



УНИВЕРЗИТЕТ У НОВОМ САДУ
ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА У
НОВОМ САДУ



Бојана Бајић

**МОДЕЛ ЗА РАНО ОТКРИВАЊЕ
НЕУСАГЛАШЕНОСТИ ПРОЦЕСНИХ
ПАРАМЕТАРА У ПРОИЗВОДНИМ
СИСТЕМИМА**

ДОКТОРСКА ДИСЕРТАЦИЈА

Нови Сад, 2021



КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА

Редни број, РБР:			
Идентификациони број, ИБР:			
Тип документације, ТД:	Монографска документација		
Тип записа, ТЗ:	Текстуални штампани материјал		
Врста рада, ВР:	Докторска дисертација		
Аутор, АУ:	Бојана Бајић		
Ментор, МН:	Проф. др Александар Рикаловић, ванредни професор		
Наслов рада, НР:	Модел за рано откривање неусаглашености процесних параметара у производним системима		
Језик публикације, ЈП:	Српски		
Језик извода, ЈИ:	Српски		
Земља публиковања, ЗП:	Република Србија		
Уже географско подручје, УГП:	Војводина		
Година, ГО:	2021		
Издавач, ИЗ:	Факултет техничких наука, Универзитет у Новом Саду		
Место и адреса, МА:	Нови Сад, Трг Доситеја Обрадовића 6		
Физички опис рада, ФО: (поглавља/страна/цитата/табела/спика/графика/прилога)	8/242/250/26/119/7/0		
Научна област, НО:	Индустријско инжењерство и инжењерски менаџмент		
Научна дисциплина, НД:	Производни системи, организација и менаџмент		
Предметна одредница/Кључне речи, ПО:	Неусаглашеност процесних параметара, аналитика процесних података, машинско учење, напредне статистичке методе.		
УДК			
Чува се, ЧУ:	Библиотеци Факултета техничких наука		
Важна напомена, ВН:			
Извод, ИЗ:	Докторска дисертација се бави развојем концептуалног модела за рано откривање неусаглашености процесних параметара (РОНП) у производним системима. РОНП модел представља хибридни модел базиран на употреби фази експертних система и метода напредне аналитике, чији је развој подељен у седам фаза применом и прилагођавањем методологије проучавања података. Верификација модела је урађена у процесној индустрији за производњу подних облога од винила где је и експериментално потврђена његова применљивост.		
Датум прихватавања теме, ДП:	28.12.2020.		
Датум одбране, ДО:			
Чланови комисије, КО:	Председник:	Проф. др Илија Ђосић, професор емеритус	
	Члан:	Проф. др Дубравко Ђулибрк, редовни професор	
	Члан:	Проф. др Драгослав Словић, редовни професор	
	Члан:	Проф. др Слободан Морача, редовни професор	
	Члан, ментор:	Проф. др Александар Рикаловић, ванредни професор	
		Потпис ментора	



КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА

Accession number, ANO:		
Identification number, INO:		
Document type, DT:	Monographic publication	
Type of record, TR:	Textual material, printed	
Contents code, CC:	Ph. D. thesis	
Author, AU:	Bojana Bajic	
Mentor, MN:	Dr. Aleksandar Rikalovic	
Title, TI:	Model for early detection of non-compliance of process parameters in manufacturing systems	
Language of text, LT:	Serbian	
Language of abstract, LA:	Serbian	
Country of publication, CP:	Republic of Serbia	
Locality of publication, LP:	Vojvodina	
Publication year, PY:	2021	
Publisher, PB:	Faculty of Technical Sciences, University of Novi Sad	
Publication place, PP:	Novi Sad, Trg Dositeja Obradovica 6	
Physical description, PD: (chapters/pages/ref./tables/pictures/graphs/appendices)	8/242/250/26/119/7/0	
Scientific field, SF:	Industrial engineering and management	
Scientific discipline, SD:	Production systems, organization and management	
Subject/Key words, S/KW:	Non-compliance of process parameters, process data analytics, machine learning, advanced statistical methods.	
UC		
Holding data, HD:	Library Faculty of Technical Sciences	
Note, N:		
Abstract, AB:	The Ph. D. thesis deals with the development of a conceptual model for early detection of non-compliance of process parameters in manufacturing systems. The model represents a hybrid model based on the use of fuzzy expert systems and advanced analytics methods. The development of the model is divided into seven phases by applying and adapting the data mining methodology. The verification of the model was done in the process industry for the production of vinyl flooring, where its applicability was experimentally confirmed.	
Accepted by the Scientific Board on, ASB:	28.12.2020.	
Defended on, DE:		
Defended Board, DB:	President:	Prof. Dr. Ilija Cosic, Emeritus Professor
	Member:	Prof. Dr. Dubravko Culibrk, Full Professor
	Member:	Prof. Dr. Dragoslav Slovic, Full Professor
	Member:	Prof. Dr. Slobodan Moraca, Full Professor
Member, Mentor:	Prof. Dr. Aleksandar Rikalovic, Associate Professor	Mentor's sign

SADRŽAJ

<u>1. UVOD</u>	<u>22</u>
1.1. OPIS PROBLEMA	22
1.2. CILJ ISTRAŽIVANJA.....	24
1.3. HIPOTEZE.....	25
1.4. METODE ISTRAŽIVANJA OBRADE PODATAKA	25
1.5. ZNAČAJ I DOPRINOS RADA	26
1.6. PRIKAZ PO POGLAVLJIMA	27
<u>2. TEORETSKE OSNOVE PROIZVODNIH SISTEMA</u>	<u>29</u>
2.1. PROIZVODNJA I PROIZVODNI SISTEMI	29
2.2 ISTORIJSKI RAZVOJ PROIZVODNIH SISTEMA	30
2.2.1. PRVA INDUSTRIJSKA REVOLUCIJA	31
2.2.2. DRUGA INDUSTRIJSKA REVOLUCIJA.....	32
2.2.3. TREĆA INDUSTRIJSKA REVOLUCIJA	32
2.2.4. ČETVRTA INDUSTRIJSKA REVOLUCIJA	33
2.3. UNAPREĐENJA PROIZVODNIH SISTEMA	35
2.3.1. STUDIJE SLUČAJA UNAPREĐENJA PROIZVODNIH SISTEMA	37
2.3.2. IZAZOVI UNAPREĐENJA PROIZVODNIH SISTEMA PRIMENOM INDUSTRIJE 4.0	42
2.3.2.1. Menadžerski izazovi implementacije Industrije 4.0 za unapređenje proizvodnih sistema	43
2.3.2.2. Tehnološki izazovi implementacije Industrije 4.0 za unapređenje proizvodnih sistema	46
2.4. UNAPREĐENJA PROIZVODNIH SISTEMA PRIMENOM ANALITIČKIH METODA	49
<u>3. ANALITIKA PROCESNIH PODATAKA</u>	<u>53</u>
3.1. PROCESNI PODACI U PROIZVODNIM SISTEMIMA.....	53
3.2. TEHNOLOGIJE KOJE OMOGUĆAVAJU PRIMENU METODA NAPREDNE ANALITIKE PROCESNIH PODATAKA U PROIZVODNIM SISTEMIMA	55
3.2.1. INTERNET STVARI KAO TEHNOLOGIJA ZA PRIKUPLJANJE PODATAKA.....	56
3.2.2. CLOUD SISTEMI RAČUNARSKE TEHNOLOGIJE ZA OBRADU VELIKE KOLIČINE PODATAKA.....	57
3.2.3. FOG SISTEMI RAČUNARSKE TEHNOLOGIJE ZA OBRADU SREDNJE KOLIČINE PODATAKA.....	58
3.2.4. EDGE SISTEMI RAČUNARSKE TEHNOLOGIJE ZA OBRADU OGRANIČENE KOLIČINE PODATAKA	59
3.3. METODE NAPREDNE ANALITIKE PROCESNIH PODATAKA U PROIZVODNIM SISTEMIMA	60
3.3.1. NAPREDNE STATISTIČKE METODE	60
3.3.1.1. Regresiona tehnika napredne statističke metode	61
3.3.1.1.1. Višeparametarska linearna regresija	62

3.3.1.2. Klasifikacione tehnike napredne statističke metode	63
3.3.1.2.1. Logistička regresija	64
3.3.1.2.2. Mahalanobis-Taguci sistem	66
3.3.2. METODE MAŠINSKOG UČENJA.....	67
3.3.2.1. Veštačka neuronska mreža	69
3.3.2.1.1. Veštačke neuronske mreže za klasifikaciju	72
3.3.2.1.2. Veštačke neuronske mreže za regresiju.....	72
3.3.2.1.3. Veštačke neuronske mreže za klasterovanje.....	73
3.3.2.2. Potporni vektori.....	74
3.3.2.2.1. Metoda potpornih vektora za klasifikaciju korišćenjem izbalansiranog skupa podataka....	74
3.3.2.2.2. Metoda potpornih vektora za klasifikaciju korišćenjem neizbalansiranog skupa podataka	75
3.3.2.2.3. Metoda potpornih vektora za regresiju	76
3.3.2.3. Slučajna šuma	77
3.3.2.3.1. Slučajna šuma za klasifikaciju	78
3.3.2.3.2. Slučajna šuma za regresiju.....	79
3.3.3. FAZI LOGIKA	80
3.3.3.1. Fazi broj.....	81
3.3.3.2. Fazi sistem zaključivanja.....	83
3.3.3.2.1. Fazifikacija	84
3.3.3.2.2. Baza znanja.....	85
3.3.3.2.3. Defazifikacija.....	86

4. RAZVOJ MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA U PROIZVODNIM SISTEMIMA 89

4.1. METODOLOGIJA RAZVOJA MODELA	89
4.1.1. DESKRIPTIVNA METODA.....	90
4.1.2. METODA SISTEMATSKEGA PREGLEDA LITERATURE.....	90
4.1.3. METODE EKSPERTSKE ANALIZE	91
4.1.4. ANALITIČKA METODA.....	91
4.1.5. METODA EKSPERIMENTA.....	91
4.2. FAZE RAZVOJA MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA U PROIZVODNIM SISTEMIMA	92
4.2.1. FAZA 1: PROCENA TRENTNOG STANJA PROIZVODNOG SISTEMA	94
4.2.1.1. Karakteristike proizvodnog sistema	94
4.2.1.1.1. Delatnost proizvodnog sistema	94
4.2.1.1.2. Karakteristike programa proizvodnje.....	97
4.2.1.2. Funkcija cilja proizvodnog sistema	106
4.2.1.3. Procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara.....	106
4.2.2. FAZA 2: DEFINISANJE PROBLEMA NEUSAGLAŠENOSTI U PROIZVODNOM SISTEMU.....	118
4.2.2.1. Preciziranje vrste neusaglašenosti u proizvodnom sistemu.....	119
4.2.2.2. Određivanje lokacije nastanka neusaglašenosti u proizvodnom sistemu.....	119
4.2.2.3. Određivanje tipa problema neusaglašenosti u proizvodnom sistemu	119
4.2.3. FAZA 3: IDENTIFIKACIJA UTICAJNIH PARAMETARA I PRIKUPLJANJE PODATAKA.....	120
4.2.3.1. Definisanje kriterijuma za identifikaciju uticajnih parametara	121
4.2.3.2. Identifikacija uticajnih parametara	121

4.2.3.3. Dostupnost uticajnih parametara	121
4.2.3.4. Određivanje tipa podataka uticajnih parametara.....	122
4.2.3.5. Prikupljanje podataka uticajnih parametara.....	123
4.2.4. FAZA 4: PRIPREMA I OBRADA PRIKUPLJENIH PODATAKA.....	123
4.2.4.1. Eliminacija nedoslednih, konstantnih i podataka sa šumom	124
4.2.4.2. Dodavanje vrednosti nepotpunim podacima	125
4.2.4.3. Redukcija broja prikupljenih procesnih parametara	126
4.2.4.4. Definisanje zavisnog parametra.....	129
4.2.4.5. Optimizacija i kreiranje precizno odabranog skupa podataka za razvoj matematičkog modela	129
4.2.5. FAZA 5: RAZVOJ MATEMATIČKOG MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA POMOĆU IZABRANE GRUPE PODATAKA	130
4.2.5.1. Metodologija za podelu izabrane grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela	131
4.2.5.2. Odabir metoda i tehnika za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara	133
4.2.5.2.1. Napredne statističke metode.....	133
4.2.5.2.2. Metode mašinskog učenja	135
4.2.5.3. Razvoj matematičkog modela u proizvodnim sistemima pomoću izabrane grupe podataka za razvoj modela i primenom izabrane metode i tehnike napredne analitike.....	136
4.2.6. FAZA 6: TESTIRANJE MATEMATIČKOG MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA.....	136
4.2.6.1. Testiranje matematičkog modela pomoću podataka za testiranje.....	137
4.2.6.2. 2. Procena performansi matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara primenom tehnika testiranja	137
4.2.6.2.1. Tehnike za procenu performansi matematičkog modela na osnovu definisanog klasifikacionog problema.....	139
4.2.6.2.2. Tehnike za procenu performansi matematičkog modela na osnovu definisanog regresionog problema	140
4.2.6.3. Analiza dobijenih rezultata matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara.....	142
4.2.7. FAZA 7: VALIDACIJA MATEMATIČKOG MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA.....	143
4.2.7.1. Rano otkrivanje neusaglašenosti procesnih parametara i procena performansi primenom metoda napredne analitike	145
4.2.7.2. Automatizacija analize procesnih parametara u trenutku njihovog prikupljanja.....	146
5. VERIFIKACIJA MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA U PROIZVODNOM SISTEMU	148
5.1. LOKACIJA ZA EKSPERIMENTALNI RAD	148
5.2. OPREMA KORIŠĆENA ZA EKSPERIMENTALNI RAD	154

5.2.1. INDUSTRIJSKI RAČUNAR.....	154
5.2.2. PERSONALNI RAČUNAR.....	158
5.3. PRIMENA FAZA ZA RAZVOJ MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA U PROIZVODNOM SISTEMU	160
5.3.1. FAZA 1: PROCENA TRENUOTNOG STANJA PROIZVODNOG SISTEMA	160
5.3.1.1. Karakteristike proizvodnog sistema	160
5.3.1.1.1. Delatnost proizvodnog sistema	161
5.3.1.1.2. Karakteristike programa proizvodnje.....	161
5.3.1.2. Funkcija cilja proizvodnog sistema	167
5.3.1.3. Procena stepena spremnosti proizvodnog sistema za razvoj RONP modela	167
5.3.1.4. Rezultati Faze 1	169
5.3.2. FAZA 2: DEFINISANJE PROBLEMA NEUSAGLAŠENOSTI U PROIZVODNOM SISTEMU.....	170
5.3.2.1. Preciziranje vrste neusaglašenosti	171
5.3.2.2. Određivanje lokacije nastanka neusaglašenosti.....	172
5.3.2.3. Određivanje tipa problema neusaglašenosti	172
5.3.2.4. Rezultati Faze 2.....	173
5.3.3. FAZA 3: IDENTIFIKACIJA UTICAJNIH PARAMETARA I PRIKUPLJANJE PODATAKA.....	173
5.3.3.1. Definisanje kriterijuma za identifikaciju uticajnih parametara	173
5.3.3.2. Identifikacija uticajnih parametara	174
5.3.3.3. Dostupnost uticajnih parametara	175
5.3.3.4. Određivanje tipa podataka uticajnih parametara.....	175
5.3.3.5. Prikupljanje podataka uticajnih parametara.....	176
5.3.3.6. Rezultati Faze 3	179
5.3.4. FAZA 4: PRIPREMA I OBRADA PRIKUPLJENIH PODATAKA	180
5.3.4.1. Eliminacija nedoslednih, konstantnih i podataka sa šumom	188
5.3.4.2. Dodavanje vrednosti nepotpunim podacima	189
5.3.4.3. Redukcija broja prikupljenih procesnih parametara	189
5.3.4.4. Definisanje zavisnog parametra.....	190
5.3.4.5. Optimizacija i kreiranje precizno odabranog skupa podataka za razvoj matematičkog modela	191
5.3.4.6. Rezultati Faze 4	192
5.3.5. FAZA 5: RAZVOJ MATEMATIČKOG MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA POMOĆU IZABRANE GRUPE PODATAKA	193
5.3.5.1. Metodologija za podelu izabrane grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela	193
5.3.5.2. Odabir metoda i tehnika za razvoj matematičkog RONP modela.....	194
5.3.5.3. Razvoj matematičkog modela u proizvodnim sistemima pomoću izabrane grupe podataka za razvoj modela i primenom izabrane metode i tehnike napredne analitike.....	195
5.3.5.3.1. Razvoj matematičkog RONP modela primenom MTS tehničke napredne statističke metode	195
5.3.5.3.2. Razvoj matematičkog RONP modela primenom OCSVM tehničke mašinskog učenja.....	196
5.3.5.4. Rezultati Faze 5	197
5.3.6. FAZA 6: TESTIRANJE MATEMATIČKOG MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA.....	198
5.3.6.1. Testiranje matematičkog modela pomoću podataka za testiranje.....	199
5.3.6.2. Procena performansi matematičkog RONP modela primenom tehnika testiranja	199
5.3.6.2.1. Procena performansi matematičkog RONP modela razvijenog primenom MTS tehničke napredne statističke metode	199

5.3.6.2.2. Procena performansi matematičkog RONP modela razvijenog primenom OCSVM tehnike mašinskog učenja	201
5.3.6.3. Analiza dobijenih rezultata matematičkog RONP modela	203
5.3.6.4. Rezultati Faze 6.....	204
5.3.7. FAZA 7: VALIDACIJA MATEMATIČKOG MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA U PROIZVODNOM SISTEMU	204
5.3.7.1. Rano otkrivanje neusaglašenosti procesnih parametara primenom Edge sistema računarske tehnologije i procena performansi validiranog modela primenom MTS tehnike napredne statističke metode	205
5.3.7.2. Automatizacija analize procesnih parametara u trenutku njihovog prikupljanja primenom Edge sistema računarske tehnologije.....	208
5.3.7.3. Rezultati Faze 7	210
<u>6. DISKUSIJA REZULTATA</u>	<u>212</u>
<u>7. ZAKLJUČAK</u>	<u>219</u>
<u>8. LITERATURA</u>	<u>225</u>

LISTA SLIKA

- Slika 1. Osnovni model transformisanja raspoloživih resursa u proizvode
- Slika 2. Tok razvoja industrijske proizvodnje
- Slika 3. Pregled mogućnosti primene metoda i tehnika u odnosu na delove procesa rada
- Slika 4. Brojnost tehnoloških izazova za implementaciju Industrije 4.0 po tehnološkoj kategoriji i generisanje izazova od strane drugih tehnoloških kategorija
- Slika 5. Veza između IoT tehnologije i analitike velikih podataka u okruženju Industrije 4.0
- Slika 6. Arhitektura Cloud, Fog i Edge sistema u proizvodnim sistemima
- Slika 7. Klasifikacija naprednih statističkih metoda
- Slika 8. Višeparametarska linearna regresija
- Slika 9. Logistička regresija
- Slika 10. Primer određivanja Mahalanobisove udaljenosti u dvodimenzionalnom prostoru
- Slika 11. Klasifikacija metoda mašinskog učenja
- Slika 12. Opšta šema učenja primenom ANN tehnike
- Slika 13. Metod nadgledanog učenja primenom ANN tehnike
- Slika 14. Metod nenadgledanog učenja primenom ANN tehnike
- Slika 15. Nelinearni model neurona
- Slika 16. Višeslojna ANN mreža sa jednim skrivenim slojem primenom klasifikacione tehnike
- Slika 17. Višeslojna ANN mreža sa jednim skrivenim slojem primenom regresione tehnike
- Slika 18. Višeslojna ANN mreža sa jednim skrivenim slojem primenom tehnike klasterovanja

- Slika 19. SVM metoda klasifikacije izbalansiranog skupa podataka: a) neoptimalne hiper-ravni i b) optimalna hiper-ravan
- Slika 20. OCSVM metoda klasifikacije neizbalansiranog skupa podataka
- Slika 21. SVR metoda regresije
- Slika 22. Metodologija klasifikacije primenom RF tehnike mašinskog učenja
- Slika 23. Metodologija regresije primenom RF tehnike mašinskog učenja
- Slika 24. Trougaoni fazi broj
- Slika 25. Trapezoidni fazi broj
- Slika 26. Gausov fazi broj
- Slika 27. Fazi sistem zaključivanja
- Slika 28. Fazifikacija ulaznih veličina preko trapezoidnih pripadajućih funkcija
- Slika 29. Mamdani fazi sistem zaključivanja – kreiranje baze znanja
- Slika 30. Defazifikacija izlaznih veličina koristeći centoid metode
- Slika 31. Mamdani metod fazi zaključivanja
- Slika 32. Trougaone pripadajuće funkcije izlaznih vrednosti kod Mamdani metoda zaključivanja
- Slika 33. Sugeno metod fazi zaključivanja
- Slika 34. Algoritam razvoja konceptualnog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima
- Slika 35. Osnovna područja zavisnosti struktura/količine
- Slika 36. Stuktura programa proizvodnje sa stanovišta učestalosti izmena
- Slika 37. Odnos struktura/količine kod pojedinačnog zahteva potrošača
- Slika 38. Odnos struktura/količine kod serijskih zahteva potrošača
- Slika 39. Odnos struktura/količine kod grupnih zahteva potrošača
- Slika 40. Odnos struktura/količine kod masovnih zahteva potrošača
- Slika 41. Raspodela dimenzija za dve grupe proizvoda datog programa proizvodnje
- Slika 42. Raspodela broja mašina prilikom proizvodnje datog proizvodnog programa
- Slika 43. ABC analiza relativnog učešća proizvoda u programu proizvodnje

- Slika 44. Razvoj RONP modela sa svrhom ostvarenja ciljeva kompanije
- Slika 45. Pripadajuće funkcije za kriterijum „strategija kompanije“
- Slika 46. Pripadajuće funkcije za kriterijum „ljudski resursi“
- Slika 47. Pripadajuće funkcije za kriterijum „podaci“
- Slika 48. Pripadajuće funkcije za kriterijum „nivo automatizacije“
- Slika 49. Pripadajuće funkcije za kriterijum „napredne tehnologije“
- Slika 50. Pripadajuće funkcije za kriterijum „upravljački pristupi“
- Slika 51. Pripadajuće funkcije za izlaznu vrednost „stepen spremnosti“
- Slika 52. Matrični prikaz pravilno struktuirane tabelarne forme sa spojenim nezavisnim i zavisnim uticajnim parametrom
- Slika 53. Eliminacija redova ili kolona matrice u zavisnosti tipova podataka uticajnih parametara
- Slika 54. Načini dodavanja vrednosti nepotpunim podacima
- Slika 55. Odabir tehnike za redukciju broja prikupljeni parametara u zavisnosti od cilja analize
- Slika 56. Način definisanja zavisnog parametra
- Slika 57. Način optimizacije i kreiranja precizno posmatranog skupa podataka za razvoj modela
- Slika 58. Postupak razvoja matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara
- Slika 59. Postupak testiranja matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara
- Slika 60. Matrica konfuzije
- Slika 61. Postupak validacije matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u industrijskom okruženju
- Slika 62. Postupak ranog otkrivanja neusaglašenosti procesnih parametara u proizvodnom sistemu
- Slika 63. Postupak slanja povratne informacije (označene narandžastom bojom) u proizvodnom sistemu
- Slika 64. Proizvodna linija posmatranog proizvodnog sistema grupisana u klastere

- Slika 65. Dvodimenzionalni prikaz mašine P1
- Slika 66. Dvodimenzionalni prikaz mašine P2
- Slika 67. Dvodimenzionalni prikaz mašine za štampu
- Slika 68. Dvodimenzionalni prikaz mašine P3
- Slika 69. Dvodimenzionalni prikaz mašine P4
- Slika 70. Dvodimenzionalni prikaz mašine P5
- Slika 71. Dvodimenzionalni prikaz mašine kanala
- Slika 72. Dvodimenzionalni prikaz mašine P6
- Slika 73. Dvodimenzionalni prikaz mašine za pregovanje
- Slika 74. Dvodimenzionalni prikaz UV mašine
- Slika 75. Dvodimenzionalni prikaz mašine za poleđinsku štampu
- Slika 76. Dvodimenzionalni prikaz mašine za krojenje finalnog proizvoda
- Slika 77. Industrijski računar MELIPC MI5000 zasnovan na Edge sistemu računarske tehnologije
- Slika 78. Softver Real-rime Flow Designer, MELIPC 5000, Edge sistem računarske tehnologije
- Slika 79. Softver Real-rime Statistics Diagnosis Tool, MELIPC 5000, Edge sistem računarske tehnologije
- Slika 80. Postupak rada industrijskog računara MELIPC MI5000
- Slika 81. Personalni računar DELL Inspiron 15 5000
- Slika 82. Jupyter Notebook veb aplikacija
- Slika 83. Procenjeni stepen spremnosti proizvodnog sistema primenom fazi ekspertnog sistema
- Slika 84. Šifrarnik grešaka proizvodnog sistema za proizvodnju podnih obloga od vinila
- Slika 85. Etape prikupljanja podataka pomoću Real-time Flow Designer softvera, MELIPC MI5000

- Slika 86. Vremenski interval između zapisivanja uzorka prikupljenih podataka pomoću Real-time Flow Designer softvera, MELIPC MI5000
- Slika 87. Definisanje situacija kada je potrebno da se prikupljaju podaci, odnosno vrednosti uticajnih procesnih parametara pomoću Real-time Flow Designer softvera, MELIPC MI5000
- Slika 88. Generisanje .csv fajlova sa vrednostima uticajnih procesnih parametara pomoću Real-time Flow Designer softvera, MELIPC MI5000
- Slika 89. Vizuelni prikaz uticajnog parametra Zazor_GV2_desna
- Slika 90. Vizuelni prikaz uticajnog parametra Zazor_GV2_leva
- Slika 91. Vizuelni prikaz uticajnog parametra Temperatura_GV2
- Slika 92. Vizuelni prikaz uticajnog parametra Temperatura_B2
- Slika 93. Vizuelni prikaz uticajnog parametra Temperatura_OV2
- Slika 94. Vizuelni prikaz uticajnog parametra Temperatura_PB2
- Slika 95. Vizuelni prikaz uticajnog parametra THB2D
- Slika 96. Vizuelni prikaz uticajnog parametra THB2G
- Slika 97. Vizuelni prikaz uticajnog parametra KorPendPosleB2
- Slika 98. Vizuelni prikaz uticajnog parametra KorPendPreB2
- Slika 99. Vizuelni prikaz uticajnog parametra LineSpeed
- Slika 100. Vizuelni prikaz uticajnog parametra LineStopped
- Slika 101. Vizuelni prikaz uticajnog parametra ViskP2
- Slika 102. Vizuelni prikaz uticajnog parametra PHR_P2
- Slika 103. Vizuelni prikaz uticajnog parametra Saum
- Slika 104. Rezultat korelace analize urađen pomoću Real-time Statistics Diagnosis Tool softvera, MELIPC MI5000
- Slika 105. Definisanje zavisnog parametra na osnovu informacija o lošem kvalitetu finalnog proizvoda u periodu od 28. avgusta do 29. septembra 2020. godine
- Slika 106. Optimizacija .csv fajlova korišćenjem statističke metode Opseg za kreiranje jednog jedinstvenog .csv fajla
- Slika 107. Podela izabrane grupe podataka na podatke za razvoj modela i podatke za testiranje matematičkog modela primenom odnosa 80/20

- Slika 108. Rezultati Mahalanobisove udaljenosti razvijenog matematičkog RONP modela primenom MTS tehnike napredne statističke metode
- Slika 109. Vizuelni prikaz rezultata Mahalanobisove udaljenosti razvijenog matematičkog RONP modela primenom MTS tehnike napredne statističke metode
- Slika 110. Rezultat razvijenog matematičkog RONP modela primenom OCSVM tehnike mašinskog učenja sa prikazom definisanih parametara
- Slika 111. Rezultati Mahalanobisove udaljenosti testiranog matematičkog RONP modela primenom MTS tehnike napredne statističke metode
- Slika 112. Vizuelni prikaz odstupanja analiziranih vrednosti od definisane granične vrednosti Mahalanobisove udaljenosti postavljenje na 4
- Slika 113. Rezultat testiranog matematičkog RONP modela primenom OCSVM tehnike mašinsnog učenja sa prikazom definisanih parametara
- Slika 114. Detektovane neusaglašenosti procesih parametara primenom razvijenog modela MTS tehnike napredne statističke metode
- Slika 115. Iskakajući prozor kao upozorenje o ranoj neusaglašenosti procesnih parametara odgovornih za nastanak proizvoda lošeg i nedovoljno dobrog kvaliteta
- Slika 116. Dva registrovana proizvoda lošeg ili nedovoljno dobrog kvaliteta od strane posmatranog proizvodnog sistema
- Slika 117. Definisani parametar Feedback binarnog tipa
- Slika 118. Promenjena i zabeležena nova vrednost parametra Feedback na osnovu matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u posmatranom proizvodnom sistemu
- Slika 119. Automatizovana analiza ranog otkrivanja neusaglašenosti procesnih parametara u posmatranom proizvodnom sistemu

LISTA TABELA

- Tabela 1. Faze pretrage radova i kriterijumi za njihov odabir
- Tabela 2. Spisak oblasti prerađivačke industrije
- Tabela 3. Određivanje grupe proizvoda na osnovu određene oblasti prerađivačke industrije
- Tabela 4. Kriterijumi za razvoj fazi ekspertnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara
- Tabela 5. Pravila za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara
- Tabela 6. Vrednosti koeficijenta korelacione analize
- Tabela 7. Rastojanja mašina, grupisanih u klastere, u odnosu na ulaz linije proizvodnog sistema
- Tabela 8. Specifikacije industrijskog računara MELIPC MI5000
- Tabela 9. Specifikacije personalnog računara DELL Inspiron 15 5000
- Tabela 10. Delatnost odabranog proizvodnog sistema procesne industrije
- Tabela 11. Prikaz svih proizvoda sa mesečnim količinama i ukupnom godišnjom količinom izraženim u [m²]
- Tabela 12. Sumirane vrednosti za dve definisane grupe proizvoda
- Tabela 13. Dobijene vrednosti kriterijuma za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara primenom metode intervjuja eksperata iz proizvodnog sistema
- Tabela 14. Sumirani rezultati Faze 1
- Tabela 15. Sumirani rezultati Faze 2
- Tabela 16. Definisana grupe proizvoda na osnovu sličnosti tolerancija procesnih parametara
- Tabela 17. Definisani uticajni procesni parametri
- Tabela 18. Određeni tipovi svih uticajnih procesnih parametara

Tabela 19. Sumirani rezultati Faze 3

Tabela 20. Sumirani rezultati Faze 4

Tabela 21. Sumirani rezultati Faze 5

Tabela 22. Matrica konfuzije dobijena na osnovu rezulatata testiranog matematičkog RONP modela primenom MTS tehnike

Tabela 23. Matrica konfuzije dobijena na osnovu rezulatata testiranog matematičkog RONP modela primenom OCSVM tehnike

Tabela 24. Komparativna analiza rezultata razvijenog i testiranog matematičkog RONP modela u proizvodnom sistemu

Tabela 25. Sumirani rezultati Faze 6

Tabela 26. Sumirani rezultati Faze 7

LISTA GRAFIKA

- Grafik 1. Broj prijavljenih menadžerskih izazova implementacije Industrije 4.0 po godinama podeljenih na: (a) izazove sveobuhvatne implementacije Industrije 4.0 i (b) izazove implementacije za primenu definisane tehnološke kategorije Industrije 4.0
- Grafik 2. Nelinearna funkcija na primeru kriterijuma „nivo automatizacije“ i „napredne tehnologije“
- Grafik 3. Program proizvodnje prema količinama na godišnjem nivou posmatranog proizvodnog sistema
- Grafik 4. Količine proizvoda na godišnjem nivou za dve grupe proizvoda
- Grafik 5. Analiza struktura delova proizvodnog programa po osnovnim dimenzijama (širina proizvoda/rolne)
- Grafik 6. Analiza struktura delova proizvodnog programa po složenosti proizvoda
- Grafik 7. ABC dijagram količina proizvoda posmatranog proizvodnog sistema na godišnjem nivou

PREDGOVOR

Tokom perioda trajanja doktorskih studija, imala sam priliku da upoznam ljude koje su uticali na razvoj moje ličnosti u naučnoj karijeri. Zahvalnost za to dugujem:

- ◆ svom mentoru, prof. dr Aleksandru Rikaloviću, koji me je svojom ogromnom podrškom, savetima i usmeravanjima vodio tokom celog procesa učenja i rada na doktorskoj disertaciji. Zahvalna sam mu što bi me svaki put demantovao kada sam smatrala neke stvari nemogućim, navodio na smer rešavanja problema – ne pristajući na odustajanje i podsticao da sama dođem do rešenja i realizujem ih na najbolji mogući način;
- ◆ dr Nikoli Suziću na ukazanoj ljudskosti, nesebičnom prenošenju znanja, kao i na svim konstruktivnim kritikama, koje su oformile moj način razmišljanja i delovanja, kako u naučnom, tako i u privatnom životu;
- ◆ članovima komisije –prof. emeritusu dr Iliji Čosiću, prof. dr Dubravku Ćulibrku, prof. dr Dragoslavu Sloviću i prof. dr Slobodanu Morači na ukazanom poverenju pristavši da budu članovi komisije;
- ◆ ekspertima iz proizvodnog sistema za izradu podnih obloga, Radošu Trivunu, Predragu Nježiću i Dejanu Čokiću, na saradnji i pomoći prilikom izrade eksperimentalnog dela doktorske disertacije;
- ◆ svojim roditeljima, Milici i Milošu Nikoliću, kao i bratu Milanu na neizmernoj podršci i pomoći oko svakodnevnih životnih aktivnosti tokom čitavog perioda školovanja radi izrade ove doktorske disertacije; i
- ◆ svojoj porodici, suprugu Kostu i sinu Vasiliju, koji su me čekali, razumeli, voleli i pomagali (ali i odmagali – *Vasilije, ovo se odnosi pretežno na tebe, sine!*) bez kojih ovaj period mog života ne bi imao smisla.

Ova doktorska disertacija treba da bude podstrek i podsetnik Vasiliju da uvek može više i da uvek može bolje bez obzira na životne okolnosti. Zato ovaj doktorat posvećujem njemu!

Novi Sad, 2021.
Bojana Bajić

APSTRAKT

Proizvodni sistemi predstavljaju složene dinamične sisteme koji čine skup osnovnih tehnoloških, tehničkih, informacionih i energetskih struktura obezbeđujući vršenje definisanog cilja i ostvarenja projektovanih efekata. Razvoj proizvodnih sistema je uslovjen „*sposobnošću predviđanja novih događaja, brzinom usvajanja novih tehnoloških i tehničkih rešenja, kvalitetom postupaka promene stanja, oblikovanja elemenata sistema i relacija između njih i njihovih karakteristika, kvalitetom organizovanja sistema i kvalitetom upravljanja postupcima promene stanja*”¹. U današnje vreme napretka informacionih i komunikacionih tehnologija, da bi se proizvodni sistemi razvijali neophodno je izvođenje istraživačko – razvojnih aktivnosti koje za cilj imaju postizanje i dobijanje procesa koji će imati karakteristike konkurentnosti na tržištu, a samim tim i obezbediti dalji razvoj kako privrednih tako i društvenih delatnosti.

Nedavno je četvrta industrijska revolucija, nazvana Industrija 4.0, postala jedna od glavnih istraživačko – razvojnih tema kako industrije tako i akademije iz oblasti industrijskog inženjerstva i menadžmenta. Industrija 4.0 predstavlja koncept nastao krajem 2011. godine kako bi se promovisala nova strategija razvoja industrije zasnovana na naprednim tehnologijama. Napredne tehnologije (sajber-fizički sistemi, Internet stvari, analitika velikih podataka, itd.), kao sastavni deo koncepta Industrije 4.0, transformišu različite sektore, posebno proizvodni, nudeći veću efikasnost, kao i inovativna rešenja. Sve je to omogućeno zbog dostupnosti velike količine procesnih podataka (*Big Data*) pomoću kojih se postiže precizniji nivo odlučivanja na osnovu dobijenih informacija.

Velike količine neobrađenih procesnih podataka sa sobom donose i stvaraju nove složenije izazove u proizvodnji. Jedan od najprisutnijih problema jeste njihova obrada i analiza. Obrada i analiza velikih podataka u proizvodnim sistemima je teško izvodljiva pomoću postojećih softverskih aplikacija i korišćenjem personalnih računara zbog nedovoljno velike računarske snage. Stoga, neophodna je primena novih tehnologija računarstva, kao što su *Cloud*, *Fog* ili *Edge* sistemi računarske tehnologije, koji se oslanjaju na metode napredne analitike (napredna statističke metode, metode mašinskog učenja i fazi logika) za obradu i analizu podataka.

Pored problema obrade i analize podataka, zbog trenutnog trenda i zahteva tržišta smanjuju se veličine serija masovne proizvodnje i povećava se broj proizvoda prilagođenih

¹ [3] D. Zelenović, Projektovanje proizvodnih sistema, 3. izdanje. Fakultet tehničkih nauka u Novom Sadu, 2003

potrebama pojedinačnih kupaca. Takav trend u proizvodnim sistemima dovodi do stalnog menjanja procesnih parametara, a čestim menjanjem vrednosti procesnih parametara dolazi do njihove neusaglašenosti. U takvim situacijama je od presudnog značaja ostvariti rano otkrivanje neusaglašenosti procesnih parametara nastalih u proizvodnim sistemima.

Rano otkrivanje neusaglašenosti procesnih parametara je omogućeno analizom procensih podataka u trenutku njihovog prikupljanja ili u vremenu približnom tom trenutku. Analiza podataka u trenutku njihovog prikupljanja (ili u približnom trenutku) zasniva se na principima metoda napredne analitike oslanjajući se na dostupne procesne podatke. Ova doktorska disertacija je fokusirana upravo na problematiku analize procesnih podataka u trenutku njihovog prikupljanja, gde je stavljen naglasak na rano otkrivanje neusaglašenosti procesnih parametara sa svrhom unapređenja proizvodnih sistema, procesa i kvaliteta proizvoda.

Zbog složenosti problema unapređenja proizvodnih sistema, procesa i kvaliteta proizvoda pomoću dostupnih procesnih podataka sa ciljem ranog otkrivanje neusaglašenosti procesnih parametara razvijen je konceptualni model koji je potom verifikovan u industrijskom okruženju. Konceptualni model za rano otkrivanje neusaglašenosti procesnih parametara (RONP), razvijen u ovoj doktorskoj disertaciji, pruža kvalitativne opise pomažući da se istaknu sve veze koje postoje u proizvodnim uslovima procesne industrije. RONP model predstavlja hibridni model baziran na upotrebi fazi ekspertnih sistema i metoda napredne analitike, čiji je razvoj podeljen u sedam faza:

- Faza 1: Procena trenutnog stanja proizvodnog sistema;
- Faza 2: Definisanje problema neusaglašenosti u proizvodnim sistemima;
- Faza 3: Identifikacija uticajnih parametara i prikupljanje podataka;
- Faza 4: Priprema i obrada prikupljenih podataka;
- Faza 5: Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka;
- Faza 6: Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara;
- Faza 7: Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara.

Pored razvoja RONP modela, u doktorskoj disertaciji je urađena i njegova verifikacija eksperimentalnom metodom u industrijskom okruženju. Verifikacija je podrazumevala primenu eksperimentalne metode za razvoj RONP modela u odabranom proizvodnom sistemu procesne industrije. Prema razvijenom modelu urađeno je rano otkrivanje neusaglašenosti procesnih parametara. Prva faza je pokazala da je odabrani proizvodni sistem podoban za sprovođenje narednih faza modela. U drugoj fazi definisan je problem neusaglašenosti procesnih parametara koji dovodi do nedovoljno dobrog kvaliteta proizvoda u proizvodnom sistemu, nakon čega je u trećoj fazi usledila identifikacija i prikupljanje procesnih podataka. Zatim se u

četvrtoj fazi pristupilo detaljnoj pripremi i obradi prikupljenih podataka i formiranju precizno odabranog skupa podataka spremnog za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara. Prilikom razvoja matematičkog modela, kao pete faze RONP modela, korišćene su dve različite metode napredne analitike: *napredna statistička metoda* i *metoda mašinskog učenja* između kojih je izvršena komparativna analiza. S obzirom na činjenicu da odabrani skup procesnih podataka predstavlja neizbalansiran skup, odlučeno je da se primeni tehnika Mahalanobis-Taguči sistem (MTS) kao napredna statistička metoda, dok je za metodu mašinskog učenja odabrana ekvivalentna tehnika MTS tehnički, i to metoda potpornih vektora za klasifikaciju korišćenjem neizbalansiranog skupa podataka (OCSVM). U šestoj fazi, testiranjem matematičkog modela je zaključeno da su performanse razvijenog modela primenom MTS tehnike nadmašile rezultat dobijen primenom OCSVM tehnike. Drugim rečima, dobijeni rezultat ukazuje da, iako je trend da metode mašinskog učenja daju bolje rezultate od naprednih statističkih metoda, napredna statistika ima sve veću primenu za rešavanje konkretnih inženjerskih problema analizom procesnih podataka za otkrivanje i dijagnozu anomalija u proizvodnim sistemima radi njihovog unapređenja. Stoga je odlučeno da se matematički model razvijen primenom MTS tehnike koristi u poslednjoj sedmoj fazi validacije razvoja RONP modela.

Na osnovu dobijenih rezultata tokom faze validacije može se zaključiti da razvijeni matematički model predstavlja efikasan alat za rano otkrivanje neusaglašenosti procesnih parametara koji uslovjavaju nastanak grešaka kvaliteta u vidu finalnih proizvoda koji imaju loš ili nedovoljno dobar kvalitet. Pored ranog otkrivanja neusaglašenosti procesnih parametara, upotreboom razvijenog matematičkog modela MTS tehnike omogućena je automatizovana analiza procesnih parametara u trenutku njihovog prikupljanja koristeći industrijski računar zasnovan na primeni *Edge* sistema računarske tehnologije. Validacijom matematičkog modela u proizvodnom sistemu je potvrđena i njegova fleksibilnost koja se ogleda u prilagođavanju promenama unutar proizvodnog procesa (npr. uvođenje novih tipova proizvoda).

Praktičnom primenom i eksperimentalnom potvrdom RONP modela došlo se do zaključka da je razvijeni model omogućio kreiranje sajber-fizičkog okruženja u posmatranom proizvodnom sistemu gde je izvršeno integrisanje fizičkih komponenti sistema (proizvodnih mašina i računara) i virtuelne komponente (softverskog rešenja za automatizovanu analizu procesnih podataka i SCADA sistema). Integrisanje je omogućeno primenom naprednih tehnologija Industrije 4.0, kao što su Internet stvari, *Edge* sistem računarske tehnologije i metode napredne analitike. To dalje implicira da razvijeni RONP model predstavlja inovativno i univerzalno rešenje koje omogućava realizaciju koncepta Industrije 4.0 u proizvodnim sistemima procesne industrije.

1. UVOD

1.1. Opis problema

Proizvodni sistemi predstavljaju složene dinamične sisteme za ostvarenje ciljeva proizvodnje, odnosno za dobijanje proizvoda neophodnih za zadovoljenje potreba u društvu. Kako su proizvodni sistemi izloženi konstantnom tehničko-tehnološkom i socijalnom dejstvu okoline u kojoj funkcionišu, potrebno je stalno usavršavanje njihovih proizvodnih procesa za zadovoljenje potreba tržišta. Zahtevi tržišta diktiraju trendove u proizvodnim sistemima koji se trenutno ogledaju u smanjenju veličine serija masovne proizvodnje i povećanju broja proizvoda prilagođenih potrebama pojedinačnih kupaca (*mass customization*). Takav trend u proizvodnji neminovno dovodi do promena unutar samih proizvodnih sistema.

Promene u proizvodnim sistemima su praćene nastankom neusaglašenosti procesnih parametara koji ometaju tok proizvodnih procesa. Neusaglašenosti procesnih parametara koji se javljaju u proizvodnim sistemima mogu se definisati kao problemi koji dovode do gubitaka u preduzeću. Ovi gubici mogu biti vezani za nastanak proizvoda lošeg kvaliteta (škarta); kratkih ili potpunih zastojima mašina; otkaza mašina ili lomova pojedinih njenih delova mašina, itd.

Danas, gubici ne predstavljaju isključivo fizički vidljive probleme u proizvodnim sistemima, već i gubitke u vidu neiskorišćenja podataka, čije je prikupljanje počelo brzim razvojem informaciono-komunikacionih tehnologija i digitalnom transformacijom industrije. Prikupljanje neobrađenih procesnih podataka predstavlja uobičajen proces unutar proizvodnih sistema, gde se podaci čuvaju duži vremenski period u bazama podataka. Zbog ovako dugog perioda čuvanja podataka, baze postaju pretrpane velikim količinama neiskorišćenih podataka, odnosno podacima koji se nisu upotrebili u svrhu dobijanja informacija sa ciljem unapređenja proizvodnih sistema. Stoga, ovi neiskorišćeni podaci mogu biti okarakterisani kao gubici unutar proizvodnih sistema, čiji potencijal nije na vreme prepoznat i upotrebljen kao izvor informacija za eliminisanje gubitaka. Eliminisanje gubitaka se postiže primenom analitičke obrade procesnih podataka koji dovodi do unapređenja kvaliteta proizvoda, proizvodnih procesa i sistema u celini.

Klasične metode analitike podataka više ne daju zadovoljavajuće rezultate prilikom unapređenja proizvodnih sistema. Unapređenje proizvodnih sistema zahteva upotrebu novih prilaza baziranih na analitičkoj obradi procesnih podataka. Novi prilazi analitičke obrade procesnih podataka predstavljaju primenu metoda napredne analitike. Trenutno u eri digitalne transformacije industrije sve je češća upotreba metoda napredne analitike u proizvodnim sistemima. Cilj upotrebe metoda napredne analitike u proizvodnim sistemima jeste proaktivni i prediktivni način delovanja unutar proizvodnih sistema. Proaktivni i prediktivni način

delovanja u proizvodnim sistemima omogućava rano otkrivanje neusaglašenosti procesnih parametara na osnovu prikupljenih procesnih podataka, gde se pod „*ranim otkrivanjem neusaglašenosti*“ podrazumeva detektovanje neusklađenosti procesnih parametara u trenutku njenog nastanka ili u vremenu približnom tom trenutku.

Međutim, da bi se izvršilo unapređenje proizvodnih sistema primenom metoda napredne analitike sa ciljem ranog otkrivanja neusaglašenosti procesnih parametara, važno je ostvariti saradnju i konstantnu komunikaciju između eksperata (inženjera), koji poznaju način funkcionisanja proizvodnog procesa, i akademske zajednice (naučnika i istraživača) koji bi primenili metode napredne analitike u tom proizvodnom sistemu. Zbog složenosti proizvodnih sistema i proizvodnih procesa, prvi problem na koji se nailazi prilikom ostvarivanja saradnje jeste nedovoljno poznavanje načina funkcionisanja proizvodnog sistema i/ili procesa od strane eksperata kompanije. Takav slučaj značajno otežava postavku samog problema, jer je neophodno potpuno razumevanja načina funkcionisanja proizvodnog procesa kako bi se mogli jasno odrediti ciljevi, prepoznati problemi, identifikovati neophodni podaci i definisati načini rada. Drugim rečima, od izuzetnog značaja je imati potpuno razumevanje načina funkcionisanja proizvodnog procesa kako bi se primenila određena metoda napredne analitike sa ciljem ranog otkrivanja neusaglašenosti procesnih parametara.

Takođe, akademska zajednica, da bi primenila metode napredne analitike za rano otkrivanje neusaglašenosti procesnih parametara u određenom proizvodnom sistemu, mora i sama razumeti načine funkcionisanja proizvodnih procesa kako bi se razumeli i prikupljeni procesni podaci zbog kojih dolazi do pojave neusaglašenosti. Pored toga, od suštinske je važnosti i činjenica da je neophodno da podaci koji su generisani istinski opisuju stanje koje je potrebno detektovati i da su dovoljno tačni da bi imali i kvantitativnu meru stanja sistema. Stoga, upotreba metoda napredne analitike zavisi i od prirode podataka prikupljenih tokom određenog vremenskog perioda u proizvodnim sistemima, gde je potrebno odabrati skup podataka koji neće imati nepotpune, homogene ili podatke sa mnogo šuma, i time narušiti kvalitet definisanog skupa podataka.

Da bi se definisani skup podataka smatrao kvalitetnim, treba da postoji izbalansiran odnos između podataka koji opisuju stanje proizvodnog sistema kada se nisu pojavili neusaglašenosti i od podataka kada su se u proizvodnim sistemima javili određene neusaglašenosti. U slučajevima primene kontinualnog unapređenja proizvodnih sistema, procesa i kvaliteta proizvoda upotrebom različitih upravljačkih pristupa, većina ključnih problema nastalih tokom proizvodnih procesa su u velikoj meri već otklonjeni. U takvim situacijama je izuzetno teško pronaći izbalansiran odnos između podataka. Drugim rečima, u proizvodnim sistemima, naročito u proizvodnim sistemima iz procesne industrije, nailazi se na prepreku u vidu neizbalansiranog skupa generisanih podataka, koji opisuju proizvodni proces bez nastanka ikakvih problema, prekida i poteškoća prilikom njegovog rada. Neizbalansiran skup podataka

dalje ukazuje na homogenost, gde se prilikom pripreme i obrade skup procesnih podataka značajno smanjuje. Takvi slučajevi značajno otežavaju primenu metoda napredne analitike za rano otkrivanje neusaglašenosti procesnih parametara za dalja unapređenja proizvodnih sistema.

Zbog složenosti problema unapređenja proizvodnih sistema pomoću dostupnih procesnih podataka sa ciljem ranog otkrivanje nastalih neusaglašenosti procesnih parametara neophodno je razviti konceptualni model gde se na sistematičan način dolazi do problema neusaglašenosti i njegovog rešavanja. Konceptualni model za rano otkrivanje neusaglašenosti procesnih parametara (RONP) predstavlja hibridni model sačinjen od sedam zasebnih faza, gde se primenjuju različite metodologije prilikom njegovog razvoja: metoda ekspertske analize (za procenu trenutnog stanja proizvodnog sistema, kao i za razumevanje načina funkcionisanja proizvodnog sistema kako bi se došlo do preciznog definisanja problema neusaglašenosti) i metode napredne analitike (za pripremu i obradu procesnih podataka i za razvoj, testiranje i validaciju matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara).

Razvijeni RONP model bi imao karakteristike efikasnosti (u smislu tačnog određivanja definisane neusaglašenosti u trenutku njenog nastanka), i univerzalnosti (u smislu postojanja mogućnosti verifikacije u sličnim uslovima različitih proizvodnih sistema uz minimalna prilagođavanja). Razvojem ovakvog modela i njegovom verifikacijom u proizvodnom sistemu procesne industrije se menja princip dosadašnjeg pristupa prilikom unapređenja proizvodnih sistema, gde se naglasak stavlja na proaktivni i prediktivni način delovanja tokom proizvodnih procesa, a ne reaktivni. Ovakav princip unapređenja proizvodnih sistema se ostvaruje kroz primenu metoda napredne analitike, što predstavlja korak bliže ka realizaciji koncepta Industrije 4.0.

1.2. Cilj istraživanja

Cilj istraživanja je razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima. Razvijeni model određuje da li se pojavila određena predefinisana neusaglašenost u okviru proizvodnog sistema ili definisanog dela proizvodnog sistema u trenutku prikupljanja podataka na osnovu nezavisnih procesnih parametara. Razvijeni model pruža mogućnost verifikacije u različitim proizvodnim sistemima sa slično defenisanim problemom i uslovima. Nadalje, razvijeni model za rano otkrivanje neusaglašenosti procesnih parametara bi trebao imati mogućnost primene u razvoju alarmnih sistema, sistema za preporuku i samoodlučujućih sistema radi povećanja efikasnosti i konkurentnosti proizvodnog sistema na tržištu.

Da bi se pomenuti model razvio potrebno je:

- uraditi teoretsko istraživanje ključnih faza koje utiču na proces otkrivanja veza i obrazaca među prikupljenom velikom količinom neobrađenih podataka,
- odrediti karakteristike proizvodnih sistema,
- odrediti funkciju cilja proizvodnih sistema,
- sagledati trenutno stanje proizvodnih sistema radi donošenja zaključaka o spremnosti sistema za sprovođenje faza razvoja modela,
- precizno definisati problematiku nastanka neusaglašenosti u posmatranom proizvodnom sistemu,
- formirati jedinstven skup podataka prikupljenih iz proizvodnog sistema relevantan za razvoj modela,
- razviti model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu,
- uraditi verifikaciju razvijenog modela u industrijskom okruženju.

1.3. Hipoteze

Na osnovu definisanog predmeta, potreba i cilja istraživanja, kao i pregleda vladajućih stavova u relevantnoj literaturi, definisane su hipoteze istraživanja:

H1. *Moguće je razviti model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima.*

H2. *Primenom razvijenog modela moguće je smanjiti gubitke u vidu lošeg kvaliteta proizvoda (škarta) ranim otkrivanjem neusaglašenosti procesnih parametara.*

H3. *Primenom razvijenog modela moguće je automatizovati analizu procesnih parametara u trenutku njihovog prikupljanja.*

1.4. Metode istraživanja obrade podataka

U skladu sa postavljenim ciljevima istraživanja, biće primenjene različite metodologije za izradu doktorske disertacije. Početna faza istraživanja podrazumeva primenu deskriptivne metode radi opisivanja stanja nastalih tokom proizvodnih procesa kao i njihovih odnosa i veza, bez naučnog tumačenja i objašnjenja. Stoga, ova metoda korišćena je za prikazivanje teorijskog istraživanja kao pregled aktuelnog stanja u oblasti.

Primenjivaće se i metodologija izdvajanja i prikazivanja do sada postignutih rezultata iz naučne oblasti u vidu sistematskog pregleda literature za izradu teorijskih istraživanja doktorske disertacije. Metodom sistematskog pregleda literature će se vršiti identifikacija, odabir i kritičko ocenjivanje naučnih istraživanja kako bi se dobio odgovor na jasno formulisano istraživačko pitanje.

Dalje, za izradu praktičnog dela doktorske disertacije biće primenjeno više metoda kako bi se izvršio razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Prva metodologija jeste metoda ekspertske analize koja predstavlja skup logičkih postupaka zasnovanih na znanju i iskustvu radi dobijanja informacija, od strane eksperata. Svrha korišćenja metode ekspertske analize jeste dobijanje stručnih informacija, primenom metode intervjuja, koje su konkterno vezane za praktičnu primenu razvijenog modela.

Naredna metodologija korišćena za izradu praktičnog dela istraživanja jeste analitička metoda. Analitička metoda će se koristiti kao sistemski postupak koji podrazumeva matematičku analizu podataka primenom analitičkih tehniku u naučnoistraživačkom radu. Analitička metoda predstavlja rezonovanje na osnovu kojeg se postavljaju osnove za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima. Prvi korak ka razvoju modela podrazumevaće primenu istraživačke strategije bazirane na nauci o projektovanju (*Design Science Research*) u cilju određivanja trenutnog stanja proizvodnih sistema radi procene spremnosti sistema za sprovođenje faza razvoja modela. Nakon procene spremnosti proizvodnog sistema za razvoj modela, izvršiće se generisanje uzorka istraživanja.

Takođe, primenjivaće se i metoda eksperimenta u cilju eksperimentalnog ispitivanja i dokazivanja rada modela i dobijanje eksperimentalnih rezultata. Eksperimentalna metoda će se sprovesti u odabranom proizvodnom sistemu iz oblasti procesne industrije.

1.5. Značaj i doprinos rada

Razvijeni model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima pruža mogućnost:

1. uvida u trenutno stanje proizvodnog sistema, pružajući informaciju kakvi tipovi proizvodnih sistema mogu razmatrati implementaciju modela za rano otkrivanje neusaglašenosti procesnih parametara radi unapređivanja proizvodnih sistema, kao i određivanje uslova potrebnih za ispunjavanje zahteva te implementacije;
2. unapređenje kvaliteta proizvoda i procesa pronalaženjem skrivenih veza i informacija među podacima;

3. primene metoda napredne analitike podataka na procesne parametre u trenutku njihovog prikupljanja i u skladu sa tim preduzeti određene odluke unutar proizvodnih sistema;
4. razvoja alarmnih sistema, sistema za davanje preporuka i samoodličujućih sistema (mašine same donose odluke na osnovu razvijenog modela);
5. povećanje efikasnosti i efektivnosti proizvodnih sistema.

1.6. Prikaz po poglavlјima

U uvodnom delu prikazana su opšta razmatranja i trendovi koji se tiču unapređenja proizvodnih sistema primenom novih prilaza. Novi prilazi su zasnovani na naprednoj obradi dostupnih podataka i iskorišćenju potencijala prikupljenih velikih količina procesnih podataka. Takav način upotrebe podataka na osnovu koji se dobijaju skrivene informacije o procesima zahteva promene unutar proizvodnih sistema. Prema tom razmatranju izložena je osnovna ideja, problem i predmet istraživanja, cilj istraživanja, hipoteze, metodologija istraživanja i značaj i doprinos disertacije.

Drugo poglavlje obuhvata pregled značajnih teoretskih istraživanja počev od istorijskog razvoja proizvodnih sistema, pa sve do četvrte industrijske revolucije. U ovom poglavlju akcenat je stavljen na unapređenja proizvodnih sistema, gde su obuhvaćeni stavovi autora o načinu unapređenja proizvodnih sistema koristeći metodu sistematskog pregleda literature. Takođe, dato je pojašnjenje o postojećim izazovima prilikom unapređenja proizvodnih sistema, kao i o rešenju problema unapređenja primenom analitičkih metoda obrade podataka.

Treće poglavlje obrađuje temu analitike procesnih podataka, gde se prvi deo poglavlja bazira na definisanju i objašnjenu procesnih podataka. Dalje, predstavljene su napredne tehnologije koje omogućavaju primenu analitike procesnih podataka u proizvodnim sistemima. I na kraju, sa posebnom pažnjom predstavljene su metode analitike procesnih podataka u proizvodnim sistemima, koje su grupisane u napredne statističke metode, metode mašinskog učenja, i fazi logiku.

U četvrtom poglavlju razvijen je konceptualni model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistema (RONP). Proces razvoja modela podeljen je u sedam glavnih faza: procena trenutnog stanja proizvodnog sistema, definisanje problema neusaglašenosti u proizvodnom sistemu, identifikacija uticajnih parametara i prikupljanje podataka, priprema i obrada prikupljenih podataka, razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka, testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara i validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara. U okviru svake faze razvoja modela, definisani su koraci za njihovo sprovođenje. Pored toga,

posmatrajući prevashodno izazove unapređenja proizvodnih sistema, razvijen je model koji se zasniva na upotrebi fazi ekspertnih sistema i metoda napredne analitike. Zbog složenosti problema unapređenja sa kojima se možemo susresti u proizvodnim sistemima predložen je izbor metoda napredne analitike, i to - napredne statističke metode i metode mašinskog učenja.

U petom poglavlju izvršena je verifikacija konceptualnog RONP modela: *Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu procesne industrije*. Na osnovu razvijenog modela urađena je komparativna analiza, gde su poređeni rezultati performansi tehnika napredne statističke metode i metode mašinskog učenja. Verifikacija RONP modela je realizovana u industrijskom okruženju proizvodnog sistema za proizvodnju podnih obloga od vinila primenom eksperimentalne metode, gde je izvršena praktična primena modela u trenutku prikupljanja podataka kao i automatizacija analize podataka.

U šestom poglavlju urađena je diskusija rezultata i analiza postavljenih hipoteza.

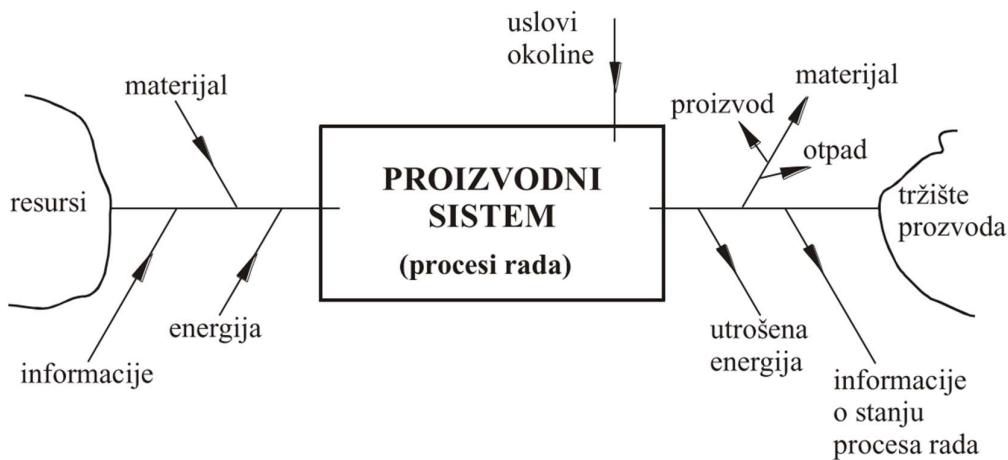
U sedmom poglavlju formulisani su zaključci i rezimirano istraživanje uz sumiranje naučnog doprinosa disertacije.

U osmom poglavlju je navedena korišćena literatura po redosledu citiranja u doktorskoj disertaciji.

2. TEORETSKE OSNOVE PROIZVODNIH SISTEMA

2.1. Proizvodnja i proizvodni sistemi

Najraniji periodi razvoja civilizacije svedoče o težnji čoveka za zadovoljenjem sopstvenih potreba. Vremenom čovek je uočio mogućnost transformacije prirodnih resursa iz okruženja u korisne proizvode sa odgovarajućom namenom radi poboljšanja kvaliteta života [1]. Proces transformacije resursa u odgovarajuće proizvode označava proizvodnju. Danas, proizvodnja predstavlja osnovno područje ljudske delatnosti sa svrhom zadovoljenja potreba većine pojedinaca uslovljena postojanjem sistema za proizvodnju oblikovanih na način da se obezbedi transformacija raspoloživih resursa u proizvode [2]. Prema tome, **proizvodnja** se može definisati kao svrshodna delatnost sa ciljem dobijanja proizvoda koji služe za zadovoljenje potreba najvećeg broja pojedinaca, radnih sistema i razvoja društva. Takođe, proizvodnja je uslovljena postojanjem skupa međusobno povezanih elemenata (predmeta rada, sredstava rada i učesnika u procesima rada) i njihovih karakteristika uređenih u skladu sa projektovanim postupcima promene stanja sa jedne strane, i postojanjem sistema za proizvodnju radi transformacije raspoloživih resursa u proizvode u skladu sa datim potrebama sa druge strane (slika 1) [2], [3]. Stoga, postojanje proizvodnih sistema je neophodno za ostvarenje ciljeva proizvodnje i dobijanje proizvoda potrebnih za zadovoljenje potreba društva [3], [4].



Slika 1. Osnovni model transformisanja raspoloživih resursa u proizvode [2], [3]

Proizvodni sistemi, kao skup osnovnih tehnoloških, tehničkih, informacionih i energetskih struktura, predstavljaju složene dinamične sisteme koji obezbeđuju ostvarenje definisanog cilja i projektovanih efekata. Razvoj proizvodnih sistema je uslovljen:

- sposobnošću predviđanja događaja,

- brzinom usvajanja novih tehnoloških rešenja,
- kvalitetom postupaka promene stanja, oblikovanja elemenata sistema i relacija između njih i njihovih karakteristika,
- kvalitetom organizovanja sistema,
- kvalitetom upravljanja postupcima promene stanja, i
- efikasnošću i kvalitetom funkcija sistemske podrške – logistike [3], [4].

Razvoj proizvodnih sistema zahteva pažljivo utvrđivanje zavisnosti između potreba (izlaznih veličina) i resursa (ulaznih veličina), kao i radnih karakteristika sistema na bazi postavljenog cilja proizvodnje. Pri ovom, nivo i kvalitet ulaznih veličina su uslovjeni kvalitetom i odnosima u okolini, a nivo i kvalitet radnih karakteristika i izlaznih veličina stepenom objektivnosti u postavljanju cilja, kvalitetom projektovanja, organizovanja, izvođenja i upravljanja procesima rada u smislu obuhvatanja uslova okoline i zadovoljenja ciljeva sistema. Radne karakteristike proizvodnih sistema su na taj način, izraz sposobnosti sistema da vrše rad u datom vremenu i datim uslovima okoline i da obezbede efekat, nivo i kvalitet izlaznih veličina, određen postavljenim ciljem proizvodnje [3]. Proces rada proizvodnog sistema naziva se **proizvodni proces**, koji čini skup aktivnosti neophodnih za izvršenje postupka promene ulaznih u izlazne veličine sistema [4].

