: konstrukcijski. -Preporuka: Cr-Ni čelici, zbog izvrsne otpornosti na trošenje -Napomena: materijal treba biti stabiliziran Ti, Mo zbog sprečavanja pada otpornosti u ZUT-u.</p> <p>7. <u>Materijali-Struktura sloja</u> -Naziv -Legure na bazi Co (Steliti), -Kemijski sastav: 2,5%C, 13%W, 33%Cr. -Udio karbida: -Legure na bazi Ni (Ni-Cr-B-Si).</p> <p>8. <u>Poželjna toplinska obradba obradka prije modifikiranja</u> -nije potrebna.</p> <p>9. <u>Poželjno stanje površine obradka prije modifikiranja</u> 9.1 <u>Hrapavost površine</u> 9.2 <u>Čišćenje površine</u> -odmaščivanje.</p>	<p>13.1 <u>Toplinska</u> -popuštanje. 13.2 <u>Mehanička</u> -tokarenje, godanje, brušenje.</p> <p>14. <u>Ravnomjernost debljine površinskog sloja i održanje konture sloja</u> -srednja.</p> <p>15. <u>Otpornost trošenju sloja</u> -Općenito: -visoka. -Napomena: -otpornost trošenju je viša nego kod zakaljenih čelika.</p> <p>16. <u>Ostala svojstva sloja</u> 16.1 <u>Korozija</u>: -visoka. 16.2 <u>Mehanička</u>: -tvrdoća: 700 – 740HV. -dinamička izdržljivost: niska, -žilavost: niska, -savojna čvrstoća: niska, -otpornost stvaranju pukotina-niska kod visokih iznosa tvrdoća (> 55 HRC).</p> <p>16.3 <u>Tehnološka</u>: -obradljivost: niska, -zavarljivost: visoka. 16.4 <u>Toplinska</u>: -postojanost: visoka, -otpornost promjeni temperature: visoka.</p> <p>17. <u>Primjena slojeva</u> 17.1 <u>Područje primjene</u> -industrija parnih turbina, industrija motora.</p> <p>17.2 <u>Praktične primjene</u> -zaštita ulaznog brida rotorskih lopatica, zaštita dosjednih površina ventila motora. 17.3 <u>Dimenzije obradka</u>: -velike dimenzije. 17.4 <u>Masa obradka</u> -velike mase.</p> <p>18. <u>Fotografija mikrostrukture - Primjer primjene</u></p>
--	---

CURRICULUM VITAE

DRAGUTIN LISJAK was born on 28th November 1962 in Čakovec, where he finished primary school. Secondary school education completed in Zagreb. Graduated at the Faculty of Mechanical Engineering and Naval Architecture in Zagreb, Department of Materials, in 1989. By the year 1991 worked with the company "Končar-Alati i strojevi", as a manufacturing technologist for aluminium die casting moulds. In the same year started working as a junior researcher in Department of Materials. His masters' degree gained by presenting the work titled "Development of abrasion wear expert system", at the Faculty of Mechanical Engineering and Naval Architecture in Zagreb, in 1998. Currently holds the position of an assistant lecturer. Participates a scientific project titled "Computer simulations and development of materials", supervised by Prof. Tomislav Filetin. Manages two projects dealing with informatical technologies, titled: "Identification of steels using their chemical composition and standard designation" and "Identification of aluminium and aluminium alloys using their chemical composition and standard designation." He is a member of Croatian Association for Materials and Tribology, Croatian Welding Association, American Materials Society and American Association for Interfacial Intelligence. Profound in English language, both written and spoken, good in German language. Married, father to two sons.