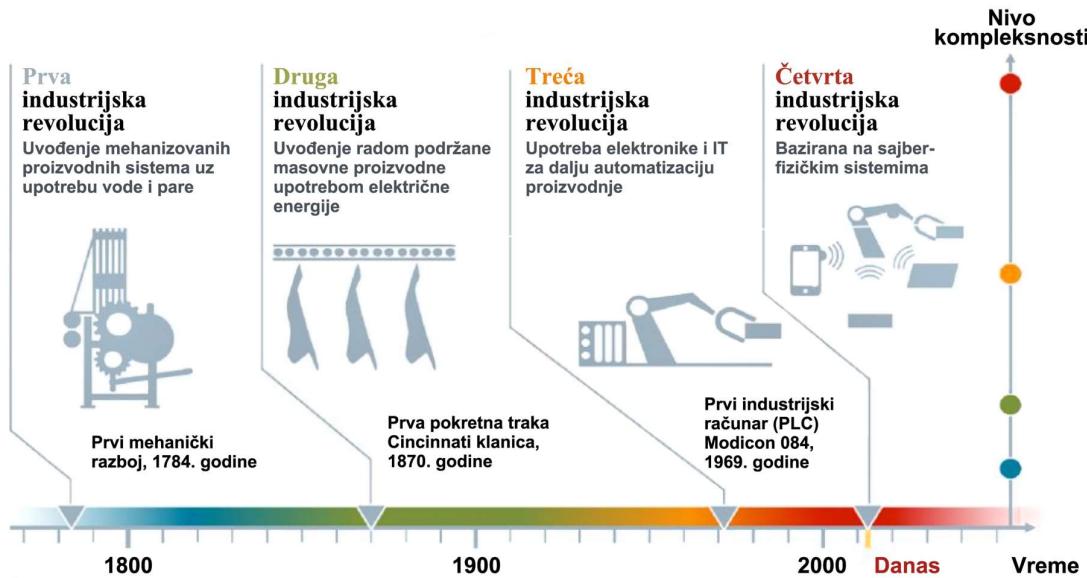
Danas, težnja za razvojem i održavanjem dovodi do sve češćih napora za poboljšanjem svih delova proizvodnih sistema primenom novih metoda i tehnika u postavljanju i racionalizaciji proizvodnih procesa. Povećanje proizvodne produktivnosti, kvaliteta proizvoda i efekata proizvodnih sistema zahteva napor stručnjaka iz različitih oblasti, što dovodi do uske povezanosti nauke i materijalne proizvodnje. Na osnovu ovoga se zaključuje da cilj povećanja efekata proizvodnih sistema postaje istovremeno i područje za stvaranje sve povoljnijih uslova za povećanje efektivnosti nauke i istraživačko–razvojnog rada. Proizvodni industrijski sistemi, kao deo proizvodnih sistema, imaju dominantnu ulogu u izvođenju istraživačko–razvojnih aktivnosti sa ciljem dobijanja procesa koji će imati karakteristike konkurentnosti na tržištu, a samim tim i obezbediti dalji razvoj privrednih i društvenih delatnosti [3].

2.2 Istoriski razvoj proizvodnih sistema

Proizvodni sektor se suočava sa konstantnim izazovima u pogledu razvoja sa ciljem unapređenja proizvodnih sistema i njihovih proizvodnih procesa. Grunberg je u svom radu [5] napomenuo da se čine naporci za razvoj proizvodnje i poboljšanje proizvodne produktivnosti još od početka industrijske ere. Sagledavanjem dosadašnjeg toka razvoja proizvodnje, uočavaju se četiri značajna perioda [6] (slika 2) i to:

- prva industrijska revolucija,
- druga industrijska revolucija,

- treća industrijska revolucija,
- četvrta industrijska revolucija.



Slika 2. Tok razvoja industrijske proizvodnje

2.2.1. Prva industrijska revolucija

Početkom prve industrijske revolucije se smatra period od druge polovine 18. veka, pa sve do sredine 19. veka [4], [6]. Glavna karakteristika ovog perioda industrializacije je bio prelazak sa manuelnog načina proizvodnje na mašinsku proizvodnju koji je izmenio ranije političke, društvene i privredne sisteme širom sveta. Najpoznatiji izum, koji je obeležio ovu eru, jeste parna mašina [7]. Ovaj izum, usavršen od strane Džejmsa Vata, napravio je preokret u proizvodnji i izazvao revoluciju u prerađivačkim delatnostima formirajući industriju u današnjem smislu [4].

Pojavom industrijalizacije, proizvodnja postaje ekonomski održivija, a masovna proizvodnja pokazuje primenu u transportu, rudarstvu i fabrikama. Takođe, parna mašina je umnogome doprinela razvoju komunikacionog sistema razvojem telegrafa, tj. uređaja za prenos pisanih poruka na velike daljine [6].

Jedan od savremenika doba industrijalizacije, poznati škotski ekonomista Adam Smit objavio je knjigu „Bogatstvo naroda“, u kojem je promovisao ekonomski sistem zasnovan na privatnom vlasništvu nad proizvodnim sredstvima, slobodnom preduzetništvu i zalaganjem za smanjenje uticaja državnih vlada na ekonomiju. Drugim rečima, knjiga promoviše savremeni

kapitalistički ekonomski poredak odbacujući ideje merkantilizma. Takođe, u njegovim delima se predočavaju i izazovi i prednosti koje industralizacija donosi sa sobom, gde standardizacija, kao novi koncept, igra značajnu ulogu u industrijskom načinu proizvodnje [4].

2.2.2. Druga industrijska revolucija

Druga industrijska revolucija, poznatija kao *Tehnološka revolucija*, je značajna po velikom broju društvenih promena koje su doveli do promena u proizvodnji. Period trajanja druge industrijske revolucije obuhvata dve etape sa različitim fokusima. Prva etapa se fokusirala na troškove, odnosno njihovo minimiziranje [8], dok se druga etapa fokusirala na kvalitet i njegovo unapređenje [9].

Fokus na troškovima – odnosi se na eru masovne proizvodnje čiji se počeci vezuju za vremenski period od 1905. do 1920. godine i Henrika Forda. On je primenio ideje naučnog menadžmenta radi unapređenja procesa proizvodnje automobila transformišući ga u masovnu proizvodnju, na osnovu čega je nastala prva pokretna montažna linija na svetu. Naime, automobili pravljeni krajem 19. veka bili su ručno rađeni i skupi. Henri Ford, osnivač kompanije *Ford Motors*, pustio je u proizvodnju 1. oktobra 1908. godine masovno proizvedeni model *T* i na taj način smanjio troškove proizvodnje. Kao rezultat toga, Ford je smanjio cenu automobila učinivši ga pristupačnjim ljudima srednje klase i na taj način ga je popularizovao među Amerikancima [8]. Međutim, masovna proizvodnja zahteva i određeni kvalitet proizvoda, zbog čega su se i razvile nove statističke metode zasnovane na uzorkovanju, metode linearног programiranja i metode za planiranje potreba za materijalima [4].

Fokus na kvalitetu – predstavlja period razvoja novih proizvodnih koncepcija sa akcentom na filozofiju kvaliteta. Japanska filozofija kvaliteta, poznatija kao *Lean* koncept predstavlja adaptaciju masovne proizvodnje u kojoj se rad ostvaruje za kraće vreme, u manjem prostoru, sa manje radnika, sa manje opreme, s tim da se postiže viši nivo kvaliteta finalnog proizvoda [10]. *Lean* koncept u proizvodnim sistemima se zasniva na kontinualnom unapređivanju svih segmenta procesa rada sa trošenjem sredstava isključivo za stvaranje nove vrednosti za krajnjeg kupca i time eliminujući sve vidove gubitaka unutar proizvodnog sistema [11].

2.2.3. Treća industrijska revolucija

Treća industrijska revolucija, poznatija kao *Digitalna revolucija*, se zasniva na transformaciji mehaničke i analogne tehnologije u digitalnu tehnologiju [7]. Započeta je pronalaskom tranzistora polovinom 20. veka i traje sve do današnjeg dana.

Naziv *Digitalna revolucija* se isto tako odnosi i na promene koje su bazirane na intezivnoj primeni računara i komunikacionih tehnologija te se može reći da je upravo ova revolucija odgovorna za početak informaciono-upravljačkog doba. Što se tiče proizvodnje ona je postala sve više potpomognuta kompjuterskom tehnologijom. Masovna proizvodnja biva zamenjana masovnom proizvodnjom prema individualnim zahtevima kupca (*mass customization*). Zatim, upotreba robota doprinosi daljoj automatizaciji proizvodnje, kao i masovna primena tehnologija zasnovanih na Internetu za kontrolu i planiranje proizvodnih procesa, kao što su SCADA (*Supervisory control and data acquisition*) i ERP (*Enterprise Resource Planning*) [4].

2.2.4. Četvrta industrijska revolucija

Nedavno je četvrta industrijska revolucija, nazvana *Industrija 4.0*, postala jedna od glavnih istraživačko–razvojnih tema kako industrije tako i akademije iz oblasti menadžmenta i inženjerstva. Industrija 4.0 predstavlja koncept nastao krajem 2011. godine, uveden od strane nemačke vlade, kako bi se promovisala nemačka nova strategija razvoja industrije zasnovana na naprednim tehnologijama [12]. Industrija 4.0 praćena je razvojem informacionih i komunikacionih tehnologija gde se tradicionalna proizvodnja transformiše u inteligentnu. Ova transformacija je omogućena razvojem naprednih tehnologija [13]–[22].

Na osnovu pregleda postojeće literature iz oblasti, može se zaključiti da se koncept Industrije 4.0 definiše na različite načine, u zavisnosti od tačke gledišta i oblasti istraživanja [23]–[26]. Međutim, definicija koncepta Industrije 4.0, koja je prihvaćena u ovoj doktorskoj disertaciji i koja kao fokus ima rano otkrivanje neusaglašenosti procesnih parametara koji se javljaju tokom procesa proizvodnje u proizvodnim sistemima i primeni napredne tehnologije na kojoj se zasniva ovaj koncept, glasi: „**Industrija 4.0 je koncept koji ima za cilj integraciju fizičkih delova proizvodnog procesa (tj. složenih mašina, različitih uređaja i senzora) i virtuelnih delova (tj. naprednih softvera), putem komunikacionih mreža vođena tehnološkim kategorijama Industrije 4.0 koje se koriste za kontrolu, održavanje i integraciju proizvodnih procesa i rano otkrivanje neusaglašenosti procesnih parametara, gde tehnološkim kategorijama pripadaju sledeće grupe tehnologija: sajber-fizički sistemi (Cyber-Physical Systems - CPS), Internet stvari (Internet of Things - IoT), analitika velikih podataka (Big Data Analytics - BDA), Cloud sistemi računarske tehnologije, Fog i Edge sistemi računarske tehnologije, proširena i virtualna stvarnost (Augmented and Virtual Reality - AR/VR), robotika, sajber bezbednost, semantičke veb tehnologije i aditivna proizvodnja (Additive Manufacturing - AM)**“ ([7] na osnovu [12], [23], [27]–[30]).

Na osnovu definicije Industrije 4.0 [7] koja se bazira na naprednim tehnologijama, neophodno je definisati šta se tačno podrazumeva pod pojmom određene tehnološke kategorije. Stoga, definicije tehnoloških kategorija su sledeće:

- **sajber-fizički sistemi** predstavljaju sisteme u kojima su fizički objekti i softver tesno integrirani, što omogućava poboljšanu interakciju (tj. razmenu informacija) između različitih komponenti [31], [32],
- **Internet stvari** predstavlja mrežu koja omogućava komunikaciju između „stvari“ (tj. predmeta ili uređaja) korišćenjem senzora putem infrastrukture informacionih i komunikacionih tehnologija [18], [33], što rezultira prikupljanjem podataka generisanih tokom proizvodnih procesa, detekcijom neusaglašenosti procesnih parametara i aktiviranjem povratne informacije u trenutku prikupljanja podataka [23],
- **analitika velikih podataka** predstavlja postupak otkrivanja skrivenih informacija između ogromnih količina podataka, prikupljenih sa različitih uređaja, koristeći metode napredne analitike (npr. napredne statističke metode, metode mašinskog učenja, fazi logika), [18], [34], koji omogućava donošenje odluka u trenutku prikupljanja podataka [23],
- **Cloud sistemi računarske tehnologije** predstavljaju računarsku uslugu koja pruža skladištenje, deljenje i obradu podataka pomoću vizuelnih i skalabilnih resursa putem Interneta [35],
- **Fog i Edge sistemi računarske tehnologije** odnose se na decentralizovane računarske usluge za skladištenje, obradu i aplikacije koje se odvijaju na mestu generisanja podataka [36]–[40],
- **proširena i virtuelna stvarnost** predstavljaju informacione tehnologije koje pružaju indirektno iskustvo stvaranjem virtuelnog prostora koji komunicira sa ljudskim senzornim sistemima (VR) [41] i omogućavaju vizuelizaciju računarske grafike smeštene u realnom okruženju (AR), pružajući ljudima interakciju sa virtuelnim prostorom [42],
- **robotika** predstavlja sistem koji koristi industrijske robote i/ili robotske uređaje, koji su autonomni, fleksibilni i kooperativni, za industrijsku automatizaciju sa ciljem tačnijeg obavljanja proizvodnih zadataka uz minimalno ljudsko učešće [23], [43], [44].
- **sajber bezbednost** predstavlja „skup tehnologija i procesa dizajniranih da zaštite računare, mreže, programe i podatke od napada, neovlašćenog pristupa, promene ili uništenja“ [45],
- **semantičke veb tehnologije**, kao produžetak trenutne mreže, predstavljaju zajednički pokret i skup standarda [46] u kojima se informacijama daje dobro definisano značenje, što omogućava računarima i ljudima da rade zajedno [47],
- **aditivna proizvodnja** predstavlja proces proizvodnje predmeta dodavanjem materijala sloj po sloj (za razliku od tehnologija obrade skidanjem materijala) na osnovu digitalnih informacija, omogućavajući izradu trodimenzionalnih predmeta na zahtev [48]–[51].

Prema usvojenoj definiciji koncepta Industrije 4.0 koja se koristi u ovoj doktorskoj disertaciji [7] akcenat je stavljen na rano otkrivanje neusaglašenosti procesnih parametara koji

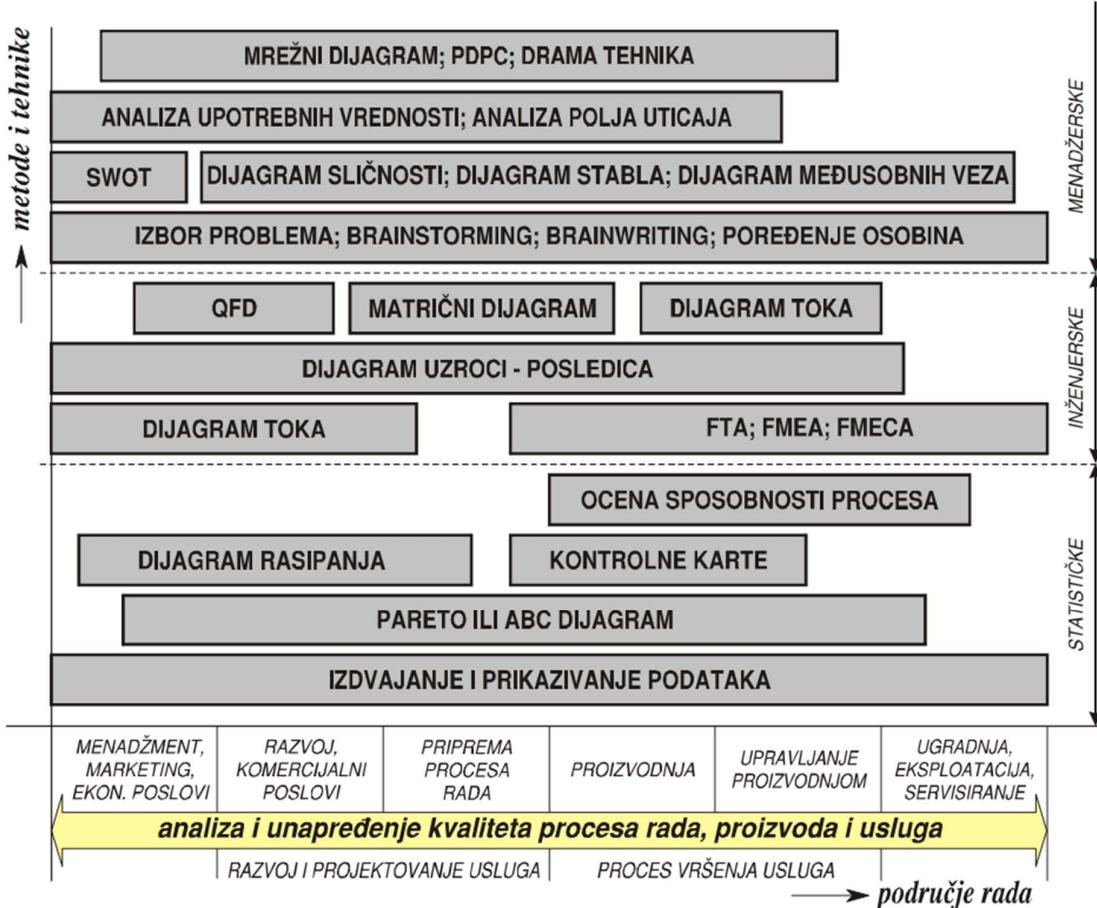
se javljaju tokom procesa proizvodnje u proizvodnim sistemima primenom naprednih tehnologija. Napredne tehnologije, pre svega IoT, CPS i BDA omogućavaju generisanje, prikupljanje, obradu podataka i njihovo pretvaranje u korisne informacije. Na osnovu ovoga dolazi se do zaključka da se primenom ovog koncepta povećava efikasnost proizvodnih procesa i kvalitet proizvoda prikupljanjem i interpretacijom podataka korišćenjem analitičkih tehnika podataka (npr. metodologiji proučavanja podataka, statističkoj analizi, mašinskom učenju itd.) i razvojem konceptualnog modela na osnovu kojih se donose i izvršavaju odluke u realnom vremenu na sistematičan način [52] kako bi se povećala konkurentnost proizvodnog sistema [53], [54]. Stoga, Industrija 4.0 kao novi koncept stvara još veću potrebu za primenom **metoda unapređenja proizvodnog sistema** koje imaju za cilj povećanje konkurentnosti na tržištu.

2.3. Unapređenja proizvodnih sistema

Današnji uslovi proizvodnje podrazumevaju da kompanije konstantno moraju da uvođe promene u proizvodne sisteme, sa ciljem zadovoljenja potreba tržišta, sa što nižim troškovima i u što kraćem vremenskom periodu. Stalna težnja za poboljšanjem proizvodnih sistema, procesa i kvaliteta proizvod, sa jedne strane, i zadovoljenjem potreba tržišta, sa druge, zahteva od kompanije da sve procesne parametre tokom proizvodnje drže pod kontrolom. Stoga, kompanije konstantno moraju da unapređuju svoje proizvodnje procese, kako bi postigle uštede u vremenu i novcu. Unapređenje proizvodnih procesa, pored tehnoloških unapređenja (uvodenje novih proizvodnih linija, poboljšavanje automatizacije, korišćenje novih tehničkih i tehnoloških rešenja, korišćenje nusproizvoda, robotike, itd.), podrazumeva i primenu različitih metoda i tehnika sa željom da se pospeši sama proizvodnja [55]. Naime, u knjizi „*Metode i tehnike unapređenja procesa rada*“ [55] autora Vulanovića i saradnika napravljena je podela metoda i tehnika unapređenja procesa (slika 3) na:

- statističke metode i tehnike:
 - izdvajanje i načini prikazivanja podataka,
 - Pareto ili ABC dijagram,
 - dijagram rasipanja,
 - kontrolne karte;
- inženjerske metode i tehnike:
 - dijagram toka,
 - dijagram uzroci - posledica,
 - matrični dijagram,
 - FTA, FMEA i FMECA (metode analize neispravnosti i otkaza),
 - QFD metoda;
- menadžerske metode i tehnike:

- izbor problema,
- dijagram sličnosti,
- dijagram stabla,
- dijagram međusobnih veza,
- PDPC dijagram,
- analiza upotrebnih vrednosti,
- analiza polja uticaja,
- poređenje osobina,
- *brainstorming* i *brainwriting*,
- SWOT analiza,
- drama tehnika,
- mrežni dijagram.



Slika 3. Pregled mogućnosti primene metoda i tehnika u odnosu na delove procesa rada [55]

2.3.1. Studije slučaja unapređenja proizvodnih sistema

Analiza studija slučaja unapređenja proizvodnih sistema je sprovedena na osnovu sistematskog pregleda akademske literature kako bi se analizirale dostupne studije slučaja. Potraga za relevantnim publikacijama obavljena je u naučnoj bazi podataka *Scopus* zaključno sa 20. februarom 2021.godine. Sistematski pregled literature obuhvatio je tri faze pretraživanja i odabira zasnovanih na metodi sistematskog pregleda literature prilagođenog iz [56], [57] (tabela 1).

Tabela 1. Faze pretrage radova i kriterijumi za njihov odabir

<i>Faze pretrage</i>	<i>Kriterijum faza pretrage</i>
	<i>Ključne reči za pretragu</i>
	Pretraživanje termina „manufacturing system* improvement* case study” u naslovu, apstraktu i ključnim rečima u indeksnoj bazi <i>Scopus</i>
	<i>Kriterijumi uključivanja radova u pretragu</i>
1. Početna pretraga	Pretraga uključuje isključivo radove koji su objavljeni u naučnim časopisima koji su dostupni bez prethodnog plaćanja članarine (<i>open source</i>);
	Pretraga uključuje radove isključivo iz obasti inženjerstva
	<i>Godina objavljanja rada</i>
	Uključeni su radovi koji su objavljeni od 01.01.2012. do 20.02.2021. godine
	<i>Kriterijum uključivanja radova iz pretrage</i>
	Iz pretrage su izuzeti radovi koji nisu napisani na engleskom jeziku
	Iz pretrage su izuzeti radovi koji predstavljaju literaturne preglede, editorijale i istraživanja zasnovana na anketama
	<i>BROJ RADOVA KOJI JE UŠAO U DALJU PRETRAGU: 142</i>
2. Izbor radova na osnovu kvaliteta časopisa	Izbor je zasnovan na rangiranju časopisa prema kvalitetu na osnovu klasifikacije prema bazi podataka <i>SCImago</i> u kojem je objavljen rad (uključeni su sam radovi koji pripadaju Q1 i Q2 rangu kvaliteta)
	<i>BROJ RADOVA KOJI JE UŠAO U DALJU PRETRAGU: 109</i>
3. Čitanje apstrakta ili celog rada	Kriterijum: U apstraktu ili radu se tvrdi da se rad bavi unapređenjem proizvodnih sistema u procesnoj industriji primenom nekih od metoda i tehnika unapređenja
	<i>BROJ RADOVA KOJI JE UŠAO U DALJU PRETRAGU: 30</i>

Prva faza bila je početna pretraga, koja se sastojala od četiri dela: prvo, termin za pretragu „*manufacturing system* improvement* case study*“ korišćen je za pretragu naslova rada, apstrakta i ključnih reči u bazi podataka *Scopus*; drugo, u pretrazi su ostali samo radovi koji su objavljeni u naučnim časopisima koji su dostupni bez prethodnog plaćanja članarine (*open source*), dalje, uključeni su samo radovi iz naučne oblasti „inženjerstvo“ prema bazi podataka *Scopus*; treće, obuhvaćene su publikacije objavljene u periodu od 1. januara 2012. do 20. februara 2021. godine (obuhvata se period u proteklih 10 godina zbog aktuelnosti radova); i konačno, isključene su sve publikacije koje nisu na engleskom, kao i radovi koji predstavljaju literaturne pregledе, editorijale i istraživanja zasnovana na anketama (tabela 1). Kao rezultat, na osnovu početne pretrage broj radova je smanjen sa 2.403 na 142 rada koji su ušli u dalju pretragu.

U drugoj fazi je izvršen izbor radova na osnovu njihovog rangiranja u časopisima (tabela1). Tako je u izboru zadržano 109 radova objavljenih u časopisima sa rang liste kvartala Q1 i Q2 baze podataka *SCImago* (na osnovu 2019. kao referentne godine).

U trećoj fazi pročitani su apstrakti izabranih 109 radova ili naučni radovi u celosti (ukoliko iz apstrakta nije jasno moglo da se zaključi da li rad treba ostati u odabiru) nad kojima je primenjen kriterijum za uži izbor - tabela 1 (tj. „*U apstraktu ili radu se tvrdi da se rad bavi unapređenjem proizvodnog sistema u procesnoj industriji primenom nekih od metoda i tehnika unapređenja*“). Nakon čitanja sažetka, u izboru je ostalo 30 radova koji se bave unapređenjem proizvodnog sistema u procesnoj industriji.

Na osnovu primenjene metodologije sistematskog pregleda relevantne literature došlo se do zaključka da se najranija zabeležena studija slučaja unapređenja proizvodnog sistema (pregledanih u periodu između 01.01.2012. do 20.02.2021.) javila 2013. godine gde se izvršilo unapređenje proizvodnog sistema za proizvodnju cevi primenom Lean koncepta. Daljom analizom relevantne literature uočava se trend primene Lean koncepta za unapređenje proizvodnih sistema procesne industrije u 47% relevantnih radova (14 od 30 ukupno), i to:

- Xia i Sun [58] koristili su mapiranje toka vrednosti (*value stream mapping – VSM*) u kombinaciji sa simulacijom diskretnih događaja za unapređenje proizvodnog sistema za proizvodnju cevi;
- Panat i sar. [59] bavili su se unapređenjem procesa konfiguracije kontrole proizvodnje primenom *Lean* koncepta i *šest-sigma* metodologije u proizvodnom sistemu Intel, u delu za istraživanje i razvoj;
- Darlington i sar. [60] u radu opisu primenu tipa *Kanban* sistema (*Drum-Buffer-Rope pull*-sistem) za unapređenje proizvodnog procesa za proizvodnju panela pomoću *Lean* koncepta;

- Jirasukprasert i sar. [61] pokazuju kako primena *šest-sigma* i DMAIC (*defining, measuring, analyzing, improving, controlling*) metodologije unaprediti kvalitet procesa u proizvodnom sistemu za proizvodnju gumenih rukavica;
- Mwanza i Mbohwa [62] u svom radu opisuju unapređenje sistema za održavanje u hemijskoj procesnoj industriji primenom TPM (*Total Productive Maintenance*) koncepta;
- Lacerda i sar. [63] su primenili VSM zajedno sa dijagramom toka kako bi unapredili proizvodni sistem automobilskog sektora;
- Rehman, Alkhatani i Umer [64] bave se studijom slučaja proizvodnog sistema u Saudijskoj Arabiji, koja naglašava primenu *Lean* koncepta gde je predložen višekriterijumski pristup oceni rezultata performansi *Lean* koncepta;
- Ponnambalam i Subramanian [65] su za unapređenje livačkog dela industrije za proizvodnju auto-delova primenili TPM koncept fokusirajući se na *Kaizen* i VSM;
- Gupta i sar. [66] su se fokusirali na unapređenje proizvodnog sistema za proizvodnju guma koristeći metodu sa *šest-sigma* pomoću alata DMAIC;
- Vieira i Lopes [67] u svom radu primenjuju alate vizuelnog menadžmenta, 5S, A3 *razmišljanja* i SMED (*single-minute exchange of die*) kako bi unapredili srednje preduzeće za proizvodnju čepova;
- Choudhary i sar. [68] su se bavili unapređenjem proizvodnog sistema za proizvodnju ambalaže koristeći prilagođeni VSM integriran sa konceptom „*zelene proizvodnje*“ u cilju poboljšanja operativne efikasnosti uz smanjenje uticaja na životnu sredinu. Na taj način su kreirali GIVSM (*green integrated VSM*) kako bi vizualizovao sav otpad pomoću dijagrama toka vrednosti;
- Dong i sar. [69] opisuju unapređenje proizvodnog sistema termoelektrane primenom *Lean* koncepta i „*zelene proizvodnje*“ u kombinaciji sa algoritmima mašinskog učenja;
- Peruchi i sar. [70] izvršili su integrisanje višeparametarske statističke analize u DMAIC metodologiju i na taj način unapredili proizvodni sistem za preradu čelika;
- Abdallah [71] u svom radu se bavi unapređenjem proizvodnog sistema za proizvodnju aluminijuma primenom *Lean* alata usled problema kvaliteta procesa i velikih troškova tokom pandemije COVID-19.

Pored primene *Lean* koncepta za unapređenje proizvodnih sistema, sistematskim pregledom relevantne literature pronađeni su primeri upotrebe različitih tehnoloških rešenja zasnovanih na matematičkim modelima i primeni kompjuterske tehnologije u 43% relevantnih radova (13 od 30), i to:

- Donauer, Peças i Azeved [72] su razvili metodologiju za identifikovanje osnovnih uzroka neusaglašenosti parametara pružajući vizuelni prikaz problematičnih područja. Metodologija je zasnovana na integraciji ekonomskog koncepta (mere koncentracije) u

KDD (*Knowledge Discovery in Databases*) metodologiju. Njegova upotreba je potvrđena u proizvodnom procesu u automobilskoj industriji;

- Li i sar. [73] se fokusiraju na kvantitativnu analizu uticaja zastoja u cilju unapređenja proizvodnih sistema na osnovu dostupnih podataka iz proizvodnje. Studija slučaja se izvodi kako bi se demonstrirao njegov potencijal u kontroli proizvodnje u trenutku prikupljanja podataka i raspodeli resursa i budžeta u višestepenom proizvodnom sistemu;
- Simeone i sar. [74] razvili su konceptualnu i analitičku metodologiju za podršku u odlučivanju o rekuperaciji otpadne toplove koja je primenjena u industrijskoj studiji slučaja;
- Pask i sar. [75] u svom radu predstavljaju hibridni višekriterijumski pristup koji koristi fazi teoriju i Monte Karlo simulaciju kao podršku u odlučivanju procene održivosti alternativnih mogućnosti poboljšanja, što je demonstrirano korišćenjem studije slučaja u procesnoj industriji;
- Dorio i sar. [76] predstavili su vezu ERP sistema sa primenom CNC (*Computer Numerical Control*) obradnog sistema za proizvodnju kuhinjskog nameštaja baveći se unapređenjem kvaliteteta proizvoda;
- Auer, Bey i Schäfer [77] bavili su se unapređenjem i modernizovanje proizvodnog sistema za proizvodnju staklenih boca pomoću LCA (*Life Cycle Assessment*) metode gde je pokazano da je najveći doprinos uticaju na životnu sredinu i ekonomskim troškovima povezan sa energetskim zahtevima tokom procesa proizvodnje;
- Rezazadeh i Khiali-miab [78] u svom istraživanju predstavljaju matematički model na principima dvoslojnog genetskog algoritma za dizajn pouzdanih čelijskih proizvodnih sistema, što dovodi do smanjenih proizvodnih troškova, poboljšanog kvaliteteta proizvoda i poboljšane ukupne pouzdanosti proizvodnog sistema;
- Ou i sar. [79] su razvili matematički model za analizu performansi portalnih sistema zasnovanih na podacima prikupljenih tokom proizvodnog procesa kako bi se poboljšale performanse složenog radnog sistema i na taj način unapredila proizvodnja;
- Zahraee, Rohani i Wong [80] naglašavaju da je cilj njihovog istraživanja integrisanje simulacionog modeliranja zajedno sa metodologijom površine odziva (RSM - *response surface methodology*) i dizajniranjem eksperimenata (DOE - *design of experiments*) kako bi se analizirala i poboljšala produktivnost u proizvodnom sistemu za kontinuiranu proizvodnju boja;
- Tamminen i sar. [81] razvili su alat za praćenje kvaliteta zasnovan na statističkom opštem modelu pojačane regresije (*Generalized Boosted Regression Models*) za predviđanje kvaliteta i analizu procesa. Alat je namenjen industrijskim linijama koje imaju veliku varijabilnost u tipovima proizvoda koji se proizvode i ispunjava zahteve za automatizovanom analizom podataka u proizvodnom sistemu za preradu čelika;

- Berrah i sar. [82] predstavljaju koncept za kontrolu unapređenja proizvodnih višekriterijumske performansi primenom modela *Choquet* integrala agregacionih funkcija, što je potvrđeno u studiji slučaja primjenjenog u malom i srednjem preduzeću;
- Straka i Lenort [83] su ispitivali efekte i uticaje računarske simulacije na poboljšanje industrijske proizvodnje. Takođe, urađena je i verifikacija razvijenog simulacionog modela i primena modela u logistici proizvodnog sistema u kompaniji za proizvodnju betona sa ciljem utvrđivanja da li simulacija odgovara stvarnom stanju sistema;
- Laudante i sar. [84] naglašavaju da bi uvođenje robotskog sistema u radnu jedinicu proizvodnog sistema trebalo da garantuje određena poboljšanja poput smanjenja rizika za ljudske operatere, bolje rezultate kvaliteta i povećanja brzine u proizvodnim procesima. Međutim, ljudska akcija je i dalje neophodna za izvršavanje dela podzadataka, kao u slučaju procesa sklapanja kompozita. Stoga, njihovo istraživanje predstavlja simulaciju i analizu čitavog radnog procesa za sastavljanje kompozitnih ploča trupa u vazduhoplovnoj industriji kako bi se demonstrirala i verifikovala primenljivost i efikasnost interakcije čovek-robot.

Sistematskim preglednom relevantne literature ustanovljeno je da je prvi slučaj unapređenje proizvodnih sistema primenom kocepta Industrije 4.0 zabeležen u 2020. godini, gde 10% pregledanih radova (3 od 30) koristi napredne tehnologije kako bi to postigao. Daljom analizom primene kocepta Industrije 4.0 za unapređenje proizvodnih sistema uočava se trend korišćenja IoT tehnologija u sva tri rada samostalno ili u kombinaciji sa nekim drugim tehnologijama:

- Miskiewicz i Wolniak[85] fokusirali su se na unapređenje proizvodnog sistema za preradu čelika primenom *Cloud* sistema računarske tehnologije i IoT uređaja koristeći MQTT (*Message Queuing Telemetry Transport*) protokol;
- Papetti i sar. [86] su predstavili transdisciplinarnu inženjersku metodu za merenje i promociju društvene održivosti na proizvodnim mestima koristeći IoT tehnologiju za podršku dizajniranju proizvodnih procesa i postrojenja ka povezanim fabrikama usmerenim na čoveka, gde je izvršena validacija predložene metode u proizvodnom sistemu za izradu obuće;
- Wang i sar. [87] predložili su arhitekturu distribuiranog i fleksibilnog rasporeda poslova zasnovanog na *Edge* sistemu računarske tehnologije i industrijskog IoT kako bi se poboljšala sposobnost sistema za raspoređivanje u trenutku prikupljanja podataka kao i podrška za donošenje odluka u proizvodnom sistemu.

Na osnovu analiziranih relevantnih radova koji predstavljaju studije slučaja o unapređenju proizvodnih sistema u procesnoj industriji, dolazi se do zaključka da se unapređenje i dalje pretežno fokusiraju na primeni *Lean* koncepta (47% relevantnih radova) u protekloj deceniji. Takođe, unapređenja u proteklih 10 godina se zasnivaju na tehnologijama i konceptima iz

Digitalne revolucije, a ne primenom koncepta Industrije 4.0 koji se promoviše od kraja 2011. godine. Međutim, i kada se izvrši unapređenje proizvodnog sistema pomoću koncepta Industrije 4.0, primenom naprednih tehnologija je dosta ograničena. Na osnovu toga može da se zaključiti da postoje određene poteškoće za unapređenje proizvodnih sistema primenom naprednih tehnologija na kojima se i zasniva koncept Industrije 4.0. Stoga, u narednom poglavljju se razmatraju problemi i izazovi koji prate proces unapređenja proizvodnih sistema praktičnom primenom koncepta Industrije 4.0.

2.3.2. Izazovi unapređenja proizvodnih sistema primenom Industrije 4.0

Nedavno je četvrta industrijska revolucija, Industrija 4.0, postala jedna od glavnih tema istraživanja i diskusija industrije i akademskih krugova u oblasti menadžmenta i inženjerstva [23], [88]. Jednostavno gledajući isključivo broj naučnih radova koji se bave temom Industrije 4.0, može se zaključiti da ukupan broj publikacija raste velikom brzinom. Konkretno, prilikom pretraživanja baze podataka *Scopus* sa frazom „*industr** 4.0“ u naslovu, apstraktu ili ključnim rečima, u periodu od 2012. do 2018. godine bilo je 5.986 publikacija, od kojih je gotovo 39% objavljeno u 2018. godini [7]. Iako je koncept Industrije 4.0 trenutno veoma aktuelna tema od koje se očekuje da će dovesti do značajnih promena u načinu proizvodnje u proizvodnjim sistemima [43], dokazi o primeni Industrije 4.0 u praksi su veoma retki. Može se tvrditi da je Industrija 4.0 još uvek u fazi „konceptualnih rešenja“, sa naučnom literaturom koja se fokusira na koncept pružajući oskudne dokaze o njegovoj primeni u praksi. Štaviše, izveštaji o primeni Industrije 4.0 obično su ograničeni na pilot studije [89]–[94] koje imaju ograničene efekte na celu kompaniju. Ovo zaostajanje u izveštavanju o primeni Industrije 4.0 još je veće kada uzmemu u obzir izveštavanje o poteškoćama koje kompanije imaju prilikom primene koncepta Industrije 4.0 u praksi za unapređenje proizvodnih sistema. Ovakve poteškoće unapređenja proizvodnih sistema nazivamo **izazovima implementacije Industrije 4.0**. Stoga, izazovi implementacije Industrije 4.0 se definišu kao *prepreke, poteškoće ili problemi koji se pojavljuju (ili se očekuje da će se pojaviti) u procesu implementacije Industrije 4.0 u proizvodnim sistemima*. Budući da ovi izazovi u praksi sprečavaju veću primenu Industrije 4.0, neophodno je usredsrediti istraživačke napore na različite izazove implementacije Industrije 4.0 sa kojima se kompanije suočavaju radi unapređenja proizvodnih sistema.

Dalje, preliminarni pregled literature urađen za potrebe ove doktorske disertacije (vidi rad [7]) pokazao je da sveobuhvatna analiza izazova implementacije Industrije 4.0 ne postoji, iako postoji neizrečeni konsenzus između istraživača i inženjera da izazovi u primeni postoje. Stoga, u naučnim radovima [7] i [95] pokušali smo da popunimo prazninu u literaturi pružajući sveobuhvatan pregled izazova u primeni Industrije 4.0. To je učinjeno kroz induktivni sistematski pregled literature relevantnih radova koji izveštavaju o izazovima implementacije

Industrije 4.0. Analiza je pokazala da se izazovi primene Industrije 4.0 mogu podeliti na **menadžerske i tehnološke izazove**.

- **Menadžerski izazovi implementacije Industrije 4.0** [7] – su izazovi koji se odnose na upravljačka pitanja u primeni Industrije 4.0 za unapređenje proizvodnih sistema. Na primer, ovi izazovi mogu biti nedostatak finansijskih sredstava, nedostatak ljudskih resursa, pitanja bezbednosti itd. Upravljački izazovi mogu biti povezani ili sa celokupnom primenom koncepta Industrije 4.0 ili sa primenom definisane tehnološke kategorije Industrije 4.0.
- **Tehnološki izazovi implementacije Industrije 4.0** [95] - su izazovi koji se odnose na određena tehnološka pitanja u primeni Industrije 4.0 za unapređenje proizvodnih sistema. Na primer, ovi izazovi mogu biti povezani sa nekompatibilnošću uređaja, analizom podataka, razvojem algoritma, itd. Tehnološki izazovi su po svojoj prirodi povezani sa primenom određene tehnološke kategorije.

2.3.2.1. Menadžerski izazovi implementacije Industrije 4.0 za unapređenje proizvodnih sistema

Analiza menadžerskih izazova implementacije Industrije 4.0 [7] za unapređenje proizvodnih sistema je pokazala da se ova grupa izazova može odnositi na:

- izazove sveobuhvatne implementacije Industrije 4.0, i
- izazove implementacije za primenu definisane tehnološke kategorije Industrije 4.0.

Izazovi sveobuhvatne implementacije Industrije 4.0 mogu biti:

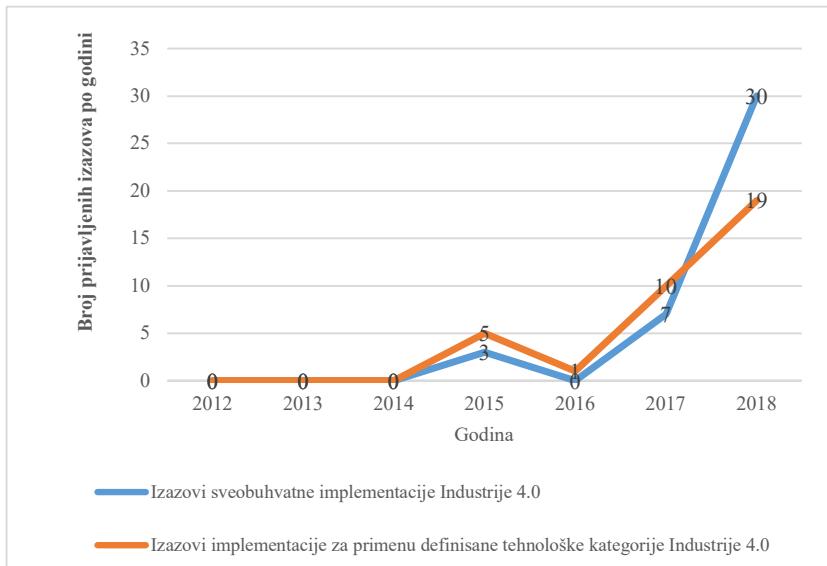
- *izazovi vezani za tehnologiju* (npr. povezani sa poteškoćama upravljanja tehnologijom, poteškoće upravljanja operacijama);
- *izazovi vezani za podatke* (npr. nestruktuirani podaci, velike količine prikupljenih podataka, nemogućnost pronalaženja korisnih informacija);
- *izazovi vezani za ljudske resurse* (npr. neobučeni radnici, otpor radnika ka novim tehnologijama);
- *izazovi vezani za bezbednost* (npr. nedovoljno bezbedne informaciono-komunikacione mreže, kao i nedovoljno obezbeđeni podaci);
- *izazovi vezani za finansijske resurse* (npr. potreba za velikim ulaganjem kompanija za unapređenje proizvodnih sistema);
- *izazovi vezani za proizvodne sisteme* (npr. nedovoljno razvijena infrastruktura proizvodnog sistema, visoka kompleksnost proizvodnog sistema);
- *izazovi vezani za standardizaciju* (npr. nedostatak ujednačenih standarda);
- *izazovi vezani za komunikaciju* (npr. nedostatak Interneta u nerazvijenim zemljama);
- *izazovi vezani za strategiju* (npr. nedostatak razrađene strategije za implementaciju Industrije 4.0 radi unapređenja proizvodnih sistema);

- *izazovi vezani za životnu sredinu* (npr. potreba za sprečavanjem potencijalnih neželjenih efekata na životnu sredinu primene koncepta Industrije 4.0).

Izazovi implementacije za primenu definisane tehnološke kategorije Industrije 4.0 mogu biti:

- *menadžerski izazovi za implementaciju sajber-fizičkih sistema* (npr. neophodnost velikih ulaganja u tehnologiju sajber-fizičkih sistema, kao i obučavanje radnika, nedostatak integracije proizvodnih sistema);
- *menadžerski izazovi za implementaciju Interneta stvari* (npr. poteškoće pri instalaciji sistema komunikacije zasnovanim na Internetu stvari u proizvodnim pogonima, otpor ka prihvatanju nove tehnologije Interneta stvari);
- *menadžerski izazovi za implementaciju analitike velikih podataka* (npr. nedostatak obučenih ljudi za primenu tehnologije za analitiku velikih podataka, nemogućnost razvoja pouzdanog algoritma na principima analitike velikih podataka);
- *menadžerski izazovi za implementaciju Cloud sistema računarske tehnologije* (npr. nedovoljan nivo razvijenosti Cloud tehnologije);
- *menadžerski izazovi za implementaciju Fog i Edge sistema računarske tehnologije* (npr. nedostatak integracije proizvodnog sistema korišćenjem Fog i Edge tehnologije);
- *menadžerski izazovi za implementaciju proširene i virtuelne realnosti* (npr. nedostatak integracije proizvodnog sistema korišćenjem tehnologije proširene i virtuelne realnosti);
- *menadžerski izazovi za implementaciju aditivne proizvodnje* (npr. nedostatak obučenih radnika za primenu tehnologije aditivne proizvodnje, neophodnost velikih ulaganja u opremu za aditivnu proizvodnju);
- *menadžerski izazovi za implementaciju više različitih tehnologija odjednom* -
 - *Internet stvari i aditivna proizvodnja* (npr. nedostatak integracije proizvodnih sistema i nemogućnost masovne proizvodnje prema individualnim zahtevima kupca za zajedničku implementaciju Interneta stvari i aditivne proizvodnje);
 - *Internet stvari, analitika velikih podataka i robotika* (npr. zakonska ograničenja za robotiku za zajedničku implementaciju Interneta stvari, analitike velikih podataka i robotike);
 - *sajber-fizički sistemi, Internet stvari i Cloud sistem* (npr. nedostatak finansijskih sredstava za zajedničku primenu sajber-fizičkih sistema, Interneta stvari i Cloud tehnologije);
 - *sajber-fizički sistemi, Internet stvari, analitika velikih podataka i Cloud sistemi* (npr. prepreke prikupljanja podataka prilikom zajedničke implementaciju sajber-fizički sistema, Interneta stvari, analitike velikih podataka i Cloud tehnologije).

Broj prijavljenih menadžerskih izazova za implementaciju Industrije 4.0 rastao je kako za sveobuhvatnu implementaciju, tako i za implementaciju definisane tehnološke kategorije. Prema urađenoj analizi (grafik 1 - [7]), za 2018. godinu, broj prijavljenih izazova za celokupnu primenu bio je za polovinu veći od broja izazova za primenu definisane tehnološke kategorije. Međutim, sazrevanjem i širom primenom Industrije 4.0, može se očekivati da će se u bliskoj budućnosti broj prijavljenih menadžerskih izazova za primenu definisanih tehnoloških kategorija povećati i na kraju premašiti broj prijavljenih izazova sveobuhvatne implementacije Industrije 4.0.



Grafik 1. Broj prijavljenih menadžerskih izazova implementacije Industrije 4.0 po godinama podeljenih na [7]:

- (a) izazove sveobuhvatne implementacije Industrije 4.0 i
- (b) izazove implementacije za primenu definisane tehnološke kategorije Industrije 4.0

Na osnovu dalje analize može se tvrditi da **analitika velikih podataka trenutno predstavlja najznačajnije tehnološko „usko grlo“ pri implementaciji Industrije 4.0 za unapređenje proizvodnih sistema** (nakon koje odmah slede sajber-fizički sistemi i Internet stvari izazovi za implementaciju) [7]. Na osnovu ovog zaključka može se očekivati da će u bliskoj budućnosti značajna pažnja istraživača i industrije biti usmerena na rešavanje izazova primene povezanih sa **analitikom velikih podataka**. Takođe, postoje neke tehnologije koje same za sebe ne prijavljuju ni jedan izazov (tj. robotika, sajber bezbednost i semantičke veb tehnologije). Upotreba ovih tehnologija ili naprednog dela ovih tehnologija (npr. upotreba kobota u robotici) u Industriji 4.0 je i dalje u razvojnoj fazi. Shodno tome, iako su u zajednici prepoznati kao izazovi može se tvrditi da izazovi za ove tehnološke kategorije još uvek nisu prijavljeni u naučnoj literaturi.

2.3.2.2. Tehnološki izazovi implementacije Industrije 4.0 za unapređenje proizvodnih sistema

Analiza tehnoloških izazova implementacije Industrije 4.0 za unapređenje proizvodnih sistema pokazala je da na izazove implementacije određene tehnološke kategorije može uticati sama kategorija, ali i druge nezavisne tehnološke kategorije [95]. Stoga, tehnološki izazovi implementacije Industrije 4.0 su identifikovani za sledeće pojedinačne tehnološke kategorije:

- **sajber-fizički sistemi**, kod kojih izazovi mogu da se odnose na:
 - *sajber-fizičke sisteme* (npr. nemogućnost integracije fizičkih i virtuelnih delova, nemogućnost kreiranja pametne automatizovane linije, nedostatak sigurnosti u tehnologiji sajber-fizičkih sistema);
 - *Internet stvari* (npr. nedovoljno razvijena tehnologija Interneta stvari, razvoj servera u skladu sa standardima Interneta stvari, nemogućnost postizanja komunikacije između sajber-fizičkih sistema putem Interneta stvari);
 - *analitiku velikih podataka* (npr. nemogućnost interakcije između tehnologija analitike velikih podataka i sajber-fizičkih sistema, poteškoće u uspostavljanju obrade velike količine podataka, nekompatibilni formati podataka prikupljeni putem tehnologije sajber-fizičkih sistema, itd.);
 - *sajber bezbednost* (npr. osetljivost tehnologija sajber-fizičkih sistema na sajber napade, nedostatak pouzdanosti sajber tehnologije u sajber-fizičkim sistemima u pogledu podataka);
- **Internet stvari**, kod kojeg izazovi mogu da se odnose na:
 - *sajber-fizičke sisteme* (npr. nemogućnost snimanja podataka u tačnom trenutku njihovog generisanja);
 - *Internet stvari* (npr. nedostatak jedinstvenih standarda, nekompatibilnost uređaja za primenu Interneta stvari, nemogućnost upravljanja proizvodnom opremom, itd.);
 - *analitiku velikih podataka* (npr. poteškoće sa analizom podataka, problemi dimenzionalnosti podataka za mala i srednja preduzeća, neuskladenost prikupljenih podataka, itd.);
 - *sajber bezbednost* (npr. odsustvo sajber bezbednosti u tehnologiji Interneta stvari, neovlašćena upotreba podataka, nedostatak standardizovane bezbednosti na globalnom nivou u tehnologiji Interneta stvari, itd.);
- **analitika velikih podataka**, kod koje izazovi mogu da se odnose na:
 - *sajber-fizičke sisteme* (npr. nedostatak tehnološke podrške za uređaje zasnovanim na tehnologiji sajber-fizičkih sistema);
 - *Internet stvari* (npr. nedostatak standarda za određene domene);
 - *analitiku velikih podataka* (npr. poteškoće sa sakupljanjem velikih količina podataka u proizvodnji, poteškoće sa prikupljanjem više vrsta podataka, poteškoće

- sa skladištenjem velike količine prikupljenih podataka, nemogućnost utvrđivanja da li su skupovi podataka dobrog kvaliteta, itd.);
- *Cloud sisteme računarske tehnologije* (npr. nemogućnost postizanja integracije analitike velikih podataka i *Cloud* sistemima računarske tehnologije)
 - *sajber bezbednost* (npr. nedostatak bezbednosne strukture u proizvodnim sistemima);
- ***Cloud sistemi računarske tehnologije***, kod koje izazovi mogu da se odnose na:
 - *sajber-fizičke sisteme* (npr. problemi sa nedostatkom usklađenosti mašina);
 - *Internet stvari* (npr. dug odziv čekanja Internet komunikacije);
 - *analitiku velikih podataka* (npr. poteškoće u razvoju algoritama u realnom vremenu);
 - *Cloud sisteme računarske tehnologije* (npr. nemogućnost razvoja algoritama za analizu podataka u trenutku njihovog generisanja);
 - *sajber bezbednost* (npr. pitanja poverenja u tehnologiju sajber bezbednosti);
 - ***Fog i Edge sistemi računarske tehnologije***, kod kojih izazovi mogu da se odnose:
 - *analitiku velikih podataka* (npr. nemogućnost rukovanja velikim količinama podataka)
 - ***proširena i virtuelna realnost***, kod kojih izazovi mogu da se odnose na:
 - *Internet stvari* (npr. nemogućnost postizanja odgovarajuće komunikacije u različitim proizvodnim sistemima);
 - *proširenu i virtuelnu realnost* (npr. nedovoljno razvijena tehnologija, nedovoljno proučena ergonomija uređaja proširene i virtuelne realnosti, potreba za standardima za primenu proširene i virtuelne realnosti);
 - ***sajber bezbednost***, kod koje izazovi mogu da se odnose na:
 - *sajber bezbednost* (npr. nedostatak bezbednosnog aspekta u integraciji uređaja, pitanja bezbednosti bežične mreže);
 - ***aditivna proizvodnja***, kod koje izazovi mogu da se odnose na:
 - *aditivnu proizvodnju* (npr. neprilagođenost tehnologije aditivne proizvodnje, nedovoljno razrađena metodologija primene tehnologije aditivne proizvodnje).

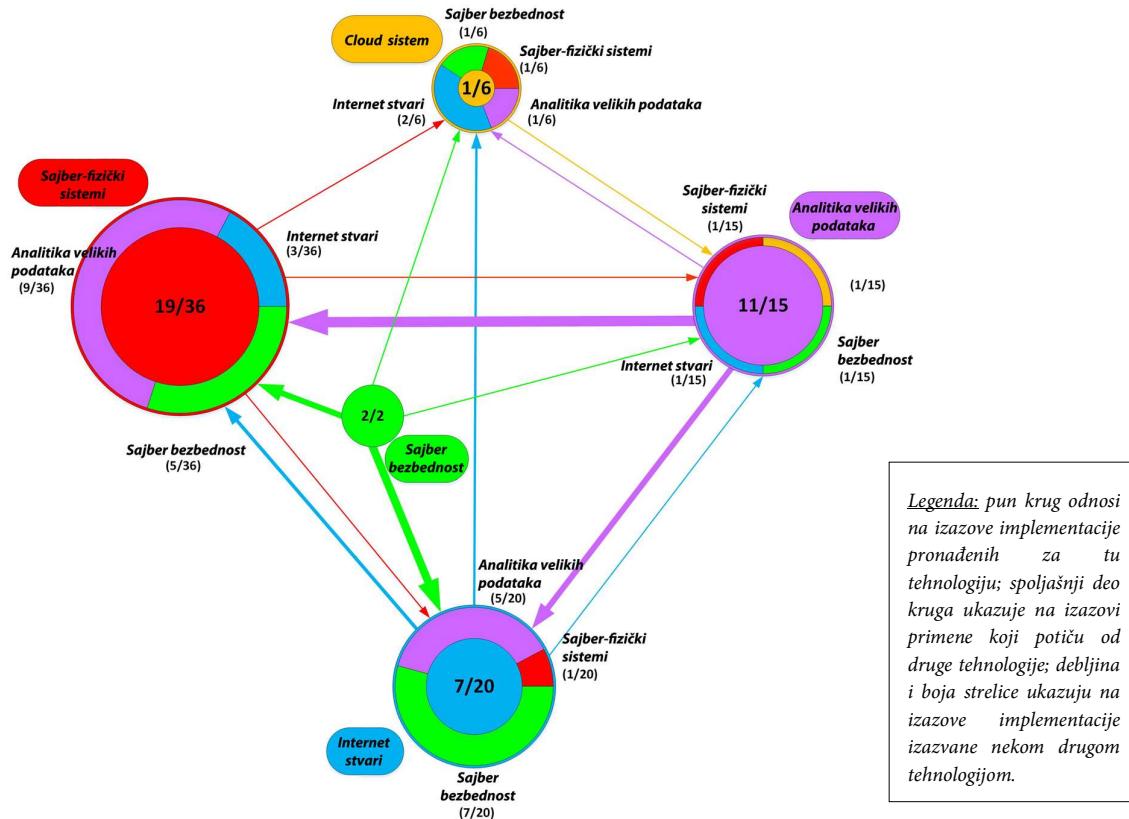
Pored izazova za pojedinačne tehnološke kategorije, tehnološki izazovi implementacije Industrije 4.0 su zabeleženi i pri implementaciji više različitih tehnologija odjednom [95], i to kod:

- ***Internet stvari i analitike velikih podataka***, kod kojih izazovi mogu da se odnose na:
 - *analitiku velikih podataka* (npr. ograničeni obim podataka, nemogućnost vizuelnog prezentovanja velikog broja podataka, potreba za adekvatnim razumevanjem podataka);

- ***Internet stvari i Cloud sistema računarske tehnologije***, kod kojih izazovi mogu da se odnose na:
 - *Cloud sisteme računarske tehnologije* (npr. neadekvatna analiza koju pružaju *Cloud sistemi računarske tehnologije*);
- ***Internet stvari, analitike velikih podataka i robotike***, kod kojih izazovi mogu da se odnose na:
 - *robotiku* (npr. ograničena upotreba autonomnih robota u proizvodnim sistemima)
- ***sajber-fizičkih sistema, Internet stvari i semantičke veb tehnologije***, kod kojih izazovi mogu da se odnose na:
 - *sajber-fizičke sisteme* (npr. integracija sajber-fizičkih sistema na niskom nivou);
 - *Internet stvari* (npr. nedostatak postojećih standarda Interneta stvari);
 - *analitiku velikih podataka* (npr. velika količina generisanih podataka)
- ***sajber-fizičkih sistema, analitike velikih podataka i semantičkih veb tehnologija***, kod kojih izazovi mogu da se odnose na:
 - *sajber-fizičke sisteme* (npr. integracija sajber-fizičkih sistema na niskom nivou);
 - *analitiku velikih podataka* (npr. poteškoće u rukovanju heterogenih podataka, poteškoće u obradi velikih podataka);
- ***sajber-fizičkih sistema, Internet stvari, analitike velikih podataka i Cloud sistema računarske tehnologije***, kod kojih izazovi mogu da se odnose na:
 - *Internet stvari* (npr. nedostatak jedinstvenih standarda u tehnologiji Interneta stvari).

Na osnovu analize relevantne literature [95] uočeno je da su tehnološke kategorije koje dominiraju u broju zabeleženih izazova sledeće: **sajber-fizički sistemi, Internet stvari, analitika velikih podataka i Cloud sistema računarske tehnologije** (slika 4). Stoga se može zaključiti da prvenstveno sajber-fizički sistemi, ali takođe i Internet stvari, analitika velikih podataka i Cloud tehnologija predstavljaju trenutni fokus primene Industrije 4.0 za unapređenje proizvodnih sistema. Možemo očekivati da će ove tendencije ostati i u bliskoj budućnosti kako za istraživače, tako i za industriju.

Međutim, **tehnološka kategorija koja u najvećoj meri sprečava implementaciju drugih tehnologija jeste analitika velikih podataka** (slika 4 – gde su debljine linija proporcionalne broju zabeleženih izazova za određenu tehnološku kategoriju). Ovakva situacija je donekle i očekivana s obzirom na činjenicu da je tehnologija analitike velikih podataka okarakterisana kao najveći izazov zabeležen i kod analize menadžerskhi izazova pri implementaciji Industrije 4.0 za unapređenje proizvodnih sistema (vidi potpoglavlje 2.3.2.1. *Menadžerski izazovi implementacije Industrije 4.0 za unapređenje proizvodnih sistema*).



Slika 4. Brojnost tehnoloških izazova za implementaciju Industrije 4.0 po tehnološkoj kategoriji i generisanje izazova od strane drugih tehnoloških kategorija [95]

2.4. Unapređenja proizvodnih sistema primenom analitičkih metoda

Koncept inteligentne proizvodnje predstavlja osnovu četvrte industrijske revolucije, odnosno Industrije 4.0 [30]. Industrija 4.0 transformiše mnoge sektore, posebno proizvodni, nudeći veću efikasnost na svim poljima kao i inovativna rešenja. Veća efikasnost proizvodnih sistema je omogućena zbog dostupnosti velike količine podataka generisanih tokom proizvodnih procesa pomoću kojih se postiže precizniji nivo odlučivanja. Količina dostupnih podataka konstantno raste iz godine u godinu, pri čemu razvoj naprednih tehnologija, pre svega razvoj IoT tehnologije, najviše doprinose ovom trendu [96], [97]. *Velike količine neobrađenih podataka* koje su generisane u proizvodnim sistemima pomoću Interneta stvari, nazvane su **veliki podaci (Big Data)** [97]–[99]. Oussous i njegovi saradnici [100] definisali su pojam velikih podataka kao „*velike rastuće skupove podataka koji uključuju heterogene formate: strukturirani, nestrukturirani i polustrukturirani podaci složenog karaktera koji zahtevaju moćne tehnologije i napredne algoritme za njihovu obradu*“.

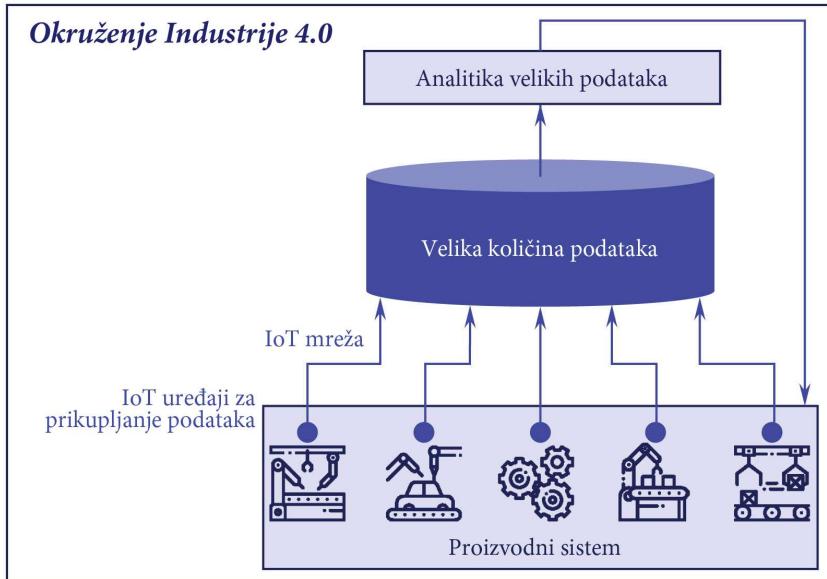
Nasuprot njima, Riahi i Riahi [101]

su dali precizniju definiciju velikih podataka osvrnuvši se na poteškoće kako u prikupljanju tako i u upravljanju heterogenim formatima i sve složenijim strukturama međusobno povezanih podacima.

Stoga, prema definiciji iz rada [101] zaključuje se da velike količine neobrađenih podataka sa sobom povlače i stvaraju nove izazove u proizvodnjim sistemima. Jedan od najprisutnijih problema sa kojima se suočavaju današnja akademija u saradnji sa industrijom jeste obrada i analiza velikih podataka [7], [95] koji se ne mogu obraditi i analizirati pomoću postojećih tehnoloških rešenja zbog nedovoljno velike računarske snage [102]. Dalje, ovako izuzetno *velike i složene skupove podataka potrebno je čuvati, obrađivati i analizirati pomoću naprednih softverskih aplikacija koje, kao krajnji rezultat, pružaju informacije, zasnovane na analitici velikih podataka (Big Data Analytics – BDA)*.

Međutim, u sistematskom pregledu literature Hashema i saradnika [103] koji su u svom istraživanju predstavili definicije, karakteristike i klasifikaciju velikih podataka, ustanovljeno je da su većina definicija orijentisane samo na velike količine neobrađenih podataka, dok se analiza podataka ne ističe kao osnovni korak u transformaciji podataka u korisne i neophodne informacije. Stoga, definicija analitike velikih podataka, koja je prihvaćena u ovoj doktorskoj disertaciji je preuzeta od [7], [95], glasi „*analitika velikih podataka predstavlja naprednu tehnologiju otkrivanja skrivenih informacija među velikim količinama podataka prikupljenih od strane različitih uređaja, koristeći napredne analitičke metode, kao što su rudarenje podataka, napredna statistička analiza, prediktivna analitika itd. koji omogućavaju donošenje odluka u trenutku njihovog prikupljanja*”.

Značaj analitike velikih podataka je istaknut i u radu [104] koji se bavi istraživanjem tehnologija koje pokreću novi koncept Industrije 5.0. To nam govori koliku važnost i velik uticaj imaju podaci i njihova analitička obrada prilikom unapređenja proizvodnih procesa, ali i da se trend upotrebe analitike velikih podataka neće promeniti u skorijoj budućnosti. Veliki podaci menjaju način na koji se donose odluke u proizvodnim sistemima, gde se stavlja akcenat na samostalno donošenje odluka od strane proizvodnih mašina [30]. Primena analitike velikih podataka u kombinaciji sa inovativnom IoT tehnologijom pruža mogućnost stvaranja inteligentnih, fleksibilnih proizvodnih sistema sposobnih da se samostalno konfigurišu, što ujedno predstavlja krajnji cilj Industrije 4.0 (slika 5). Samostalno konfigurisanje je zasnovano na objedinjavanju različitih naučnih oblasti, kao što su primenjena matematika, informatika i inženjerstvo [102]. Objedinjavanjem različitih naučnih oblasti, pronalaze se značajne informacije u velikim skupovima neobrađenih podataka, koristeći različite napredne statističke tehnike, zajedno sa tehnikama mašinskog učenja, koji igraju važnu ulogu u primeni novih tehnologija [105]–[107].



Slika 5. Veza između IoT tehnologije i analitike velikih podataka u okruženju Industrije 4.0

Da bi se postiglo samostalno konfigurisanje mašina u proizvodnim sistemima potrebne su pažljivo odabrane velike količine podataka. Međutim, sa velikom količinom podataka koji uključuju mnoge promenljive, može se uočiti više struktura i isprobati niz različitih pristupa. Ali veličina sama po sebi ne podrazumeva nužno bogatstvo strukture. Ono što skup podataka čini izazovnijim nije samo njegova veličina već i složenost. Složenost skupa podataka brzo se povećava sa povećanjem dimenzionalnosti. Sa ubrzanom primenom naprednih tehnologija, složene visokodimenzionalne baze podataka, promenljive dimenzije ili mešani tipovi podataka, nehomogenost, itd., više nisu retkost u industriji tokom proizvodnih procesa [105]. Da bi se analizirali i razumeli složeni skupovi podataka, potrebne su metode koje biraju istaknute karakteristike podataka, odbacujući šum i pružajući razumljive interpretacije podataka. Tako analizirani skupovi podataka su okarakterisani kao **kvalitetan skup podataka** [22]. Proces pronalaženja kvalitetnog skupa podataka u sirovom skupu, njegovo izdvajanje i pretvaranje podataka u informacije, predstavlja *otkrivanje znanja u bazama podataka (Knowledge Discovery in Databases - KDD)* [30]. Za prikupljanje podataka iz proizvodnog sistema moraju se koristiti napredne tehnologije, metode, algoritmi, kao i inovativna softverska rešenja [22], [30], [97].

Međutim, kao što je već napomenuto, veliki skupovi neobrađenih podataka sa sobom povlače nove izazove [97], [106] u proizvodnim sistemima, gde su najčešće zabeleženi izazovi vezani za obradu i analizu velikih podataka koje je teško ostvariti pomoću postojećih softverskih aplikacija i korišćenjem personalnih računara. Postojeće softverske aplikacije i personalni računari nemaju dovoljno veliku procesorsku snagu [89], [107]–[110]. Upravo zbog

toga, primena napredne tehnologije računarstva, kao što su *Cloud*, *Fog* i *Edge* sistemi računarske tehnologije za obradu i analizu podataka, zasnovane su na naprednim analitičkim tehnikama (kao što su napredna statistička analiza, mašinsko učenje i ekspertske sisteme) i veštačkoj inteligenciji [21], [36], [107], [111]–[115]. Obrada i analiza podataka podrazumeva upotrebu napredne tehnologije i analitičkih tehnika radi prepoznavanja skrivenih veza i obrazaca među podacima prikupljenim od strane različitih mašina i uređaja tokom proizvodnog procesa [102], [116]–[120]. Otkrivanje veza i obrazaca među neobrađenim podacima omogućava donošenje odluka u trenutku njihovog prikupljanja [22], [121] ili u vremenu približnom tom trenutku [122]. Analiza podataka u trenutku njihovog prikupljanja (ili u približnom trenutku) tokom proizvodnog procesa zasnovana je na principima rada modela koje imaju sposobnosti ranog otkrivanja problema. Među dostupnim istraživanjima analitike velikih podataka u trenutku prikupljanja podataka [123]–[125] akcenat se stavlja na *pranje rada* proizvodnih procesa i *kontrolu kvaliteta bez sposobnosti ranog otkrivanja neusaglašenosti* u proizvodnim sistemima.

3. ANALITIKA PROCESNIH PODATAKA

3.1. Procesni podaci u proizvodnim sistemima

Donošenje odluka u proizvodnim sistemima zahteva prisustvo informacija koje se dobijaju na osnovu prethodno obrađenih činjenica. Sirove činjenice generisane tokom proizvodnih procesa su poznatije pod terminom **procesni podaci**. Procesni podaci su generisani u vidu matrice sastavljene od redova i kolona. U većini slučajeva redovi predstavljaju sve identifikovane uticajne procesne parametre, dok kolone matrice odgovaraju svakom pojedinačnom slučaju (uzorku) generisanom tokom proizvodnog procesa. Matrice procesnih podataka se skladište u bazama podataka. Unutar proizvodnih sistema, baze podataka su namenjene za prikupljanje, organizovanje, čuvanje i manipulaciju procesnim podacima [126].

Procesni podaci sami po sebi nemaju značenje, već ga stiču tek kada se izvrši njihova interpretacija primenom nekih od analitičkih metoda za obradu, gde poprimaju značenje i postaju informacija [126]. Terminи *podatak* и *informacija* су usko povezani i često se koriste kao sinonimi. Međutim, neophodno je razlikovati ove termine. Informacija se definiše kao podatak koji je obrađen na takav način da se znanje osobe povećalo. Obrada podataka može biti jednostavna, kao što je tabelarni prikaz podataka, ili može biti kompleksna, kao što je primena neke od analitičkih metoda (naprednih statističkih metoda, metoda mašinskog učenja, veštačke inteligencije, ekspertnih sistema, fazi ekspertnih sistema, i sl.) nad sirovim procesnim podacima. Obrađeni podaci primenom analitičkih metoda služe kao pomoć pri donošenju odluka za unapređenje proizvodnih sistema, procesa i kvaliteta.

Stoga, na osnovu prethodno napisanog proizilazi [55]:

- procesni podaci su gradivni elementi informacija;
- informacije nastaju obradom podataka generisanih tokom proizvodnih procesa;
- informacije se koriste za otkrivanje značenja podataka;
- informacija koja je precizna, relevantna i dobijena na vreme je osnov za donošenje ispravnih odluka;
- ispravne odluke su ključ konkurentsnosti proizvodnih sistema na tržištu.

Raspoloživost informacije, koja direktno ili indirektno označava stanje procesa je preduslov za pokretanje akcija za poboljšanje i unapređenje sistema, procesa i kvaliteta. Ranije, procesni podaci su se prikupljali u cilju reaktivnog delovanja nakon nastanka određenih neusaglašenosti u proizvodnim sistemima. Međutim, sve se veći akcenat stavlja na proaktivni i prediktivni način delovanja unutar proizvodnih sistema [127], [128], gde je cilj omogućavanje detektovanja neusaglašenosti u trenutku njenog nastanka ili potpuno sprečavanje njenog

nastanka. Proaktivni i prediktivni načini delovanja, sa ciljem detektovanja neusaglašenosti što je moguće ranije, mogu se ostvariti prikupljanjem relevantnih procesnih podataka koji opisuju stanje sistema. Relevantni procesni podaci dovode do korisnih informacija. Stoga, tako generisani procesni podaci se moraju prikupljati tamo gde vrednosti podataka procesnih parametara **ne treba da sadrže nedosledne podatke, konstantne vrednosti niti podatke sa šumom.**

Takođe, procesni podaci se moraju *čuvati u odgovarajućem formatu* koji obezbeđuje lak pristup i obradu podataka. Formati za čuvanje podataka koji se najčešće koriste su .txt, .xls, .csv, .json, .xml, itd. Kao i sa svakim važnim resursom, podacima se mora pažljivo upravljati. Upravljanje podacima je disciplina koja se bavi prikupljanjem i skladištenjem podataka i njihovom obradom u cilju efikasnog dobijanja relevantnih informacija [126].

Pošto je utvrđena neophodnost upotrebe procesnih podataka, treba naglasiti da u mnogim proizvodnim sistemima ti podaci već postoje. Mogu se pojaviti u obliku popisa (listovi odštampani na računaru) koji su često u neupotrebljivom obliku za brzo rešavanje problema. S druge strane, oni mogu predstavljati procesne parametre unete gotovo pripremljenim redosledom u pripremljene obrasce. Često analiza procesnih parametara, zbog pogrešnog pristupa i načina obrade procesnih podataka, može dati pogrešne rezultate [55]. Prema tome, podaci koje je potrebno analizirati zavise od konkretnog tipa problema u proizvodnom sistemu u cilju njegovog unapređenja.

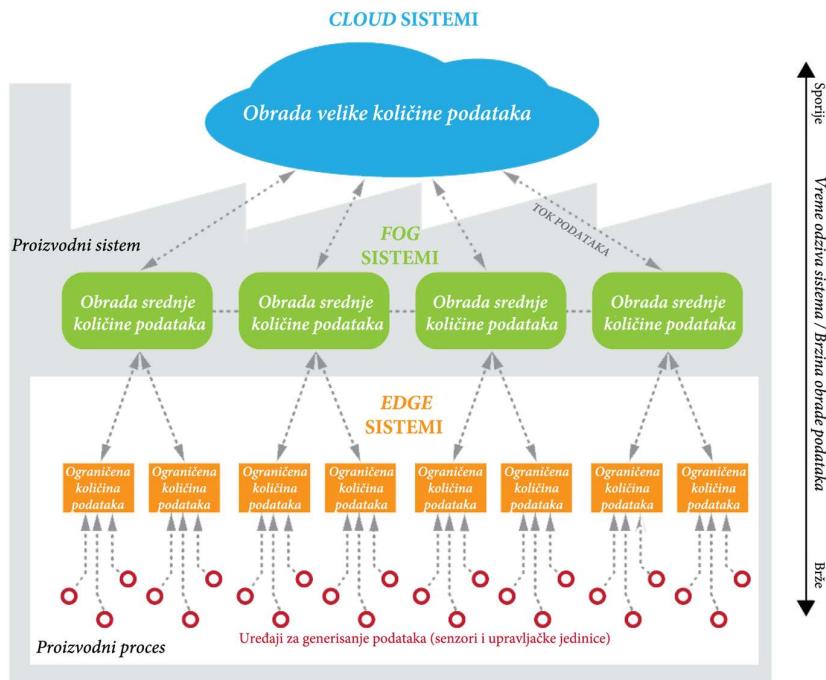
Skup relevantnih procesnih podataka je ključan kako bi se došlo do efikasnih alata za izbor adekvatne analitičke metode koji će na najbolji način pružiti uvid u stvarnu sliku stanja proizvodnih sistema. Da bi se skup procesnih podataka smatrao kvalitetnim, treba da se sastoji od određenog broja uzoraka kada je proizvodni sistem radio bez problema, prekida i poteškoća, kao i od određenog broja podataka kada su se u proizvodnim sistemima javili određeni problemi. Takav skup procesnih podataka predstavlja **izbalansiran skup podataka** [129] koji opisuje različita stanja proizvodnog sistema tokom proizvodnih procesa.

U slučajevima konstantnog unapređenja proizvodnih sistema primenom različitih upravljačkih pristupa (*LEAN*, *Kaizen*, *World Class Manufacturing* (WCM), *Total Productive Maintenance* (TPM), *Total Quality Management* (TQM), itd.) mnoge neusaglašenosti nastale tokom proizvodnog procesa su u velikoj meri otklonjene. U takvim situacijama je izuzetno teško pronaći skladan odnos između broja uzoraka procesnih podataka koji nisu doveli do problema u proizvodnji i broja uzoraka procesnih podataka koji uslovljavanju određene probleme tokom proizvodnog procesa. Tako formiran skup podataka predstavlja **neizbalansiran skup** [130] gde ne postoji informacije kada su se u proizvodnom sistemu javile neusaglašenosti. U takvim slučajevima većina prikupljenih uzoraka procesnih podataka pripada jednoj određenoj klasi, a vrlo ograničen broj uzoraka procesnih podataka pripada

drugoj klasi ili ih uopšte nema, te ne postoji informacija o specifičnim stanjima proizvodnog sistema koje je potrebno detektovati. Provost [131] smatra da kada se proučavaju problemi sa neizbalansiranim skupom podataka, upotreba klasičnih analitičkih tehniki može biti kritična greška. To je razlog zašto je problemu neizbalansiranog skupa procesnih podataka trenutno posvećena velika pažnja prilikom unapređenja proizvodnih sistema, procesa i kvaliteta proizvoda [132]–[134].

3.2. Tehnologije koje omogućavaju primenu metoda napredne analitike procesnih podataka u proizvodnim sistemima

Prikupljanje procesnih podataka iz proizvodnog sistema u kombinaciji sa naprednim tehnologijama, kao što je IoT, pružaju mogućnost stvaranja inteligentnih, fleksibilnih sistema sposobnih da se samostalno konfigurišu primenom metoda napredne analitike. Da bi se postigli inteligentni i fleksibilni sistemi, potrebne su velike količine podataka [135]. Na taj način, pronalazi se značajna informacija u velikim bazama podataka, koristeći različite metode napredne analitike koje igraju važnu ulogu u primeni novih tehnologija [135]–[137], kao što su *Cloud*, *Fog* i *Edge* sistemi računarske tehnologije za skladištenje, obradu i analizu podataka [21] (slika 6).



Slika 6. Arhitektura Cloud, Fog i Edge sistema u proizvodnim sistemima (prilagođeno iz [113])

Sa tačke gledišta proizvodnih sistema, najznačajnija razlika između ova tri sistema, jeste u sposobnosti obrađivanja određenje količine sirovih procesnih podataka. Obrada velike količine sirovih procesnih podataka se vrši pomoću *Cloud* tehnologija, koje imaju veliku kompjutersku moć. Nasuprot tome, *Fog* i *Edge* tehnologije se koriste za obradu precizno definisanog skupa podataka, zbog organičnosti rezursa kompjuterske snage.

3.2.1. Internet stvari kao tehnologija za prikupljanje podataka

Danas, kada je sve veći broj uređaja spojenih na Internet mrežu, dolazi do razvoja nove napredne tehnologije nazvane *Internet stvari (IoT)* [44]. Ova tehnologija, zahvaljujući sposobnosti povezivanja različitih uređaja, komunikacionih tehnologija, senzorskih mreža, Internet protokola, uređaj za identifikovanje radio frekvencije (RFID) i tako dalje [97], koji poseduju jedinstvene šeme adresiranja, omogućavajući interakciju i saradnju između uređaja kako bi se postigli zajednički ciljevi pri generisanju velike količine sirovih procesnih podataka [44], [138].

Definisanje IoT-a u mnogome zavisi od gledišta istraživača i oblasti njihovog istraživanja. Na primer, Atzori, Iera i Morabito[138] tvrde da se IoT tehnologija zasniva na tri perspektive koje čine osnov ove tehnologije, odnosno „*stvari*“, „*Interneta*“ i „*semantike*“. U perspektivi IoT-a koja je orijentisana na stvari, „*stvari*“ se smatraju jednostavnim objektima, odnosno RFID uređajima, povezanim preko mreže. Takva mreža predstavlja perspektivu „*Interneta*“. Pored ove dve perspektive, „*semantička*“ perspektiva usmerena je na odgovarajuće modeliranje i jezičku podršku za opisivanje IoT objekata, rezonovanje podataka generisanih Internetom stvari, semantičko izvršno okruženje, komunikacionu infrastrukturu, kao i za arhitekturu koja odgovara IoT standardima za skladištenje prikupljenih podataka [138], [139]. Činjenica koja IoT razlikuje od postojećih tehnologija jeste brzina protoka informacija kao i brzina komunikacije, gde se omogućuje uređajima da izvrše detekciju, akciju i reakciju u trenutku prikupljanja podataka [97].

Sa tačke gledišta proizvodnih sistema, sve veća dostupnost podataka o proizvodnji menja način na koji se u industriji donose odluke u vezi sa unapređenjem proizvodnog sistema, procesa i kvaliteta proizvoda korišćenjem analitičkih metoda podataka [119]. Primena IoT tehnologije u proizvodnim sistemima, omogućava veću dostupnost procesnih podataka oslanjajući se na:

- Internet/Eternet,
- standardne industrijske komunikacione protokole (otvorena platforma komunikacije – OPC, otvorena platforma komunikacije sa jedinstvenom arhitekturom – OPC UA),
- RFID uređaje,
- programabilne logičke kontrolere (PLC), i
- senzore.

IoT u kombinaciji sa metodama napredne analitike podataka može da omogući prediktivnu proizvodnju umrežavanjem proizvodnih mašina [30] za obradu podataka u trenutku njihovog prikupljanja [140]. Stoga, definicija IoT tehnologije koja je prihvaćena u ovoj doktorskoj disertaciji (prilagođena iz [7]) i usmerena ka primeni u proizvodnim sistemima, glasi: „*IoT predstavlja mrežu koja omogućava komunikaciju između „stvari“ (tj. predmeta ili uređaja) korišćenjem senzora putem infrastrukture informacionih i komunikacionih tehnologija, što rezultira prikupljanjem procesnih podataka generisanih tokom proizvodnih procesa, detekcijom neusaglašenosti procesnih parametara i aktiviranjem povratne informacije u trenutku prikupljanja podataka*“.

3.2.2. Cloud sistemi računarske tehnologije za obradu velike količine podataka

Cloud sistemi predstavlja računarsku tehnologiju centralizovanog karaktera koja pruža usluge skladištenja, deljenja i obrade podataka putem vizuelnih i skalabilnih izvora pomoću Internet mreže [141], [142] primenom u proizvodnim sistemima (slika 6). Pored naglašenih karakteristika fleksibilnosti, skladištenja, jednostavne upotrebe i deljenja informacija, *Cloud* sistemi računarske tehnologije imaju veliku primenu u procesu analize podataka sa naglaskom na velike količine podataka generisanih iz proizvodnih sistema, jer nude računarsku infrastrukturu zasnovanu na velikoj računarskoj snazi [136], [141]. Time se omogućava brža obrada velike količine podataka, u odnosu na brzinu obrade podataka na personalnom računaru.

Međutim, posmatrajući činjenicu da se *Cloud* sistemi ne nalaze unutar proizvodnog sistema, već izvan njega, mogućnost razvoja modela sa sposobnostima ranog otkrivanja neusaglašenosti procesnih parametra u trenutku prikupljanja podataka predstavlja barijeru za implementaciju ovog rešenja [113]. Takođe, pitanje sigurnosti podataka predstavlja problem prilikom skladištenja i čuvanja podataka zbog posedovanja *Cloud* sistema od strane drugog lica, gde Kadhim, Yusof i Mahdi [138] objašnjavaju da je neophodno izvršiti zaštitu podataka postavljanjem sigurnosne lozinke.

Stoga, definicija *Cloud* sistema računarske tehnologije za obradu velike količine podataka koja je prihvaćena u ovoj doktorskoj disertaciji (prilagođena iz [7]) usmerena ka primeni u proizvodnim sistemima, glasi: „*Cloud sistemi računarske tehnologije predstavljaju računarsku uslugu koja pruža skladištenje, deljenje i obradu podataka pomoću vizuelnih i skalabilnih resursa putem Interneta bez mogućnosti dobijanja povratne informacije u tačnom trenutku njenog generisanja tokom proizvodnih procesa*“ (slika 6).

3.2.3. Fog sistemi računarske tehnologije za obradu srednje količine podataka

Fog sistemi predstavljaju računarsku tehnologiju decentralizovanog karaktera koja pruža usluge komunikacije i saradnje među uređajima putem mreže kako bi se obavljali procesi skladištenja i obrade prikupljenih podataka u proizvodnim sistemima (slika 6). Ovi procesi mogu biti podržani osnovnim mrežnim funkcijama ili novim servisima i aplikacijama primenom IoT tehnologije. Ovakvo razumevanje Fog sistema naglašava njegove osnovne karakteristike, kao što su poboljšane mrežnih sposobnosti i mogućnosti i bolja podrška za saradnju između mašina i uređaja [144].

Posmatrajući glavne karakteristike Fog i Cloud sistema, zbog delimičnog preklapanja oblasti, razlike među njima je neophodno naglasiti. Fog sistemi koriste srednje veliku količinu podataka (koja je nužno manja od količine koja se koristi u procesu obrađivanja kod Cloud sistema), omogućavajući njihovu obradu u fizičkoj blizini krajnjih uređaja, gde se i izvršilo generisanje i prikupljanje procesnih podataka što se odražava i na veću bezbednost podataka [113]. Ove karakteristike Fog sistema predstavljaju i najveću razliku u poređenju sa Cloud sistemima zbog bliske integracije sa krajnjim mašinama i uređajima. Takođe, integracija sa krajnjim mašinama i uređajima sa ugrađenom i povezanom veštačkom inteligencijom, Fog sistemima povećava ukupnu efikasnost unutar proizvodnih sistema, što dovodi i do poboljšavanja performansi i kritičnih pitanja implementacije sajber-fizičkih sistema. Naredna ključna razlika između Fog i Cloud sistema jeste u tome što Cloud sistemi pokušavaju da optimizuju resurse u globalnom pogledu, dok Fog sistemi organizuju i upravljaju lokalnim virtuelnim klasterima [145]. Dalje, brzina dobijanja povratne informacije koja odgovara približno tačnom trenutku prikupljanja podataka [122] je još jedna od karakteristika i prednosti Fog sistema [146] koja je ključna kada je neophodna brza reakcija unutar proizvodnih sistema.

Stoga, definicija Fog sistema kao tehnologija za obradu srednje količine podataka koja je prihvaćena u ovoj doktorskoj disertaciji (prilagođena iz [7]) usmerena ka primeni u proizvodnim sistemima, glasi: „*Fog sistemi računarske tehnologije predstavljaju računarsku uslugu koja se odnosi na decentralizovane računarske usluge za skladištenje, obradu i aplikacije koje se odvijaju blizu mesta generisanja podataka pružajući mogućnost primene naprednih analitičkih metoda za obradu podataka u približno tačnom trenutku prikupljanja procesnih podataka generisanih tokom proizvodnih procesa*“ (slika 6).

3.2.4. Edge sistemi računarske tehnologije za obradu ograničene količine podataka

Edge sistemi predstavlja računarsku tehnologiju decentralizovanog karaktera koja pruža usluge skladištenja, obrade i primene ograničene količine podataka unutar proizvodnih sistema (slika 6). Obzirom na činjenicu da su *Edge* sistemi implementirani direktno na mestu generisanja procesnih podataka u proizvodnim procesima, smanjuje se udaljenost koju podaci prelaze prilikom generisanja pomoću IoT mreže, a istovremeno se stvaraju i minimalna kašnjenja prilikom prikupljanja podataka [21]. Autori Bhandari i Gupta [130] posmatraju *Edge* sisteme kao optimizaciju tehnologije *Cloud* sistema obavljajući obradu podataka što je moguće bliže njihovim izvorima generisanja podataka. Rezultat optimizacije tehnologije *Edge* sistema ogleda se u značajnom poboljšanju skalabilnost i efikasnost korišćenjem ove tehnologije zbog činjenice da su opterećenja za obradu podataka značajno smanjena. Ovo, takođe, ima uticaj i na smanjenje mrežnog saobraćaja gde se koristi lokalna IoT mreža, a ne Internet konekcija zbog direktne implementacije *Edge* sistema u proizvodnim pogonima [147]. Eliminisanjem Interneta i korišćenjem lokalne mreže, povećava se sigurnost skladištenih i obrađenih podataka, koji predstavljaju jedan od glavnih zahteva u proizvodnim sistemima. Nedavno istraživanje, koje je otišlo korak dalje u budućnost baveći se istraživanjem tehnologija koje pokreću koncept Industrije 5.0 [104], opisuje značaj *Edge* sistema u praktičnoj primeni u proizvodnim sistemima, gde se koriste standardni hardverski i softverski resursi za razmenu informacija. U istraživanju je naglašeno da se primenom *Edge* sistema omogućava filtriranje procesnih podataka minimiziranjem količine podataka poslatih na centralizovani server što omogućava razmenu informacija u trenutku generisanja podataka.

Većina akademskih i industrijskih zajednica termine *Edge* i *Fog* koriste kao sinonime na osnovu njihovih sličnosti pri odabiru određene količine podataka i mestu njihovog generisanja. Istina jeste da su glavni ciljevi ova dva sistema identični, odnosno teže da pruže odgovor na obrađenu informaciju u trenutku njenog generisanja. Međutim, glavna razlika se ogleda u načinu na koji se obrađuju generisani podaci i računska snaga sistema koja je na strani *Fog*-a. Međutim, *Edge* sistemi predstavljaju relativno novu tehnologiju koja je još uvek u fazi razvoja, gde su prednosti ove tehnologije očigledne kada se vrši njeno poređenje sa *Fog* i *Cloud* sistemima što se tiče brzine odaziva sistema. Međutim, glavna barijera pri implementaciji *Edge* sistema jeste ograničena količina podataka, koja mora biti pažljivo odabrana [148]. Takođe, *Edge* sistemi imaju značajno manju računarsku snagu u poređenju sa prethodna dva sistema iz razloga što su i konstruisani za obradu ograničene količine podataka [36], tako da se javlja prostor za izostanak važnih podataka iz proizvodnog sistema, koji direktno utiču na kvalitet razvijenog matematičkog modela.

Stoga, na osnovu svega prethodno obrazloženog definicija *Edge* sistema kao tehnologija za obradu ograničene količine podataka koja je prihvaćena u ovoj doktorskoj disertaciji

(prilagođena iz [7]) usmerena ka primeni u proizvodnim sistemima, glasi: „*Edge sistemi računarske tehnologije predstavljaju računarsku uslugu koja se odnosi na decentralizovane računarske usluge za skladištenje, obradu i aplikacije koje se odvijaju na mestu generisanja podataka pružajući mogućnost primene naprednih analitičkih metoda za obradu podataka u tačnom trenutku prikupljanja procesnih podataka generisanih tokom proizvodnih procesa*“ (slika 6).

3.3. Metode napredne analitike procesnih podataka u proizvodnim sistemima

U današnje vreme sa razvojem naprednih tehnologija primenjenih u proizvodnim procesnim ne može da se govori o „nedostatku procesnih podataka“. Bez obzira o kakovom proizvodnom procesu je reč (da li su u pitanju mala, srednja ili velika preduzeća ili koliko je zahtevan sam proces) mernih instrumenata koji beleže vrednosti procesnih parametara ima na pretek [149]. Vrednosti procesnih parametara su dostupne u tačno definisanim vremenskim intervalima (na svaki sekund, minut, sat, itd.) u kojima se vrši njihovo kontinualno beleženje. Na ovaj način dobija se velika količina procesnih podataka za svaki procesni parametar iz kojih je neophodno izvući informacije. Informacije se dobijaju primenom analitičkih metoda za razvoj matematičkog modela na osnovu skupa procesnih podataka.

Međutim, klasične metode analitike podataka ne daju zadovoljavajuće rezultate. Stoga je sve češća upotreba metoda napredne analitike, koja se može podeliti na:

- metode napredne statistike,
- metode mašinskog učenja i
- metode fazi logike.

U nastavku poglavља detaljnije su objašnjene metode napredne analitike za obradu procesnih podataka u proizvodnim sistemima.

3.3.1. Napredne statističke metode

Statističke metode, u naučnom smislu, koriste se za analizu velikih grupa brojeva gde se meri učestalost, distribucija, slučajnost i uzročno-posledična veza tačaka podataka u naučnim studijama. Pored toga, statističke metode se koriste za određivanje mera centra, širenja i relativne frekvencije [150]. U osnovi, većina statističkih studija, ima za cilj da utvrdi kako su brojevi koji čine podatke povezani jedni s drugima, koji parametri su uticajni i, možda najvažnije u bilo kojoj studiji ili istraživačkom zadatku, *šta nam sakupljeni podaci govore?*

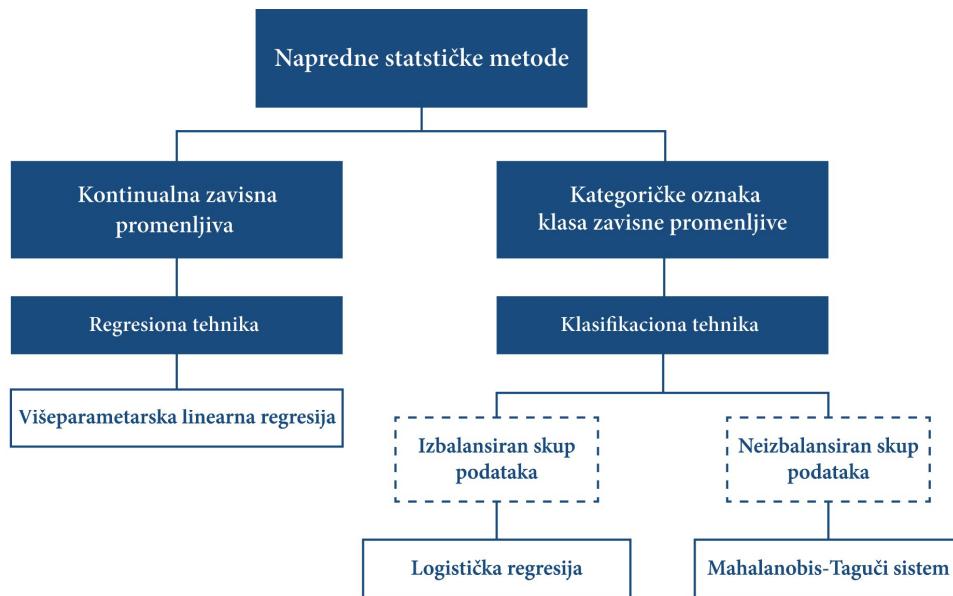
Odgovor na ova pitanja leži u primeni i korišćenju matematičkih modela razvijenih pomoću statističkih metoda. Treba primetiti da kada se statistika koristi u svrhu razvoja

matematičkog modela za različite vrste predviđanja, tada govorimo o **naprednim statističkim metodama**. Napredne statističke metode omogućavaju korišćenje različitih statističkih tehnika koje zajedno sa specijalizovanim softverima mogu pomoći u određivanju uzročno-posledične veze između unosa podataka i predviđanju budućih ishoda skupa okolnosti sa najvećom verovatnoćom. Matematički modeli razvijeni pomoću tehnika naprednih statističkih metoda se koriste za predviđanje ishoda u finansijama, marketingu, medicini i proizvodnim sistemima [150]. Najčešće korišćenje tehnike napredne statističke metode jesu [151]–[153]:

- višeparametarska linearna regresija (*Multiple Linear Regression – MLR*),
- logistička regresija (*Logistic Regression – LR*), i
- Mahalanobis-Taguchi sistem (*Mahalanobis-Taguchi System – MTS*).

Ove tehnike se mogu svrstati u dve grupe na osnovu načina razvoja modela prema definisanom problem (slika 7), i to na [154]:

- *regresione tehnike napredne statističke metode i*
- *klasifikacione tehnike napredne statističke metode.*



Slika 7. Klasifikacija naprednih statističkih metoda

3.3.1.1. Regresiona tehnika napredne statističke metode

Regresiona tehnika napredne statističke metode je studija koja daje odgovor na pitanje kako zavisna promenljiva zavisi od jedne ili više nezavisnih promenljivih (slika 7). Obično se prepostavlja da je zavisnost izražena kroz srednju vrednost, a na srednju vrednost ili regresionu funkciju mislimo kao na opisivanje kako sredina odgovora zavisi od prediktora.

Iako se neki problemi sa regresijom mogu korisno sažeti koristeći neparametrijske metode regresije koje čine minimum prepostavki, dodavanje nekoliko verovatnih prepostavki omogućava upotrebu parametarskih modela za regresiju koji daju jednostavne rezultate [155].

Važna karakteristika regresione tehnike napredne statističke metode predstavlja definisanje problema na osnovu kontinualnih nezavisnih promenljivih u slučaju kada je zavisna promenljiva kontinualna, odnosno kvantitativna vrednost na osnovu kojih se donose odluke. Obzirom na činjenicu da u proizvodnim sistemima postoji više od jedne nezavisne značajne promenljive, regresiono definisanje problema vrši predviđanje tačno iskazane vrednost, gde se mogu primenjivati više različitih matematičkih modela, od kojih je najjednostavnija i najčešće primenjivana višeparametarska linearna regresija [156]. Modeli razvijeni na principima višeparametarske linearne regresije se često koriste za unapređenje procesa i kvaliteta proizvoda u proizvodnim sistemima gde se postižu zadovoljavajući rezultati [157]–[160].

3.3.1.1. Višeparametarska linearna regresija

Višeparametarska linearna regresija predstavlja naprednu statističku metodu koja se isključivo koristi pri rešavanju regresionih problema kada je zavisni parametar kontinualna numerička vrednost (slika 7) [116]. Princip na kojem se zasniva višeparametarska linearna regresija jeste generalizacija jednoparametarske linearne regresije uzimajući u obzir više nezavisnih parametara pri kreiranju matematičkog modela [156] na osnovu sledeće formule [161], [162]:

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_kx_k + e \quad (1)$$

gde je:

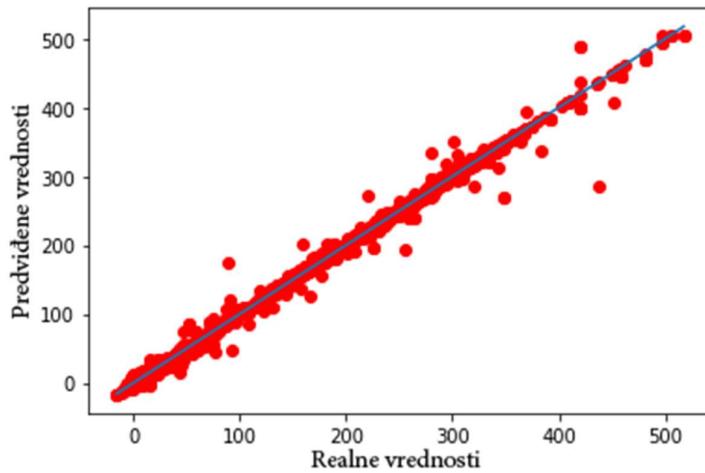
b – regresioni koeficijent ($b = 0, 1, 2, \dots, k$),

x – nezavisni parametri ($x = 0, 1, 2, \dots, k$),

y – zavisni parametar,

e – Gausova greška.

Model razvijen na principu višeparametarske linearne regresije koristi linearu površinu, odnosno ravan ili hiper-ravan (slika 8), kako bi se odredio odnos između zavisnog parametra i skupa nezavisnih procesnih parametara predviđanja [163]. Prilikom razvoja matematičkog modela mora se strogo voditi računa o tipu prikupljenih podataka nezavisnih parametara, koji ne smeju da budu kategoričke vrednosti zbog validnosti rezultata predviđanja. Nettleton [164] navodi da se kategoričke vrednosti moraju kodirati pomoću binarnih vrednosti ili pronaći neki drugi način kako da se izraze putem kontinualnih brojeva.



Slika 8. Višeparametarska linearna regresija, gde plava linija predstavlja ravan (idealno predviđene vrednosti), dok crvene tačke označavaju realne vrednosti dobijene pomoću matematičkog modela

Prema Sarstedtu i Mooiu [164] postoji nekoliko zahteva koji se tiču nezavisnih parametara i koje je neophodno ispuniti pre razvoja modela na principu višeparametarske linearne regresije, a to su:

- **veličina uzorka** – odnosi se na prihvativljivu količinu uzoraka, odnosno podrazumeva određivanje minimalne veličine uzoraka u odnosu na broj nezavisnih promenljivih (koji se po pravilu uzima da je minimalno 10 puta veći od broja nezavisnih parametara [165]);
- **heterogenost uzorka** – odnosi se na raznovrsnost među uzorcima zavisnih procesnih parametara. Ukoliko nema raznovrsnosti među uzorcima, model na principima višeparametarske linearne regresije neće moći da se razvije;
- **kolinearnost** – odnosi se na međusobnu zavisnost između nezavisnih parametara. Velika kolinearnost među parametrima (preko 0.7), odražava se na koeficijente modela i smanjuju mogućnost upotrebe nezavisnih parametara kao pokazatelja relativnog uticaja [166].

3.3.1.2. Klasifikacione tehnike napredne statističke metode

Veliki višeparametarski skupovi procesnih podataka, generisani tokom proizvodnih procesa, mogu se pokazati teškim za razumevanje te je neophodno imati metode sažimanja i izdvajanja informacija iz njih (slika 7). Predmet klasifikacione analize bavi se istraživanjem skupova formiranih na osnovu određenih sličnosti kako bi se utvrdilo da li se oni mogu valjano sažeti u smislu malog broja sličnih klasa [167]. Prema tome, klasifikacione tehnike napredne statističke metode predstavljaju studiju koja daje odgovor na pitanje kako se na osnovu

nezavisnih promenljivih (procesnih parametara) u funkciji zavisne promenljive, koja može da ima dve ili više klase, donose zaključci iz posmatranih vrednosti nezavisnih promenljivih.

U zavisnosti od problema, osnovna svrha studije klasifikacione tehnike napredne statističke metode može biti ili razvoj tačnog klasifikatora ili model za otkrivanje prediktivne strukture problema [105]. Međutim, jedan model ne isključuje nužno drugi, već je cilj njihovo dopunjavanje. Stoga, važan kriterijum za dobar odabir klasifikacione tehnike napredne statističke metode je da on ne samo da daje tačne klasifikatore (u granicama podataka), već i pruža uvid i razumevanje prediktivne strukture podataka.

Primer klasifikacione tehnike napredne statističke metode sa svrhom razvoja matematičkog modela koji će imati karakteristike i tačnog klasifikatora i tačnog predviđanja, jeste pimena u proizvodnim sistemima. U proizvodnim sistemima postoji više od jedne nezavisne značajne promenljive, klasifikacione tehnike napredne statističke metode vrše predviđanje vrednost jednog ili više ishoda, ali i njegovu klasifikaciju, odnosno razvrstavanja nepoznate instance u jednu od unapred ponuđenih klasa. Ovaj postupak se zasniva na pronalaženju sličnosti sa unapred određenim objektima koji su pripadnici različitih klasa, pri čemu se sličnost dva objekta određuje analizom njihovih karakteristika sa određenom tačnošću. Na osnovu toga, zadatak klasifikacionih tehnika napredne statističke metode u proizvodnim sistemima jeste razvoj matematičkog modela na osnovu koga će se vršiti klasifikacija novih uzoraka, gde je broj klasa unapred poznat i ograničen [168].

Najčešće primenjivana klasifikaciona tehnika napredne statističke metode jeste logistička regresija za unapređenje procesa i kvaliteta proizvoda u proizvodnim sistemima [169]–[171]. Međutim, kada je neophodno unaprediti procese ili kvalitet proizvoda u proizvodnim sistemima na osnovu generisanog neizbalansiranog skupa procesnih podataka, primenjuje se Mahalanobis-Tagući sistem (MTS) klasifikaciona tehnika napredne statističke metode [172]. Rast primene MTS tehnike za unapređenje proseca i kvaliteta proizvoda je vidljiv u porastu broja naučnih radova u naučnim bazama podataka [22], [173], [174].

3.3.1.2.1. Logistička regresija

Logistička regresija predstavlja naprednu statističku metodu za razvoj modela koja se isključivo koristi pri rešavanju klasifikacionih problema u kojoj zavisni parametar mora biti kategoričkog, odnosno binarnog karaktera [118], [163] (slika 7). Na osnovu binarnog karaktera zavisnog parametra definisane su određene klase (npr. klase 1 ili 0, da ili ne, itd.) prema sledećoj formuli [163]:

$$y = \frac{e^{b_0 + b_1 x}}{1 + e^{b_0 + b_1 x}} \quad (2)$$

gde je:

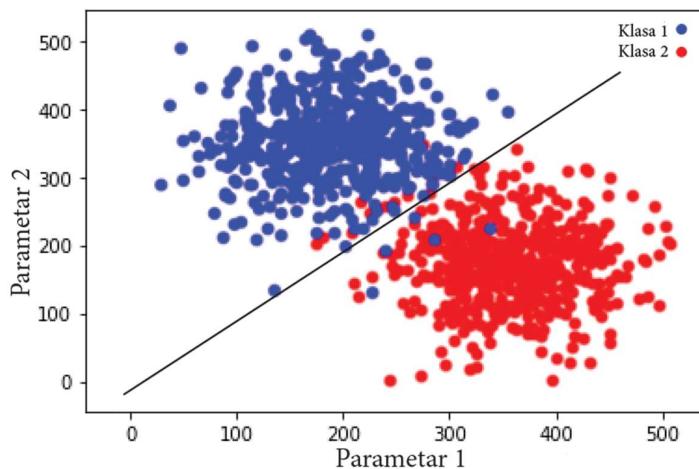
b – regresioni koeficijent ($b = 0, 1, 2, \dots, k$),

x – nezavisni parametri ($x = 0, 1, 2, \dots, k$),

y – zavisni parametar,

e – prirodni logaritam.

Na slici 9 je grafički predstavljen model logističke regresije gde su prikazane dve klase podataka (crvena i plava), kao i vrednost (prava linija) koja određuje granicu između te dve klase.



Slika 9. Logistička regresija, gde crna linija predstavlja ravan koja deli dve klase podataka. Crvene tačke predstavljaju parametre jedne klase, dok plave tačke predstavljaju parametre druge klase

Modeli logističke regresije se koriste za predikciju trendova proizvodnih sistema u određenom vremenskom periodu na osnovu trenutnog znanja eksperata, prethodno zabeleženih performansi sistema, itd., što predstavlja nezavisne parametre u definisanoj bazi podataka. Odabir nezavisnih procesnih parametara se vrši zbog identifikacije i utvrđivanja baze podataka koji su u najvećoj meri povezani sa zavisnim parametrom i koji imaju uticaj na njegovu promenu. Izbor nezavisnih parametara je praćen tehnikama koje procenjuju preciznost modela i identikuju atipične vrednosti. Nakon odabira relevantnog izbalansiranog skupa podataka, logistička regresija se primenjuje kako bi se razvio matematički model koji određuje da li se određeni događaj može dogoditi kao funkcija nezavisnih parametara na osnovu izražene verovatnoće [164].

Prema Kelleheru, Nameeu i D'Arcyu [175], problem pri klasifikaciji primenom logističke regresije nastaje u slučajevima kada se instance zavisnih parametara preklapaju jedne sa drugima i gde nije jasno definisana granica među njima na osnovu nezavisnih parametara u definisanom skupu podataka.

3.3.1.2.2. Mahalanobis-Taguči sistem

Mahalanobis-Taguči sistem (MTS) je višeparametarska tehnika napredne statističke metode zasnovana na principima prepoznavanja obrazaca i predviđanja pojave određenih događaja za rešavanje klasifikacionih problema [176] na osnovu neizbalansiranog skupa podataka (slika 7). MTS tehnika predstavlja kombinaciju različitih metoda, koja je zasnovana na principima međusobne udaljenosti referentnih podataka nazvanim **Mahalanobisova udaljenost** (*Mahalanobis distance*) po statističaru dr Prasanta Čandra Mahalanobisu, koji je i uveo ovaj statistički alat [177]. Stoga, cilj njegovog istaživanja i uvođenja pojma Mahalanobisova udaljenost bilo je donošenje statističkih odluka na principima klasifikacije kako bi se razlikovala jedna grupa od druge [178].

Mahalanobisova udaljenost je zasnovana na korelacji između parametara i različitih obrazaca koji se mogu identifikovati i analizirati u odnosu na referentni skup podataka, i koja se određuje na osnovu sledeće formule:

$$MD_j = \frac{1}{k} Z_{ij}^T A^{-1} Z_{ij}, \text{ gde se } Z_{ij} \text{ određuje na osnovu } Z_{ij} = \frac{x_{ij} - m_i}{s_i} \quad (3)$$

gde je:

k – ukupan broj parametara,

i – redni broj parametra ($i = 1, 2, \dots, k$),

j – broj uzorka ($j = 1, 2, \dots, n$),

T – transponovani vektor,

A^{-1} – invertovana korelaciona matrica,

Z_{ij} – standardizovani vektor normalizovanih karakteristika od x_{ij} ,

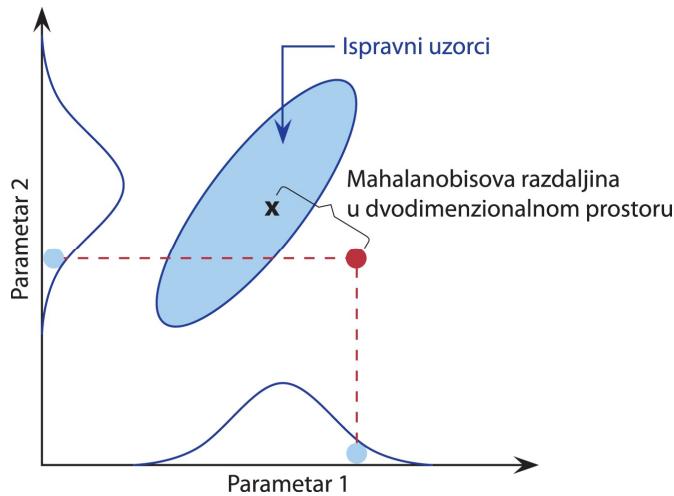
x_{ij} – vrednost i -tog parametra j -otog posmatranog uzorka,

m_i – srednja vrednost i -tog parametra,

s_i – standardna devijacija i -tog parametra.

Pored Mahalanobisove udaljenosti, drugi deo MTS tehnike je zasnovan na praćenju kvaliteta proizvodnje, kao kvaliteta i samog proizvodnog sistema, čiji je osnivač dr Geniči Taguči [179]. Stoga, MTS tehnika je Tagučijeva hibridna sistematska metoda zasnovana na principima Mahalanobisove udaljenosti koja izračunava udaljenost između referentnih podataka i uzorka i kvantitativno određuje njihovu razliku na osnovu koje se razvija i optimizuje dijagnostički sistem sa skalom merenja neusaglašenosti procesnih parametara u proizvodnim sistemima [178], [179].

Na slici 10 prikazan je primer određivanja Mahalanobisove udaljenosti na osnovu poređenja dva parametra, gde se jasno vidi da crveni uzorak ne pripada grupi relevantnih podataka. Prema Pengu i saradnicima [180], primenom MTS tehnike, donja granična vrednost Mahalanobisove udaljenosti kod uzoraka koji su okarakterisani kao ispravni je manje od 2,5, dok se gornja granična vrednost može postaviti na 4. Vrednosti Mahalanobisove udaljenosti koje prelaze vrednost 4 su izuzetno retko definisane kao ispravne [180]. Mahalanobisova udaljenost kod uzoraka koji su okarakterisani kao neispravni se izračunava na osnovu srednje vrednosti, standardne devijacije i inverznih korelacionih matrica na osnovu koeficijenta korelacije, gde se kao rezultat dobijaju velike vrednosti Mahalanobisove udaljenosti [152] koje nisu precizno definisane [181].



Slika 10. Primer određivanja Mahalanobisove udaljenosti u dvodimenzionalnom prostoru (prilagođeno iz [22])

3.3.2. Metode mašinskog učenja

Metode mašinskog učenja predstavljaju multidisciplinarnu oblast naprednih analitičkih metoda koje se zasnivaju na principima prenosa ljudskog načina učenja na veštačke sisteme (računare) [14]. U cilju obuhvatanja svih relevantnih aspekata, metode mašinskog učenja oslanjaju se na veliki broj drugih naučnih disciplina, kao što su matematika, napredna statistika, informatika, itd. [14], [102]. Sinteza ovih naučnih disciplina dovela je do praktične primene metoda mašinskog učenja sa svrhom rešavanja praktičnih problema u mnogim empirijskim disciplinama. Rešavanje mnogobrojnih problema primenom metoda mašinskog učenja je omogućena otkrivanjem i upotrebom skrivenih značajnih informacija i znanja dobijenih iz podataka [34], [218]. Raschka i Mirjalili [182] navode da metode mašinskog učenja obezbeđuje efikasniju alternativu za čuvanje informacija i znanja za postepeno poboljšanje performanse razvijenih matematičkih modela i donošenje odluka vođenih podacima.

Posebna pažnja metodama mašinskog učenja se pridaje za predviđanje ili klasifikovanje prilikom rešavanja problema unutar proizvodnih sistema [183]. Međutim, da bi se to omogućilo, neophodna je formulacija određenog problema učenja. Stoga, mašinskom učenju postoje dve osnovne formulacije problema učenja, i to [184]:

- *nadgledano učenje* - predstavlja pristup problemu učenja koji se odnosi na situacije u kojima se, prilikom razvoja matematičkog modela, zajedno sa nezavisnim vrednostima procesnih parametara iz generisanog skupa procesnih podataka na osnovu kojih se vrši učenje, daje i željeni zavisni parametar,
- *nенадгледано учење* - predstavlja pristup problemu učenja koji se odnosi na situacije u kojima se, prilikom razvoja matematičkog modela, algoritmu koji uči pružaju samo podaci bez željenog zavisnog parametra, s tim da se od algoritma koji uči očekuje se da sam uoči neke zakonitosti u procesnim podacima koji su mu dati.

Algoritmi za razvoj matematičkog modela su najčešće nadgledane metode učenja [132]. To znači da algoritmi za razvoj matematičkog modela pokušavaju da pronađu odnose među nezavisnim parametrima koji se odnose na određivanje ishoda zavisnog parametra. Međutim, prilikom razvoja matematičkog modela neophodno je precizno definisati zavisni parametar [185]. Zavisni parametar mora u potpunosti da zavisi od definisanih nezavisnih parametara i sažima prethodno definisani problem, na osnovu kojeg se određuje da li će se primenjivati:

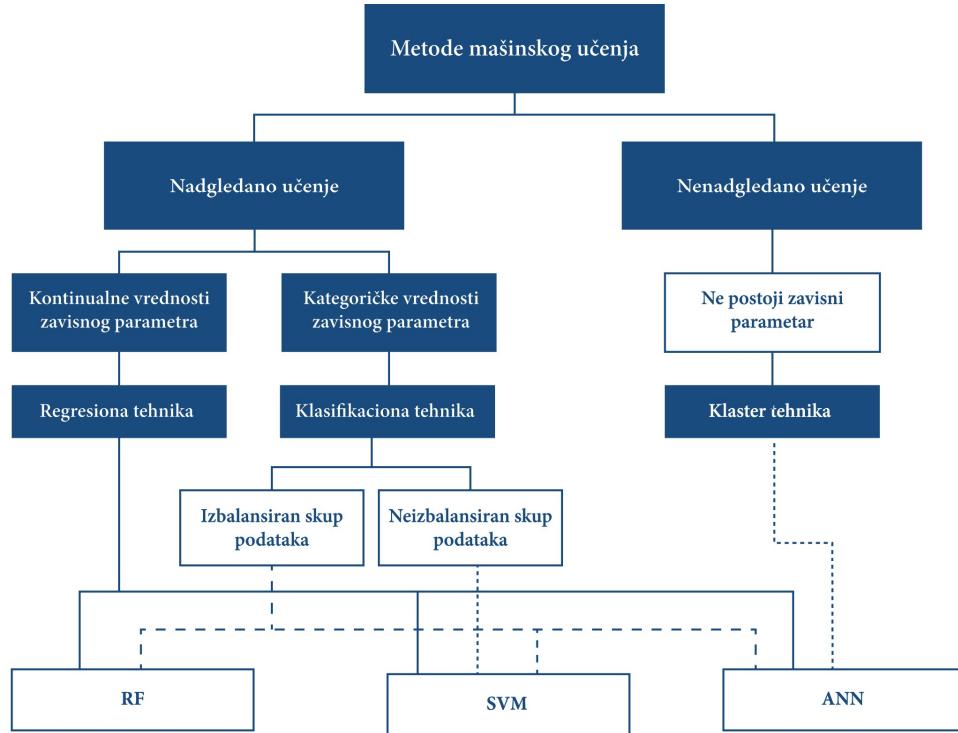
- *klasifikacione tehnike* – za kategoričke vrednosti zavisnog parametra, ili
- *regresione tehnike* – za kontinualne vrednosti zavisne parametra.

Međutim, važno je napomenuti pored klasifikacionih i regresionih metoda, postoji još i *tehnike klasterovanje* gde ne postoji zavisni parametar prilikom razvoja matematičkog modela u proizvodnim sistemima. Stoga, tehnike klasterovanje pripadaju metodama nенадгледаног mašinskog učenja. Na slici 11 je šematski prikazana klasifikacija formulacije problema kod metoda i tehnika mašinskog učenja.

U preglednom radu [127] koji se fokusirao na primenu metoda mašinskog učenja za prediktivno održavanje u proizvodnim sistemima, kao i u radu [132] koji se bavi primenom metoda mašinskog učenja u proizvodnim sistemima linijske proizvodnje, istaknuto je da su najzastupljenije tehnike metoda mašinskog učenja sledeće:

- veštačka neuronska mreža (*Artificial Neural Network* – ANN),
- potporni vektori (*Support Vector* – SV), i
- nasumične šume (*Random Forest* – FR).

Navedene tehnike metoda mašinskog učenja su izabrane kao najpogodnije za razvoj matematičkog modela za unapređenje proizvodnih sistemima, procesa i kvaliteta proizvoda (slika 11).



Slika 11. Klasifikacija metoda mašinskog učenja

3.3.2.1. Veštačka neuronska mreža

Veštačke neuronske mreže (*Artificial Neural Networks* – ANN) predstavljaju najpopularniju i jednu od najprimjenjenijih metoda mašinskog učenja (slika 11). Istraživanja ANN tehnika i primeri unapređenja proizvodnih sistema, procesa ili kvaliteta proizvoda su mnogobrojna [186]–[188] i pomeraju domete veštačke inteligencije, informatike, primenjene matematike i statistike [102]. Na osnovu opšte šeme obučavanja (slika 12) i opšte jednačine (6), generisani su mnogi zakoni obučavanja, dominantno variranjem načina generisanja signala obučavanja r [14], gde je:

$$w_i = (w_{i1}, w_{i2}, \dots, w_{im})^T, i=1,2,\dots,n - \text{vektor sinaptičkih težina } i\text{-og neurona}$$

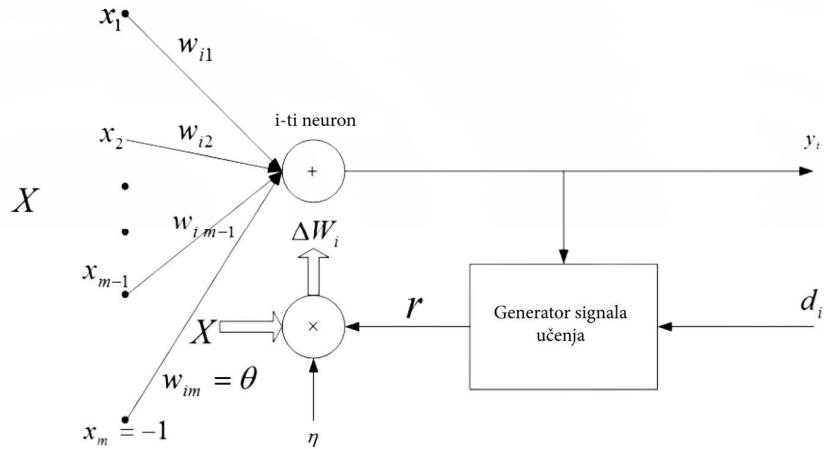
$$\Delta w_i(t) = \eta r x(t) \quad (4)$$

η - koeficijent obučavanja – pozitivna konstanta;

r – signal obučavanja, u opštem slučaju funkcija oblika

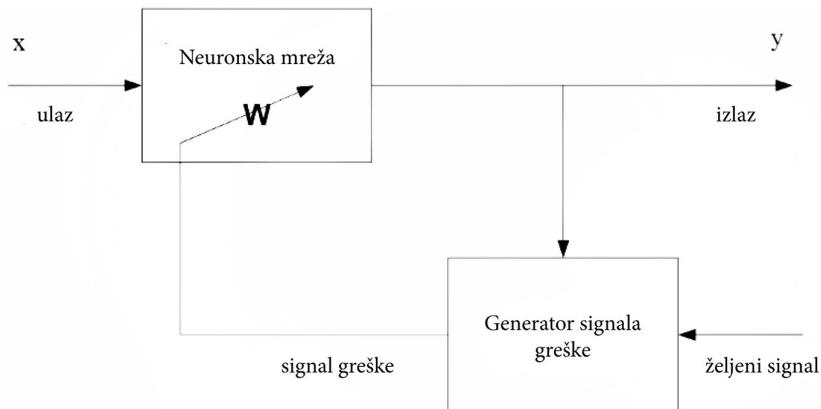
$$r = f_r(w_i, x, d_i), \quad (5)$$

$$w_i(t+1) = w_i(t) + \eta f_r(w_i(t), x(t), d_i(t)) x(t) \quad (6)$$

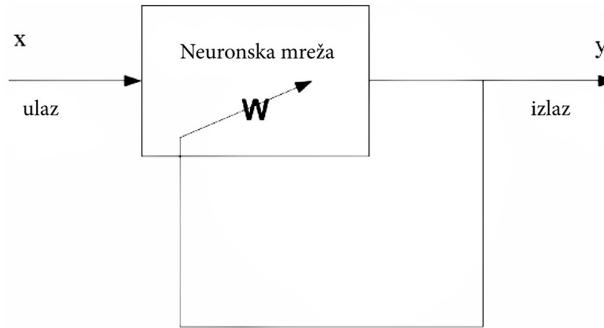


Slika 12. Opšta šema učenja primenom ANN tehnike [14]

ANN predstavlja algoritam koji se koristi kod metoda nadgledanog učenja (slika 13) u nelinearnim klasifikacionim i regresionim problemima u proizvodnim sistemima [102], [189], i radi na principu simulacija rada ljudskog mozga na decentralizovan način [114], [164]. Međutim, pored rešavanja klasifikacionih i regresionih problema, ANN ima primenu i u rešanju problema nenadgledanom metodom učenja grupisanjem rezultata u određene klastere [190] gde nije potrebno naznačiti željeni signal, odnosno zavisni parametar (slika 14). ANN spada u kategoriju tehniku zvanih *crne kutije* zbog slojeva u kojima se odvija proces obučavanja, tzv. skriveni slojevi, iz razloga što se ne zna tačno na koji način model funkcioniše unutar tih slojeva niti koji su procesi korišćeni za dobijanje rezultata, već su poznati isključivo zavisni i nezavisni parametri. Arhitektura veštačke neuronske mreže sa zavisnim i nezavisnim parametrima, kao i sa svim slojevima koji su neophodni za proces kreiranja matematičkog modela na principima veštačke neuronske mreže prikazana je na slikama 16-18.

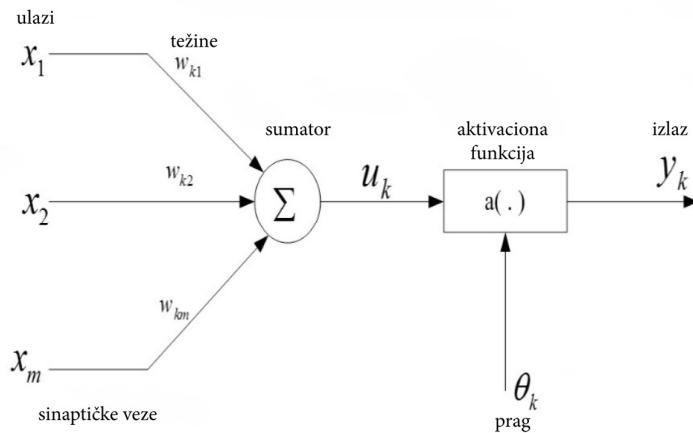


Slika 13. Metod nadgledanog učenja primenom ANN tehnike [14]



Slika 14. Metod nenadgledanog učenja primenom ANN tehnike [14]

Ono što je karakteristično za ANN jesu različite arhitekture neuronskih mreža. Različite arhitekture neuronskih mreža se dobijaju variranjem rasporeda neurona i sinapsi, kao i smera prostiranja signala kroz ove strukture, od zavisnih do nezavisnih parametara [14]. Po analogiji sa ljudskim mozgom, neuroni se po pravilu slažu u slojeve, koji se zatim povezuju na specifičan način (slike 16-18). Tačnost predviđanja primenom modela na principima ANN tehnike mašinskog učenja se značajno povećava ukoliko su i zavisni i nezavisni parametri kontinualne, odnosno numeričke vrednosti [163]. Takođe, tačnost predviđanja kreiranog modela umnogome zavisi i od odnosa međusobnih veza neurona različitih slojeva, kao i veze između ulaznog i skrivenog sloja, koji je po pravilu znatno kompleksnija od veze između skrivenog i izlaznog sloja. Dalje, svakoj vezi se dodeljuje određena značajnost (w), odnosno težina (slika 15), koja utiče na protok podataka kroz određenu vezu. Težina ima vrednost između 0 i 1, s tim da veća vrednost težine omogućava slobodni protok podataka, dok manja težina ograničava protok podataka duž veza među slojevima. Tokom procesa obučavanja modela veštačke neuronske mreže, neka područja neurona postaju aktivnija, dok druga područja ostaju neaktivna kao posledica primene nezavisnih parametara u modelu [164].

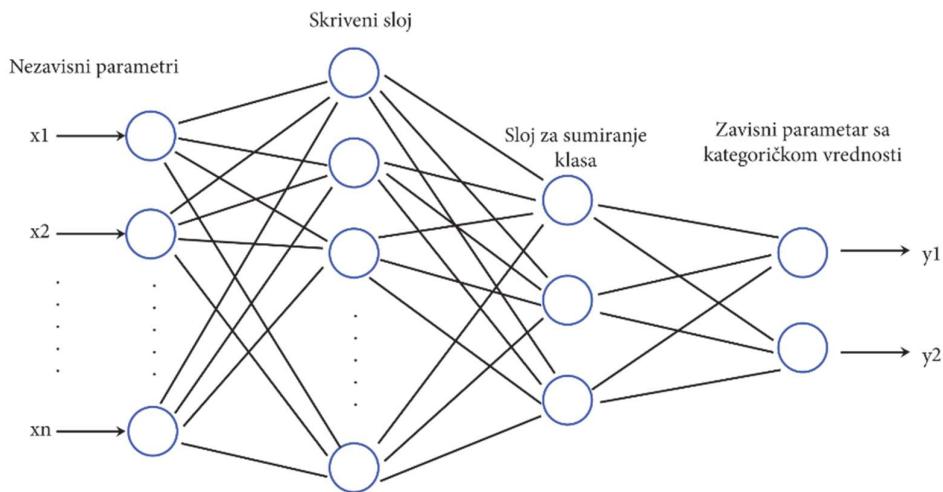


Slika 15. Nelinearni model neurona [14]

Kada je problem jasno definisan, potrebno je prikupiti podatke. Podaci se dele na podatke za razvoj matematičkog modela i podatke za testiranje. Zatim je potrebno odrediti vrednost parametra koji determiniše brzinu učenja (*gama*), veličinu praga odluke (*threshold*), kao i početnu vrednost težina. Prilikom primene ANN tehnike veći broj podataka obezbeđuje bolju obučenost mreže [191], ali zahteva više vremena za učenje u odnosu na druge tehnike mašinskog učenja obradenje u potpoglavlјima 3.3.2.2. *Potporni vektori* i 3.3.2.3. *Slučajna šuma*.

3.3.2.1.1. Veštačke neuronske mreže za klasifikaciju

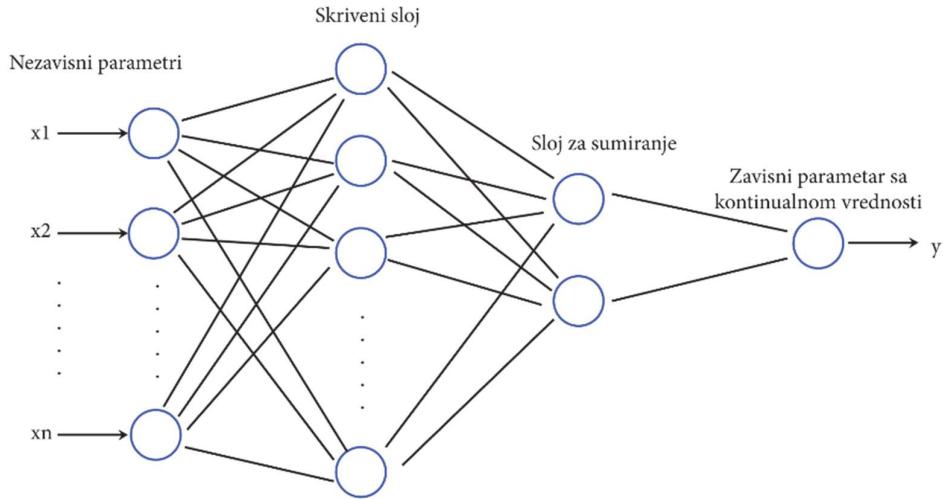
Primena ANN tehnike za rešavanje klasifikacionih problema nastoji da određena zapažanja klasifikuju kao pripadnost nekoj diskretnoj klasi u funkciji ulaznih podataka. Karakteristike nezavisnih promenljivih mogu biti kategoričke ili numeričke vrste. Međutim, u slučaju klasifikacionih problema kao zavisna promenljiva potrebna je kategoriska vrednosti izlaza. Na slici 16 je dat šematski prikaz funkcionisanja ANN algoritma mašinskog učenja za klasifikaciju.



Slika 16. Višeslojna ANN mreža sa jednim skrivenim slojem primenom klasifikacione tehnike

3.3.2.1.2. Veštačke neuronske mreže za regresiju

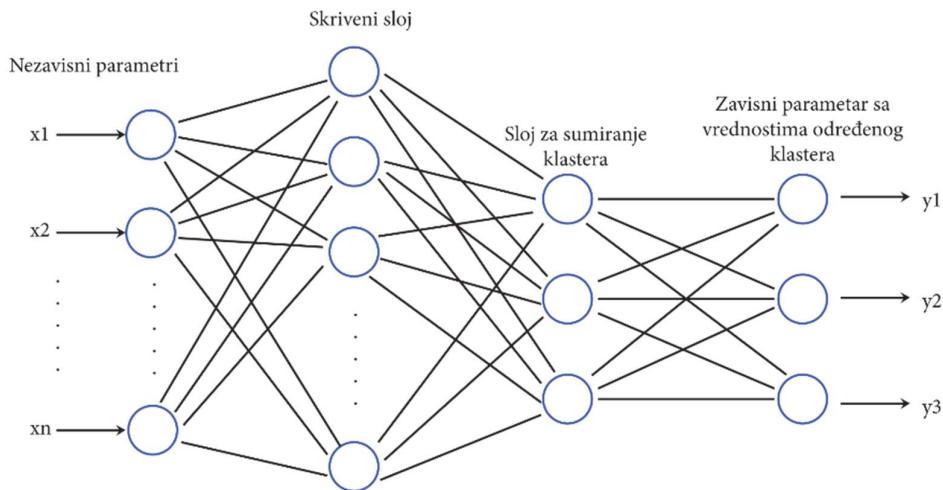
ANN tehnika prilikom rešavanja regresijskih problema predviđa izlaznu promenljivu kao funkciju ulaza. Karakteristike nezavisnih promenljivih mogu biti kategoričke ili numeričke vrste. Međutim, za regresiju primenom ANN tehnike, potrebna je numerička, odnosno kontinualna zavisna promenljiva. Na slici 17 je dat šematski prikaz funkcionisanja ANN algoritma mašinskog učenja za regresiju.



Slika 17. Višeslojna ANN mreža sa jednim skrivenim slojem primenom regresione tehnike

3.3.2.1.3. Veštačke neuronske mreže za klasterovanje

ANN tehnika prilikom rešavanja problema nastoji da određena zapažanja svrstaju u određeno grupu kao pripadnost nekoj diskretnoj kategoriji u funkciji ulaznih podataka. Karakteristike nezavisnih promenljivih mogu biti kategoričke ili numeričke vrste. Međutim, zavisna promenljiva potrebna u ovom slučaju ne postoji, već ANN algoritam na osnovu određenih sličnosti određuje pripadnost jednom od klastera. Na slici 18 je dat šematski prikaz funkcionisanja ANN algoritma mašinskog učenja za klasterovanje.



Slika 18. Višeslojna ANN mreža sa jednim skrivenim slojem primenom tehnike klasterovanja

3.3.2.2. Potporni vektori

Metode potpornih vektora (*Support Vectors – SV*) predstavljaju jednu od najčešće korišćenih metoda mašinskog učenja (slika 11). SV se prvi put pominje u radu iz 1995. godine koji su objavili Kortes i Vapnik [192]. Međutim, upotreba SV metoda je prisutna i danas gde se sve veća pažnja pridaje rešavanju, kako klasifikacionih tako i regresionih problema u proizvodnim sistemima [114], [193]. Stoga, metode potpornih vektora se mogu podeliti na [194], [195]:

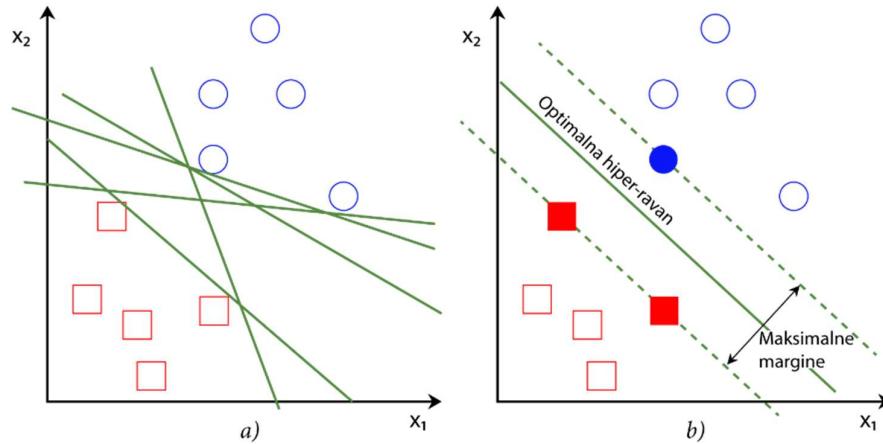
- metode potpornih vektora za klasifikaciju, gde se razlikuju:
 - metode za razvoj modela korišćenjem izbalansiranog skupa podataka, i
 - metode za razvoj modela korišćenjem neizbalansiranog skupa podataka, i
- metode potpornih vektora za regresiju.

3.3.2.2.1. Metoda potpornih vektora za klasifikaciju korišćenjem izbalansiranog skupa podataka

Metoda potpornih vektora za klasifikaciju korišćenjem izbalansiranog skupa podataka (*Support Vector Machines – SVM*) predstavljaju najpoznatiju tehniku SV metoda [194]. Zasnovan je na jasnoj geometrijskoj intuiciji koji ima za cilj razdvajanje podataka različitih klasa odgovarajućom hiper-ravni (granicu odluke) tako da su svi (ili najvećih broj) podataka iz iste klase sa iste strane hiper-ravnih.

Pod prepostavkom da postoje dve klase tačaka u ravni, s tim da su klase takve da se između elemenata te dve klase može povući prava, tako da su svi elementi jedne klase sa jedne strane, a elementi druge klase sa druge strane, nacrtane su različite rasporede takvih tačaka (slika 19). Može se primetiti da prava koja ih razdvaja praktično nikad nije jedna, već da je moguće povući više njih (slika 19 a)). Ipak, neke prave deluju bolje od ostalih. Na slici 19 b) je prikazana i optimalna prava (hiper-ravan), što je prava sa najvećim rastojanjem do najbliže joj tačke podataka, odnosno sa najširim pojasom praznog prostora oko nje [192]. Najširi pojas praznog prostora predstavlja maksimalne margine. Intuitivno, posmatrajući sliku, prava koja bi bila pod drugaćijim uglom i prolazila bliže nekoj od tačaka podataka bi nosila veći rizik da neka tačka koja nije u datim podacima završi sa pogrešne strane prave [194].

Suštinski problem ove formulacije predstavlja činjenica da se u praksi retko može očekivati linearnu razdvojivost klasa. Prosto, stvarni problemi su komplikovani. Otud je neophodno prihvatići neke greške, uz zahtev da budu što manje.



Slika 19. SVM metoda klasifikacije izbalansiranog skupa podataka [194]

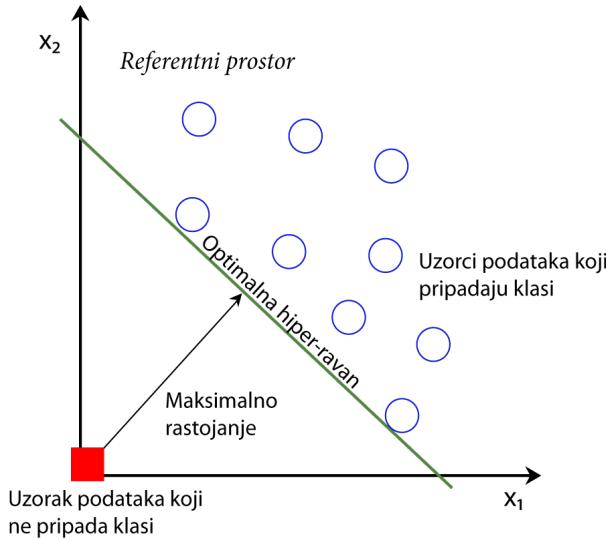
a) neoptimalne hiper-ravni

b) optimalna hiper-ravan

3.3.2.2.2. Metoda potpornih vektora za klasifikaciju korišćenjem neizbalansiranog skupa podataka

Susretanje sa neizbalansiranim skupovima podataka gde broj podataka iz jedne od dve klase daleko premašuje broj iz druge klase ili je čak jednak nuli, je vrlo česta situacija u proizvodnim sistemima [196]. U cilju rešavanja ovog problema, razvijene su metode za klasifikaciju neizbalansiranog skupa podataka. Metodu potpornih vektora za klasifikaciju korišćenjem neizbalansiranog skupa podataka prvi put opisali Skolkof i sar. [197] koja je poznatija kao jednoklasna metoda potpornih vektora (*OneClass Support Vector Machines – OCSVM*) [134].

Osnovna ideja OCSVM metode jeste izgradnja hiper-ravni koja optimalno odvaja dostupni jednoklasni skup podataka od ishodišta u prostoru visoke dimenzije [198]. U ovom kontekstu, optimum se odnosi na hiper-ravan koji maksimizira svoju marginu (udaljenost) do ishodišta, zadržavajući pritom većinu jednoklasnih uzoraka podataka. Hiper-ravan se u tom slučaju gradi maksimiziranjem rastojanja između podataka za razvoj modela i krajnjeg rezultata, kao što je prikazano na slici 20. Na ovaj način, novi primer se može klasifikovati kao pozitivan (koji pripada raspoloživoj klasi) ako je preko hiper-ravni (daleko od ishodišta), i negativan u suprotnom [199]. U rešavanju pojedinih inženjerskih problema, kao što je predviđanje pouzdanosti sistema ili rano otkrivanje anomalija, OCSVM je našao veliku primenu [200]–[202].



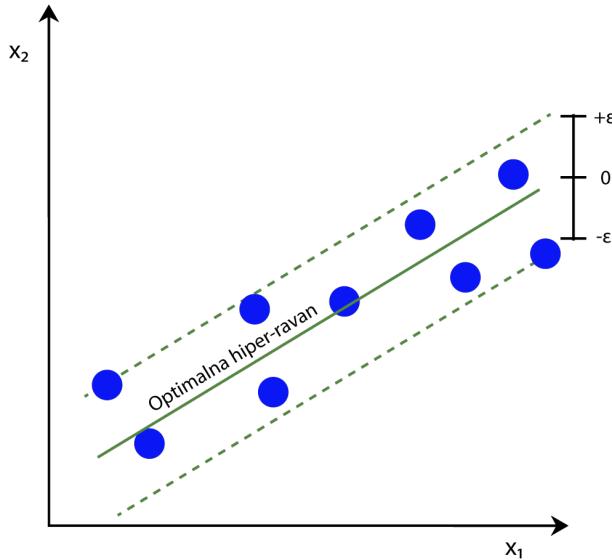
Slika 20. OCSVM metoda klasifikacije neizbalansiranog skupa podataka (prilagođeno iz [196])

3.3.2.2.3. Metoda potpornih vektora za regresiju

Metod potpornih vektora se možda još prirodnije formuliše za regresiju (*Support Vector Regression – SVR*) [203]. Ipak, jedna važna tehnička razlika u odnosu na klasifikaciju metodama potpornih vektora je u tome što čak ni u osnovnoj varijanti metoda nema smisla tražiti tačna predviđanja (što je u linearno razdvojivom slučaju kod klasifikacije bio zahtev). Razlog tome je taj što u slučaju regresije postoji kontinuitet ishoda i zahtev za tačnom jednakošću je preteran, a često ne bi ni davao zadovoljavajuće rezultate. Naime, podaci retko predstavljaju merenja promenljivih veličina sa savršenom tačnošću. Ako podaci sadrže grešku, nema smisla insistirati da se ta greška nauči. Stoga, uvodi se parametar tolerancije ε koji izražava razliku između predviđanja i stvarne vrednosti koja se smatra potpuno prihvatljivom. Osnovni model metoda potpornih vektora za regresiju je predstavljen na slici 21.

Međutim, u ovom slučaju postavlja se pitanje – na koji način se kod ove metode određuje široki pojas? U ε okolini modela ne bi mogao biti, pošto se u idealnom slučaju baš tu nalaze svi podaci, a u idealnom slučaju, baš u njemu ne bi trebalo da budu. Razmatrajući funkciju greške, u slučaju klasifikacije potporni vektori i instance koje su dalje od njih u odgovarajućem poluprostoru ne doprinose grešci. Instance koje zađu u pojas doprinose grešci u skladu sa proporcionalnom udaljenosti od hiper-ravnih na kojoj leže potporni vektori. U regresionom slučaju, uzorci podataka čija se vrednost razlikuje od vrednosti modela za manje od ε , ne doprinose nastanku greške. Čim se razlikuju za više od ε , doprinose proporcionalno toj dodatnoj razlici. To nas navodi na ideju da je u regresionom slučaju široki pojas zapravo prostor tačaka koje se po x_2 osi razlikuju od regresione krive za više od ε [194]. Što se tiče

primene u proizvodnim sistemima, SVR se pokazao kao dobar metod za dinamičko predviđanje proizvodnog procesa [204] i procene kvaliteta proizvoda [205].



Slika 21. SVR metoda regresije [194]

3.3.2.3. Slučajna šuma

Slučajna šuma (*Random Forest* – RF) predstavlja algoritam razvoja matematičkog modela koji može obavljati zadatke klasifikacije i zadatke regresije, uveden od strane Breimana [206] (slika 11). Konkretno, Breiman definiše RF na sledeći način: „*Slučajna šuma je klasifikator koji se sastoji od kolekcije stabala strukturiranih privremenih klasifikatora identično raspoređenih slučajnih vektora gde svako stablo daje jedinstveni glas za najpopularniju klasu na ulazu*“ [207].

RF je zasnovan na tehnikama stabala odlučivanja. Drugim rečima, RF metod predstavlja kolekciju stabala odlučivanja koji koristi predikcije tih stabala. Svako stablo predstavlja jedan glas u većinskom donošenju odluke.

U RF tehnici mašinskog učenja, obeležja se biraju nasumično u svakoj podeli odluke. Korelacija između stabala smanjuje se slučajnim odabirom karakteristika koje poboljšavaju snagu predviđanja i rezultiraju većom efikasnošću. Kao takve, prednosti RF tehnike su [208]:

- obrađivanje podataka sa velikom dimenzionalnošću (sposobnost obrađivanja više od nekoliko hiljada promenljivih i identifikacija najuticajnijih parametara), stoga se smatra važnom metodom smanjenja dimenzionalnosti;
- obrađivanje kontinualnih kategoričkih i binarnih podataka;

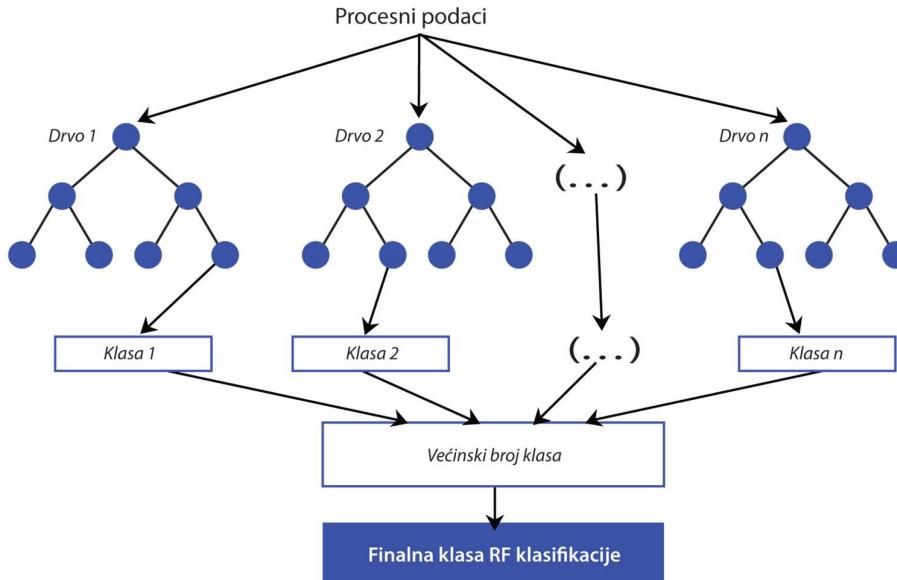
- efikasna procena podatka koji nedostaju i lako održavanje tačnosti razvijenog modela čak i ako mu se unosi velika količina podataka;
- primena metoda koje se mogu koristiti za uravnoteženje grešaka u skupu podataka.

Međutim, pored svojih prednosti, RF tehnika mašinsnog učenja ima i sledeće nedostatke:

- podaci mogu postati previše prilagođeni ako uzorci podataka imaju previše šuma;
- može delovati kao pristup *crnoj kutiji* prilikom razvoja modela jer ne postoji mogućnost kontrolisanja performansi.

3.3.2.3.1. Slučajna šuma za klasifikaciju

Algoritam RF za klasifikaciju se sastoji od nekoliko osnovnih iteracija. U prvom koraku se odabiraju podskupovi podataka za učenje koji predstavljaju baze za pojedinačna stabla odlučivanja. Potom se generišu stabla odlučivanja i sledi testiranje na svim preostalim primerima. U poslednjem koraku se prikupljaju glasovi svih stabala odlučivanja i vrši se klasifikacija. Krajnja odluka se dobija na osnovu histograma odluka svakog stabla i odluka koja je podržana od najvećeg broja stabala se uzima kao konačna [209]. Metod RF za klasifikaciju ima mnogo prednosti u odnosu na ostale popularne algoritme mašinskog učenja, a posebno su značajne bolja tačnost klasifikacije i efikasnost u radu sa velikim podacima. Poznat je kao ansambl način učenja, jer se grupa slabih modela kombinuje u ovaj snažni model [210]. Metode ansambla kombinuju rezultate klasifikacije nekoliko baznih modela sa ciljem da se unapredi moć generalizacije rezultujućeg modela (slika 22).



Slika 22. Metodologija klasifikacije primenom RF tehnike mašinskog učenja

Na osnovu dobijenih rezultata klasifikacije, razlikuju se dva tipa ovih metoda:

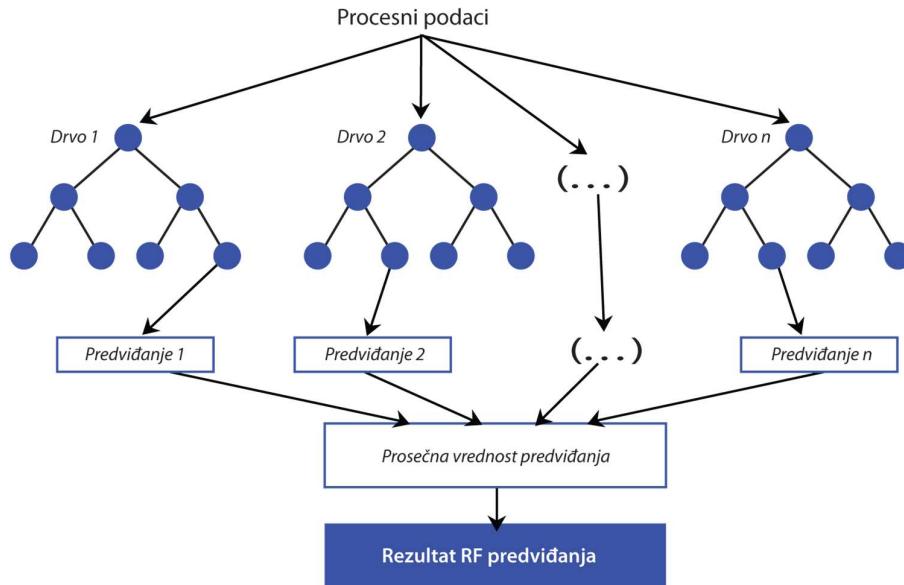
- metode izračunavanja prosečne vrednosti (*averaging methods*) - nekoliko modela se nezavisno obuči, pa se kao rezultujuće predviđanje uzima prosek predviđanja tih modela; ove metode predstavljaju vid regularizacije, jer im je cilj da smanje varijansu rezultujućeg modela, pa su pogodne za fleksibilne bazne modele sklone preteranom prilagođavanju;
- metode jačanja (*boosting methods*) - bazni modeli se obučavaju sekvencialno, tako da svaki model popravlja nedostatke svog prethodnika u cilju smanjenja sistematskog odstupanja rezultujućeg modela.

Primena tehnike RF za klasifikaciju samostalno ili u kombinaciji sa drugim tehnikama metoda mašinskog učenja sa ciljem razvoja hibridnih modela je sve češće prisutna u proizvodnim sistemima pretežno za rešavanje problema za predviđanje kvaliteta [211]–[213].

3.3.2.3.2. Slučajna šuma za regresiju

Princip rada algoritma RF za regresiju je sličan kao i kod RF za klasifikaciju. Metode ansambla kombinuju rezultate predikcije nekoliko baznih modela sa ciljem da se unapredi moć generalizacije rezultujućeg modela (slika 23). RF za regresiju lako se prilagođavaju nelinearnostima koje se nalaze u podacima i stoga teže da predviđaju bolje od linearne regresije. Preciznije, algoritmi učenja ansambla poput slučajnih šuma pogodni su za obradu srednjih do velikih skupova podataka. Kada je broj nezavisnih promenljivih veći od broja posmatranja, algoritmi naprednih statističkih tehnika, kao što je višeparametarska linearna regresija neće dati dobre rezultate predviđanja, jer broj parametara koji se procenjuju premašuje broj posmatranja. RF za regresiju će pružiti mnogo bolje rezultate predikcije, jer se ne koriste sve promenljive prediktora odjednom.

Međutim, RF nije toliko dobar u regresiji kao u klasifikaciji. Često ne izađe sa preciznim, kontinuiranim predviđanjima. Takođe, u slučaju regresije, ne može da daje predviđanja izvan opsega pruženih podataka o obuci. Stoga, u raspoloživoj literaturi postoji mali broj radova koji se bave razvojem RF modela za regresione probleme [132], iako postoje istraživanja koja tvrde da predviđanje zasnovano na RF tehnici mašinskog učenja daje bolje rezultate od ANN i SV tehnika [214].



Slika 23. Metodologija regresije primenom RF tehnike mašinskog učenja

3.3.3. Fazi logika

U proizvodnim sistemima, mnogi problemi sa kojima se inženjeri svakodnevno susreću i koje je neophodno rešiti su neprecizni i neizvesni. Sa povećanjem složenosti proizvodnog sistema, povećava se i kompleksnost problema. Stoga, mogućnost definisanja precizne tvrdnje o načinu njegovog ponašanja se smanjuje. Proučavanje problema zasnovanih na logici sa više od dve istinitosne vrednosti je započeo Lukašijević uvođenjem treće istinitosne vrednosti – *delimično tačno* [215]. Uvođenjem pojmove fazi logike i fazi skupa, Zadeh je otvorio put za primenu logika sa više istinitosnih vrednosti [216]. Lotfi Zadeh je predložio da pristup vrlo složenim problemima, umesto da se preciznije opisuje i razmišlja o njegovim pojavama, treba da ide u suprotnom smeru i da se dozvoljava njihova nepreciznost. Povećavanjem nepreciznosti izjava kojima kvalifikujemo rešenje problema, dobija se na njegovoj relevantnosti i značenju [216].

Fazi logika je bazira na viševrednosnoj logici koja priznaje srednje vrednosti definisane između tradicionalnih stavova klasične logike gde su tačno definisane granice vrednosti (da/ne, crno/belo, istina/neistina, itd.) [191]. Za razliku od promenljivih koje se koriste u klasičnoj logici koje dopuštaju isključivo dva moguća stanja vrednosti (0 i 1), fazi skup je napravljen bez jasno definisanih granica. Definisane granice po tom principu mogu sadržati elemente sa samo delimičnim članstvom pripadanja. Na taj način, modeli bazirani na primeni fazi logike imaju sposobnost prepoznavanja, predstavljanja, interpretiranja i korišćenja podataka i informacija koji su neprecizno definisani sa ciljem eksploatacije tolerancije koja postoji pri nepreciznosti i

nejasnoći. Takvi modeli se baziraju na iskustvu eksperata iz određene oblasti u formi AKO-ONDA (*IF-THEN*) pravila, dok mehanizam aproksimativnog rezonovanja računa upravljačku akciju za konkretni slučaj [191].

Stoga, fazi logika ima široku primenu u današnje vreme, i to u automatskom upravljanju, ekspertnim sistemima, sistemima za podršku u odlučivnaju, industriji, medicini, ekonomiji, marketingu, itd. Široka primena fazi logike je uslovljena njenim prednostima, a to su [191]:

- jednostavnost razumevanja;
- fleksibilnost;
- upotreba nepreciznih podataka;
- mogućnost modelovanja nelinearnih funkcija;
- korišćenje ekspertskega iskustava;
- upotreba jezika u obliku prirodne ljudske komunikacije;

gde se neretko fazi logika koristi u kombinaciji sa različitim statističkim i/ili metodama mašinskog učenja [217]–[221].

3.3.3.1. Fazi broj

U literaturi se fazi skupovi definišu na više načina. Razlog različitih definicija fazi skupa zavisi od skupa vrednosti odgovarajuće funkcije pripadnosti, te zbog toga postoji i više tipova fazi skupova. Kod osnovnog tipa fazi skupa funkcija pripadnosti ima vrednosti u intervalu [0, 1]. Ukoliko je X proizvoljan neprazan skup, fazi skup A sa vrednostima u intervalu [0, 1] definisan na X okarakterisan je funkcijom $\mu_A: X \rightarrow [0,1]$, odnosno uređeni par (X, μ_A) predstavlja **fazi skup**. Funkcija μ_A se naziva pripadajućom funkcijom (*membership function*) fazi skupa A . Pripadajuća funkcija $\mu_A(x)$ se često označava i sa $A(x)$, i poistovećuje se sa samim fazi skupom (X, μ_A) . Vrednost $\mu_A(x)$ se interpretira kao stepen pripadnosti elementa x skupu A . Uslučaju kada je vrednost $\mu_A(x)=0$, element x uopšte ne pripada skupu A , dok vrednost $\mu_A(x)=1$ označava da element x u potpunosti pripada skupu A . Fazi broj je fazi skup A koji je normalizovan, konveksan i ima ograničeno jezgro [216].

Neke od osnovnih definicija fazi skupova glase [216], [222], [223]:

1. Fazi skup A iz skupa U može se definisati kao skup uređenih parova $(x, \mu_A(x))$,

$$A = \{(x, \mu_A(x)) \mid x \in U\}, \mu_A(x) \in [0,1], \quad (7)$$

gde je U skup pozitivnih realnih brojeva, a μ_A funkcija pripadnosti skupa A i pri tom $\mu_A(x)$ predstavlja stepen pripadanja elementa x fazi skupu A .

2. Dva fazi skupa A i B su jednaki, u oznaci $A=B$ ako i samo ako važi:

$$\forall x \in U, \mu_A(x) = \mu_B(x), \quad (8)$$

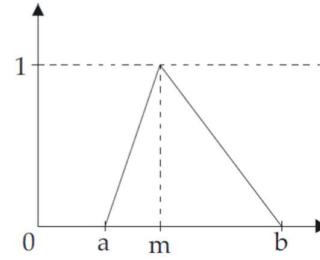
3. Za fazi skup A kažemo da je poskup fazi skupa B , u oznaci $A \subseteq B$ ako i samo ako važi:

$$\forall x \in U, \mu_A(x) \leq \mu_B(x). \quad (9)$$

Zadeh [216] je izvršio klasifikaciju ove funkcije u dve kategorije: linearne i nelinearne. Najčešće vrsta karakterističnih funkcija, tj. fazi skupova su:

1. trougaoni fazi broj, prikazan na slici 24. koji se definiše na sledeći način:

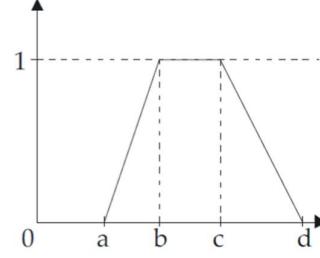
$$\mu_A(x) = \begin{cases} 0, & x \leq a, x \geq b \\ \frac{(x-a)}{(m-a)}, & x \in (a, m] \\ \frac{(b-x)}{b-m}, & x \in (m, b) \end{cases}$$



Slika 24. Trougaoni fazi broj [191]

2. trapezoidni fazi broj je prikazan na slici 25. koji se definiše na sledeći način:

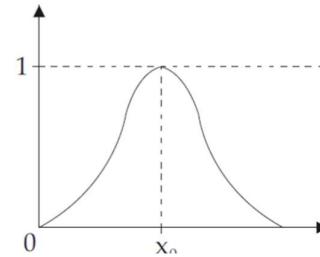
$$\mu_A(x) = \begin{cases} 0, & x \leq a, x \geq d \\ \frac{(x-a)}{(b-a)}, & x \in (a, b) \\ 1, & x \in (b, c) \\ \frac{(d-x)}{(d-c)}, & x \in (c, d) \end{cases}$$



Slika 25. Trapezoidni fazi broj [191]

3. Gausov fazi broj je prikazan na slici 26, a njegova karakteristična funkcija je:

$$\mu_A(x) = e^{\frac{-(x-x_0)^2}{d}}$$



Slika 26. Gausov fazi broj [191]

3.3.3.2. Fazi sistem zaključivanja

Fazi sistem zaključivanja (*Fuzzy Inference System* – FIS) predstavlja metodu obrade podataka pretvaranjem ulaznih veličina u izlazne veličine upotrebom fazi logike [224]. Posmatrano sa aspekta proizvodnih sistema, FIS metoda ima široku primenu u različitim oblastima kao što su kontrola, optimizacija, podrška odlučivanju, ekspertni sistemi, ocena rizika, itd. [225], [226], zbog jedostavnosti razumenanja i lakoće rukovanja i upravljanja razvijenim modelima.

Način zaključivanja FIS metode se odvija pomoću tri glavne komponente: fazifikacija, baza znanja i defazifikacija (slika 27). Fazifikacija i defazifikacija pretvaraju spoljašnje informacije u fazi vrednosti i obrnuto. Baza znanja podrazumeva fazi kreirana pravila i smatra se jezgrom sistema, jer omogućava aproksimativno rezonovanje [191].



Slika 27. Fazi sistem zaključivanja [191]

Da bi dobole izlazne vrednosti od datih ulaznih, potrebno je uraditi sledeće korake:

- identifikovati ulazne vrednosti i njihov opseg;
- identifikovati izlazne vrednosti i njihov opseg;
- definisati fazi pripadajuće funkcije za svaki ulaz i izlaz;
- kreirati pravila pod kojima će sistem funkcionisati;
- odlučiti kako će akcija biti izvršena dodeljivanjem snage pravilima;
- kombinovati pravila i uraditi defazifikaciju izlaznih vrednosti.

Princip rada FIS metode jeste sledeći: fazifikator pretvara jasne (*crisp*) ulazne varijable $x \in X$, gdje je X skup mogućih ulaznih promenljivih, u fazi lingvističke promenljive (čije vrednosti nisu brojevi, već reči ili rečenice u prirodnom ili veštačkom jeziku) primenom odgovarajućih pripadajućih funkcija. Ulazna promenljiva može biti povezana sa jednim ili više fazi skupova u zavisnosti od izračunatog stepena pripadnosti. Zatim, fazifikovane vrednosti se

obrađuju primenom AKO-ONDA izjava u skladu sa skupom unapred definisanih pravila izvedenih na osnovu znanja iz određenog domena od strane eksperata [224].

U ovoj fazi podsistem za zaključivanje ulazne fazi skupove pretvara u izlazne fazi skupove. Konačno, defazifikator proračunava tačne vrednosti iz seta izlaznih fazi skupova primenom pravila. Izlazne tačne vrednosti predstavljaju kontrolne akcije koje bi se trebale preduzeti. Odnosno, ulazne vrednosti predstavljaju stanja sistema kojim se upravlja, dok izlazni signali fazi sistema služe za obavljanje željenog upravljanja [191].

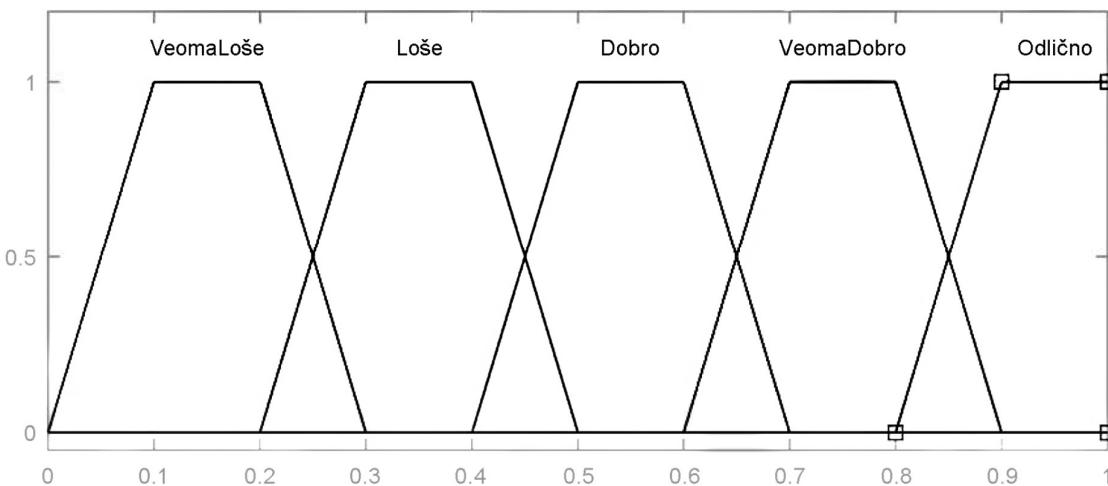
3.3.3.2.1. Fazifikacija

Fazifikator pretvara tačnu vrednost u stepen pripadnosti primenom odgovarajuće pripadajuće funkcije. Pripadajuća funkcija određuje sa kojom izvesnošću je tačna vrednost povezana sa odgovarajućom lingvističkom vrednošću. Na primer, kvalitet ulazne sirovine (koji se kvantitativno ispituje pre početka proizvodnog procesa) fazifikujemo preko pripadajućih funkcija i definišemo ulazne fazi veličine kao *veoma loše, loše, dobro, veoma dobro i odlično*.

Na ovaj način kvantitativne vrednosti pretvaramo u fazi lingvističke vrednosti i određujemo njihovu pripadnost fazi skupu. Grafički prikaz pripadajućih funkcija u fazifikaciji može se videti na slici 28 na primeru ulaznih trapezoidnih pripadajućih funkcija.

Proces fazifikacije se odvija u tri koraka, i to:

- mjeri se vrednost ulazne veličine u cilju dobijanja jasnog ulaza;
- primenjuje se skaliranje ulazne veličine na oblast delovanja;
- primenjuju se ulazne pripadajuće funkcije, koje oblast delovanja pretvarajući ih u fazi skupove, gde se na taj način se dobijaju fazi ulazi.



Slika 28. Fazifikacija ulaznih veličina preko trapezoidnih pripadajućih funkcija (MATLAB)

3.3.3.2.2. Baza znanja

Fazi pravilima za zaključivanje se opisuje ponašanje sistema, odnosno međusobna zavisnost fazi skupova različitih opisnih promenljivih. Iako izgleda da su fazi pravila - slobodne jezičke forme, ona imaju ograničen skup jezičkih izraza i strogu sintaksu. Jezik fazi pravila je veoma jednostavan. Međutim, forma pravila zavisi od tima fazi sistema zaključivanja. Stoga, postoje dva tipa fazi sistema zaključivanja: *Mamdani* i *Sugeno* [224].

Kod *Mamdani* sistema zaključivanja izlazna pripadajuća funkcija predstavlja fazi skup, gde je svako pravilo predstavljeno u formi:

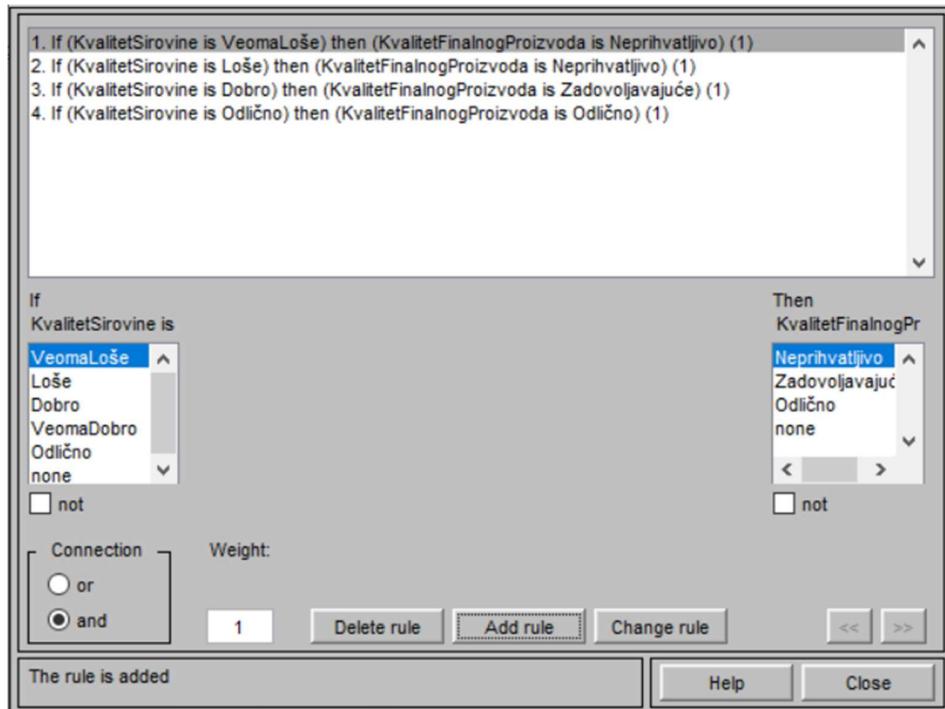
$$\text{IF } x \text{ is } A_i \text{ AND } y \text{ is } B_i \text{ THAN } z = C_i, i=1,2,\dots,n \quad (10)$$

gde su x , y i z lingvističke promenljive, a A , B i C su fazi skupovi. Na taj način je kreira baza znanja (slika 29).

Sugeno fazi metod je veoma sličan *Mamdani* metodi. *Sugeno* se jedino razlikuje u posledicama pravila, gde se umesto fazi skupa koristi matematička funkcija ulazne promenljive. Format *Sugeno* fazi pravila je:

$$\text{IF } x \text{ is } A \text{ AND } y \text{ is } B \text{ THEN } z \text{ is } f(x, y) \quad (11)$$

gde su x i y lingvističke promenljive, A i B su fazi skupovi, a $f(x, y)$ je matematička funkcija.

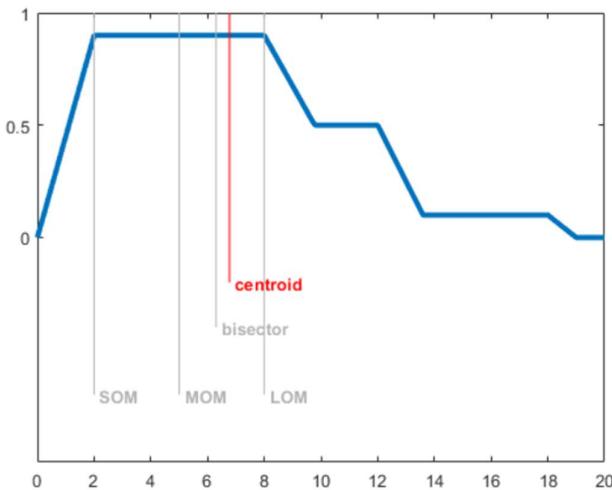


Slika 29. Mamdani fazi sistem zaključivanja – kreiranje baze znanja (MATLAB)

3.3.3.2.3. Defazifikacija

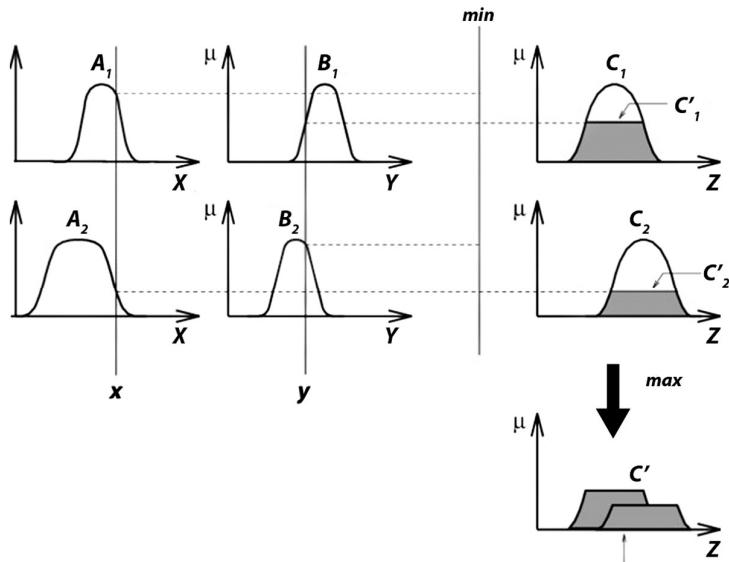
U procesu defazifikacije se vrši kombinovanje svih fazi izlaza, tako da se kao rezultat iz fazi regulatora dobije jasan izlaz (odnosno, tačno određena brojna vrednost izlazne veličine iz sistema). Drugim rečima, defazifikacija predstavlja obrnut proces od fazifikacije, u kome se od fazi izlaza, primenom izlaznih pripadajućih funkcija, dobija jasan izlaz [224]. Na osnovu toga kako se vrši ova transformacija, defazifikatori su podeljeni u više kategorija. Najčešće se koriste sledeći defazifikatori (slika 30):

- centroid metod;
- bisector metod;
- MOM – srednja vrednost maksimuma;
- LOM – najveća vrednost maksimuma;
- SOM – najmanja vrednost maksimuma.

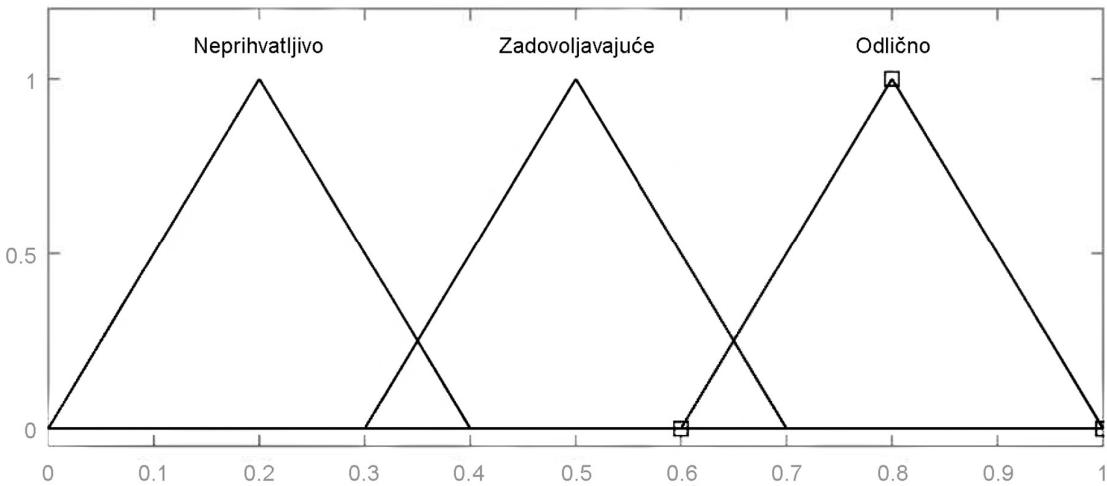


Slika 30. Defazifikacija izlaznih veličina korišćenjem centoid metode (MATLAB)

Mamdani metod zaključivanja (slika 31) zahteva pronašanje centra dvodimenzionalnog oblika integracijom kontinualno promenljive funkcije koji predstavlja jednostavnu metodu na bazi pravila koja ne zahteva komplikovane proračune. Stoga je pogodan za primenu pravila AKO-ONDA za kontrolu sistema [191]. Na primer izlazne lingvističke fazi vrednosti: neprihvatljivo, zadovoljavajuće i odlično se defazifikuju na brojevnoj skali od 0 do 1. Na ovaj način je izlaz iz fazi sistema zaključivanja jasno definisana kvantitativna vrednost. Grafički prikaz pripadajućih izlaznih funkcija može se videti na slici 32 na primeru trougaonih izlaznih pripadajućih funkcija [224].



Slika 31. Mamdani metod fazi zaključivanja (prilagođeno iz [227])

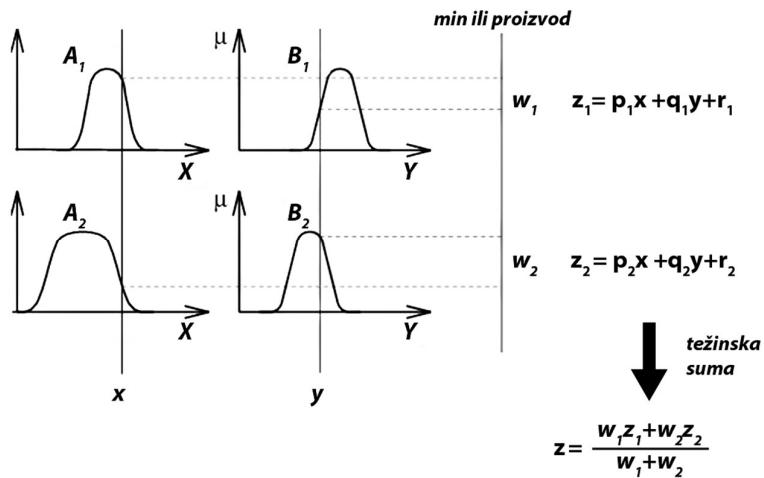


Slika 32. Trougaone pripadajuće funkcije izlaznih vrednosti kod Mamdani metoda zaključivanja (MATLAB)

Sugeno metod fazi zaključivanja (slika 33) je vrlo sličan *Mamdani* metodi s tim što *Sugeno* ima drugačiji rezultat pravila, gde, umesto fazi skupa, *Sugeno* metod koristi matematičku funkciju ulazne promenljive. Broj ulaznih fazi promenljivih u *Sugeno* fazi sistemu zaključivanja zavisi od broja i lokacija ekstrema funkcije koje treba aproksimovati. U *Sugeno* metodi potrebno je primeniti veliki broj pravila kako bi se aproksimirala periodična i veoma osculatorna funkcija [224].

Međutim, prilikom zaključivanja ovaj metod koristi relativan doprinos svakog pravila koji je dođen poređenjem ulaznog vektora sa premisom pravila. Rezultat zavisi od stepena u kom ulazni vektor zadovoljava osobine lingvističkih promenljivih, predstavljenim pomoću odgovarajućih fazi skupova, koje zavise od izbora odgovarajućih operatora. Težinska suma pojedinačnih izlaza dobija se linearom kombinacijom ulaznih promenljivih i relativnih doprinosa (uvećanim za vrednost konstante). Na ovaj način, linearna funkcija izlaza primenom Sugeno metoda može generisati kako linearne tako i nelinearne pripadajuće funkcije [228].

Sugeno metod je računarski efikasan i dobro radi sa optimizacijom i adaptivnim tehnikama, te je zgodan za rešavanje problema kontrole, posebno ukoliko se radi o dinamičkim nelinearnim sistemima. Nasuprot Sugeno metodi, Mamdani metod je pogodan za predstavljanje i interpretaciju ekspertnog znanja [191].



Slika 33. Sugeno metod fazi zaključivanja (prilagođeno iz [227])

4. RAZVOJ MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA U PROIZVODNIM SISTEMIMA

4.1. Metodologija razvoja modela

Učestale društvene, ekonomске i tehnološke promene uslovljavaju da se razvijaju modeli u skladu sa potrebama tržišta. Zadovoljenje potreba tržišta predstavlja jednu od polaznih tačaka pri donošenju odluka u industriji o načinu unapređenja proizvodnih sistema. Željeni cilj industrije, pored zadovoljena potreba tržišta, podrazumeva težnju proizvodnih sistema ka smanjenju troškova proizvodnje (u vidu različitih vrsta gubitaka, kratkih ili potpunih zastoja mašina, otkazivanja rada ili lomova pojedinih delova mašina, itd.) sa jedne strane, i povećanje profita (u vidu učinka, odgovarajućeg kvaliteta proizvoda i proizvodnih procesa, itd.) sa druge. Kao odgovor na sadašnje i buduće ciljeve industrije, ***neophodno je razmotriti razvoj univerzalnog modela*** sa sposobnostima detekcije neusaglašenosti na osnovu procesnih parametara u trenutku prikupljanja procesnih podataka (ili u približnom trenutku) kako bi se poboljšali svi aspekti proizvodnih sistema. Na osnovu prethodno rečenog, fokusirajući se na proizvodne sisteme procesne industrije, ***razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara (RONP) u proizvodnim sistemima je postao potreba***. Stoga, RONP predstavlja ***konceptualni model*** koji pruža kvalitativne opise pomažući da se istaknu sve veze koje postoje u realnim procesima procesne industrije.

Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima zasnovan je na primeni definisane metodologije. Metodologija razvoja RONP modela u proizvodnim sistemima zasniva se na naučnom prilazu korišćenjem ***istraživačkih metoda***. Odabrane istraživačke metode su korišćene zbog složenosti i multidisciplinarnosti predmeta istraživanja radi definisanja, prepoznavanja, rešavanja i otklanjanja problema nastalih tokom procesa proizvodnje usled neusaglašenosti procesnih parametara. Definisanje, prepoznavanje, rešavanje i otklanjanje problema nastalih tokom procesa proizvodnje je moguće uraditi razvojem RONP modela praćenjem njegovih faza. Faze razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima su:

- **Faza 1: Procena trenutnog stanja proizvodnog sistema**
- **Faza 2: Definisanje problema neusaglašenosti u proizvodnom sistemu**
- **Faza 3: Identifikacija uticajnih parametara i prikupljanje podataka**
- **Faza 4: Priprema i obrada prikupljenih podataka**

- **Faza 5: Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka**
- **Faza 6: Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara**
- **Faza 7: Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara**

U skladu sa predloženim fazama razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima, odabране su istraživačke metode koje obezbeđuju sistematičnost, validnost, pouzdanost, objektivnost, tačnost i ponovljivost. U nastavku rada objašnjene su istraživačke metode koje su primenjene.

4.1.1. Deskriptivna metoda

Deskriptivna metoda podrazumeva opisivanje činjenica nastalih tokom proizvodnih procesa kao i njihovih odnosa i veza, bez naučnog tumačenja i objašnjenja. Stoga, ova metoda korišćena je za prikazivanje teorijskih istraživanja. Teorijska istraživanja kao pregled aktuelnog stanja u oblasti predstavljaju temelj doktorske disertacije kako bi se ustanovila inovativnost i aktuelnost predmeta istaživanja.

4.1.2. Metoda sistematskog pregleda literature

Metoda sistematskog pregleda literature podrazumeva navođenje tuđih rezultata naučnoistraživačkog rada, odnosno tuđih spoznaja, opažanja i zaključaka na tačno i precizno definisan i sistematičan način. Sistematski pregled literature sledi precizno definisan protokol ili plan gde su kriterijumi jasno navedeni pre nego što se pregled sprovede. Ova metoda uključuje planiranje dobro osmištjene strategije pretraživanja koja ima poseban fokus ili odgovar na definisano pitanje pružajući uvid i pregled aktuelnog stanja u oblasti istraživanja. Metodom sistematskog pregleda literature se vrši identifikacija, odabir i kritičko ocenjivanje naučnih istraživanja kako bi odgovorilo na jasno formulisana pitanja. Pitanja koja su formulisana u ovoj doktorskoj disertaciji se odnose na:

- *studije slučaja unapređenja proizvodnih sistema, i*
- *pregled izazova implementacije koncepta Industrije 4.0 u proizvodnim sistemima.*

Na ovaj način se došlo do aktuelnosti predmeta istraživanja ove doktorske disertacije.

4.1.3. Metode ekspertske analize

Metode ekspertske analize podrazumevaju skup logičkih postupaka zasnovanih na znanju i iskustvu radi dobijanja informacija, od strane eksperata, kako bi se izabralo racionalno i optimalno rešenje. Metode ekspertske analize sastoje se u tome da se pri traženju nove informacije, na osnovu polaznih informacija, formira grupa eksperata koji, primenjujući intuitivno logičku analizu, realizuju postavljeni zadatak radi donošenja kvantitativnog i kvalitativnog suda o zadatom problemu. Metode ekspertske analize korišćene su u različitim fazama razvoja modela primenom metode intervjeta, i to su:

- *Faza 1: Procena trenutnog stanja proizvodnog sistema,*
- *Faza 2: Definisanje problema neusaglašenosti u proizvodnom sistemu, i*
- *Faza 3: Identifikacija uticajnih parametara i prikupljanje podataka.*

Dalje, metode ekspertske analize su korišćenje i u svrhu identifikacije karakteristika proizvodnog sistema, definisanja glavnih ciljeva kompanije, procene stepena spremnosti proizvodnog sistema za razvoj RONP modela, preciznog definisanja problema neusaglašenosti u proizvodnom sistemu i identifikacije procesnih parametara čija neusaglašenost dovodi do nastanka definisanog problema.

4.1.4. Analitička metoda

Analitička metoda je sistemski postupak koji podrazumeva matematičku analizu podataka primenom analitičkih tehnika u naučnoistraživačkom radu. Za definisani predmet istraživanja, korišćene su različite analitičke metode u različitim fazama razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima. Faze razvoja modela u kojima su primenjene analitičke metode su:

- *Faza 4: Priprema i obrada prikupljenih podataka i*
- *Faza 5: Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka.*

4.1.5. Metoda eksperimenta

Metoda eksperimenta podrazumeva eksperimentalno ispitivanje definisane problematike na modelu ili stvarnom sistemu i dobijanje eksperimentalnih rezultata. Pomenuta metoda je korišćena u dve faze, a to su:

- *Faza 6: Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u laboratorijskim uslovima kako bi se proverili rezultati razvijenog modela,*

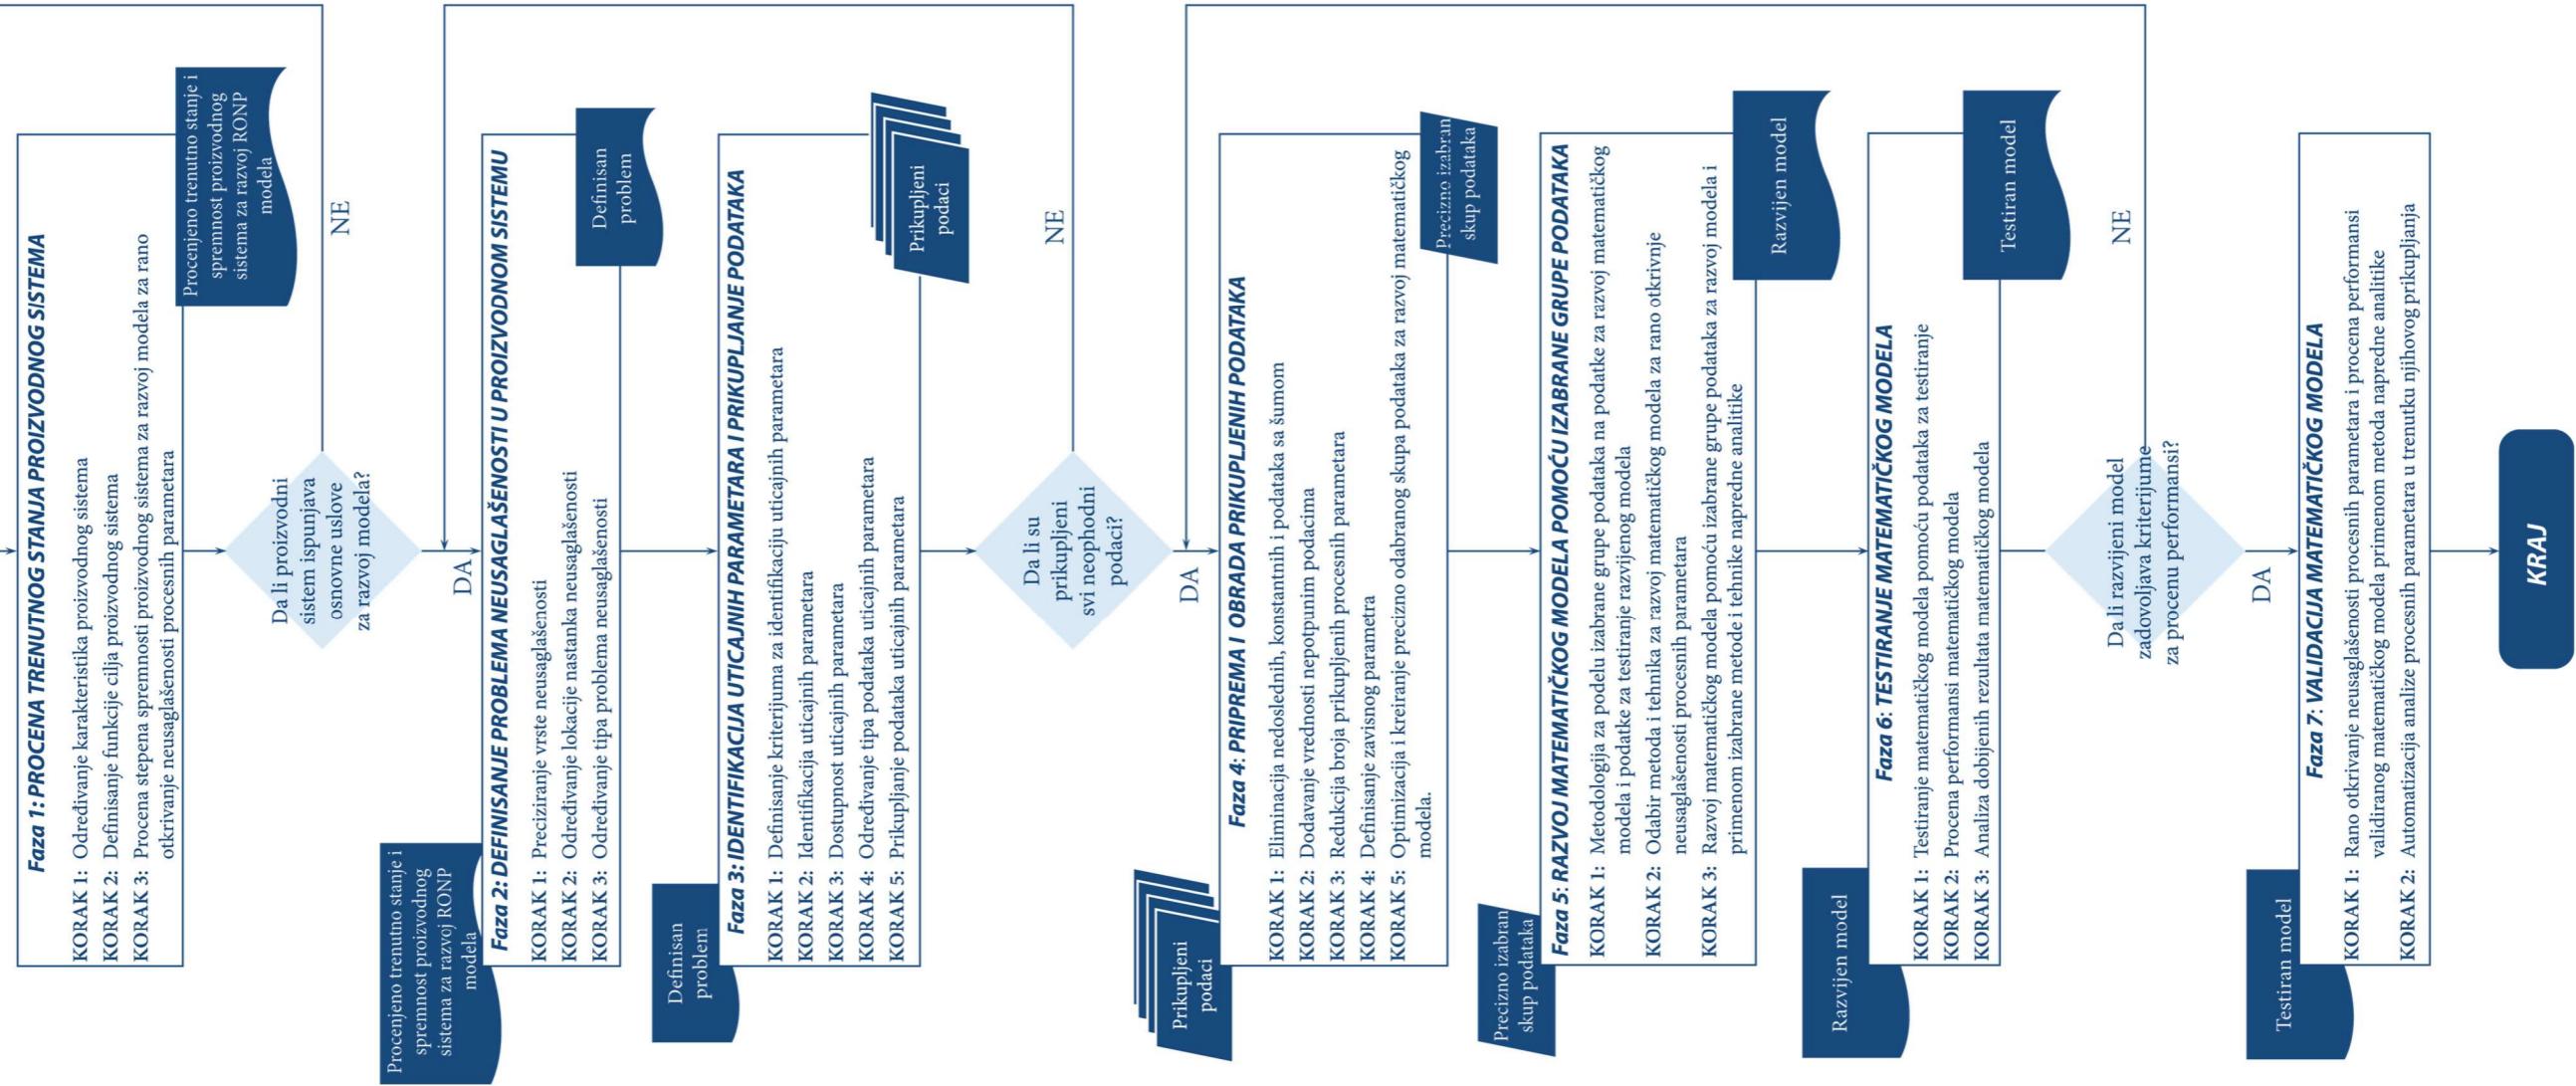
- *Faza 7: Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* u industrijskom okruženju kako bi se testirale performanse razvijenog modela.

4.2. Faze razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima

Zbog složenosti problema unapređenja proizvodnih sistema pomoću dostupnih podataka generisanih tokom proizvodnih procesa sa kojima se današnja industrija suočava, predložen je konceptualni model za rano otkrivanje neusaglašenosti procesnih parametara. Razvoj modela podeljen je u sedam faza koje su prilagođene od [185] i bazirane su na principima metodologije proučavanja podataka (slika 34). Faze razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima su sledeće (slika 34):

- Faza 1: Procena trenutnog stanja proizvodnog sistema – podrazumeva određivanje karakteristika proizvodnog sistema, definisanje glavnih ciljeva kompanije u vidu funkcije cilja i procenu stepena spremnosti proizvodnog sistema za razvoj RONP modela.
- Faza 2: Definisanje problema neusaglašenosti u proizvodnom sistemu – predstavlja odabir, analizu i precizno određivanje problema u proizvodnom sistemu.
- Faza 3: Identifikacija uticajnih parametara i prikupljanje podataka – predstavlja prikupljanje svih procesnih parametara za koje se smatra da utiču na nastanak definisanog problema u proizvodnom sistemu.
- Faza 4: Priprema i obrada prikupljenih podataka – predstavlja tehniku obrađivanja podataka, uklanjajući sve nepouzdane i konstantne podatke, podatke koji imaju šum, zatim dopunjavajući nepotpune vrednosti podataka i na kraju smanjenje količine podataka koji ne doprinose povećanju tačnosti prilikom razvoja matematičkog modela.
- Faza 5: Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka – predstavlja fazu kreiranja modela na principima naprednih analitičkih metoda odabirom određenih tehnika na osnovu prethodno definisanog problema.
- Faza 6: Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara – predstavlja proveru razvijenog modela na principima naprednih analitičkih metoda na novom skupu podataka, kako bi se potvrdili ili opovrgli dobijeni rezultati.
- Faza 7: Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara – predstavlja verifikaciju razvijenog matematičkog modela u industrijskom okruženju kako bi se testirale njegove performanse.

POČETAK



Slika 34. Algoritam razvoja konceptualnog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima

4.2.1. Faza 1: Procena trenutnog stanja proizvodnog sistema

Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima zahteva razmatranje osnovnih karakteristika sistema, funkciju cilja kompanije kao i procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara kako bi se doneo zaključak o podobnosti sistema za razvoja modela. Stoga, definisanje svih ovih razmatranja predstavlja prvu fazu razvoja RONP modela - *Procena trenutnog stanja proizvodnog sistema*.

Faza 1 - *Procena trenutnog stanja proizvodnog sistema* - sastoji se od definisanih koraka koje je neophodno uraditi u cilju dobijanja odgovora o ispunjenju uslova za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara, i to:

1. određivanje karakteristika proizvodnog sistema,
2. definisanje funkcije cilja proizvodnog sistema, i
3. procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara.

U nastavku ovog poglavlja dat je pregled karakteristika proizvodnog sistema, obrazloženje funkcije cilja u svrsi razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara, kao i način procene stepena spremnosti proizvodnog sistema za razvoj RONP modela koji se vrši na osnovu ekspertkse logike primenom fazi ekspertnog sistema.

Kao izlaznu informaciju nakon završene faze 1 - *Procena trenutnog stanja proizvodnog sistema* dobija se procenjeno trenutno stanje proizvodnog sistema za razvoj RONP modela (slika 34).

4.2.1.1. Karakteristike proizvodnog sistema

Prostorna struktura proizvodnog sistema određuje položaj i međusobni odnos strukturnih elemenata utvrđenih na osnovu njihove funkcije cilja, dok su same karakteristike proizvodnog sistema uslovnjene njegovom prostornom strukturom. Karakteristike proizvodnog sistema koje su od ključnog značaja za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara jesu sledeće:

1. delatnost proizvodnog sistema, i
2. karakteristike programa proizvodnje.

4.2.1.1.1. Delatnost proizvodnog sistema

Delatnosti preduzeća (kompanije) i drugih oblika organizovanja se razvrstavaju prema Klasifikaciji delatnosti sa nazivima, šiframa i opisima delatnosti (u daljem tekstu: Klasifikacija)

koju je donela Republika Srbija na osnovu člana 3. Zakona o klasifikaciji delatnosti („Službeni glasnik RS”, broj 104/09) i člana 42. stav 1. Zakona o Vladi („Službeni glasnik RS”, br. 55/05, 71/05 – ispravka, 101/07 i 65/08) [229].

Klasifikacija predstavlja opšti standard prema kojem se vrši razvrstavanje jedinica razvrstavanja u okviru određene delatnosti. Klasifikacijom se razvrstavaju po delatnostima: preduzeća i drugi oblici organizovanja, državni organi i organi jedinica lokalne samouprave, političke, sindikalne i druge organizacije i lica koja u vidu zanimanja u svoje ime trajno obavljaju određenu delatnost. Razvrstavanje po delatnostima vrši se po propisanoj metodologiji. Metodologija Klasifikacije delatnosti je hijerarhijska klasifikacija i čine je četiri nivoa, počev od najvišeg [229]:

- sektor,
- oblast,
- grana,
- grupa.

Prema Klasifikaciji, delatnosti proizvodnih sistema spadaju u sektor prerađivačke industrije podeljenih prema oblastima. Na osnovu Klasifikacije, data je tabela sa spiskom oblasti prerađivačke industrije (tabela 2). Na osnovu tabele 2 se identificuje oblast prerađivačke industrije kojoj pripada izabrani proizvodni sistem.

Tabela 2. Spisak oblasti prerađivačke industrije

Sektor C	Prerađivačka industrija
Oblasti prerađivačke industrije	
Oblast 11 - Proizvodnja pića	
Oblast 12 - Proizvodnja duvanskih proizvoda	
Oblast 13 - Proizvodnja tekstila	
Oblast 14 - Proizvodnja odevnih predmeta	
Oblast 15 - Proizvodnja kože i predmeta od kože	
Oblast 16 - Prerada drveta i proizvodi od drveta, plute, slame i pruća, osim nameštaja	
Oblast 17 - Proizvodnja papira i proizvoda od papira	
Oblast 18 - Štampanje i umnožavanje audio i video zapisa	
Oblast 19 - Proizvodnja koksa i derivata nafte	
Oblast 20 - Proizvodnja hemikalija i hemijskih proizvoda	
Oblast 21 - Proizvodnja osnovnih farmaceutskih proizvoda i preparata	
Oblast 22 - Proizvodnja proizvoda od gume i plastike	

-
- Oblast 23 - Proizvodnja proizvoda od ostalih nemetalnih minerala
Oblast 24 - Proizvodnja osnovnih metala
Oblast 25 - Proizvodnja metalnih proizvoda, osim mašina i uređaja
Oblast 26 - Proizvodnja računara, elektronskih i optičkih proizvoda
Oblast 27 - Proizvodnja električne opreme
Oblast 28 - Proizvodnja nepomenutih mašina i nepomenute opreme
Oblast 29 - Proizvodnja motornih vozila, prikolica i poluprikolica
Oblast 30 - Proizvodnja ostalih saobraćajnih sredstava
Oblast 31 - Proizvodnja nameštaja
Oblast 32 - Ostale prerađivačke delatnosti
Oblast 33 - Popravka i montaža mašina i opreme
-

Prema Klasifikaciji [229], kao što je navedeno, delatnosti proizvodnih sistema spadaju u sektor prerađivačke industrije podeljenih prema oblastima. Svaka oblast sadrži informacije o grani proizvodnje. U okviru svake grane nalaze informacije o grupi proizvoda koji se proizvode u dатој oblasti proizvodnje.

Stoga, na osnovu hijerarhijske klasifikacije se vrši određivanje grupe proizvoda koji se proizvode u odabranom proizvodnom sistemu prema Klasifikaciji koju je donela Republika Srbija [229]. Primer određivanja grupe proizvoda za prerađivačku industriju iz oblasti 21 je prikazan u tabeli 3.

Tabela 3. Određivanje grupe proizvoda na osnovu određene oblasti prerađivačke industrije

Sektor C	Prerađivačka industrija	
Oblast prerađivačke industrije	Oblast 21	Proizvodnja osnovnih farmaceutskih proizvoda i preparata
Grana	Grupa proizvoda	
<i>Grana 21.1</i> Proizvodnja osnovnih farmaceutskih proizvoda		<ul style="list-style-type: none"> • ispitivanje, usavršavanje i proizvodnju medicinskih aktivnih supstanci koje se koriste u proizvodnji farmaceutskih preparata: <ul style="list-style-type: none"> - antibiotika, vitamina, salicilne kiseline, acetosalicilne kiseline i dr. • obrada krvi • proizvodnja hemijski čistih šećera • obrada žlezda i proizvodnju ekstrakata iz žlezda
<i>Grana 21.2</i> Proizvodnja farmaceutskih preparata		<ul style="list-style-type: none"> • proizvodnja lekova: <ul style="list-style-type: none"> - antiseruma i drugih frakcija krvi - vakcina

-
- raznovrsnih medikamenata, uključujući i homeopatske preparate
 - proizvodnja hemijskih kontraceptivnih sredstava za spoljnu upotrebu i hormonskih kontraceptivnih preparata
 - proizvodnja medicinskih dijagnostičkih preparata, uključujući testove za proveru graviditeta
 - proizvodnja radioaktivnih dijagnostičkih preparata za preglede
 - proizvodnja biotehničkih farmaceutskih preparata
 - proizvodnja medicinski impregnirane vate, gaze, zavoja, bandažnog materijala, hirurškog ketguta i dr.
 - prerada biljaka (mlevenje, razvrstavanje) za farmaceutske svrhe

NAPOMENA: Grupa proizvoda koja nije obuhvaćena u grani 21.2 ne obuhvata:

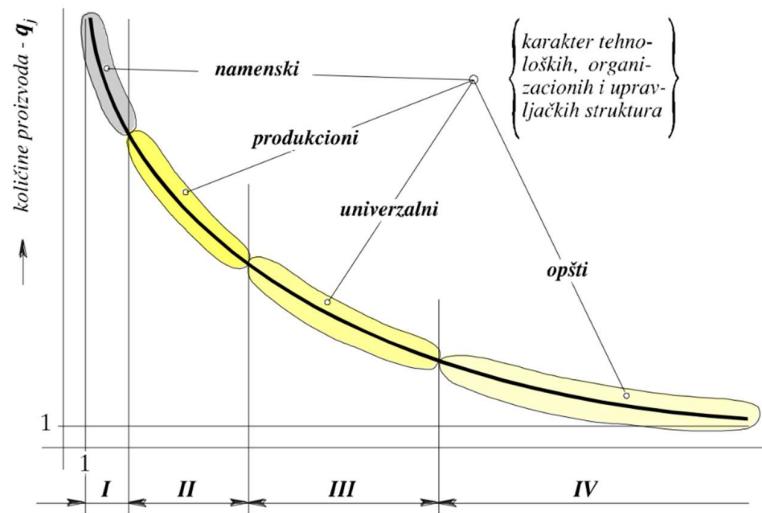
- proizvodnju biljnih smesa (menta, sporiš, kamilica, itd.), del. 10.83
 - proizvodnju zubnog materijala i cementa, del. 32.50
 - proizvodnju cementa za rekonstrukciju kostiju, del. 32.50
 - proizvodnju hirurške odeće, del. 32.50
 - trgovinu na veliko farmaceutskim proizvodima, del. 46.46
 - trgovinu na malo farmaceutskim proizvodima, del. 47.73
 - istraživanje i razvoj u farmakologiji i biljnoj farmakologiji, del. 72.1
 - pakovanje farmaceutskih preparata, del. 82.92
-

4.2.1.1.2. Karakteristike programa proizvodnje

Program proizvodnje predstavlja skup različitih proizvoda p_j u okviru potencijala sistema. Izbor proizvoda za program proizvodnje jeste kompromis između mogućnosti razmene, potencijala proizvodnih sistema i odnosa troškova i profita. Na osnovu toga, program proizvodnje je određen veličinama osnovnih parametara, odnosno *strukturom* (p_j) i *količinama* (q_j), koji predstavljaju podlogu istraživanja, projektovanja, organizovanja i upravljanja proizvodnog sistema [3].

Opšti oblik zavisnosti *struktura/količine* je od ključnog uticaja na određivanje karakteristika tehnoloških i prostornih struktura u fazama procesa rada proizvodnih sistema. Na osnovu toga razlikuju se četiri područja opštег slučaja date zavisnosti prikazanog na slici 35, gde:

- **područje I** - zahteva »brže« tehnologije sa tehnološkim i prostornim strukturama namenskog karaktera, povišenog stepena automatizacije i nižeg nivoa fleksibilnosti;
- **područje II** - postavlja zahtev za primenu tehnoloških prostornih struktura produktionog karaktera, nižih karakteristika u pogledu učinka i povećanog, u odnosu na područje I, nivoa fleksibilnosti;
- **područje III**, traži tehnološke i prostorne strukture univerzalnog karaktera i visokog nivoa fleksibilnosti (»sporije« tehnologije); i
- **područje IV**, zahteva tehnološke sisteme opšteg karaktera sa širokim mogućnostima obrade, a prostorne strukture tipa jediničnog radnog mesta.



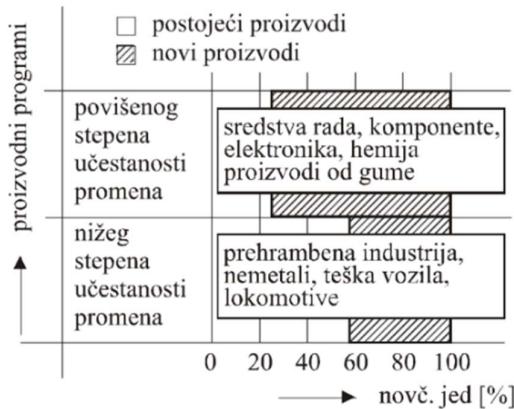
Slika 35. Osnovna područja zavisnosti struktura/količine [3]

Analiza osnovne zavisnosti *struktura/količine* se izvodi prema sledećim koracima:

1. utvrđivanje redosleda proizvoda u program proizvodnje prema količinama (od proizvoda sa najvećom do proizvoda sa najmanjom količinom) i grafičko prikazivanje dijagramom *struktura/količine*;
2. analiza dobijene zavisnosti u smislu ocene područja, iz opšteg slučaja zavisnosti *struktura/količine* (slici 35) kome pripada predmetni program, gde se dobijaju osnova za izbor karaktera tehnoloških i prostornih struktura u pogledu brzine promene stanja u fazama procesa rada.

Programi proizvodnje, različiti po vrsti i količinama, zahtevaju, pored naznačene zavisnosti *struktura/količine*, produbljenu analizu veličina relevantnih za razvoj RONP modela. Analiza relevantnih veličina prilikom razvoja RONP modela podrazumeva analizu programa proizvodnje koja obuhvata strukturu proizvodnog programa.

Struktura proizvodnog programa obuhvata sve ono što se dešava sa predmetom rada između početka proizvodnog procesa, pa sve do dobijanja finalnog proizvoda. Program proizvodnje se može posmatrati sa stanovišta učestalosti izmena proizvoda tokom proizvodnog procesa prema prikazu na slici 36. Sa stanovišta proizvodnih sistema, proizvodni program se definiše odnos *struktura/količine*, odnosno vrstom i količinom pojedinih proizvoda.

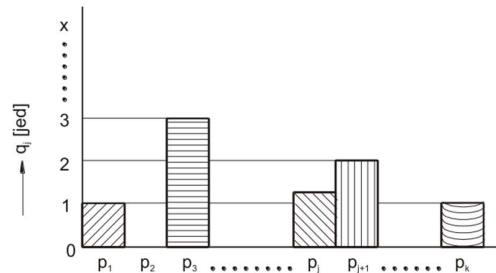


Slika 36. Stруктура програма производње са stanovišta učestalosti izmena [3]

Prema odnosu *struktura/količine*, proizvodni programi povишеног stepena učestalosti izmena su po pravilu i programi stalno rastуćeg stepena složenosti i kapitalno-intenzivnih investicionih zahvata. Na osnovu toga, program proizvodnje se može podeliti prema programu rada na sledeće zahteve [3]:

1. Pojedinačni zahtevi potrošača (varijanta 1.1 opšteg modela radnih tokova preduzeća):

- Odnos struktura/količine u programu prikazan na slici 37



Slika 37. Odnos struktura/količine kod pojedinačnog zahteva potrošača [3]

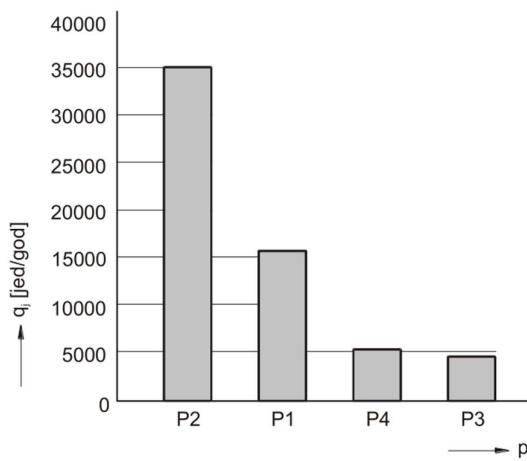
- Osnovna obeležja programa:

- количина у процесу – *jediničна/reђе x* комада производа по захтеву потрошача/корисника,
- квалитет – одређен захтевом корисника и искуством/компетентношћу извођача,

- stepen tehnološke složenosti – niži, različit u funkciji namene,
 - nivo standardizacije – niži,
 - proces rada – visok stepen fleksibilnosti, niža produktivnost,
 - sredstva rada – opšte namene, nižeg stepena složenosti,
 - ljudski resursi – visok stepen stručnosti i iskustvo u radu.
- Područja primene: projekti, programi, zanatski proizvodi, likovna dela, književna dela, kulinarski proizvodi i slični programi.

2. Serijski zahtevi potrošača (varijanta 1.2 opšteg modela radnih tokova preduzeća):

- Odnos struktura/količine u programu prikazan na slici 38



Slika 38. Odnos struktura/količine kod serijskih zahteva potrošača [3]

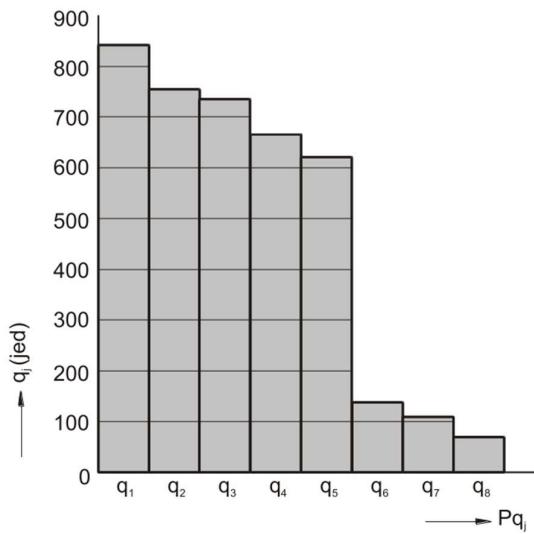
- Osnovna obeležja programa:

- količina u procesu – *serija* predmeta rada iste vrste po oceni marketinga i odelenja za upravljanje procesima rada, po zahtevu korisnika ili za plasman sa skladišta,
- kvalitet – određen propisanim standardima (preduzetnim, nacionalnim, međunarodnim/ISO),
- stepen tehnološke složenosti – povišen, različit u funkciji namene,
- nivo standardizacije – potpun,
- proces rada – niži stepen fleksibilnosti, povišen učinak i potpun stepen određenosti,
- sredstva rada – univerzalno/produkcionalna,
- ljudski resursi – specijalistička stručnost, iskustvo u radu.

- Područja primene: industrijski programi u prehrambenoj, metalnoj, drvnoj, industriji plastičnih materijala i sličnim područjima.

3. Grupni zahtevi marketinško/tehnološko/ekonomске strukture preduzeća (varijanta 2.1 opštег modela radnih tokova preduzeća):

- Odnos struktura/količine u programu prikazan na slici 39

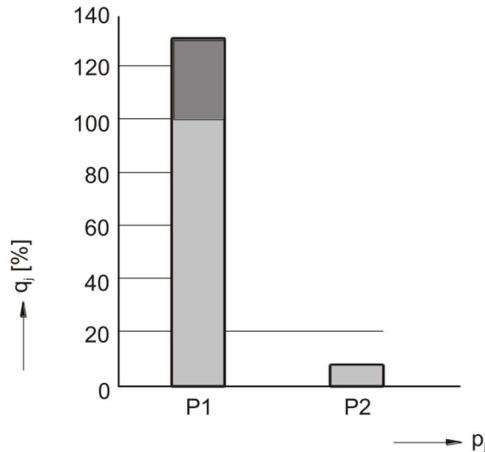


Slika 39. Odnos struktura/količine kod grupnih zahteva potrošača [3]

- Osnovna obeležja programa:
 - količina u programu – *grupa* sličnih predmeta rada istog tehnološkog toka, određena tehnološko/ekonomskim zahtevima u cilju ostvarenja principa,
 - kvalitet – određen propisanim standardima (preduzetnim, nacionalnim, međunarodnim/ISO),
 - stepen tehnološke složenosti – visok u funkciji stepena različitosti predmeta rada u grupi,
 - nivo standardizacije – potpun,
 - proces rada – stepen fleksibilnosti u funkciji tehnoloških zahteva predmeta rada grupe i parametara sredstava rada, potpun stepen određenosti,
 - sredstva rada – univerzalno/produkciona sa podešenim priborima za hvatanje predmeta različitih, u okviru grupe, dimenzija,
 - ljudski resursi – povišenog stepena stručnosti, specijalizacije i iskustva.
- Područja primene: programi u prehrambenoj, metalnoj i industriji plastičnih materijala, proizvodnja hleba i pekarskih proizvoda.

4. Masovni zahtevi potrošača (varijanta 2.2 opšteg modela radnih tokova preduzeća):

- Odnos struktura/količine u programu prikazan na slici 40



Slika 40. Odnos struktura/količine kod masovnih zahteva potrošača [3]

- Osnovna obeležja programa:

- količina u programu – *jedan* osnovni proizvod (često više tehnološki sličnih proizvoda uvek *jedne* vrste) u potrebnim godišnjim količinama,
 - kvalitet – utvrđen standardima, visok stepen pouzdanosti i povišen stepen privlačnosti i kvaliteta zadovoljstva,
 - stepen tehnološke složenosti – visok, u funkciji namene i zahteva potrošača,
 - nivo standardizacije – potpun,
 - proces rada – nizak stepen fleksibilnosti, potpuna razrađenost postupaka, potpun stepen određenosti, visok stepen automatizacije,
 - sredstva rada – *namenska* izvedena u integrativnom prilazu, posebne izvedbe,
 - ljudski resursi – visok stepen obrazovanosti, stručnosti i iskustva u razvoju, pripremi i održavanju, i niži specijalistički stepen stručnosti na operativnim radnim mestima.
- Područja primene: toplotna energija za grejanje, prehrambene tehnologije, automobilska industrija, konditorski proizvodi, industrija obuće, tekstilna industrija, industrija mlečnih proizvoda, proizvodnja pića, ulja za ishranu i slični proizvodi.

Kako bi se odredile karakteristike proizvodnog programa na osnovu struktura i količina proizvodnog programa neophodno je sprovesti sledeće analize:

- struktura delova po osnovnim dimenzijama,
- struktura delova po složenosti proizvoda, i
- količinska analiza programa proizvodnje.

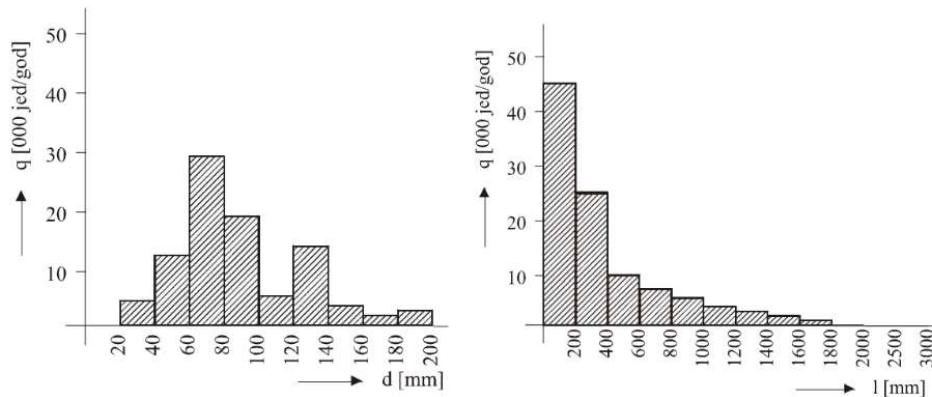
Struktura delova po osnovnim dimenzijama

Osnovne mere delova u programu proizvodnje uslovljavaju pored ostalih parametara izbor proizvodnih sistema različite vrste [3]. Analiza strukture delova po osnovnim dimenzijama sa stanovišta osnovnih mera jedna je od podloga za određivanje karakteristika programa proizvodnje za razvoj RONP modela. Dimenzijske proizvoda određenog proizvodnog programa daju informaciju o složenosti njegove izrade. Stoga, dimenzijske proizvoda se odnose na širinu, dužinu i prečnik proizvoda.

Analiza struktura delova po osnovnim dimenzijama može da se sproveđe na dva načina:

- vizuelno – koristeći grafički prikaz preko histograma (ukoliko je programom proizvodnje definisano da se radi o proizvodima različitih dimenzija), i
- kvalitativno – koristeći opise (ukoliko je programom proizvodnje definisano da se radi o proizvodima istih dimenzija).

Na slici 41 je dat primer raspodele delova datog programa proizvodnje po dužini proizvoda.



Slika 41. Raspodela dimenzijskih parametara za dve grupe proizvoda datog programa proizvodnje [3]

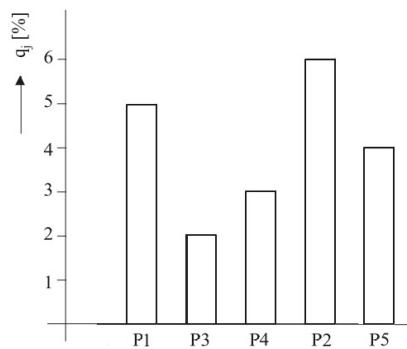
Struktura delova po složenosti proizvoda

Zavisno od vrste delatnosti kao isloženosti izrade proizvoda tokom procesa proizvodnje, proizvod može da bude manje ili više složen. Treba imati u vidu da složenost proizvoda značajno utiče i na složenost i obim aktivnosti koje treba sprovesti prilikom njihove proizvodnje. To dalje implicira da se sa povećanjem složenosti i obimom aktivnosti prilikom izrade proizvoda povećava i mogućnost nastanka neusaglašenosti uslovljenih procesnim parametrima. Stoga, analiza strukture delova prema složenosti proizvoda vrši se na osnovu pregleda broja operacija kroz koje svaki proizvod prolazi.

Analiza struktura delova po složenosti proizvoda može da se sprovede na dva načina:

- vizuelno – koristeći grafički prikaz preko histograma (ukoliko je programom proizvodnje definisano da se radi o proizvodima različitog stepena složenosti), i
- kvalitativno – koristeći opise (ukoliko je programom proizvodnje definisano da se radi o proizvodima istog stepena složenosti).

Na slici 42 je dat primer raspodele delova datog programa proizvodnje po složenosti proizvoda.



Slika 42. Raspodela broja mašina prilikom proizvodnje datog proizvodnog programa

Količinska analiza programa proizvodnje

Osnovna zavisnost struktura/količine u programu proizvodnje omogućava analizu odnosa datih veličina obezbeđujući posebne informacije o kvalitetu u smislu tehnologičnosti, profitabilnosti i drugih elemenata sa svrhom donošenja odluka o usmeravanju tehnološkog rada ka kritičnim područjima. Takav postupak se izvodi metodom količinske analize (**ABC analiza**) [3].

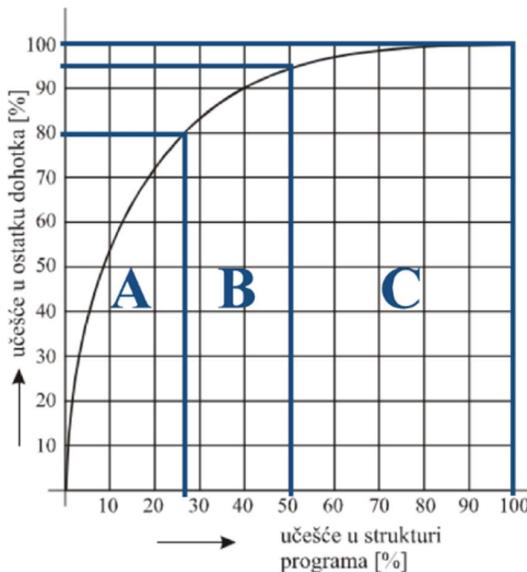
ABC analiza predstavlja grafičku metodu za analizu različitih pojava unutar poizvodnih sistema (sistemske faktore; greške, uzroci, uzroci i slični problemi; kvantitativne, masene, vrednosne i druge karakteristične veličine radnog procesa) u smislu [55]:

- rangiranja veličina/pojava koje se analiziraju prema stepenu značajnosti, na osnovu utvrđenih kriterijuma,
- identifikovanje kritičnih područja posmatranih veličina/pojava, i
- usmeravanje napora ka podacima, kritičnim oblastima u cilju efikasnijeg rešavanja problema ili koncentracije rada u oblastima koje pružaju veće učešće u ostvarivanju efekata.

ABC analiza prikazuje relativan značaj (učešće, uticaj) posmatrane veličine ili grupe veličina u skupu veličina čija se analiza vrši u opadajućem redosledu. Koraci izvođenja ABC analize su sledeći:

1. utvrđivanje zavisnosti *struktura/količine* pri čemu se za svaki proizvod određuje procentualno učešće u ukupnoj veličini date karakteristike i grafičko predstavljanje u vidu kumulativnog dijagrama;
2. analiza i određivanje područja datih veličina:
 - **područje A** – najvećeg prirasta,
 - **područje B** – značajnog prirasta,
 - **područje C** – malog, odnosno nedovoljno značajnog prirasta;
3. usmeravanje rada na kritična područja u smislu koncentracije rada na područja većeg prirasta relevantnih veličina.

Primer ABC analize sa određenim područjima je dat na slici 43.



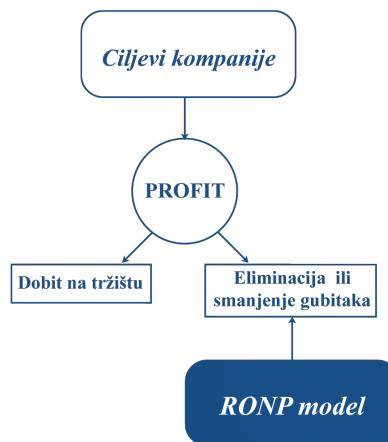
Slika 43. ABC analiza relativnog učešća proizvoda u programu proizvodnje

Važnost ABC analize u razvoju konceptualnog RONP modela ogleda se identifikaciji i izboru proizvoda predstavnika. Proizvod predstavnik je definisan kao stvaran, odnosno realan deo programa proizvodnje koji po svojim karakteristikama obuhvata najveći broj elemenata strukture površina ostalih delova programa proizvodnje koji se po pravilu bira iz područja A na osnovu ABC analize programa proizvodnje. Međutim, u pojedinim slučajevima kada je moguće izvršiti grupaciju proizvoda na osnovu određenih definisanih sličnosti, kao „*proizvod predstavnik*” se uzima grupa proizvoda.

4.2.1.2. Funkcija cilja proizvodnog sistema

Funkcija cilja proizvodnog sistema predstavlja dobit kompanije. Unutar proizvodnih sistema se organizuje proizvodnja na taj način da se ponude na tržištu određene količine roba (gotovih proizvoda), nastojeći da se maksimizuju dobici u vidu profita. Međutim, povećanje profita kompanije se ne ostvaruje samo u dobiti na tržištu, već i smanjenjem ili eliminacijom gubitaka tokom proizvodnog procesa u proizvodnim sistemima.

Gubici nastaju usled novih zahteva tržišta, što neminovno dovodi do promena unutar proizvodnih sistema. Promene u proizvodnim sistemima su praćene nastankom neusaglašenosti procesnih parametara koje ometaju tok proizvodnih procesa. Neusaglašenosti procesnih parametara koje se javljaju u proizvodnim sistemima mogu se definisati kao problemi koje je neophodno otkloniti. Stoga, funkcija cilja proizvodnih sistema prvenstveno se ogleda u ranom otkrivanju neusaglašenosti procesnih parametara kako bi se što ranije eliminisali gubici ili u potpunosti sprečio njihov nastanak, a samim tim i brže odgovorilo potrebama tržišta (slika 44).



Slika 44. Razvoj RONP modela sa svrhom ostvarenja ciljeva kompanije

Funkcija cilja za razvoj RONP modela se definiše putem intervjuja sa menadžmentom i ekspertima iz proizvodnog sistema sa akcentom na profit kompanije. Primenom metode intervjuja dobijaju se tačne informacije o tome šta predstavlja najznačajniji problem u proizvodnom sistemu koji direktno negativno utiče na ostvarivanje profit kompanije.

4.2.1.3. Procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara

Uvid u trenutno stanje proizvodnog sistema predstavlja njegovu analizu kako bi se procenio **stepen spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara**. Stepen spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara predstavlja preuslov

neophodan za implementaciju modela u proizvodnim sistemima. Odnosno, stepen spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara **predstavlja eliminatorični faktor** koji mora biti ispunjen prilikom razmatranja razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u određenom proizvodnom sistemu. Procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara vrši se na osnovu ekspertne logike primenom fazi ekspertnog sistema. Razlog primene fazi ekspertnog sistema za procenu stepena spremnosti proizvodnog sistema za primenu modela jeste način tumačenja lingvističkih promenljivih koje obično ne mogu biti eksplicitno analizirane ili statistički izražene. Primenom fazi ekspertnog sistema se prevazile nesigurnosti i neizvesnosti koje nastaju primenom standarnih metoda za procenu trenutnog stanja proizvodnih sistema.

Način rada fazi ekspertnog sistema zasniva se na upravljanju bazom znanja pomoću odgovarajućih pravila zaključivanja. U takvim slučajevima, fazi logika se primenjuje u sistemu kao podrška za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara na osnovu definisanih kriterijuma. Kriterijumi se odnose na organizacioni aspekt proizvodnog sistema na osnovu kojih se vrši procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Kriterijumi su generisani na osnovu literaturnog pregleda [218], [230]–[233] i na osnovu ekspertskega znanja primenom metode intervjuja. Pored toga, generisani kriterijumi ujedno predstavljaju i izazove prilikom implementacije koncepta Industrije 4.0 [7] u proizvodnim sistemima. Na osnovu toga generisani su sledeći kriterijumi:

- **strategija kompanije** – podrazumeva primenu nekog od upravljačkog pristupa za kontinualna unapređenja proizvodnih sistema; razmatranje strategije za novim načinima unapređenja proizvodnih sistema primenom metoda napredne analitike; dostupnost resursa za realizaciju unapređenja proizvodnih sistema primenom metoda napredne analitike; prilagođavanje poslovnih i proizvodnih modela za realizaciju unapređenja proizvodnih sistema primenom napredne analitike, itd. Strategija, kao jedan od izazova pri razmatranju unapređenja proizvodnih sistema je opisana u naučnom radu [7], gde je naglašeno da je izuzetno važno osmisлити detaljnu strategiju zasnovanu na zahtevima i potrebama kompanije radi njenog unapređenja primenom novih naprednih tehnologija. Stoga, ovaj kriterijum se odnosi na razmatranje kompanije da li je i u kojoj meri je moguće unaprediti proizvodni sistem primenom modela za rano otkrivanje neusaglašenosti procesnih parametara na principima napredne analitike.
- **ljudski resursi** – podrazumevaju ljude zaposlene u proizvodnim sistemima koji pomažu kompanijama da ostvare kontinualna unapređenja, s tim da su radnici upravo ti koji su najviše pogodeni promenama uvođenja digitalizacije na radnim mestima. Njihovo radno okruženje se direktno menja, što zahteva sticanje novih veština i

kvalifikacija. Analizom izazova implementacija koncepta Industrije 4.0, kao vida digitalne transformacije, utvrđeno je da postoje problemi koji se direktno odnose na ljudske resurse [7], i to: nedostatak obučenih radnika, otpor radnika ka promena i nedoslednost radnika prilikom primene novih mera za kontinualna unapređenja proizvodnog sistema. Zbog toga je važno da kompanije svoje zaposlene pripremaju za ove promene kroz odgovarajuću obuku i kontinualno obrazovanje. Stoga, kriterijum ljudskih resursa za razvoj fazi ekspertnog sistema se odnosi na pitanje da li su radnici voljni i adekvatno obučeni da aktivno učestvuju u unapređenju proizvodnog sistema primenom modela za rano otkrivanje neusaglašenosti procesnih parametara.

- **upravljački pristupi** – predstavljaju upravljanje proizvodnim procesima primenom različitih upravljačkih pristupa kao proces sprovođenja odluka koje su donete na osnovu dostupnih informacija. Dostupnost informacija generisanih putem upravljačkih pristupa služe kao osnov i predstavljaju preduslov za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima. Upravljački pristupi se zasnivaju na filozofiji upravljanja proizvodnim sistemima primenom različitih standardizovanih alata u cilju kontinualnog unapređenje proizvodnih sistema. Međutim, važno je naglasiti da se u postojećoj literaturi [234]–[237] nalaze navodi o uskoj povezanosti primene novih naprednih tehnologija Industrije 4.0 sa postojećim upravljačkim pristupima. Primena naprednih tehnologija Industrije 4.0 u proizvodnim sistemima treba da se posmatra kao jedan on alata za dalja kontinualna unapređenja. Odnosno, koncept Industrije 4.0 se nadovezuje i nadograđuje na postojeće upravljačke pristupe koji se koriste u proizvodnim sistemima. Za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara neophodno je odrediti da li se primenjuje određeni upravljački pristup i u kojoj meri su zastupljeni, kako bi se došlo do podataka koji su prikupljeni, a samim tim i izvršila procena stanja proizvodnog sistema. Stoga, kriterijum upravljačkih pristupa se odnosi na pitanje da li se primenjuju upravljački pristupi (*Lean*, WCM, TPM, TQM, itd.) u proizvodnom sistemu.
- **podaci** – predstavljaju glavnu komponentu za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u cilju digitalne transformacije proizvodnog sistema. Prikupljanje i analiza velike količine podataka tokom proizvodnih procesa postalo je potreba industrije kako bi se odgovorillo na željeni cilj. Analizom prikupljenih podataka povećava se produktivnost, utiče se na kvalitet proizvodnje i proizvoda što dovodi do smanjenja troškova. Prilikom kreiranja fazi ekspertnog sistema za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara na osnovu definisanog kriterijuma vezanog za podatke, postavlja se pitanje o prikupljanju podataka o mašinama i procesima tokom proizvodnje, kao i o analiziranju prikupljenih podataka određenih uticajnih parametara, kao jednom od najvećih izazova pronađenih u raspoloživoj

literaturi [7], [90], [97], [238], [239]. Stoga, kriterijum podataka se odnosi na pitanje da li se prikupljaju i analiziraju procesni parametri dostupni tokom procesa proizvodnje u proizvodnom sistemu.

- **nivo automatizacije** – predstavlja stepen opremljenosti proizvodnog sistema mehaničkim, elektronskim i računarskim sistemima u radu i upravljanju proizvodnim procesima. Primenom mehaničkih, elektronskih i računarskih sistema u radu i upravljanju smanjuje se uticaj ljudskog faktora, a samim tim smanjuju se i procenat nastanka određenih grešaka. Takođe, sve opasne operacije koje potencijalno mogu da naruše bezbednost radnika, kao i poslovi koji zahtevaju upotrebu opasnih materija i rad sa metalima, zahtevaju povećan nivo automatizacije. Stoga, inženjeri teže da kombinuju automatizovane uređaje sa matematičkim i organizacionim modelima, kako bi napravili složene sisteme za širu oblast primene. Trenutno, u proizvodnim sistemima automatizacija proizvodnje je prešla sa povećane proizvodnje i smanjenja troškova na kompleksije probleme, kao što su povećanje kvaliteta proizvoda i proizvodnih procesa i fleksibilnosti u procesu proizvodnje. To je omogućeno primenom:
 - hardverskih komponenti za automatizaciju i kontrolu procesa (programabilni logički kontrolери (PLC), aktuatori, analogno-digitalni pretvarači, digitalno-analogni pretvarači, industrijska robotika, itd.),
 - automatske identifikacije i zapisa podataka (senzori, RFID, bar-kod za optičko predstavljanje podataka, itd.)
 - softverskih alata za merenje, praćenje i kontrolu proizvodnih sistema (SCADA, MES, ERP, PDM, PDA, MDC, CAD, itd.)²

Stoga, nivo automatizacije predstavlja vrlo bitan kriterijum prilikom razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima, gde je neophodna integracija postojećih sistema u svrhu razvoja modela. Zbog toga, nivo automatizacije, kao kriterijum za razvoj fazi ekspertnog sistema radi procene stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara, dobija se odgovorom na pitanje da li postoji primena automatizacije u vidu implementacije odgovarajućih mehaničkih, elektronskih i računarskih sistemima u proizvodnom sistemu.

² SCADA – supervisory control and data acquisition

MES – manufacturing execution system

ERP – enterprise resource planning

PDM – product data management

PDA – production data acquisition

MDC – machine data collection

CAD – computer-aided design

- **napredne tehnologije** – podrazumevaju primenu naprednih tehnologija, definisanih u okviru koncepta Industrije 4.0 [7], koje potpomažu razvoju modela za rano otkrivanje neusaglašenosti procesnih parametara. Primena naprednih tehnologija odnosi se na: postojanje standardizovanih informaciono – komunikacionih tehnologija (IoT/IIoT) i njihovu razvijenost, korišćenje napredne računarske tehnologije za skladištenje i analizu podataka (*Cloud, Fog i Edge Computing*), korišćenje komunikacije mašina sa mašinom (M2M), primena veštačke inteligencije u proizvodnim procesima, itd. Primena naprednih tehnologija nije nužan kriterijum koji mora biti ispunjen za razvoj modela. Međutim, njihova primena značajno olakšava razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima. Stoga, kriterijum napredne tehnologije se odnosi na to da li uopše postoji primena naprednih tehnologija koncepta Industrije 4.0 u proizvodnom sistemu ili ne.

U tabeli 4 dat je pregled definisanih kriterijuma za razvoj fazi ekspertnog sistema za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara kako bi se objektivno procenilo trenutno stanje sistema.

Tabela 4. Kriterijumi za razvoj fazi ekspertnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara

Kriterijumi	Pitanje za kompaniju na osnovu kriterijuma	Lingvistička promenljiva	Pripadajuće funkcije
Strategija kompanije	Da li postoji strategija u okviru kompanije koja se odnosi na primenu modela za rano otkrivanje neusaglašenosti procesnih parametara?	- Ne postoji strategija - Strategija u razvoju (razmatranje pilot projekata kao početni korak za razvoj strategije)	(0, 0.25, 0.5) (0.25, 0.5, 0.75)
		- Strategija u primeni (primena pilot projekata)	(0.5, 0.75, 1)
		- Sprovedena strategija (implementiran RONP model)	(0.75, 1, 1)
Ljudski resursi	Da li su radnici voljni i adekvatno obučeni da aktivno učestvuju u unapređenju proizvodnog sistema primenom modela za rano otkrivanje neusaglašenosti procesnih parametara?	- Nisu voljni i nisu obučeni - Nisu voljni, ali su obučeni - Voljni su, ali nisu obučeni - Voljni su i adekvatno obučeni	(0, 0.25, 0.5) (0.25, 0.5, 0.75) (0.5, 0.75, 1) (0.75, 1, 1)

Upravljački pristupi	Da li se primenjuju upravljački pristupi (<i>Lean</i> , WCM, TPM, TQM, itd.) u proizvodnom sistemu?	- Uopšte se ne primenjuju upravljački pristupi (0, 0.3, 0.6)
		- Delimično se primenjuju upravljački pristupi (0.5, 0.7, 0.9)
		- U potpunosti se primenjuju upravljački pristupi (0.8, 1, 1)
Podaci	Da li se prikupljaju i analiziraju procesni parametri dostupni tokom procesa proizvodnje u proizvodnom sistemu?	- Ne prikupljaju se i ne analiziraju se (0, 0.25, 0.5)
		- Prikupljaju se pojedini parametni, ali se ne analiziraju (0.25, 0.5, 0.75)
		- Prikupljaju se pojedini parametni i analiziraju se (0.5, 0.75, 1)
		- Prikupljavaju se svi parametri i analiziraju se (0.75, 1, 1)
Nivo automatizacije	Da li postoji primena automatizacije u vidu primene odgovarajućih mehaničkih, elektronskih i računarskih sistema u proizvodnom sistemu?	- Ne postoji automatizacija (0, 0.25, 0.5)
		- Nedovoljan nivo automatizacija (0.25, 0.5, 0.75)
		- Dovoljan nivo automatizacija (0.5, 0.75, 1)
		- Potpuna automatizacija (0.75, 1, 1)
Napredne tehnologije	Da li postoji primena naprednih tehnologija koncepta Industrije 4.0 u proizvodnom sistemu?	- Ne postoji primena (0, 0.25, 0.5)
		- Ne postoji, ali se razmatra primena pojedinih naprednih tehnologija (0.25, 0.5, 0.75)
		- Primena zasnovana na pilot projektima (0.5, 0.75, 1)
		- Potpuna implementacija određenih naprednih tehnologija (0.75, 1, 1)

Svaki kriterijum može biti definisan od strane jedne ili više lingvističkih promenljivih koje imaju kvantitativno interpretirane vrednosti (tabela 4). Kvantitativna vrednosti svake lingvističke promenljive predstavljena je pomoću skale od 0 do 1 na osnovu znanja eksperata iz proizvodnog sistema. Stoga, definisanjem pripadajućih funkcija promenljivih javlja se određen stepen nesigurnosti prilikom definisanja granica područja i ocenjivanja pogodnosti dobijenih vrednosti. Posmatranje nesigurnosti pri definsanju granica područja na rasplinuti način omogućava iterpretaciju podataka pomoću definisanja međupodručja i ekstremnih područja. Razvijeni fazi ekspertnog sistema integriše procentualne vrednosti promenljivih u standardizovane kriterijume za podršku pri proceni stepena spremnosti proizvodnog sistema kako bi se procenilo njegovo trenutno stanje kao preduslov za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara.

Za svaki kriterijum dizajniran je Mamdani fazi sistem zaključivanja (*Mamdani Fuzzy Inference System- FIS*) za definsanje pripadajućih funkcija na osnovu ekspertsog znanja i integraciju podataka korišćenjem FIS editora u okviru *Matlab* softverskog paketa.

Fleksibilnost razvijenog ekspertnog sistema ogleda se u lakoći modifikacije i prilagođavanja različitim proizvodnim sistemima, iz razloga što svi sistemi dele zajedničke osobine u fazifikaciji i defazifikaciji. Glavne razlike se nalaze u bazi znanja. Baza znanja izražena je u smislu fazi AKO-ONDA (*IF-THEN*) pravila, koja predstavljaju jezgro sistema. Razlog zbog kojeg se nisu koristile relacije (*AND (I)* i *OR (IL)*) prilikom definisanja baze znanja jeste taj što se težilo njenom pojednostavljinju gde mora da postoji prisutnost svih navedenih kriterijuma u određenoj meri kako bi moglo da se pristupi razvoju modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima. Stoga, za svaki kriterijum odlučivanja su:

1. identifikovane ulazne promenljive, njihov opseg i funkcije pripadnosti,
2. identifikovane izlazne promenljive, njihov opseg i funkcije pripadnosti,
3. definisana pravila koja opisuju relacije između ulaza i izlaza sistema i
4. određene metode defazifikacije za kombinovanje fazi pravila na izlaze.

Fazifikaciona komponenta, zasnovana je na trouglastim funkcijama pripadanja, definisana je kao:

$$f(x; a, b, c) = \max (\min (((x - a)/(b - a)), ((c - x)/(c - b))), 0), \quad (12)$$

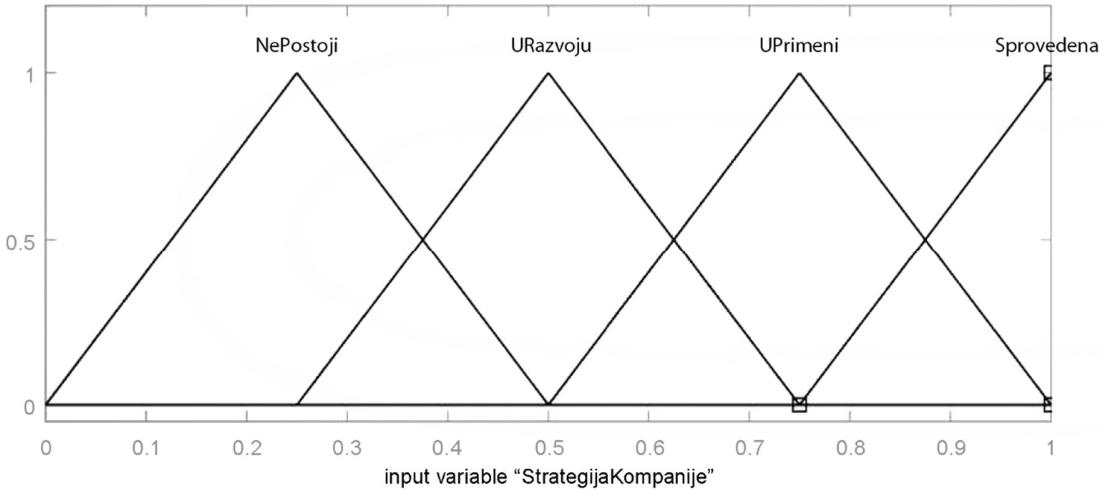
gde parametri a i c predstavljaju stranice trougla, a parametar b definiše vrh trougla.

Baza znanja fazi ekspertnog sistema kreira se u saradnji sa ekspertima iz proizvodnog sistema na osnovu koje se vrši analiza definisanih kriterijuma gde je za svaki kriterijum definisano fazi pravilo prema iskazu:

$$\text{IF } (x \text{ is } A) \text{ THEN } (y \text{ is } B) \quad (13)$$

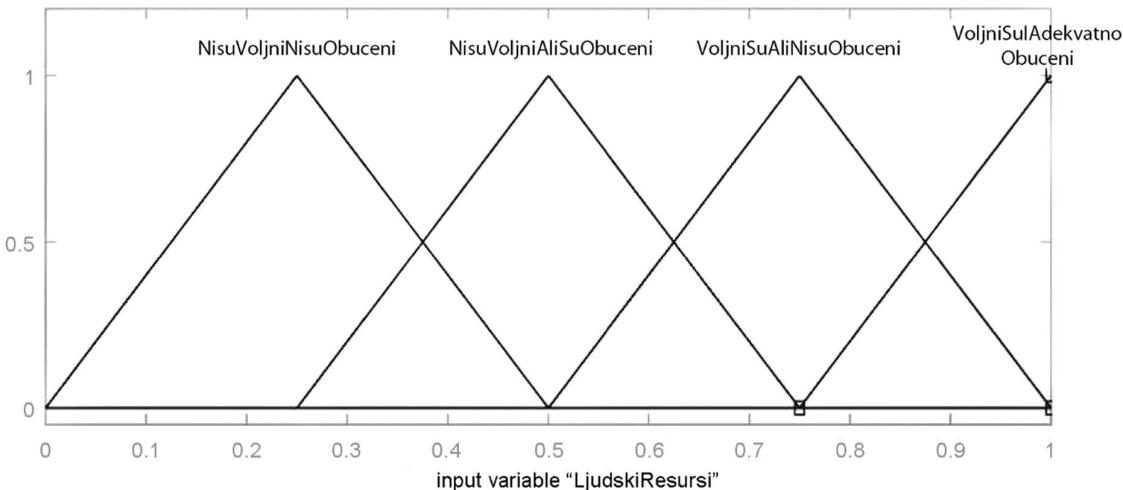
gde su A i B fazi skupovi definisani kao ulazne i izlazne veličine. Prvi deo pravila x je A predstavlja postavku pravila, dok drugi deo pravila y je B izražava rezultat.

Za kriterijum *strategija kompanije* definisane su četiri trouglaste pripadajuće funkcije za vrednosti promenljivih. Izgled definisanih pripadajućih funkcija za kriterijum *strategija kompanije* je prikazan na slici 45.



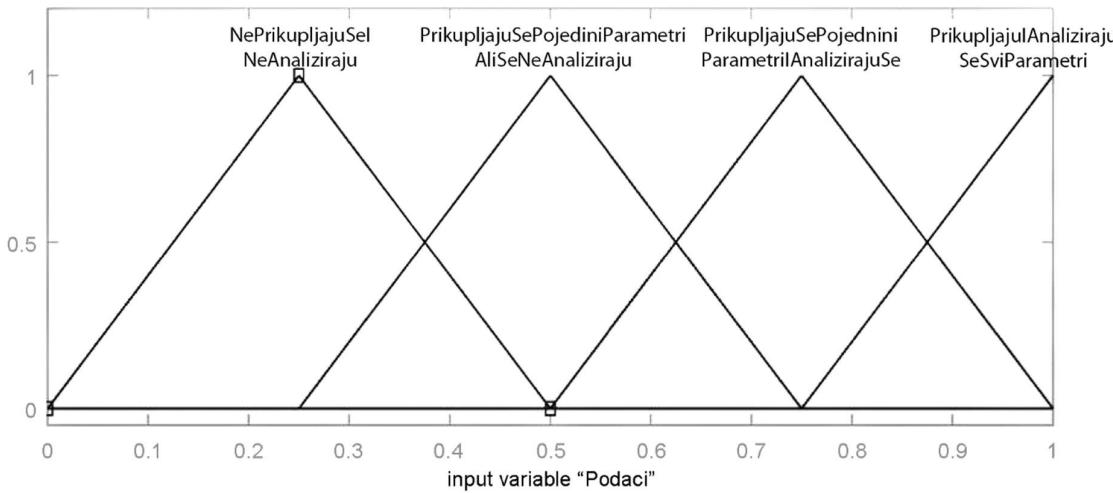
Slika 45. Pripadajuće funkcije za kriterijum „strategija kompanije“ (MATLAB)

Za kriterijum *ljudski resursi* definisane su četiri trouglaste pripadajuće funkcije za vrednosti promenljivih. Izgled definisanih pripadajućih funkcija za kriterijum *ljudski resursi* je prikazan na slici 46.



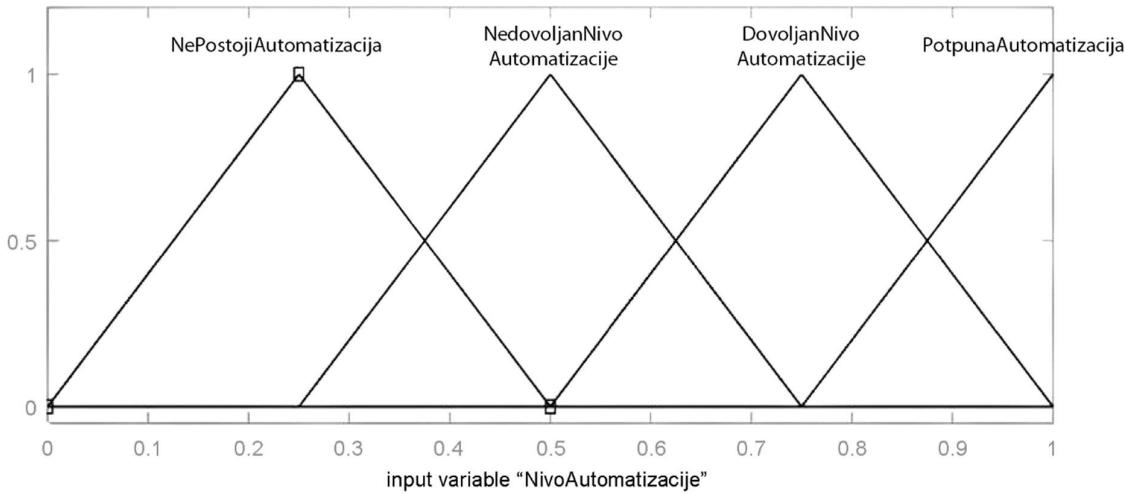
Slika 46. Pripadajuće funkcije za kriterijum „ljudski resursi“ (MATLAB)

Za kriterijum *podaci* definisane su četiri trouglaste pripadajuće funkcije za vrednosti promenljivih. Izgled definisanih pripadajućih funkcija za kriterijum *podaci* je prikazan na slici 47.



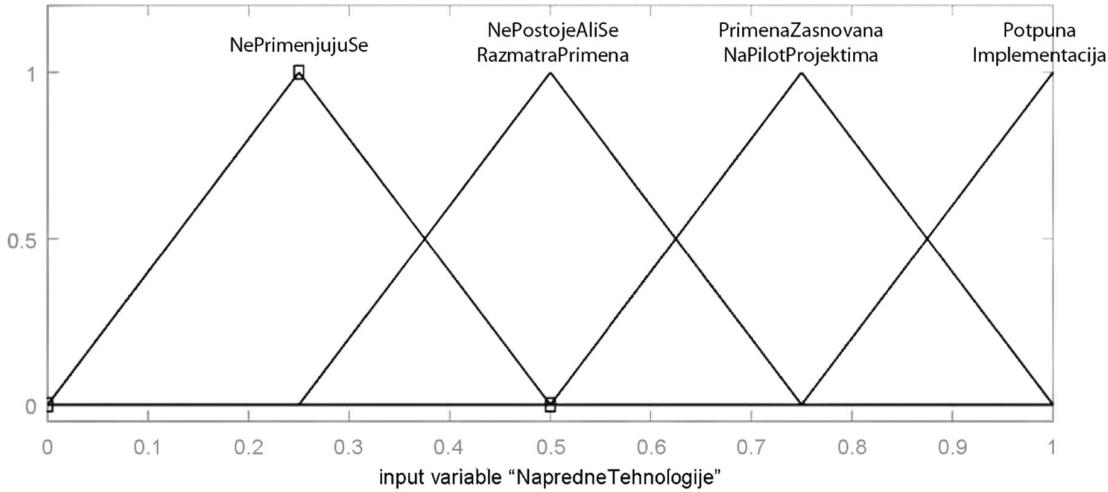
Slika 47. Pripadajuće funkcije za kriterijum „podaci“ (MATLAB)

Za kriterijum *nivo automatizacije* definisane su četiri trouglaste pripadajuće funkcije za vrednosti promenljivih. Izgled definisanih pripadajućih funkcija za kriterijum *nivo automatizacije* je prikazan na slici 48.



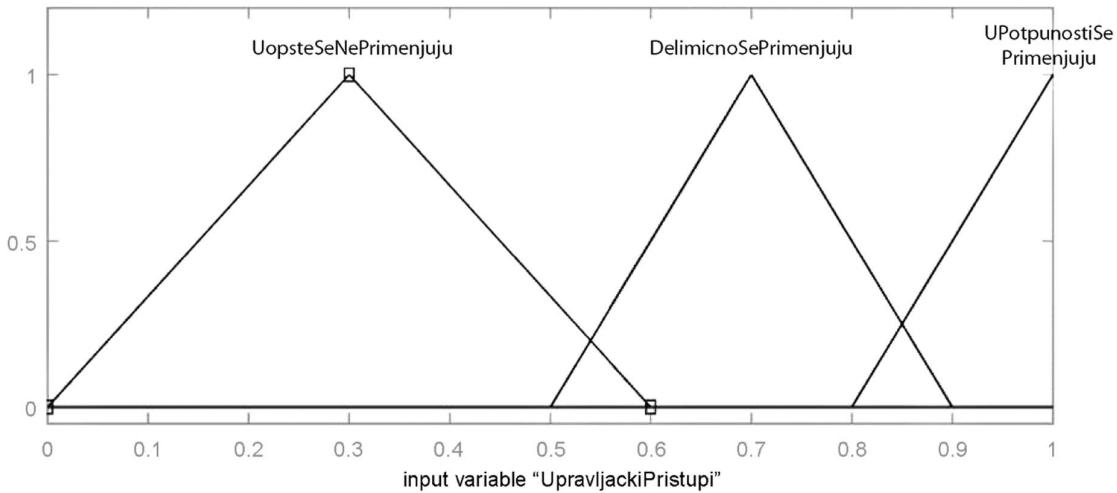
Slika 48. Pripadajuće funkcije za kriterijum „nivo automatizacije“ (MATLAB)

Za kriterijum *napredne tehnologije* definisane su četiri trouglaste pripadajuće funkcije za vrednosti promenljivih. Izgled definisanih pripadajućih funkcija za kriterijum *napredne tehnologije* je prikazan na slici 49.



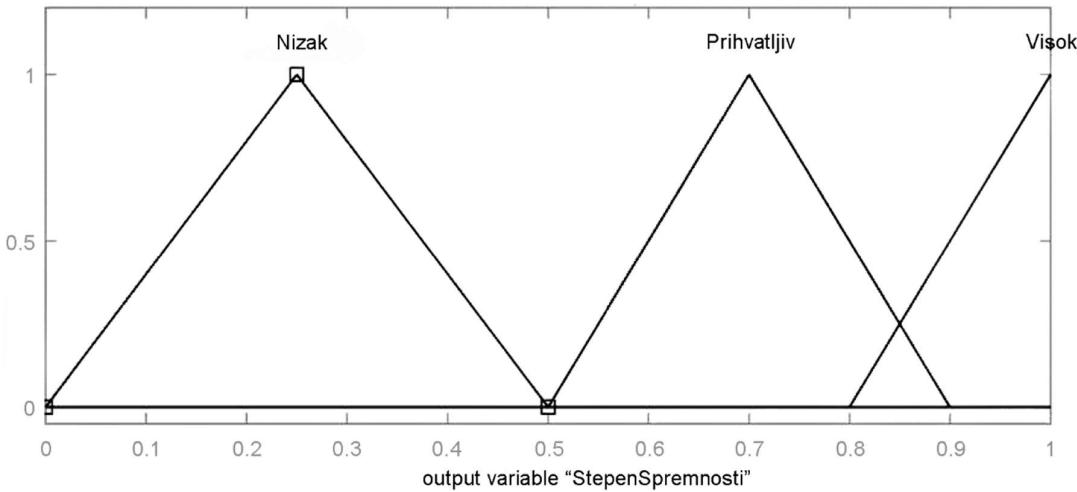
Slika 49. Pripadajuće funkcije za kriterijum „napredne tehnologije“ (MATLAB)

Za kriterijum *upravljački pristupi* definisane su tri trouglaste pripadajuće funkcije za vrednosti promenljivih. Izgled definisanih pripadajućih funkcija za kriterijum *upravljački pristupi* je prikazan na slici 50.



Slika 50. Pripadajuće funkcije za kriterijum „upravljački pristupi“ (MATLAB)

Izlazna vrednost fazi ekspertnog sistema za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara je definisan pomoću tri pripadajuće funkcije što je prikazano na slici 51.



Slika 51. Pripadajuće funkcije za izlaznu vrednost „stepen spremnosti“ (MATLAB)

Za sve kriterijume definisan je isti modul defazifikacije zasnovan na pripadajućoj funkciji izlazne promenljive u obliku vrednosti: nizak (0, 0.25, 0.5), prihvatljiv (0.5, 0.7, 0.9), i visok (0.8, 1, 1) na osnovu koje se dobija procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Na ovaj način sve ulazne vrednosti standardizovane su u opsegu vrednosti od 0 do 1 (odносно od 0 do 100%) za svaki kriterijum. U poslednjem koraku defazifikacije korišćen je metod zasnovan na centroid metodi.

Korišćena je ista postavka parametara fazi sistema zaključivanja za sve kriterijume i to:

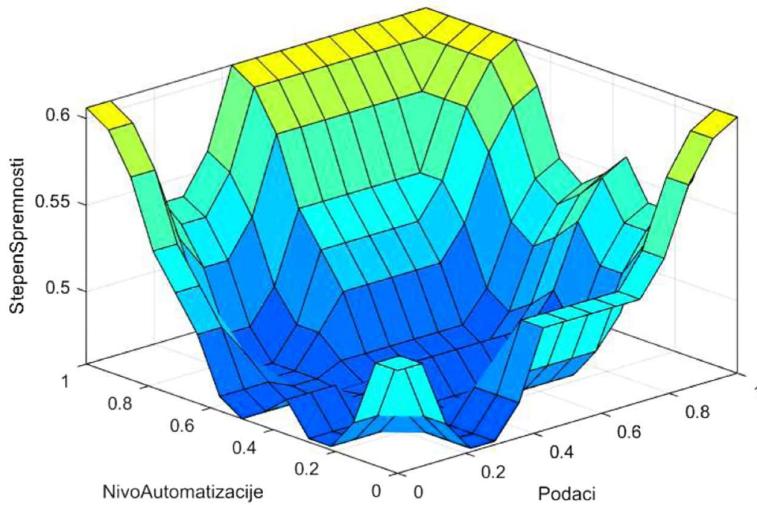
- *AND method - MIN*
- *OR method - MAX*
- *Implication - MIN*
- *Aggregation - MAX*
- *Defuzzification – CENTROID*

Nakon kreiranja pripadajućih funkcija kriterijuma, definisana su fazi pravila na osnovu kojih se određuje stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara, gde je u tu svrhu kreirano 23 fazi pravila. Fazi pravila su prikazana u tabeli 5.

Tabela 5. Pravila za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara

RB	Pravila i relacije
1.	If (StrategijaKompanije is NePostoji) then (StepenSpremnosti is Nizak)
2.	If (StrategijaKompanije is URazvoju) then (StepenSpremnosti is Prihvatljiv)
3.	If (StrategijaKompanije is UPrimeni) then (StepenSpremnosti is Prihvatljiv)
4.	If (StrategijaKompanije is Sprovedena) then (StepenSpremnosti is Visok)
5.	If (LjudskiResursi is NisuVoljniNisuObuceni) then (StepenSpremnosti is Nizak)
6.	If (LjudskiResursi is NisuVoljniAliSuObuceni) then (StepenSpremnosti is Prihvatljiv)
7.	If (LjudskiResursi is VoljniSuAliNisuObuceni) then (StepenSpremnosti is Prihvatljiv)
8.	If (LjudskiResursi is VoljniSuIAdekvatnoObuceni) then (StepenSpremnosti is Visok)
9.	If (UpravljačkiPristupi is UopsteSeNePrimenjuju) then (StepenSpremnosti is Nizak)
10.	If (UpravljačkiPristupi is DelimicnoSePrimenjuju) then (StepenSpremnosti is Prihvatljiv)
11.	If (UpravljačkiPristupi is UPotpunostiSePrimenjuju) then (StepenSpremnosti is Visok)
12.	If (Podaci is NePrikupljajuSeINeAnaliziraju) then (StepenSpremnosti is Nizak)
13.	If (Podaci is PrikupljajuSePojediniParametriAliSeNeAnaliziraju) then (StepenSpremnosti is Prihvatljiv)
14.	If (Podaci is PrikupljajuSePojedniniParametriIAnalizirajuSe) then (StepenSpremnosti is Prihvatljiv)
15.	If (Podaci is PrikupljajuIAnalizirajuSeSviParametri) then (StepenSpremnosti is Visok)
16.	If (NivoAutomatizacije is NePostojiAutomatizacija) then (StepenSpremnosti is Nizak)
17.	If (NivoAutomatizacije is NedovoljanNivoAutomatizacije) then (StepenSpremnosti is Nizak)
18.	If (NivoAutomatizacije is DovoljanNivoAutomatizacije) then (StepenSpremnosti is Prihvatljiv)
19.	If (NivoAutomatizacije is PotpunaAutomatizacija) then (StepenSpremnosti is Visok)
20.	If (NapredneTehnologije is NePrimenjujuSe) then (StepenSpremnosti is Nizak)
21.	If (NapredneTehnologije is NePostojeAliSeRazmatraPrimena) then (StepenSpremnosti is Prihvatljiv)
22.	If (NapredneTehnologije is PrimenaZasnovanaNaPilotProjektima) then (StepenSpremnosti is Prihvatljiv)
23.	If (NapredneTehnologije is PotpunaImplementacija) then (StepenSpremnosti is Visok)

Na grafiku 2 može se videti nelinearna funkcija u trodimenzionalnom prostoru na primeru dva kriterijuma i izlazne ocene, na osnovu definisanih pripadajućih funkcija i AKO-ONDA pravila.



Grafik 2. Nelinearna funkcija na primeru kriterijuma „nivo automatizacije“ i „napredne tehnologije“ (MATLAB)

4.2.2. Faza 2: Definisanje problema neusaglašenosti u proizvodnom sistemu

Svaki proces rešavanja problema počinje sa njegovim prepoznavanjem i određivanjem. Pri unapređenju proizvodnih sistema problemi koji se susreću mogu da budu okarakterisani kao različite vrste neusaglašenosti tokom proizvodnih procesa (problem kvaliteta proizvoda, problemi održavanja, itd.). Prepoznavanje i određivanje problema u proizvodnim sistemima su direkto vezani za karakteristike proizvodnog sistema, njegovo trenutno stanje i funkciju cilja.

Stoga, *Definisanje problema neusaglašenosti u proizvodnom sistemu* je druga faza razvoja modela za rano otkrivanje neusaglašenosti procesih parametara (slika 34) u proizvodnim sistemima. Pravilno definisan problem predstavlja kompleksan zadatak, jer je **neophodno posedovanje znanja o proizvodnom procesu, bazama podataka i infrastrukturi podataka, kao i ostvarenje saradnje sa inženjerima**, odnosno ekspertima za određeni proizvodni proces u okviru posmatranog proizvodnog sistema [185].

Na osnovu procenjenog trenutnog stanja proizvodnog sistema, kao prve faze razvoja RONP modela, pristupa se fazi 2 - *Definisanje problema neusaglašenosti u proizvodnom sistemu* - koja se sastoji od tri koraka:

1. preciziranje vrste neusaglašenosti,
2. određivanje lokacije nastanka neusaglašenosti, i
3. određivanje tipa problema neusaglašenosti.

Kao izlaznu informaciju nakon završene faze 2 - *Definisanje problema neusaglašenosti u proizvodnom sistemu* dobija se jasno definisan problem (slika 34).

4.2.2.1. Preciziranje vrste neusaglašenosti u proizvodnom sistemu

Polazna osnova za preciziranje vrste neusaglašenosti je u uskoj vezi sa određivanjem funkcije cilja unapređenja proizvodnog sistema, a samim tim i rešavanjem postojećih problema. Na osnovu toga vrste neusaglašenosti mogu biti vezane za probleme:

- nedovoljnog kvaliteta proizvoda,
- prestanka rada mašina,
- lomova pojedinih delova mašina, i
- upravljanja proizvodnim procesima.

Do ovih problema dolazi najčešće usled nastanka neusaglašenosti procesnih parametara. Preciziranje vrste neusaglašenosti u proizvodnom sistemu je određeno na osnovu postojećeg problema koji se javlja tokom proizvodnih procesa.

4.2.2.2. Određivanje lokacije nastanka neusaglašenosti u proizvodnom sistemu

Nakon preciziranja vrste neusaglašenosti, odnosno odrednica koje je opisuju, sledeći korak jeste određivanje lokacije njenog nastanka. Lokacija nastanka neusaglašenosti se određuje uz pomoć saradnje eksperata iz proizvodnog sistema koji su upoznati sa proizvodnim procesom za koji se razvija RONP model. Zajedno sa njima neophodno je razmotriti sva moguća potencijalna mesta, gde se kasnije vrši sužavanje izbora lokacije nastanka neusaglašenosti. Važno je naglasiti da lokacija nastanka precizirane neusaglašenosti može da obuhvata jednu ili više mašina u proizvodnom sistemu.

4.2.2.3. Određivanje tipa problema neusaglašenosti u proizvodnom sistemu

Tip problema neusaglašenosti u proizvodnom sistemu se određuje na osnovu precizirane vrste neusaglašenosti, gde se razlikuju dva tipa problema - **klasifikacioni ili regresioni načini određivanja tipa problema**.

Klasifikacioni problem predstavlja određivanje tipa problema neusaglašenosti na osnovu nezavisnih promenljivih (procesnih parametara) u funkciji zavisne promenljive, koja može da ima dve ili više klase na osnovu čega se donose zaključci iz posmatranih vrednosti nezavisnih promenljivih. S obzirom na činjenicu da u proizvodnim sistemima postoji više od jedne nezavisne značajne promenljive, klasifikacioni tip problema vrši predviđanje vrednosti jednog ili više ishoda. Drugim rečima, klasifikacija predstavlja predviđanje kategoričke oznake klase, odnosno razvrstavanja nepoznate instance u jednu od unapred ponuđenih klasa, koji se zasniva na pronalaženju sličnosti sa unapred određenim objektima koji su pripadnici različitih klasa, pri čemu se sličnost dva objekta određuje analizom njihovih karakteristika sa određenom tačnošću. Zadatak definisanja klasifikacionog tipa problema, na osnovu unapred poznate

klasifikacije jeste razvoj matematičkog modela na osnovu koga će se vršiti klasifikacija novih uzoraka, gde je broj klasa unapred poznat i ograničen [168].

Za razliku od klasifikacionog, regresioni tip problema predstavlja definisanje problema neusaglašenosti na osnovu kontinualnih nezavisnih promenljivih u slučaju kada je zavisna promenljiva, takođe, kontinualna, odnosno kvantitativna vrednost na osnovu kojih se donose odluke. Obzirom na činjenicu da u proizvodnim sistemima postoji više od jedne nezavisne značajne promenljive, regresiono definisanje problema vrši predviđanje tačno iskazane vrednost, gde se mogu primenjivati više različitih matematičkih modela, od kojih je najjednostavnija i najčešće primenjivana linearna regresija [156].

4.2.3. Faza 3: Identifikacija uticajnih parametara i prikupljanje podataka

Faza 3 - *Identifikacija uticajnih parametara i prikupljanja podataka* (slika 34) - podrazumeva proces stalne komunikacije i diskusije između inženjera zaposlenih u proizvodnim sistemima i istraživača koji razvijaju model za rano otkrivanje neusaglašenosti procesnih parametara, kako bi se ustanovilo koji parametri utiču na definisani problem neusaglašenosti (*faza 2 RONP modela*) na osnovu znanja i iskustva eksperata. Takođe je neophodno uzeti u obzir i one parametre koji indirektno utiču na nastanak definisanog problema u proizvodnom sistemu, a samim tim imaju i značajan uticaj na razvoj modela.

Identifikacijom svih uticajnih parametara se omogućava prikupljanje podataka generisanih tokom proizvodnog procesa. Prikupljanje podataka koji su vezani isključivo za identifikovane uticajne parametre omogućavaju optimalno korišćenje prostora baze podataka.

Stoga, *Identifikacija uticajnih parametara i prikupljanje podataka* je treća faza razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima koja se sastoji od pet koraka:

1. definisanje kriterijuma za identifikaciju uticajnih parametara,
2. identifikacija uticajnih parametara,
3. dostupnost uticajnih parametara,
4. određivanje tipa podataka uticajnih parametara, i
5. prikupljanje podataka uticajnih parametara.

Kao izlaznu informaciju nakon završene faze 3 - *Identifikacija uticajnih parametara i prikupljanje podataka* - dobijaju se definisani parametri i njihove prikupljene vrednosti neophodne za obradu podataka (slika 34).

4.2.3.1. Definisanje kriterijuma za identifikaciju uticajnih parametara

Kriterijumi na osnovu kojih se vrši identifikacija parametara direktno zavise od preciziranja vrste neusaglašenosti (*faza 2: korak 1 RONP modela*) u proizvodnom sistemu, kao i od lokacije nastanka definisane neusaglašenosti (*faza 2: korak 2 RONP modela*). Definisanje kriterijuma se odnosi na pojednostavljivanje definisanog problema kako bi se lakše izvršila identifikacija uticajnih parametara.

Korak 1 - Preciziranje vrste neusaglašenosti (faza 2 RONP modela) - za definisanje kriterijuma za identifikaciju uticajnih parametara, podrazumeva da se za:

- nedovoljan kvalitet proizvoda posmatra određeni proizvod, proizvod predstavnik ili određena grupa proizvoda odabralih na osnovu utvrđenih i definisanih sličnosti proizvodnog procesa,
- prestanak rada mašina definišu kriterijumi za najčešći uzrok nastanka ključnog problema ne uzimajući u razmatranje druge probleme,
- lomove pojedinih delova mašina razmatraju tačni razlozi nastanka loma ne posmatrajući indirektne i manje uticajne parametre, i
- upravljanje proizvodnim procesima bira deo proizvodnog sistema koji stvara najveću neizvesnost u njegovom upravljanju.

Posmatrajući korak 2 -*Odredivanje lokacije nastanka neusaglašenosti (faza 2 RONP modela)* - kriterijum za identifikaciju uticajnih parametara jeste razmatranje samo onih parametara koji se generišu direktno na definisanoj lokaciji.

4.2.3.2. Identifikacija uticajnih parametara

Korak 2 u fazi 3 RONP modela jeste definisanje samih uticajnih parametara i njihov odabir. Uticajni parametri se biraju na osnovu definisanih kriterijuma za identifikaciju uticajnih parametara u saradnji sa ekspertima iz posmatranog proizvodnog sistema. Znanje eksperata je ključno u ovom koraku, jer bez tačnog definisanja i odabira uticajnih parametara, validnost modela za definisani problem se dovodi u pitanje.

4.2.3.3. Dostupnost uticajnih parametara

Dostupnost uticajnih parametara je direktno vezana za stepen spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Stepen spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara (*faza 1: korak 3 RONP modela*) podrazumeva postojanje velikog broja senzora za svaki uticajni parametar radi merenja njihovih vrednosti tokom proizvodnog procesa. Takođe, primena programabilnih logičkih kontrolera (PLC) je neizostavna iz razloga

što omogućava prikupljanje vrednosti uticajnih procesnih parametara u tačnom trenutku njihovog generisanja.

Dostupnost uticajnih parametara se proverava primenom metode intervju sa ekspertima iz proizvodnog sistema. Međutim, ukoliko se u ovom koraku zaključi da nisu svi uticajni procesni parametri dostupni, naredni korak mora biti podizanje nivoa digitalizacije proizvodnog sistema. Nakon podizanje nivoa digitalizacije proizvodnog sistema se ponovo vrši provera dostupnosti svi uticajnih parametara za definisani problem.

4.2.3.4. Određivanje tipa podataka uticajnih parametara

Dostupnost uticajnih parametara odražava se na generisanje i prikupljanje procesnih podataka, tačnije na generisanje i prikupljanje vrednosti uticajnih parametara, tokom proizvodnih procesa u odabranom proizvodnom sistemu. Tipovi podataka direktno utiču na odabir metoda za razvoj matematičkog modela (*faza 5 RONP modela*). Stoga, važno je odrediti kom tipu podataka pripada generisana vrednost uticajnih parametara. Tipovi podataka koji su dostupni proizvodnim sistemima okaraterisani su kao:

- tekstualni,
- numerički, i
- vremenski.

Tekstualni tipovi podataka se koriste za čuvanje tekstualnih vrednosti, kao što su imena, opisi, oznake, šifre, itd. Oni se razlikuju prema načinu skladištenja i čuvanja vrednosti, kodiranju tekstualnog zapisa i prema maksimalnoj dužini tekstualne vrednosti koja može da se čuva u poljima određenog tipa. Stoga, tekstualni tipovi podataka se dele na *kodirane* i *nekodirane* tipove podatke.

- *Kodirani tekstualni tipovi podataka* se koriste za čuvanje tekstualnih vrednosti, gde tekst nije kodiran ASCII kodnom mapom, već UNICODE kodnom mapom promenljive širine. Najčešće se dužina vrednosti ovih tipova podataka izražava u broju karaktera.
- *Nekodirani*, odnosno *binarni tipovi podataka* se koriste za čuvanje binarnih zapisa, kao što su sadržaji datoteka ili binarnih serijalizacija objekata iz programa. Najčešće se dužina vrednosti ovih tipova podataka izražava u broju bajtova.

Numerički tipovi podataka se koriste za čuvanje numeričkih vrednosti procesnih parametara, kao što su brzina, debljina, količina, itd. Osnovna podela numeričkih tipova podataka se ogleda u tome da li se čuvaju cele ili realne vrednosti procesnih parametara. Stoga, njihova podela se vrši na:

- celobrojne (celobrojni numerički tipovi podataka podržavaju vrednosti sa decimalnom pozicijom), i

- realne (dodatna podele realnih numeričkih tipova podataka se vrši na realne sa fiksnom i na realne sa promenljivom pozicijom decimalne tačke).

Pored osnovne podele numeričkih tipova podataka, postoji i podele na:

- označene (označeni numerički tipovi podataka podržavaju negativne vrednosti procesnih parametara), i
- neoznačene (neoznačeni numerički tipovi podataka podržavaju samo pozitivne vrednosti i nulu).

Vremenski tipovi podataka se koriste za čuvanje datuma, vremena, kombinacije datuma i vremena, intervala itd.

4.2.3.5. Prikupljanje podataka uticajnih parametara

Poslednji korak u fazi 3 razvoja RONP modela jeste prikupljanje vrednosti identifikovanih procesnih parametara u trenutku njihovog generisanja i skladištenja u određenu bazu podataka. Tako prikupljeni podaci predstavljaju sirove podatke. Sirovim podacima je važno odrediti format za čuvanje podataka (.txt, .xls, .csv, .json, .xml, itd.) kao i definisati način struktuiranja podataka. Prikupljeni podaci moraju da budu struktuirani u obliku matrice koja sadrži redove i kolone, odnosno neophodno je da skup podataka bude struktuiran kao dvodimenzionalna matrica.

Prikupljanje podataka iz proizvodnog sistema moguće je realizovati pomoću naprednih tehnologija, kao što su IoT zajedno sa *Cloud*, *Fog* ili *Edge* sistemima računarske tehnologije pružajući mogućnost skladišnjenja podataka u decentralizovanoj bazi. Formiranje decentralizovane baze podataka je od presudnog značaja za sigurnost prikupljenih podataka u proizvodnom sistemu.

4.2.4. Faza 4: Priprema i obrada prikupljenih podataka

Nakon završenog prikupljanja podataka, sledi faza 4 - *Priprema i obrada prikupljenih podataka* (slika 34). Polazna osnova ove faze jeste razumevanje prikupljenih sirovih podataka. Razumevanje sirovih podataka podrazumeva tumačenje dobijene matrice. Matrica prikupljenih podataka se sastoji od redova i kolona. U većini slučajeva redovi predstavljaju sve identifikovane nezavisne uticajne parametre, kao i jedan zavisni parametar određen od strane eksperata (*faza 4: korak 4 RONP modela*) koji se naknadno dodaje kreiranoj matrici (vrši se spajanje nezavisnih uticajnih parametara i zavisnog parametra u *fazi 4: korak 5 RONP modela*). Kolone matrice odgovaraju svakom pojedinačnom slučaju (uzorku) zabeleženom tokom proizvodnog procesa, što je predstavljeno na slici 52. Nakon tumačenja dobijene matrice

podataka, važno je sprovesti proces čišćenje i uklanjanja podataka koji ne bi doprineli poboljšanju rezultata razvijenog modela.

	<i>Definisani nezavisni uticajni parametri ($x_1, x_2, x_3, \dots, x_n$)</i>				<i>Zavisni parametar (y)</i>
<i>Uzorak 1</i>					
<i>Uzorak 2</i>					
:					
<i>Uzorak n</i>					

Slika 52. Matrični prikaz pravilno struktuirane tabelarne forme sa spojenim nezavisnim i zavisnim uticajnim parametrom

Stoga, *Priprema i obrada prikupljenih podataka* je četvrta faza razvoja modela za rano otkrivanje neusaglašenosti procesih parametara u proizvodnim sistemima koja se sastoji od pet koraka:

1. eliminacija nedoslednih, konstantnih i podataka sa šumom,
2. dodavanje vrednosti nepotpunim podacima,
3. redukcija broja prikupljenih procesnih parametara,
4. definisanje zavisnog parametra, i
5. optimizacija i kreiranje precizno odabranog skupa podataka za razvoj matematičkog modela.

Međutim, važno je naglasiti da nije neophodno sprovesti sve definisane korake. **Sprovođenje definisanih koraka ogleda se u univerzalnosti metodologije razvoja modela, koji zavisi isključivo od prirode prikupljenih podataka, kao i od definisanog problema prilikom primene modela u industrijskom okruženju.**

Kao izlaznu informaciju nakon završene faze 4 - *Priprema i obrada prikupljenih podataka* dobija se precizno definisan skup podataka, odnosno skup vrednosti uticajnih parametara (slika 34).

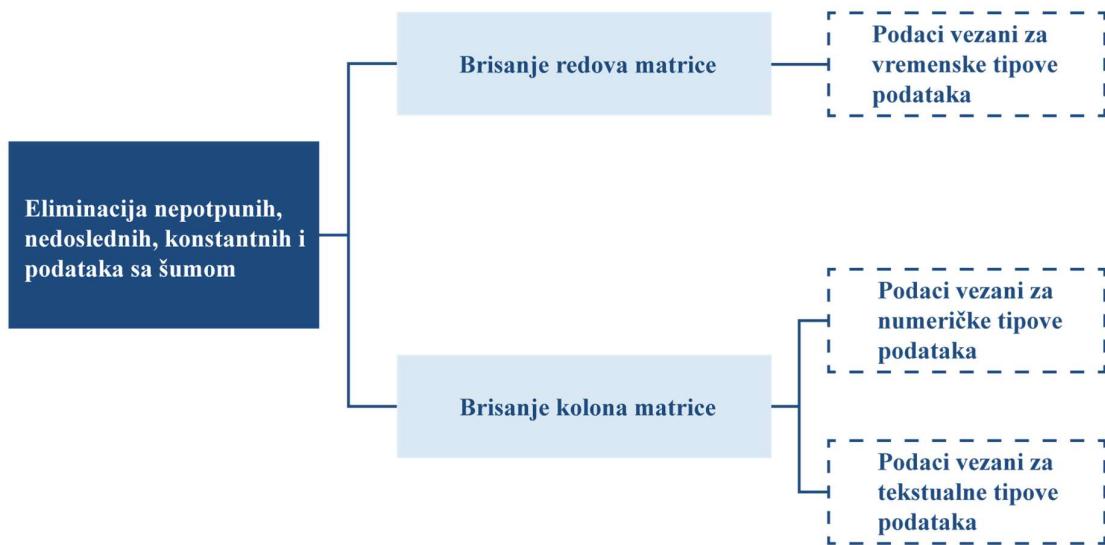
4.2.4.1. Eliminacija nedoslednih, konstantnih i podataka sa šumom

Podaci koji se generišu i prikupljaju tokom proizvodnih procesa mogu imati određene defekte. Najčešći uzrok nastanka defekata jesu problemi tokom procesa proizvodnje (prestanak napajanja, zastoj proizvodnje, itd.) i problemi komunikacionih mreža za prikupljanje podataka

u određenoj bazi (prekid komunikacije). Na osnovu toga, defekti među podacima mogu biti okarakterisani kao nepotpuni, nedosledni i podaci koji imaju šum. Stoga:

- nedosledni podaci predstavljaju vrednosti procesnih parametara koji sadrže odstupanja u kodovima ili imenima,
- konstantni podaci predstavljaju nepromenljive vrednosti procesnih parametara tokom proizvodnog procesa, i
- podaci sa šumom predstavljaju vrednosti procesnih parametara koji sadrže greške ili izdatke.

Podaci za koje je utvrđeno da imaju nabrojane defekte, potrebno je ukloniti kako ne bi negativno uticali na tačnost analiza, gde se vrši eliminacija redova ili kolona matrice u zavisnosti tipova podataka uticajnih parametara (slika 53).

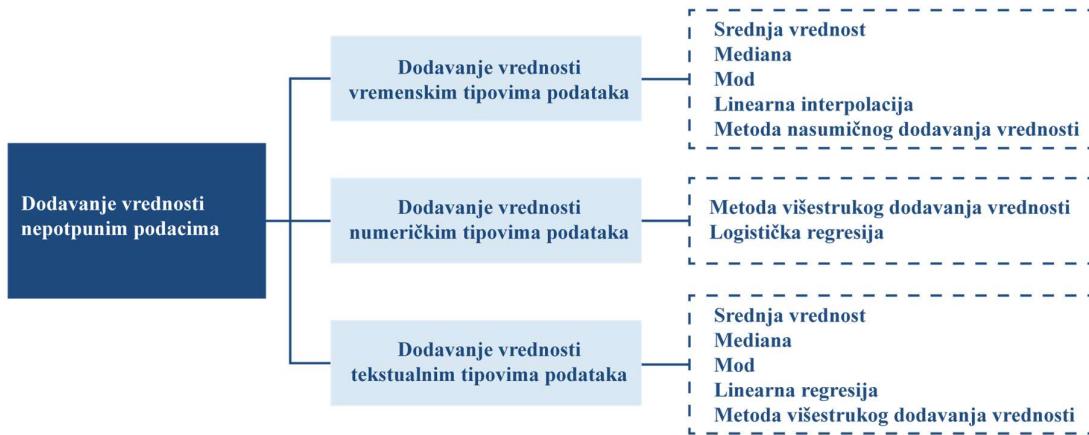


Slika 53. Eliminacija redova ili kolona matrice u zavisnosti tipova podataka uticajnih parametara

4.2.4.2. Dodavanje vrednosti nepotpunim podacima

Pored podataka sa nabrojanim defektima (*faza 4: korak 1 RONP modela*), podaci koji se generišu i prikupljaju tokom proizvodnih procesa mogu imati nedostajuće vrednosti procesnih parametara. Stoga, vrednosti procesnih parametara kojima nedostaju određeni atributi, pojedinačne vrednosti atributa, ili podaci koji sadrže samo zbirne vrednosti predstavljaju nepotpune podatke.

Nepotpune podatke je potrebno zameniti primenom odgovarajućih metoda za dodavanje vrednosti procesnih parametara u zavisnosti od tipa podataka (slika 54).



Slika 54. Načini dodavanja vrednosti nepotpunim podacima

4.2.4.3. Redukcija broja prikupljenih procesnih parametara

Kompleksnost razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara je u direktnoj vezi sa brojem uticajnih procesnih parametara, odnosno sa brojem nezavisnih promenljivih. Broj nezavisnih promenljivih u prikupljenom skupu podataka (*faza 3 RONP modela*) predstavlja njegovu dimenzionalnost. Smanjenjem broja nezavisnih promenljivih se ujedno smanjuje dimenzionalnost skupa podataka, a samim tim se smanjuje i kompleksnost razvoja matematičkog modela. Jedan od problema sa visokodimenzionalnim skupovima podataka jeste taj što nemaju sve nezavisne promenljive jednak uticaj za razumevanje i razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara. Stoga, važno je eliminisati one nezavisne promenljive koje imaju mali uticaj na razvoj matematičkog modela, a utiču na njegovu dimenzionalnost.

Smanjenje dimenzionalnosti se vrši pomoću statističkih tehnika koje smanjuju broj nezavisnih promenljivih i na taj način pojednostavljaju skup podataka. Najčešće korištene tehnike za smanjenje broja nezavisnih promenljivih [240] jesu sledeće:

- analiza glavnih komponenti,
- faktorska analiza,
- višeparametarska regresija, i
- korelaciona analiza.

Analiza glavnih komponenti predstavlja statističku analizu redukcije dimenzionalnosti skupa podataka, koji sadrže veliki broj međusobno povezanih nezavisnih promenljivih, na taj način da bude obuhvaćena što veća količina varijanse podataka. To se postiže izračunavanjem novog skupa nekorelisanih promenljivih, zvanih **glavne komponente** tako da prvih nekoliko glavnih komponenti obuhvati najveći deo varijanse sadržane u originalnim promenljivima

[241]. Cilj analize glavnih komponenti jeste i da se pronađe kombinacija nezavisnih varijabli da bi se izračunale nove varijable, odnosno komponente koje međusobno nisu u korelaciji i koje će opisivati varijacije podataka. Kada se radi analiza glavnih komponenti, želja je da varijanse većine dobijenih komponenti budu zanemarljivo male. Stoga, veći deo varijacija originalnih podataka se može adekvatno opisati sa svega nekoliko glavnih komponenti [240]–[242]. Na taj način se smanjuje broj nezavisnih promenljivih, koje su dobijene na osnovu faze 3 RONP modela gde se dobija ***manji broj glavnih komponenti***.

Faktorska analiza predstavlja jednu od multivarijacionih tehnika koja u cilju smanjivanje broja uticajnih nezavisnih promenljivih, u analizi definiše **faktore** koji se utvrđuju u postupku faktorske analize i objašnjavaju međusobni odnos posmatranih promenljivih. Na osnovu toga, cilj ove analize jeste da se umesto velikog broja međusobno povezanih promenljivih, koje su dobijene na osnovu faze 3 RONP modela, utvrdi ***manji broj međusobno nezavisnih faktora*** koje mogu objasniti međusobne odnose nezavisnih promenljivih [241]–[243].

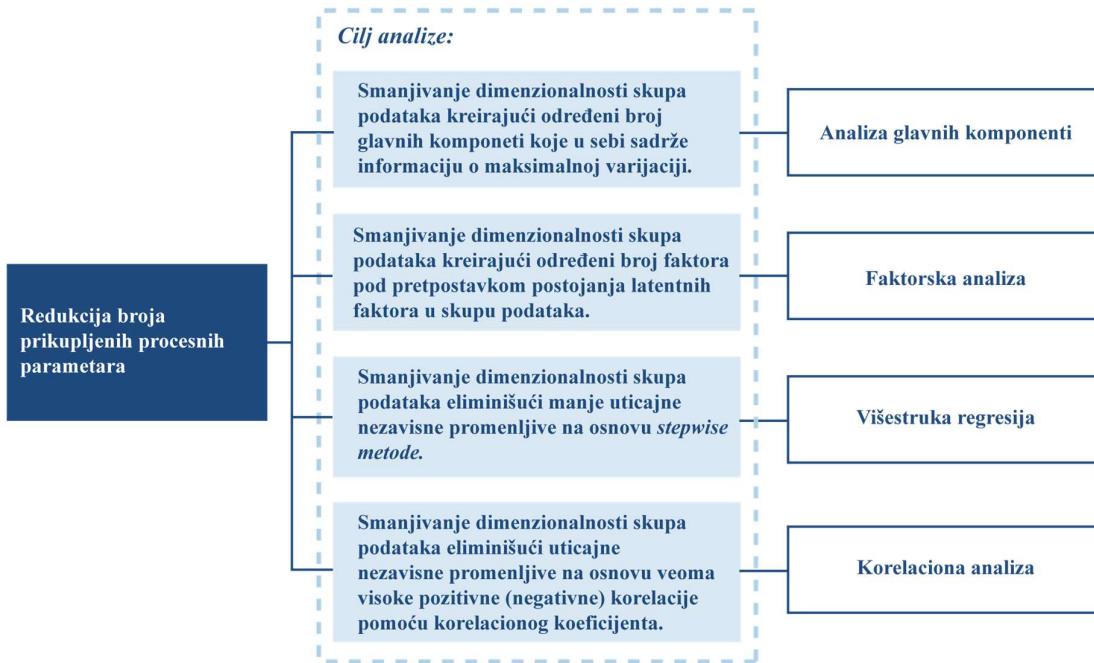
Višeparametarska regresija predstavljaju statističku metodu koja se koristi za smanjenja dimenzionalnosti skupa podataka koja ima za cilj da objasni zavisnu promenljivu uz pomoć niza nezavisnih promenljivih [240]. Metoda u okviru višeparametarske regresije koja se koristi za redukciju broja nezavisnih promenljivih jeste postupna (*stepwise*) regresija, gde se uklapaju različiti modeli koristeći različite podskupove nezavisnih promenljivih. Rezultati se zatim upoređuju izračunavanjem mera dobrog prilagođavanja, a podskup sa najboljom merom predstavlja skup parametara sa ***smanjenim brojem nezavisnih promenljivih***, koje su dobijene na osnovu faze 3 RONP modela.

Koreaciona analiza predstavlja zavisnost između dva nezavisna parametara. Njihova zavisnost se određuje na osnovu koeficijenta korelacije. Vrednost koeficijenta korelacije se kreće u rasponu od -1 do +1, gde vrednost -1 predstavlja potpunu negativnu, a vrednost +1 potpunu pozitivnu korelaciju. Vrednost 0 pokazuje da ne postoji povezanost između dva nezavisna parametara. Vrednosti koeficijenta koreacione analize su prikazani u koreacionoj matrici na osnovu koje se tumače dobijeni rezultati [165], [244]. Dobijeni rezultati se koriste kao statistički alat za donošenje odluka o tome koji nezavisni parametri, koji su dobijeni na osnovu faze 3 RONP modela, treba da budu eliminisani iz dalje analize na osnovu koreacionog koeficijenta. Statističko zaključivanje vrši na osnovu preporuka intervala kojem pripada vrednost koreacionog koeficijenta prikazanom u tabeli 6, gde je cilj ***eliminisanje svih nezavisnih parametara koji dovode do veoma visoke pozitivne (negativne) korelacije***.

Tabela 6. Vrednosti koeficijenta korelacione analize

Vrednost korelacionog koeficijenta	Interpretacija dobijene vrednosti
0.9 do 1 (-0.9 do -1)	Veoma visoka pozitivna (negativna) korelacija
0.7 do 0.9 (-0.7 do -0.9)	Visoka pozitivna (negativna) korelacija
0.5 do 0.7 (-0.5 do -0.7)	Umerena pozitivna (negativna) korelacija
0.3 do 0.5 (-0.3 do -0.5)	Niska pozitivna (negativna) korelacija
0 do 0.3 (0 do -0.3)	Zanemarljiva korelacija

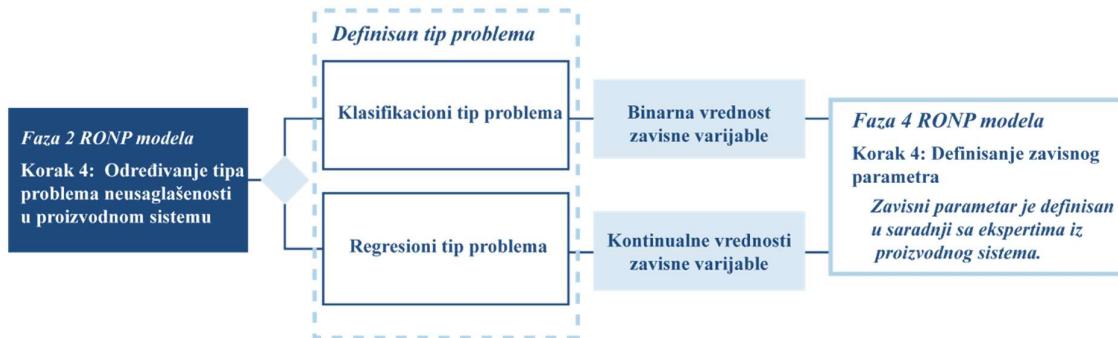
Odabir metoda za redukciju broja nezavisnih promenjivih radi smanjenja dimenzionalnosti skupa podataka zavisi od cilja analize, odnosno načina na koji je potrebno predstaviti najuticajnije nezavisne parametre. Na slici 55 je prikazan način odabira tehnike za redukciju broja nezavisnih promenljivih na osnovu cilja analize.



Slika 55. Odabir tehnike za redukciju broja prikupljeni parametara u zavisnosti od cilja analize

4.2.4.4. Definisanje zavisnog parametra

Korak 4 u fazi 4 - *Priprema i obrada prikupljenih podataka* - jeste definisanje zavisnog parametra. Zavisni parametar se bira na osnovu određenog tipa problema neusaglašenosti u proizvodnom sistemu (*faza 2: korak 4 RONP modela*), koji predstavlja izlaznu vrednost procesnih parametara tokom proizvodnog procesa, odnosno zavisnu varijablu (slika 56). Izlazna vrednost procesnih parametara se definiše u saradnji sa ekspertima iz posmatranog proizvodnog sistema i može da ima binarne vrednosti (ukoliko je problem definisan kao klasifikacioni) ili kontinualne vrednosti (ukoliko je problem definisan kao regresioni).

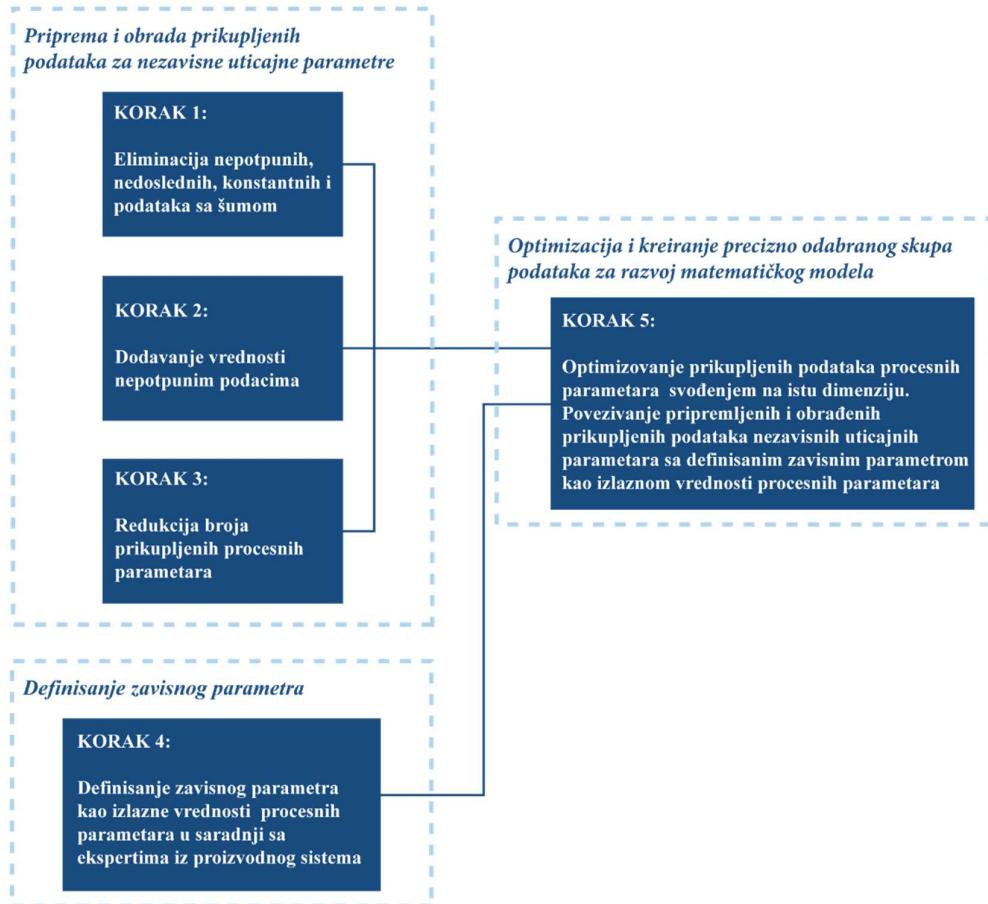


Slika 56. Način definisanja zavisnog parametra

4.2.4.5. Optimizacija i kreiranje precizno odabranog skupa podataka za razvoj matematičkog modela

Praćenje koraka od 1 do 4 u okviru faze 4 - *Priprema i obrada prikupljenih podataka* - predstavlja polaznu osnovu za kreiranje skupa koji sadrži precizno odabrane podatke za razvoj matematičkog modela. Korak 5 u okviru faze 4 RONP modela podrazumeva postupak optimizacije podataka prikupljenih nezavisnih procesnih parametara primenom statističke metode *Opseg* kako bi se svi prikupljeni fajlovi sveli na jedan jedinstveni fajl sa istom dimenzijom. Nakon toga sledi povezivanja prikupljenih procesnih parametara (koji su pripremljeni i obrađeni u okviru *koraka od 1 do 3, faza 4 RONP modela*) sa zavisnim parametrom (parametar je definisan u *koraku 4, faza 4 RONP modela*), što je prikazano na slici 57.

Rezultat uspešno završenog koraka 5 - *Kreiranje precizno odabranog skupa podataka za razvoj modela* - predstavlja izdefinisan i pripremljen skup podataka koji je spreman za sledeću fazu, odnosno za razvoj matematičkog modela.



Slika 57. Način optimizacije i kreiranja precizno posmatranog skupa podataka za razvoj modela

4.2.5. Faza 5: Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka

Baza konceptualnog RONP modela predstavlja razvoj matematičkog modela za rano otkrivanje neusaglašenosti pomoću izabrane grupe podataka. Stoga, nakon završene faze 4 RONP modela, sledi faza 5 - *Razvoj matematičkog modela za rano otkrivanje neusaglašenosti pomoću izabrane grupe podataka* (slika 34) - kao ključna faza u procesu ranog otkrivanja definisanih neusaglašenosti u proizvodnom sistemu.

S obzirom na činjenicu da faza 5 RONP modela direktno zavisi od prirode prikupljenih podataka (pogledati *fazu 4 RONP modela*), posebna pažnja se treba obratiti na (*korak 4 faze 4 RONP modela*, odnosno na **definisani zavisni parametar**). Definisani zavisni parametar određuje koja tehnika napredne analitičke metode može biti korišćena za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima.

Stoga, tehnike za razvoj matematičkog modela su najčešće nadgledane metode, gde zavisni parametar mora u određenoj meri da zavisi od definisanih nezavisnih parametara i sažima prethodno definisani problem, na osnovu kojeg se određuje da li će se primenjivati klasifikacioni alati za kategoričke vrednosti zavisnog parametra ili regresioni alati za kontinualne vrednosti zavisnog parametra (*faza 2: korak 3 RONP modela*).

Važno je naglasiti da se prilikom razvoja matematičkog modela koriste ekvivalentne tehnike naprednih statističkih metoda i metoda mašinskog učenja. Cilj upotrebe ekvivalentnih tehnika prilikom razvoja matematičkog modela jeste dobijanje rezultata komparativne analize (slika 58), a samim tim i objektivno određivanje koja tehnika daje prihvatljivije rezultate.

Rezultati uspešnosti prethodnih faza direktno su povezani sa rezultatima ove faze, odnosno faze 5 - *Razvoj matematičkog modela za rano otkrivanje neusaglašenosti pomoći izabrane grupe podataka* - a samim tim rezultati uspešnosti prethodnih faza utiču i na tačnost razvijenog modela.

Faza 5 RONP modela sastoji se od tri koraka, i to:

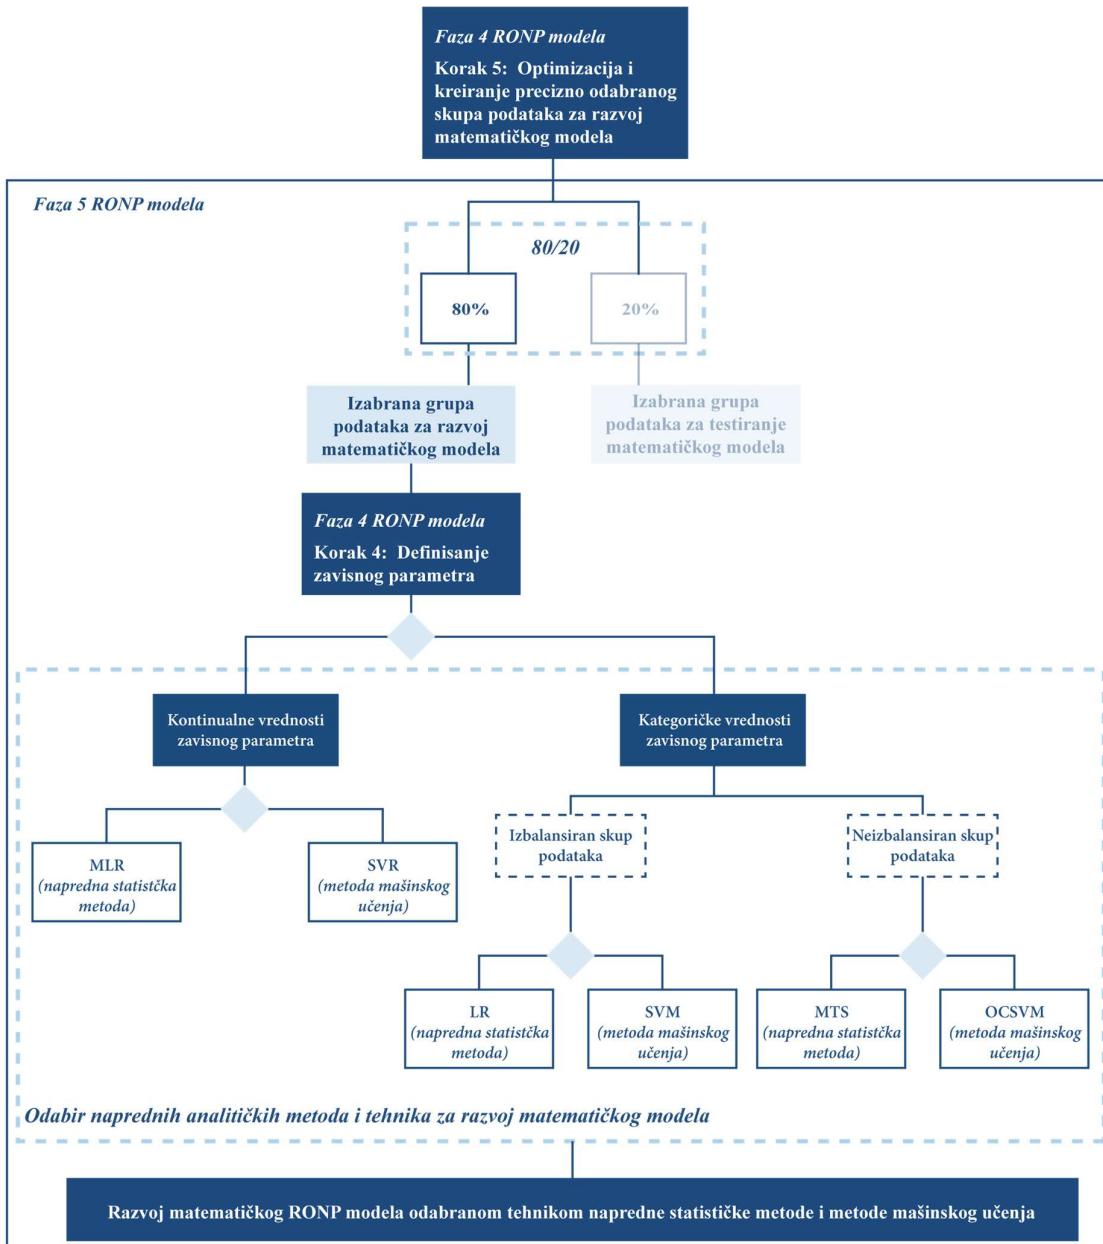
1. metodologija za podelu izabrane grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela,
2. odabir metoda i tehnika za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara, i
3. razvoj matematičkog modela u proizvodnim sistemima pomoći izabrane grupe podataka za razvoj modela i primenom izabrane metode i tehnike napredne analitike.

Kao prihvatljiv rezultat uspešno završene faze 5 - *Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoći izabrane grupe podataka* - jeste razvijen matematički model primenom ekvivalentnih tehnika napredne statističkih metode i metode mašinskog učenja (slika 58) sa visokom tačnošću (preko 95%) spremam za narednu fazu. Matematički model koji nema tačnost preko 95% se ne koristi u narednim fazama konceptualnog RONP modela.

4.2.5.1. Metodologija za podelu izabrane grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela

Metodologija za podelu podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela se koristi kako bi se lako postigla ponovljivost rezultata i kako bi se na jednostavan način izvršilo poređenje rezultata razvijenog matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara primenom različitih metoda za razvoj modela (porede se rezultati matematičkog modela dobijeni primenom različitih tehnika naprednih statističkih metoda i metoda mašinskog učenja). Upravo je to osnovni razlog zašto se u ovoj doktorskoj disertaciji ne primenjuje metoda nasumične podele grupe podataka

(određivanjem procentualnog odnosa između podataka za razvoj matematičkog modela i podataka za testiranje matematičkog modela njihovim nasumičnim odabirom), već se njihova podela zasniva na određenoj metodologiji. Podela podataka primenom određene metodologije dovodi do toga da se poseduje tačna informacija koji podaci su korišćeni za razvoj matematičkog modela, a koji za njegovo testiranje.



Slika 58. Postupak razvoja matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara

U većini pregledanih radova koji se bave razvojem matematičkog modela u proizvodnim sistemima [119], [200], [245]–[247] nije pronađena precizna informacija koja pruža detalje vezane za način odabira metodologije niti nudi predloge za podelu izabrane grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela. Međutim, Kursad i sar. [130] su uvideli važnost postojanja metodologije za podelu grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela, fokusirali su svoje istraživanje na metodologije nasumične podela podataka. Međutim, nasumična podela podataka nije razmatrana u ovoj doktorskoj disertaciji.

Gholamy, Kreinovich i Kosheleva [248] u svom naučnom izveštaju su objasnili zašto je $p \approx 80\%$ empirijski najbolja podela na skupove za razvoj i testiranje matematičkog modela. Stoga, metodologija za podelu izabrane grupe podataka na podatke koji su korišćeni za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara i podatke za testiranje matematičkog modela jeste odnos 80/20.

Prema tome, skup izabrane grupe podataka se deli prema odnosu 80/20, gde će se u izabranoj grupi podataka za razvoj matematičkog modela nalaziti 80% podataka izabranim hnonološkim redosledom, dok će se u skupu podataka za testiranje matematičkog modela nalaziti preostalih 20%. Drugim rečima, skup za testiranje koji se koristi u fazi 6 RONP modela, ima 20% od ukupnog broja podataka.

4.2.5.2. Odabir metoda i tehnika za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara

Metode za razvoj matematičkog modela u proizvodnim sistemima mogu biti zasnovane na primeni različitih metoda napredne analitike. Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara predstavlja proces upotrebe naprednih analitičkih metoda za kreiranje modela za detekciju definisanih neusaglašenosti u trenutku prikupljanja podataka kako bi se unapredio proizvodni proces i kvalitet proizvoda. Metode napredne analitike zasnivaju se na upotrebi različitih tehnika za razvoj matematičkog RONP modela (slika 58), koji mogu pripadati:

- naprednim statističkim metodama, i
- metodama mašinskog učenja.

4.2.5.2.1. Napredne statističke metode

Osnovne statističke metode poput intervala poverenja, t-testova i testova sa 2 proporcije pružaju odgovore na većinu pitanja koje istaživači koriste tokom svojih teorijskih istraživanja, kako bi se potvrdile ili opovrgle usvojene hipoteze. Međutim, da bi se došlo do odgovora na neka istraživačka pitanja koja su povezana sa unapređenjem proizvodnog procesa i kvaliteta proizvoda, a samim tim i proizvodnog sistema, neophodna je primena naprednije statistike sa

svrhom razvoja matematičkog modela, gde se na taj eksperimentalni način potvrđuju ili opovrgavaju postavljene hipoteze. Stoga, matematički model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima može da se razvija primenom naprednih statističkih metoda. Napredne statističke metode za razvoj matematičkog modela se zasnivaju na naprednim statističkim tehnikama gde je u određenim slučajevima zavisni parametar predstavlja kontinualnu vrednost, dok kod drugih tehnike zavisni parametar predstavlja kategoričku vrednost. Stoga, tehnike napredne statističke metode pomoću kojih se razvija matematički model jesu (slika 58):

- višeparametarska linearna regresija (MLR) – gde zavisni parametar ima kontinualne vrednosti,
- logistička regresija (LR) – gde zavisni parametar ima kategoričke vrednosti,
- Mahalanobis-Tagući sistem (MTS) – gde zavisni parametar ima kategoričke vrednosti.

Odabir napredne statističke tehnike se vrši u zavisnosti od postavke definisanog problema (*faza 2: korak 4 RONP modela*) i definisanog zavisnog parametra (*faza 4: korak 4 RONP modela*).

Pored ovih kriterijuma za odabir napredne statističke tehnike koji se odnose na faze RONP modela, važno je istaći i kriterijum koji se tiče izbalansiranosti skupa podataka. Izbalansiran skup podataka pruža informacije o različitim situacijama tokom proizvodnih procesa unutar proizvodnog sistema. Prema ovom kriterijumu, MLR i LR, kao tehnike napredne statističke metode, se koriste za razvoj matematičkog RONP modela u slučaju kada skup prikupljenih procesnih podataka sadrži informacije i kada je proizvodni sistem radio bez ikakvih problema i poteškoća, kao i kada su se javile određenje neusaglašenosti. Odnosno, za razvoj matematičkog modela primenom MLR ili LR tehnike neophodno je imati izbalansiran skup podataka koji opisuju različita stanja proizvodnog sistema tokom proizvodnih procesa. Međutim, ukoliko uzmemo u obzir MTS, kao naprednu statističku metodu, razvoj matematičkog modela se zasniva isključivo na podacima koji pružaju informacije samo o situacijama kada je proizvodni sistem radio bez ikakvih problema i poteškoća. Drugim rečima, za razvoj matematičkog modela primenom MTS tehnike neophodno je imati neizbalansiran skup podataka generisanih tokom proizvodnog procesa.

Dalje, razvoj matematičkog modela primenom naprednih statističkih tehnika zasniva se na praćenju nezavisnih uticajnih parametara. Praćenje svakog nezavisnog parametra koji utiče na kvalitet i posmatranje pojedinačnih slučajeva nije cilj naprednih statističkih metoda za unapređenje proizvodnih procesa i kvaliteta proizvoda. Napredne statističke metode obuhvataju praćenje celokupnog stanja proizvodnog sistema i kvaliteta proizvoda u celini. Zahvaljujući naprednim statističkim metodama, pored utvrđenih ograničenja (tolerancija) procesnih parametara karakterističnih za praćenje proizvodnih procesa i kvaliteta proizvoda, postoji i dozvoljeni procenat jedinica proizvoda koji mogu prekoračiti ove granice (a da to

nema negativan uticaj na proizvodni proces ili kvalitet finalnog proizvoda) što se upravo postiže primenom razvijenog matematočkog RONP modela za rano otkrivanje neusaglašenosti procesnih parametara. Statističke metode i tehnike poboljšanja proizvodnih procesa i kvaliteta proizvoda primenom razvijenog matematičkog modela uključuju prikupljene podatke, stvarajući dokumentovanu osnovu za dalju analizu i donošenje zaključaka o proizvodnom sistemu.

4.2.5.2.2. Metode mašinskog učenja

U složenom procesu razvoja RONP prikupljaju se brojni podaci, koje je neophodno analizirati i na osnovu empirijskih činjenica doneti zaključke i odluke. U slučajevima kada napredne statističke metode ne daju zadovoljavajuće rezultate, primenjuju se metode mašinskog učenja. Metode mašinskog učenja predstavljaju naprednu analitičku tehniku za otkrivanje i primenu skrivenih informacija za rešavanje praktičnih problema u mnogim empirijskim disciplinama [102], [249]. Mnogi zadaci u procesu razvoja matematičkog modela mogu se formulisati kao problemi učenja, za čije se rešavanje mogu upotrebiti različite metode mašinskog učenja, koje daju dobre rezultate u slučajevima:

- kada nisu poznate egzaktne procedure rešavanja,
- kada postoji veliki broj uticajnih procesnih parametara dokumentovanih u bazama podataka,
- unapređenja proizvodnih sistema koji moraju da funkcionišu tokom proizvodnih procesa koji se neprekidno menjaju.

Razvoj matematičkog RONP modela u proizvodnim sistemima može se postići i primenom metoda mašinskog učenja. Za razvoj matematičkog modela koriste se tehnike nadgledanog mašinskog učenja koje mogu biti sledeće (slika 58):

- metoda potpornih vektora za regresiju (SVR) – gde zavisni parametar ima kontinualne vrednosti,
- metoda potpornih vektora za klasifikaciju korišćenjem izbalansiranog skupa podataka (SVM) – gde zavisni parametar ima kategoričke vrednosti,
- metoda potpornih vektora za klasifikaciju korišćenjem neizbalansiranog skupa podataka (OCSVM) – gde zavisni parametar ima kategoričke vrednosti.

Razlog zašto su izabrane baš ove tehnike mašinskog učenja je taj što su one ekvivalentne izabranim tehnikama naprednih statističkih metoda gde se postižu objektivni rezultati komparativnih analiza.

Odabir tehnike nadgledanog mašinskog učenja se vrši u zavisnosti od postavke definisanog problema (*faza2: korak 4 RONP modela*) i definisanog zavisnog parametra (*faza 4: korak 4 RONP modela*).

Pored ovih kriterijuma za odabir tehnike mašinskog učenja koja se odnosi na fazu razvoja matematičkog modela, važno je istaći da kriterijum izbalansiranosti skupa podataka, takođe igra važnu ulogu. Prema ovom kriterijumu, SVR i SVM, kao tehnike mašinskog učenja, se koriste za razvoj matematičkog modela u slučaju kada skup prikupljenih procesnih podataka sadrži informacije i kada je proizvodni sistem radio bez ikakvih problema i poteškoća, kao i kada su se javile određenje neusaglašenosti procesnih parametara. Odnosno, za razvoj matematičkog modela primenom SVR ili SVM tehnike neophodno je imati izbalansiran veliki skup podataka koji opisuju različita stanja proizvodnog sistema tokom proizvodnih procesa. Međutim, ukoliko uzmemo u obzir OCSVM, kao tehniku mašinskog učenja, razvoj matematičkog modela se zasniva isključivo na podacima koji pružaju informacije samo o situacijama kada je proizvodni sistem radio bez ikakvih problema i poteškoća. Drugim rečima, za razvoj matematičkog modela primenom OCSVM tehnike neophodno je imati neizbalansiran skup podataka generisanih tokom proizvodnih procesa.

4.2.5.3. Razvoj matematičkog modela u proizvodnim sistemima pomoću izabrane grupe podataka za razvoj modela i primenom izabrane metode i tehnike napredne analitike

Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima se vrši pomoću izabrane grupe podataka za razvoj modela, koja sadrži 80% od ukupnog broja podataka izabranih hronološkim redosledom, i primenom izabrane metode i tehnike napredne analitike, koja je opisana u koraku 2 faze 5 RONP modela (slika 58). Postupak razvoja matematičkog modela se ogleda u primeni i prilagođavanju postojećih algoritama napredne analitike i korišćenju softverskih rešenja kako bi se došlo do što veće tačnosti razvijenog matematičkog modela.

4.2.6. Faza 6: Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara

Postupak za ocenu efikasnosti razvijenog matematičkog modela predstavlja faza 6 - *Testiranje matematičkog modela* (slika 34) - na osnovu skupa podataka koji nije korišćen u fazi 5 RONP modela i koji predstavlja do sada neviđen skup podataka, odnosno preostalih 20% od ukupnog broja podataka izabranih hronološkim redosledom (*faza 5: korak 1 RONP modela*). Pomoću novog skupa podataka, testira se razvijeni matematički model, gde se vrši poređenje dobijenih rezultata primenom ekvivalentnih tehnika naprednih statističkih metoda i metoda mašinskog učenja (slika 59). Na osnovu poređenja, mera performansi se može koristiti za numeričko poređenje kako bi se odredilo da li se predviđanja koja je dao razvijeni model podudaraju sa očekivanim rezulatima [175].

Zadatak testiranja modela jeste određivanje u kojoj meri i u kojem stepenu razvijeni matematički model za rano otkrivanje neusaglašenosti procesnih parametara odgovara stvarnim slučajevim (očekivanim rezultatima) koji se događaju tokom proizvodnog procesa.

Stoga, *Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* kao šesta faza RONP modela sastoji od tri koraka:

1. testiranje matematičkog modela pomoću podataka za testiranje definisanih u fazi 5 RONP modela,
2. procena performansi matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara primenom tehnika testiranja, i
3. analiza dobijenih rezultata matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara.

Kao izlaznu informaciju nakon završene faze 6 - *Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* - dobija se testiran model koji je, ukoliko su dobijeni rezultati zadovoljavajući, spreman za validaciju u proizvodnom sistemu u trenutku generisanja podataka tokom proizvodnog proseca (slika 34).

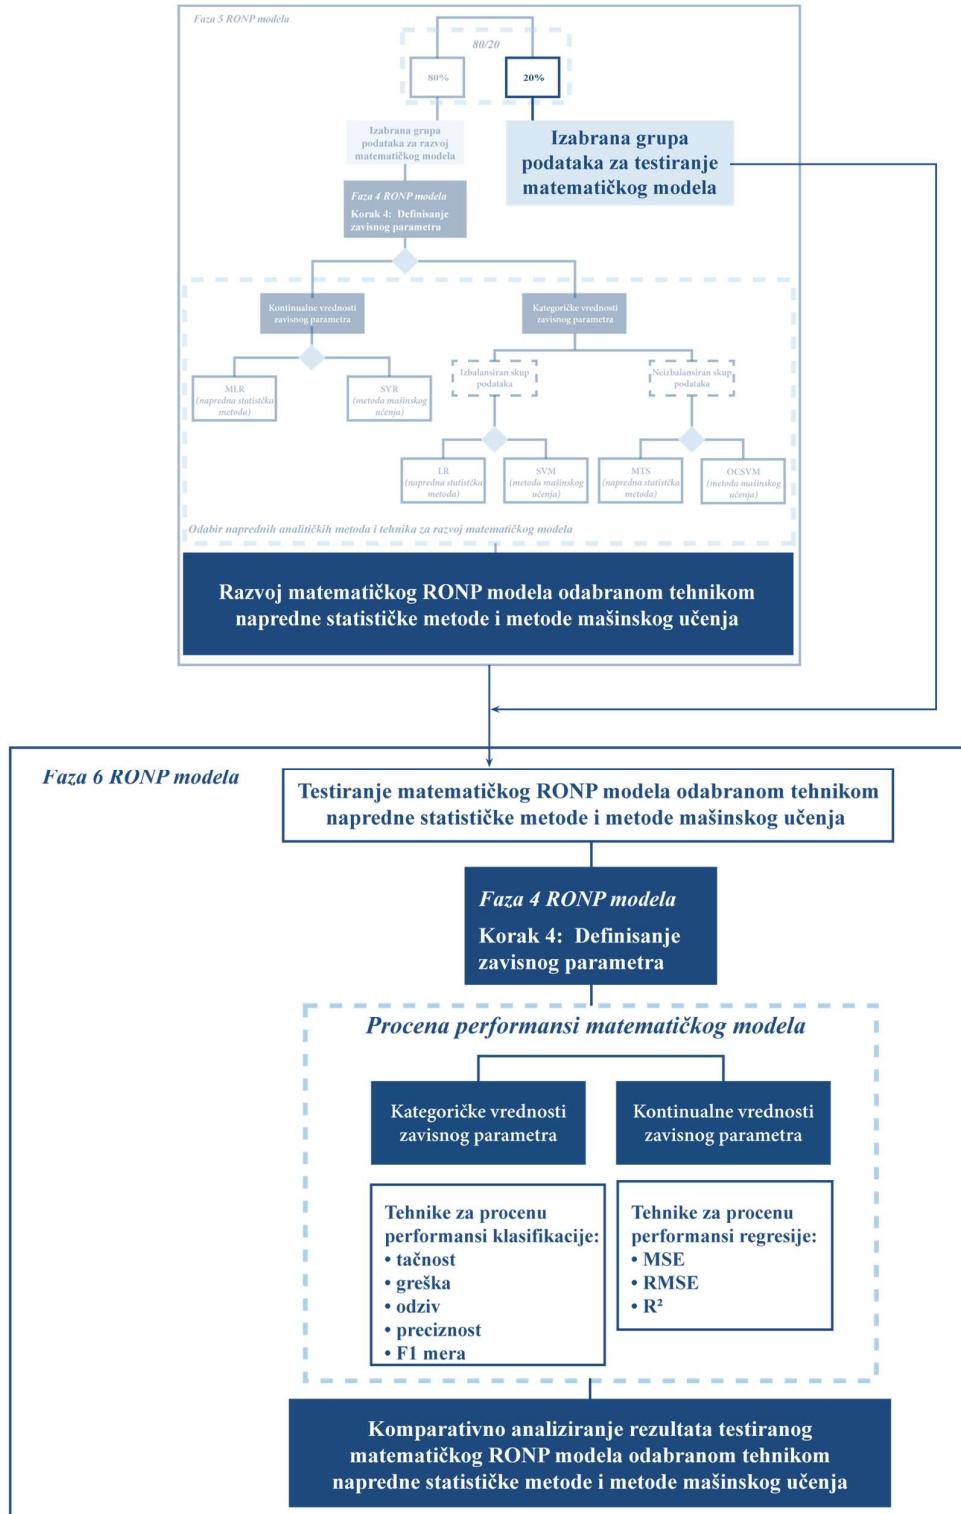
4.2.6.1. *Testiranje matematičkog modela pomoću podataka za testiranje*

Testiranje matematičkog modela se vrši prema istom principu kao i razvijanje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima. Odnosno, testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima se vrši pomoću ekvivalentnih tehnika napredne statističke metode i metode mašinskog učenja.

Podaci koji se koriste u fazi testiranja matematičkog modela predstavljaju grupu podataka izabranu hronološkim redosledom za razvoj modela, koja sadrži preostalih 20% od ukupnog broja podataka, i primenom izabrane metode napredne analitike, koja je opisana u fazi 5 - korak 2 RONP modela (slika 59).

4.2.6.2. 2. *Procena performansi matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara primenom tehnika testiranja*

U zavisnosti od načina posmatranja performansi modela, kao i definisanog problema, postoji više različitih mera za njegovo testiranje [184]. Stoga, u daljem tekstu biće razmatrane tehnike za procenu performansi razvijenog matematičkog modela na osnovu definisanog problema u proizvodnim sistemima (*faza 2 RONP modela*), koji je podeljen na klasifikacione ili regresione probleme (slika 59).



Slika 59. Postupak testiranja matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara

4.2.6.2.1. Tehnike za procenu performansi matematičkog modela na osnovu definisanog klasifikacionog problema

Prilikom testiranja modela zasnovanih na klasifikacionim problemima, osnovni pojmovi koji se koriste jesu pojmovi *greške* i *tačnosti* razvijenog modela. Novaković [184] objašnjava da ukoliko primena razvijenog matematičkog modela na principima klasifikacije, prilikom njegovog testiranja, dovodi do rezultata predviđanja klase koja je različita od stvarne klase primera, tada je nastala greška prilikom klasifikacionog procesa, čime se smanjuje tačnost predviđanja razvijenog modela, a povećava nivo greške [163]. Na taj način *greška*, odnosno *tačnost* predstavlja dobar indikator rada klasifikacionog modela, koja se računa prema sledećoj formuli:

$$\text{tačnost} = \frac{TN+TP}{TN+FN+FP+T} = \frac{TN+TP}{N} \quad (14)$$

$$\text{greška} = 1 - \text{tačnost} \quad (15)$$

gde je:

TN („*true negative*“) – vrednost pozitivno klasifikovanih podataka koji izazivaju određeni tip greške u proizvodnom sistemu,

FN („*false negative*“) – vrednost negativno klasifikovanih podataka koji izazivaju određeni tip greške u proizvodnom sistemu,

TP („*true positive*“) – vrednost pozitivno klasifikovanih podataka koji ne izazivaju ni jedan tip greške u proizvodnom sistemu,

FP („*false positive*“) – vrednost negativno klasifikovanih podataka koji ne izazivaju ni jedan tip greške u proizvodnom sistemu.

N – vrednost ukupnog broja uzoraka (suma TN, FN, TP i FP) nad kojim je razvijen matematički model.

Na ovom pristupu se zasniva određivanje tačnosti matematičkog modela kao mere za testiranje njegovog kvaliteta zasnovanog na klasifikaciji, koja se definiše kao odnos broja ispravno klasifikovanih primera u odnosu na ukupan broj klasifikovanih primera primenom matrice konfuzije [184]. Matrica konfuzije je prikazana na slici 60.

MATRICA KONFUZIJE		STVARNE VREDNOSTI	
PREDVIĐENE VREDNOSTI		<i>Negativni podaci</i>	<i>Pozitivni podaci</i>
	<i>Negativni podaci</i>	TN	FN
	<i>Pozitivni podaci</i>	FP	TP

Slika 60. Matrica konfuzije

Takođe, pored određivanja tačnosti razvijenog matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemima, na osnovu matrice konfuzije se vrši i određivanje *odziva* i *preciznosti* modela, koji se računaju prema sledećim formulama:

$$odziv = \frac{TP}{FN+} \quad (16)$$

$$preciznost = \frac{TP}{TP+FP} \quad (17)$$

gde u ovom slučaju kod predviđanja negativnih slučajeva, *odziv* predstavlja udeo negativnih slučajeva koji su klasifikovani ispravno, dok *preciznost* predstavlja udeo pozitivno predviđenih slučajeva koji jesu tačni.

Međutim, prilikom praktične primene matematičkih modela u proizvodnim sistemima, nužno je praviti kompromis između *odziva* i *preciznosti*: ako je cilj povećanje vrednosti *odziva*, smanjuje se vrednost *preciznosti*, i obrnuto. U takvim slučajevima je neophodno uvođenje harmonijske sredine *preciznosti* i *odziva*, poznatija kao *F mera* [189].

F mera kombinuje *preciznost* i *odziv* omogućavajući jednostavnije poređenje dva ili više algoritama, prema sledećoj formuli:

$$F = (1 + \beta^2) \frac{preciznost \times odziv}{\beta^2 \times preciznost + odziv} \quad (18)$$

gde β uzima vrednosti u opsegu $0 < \beta < 1$ ukoliko je cilj davanje prioriteta *preciznosti*, dok $\beta > 1$ daje prioritet *odzivu*. Kada je $\beta = 1$, dobija se uravnotežena *F mera* (poznatija kao *F1*).

F1 mera, koja daje **jednak značaj i preciznosti i odzivu**, se znatno češće koristi prilikom praktičke primene razvijenog modela u industrijskom uslovima, prema formuli:

$$F1 = 2 \frac{preciznost \times odziv}{preciznost + odziv} \quad (19)$$

4.2.6.2.2. Tehnike za procenu performansi matematičkog modela na osnovu definisanog regresionog problema

Testitanje razvijenog matematičkog modela za rano otkrivanje neusaglašenosti procesnih parmetara u proizvodnom sistemima definiše se merom kvaliteta prilagođene linearne krive koja određuje koliko se predviđene vrednosti slažu sa stvarnim podacima. Prilikom testiranja matematičkih modela zasnovanih na regresiji, osnovni pojmovi koji se koriste jesu pojma *srednja kvadratna greška* i *koren srednje kvadratke greške*, ali se koristi i *koeficijent determinacije*, poznatiji kao R^2 [189].

Srednja kvadratna greška („Mean Square Error” - MSE)

Srednja kvadratka greška (MSE) poznata kao i srednja greška varijanse, označava procenu i meru proseka kvadrata grešaka, što predstavlja prosečnu razliku u kvadratima između procenjene vrednosti i stvarne vrednosti zavisnog parametra. MSE kao mera funkcije predviđanja odgovara očekivanoj vrednosti kvadrata gubitka greške, i određuje se preko sledeće funkcije [163]:

$$MSE = \frac{\sum_i (y_i - \hat{y}_i)^2}{n-p-1} \quad (20)$$

gde je:

- y – stvarna vrednost zavisnog parametra,
- \hat{y} – predviđena vrednost zavisnog parametra,
- n – broj uzoraka,
- p – broj nezavisnih varijabli.

Što je vrednost MSE manja, to ukazuje na bolju sposobnost predviđanja razvijenog matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemima [175].

Koren srednje kvadratne greške („Root Mean Square Error” - RMSE)

Koren srednje kvadratne greške (RMSE) predstavlja koren MSE [163], [175]. Na osnovu vrednosti RMSE vrši se utvrđivanje odnosa između stvarnih i predviđenih vrednosti zavisnog parametra na osnovu sledeće formule [163]:

$$RMSE = \sqrt{\frac{\sum_i (y_i - \hat{y}_i)^2}{n-p-1}} \quad (21)$$

gde je:

- y – stvarna vrednost zavisnog parametra,
- \hat{y} – predviđena vrednost zavisnog parametra,
- n – broj uzoraka,
- p – broj nezavisnih varijabli.

Što je vrednost RMSE manja, to ukazuje na bolju sposobnost predviđanja razvijenog matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemima [118], [175]. Takođe, Ratner [118] smatra da je u većini slučajeva bolje osloniti se na RMSE vrednost nego na MSE, jer se RMSE meri u istim jedinicama kao i podaci, umesto u kvadratnim jedinicama, i predstavlja veličinu "tipične" greške, gde je RMSE validan pokazatelj relativnog kvaliteta modela samo ukoliko razvijeni model ne pokazuje karakteristike prevelikog ili premalog prilagođavanja matematičkog modela.

Koeficijent determinacije (R^2)

Koeficijent determinacije (R^2) je prvi indikator koji pokazuje da li je razvijeni matematički model valjan ili ne. Odnosno R^2 je pokazatelj sposobnosti predviđanja razvijenog matematičkog modela izražen preko relativne mere prilagodavanja modela. Drugim rečima R^2 odgovara proporciji koja se izračunava linearnim odnosom između predviđenih i stvarnih vrednosti [120] prema sledećoj formuli:

$$R^2 = 1 - \frac{SSE}{SST} \quad (22)$$

gde je:

SSE – zbir kvadrata grešaka,

SST – ukupna suma kvadrata.

Vrednosti R^2 se kreću od 0 do 1 (odnosno od 0% do 100%), gde vrednosti bliže 0 označavaju slabu sposobnost predviđanja razvijenog matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemima ($R^2 = 0\%$ označava da varijansa zavisne promenljive nije objašnjena nezavisnim promenljivim). Suprotno tome, vrednosti bliže 1 označavaju maksimalnu sposobnost predviđanja ($R^2 = 100\%$ označava da je varijansa zavisne promenljive u potpunosti objašnjena nezavisnim promenljivim) što oslikava savršeni linearni odnos [120].

Međutim, Christensen [162] napominje da R^2 meri prediktivne sposobnosti, a ne ispravnost modela, gde neispravni modeli mogu biti veoma dobri prediktori i imati vrlo visoke R^2 , dok ispravni modeli mogu biti loši prediktori i imati veoma niske R^2 . Modeli razvijeni na osnovu većeg broja nezavisnih parametara imaju veće vrednosti R^2 iz razloga što takvi modeli mogu bolje obaviti aproksimaciju vrednosti. Isto tako, velike vrednosti R^2 ne moraju nužno značiti da će dobro izvršiti predikcija na osnovu razvijenog modela u apsolutnom smislu. Drugim rečima, iako razvijeni model objašnjava veći deo varijabilnosti, može se ustanoviti da ne objašnjava toliko promenljivosti koliko bi trebao. Takođe, model sa niskim R^2 može biti dobro razvijen. Međutim, podaci mogu jednostavno imati veliku promenljivost usled čega se smanjuje vrednost R^2 .

4.2.6.3. Analiza dobijenih rezultata matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara

Analiza dobijenih rezultata matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu predstavlja komparativnu analizu na osnovu procenjenih performansi (slika 59). Komparacija se vrši poređenjem rezultata dva matematička modela razvijena ekvivalentnim tehnikama naprednih statističkih metoda i metoda mašinskog učenja, gde se određuje koji model ima bolje performanse. Komparativna analiza dobijenih

rezultata matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu obavlja se deskriptivnom metodom. Matematički model sa boljim performansama se koristi u fazi 7 - *Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara*.

4.2.7. Faza 7: Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara

Faza 7 - *Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* (slika 34) - predstavlja **fazu potvrđivanja odabranog matematičkog RONP modela**. Validacija matematičkog RONP modela se vrši na osnovu **automatizovane analize procesnih podataka u trenutku njihovog prikupljanja**. Nadalje, faza *Validacije* se vrši isključivo **primenom metode eksperimenta u industrijskom okruženju** (slika 61) kako bi se:

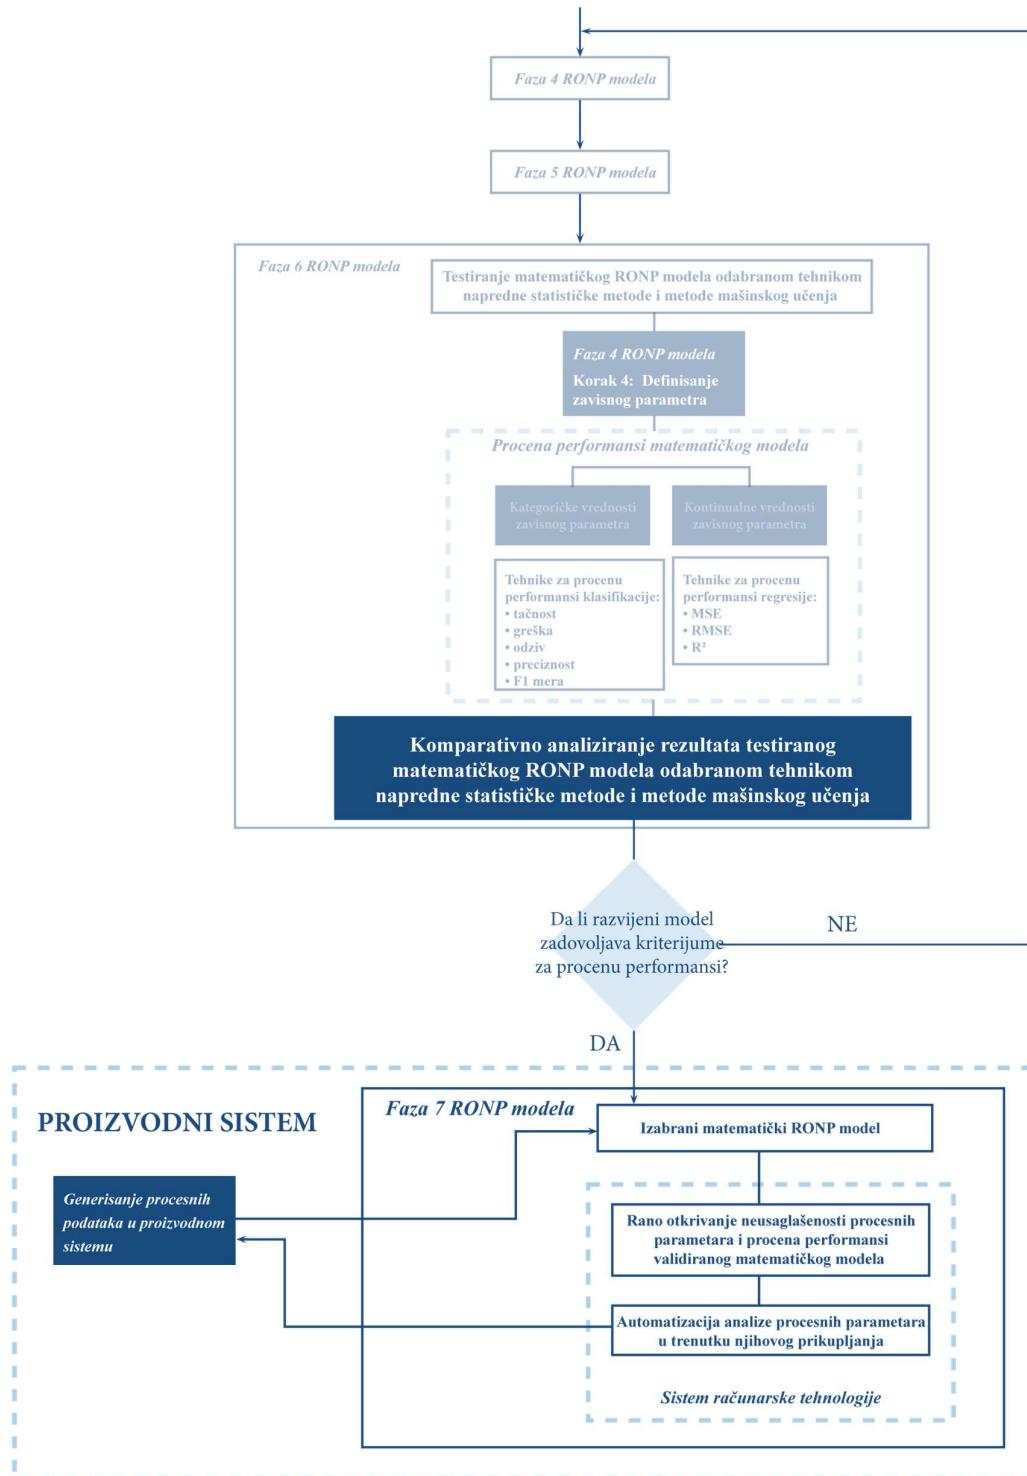
- potvrdila ispravnost i univerzalnost razvijene metodologije RONP modela, i
- testirale performanse razvijenog matematičkog modela u posmatranom proizvodnom sistemu.

Drugim rečima, cilj faze 7 - *Validacija matematičkog RONP modela* jeste praktična primena modela u odabranom proizvodnom sistemu, gde se vrši praćenje performansi matematičkog modela u određenom vremenskom periodu na osnovu novih podataka koji nisu prethodno pripremljeni niti obrađeni, s tim da se analiza procesnih podataka vrši u trenutku njihovog prikupljanja. Na taj način se dokazuju rezultati razvijenog RONP modela u stvarnom okruženju.

Stoga, *Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* kao sedma faza RONP modela sastoji od dva koraka:

1. rano otkrivanje neusaglašenosti procesnih parametara i procena performansi validiranog matematičkog modela primenom metoda napredne analitike, i
2. automatizacija analize procesnih parametara u trenutku njihovog prikupljanja.

Izlazna informacija faze 7 predstavlja validiran matematički model čije su performanse testirane u industrijskom okruženju, dok se kao rezultat završene faze 7 - *Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* - dobija validiran konceptualni RONP model čime je potvrđena njegova univerzalnost i mogućnost primene u različitim oblastima procesne industrije (slika 34).



Slika 61. Postupak validacije matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u industrijskom okruženju

4.2.7.1. *Rano otkrivanje neusaglašenosti procesnih parametara i procena performansi primenom metoda napredne analitike*

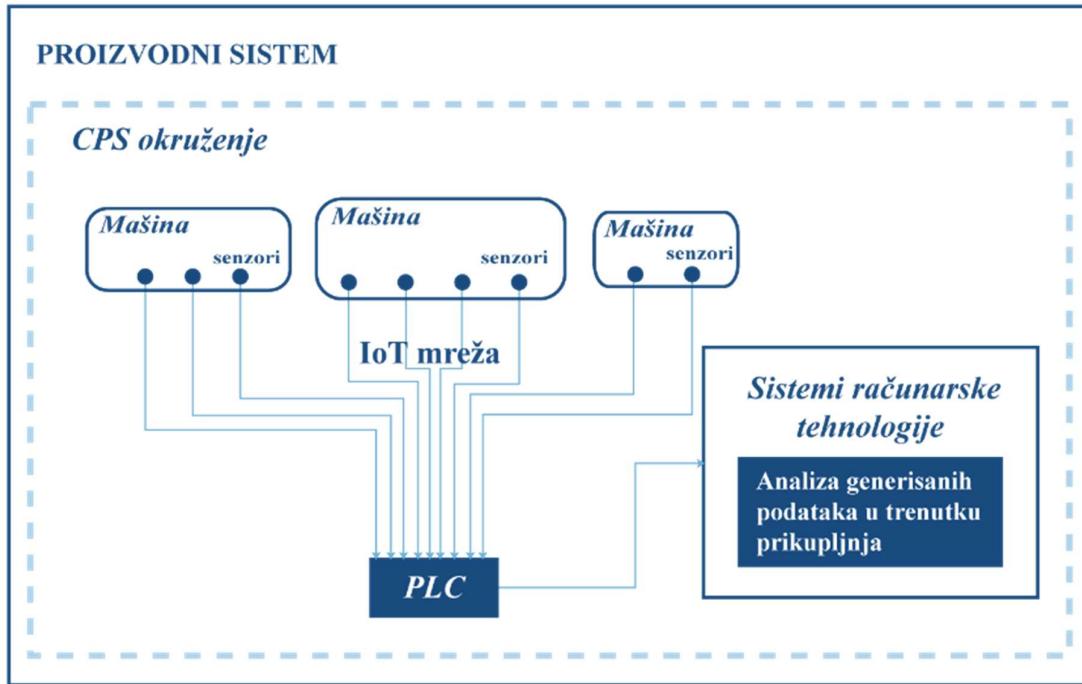
Rano otkrivanje neusaglašenosti procesnih parametara zahteva implementaciju određene opreme. Implementacija odgovarajuće opreme predstavlja primenu hardverskog i/ili softverskog rešenja koji imaju sposobnost izvršavanja analize procesnih podataka u trenutku nihovog prikupljanja u eksperimentalnom okruženju (slika 62). Takva oprema je zasnovana na primeni napredne tehnologije koncepta Industrije 4.0, gde je moguće koristiti sisteme računarske tehnologije kao što su:

- *Cloud*,
- *Fog*, ili
- *Edge*.

Pored opreme, neophodno je imati i odgovarajuću konekciju koja pruža dovoljno brz odziv sistema gde bi se omogućilo prikupljane podatke u određenom vremenskom intervalu. Konekcija može da se izvrši putem Internet ili industrijske Eternet mreže pomoću odgovarajućeg protokola, omogućavajući brz protok informacija, gde se izabrana oprema na adekvatan način povezuje sa mašinama iz proizvodnog sistema. Takva vrsta konekcije u proizvodnom sistemu predstavlja IoT mrežu (slika 62). Međutim, povezivanje samo po sebi nije dovoljno ukoliko nije omogućeno generisanje procesnih podataka. Generisanje procesnih podataka u proizvodnom sistemu se ostvaruje primenom različitih vrsta industrijske opreme, gde se pre svega misli na senzore (za detektovanje podataka) i PLC uređaje (za zapisivanje podataka) putem IoT mreže (slika 62).

Prema tome, takva vrsta konekcije u proizvodnom sistemu predstavlja IoT mrežu gde se umrežavaju mašine, industrijska oprema i računarska tehnologija omogućava kreiranje CPS okruženja (slika 62). Povezivanje je neophodno uraditi u saradnji sa ekspertima iz oblasti kako se ne bi narušila privatnost generisanih procesnih podataka u CPS okruženju.

Nakon kreiranja CPS okruženja, naredni korak predstavlja definisanje vremenskog perioda validacije. Definisanje vremenskog perioda validacije podrazumeva preciziranje vremenskog intervala u kojem će se vršiti validacija matematičkog modela. U tom definisanom periodu je neophodno da se vrši prikupljanje procesnih podataka isključivo za proizvode za koje je utvrđeno da imaju iste ili slične vrednosti uticajnih procesnih parametara, prilikom čega se vrši analiza podataka u trenutku njihovog prikupljanja. Analiza podataka prilikom validacije matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara se sprovodi na generisanom sirovom skupu podataka. To znači da generisani skup podataka nije prethodno pripremljen niti obrađen. Na osnovu rezultata analize procenjuju se performanse matematičkog modela.



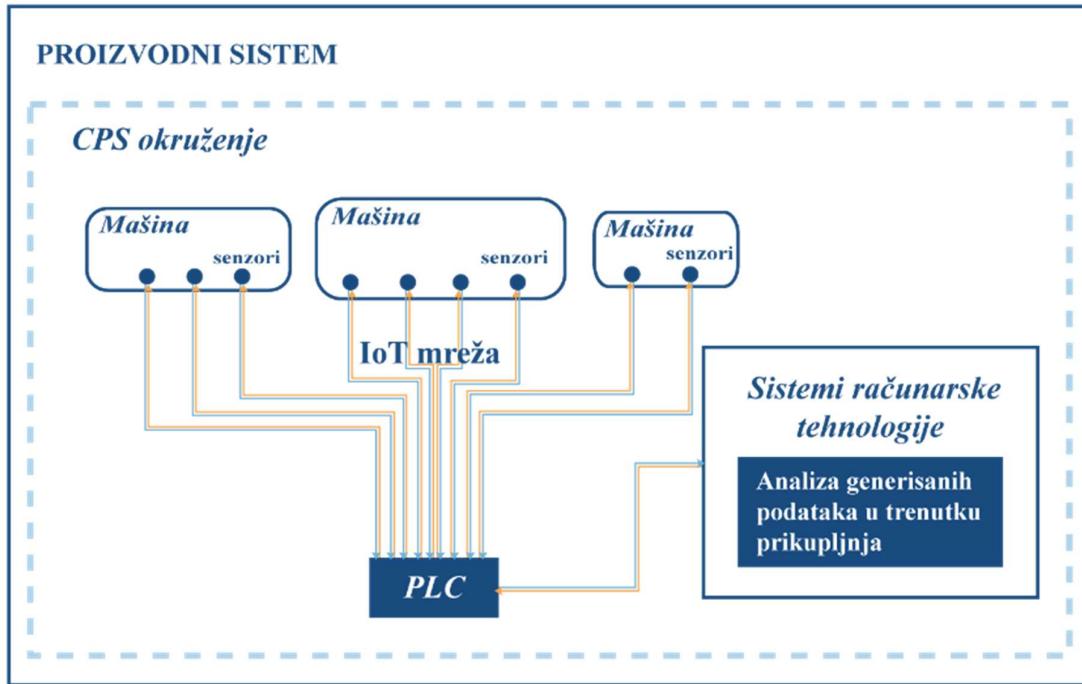
Slika 62. Postupak ranog otkrivanja neusaglašenosti procesnih parametara u proizvodnom sistemu

4.2.7.2. Automatizacija analize procesnih parametara u trenutku njihovog prikupljanja

Automatizacija analize procesnih podataka u trenutku njihovog prikupljanja predstavlja slanje povratne informacije sa odabranog sistema računarske tehnologije preko PLC uređaja direktno na mašinu (slika 63). Povratna informacija, odnosno željeni signal se šalje nakon ranog detektovanja neusaglašenosti procesnih parametara koristeći razvijeni matematički model.

Kako bi se poslala povratna informacija nazad na PLC, neophodno je definisati novi poziciju (parametar) na samom uređaju definisan kao binarni tip podatka. Parametar se aktivira na osnovu analize matematičkog modela u trenutku generisanja podataka. Takođe, neophodno je izvršiti kodiranje u samom PLC uređaju gde će novi parametar predstavljati okidač za automatizovanu promenu svih ili samo određenog parametra.

Slanje povratne informacije nazad na mašine u proizvodnom sistemu se omogućava primenom napredne tehnologije koncepta Industrije 4.0.



Slika 63. Postupak slanja povratne informacije (označene narandžastom bojom) u proizvodnom sistemu

5. VERIFIKACIJA MODELA ZA RANO OTKRIVANJE NEUSAGLAŠENOSTI PROCESNIH PARAMETARA U PROIZVODNOM SISTEMU

Verifikacija modela za rano otkrivanje neusaglašenosti procesnih parametara predstavlja primenu i finalno potvrđivanje razvijenog modela za rano otkrivanje neusaglašenosti procesnih parametara u trenutku prikupljanja podataka u industrijskom okruženju. Primena modela u industrijskom okruženju se definisiše odabirom proizvodnog sistema procesne industrije. Verifikacija služi kao eksperimentalna metoda dokazivanja konceptualnog RONP modela (slika 34) na osnovu praktične primene modela u odabranom proizvodnom sistemu koje predstavlja lokaciju za eksperimentalni rad.

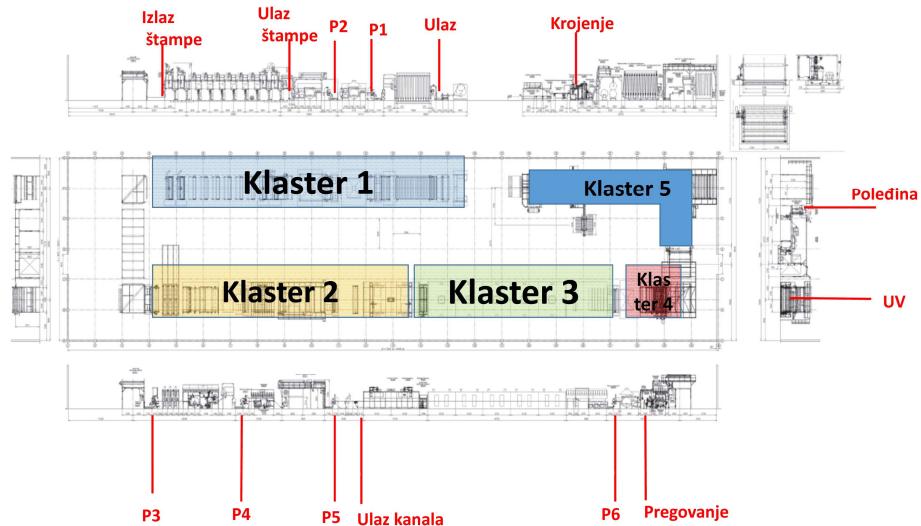
5.1. Lokacija za eksperimentalni rad

Lokacija za eksperimentalni rad predstavlja proizvodni sistem procesne industrije. Delatnost odabranog proizvodnog sistema jeste proizvodnja podnih obloga od vinila. Proizvod se proizvodi i isporučuje u obliku rolne, što uslovljava postojanje kontinualne proizvodnje u vidu proizvodne linije.

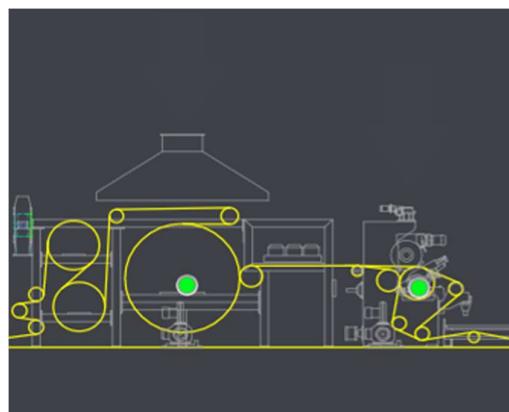
Posmatranu proizvodnu liniju čini 12 mašina. Broj mašina povećava složenost proizvodnog procesa, a samim tim se povećava i složenost njegovog unapređena primenom metoda napredne analitike. Stoga je proizvodna linija podeljena na klastere. Klasteri su delovi proizvodne linije koji obuhvataju jednu ili više mašina, gde je ekspertnom analizom zaključeno da neusaglašenost procesnih parametara na jednoj mašini potencijalno može da dovede i do nastanka proizvoda lošeg ili nedovoljno dobrog kvaliteta na drugoj mašini. Pored toga, postavljen je uslov da mašine moraju da se grupišu logičkim redosledom izvođenja tehnoloških operacija (slika 64). Proizvodna linija posmatranog proizvodnog sistema je podeljena na pet klastera, i to:

- **Klaster 1** obuhvata ulaz sirovine i tri mašine:
 - premazivanje 1 (P1) (slika 65),
 - premazivanje 2 (P2) (slika 66), i
 - štampu - gde se zasebno posmatraju ulaz i izlaz štamparske mašine (slika 67);
- **Klastre 2** obuhvata mašine:
 - premazivanje 3 (P3) (slika 68),
 - premazivanje 4 (P4) (slika 69), i
 - premazivanje 5 (P5) (slika 70);
- **Klaster 3** obuhvata mašine:

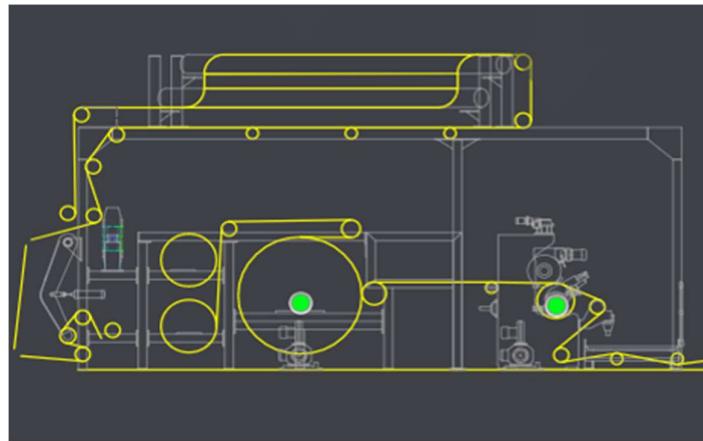
- kanal (slika 71), i
- premazivanje 6 (P6) (slika 72);
- **Klaster 4** obuhvata mašinu:
 - pregovanje (slika 73);
- **Klaster 5** obuhvata maštine:
 - UV mašina (slika 74),
 - poledinska štampa (slika 75), i
 - krojenje - koje podrazumeva operacije klasifikacije finalnog proizvoda, namotavanje rolne finalnog proizvoda i proces pakovanja (slika 76).



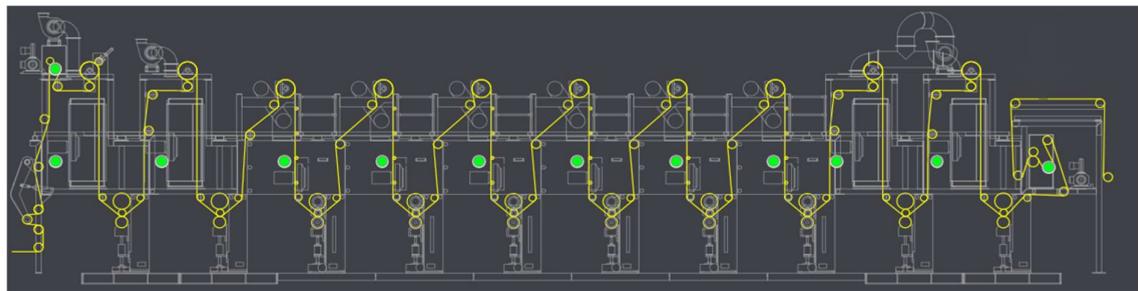
Slika 64. Proizvodna linija posmatranog proizvodnog sistema grupisana u klastere (SCADA)



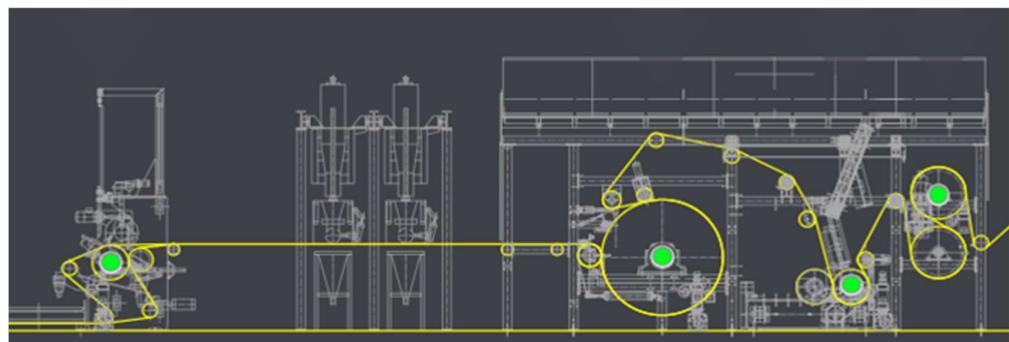
Slika 65. Dvodimenzionalni prikaz maštine P1 (SCADA)



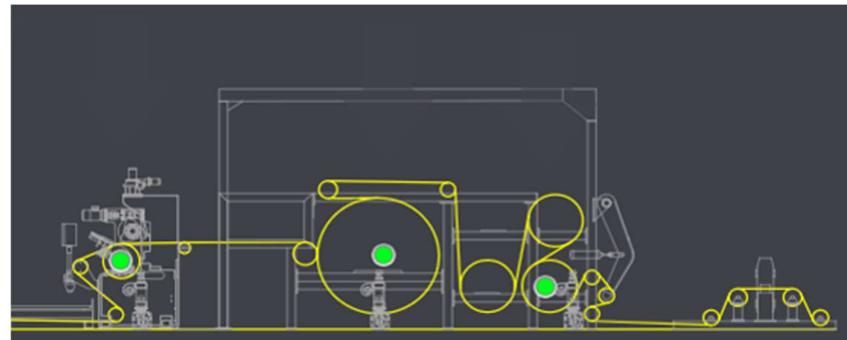
Slika 66. Dvodimenzionalni prikaz mašine P2 (SCADA)



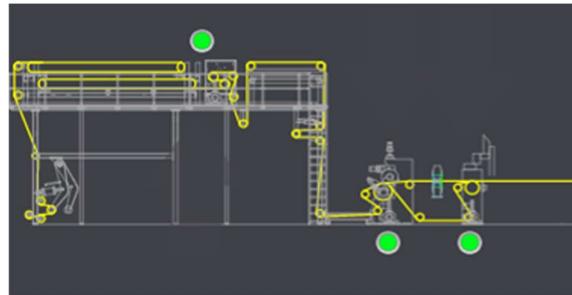
Slika 67. Dvodimenzionalni prikaz mašine za štampu (SCADA)



Slika 68. Dvodimenzionalni prikaz mašine P3 (SCADA)



Slika 69. Dvodimenzionalni prikaz mašine P4 (SCADA)



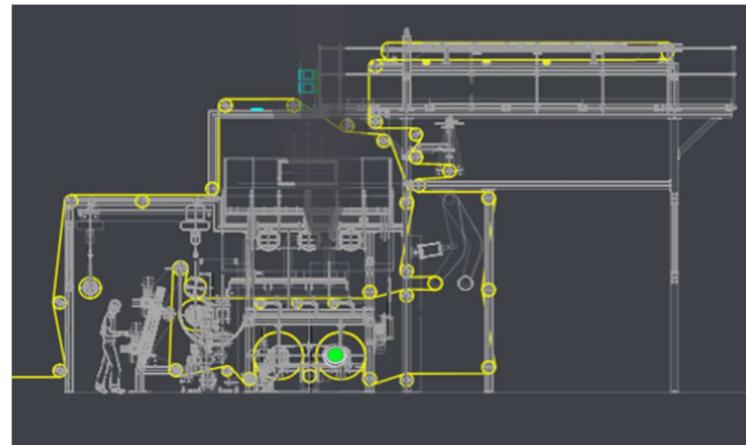
Slika 70. Dvodimenzionalni prikaz mašine P5 (SCADA)



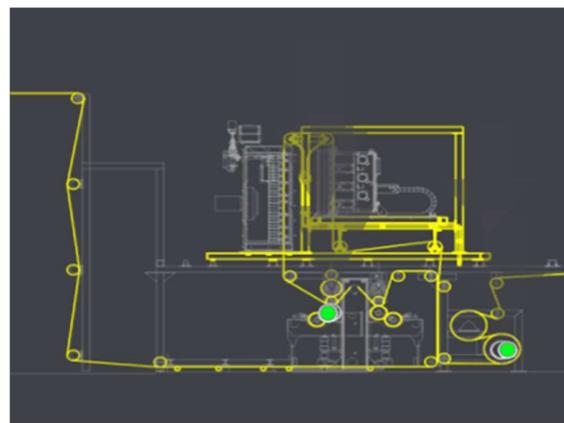
Slika 71. Dvodimenzionalni prikaz mašine kanala (SCADA)



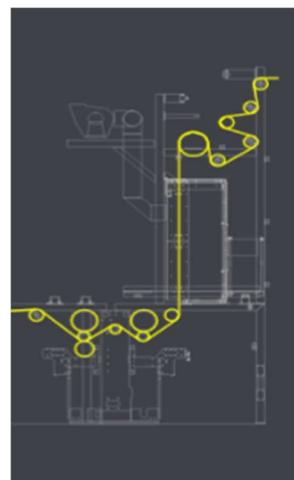
Slika 72. Dvodimenzionalni prikaz mašine P6 (SCADA)



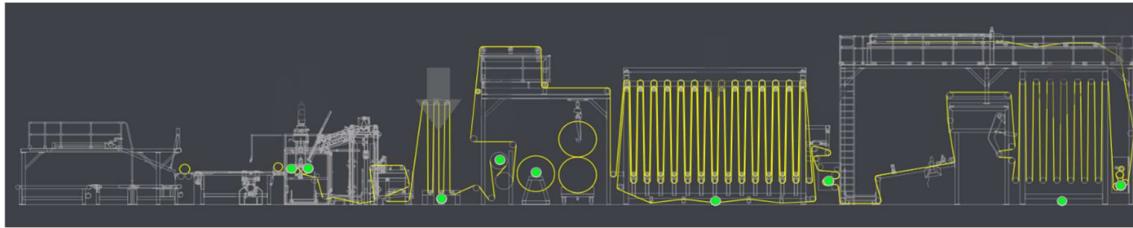
Slika 73. Dvodimenzionalni prikaz mašine za pregovanje (SCADA)



Slika 74. Dvodimenzionalni prikaz UV mašine (SCADA)



Slika 75. Dvodimenzionalni prikaz mašine za poleđinsku štampu (SCADA)



Slika 76. Dvodimenzionalni prikaz mašine za krojenje finalnog proizvoda (SCADA)

Ukupna dužina proizvodne linije posmatranog proizvodnog sistema iznosi 850 metara. U tabeli 7 su prikazana rastojanja mašina u odnosu na ulaz linije.

Tabela 7. Rastojanja mašina, grupisanih u klastere, u odnosu na ulaz linije proizvodnog sistema

Klaster	Mašina	Rastojanja mašina u odnosu na ulaz linije [m]
1	P1	150
1	P2	175
1	Štampa	Ulaz Izlaz
2	P3	405
2	P4	455
2	P5	535
3	Kanal	540
3	P6	610
4	Pregovanje	660
5	UV mašina	685
5	Poleđinska štampa	715
5	Krojenje	850

5.2. Oprema korišćena za eksperimentalni rad

5.2.1. Industrijski računar

Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima zasniva se na primeni metoda napredne analitike. Korišćenje metoda napredne analitike u određenim slučajevima zahteva upotrebu industrijskih računara sa značajno većim računarskim kapacitetima u odnosu na klasične personalne računare. Danas, industrijski računari se baziraju na primeni naprednih računarskih tehnologija radi obrade podataka generisanih i prikupljenih tokom proizvodnih procesa. Stoga, oprema koja je korišćena za eksperimentalni rad u cilju razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu primenom naprednih statističkih metoda, a kasnije i njegove verifikacije, jeste računarska tehnologija zasnovana na *Edge* sistemu prikupljanja i analize podataka. *Edge* sistem računarske tehnologije koji je primenjen jeste MELIPC MI5000 (slika 77), rešenje koje je razvila kompanija *Mitsubishi Electric*.

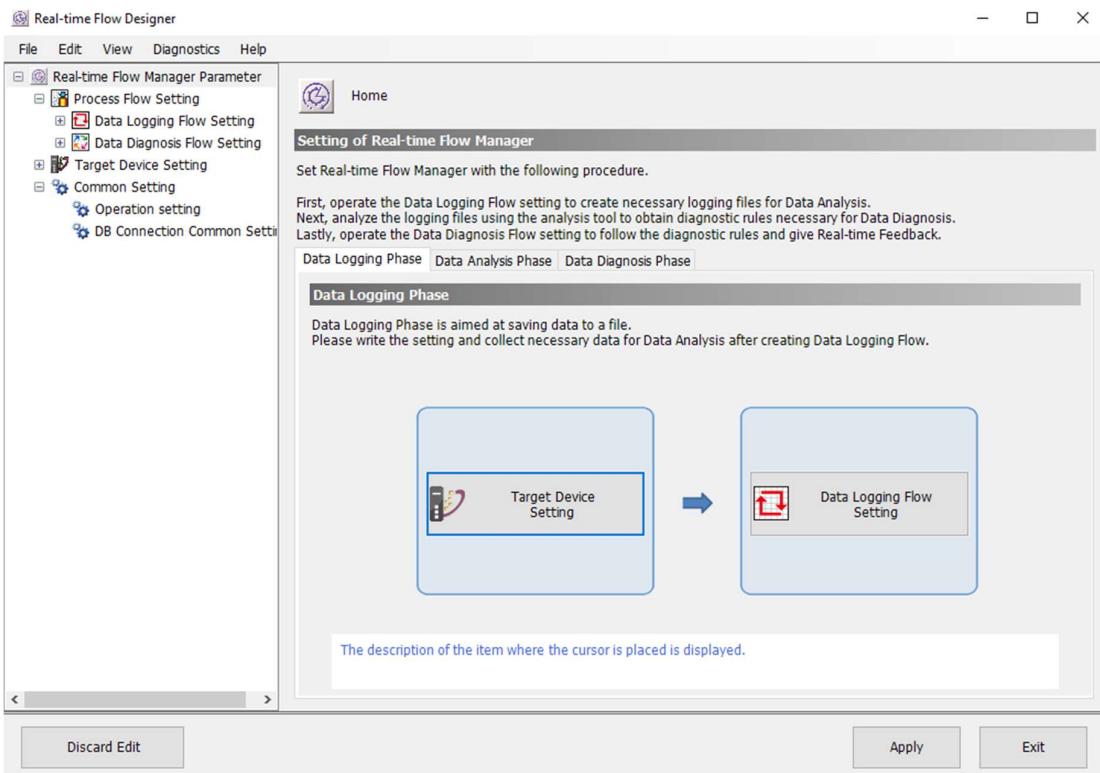


Slika 77. Industrijski računar MELIPC MI5000 zasnovan na Edge sistemu računarske tehnologije

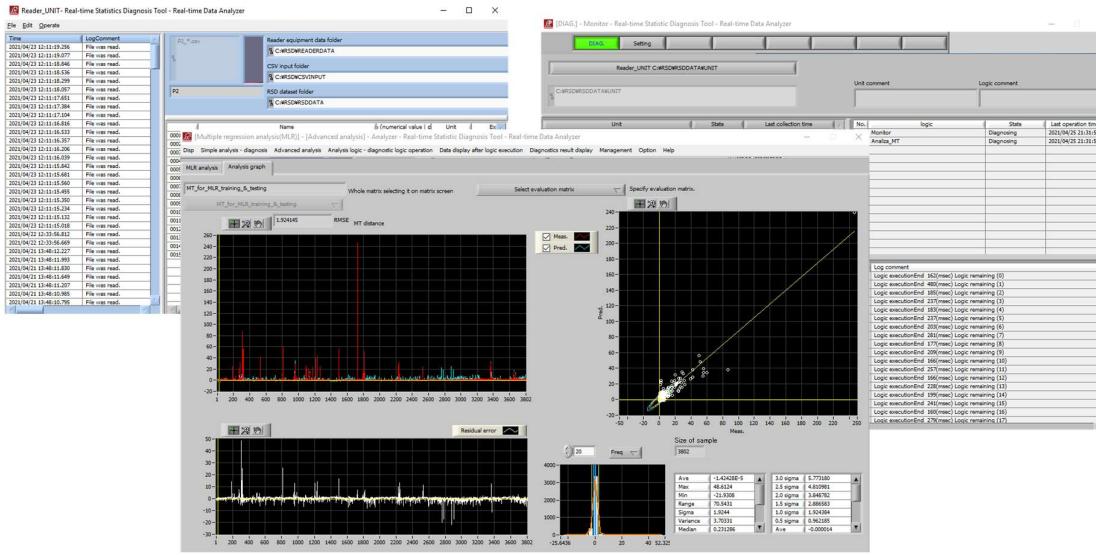
MELIPC MI5000 realizuje kontrolu uređaja „*u realnom vremenu*“, dok *Edge* sistem računarske tehnologije omogućava prikupljanje i analizu podataka na mestu njihovog generisanja. MELIPC MI5000 odgovara zahtevima kao što su kontrola prikupljanja podataka, preventivno održavanje i poboljšanje kvaliteta proizvoda, što doprinosi povećanju produktivnosti korišćenjem proizvodnih podataka. **Cilj upotrebe MELIPC MI5000, kao Edge sistema računarske tehnologije, jeste razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara na osnovu malog precizno kreiranog skupa podataka primenom naprednih statističkih metoda.**

MELIPC MI5000 može istovremeno da pokreće dva operativna sistema *VxWorks*[®] i *Windows*[®]. *VxWorks*[®] se koristi za kontrolu uređaja i prikupljanje podataka, dok *Windows*[®] prikazuje rezultate analize prikupljenih podataka, omogućavajući njihovu obradu. Unapred

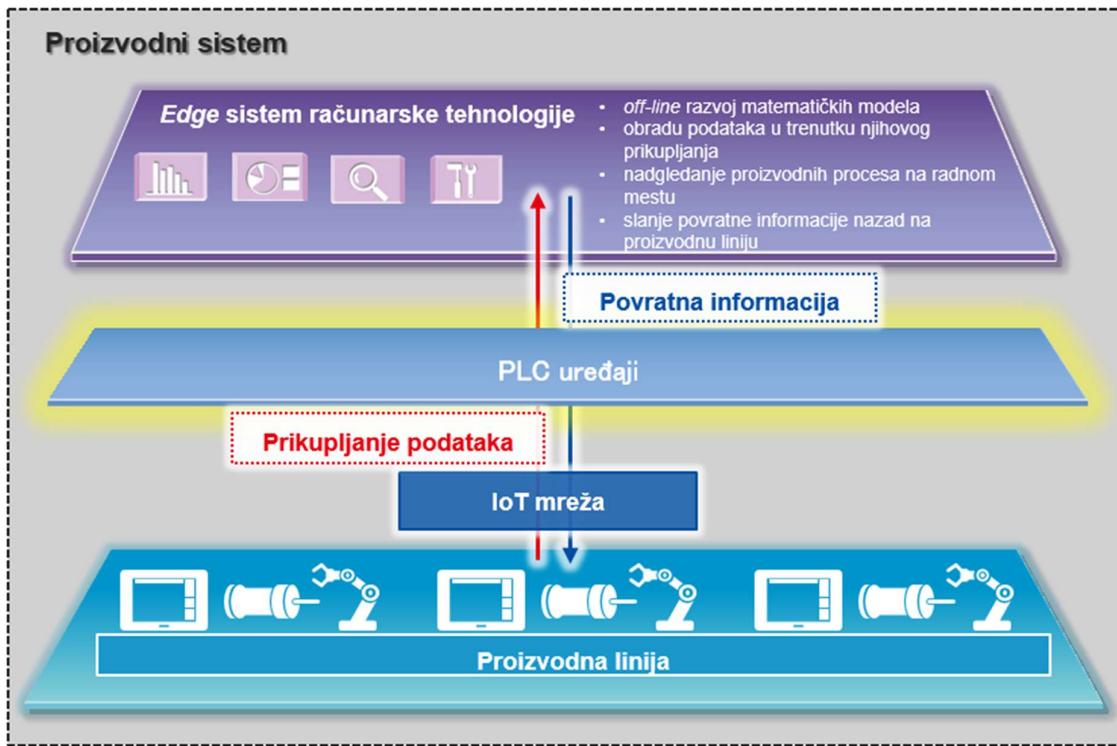
instalirani softver, *Real-time Flow Designer* (slika 78) omogućava lakše prikupljanje procesnih podataka iz proizvodnog sistema nezavisnih kompanija, dok softver *Real-time Statistics Diagnosis Tool* (slika 79) omogućava *off-line* razvoj matematičkih modela, obradu podataka u trenutku njihovog prikupljanja i nadgledanje proizvodnih procesa na radnom mestu. Sve je to omogućeno pomoću funkcija koje se pružaju na nivou *Edge* sistema računarske tehnologije. Konačno, najvažnija karakteristika ovog *Edge* sistema računarske tehnologije je njegova sposobnost da podrži samokonfiguraciju mašine pružanjem odgovarajućih povratnih informacija u proizvodni sistem. Način rada industrijskog računara MELIPC MI5000 je prikazan na slici 80, dok su njegove specifikacije predstavljenje u tabeli 8.



Slika 78. Softver *Real-rime Flow Designer*, MELIPC 5000, *Edge* sistem računarske tehnologije



Slika 79. Softver Real-rime Statistics Diagnosis Tool, MELIPC 5000, Edge sistem računarske tehnologije



Slika 80. Postupak rada industrijskog računara MELIPC MI5000

Tabela 8. Specifikacije industrijskog računara MELIPC MI5000

MELIPC MI5000	<i>Specifikacije operativnog sistema</i>	
	<i>VxWorks®</i>	<i>Windows®</i>
Hardver		
Mikroprocesor	Intel® Core™ i7-5700EQ 2.6G Hz (Quad Core)	
Glavna memorija (bajt)	1G	12G
Kapacitet internog skladištenja (bajt)	4G	45G
Prošireni interfejs za skladištenje	-	CFastcard x 1
Softver		
Operativni sistem (OS)	VxWorks® 7.0	Windows® 10 IoT Enterprise 2016 LTSB
Programski jezik	C/C++	Svi jezici koje podržava OS
Format namenskih API-ja	C/C++ forat	Standardni DLL
Interfejs ekrana		
Interfejs	-	DisplayPort x 1
Rezolucija	-	Max 3840x2160
RS-232		
Broj kanala	1	
Brzina prenosa (bps)	9600...115200	
USB		
USB3.0	2	
USB2.0	2	
I/O terminal		
Unos zahteva za isključivanje OS-a	•	
Isključivanje OS je završilo izlaz obaveštenja	•	
Napajanje (AC ulaz)		
Procenjeni ulazni napon	100...240 V AC	
Promenljivi opseg ulaznog napona (V AC)	85...264	
Ulagna frekvencija (Hz)	47...63	
Maksimalna ulazna prividna snaga (VA)	≤ 139	
Doktorska disertacija		

Ostalo

Spoljne dimenzije (V k Š k D, mm)	106 x 362 x 119
Težina (g)	2.674

5.2.2. Personalni računar

Personalni računar je korišćen isključivo u fazi 5 - *Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoći izabrane grupe podataka* - primenom metode mašinskog učenja radi sprovođenja komparativne analize performansi dva razvijena modela. Računar koji je korišćen u tu svrhu jeste *DELL Inspiron 15 5000* sa procesorom *Intel Core i7* 8. generacije (slika 81). Operativni sistem instaliran na personalnom računaru je *Windows®*. Specifikacije personalnog računara date su u tabeli 9.

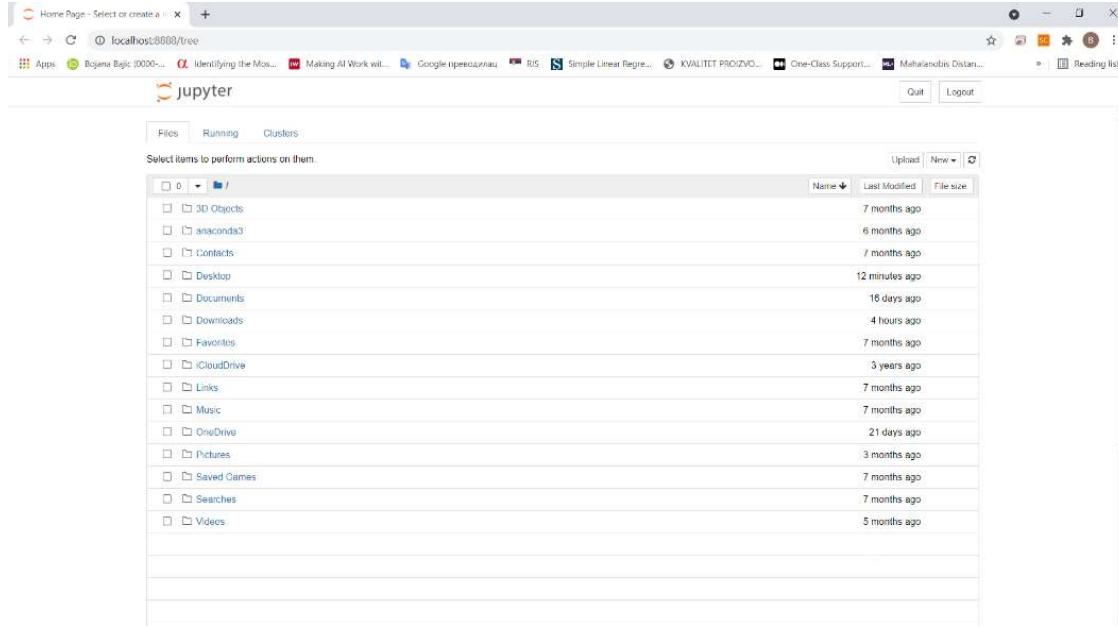


Slika 81. Personalni računar DELL Inspiron 15 5000

Softversko rešenje koje je korišćeno za razvoj matematičkog modela jeste *Jupyter Notebook* (slika 82) veb aplikacija otvorenog koda koja omogućava kreiranje i deljenje dokumenata koji sadrže kod, jednačine, vizualizacije i narativni tekst. Pogodnosti ovog softverskog rešenja uključuju čišćenje i transformaciju podataka, numeričku simulaciju i vizualizaciju podataka, razvoj modela korišćenjem naprednih statističkih metoda ili mašinskog učenja, itd. korišćenjem programskog jezika *Python*.

Tabela 9. Specifikacije personalnog računara DELL Inspiron 15 5000

DELL Inspiron 15 5000	<i>Specifikacije operativnog sistema: Windows®</i>
Hardver	
Mikroprocesor	Intel® Core™ i7- 8565U 4 x 1.8 - 4.6 GHz
Glavna memorija (bajt)	1TB HDD
Kapacitet internog skladištenja (bajt)	8G DDR4 RAM
Softver	
Operativni sistem (OS)	Windows® 10
Programski jezik	Svi jezici koje podržava OS
Interfejs ekrana	
Interfejs	SATA 6 GB/s
Rezolucija	Max 1920 x 1080
USB	
USB3.1 Gen 1 sa PowerShare tehnologijom	1
USB3.1 Gen 1	1
USB2.0	1
Audio/Video	
HDMI 1.4b	1
Slušalice sa mikrofonom	1
Napajanje (AC ulaz)	
Procenjeni ulazni napon	100...240 V AC
Ulagna frekvencija (Hz)	50...60
Ulagna struja	Max 1,30 A/1,60 A/1,70 A
Izlagna struja (neprekidna)	2,31 A/3,34 A
Ostalo	
Spoljne dimenzije (V k Š k D, mm)	20,2 x 380,9 x 253,1
Težina (g)	2.200
Baterija	“Pametna” litijum-jonska sa 3 čelije (42 WHr)
Čitač memorijskih kartica	SD kartica



Slika 82. Jupyter Notebook veb aplikacija

5.3. Primena faza za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu

5.3.1. Faza 1: Procena trenutnog stanja proizvodnog sistema

Procena trenutnog stanja proizvodnog sistema počinje koracima za određivanje karakteristika i funkcije cilja posmatranog proizvodnog sistema, opisanog u poglavlju 5.1. *Lokacija za eksperimentalni rad.* Nakog toga sledi korak procene stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Svaki od ovih koraka su detaljno predstavljeni u narednim potpoglavlјjima.

5.3.1.1. Karakteristike proizvodnog sistema

Određivanje karakteristika proizvodnog sistema je izvršeno u industrijskom okruženju odabranog proizvodnog sistema, gde je određena njegova delatnost, kao i karakteristike programa proizvodnje.

5.3.1.1.1. Delatnost proizvodnog sistema

Prema Klasifikaciji delatnosti sa nazivima, šiframa i opisima delatnosti Republike Srbije, prema definisanoj studiji slučaja delatnost odabranog proizvodnog sistema pripada *sektoru C – prerađivačke industrije*, za oblast proizvodnje proizvoda od gume i plastike. Delatnost odabranog proizvodnog sistema je predstavljena u tabeli 10.

Tabela 10. Delatnost odabranog proizvodnog sistema procesne industrije

<i>Odabrani proizvodni sistem procesne industrije</i>		
<i>Sektor C</i>	<i>Prerađivačka industrija</i>	
<i>Oblast prerađivačke industrije</i>	<i>Oblast 22</i>	<i>Proizvodnja proizvoda od gume i plastike</i>
<i>Grana</i>	<i>Grupa proizvoda</i>	
Grana 21.23 Proizvodnja predmeta od plastike za građevinarstvo		<ul style="list-style-type: none"> • proizvodnja predmeta od plastike za građevinarstvo: <ul style="list-style-type: none"> – vrata, prozora, ramova, kapaka, žaluzina, lajsni za pod i dr. – tankova i rezervoara – podnih, zidnih ili plafonskih obloga u obliku rolni ili pločica i dr. – sanitarnih predmeta kao što su kade, tuš-kade, umivaonici, klozetiske šolje, vodokotlići i dr. • proizvodnja linoleuma i tvrdih pokrivača za pod bez obzira na to da li su obloženi s donje strane tkaninom ili netkanim tekstilom • proizvodnja veštačkog kamena (npr. imitacija mermara)

5.3.1.1.2. Karakteristike programa proizvodnje

Karakteristike programa proizvodnje određene su primenom strukture i količine programa proizvodnje. Karakteristike programa proizvodnje su određene na osnovu tri analize, i to:

- struktura delova po osnovnim dimenzijama,
- struktura delova po složenosti proizvoda, i
- količinska analiza programa proizvodnje.

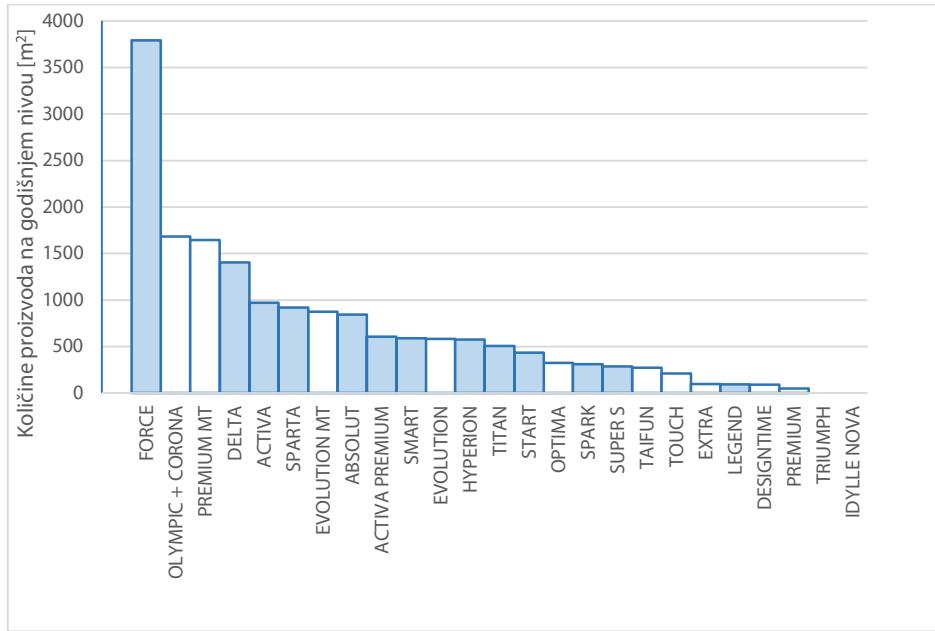
Na osnovu razgovora sa ekspertima iz posmatranog proizvodnog sistema primenom metode intervjeta, zaključeno je da se svi proizvodi mogu podeliti u **dve grupe proizvoda na osnovu sličnih vrednosti procesnih parametara koji se podešavaju tokom proizvodnog procesa** (npr. procesni parametri za debljinu nanosa paste, temperature bubenjeva za zagrevanje površine materijala, viskozitet paste, itd.). **Plavom bojom su označeni svi proizvodi koji pripadaju prvoj grupi proizvoda**, dok svi neoznačeni proizvodi pripadaju drugoj grupi proizvoda.

U tabeli 11 su dati svi proizvodi koji se proizvode u posmatranom proizvodnom sistemu sa naznačenim mesečnim količinama, kao i ukupnom godišnjom količinom izraženom u m^2 .

Tabela 11. Prikaz svih proizvoda sa mesečnim količinama i ukupnom godišnjom količinom izraženom u $[m^2]$

Proizvodi	Količine po mesecima u $[m^2]$												Količine na godišnjem nivou $[m^2]$
	jan	feb	mar	apr	maj	jun	jul	aug	sep	okt	nov	dec	
FORCE	313	201	437	365	269	375	416	291	323	398	232	172	3792
OLYMPIC + CORONA	124	136	145	121	150	109	180	177	142	134	182	83	1683
PREMIUM MT	83	136	136	133	169	155	187	158	126	145	153	65	1646
DELTA	137	125	118	110	146	139	160	129	105	101	96	37	1403
ACTIVA	64	88	77	84	108	95	119	90	72	80	78	13	968
SPARTA	86	80	82	69	82	71	92	86	74	67	80	49	918
EVOLUTION MT	57	69	76	68	88	77	100	90	69	66	75	38	873
ABSOLUT	132	42	89	69	55	82	92	55	75	69	47	36	843
ACTIVA PREMIUM	17	70	0	36	122	0	56	118	4	94	23	65	605
SMART	44	56	49	39	62	51	73	53	44	44	54	18	587
EVOLUTION	38	46	50	45	59	52	67	60	46	44	50	25	582
HYPERION	22	45	49	44	56	53	79	67	49	46	58	6	574
TITAN	0	44	44	51	57	66	63	46	42	42	31	19	505
START	38	34	36	31	40	32	51	44	35	34	43	18	436
OPTIMA	23	21	28	22	29	18	38	37	28	25	40	16	325
SPARK	6	28	19	47	18	41	8	42	28	32	23	16	308
SUPER S	3	25	23	21	30	23	35	32	25	25	34	11	287
TAIFUN	0	26	23	28	31	37	32	23	22	22	16	11	271
TOUCH	25	19	18	16	18	12	18	18	18	19	22	8	211
EXTRA	12	0	12	8	7	13	6	10	8	16	3	0	95
LEGEND	4	6	5	8	10	12	12	9	8	7	6	4	91
DESIGNTIME	11	9	10	5	7	7	6	9	6	8	11	0	89
PREMIUM	2	4	4	4	5	5	5	5	4	4	4	2	48
TRIUMPH	0	0	0	0	0	0	0	0	0	0	0	0	0
IDYLLE NOVA	0	0	0	0	0	0	0	0	0	0	0	0	0

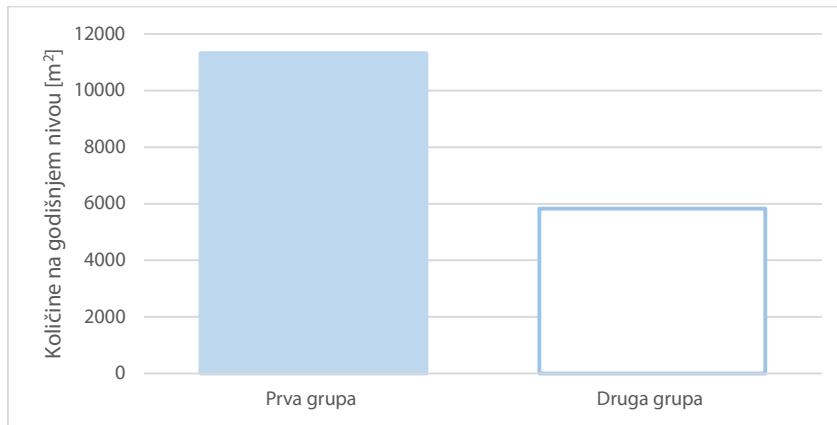
Na osnovu podataka iz tabele 11, dat je i grafički prikaz (grafik 3) odnosa struktura/količine gde je predstavljen redosled proizvoda u programu proizvodnje prema količinama - od proizvoda sa najvećom do proizvoda sa najmanjom količinom na godišnjem nivou. Nadalje, u tabeli 12 su prikazane sumirane količine za definisane grupe proizvoda, dok su na grafiku 4 prikazane količine obe grupe proizvoda.



Grafik 3. Program proizvodnje prema količinama na godišnjem nivou posmatranog proizvodnog sistema

Tabela 12. Sumirane vrednosti za dve definisane grupe proizvoda

Proizvodi	Količine na godišnjem nivou [m ²]	Kumulativne vrednosti	Kumulativni procenti [%]
Prva grupa	11317	11317	66
Druga grupa	5823	17140	100



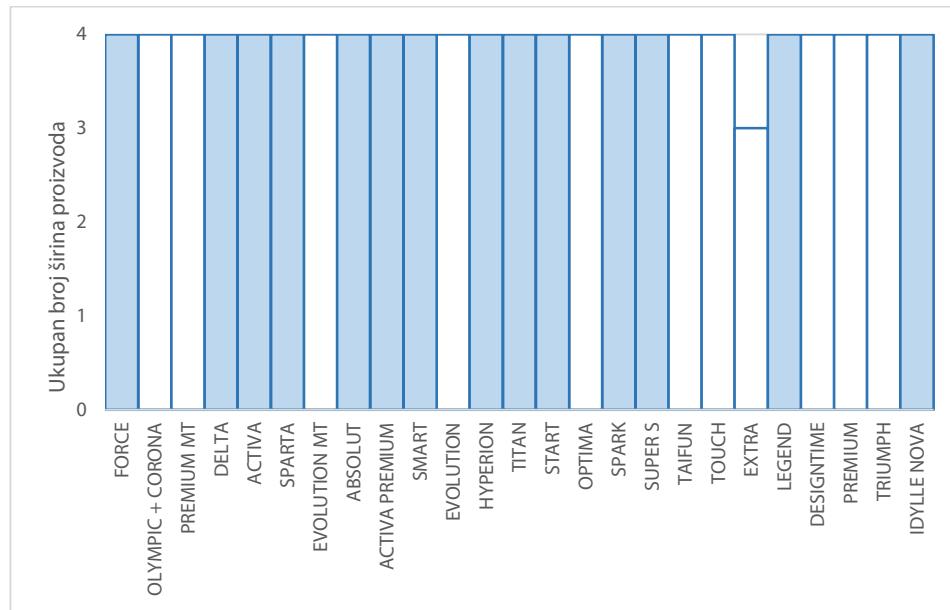
Grafik 4. Količine proizvoda na godišnjem nivou za dve grupe proizvoda

Struktura delova po osnovnim dimenzijama

S obzirom da je finalni proizvod odabranog proizvodnog sistema u obliku rolne, relevantan parametar dimenzijske ještosti jeste isključivo širina proizvoda. Razlog zašto dužina i prečnik nisu uzeti u razmatranje jeste taj što te dimenzijske mogu da variraju u zavisnosti od potreba. Drugim rečima, dužina, a samim tim i prečnik rolne, mogu da se smanje u slučaju da je uočena određena faličnost na proizvodu. To se radi da ne bi finalni proizvod (rolnu) kodirali kao proizvod lošeg ili nedovoljno dobrog kvaliteta, gde se u tom slučaju smanjuje dužina finalnog proizvoda (odsecaju falične delove proizvoda) kako ne bi bili u potpunosti na gubitku profita.

Po pitanju širine proizvoda/rolne, proizvodi se proizvode u ukupno 4 različine širine, i to od 2,5m, 3m, 3,5m i 4m širine. Međutim, važno je naglasiti da je princip izrade proizvoda isti za sve širine proizvoda. Stoga, predmet analize je širina proizvoda gde je uzeto u razmatranje broj širina određenog proizvoda. Razlog zašto se razmatra broj širina je taj što promena širine proizvoda utiče na nastanak neusaglašenosti procesnih parametara u proizvodnom sistemu, a samim tim je i povećana kompleksnost izvođenja proizvodnog procesa.

Na grafiku 5 se vidi da je maksimalan ukupan broj širina proizvoda u posmatranom proizvodnom sistemu 4. Prema tome, analiza dobijenih rezultata govori da svi proizvodi u proizvodnom programu se proizvode u sve četiri širine, osim proizvoda „Extra“ koji se proizvodi u 3 širine. To dalje implicira da su sve 4 širine proizvoda podjednako zastupljene kod obe grupe proizvoda.

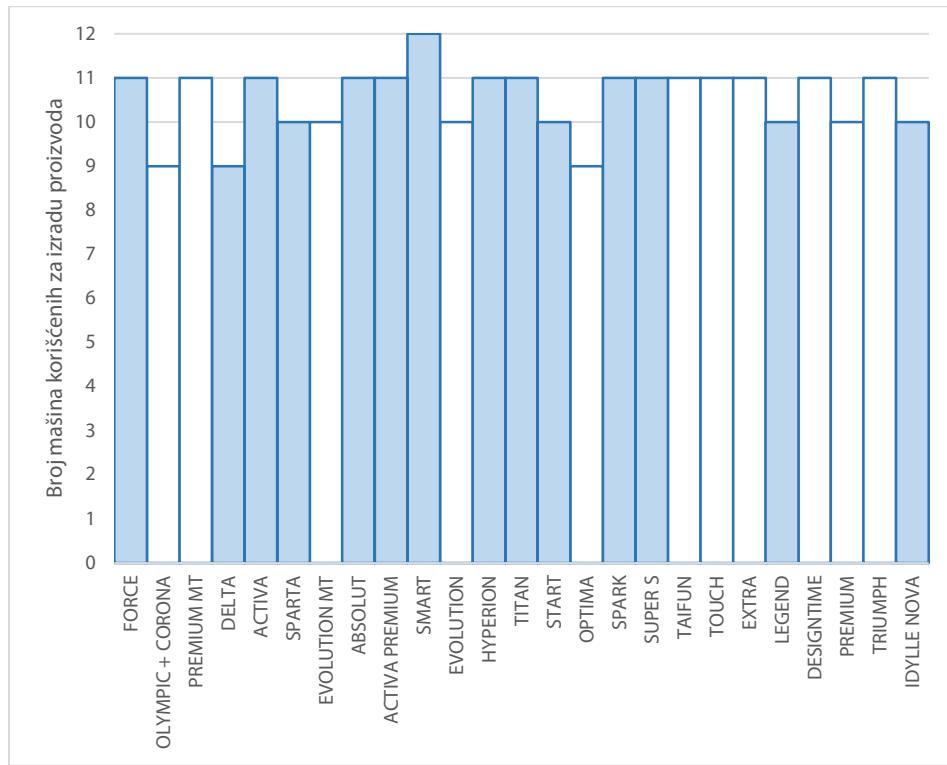


Grafik 5. Analiza struktura delova proizvodnog programa po osnovnim dimenzijama (širina proizvoda/rolne)

Struktura delova po složenosti proizvoda

Prilikom izrade podnih obloga od vinila se koriste različiti materijali kako bi se osigurala njihova otpornost. Materijal koji predstavlja osnov svake podne obloge u posmatranom proizvodnom sistemu jeste flis (vrsta visoko kvalitetnog tekstila dobijenog valjanjem celuloznih vlakana). Da bi se osigurao kvalitet podnih obloga, neophodno je na flis naneti različite slojeve. Slojevi koji se nanose tokom proizvodnog procesa predstavljaju delove proizvoda. Delovi proizvoda su određeni tehnološkim postupkom izrade. Stoga, struktura delova po složenosti proizvoda je izvršena na osnovu broja korišćenih mašina tokom procesa izrade svakog proizvoda, gde je maksimalan broj mašina 12.

Sa grafika 6 se vidi da proizvod „Smart“ ima najveću složenost i koriste svih 12 mašina tokom procesa izrade, dok proizvodi „Olympic+Corona“, „Delta“ i „Optima“ imaju najmanju složenost i koriste 9 mašina. Na osnovu urađene analize se jasno vidi da prva grupa proizvoda ima veću složenost proizvoda u odnosu na drugu grupu.

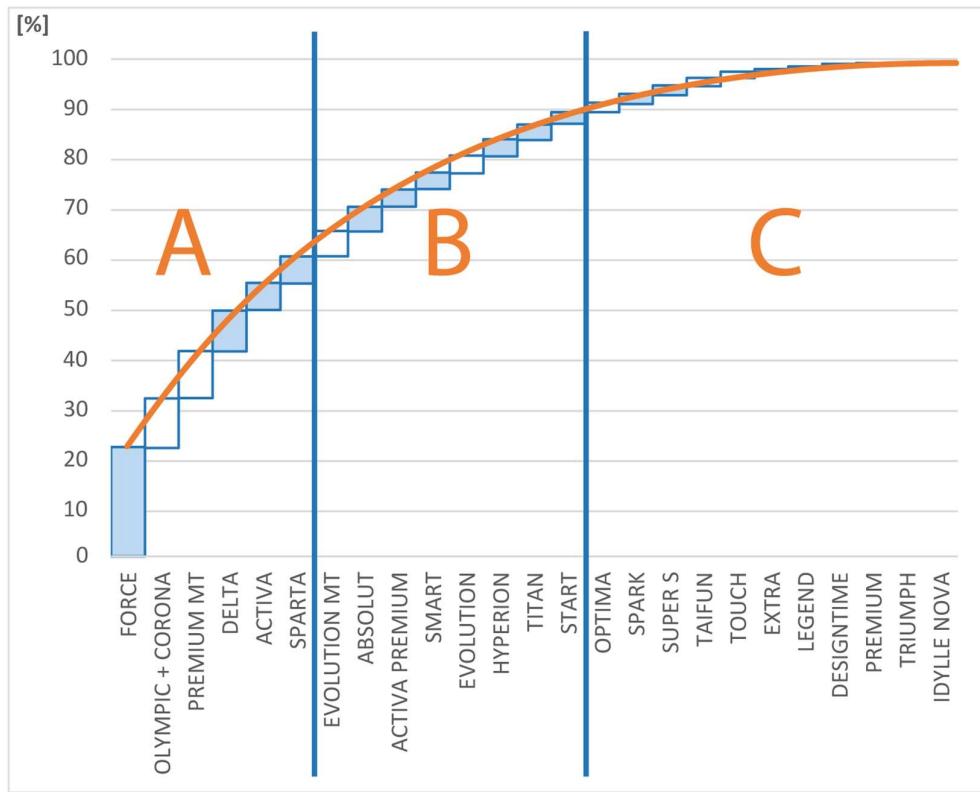


Grafik 6. Analiza struktura delova proizvodnog programa po složenosti proizvoda

Količinska analiza programa proizvodnje

Za količinsku analizu programa proizvodnje, uradenu primenom ABC analize, uzeti su svi proizvodi koji se proizvode u posmatranom proizvodnom sistemu. U tabeli 11 je dat prikaz svih proizvoda sa njihovim mesečnim količinama. S obzirom da je proizvod u obliku rolne, njegova količina je izražena u jedinici [m²].

Grafik 7 predstavlja ABC dijagram gde stupci predstavljaju godišnje količine za svaki proizvod izražen u [m²], dok narandžasta linija predstavlja kumulativnu krivu izraženu u [%]. Rezultat ABC analize prikazane na dijagramu (grafik 7) govori da se u području „A“ nalaze proizvodi „Force“, „Olympic+Corona“, „Premium MT“, „Delta“, „Activa“ i „Sparta“.



Grafik 7. ABC dijagram količina proizvoda posmatranog proizvodnog sistema na godišnjem nivou

Na osnovu svih prethodnih analiza za **predstavnika proizvodnog programa izabrana je prva grupa proizvoda** u okviru primene modela u industrijskom okruženju iz razloga što:

- predstavljaju 66% ukupne godišnje proizvodnje (grafik 4);
- svi proizvodi u okviru izabrane grupe proizvoda se proizvode u maksimalnom broju definisanih širina (grafik 5);

- većina proizvoda u okviru izabrane grupe proizvoda imaju visoku složenost izrade (grafik 6);
- većinski deo proizvoda u okviru izabrane grupe proizvoda se nalazi u području najvećeg prirasta – područje A (grafik 7).

5.3.1.2. *Funkcija cilja proizvodnog sistema*

Funkcija cilja svakog proizvodnog sistema određena je njegovim profitom. Funkcija cilja za razvoj RONP modela je definisana metodom intervjua sa menadžmentom i ekspertima iz posmatranog proizvodnog sistema sa akcentom na profit kompanije. Primenom metode intervjua dobijene su informacije o najznačajnijim problema sa kojima se inženjeni susreću u posmatranom proizvodnom sistemu, gde je akcenat stavljen na probleme koji direktno negativno utiču na ostvarivanje profita kompanije.

Stoga, funkcija cilja posmatranog proizvodnog sistema je definisana kao **unapređenje kvaliteta odabrane grupe proizvoda predstavnika** (prva grupa proizvoda) kako bi se smanjio broj proizvoda koji ne zadovoljavaju zahtevani nivo kvaliteta. Zahtevani nivo kvaliteta proizvoda podrazumeva da finalni proizvodi na sebi nemaju nabore na finalnom proizvodu, nizak kvalitet završne boje, tragove mrljanja, vazdušne plikove na površini, tragove cepanja usled slepljivanja proizvoda za površinu prenosnih valjaka, neu jednačen nanos proizvoda za lepljenje slojeva, itd.

5.3.1.3. *Procena stepena spremnosti proizvodnog sistema za razvoj RONP modela*

Trenutno stanje proizvodnog sistema je utvrđeno primenom fazi ekspertnog sistema. Fazi ekspertni sistem služi kao alat za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Primenom razvijenog ekspertnog sistema, za svaki kriterijum odlučivanja definisan je fazi sistem zaključivanja.

Korišćenjem metode intervjua sa ekspertima iz proizvodnog sistema, na osnovu kojeg je rađena primena modela u industrijskom okruženju, određene su sledeće vrednosti za svaki kriterijum, i to na sledeći način:

- ekspertima su postavljana pitanja generisana na osnovu kriterijuma (tabela 4);
- eksperti su pomoću lingvističkih promenljivih za svaki od kriterijuma opisali trenutno stanje proizvodnog sistema (tabela 4);
- eksperti su dodeljivali procentualne vrednosti kriterijumima koji odgovaraju pripadajućim funkcijama (tabela 4).

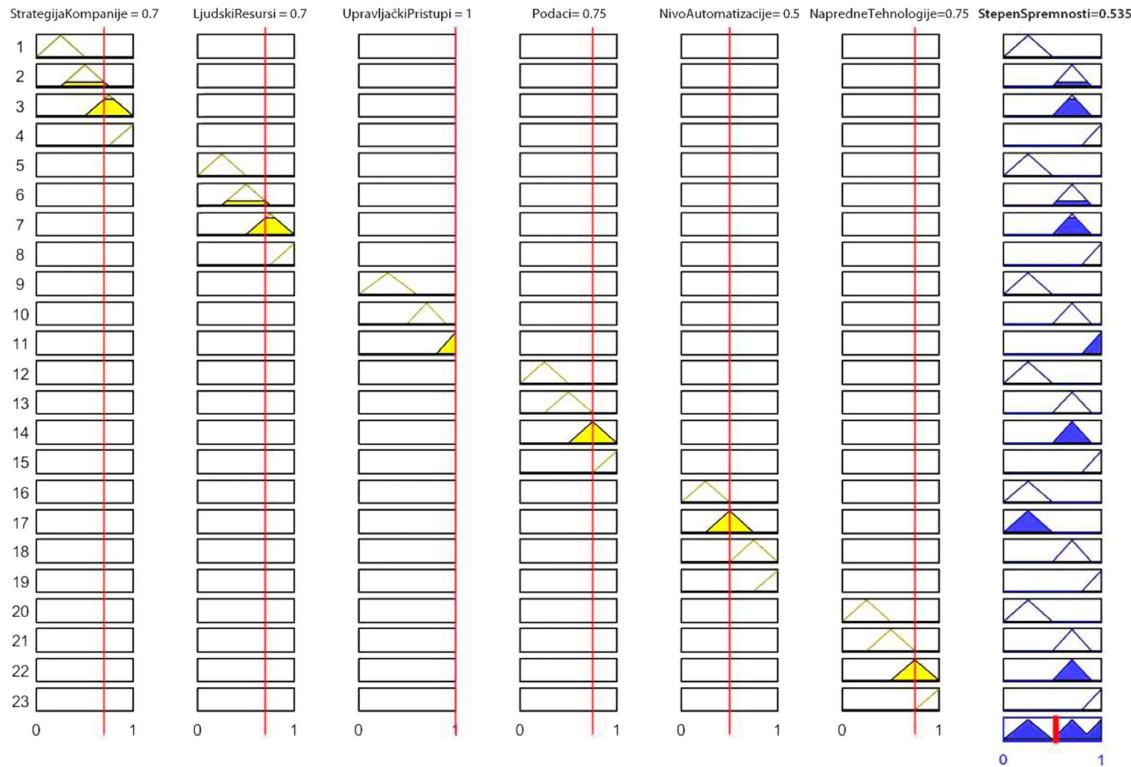
Dobijene vrednosti kriterijuma na osnovu kojih je urađena procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara su prikazane u tabeli 13.

Prema dodeljenim lingvističkim promenljivima na osnovu definisanih vrednosti za svaki kriterijum, dobijen je rezultat **0,535** koji govori da je stepen spremnosti proizvodnog sistema *prihvatljiv* za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Na slici 83 je prikazan dobijeni rezultat procenjenog stepena spremnosti proizvodnog sistema primenom razvijenog fazi ekspertnog sistema.

Tabela 13. Dobijene vrednosti kriterijuma za procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara primenom metode intervjuja eksperata iz proizvodnog sistema

Stepen spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara

<i>RB</i>	<i>Kriterijum</i>	<i>Dodeljena lingvistička promenljiva</i>	<i>Vrednost [%]</i>	<i>Vrednosti pripadajuće funkcije</i>
1.	Strategija kompanije	Strategija u razvoju (razmatranje pilot projekata kao početni korak za razvoj strategije)	70	0,7
2.	Ljudski resursi	Voljni su, ali nisu obučeni	70	0,7
3.	Upravljački pristupi	U potpunosti se primenjuju upravljački pristupi	100	1
4.	Podaci	Prikupljaju se pojedini parametri i analiziraju se	75	0,75
5.	Nivo automatizacije	Dovoljan nivo automatizacije	50	0,5
6.	Napredne tehnologije	Ne postoji, ali se razmatra primena pojedinih naprednih tehnologija	75	0,75



Slika 83. Procjenjeni stepen spremnosti proizvodnog sistema primenom fazi ekspertnog sistema

5.3.1.4. Rezultati Faze 1

Rezultati faze 1 - *Procena trenutnog stanja proizvodnog sistema* predstavlja procenjen stepen spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara nakon njenog završetka primenom fazi ekspertnog sistema. Rezultati faze 1 - *Procene trenutnog stanja proizvodnog sistema* su prikazani u tabeli 14.

Tabela 14. Sumirani rezultati Faze 1

Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu

Faza 1		Procena trenutnog stanja proizvodnog sistema
RB	Korak	Rezultat
		<u>Delatnost proizvodnog sistema:</u> odabrani proizvodni sistem pripada sektoru C – preradivačke industrije, za oblast proizvodnje proizvoda od gume i plastike
1.	Karakteristike proizvodnog sistema	<u>Karakteristike programa proizvodnje:</u> kao predstavnik proizvodnog programa izabrana je grupa proizvoda

		<i>grupisana na osnovu sličnosti procesnih parametara, analize osnovnih dimenzija, složenosti proizvoda i količine.</i>
2.	Funkcija cilja proizvodnog sistema	Unapređenje kvaliteta odabrane grupe proizvoda predstavnika
3.	Procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara	0,535

Zaključak: Prema rezultatima prve faze RONP modela zaključuje se da se mogu sprovesti sve naredne faze za razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara.

5.3.2. Faza 2: Definisanje problema neusaglašenosti u proizvodnom sistemu

Na osnovu razvijenog modela za rano otkrivanje neusaglašenosti procesnih parametara definisan je problem u posmatranom proizvodnom sistemu. Svi procesi proizvodnje u proizvodnom sistemu se odvijaju kontinualno u vremenu. Trenutni tok procesa proizvodnje u proizvodnom sistemu se ogleda u sistematičnom utvrđivanju nastanka grešaka i njihovoj klasifikaciji na finalnom proizvodu pomoću definisanog šifrarnika grešaka (slika 84). Međutim, nastale greške na finalnom proizvodu se klasificuju tek na kraju proizvodne linije. Odnosno, ne postoji način utvrđivanja grešaka na samom mestu njihovog nastanka, već se ta informacija naknadno unosi u sistem na osnovu iskustva eksperata, gde veliku ulogu igra ljudski faktor.

DefectCode	Mesto	CausalWC	Masina	CausalLossCode	ResultantLossCode	Za
NPS	Poledinska štampa	LINIJA PVC4M	Poledinska stampa	V14-PVC	V14-PVC	4
S-1F	Premazivanje 1	LINIJA PVC4M	Premazivanje 1	V14-PVC	V14-PVC	1
PPV	Mehaničko pregovanje	LINIJA PVC4M	Pregovanje	V14-PVC	V14-PVC	3
PRL	Linija	LINIJA PVC4M	Cela linija	V14-PVC	V14-PVC	0
PSF	Premazivanje 4	LINIJA PVC4M	Premazivanje 4	V14-PVC	V14-PVC	1
PSL	Poledinska štampa	LINIJA PVC4M	Poledinska stampa	V14-PVC	V14-PVC	4
PSN	Poledinska štampa	LINIJA PVC4M	Poledinska stampa	V14-PVC	V14-PVC	4
PSS	Poledinska štampa	LINIJA PVC4M	Poledinska stampa	V14-PVC	V14-PVC	4
RU	Tehnološki	LINIJA PVC4M	Cela linija	V14-PVC	V14-PVC	0
RV	Linija	LINIJA PVC4M	Cela linija	V14-PVC	V14-PVC	0
S-5NP	Premazivanje 5	LINIJA PVC4M	Premazivanje 5	V14-PVC	V14-PVC	3
S-1C	Premazivanje 1	LINIJA PVC4M	Premazivanje 1	V14-PVC	V14-PVC	1
1C	Premazivanje 1	LINIJA PVC4M	Premazivanje 1	V14-PVC	V14-PVC	1
1F	Premazivanje 1	LINIJA PVC4M	Premazivanje 1	V14-PVC	V14-PVC	1
1L	Premazivanje 1	LINIJA PVC4M	Premazivanje 1	V14-PVC	V14-PVC	1
1NP	Premazivanje 1	LINIJA PVC4M	Premazivanje 1	V14-PVC	V14-PVC	1
SU	Tehnološki	LINIJA PVC4M	Cela linija	V14-PVC	V14-PVC	0
TP	Premazivanje 5	LINIJA PVC4M	Premazivanje 5	V14-PVC	V14-PVC	3
U	Tehnološki	LINIJA PVC4M	Cela linija	V14-PVC	V14-PVC	0
1SP	Premazivanje 1	LINIJA PVC4M	Premazivanje 1	V14-PVC	V14-PVC	1
1Z	Premazivanje 1	LINIJA PVC4M	Premazivanje 1	V14-PVC	V14-PVC	1
S-2C	Premazivanje 2	LINIJA PVC4M	Premazivanje 2	V14-PVC	V14-PVC	1

Slika 84. Šifrarnik grešaka proizvodnog sistema za proizvodnju podnih obloga od vinila

U okviru posmatranog proizvodnog sistema gde je čovek ključan za detektovanje određenih stanja sistema, dolazi se do poteškoća u njegovom upravljanju. Razlog tome je taj što su ljudska percipiranja nekonzistentna i informacije se dobijaju tek po završetku određenih procesa proizvodnje. U praksi određeno stanje unutar sistema može da postoji duže vremena, ali se kao takvo definiše tek onda kada ga ljudi primete, odnosno kada dostupne podatke pretoče u informaciju o tom stanju. Upravo zbog toga, model za rano otkrivanje neusaglašenosti procesnih parametara služi kao alat za unapređenje kvaliteta proizvoda, a samim tim i proizvodnih procesa, gde je cilj da se eliminiše uticaj ljudskog faktora u donošenju odluka unutar posmatranog proizvodnog sistema.

Stoga, prema definisanim fazama razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara, u nastavku rada definisan je problem na osnovu praćenja koraka u okviru faze 1 - *Definisanje problema neusaglašenosti u proizvodnom sistemu*. Svaki od definisanih koraka su detaljno predstavljeni u narednim potpoglavljima.

5.3.2.1. Preciziranje vrste neusaglašenosti

Imajući u vidu da je polazna osnova za preciziranje vrste neusaglašenosti u uskoj vezi sa određenom funkcijom cilja (faza 1, slika 34), važno je uzeti je u obzir tokom validacije matematičkog RONP modela. Prema rezultatima faze 1, funkcija cilja posmatranog proizvodnog sistema predstavlja unapređenje kvaliteta odabrane grupe proizvoda predstavnika nedovoljno dobrog kvaliteta.

Nedovoljno dobar kvalitet proizvoda okarakterisan je kao **neusaglašenost**, odnosno *odstupanje od utvrđenih zahteva od gotovog proizvoda za koji, prema standardima posmatranog proizvodnog sistema, treba da pripada grupi "A" klase proizvoda*. Nedovoljan kvalitet proizvoda nastaje usled **neusaglašenosti procesnih parametara**. Shodno tome, precizirana vrsta neusaglašenosti okarakterisana je kao **nedovoljno dobar kvalitet proizvoda nastao na osnovu neusaglašenosti procesnih parametara**.

Kao što je prethodno navedeno pitanja problema kvaliteta finalnog proizvoda uključuju:

- nabore na finalnom proizvodu,
- nizak kvalitet završne boje,
- tragove mrljanja,
- vazdušne plikove na površini,
- tragove cepanja usled slepljivanja proizvoda za površinu prenosnih valjaka,
- neujednačen nanos proizvoda za lepljenje slojeva, itd.,

koji su uslovljeni nastankom neusaglašenosti procesnih parametara tokom proizvodnog procesa.

5.3.2.2. Određivanje lokacije nastanka neusaglašenosti

Nakon preciziranja vrste neusaglašenosti, odnosno odrednica koje opisuju vrstu neusaglašenosti, sledi korak određivanja lokacije njenog nastanka. Lokacija nastanka definisane neusaglašenosti određena je pomoću analize eksperata iz posmatranog proizvodnog sistema koji su u potpunosti upoznati sa proizvodnim procesom u kojem se vrši validacija razvijenog RONP modela.

Prema preciziranoj vrsti neusaglašenosti procesnih parametara, zaključeno je da se nedovoljan kvalitet proizvoda u proizvodnom sistemu najčešće javlja na početku proizvodne linije. Početak linije, prema definiciji eksperata iz posmatranog proizvodnog sistema, obuhvata *Klaster 1* (slika 64), odnosno ulaz sirovine i tri mašine nazvane **P1** (slika 65), **P2** (slika 66) i **Štampa** (slika 67).

S obzirom na to da se na mašini za štampu materijala ne dešavaju greške koje utiču na nedovoljan kvalitet proizvoda čiji je uzrok nausaglašenost procesnih parametara (na mašini za štampu se javlaju proizvodi lošeg kvaliteta gde je uzrok nastanka povezan sa ljudskim radom), ova mašina je izuzeta iz analize i ne predstavlja jednu od lokacija nastanka neusaglašenosti.

Daljom analizom lokacije nastanka neusaglašenosti u vidu lošeg ili nedovoljno dobrog kvaliteta proizvoda, došlo se do zaključka da se na mašini *P1* dešava zanemarljivo mali broj grešaka kvaliteta. Stoga, **lokacija nastanka neusaglašenosti parametara u proizvodnom sistemu obuhvata mašinu premazivanje 2 (P2)**.

5.3.2.3. Određivanje tipa problema neusaglašenosti

Tip problema u posmatranom proizvodnom sistemu određen je na osnovu precizirane vrste neusaglašenosti, koja se odnosi na **nedovoljan kvalitet proizvoda na osnovu procesih parametara**. S obzirom na činjenicu da se razlikuju dva tipa problema neusaglašenosti u proizvodnom sistemu - **klasifikacioni** ili **regresioni načini određivanja tipa problema**, tip problema u posmatranom proizvodnom sistemu je okarakterisan kao **klasifikacioni tip problema**. Razlog zašto je problem okarakterisan kao klasifikacioni jeste taj što je cilj utvrđivanje da li proizvod pripada grupi "A" klase proizvoda ili ne, na osnovu neusaglašenosti procenih parametara. Drugim rečima, klasifikacioni tip problema određuje broj klasa zavisne promenljive koja u ovom istraživanju ima dve klase.

Klasifikacioni tip problema sa dve klase predstavljen je pomoću binarnog zapisa gde "0" daje informaciju o tome kada se u posmatranom proizvodnom sistemu nije dogodila definisana neusaglašenost, dok zapis "1" daje informaciju kada se dogodila definisana neusaglašenost. Odnosno, zapis "1" predstavlja podatak koji govori o tome da se tokom procesa proizvodnje javila određena greška kvaliteta prouzrokovana neusaglašenošću procesnih parametara na definisanoj lokaciji.

5.3.2.4. Rezultati Faze 2

Rezultati faze 2 - *Definisanje problema neusaglašenosti u proizvodnom sistemu* za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara predstavlja izlaznu informaciju nakon njenog završetka, odnosno nakon uspešnog sprovođenja svih njenih koraka, u vidu definisanog problema. Rezultati faze 2 - *Definisanje problema neusaglašenosti u proizvodnom sistemu* su prikazani u tabeli 15.

Tabela 15. Sumirani rezultati Faze 2

Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu		
Faza 2	Definisanje problema neusaglašenosti u proizvodnom sistemu	
RB	Korak	Rezultat
1.	Preciziranje vrste neusaglašenosti	Nedovoljno dobar kvalitet proizvoda nastao na osnovu neusaglašenosti procesnih parametara.
2.	Određivanje lokacije nastanka neusaglašenosti	Mašina premazivanje 2 (P2)
3.	Određivanje tipa problema neusaglašenosti	Klasifikacioni tip problema neusaglašenosti

5.3.3. Faza 3: Identifikacija uticajnih parametara i prikupljanje podataka

Identifikacija uticajnih parametara urađena je primenom metode intervju sa ekspertima iz posmatranog proizvodnog sistema, nakon čega je usledilo njihovo prikupljanje. Prikupljanje uticajnih parametara je omogućeno primenom industrijskog računara MELIPC MI5000, zasnovanog na *Edge* sistemu računarske tehnologije.

Za posmatrani proizvodni sistem su identifikovani uticajni parametri u skladu da koracima faze 3 - *Identifikacija uticajnih parametara i prikupljanje podataka*. Svaki od definisanih koraka su detaljno predstavljeni u narednim potpoglavljkima.

5.3.3.1. Definisanje kriterijuma za identifikaciju uticajnih parametara

Kriterijumi na osnovu kojih se vrši identifikacija parametara direktno zavise od precizirane vrste neusaglašenosti u posmatranom proizvodnom sistemu, kao i od lokacije nastanka definisane neusaglašenosti, što predstavlja ujedno i rezultat faze 2 - *Definisanje problema neusaglašenosti u proizvodnom sistemu* (tabela 15).

Definisan problem u proizvodnom sistemu za proizvodnju podnih obloga od vinila vezan je za nedovoljno dobar kvalitet proizvoda nastao na osnovu neusaglašenosti procesih parametara. Na osnovu toga definisan je i kriterijum da se posmatra određena grupa proizvoda odabranih na osnovu određenih sličnosti proizvodnog procesa, tačnije na osnovu sličnosti procesnih parametara.

Grupa proizvoda (tabela 16), koja se sastoji od 14 proizvoda, odabrana je na osnovu *sličnosti tolerancija procesnih parametara na mašini P2*. Grupa proizvoda obuhvata određeni skup koji čini većinski ideo proizvodnje na godišnjem nivou, odnosno 66% od ukupne proizvodnje (tabela 12). Stoga, osnovni **kriterijum za identifikaciju uticajnih parametara** jeste *definisanje grupe proizvoda na osnovu sličnosti tolerancija procesnih parametra koja se na godišnjem nivou najviše proizvodi u posmatranom proizvodnom sistemu*.

Tabela 16. Definisana grupe proizvoda na osnovu sličnosti tolerancija procesnih parametra

<i>RB</i>	<i>Naziv proizvoda</i>	<i>RB</i>	<i>Naziv proizvoda</i>
1.	Delta	8.	Activa Premium
2.	Start	9.	Absolut
3.	Idylle Nova	10.	Smart
4.	Spark	11.	Force
5.	Titan	12.	Sparta
6.	Super S	13.	Legend
7.	Activa	14.	Hyperion

5.3.3.2. Identifikacija uticajnih parametara

Nakon definisanja kriterijuma za identifikaciju uticajnih parametara definisani su i sami uticajni procesni parametri. Uticajni procesni parametri su izabranu uz konsultacije sa eksperatima iz posmatranog proizvodnog sistema na osnovu odabrane grupe proizvoda, kao i lokacije nastanka definisane neusaglašenosti. Broj definisanih uticajnih procesnih parametara za **mašinu P2** iznosi 15, što je prikazano u tabeli 17.

Tabela 17. Definisani uticajni procesni parametri

<i>RB</i>	<i>Naziv parametra</i>	<i>RB</i>	<i>Naziv parametra</i>
1.	Zazor_GV2_desna	9.	KorPendPosleB2
2.	Zazor_GV2_leva	10.	KorPendPreB2
3.	Temperatura_GV2	11.	LineSpeed
4.	Temperatura_B2	12.	LineStopped
5.	Temperatura_OV2	13.	ViskP2
6.	Temperatura_PB2	14.	PHR_P2
7.	THB2D	15.	Saum
8.	THB2G		

5.3.3.3. Dostupnost uticajnih parametara

Svi definisani uticajni procesni parametri moraju biti dostupni u vidu digitalnih podataka za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Njihova dostupnost je proverena na osnovu konsultacija sa ekspertima iz posmatranog proizvodnog sistema, gde je zaključeno da se svi definisani uticajni procesni parametri prate pomoću senzora i da su njihove vrednosti dostupne u internoj bazi podataka.

5.3.3.4. Određivanje tipa podataka uticajnih parametara

Tip podataka uticajnih procesnih parametara je predefinisan u internoj bazi podataka od strane eksperata iz proizvodnog sistema. Međutim, za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara je neophodno da informacija o tipu podataka bude tačno naznačena kako bi mogli da se sprovedu naredne faze razvoja modela. Za svaki uticajni procesni parametar je određen tip podataka što je prikazano u tabeli 18.

Tabela 18. Određeni tipovi svih uticajnih procesnih parametara

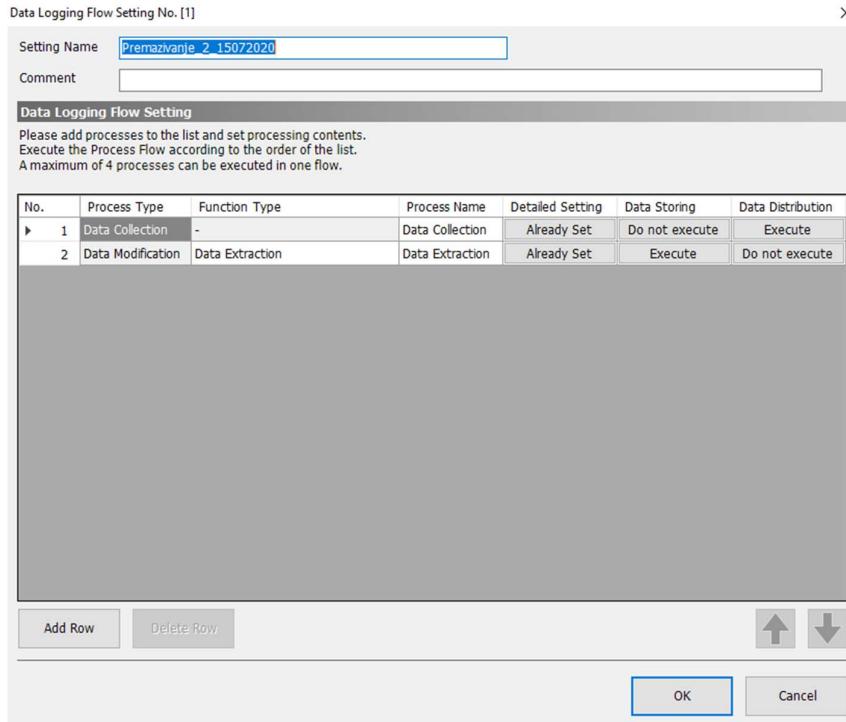
<i>RB</i>	<i>Naziv parametra</i>	<i>Tip podatka</i>	<i>RB</i>	<i>Naziv parametra</i>	<i>Tip podatka</i>
1.	Zazor_GV2_desna	realni	9.	Saum	realni
2.	Zazor_GV2_leva	realni	10.	KorPendPosleB2	realni
3.	Temperatura_GV2	realni	11.	KorPendPreB2	realni
4.	Temperatura_B2	realni	12.	LineSpeed	realni
5.	Temperatura_OV2	realni	13.	LineStopped	binarni
6.	Temperatura_PB2	realni	14.	ViskP2	realni
7.	THB2D	realni	15.	PHR_P2	binarni
8.	THB2G	realni			

5.3.3.5. Prikupljanje podataka uticajnih parametara

Prikupljanje uticajnih procesnih parametara je izvršeno zapisivanjem podataka sa senzora preko *Edge* sistema računarske tehnologije. To je omogućeno korišćenjem specijalizovanog softvera za prikupljanje podataka *Real-time Flow Designer* na MELIPC MI5000 industrijskom računaru.

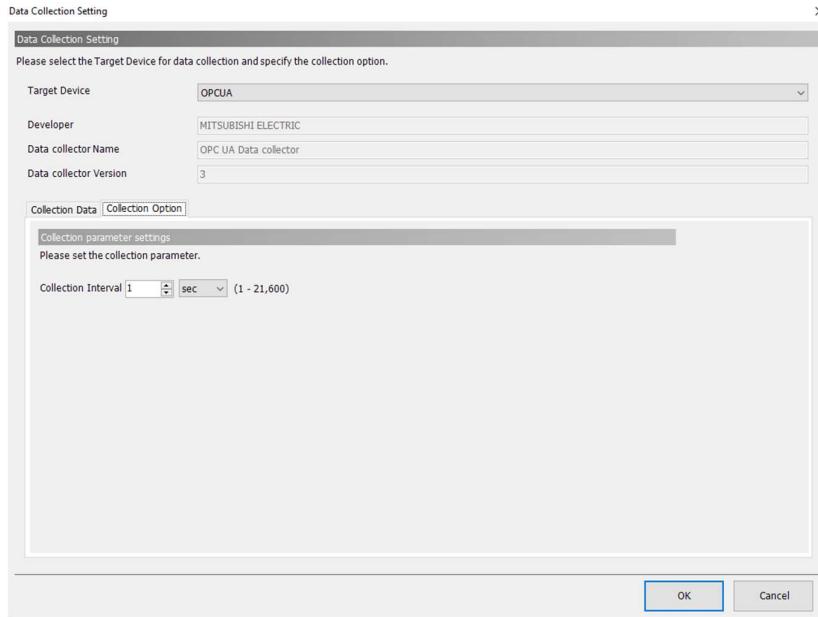
Prikupljanje podataka se odvijalo u dve etape (slika 85), i to:

1. *definisanje uslova prikupljanja podataka (Data Collection)* – podrazumeva korišćenje standardizovanog formata prikupljanja podataka koji je odabran da bude **.csv format** (razlog zašto je odabran .csv format jeste taj što se on prvenstveno koristi za skladištenje tabelarnih podataka, odnosno podataka koji se mogu raščlaniti na redove i kolone koji se odlikuju jednostavnom manipulacijom, lakoćom kreiranja fajla i velikom brzinom očitavanja). Takođe, u ovoj etapi prikupljanja podataka se određuje tačan vremenski interval između zapisivanja uzorka prikupljenih podataka. Vremenski interval je određen da bude podešen na *1 sekundu* (slika 86). Drugim rečima, to znači da se podatak za svaki uticajni procesni parametar prikuplja svake sekunde u okviru jednog fajla. Dalje, način prikupljanja podataka uticajnih procesnih parametara je određen veličinom generisanog fajla, gde je definisano da se u jedom fajlu nalazi *300 uzoraka*. Na taj način, svaki novi fajl sa po 300 uzoraka, prikupljenih na jedan sekund, se generiše na *5 minuta*.

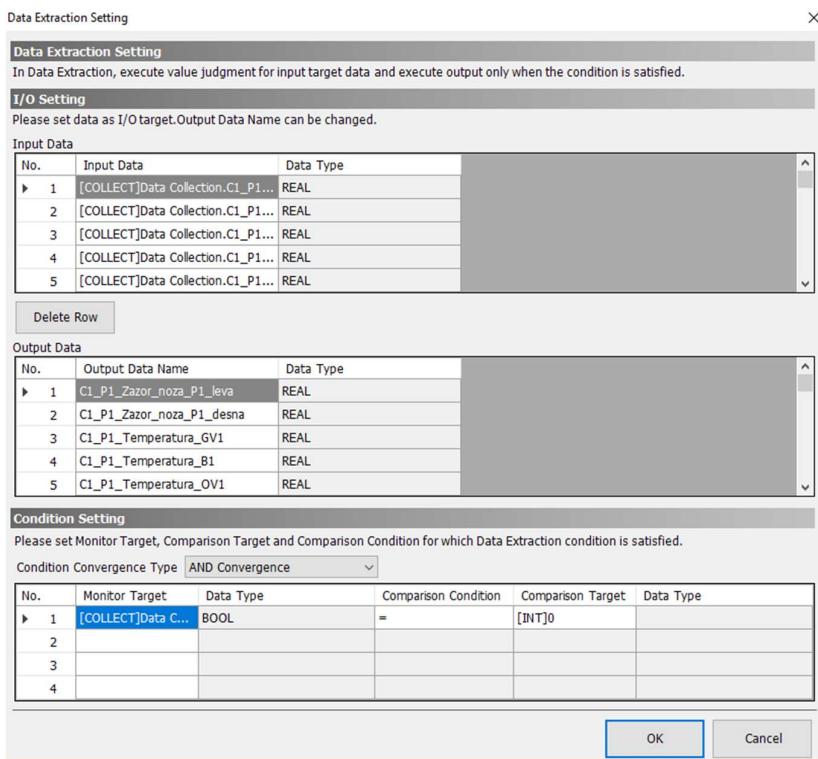


Slika 85. Etape prikupljanja podataka pomoću Real-time Flow Designer softvera, MELIPC MI5000

2. modifikacija definisanih uslova za prikupljanje podataka (*Data Modification*) - podrazumeva definisanje situacija kada je potrebno da se prikupljaju podaci, odnosno vrednosti uticajnih procesnih parametara. Uslov za modifikaciju se odnosi na prikupljanje podataka isključivo kada mašine ne stoje. To je omogućeno na osnovu definisanog uticajnog parametra *LineStopped*. S obzirom na činjenicu da je taj definisani parametar binarnog tipa, uslov za modifikaciju je definisan na sledeći način (slika 87): *Kada je uticajni parametar LineStopped aktivan* (odnosno kada mu je vrednost jednaka 0), *tada se vrši prikupljanje podataka svih definisanih uticajnih procesnih parametara. U svakom drugom slučaju ne vrši se prikupljanje podataka.*



Slika 86. Vremenski interval između zapisivanja uzoraka prikupljenih podataka pomoću Real-time Flow Designer softvera, MELIPC MI5000



Slika 87. Definisanje situacija kada je potrebno da se prikupljaju podaci, odnosno vrednosti uticajnih procesnih parametara pomoću Real-time Flow Designer softvera, MELIPC MI5000

Nakon završetka obe etapa prikupljanja podataka uticajnih parametara, započeto je njihovo generisanje u internoj bazi podataka (slika 88).

 P2_00001F17	28-Aug-20 4:00 AM	Microsoft Excel Co...	53 KB
 P2_00001F18	28-Aug-20 4:05 AM	Microsoft Excel Co...	53 KB
 P2_00001F19	28-Aug-20 4:10 AM	Microsoft Excel Co...	53 KB
 P2_00001F1A	28-Aug-20 4:15 AM	Microsoft Excel Co...	53 KB
 P2_00001F1B	28-Aug-20 4:20 AM	Microsoft Excel Co...	53 KB
 P2_00001F1C	28-Aug-20 4:25 AM	Microsoft Excel Co...	53 KB
 P2_00001F1D	28-Aug-20 4:30 AM	Microsoft Excel Co...	53 KB
 P2_00001F1E	28-Aug-20 4:35 AM	Microsoft Excel Co...	53 KB
 P2_00001F1F	28-Aug-20 4:40 AM	Microsoft Excel Co...	53 KB
 P2_00001F20	28-Aug-20 4:45 AM	Microsoft Excel Co...	53 KB
 P2_00001F21	28-Aug-20 4:50 AM	Microsoft Excel Co...	53 KB
 P2_00001F22	28-Aug-20 4:55 AM	Microsoft Excel Co...	53 KB
 P2_00001F23	28-Aug-20 5:00 AM	Microsoft Excel Co...	53 KB
 P2_00001F24	28-Aug-20 5:05 AM	Microsoft Excel Co...	53 KB
 P2_00001F25	28-Aug-20 5:10 AM	Microsoft Excel Co...	53 KB

Slika 88. Generisanje .csv fajlova sa vrednostima uticajnih procesnih parametara pomoću Real-time Flow Designer softvera, MELIPC MI5000

Period prikupljanja podataka je definisan da traje mesec dana, počev od 28. avgusta 2020. godine, pa sve do 29. septembra 2020. U tom periodu broj prikupljenih podataka je iznosio **6.534 .csv fajlova**, gde se u svakom fajlu nalazi po **300 podataka** za svaki uticajni procesni parametar. Odnosno, ukupan broj prikupljenih podataka za svaki uticajni parametar u okviru definisanog vremenskog perioda iznosio je **1.960.200 podataka**.

5.3.3.6. Rezultati Faze 3

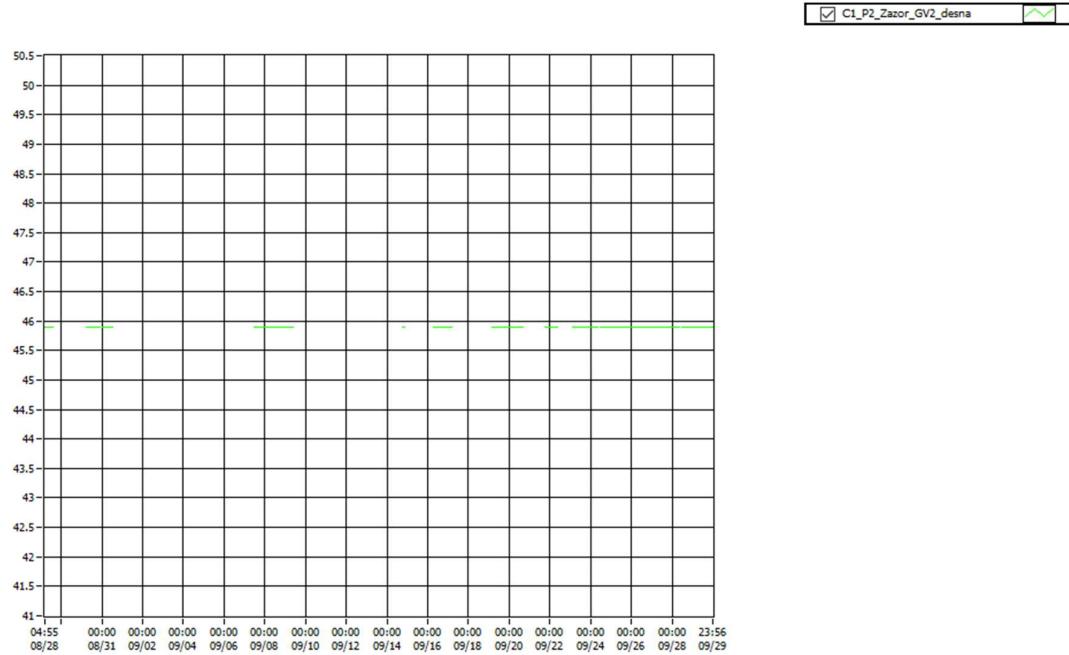
Rezultati faze 3 - *Identifikacija uticajnih parametara i prikupljanje podataka za razvoj RONP modela* predstavlja izlaznu informaciju nakon njenog završetka, odnosno nakon uspešnog sprovođenja svih njenih koraka, u vidu prikupljenih podataka. Rezultati faze 3 - *Identifikacija uticajnih parametara i prikupljanje podataka* su prikazani u tabeli 19.

Tabela 19. Sumirani rezultati Faze 3

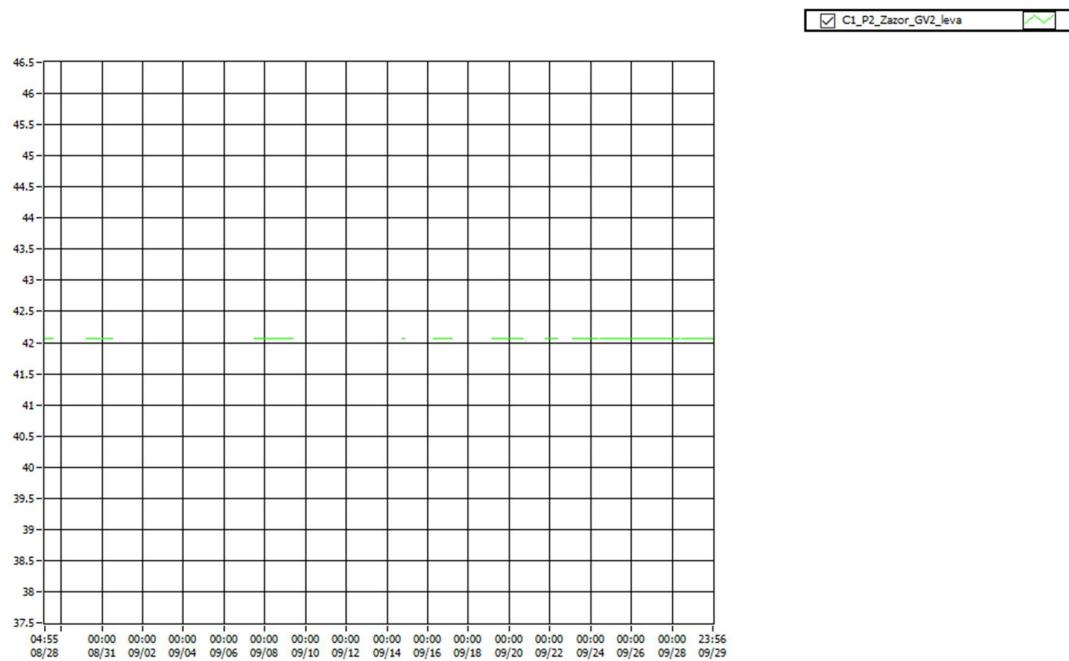
Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu		
Faza 3	Identifikacija uticajnih parametara i prikupljanje podataka	
RB	Korak	Rezultat
1.	Definisanje kriterijuma za identifikaciju uticajnih parametara	Definisana grupa proizvoda na osnovu sličnosti tolerancija procesnih parametra koja se na godišnjem nivou najviše količinski proizvodi u posmatranom proizvodnom sistemu
2.	Definisanje uticajnih parametara	Broj definisanih uticajnih procesnih parametara za mašinu P2 iznosi 15.
3.	Dostupnost uticajnih parametara	Svi definisani uticajni procesni parametri su dostupni.
4.	Odredivanje tipa podataka uticajnih parametara	Svi tipovi podataka uticajnih procesnih parametara su određeni.
5.	Prikupljanje podataka uticajnih parametara	U definisanom vremenskom periodu broj prikupljenih podataka je iznosio 6.534 .csv fajlova, gde se u svakom fajlu nalazi po 300 podataka za svaki uticajni procesni parametar. Odnosno, ukupan broj prikupljenih podataka je 1.960.200.

5.3.4. Faza 4: Priprema i obrada prikupljenih podataka

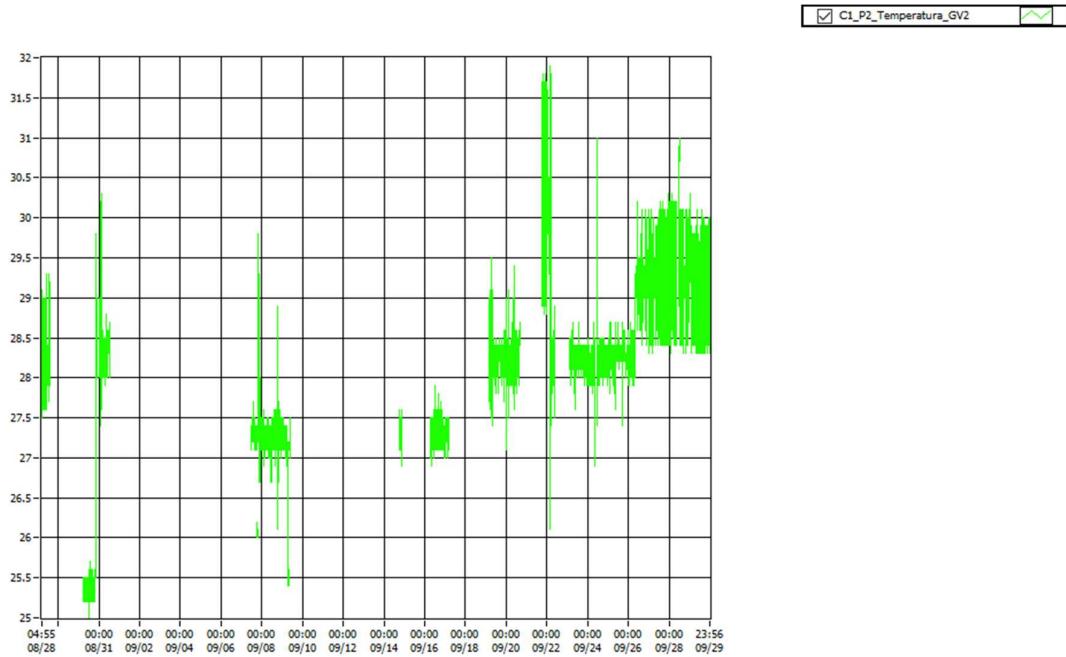
Priprema i obrada prikupljenih podataka se sprovodi na osnovu definisanih koraka, gde je cilj eliminisanje svih podataka koji negativno utiču na razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara. Priprema prikupljenih podataka se radi manuelno gde se eliminišu podaci ili celi .csv fajlovi, dok je obrada prikupljenih podataka omogućena primenom industrijskog računara MELIPC MI5000, zasnovanog na *Edge* sistemu računarske tehnologije, u okviru softverskog paketa *Real-time Statistics Diagnosis Tool*. Međutim, pre same pripreme prikupljenih podataka neophodna je njihova vizuelizacija i analiza. Slike 89–103 predstavljaju vizuelizaciju svih uticajnih procesnih parametara ponaosob prikupljenih u definisanom vremenskom periodu (potpoglavlje 5.3.3.5).



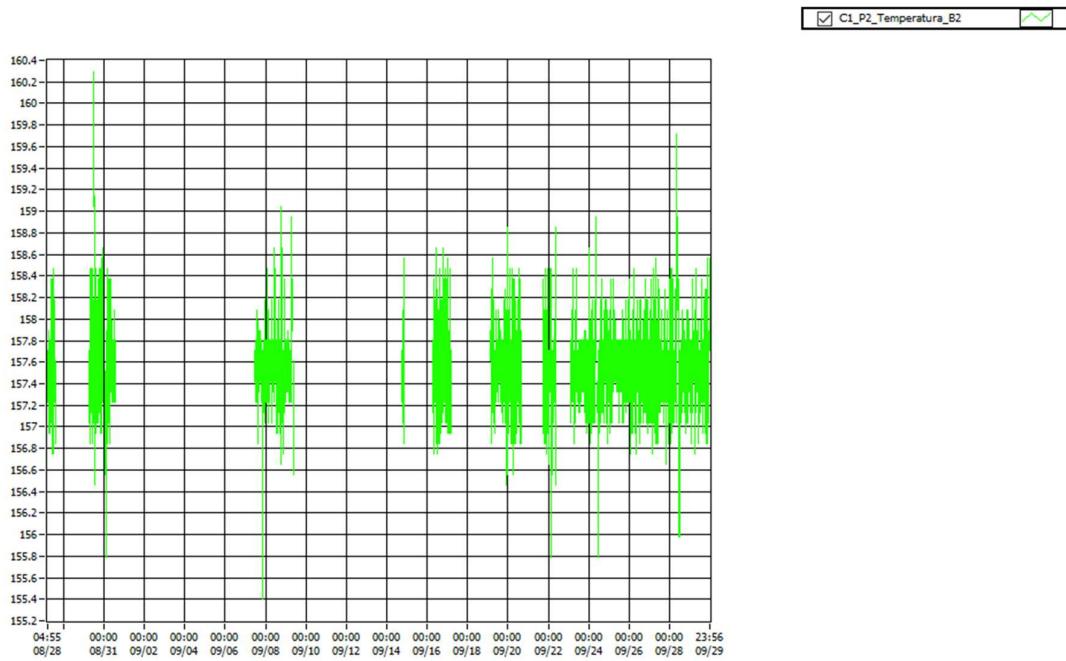
Slika 89. Vizuelni prikaz uticajnog parametra Zazor_GV2_desna



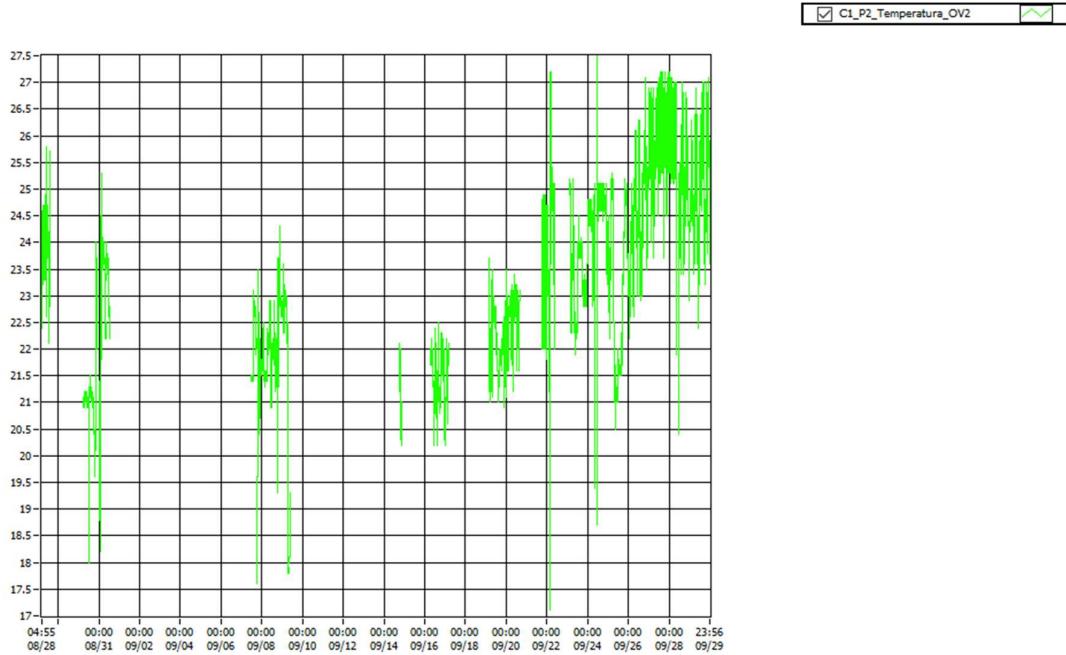
Slika 90. Vizuelni prikaz uticajnog parametra Zazor_GV2_leva



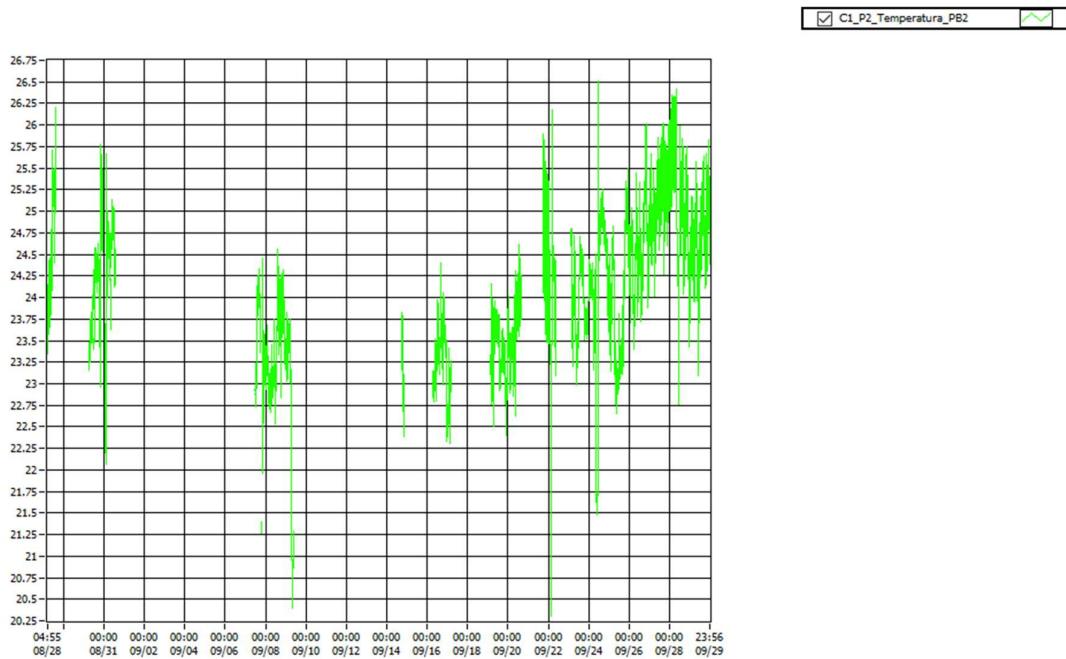
Slika 91. Vizuelni prikaz uticajnog parametra Temperatura_GV2



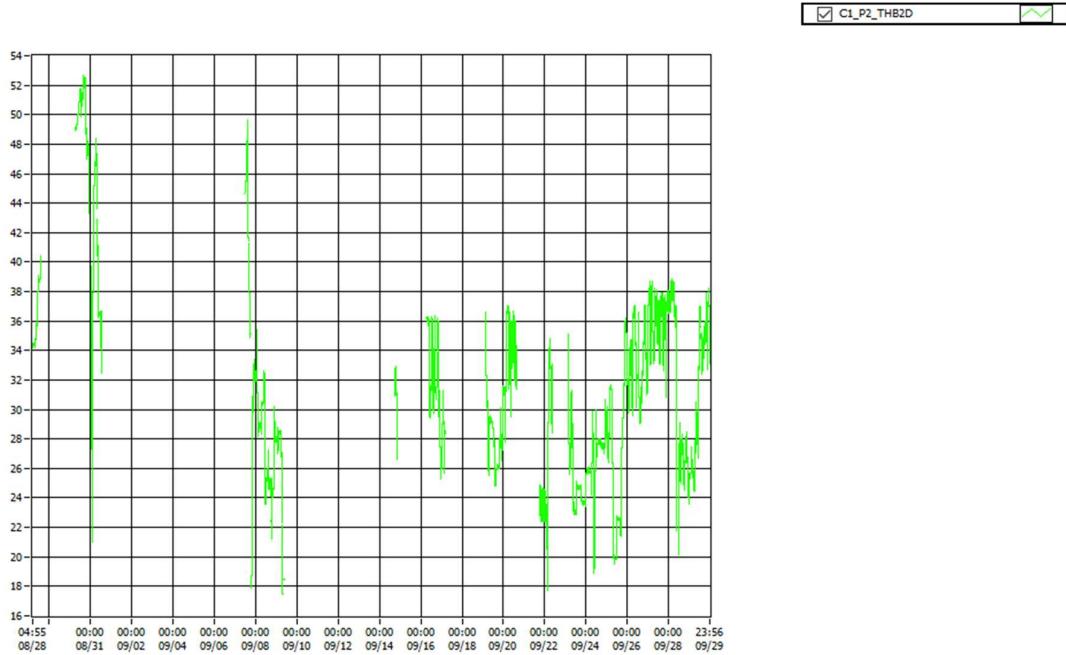
Slika 92. Vizuelni prikaz uticajnog parametra Temperatura_B2



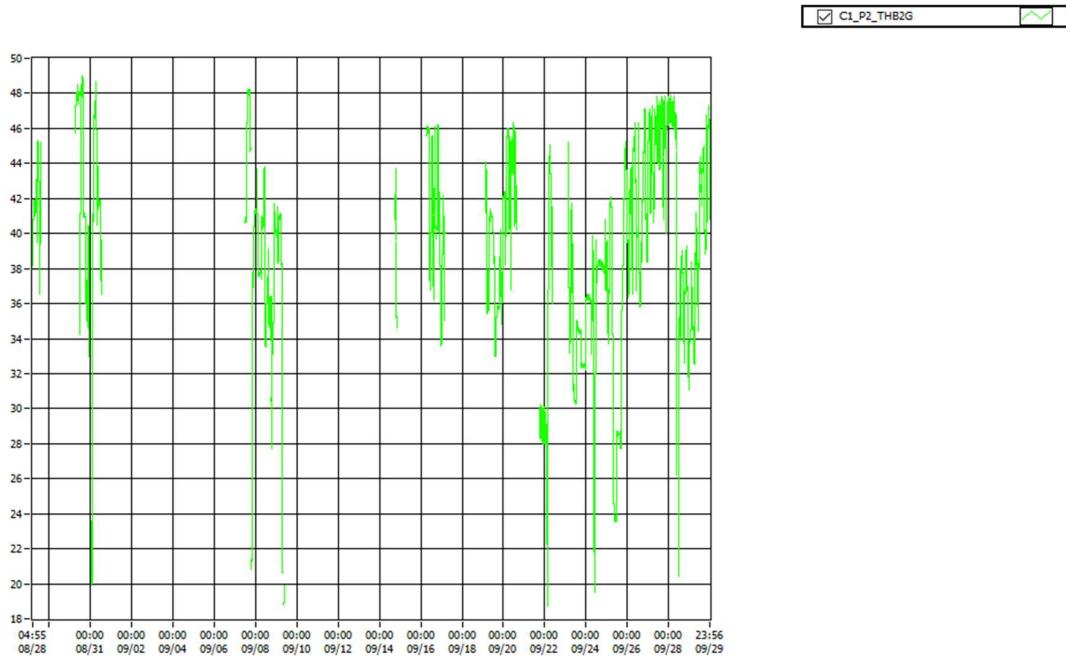
Slika 93. Vizuelni prikaz uticajnog parametra Temperatura_OV2



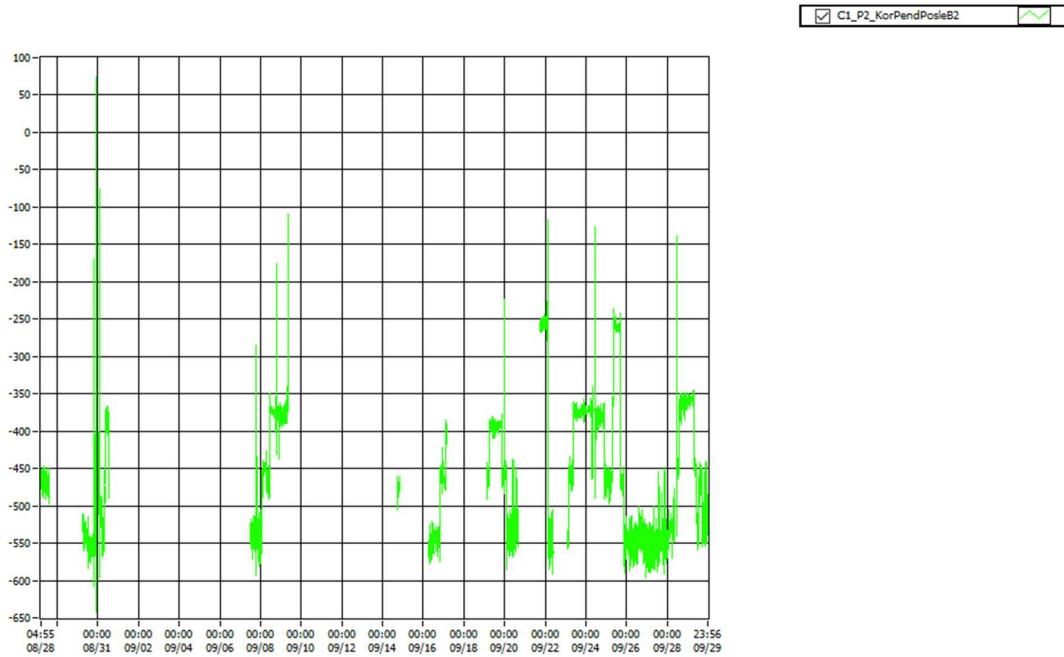
Slika 94. Vizuelni prikaz uticajnog parametra Temperatura_PB2



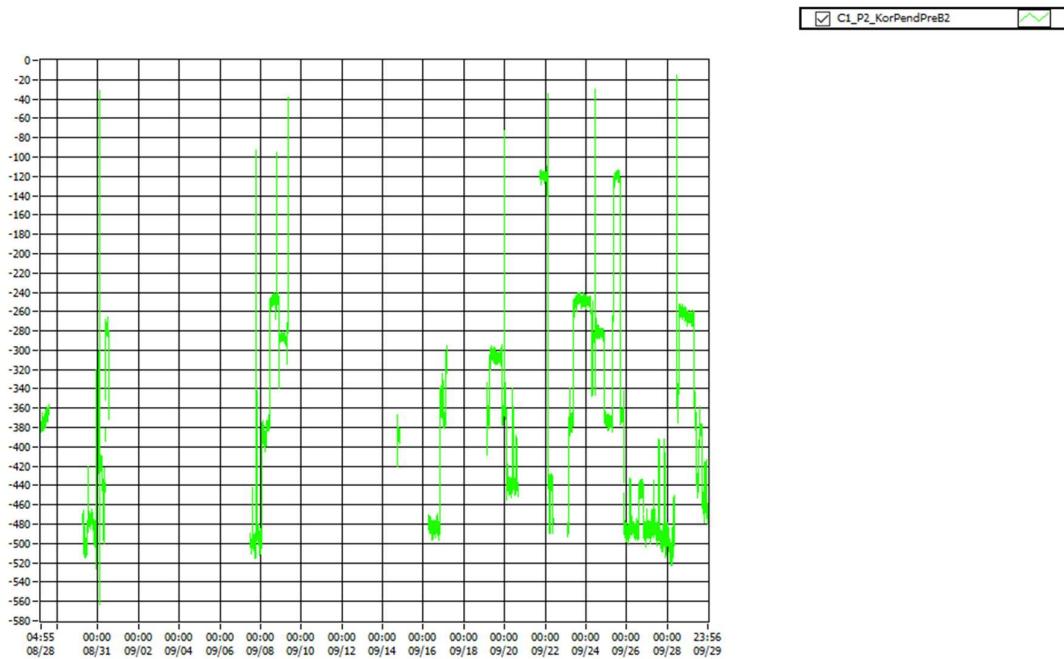
Slika 95. Vizuelni prikaz uticajnog parametra THB2D



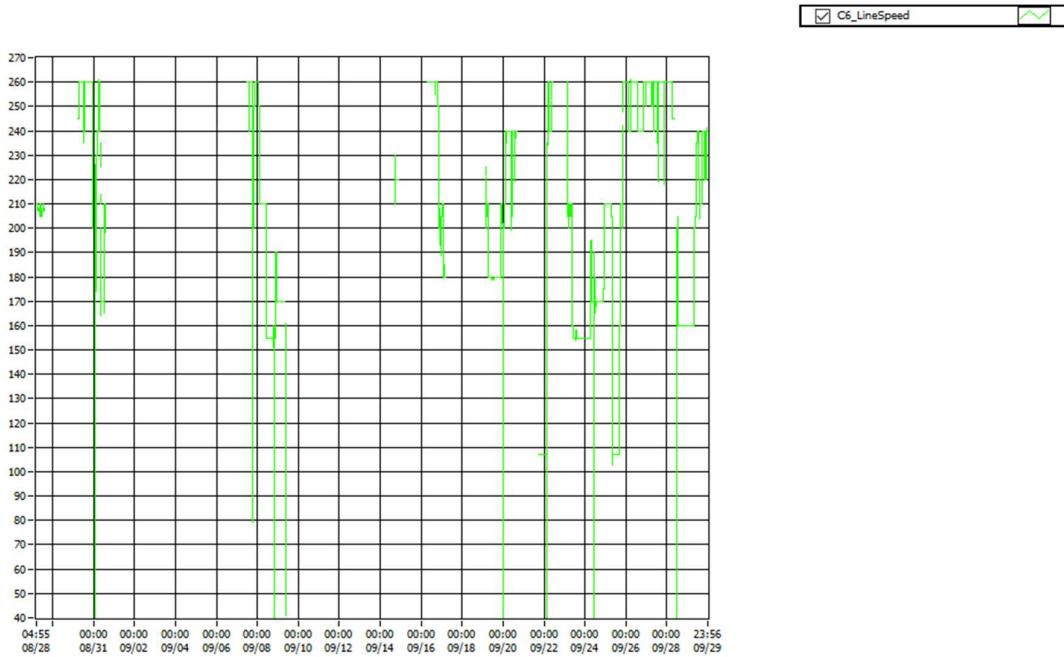
Slika 96. Vizuelni prikaz uticajnog parametra THB2G



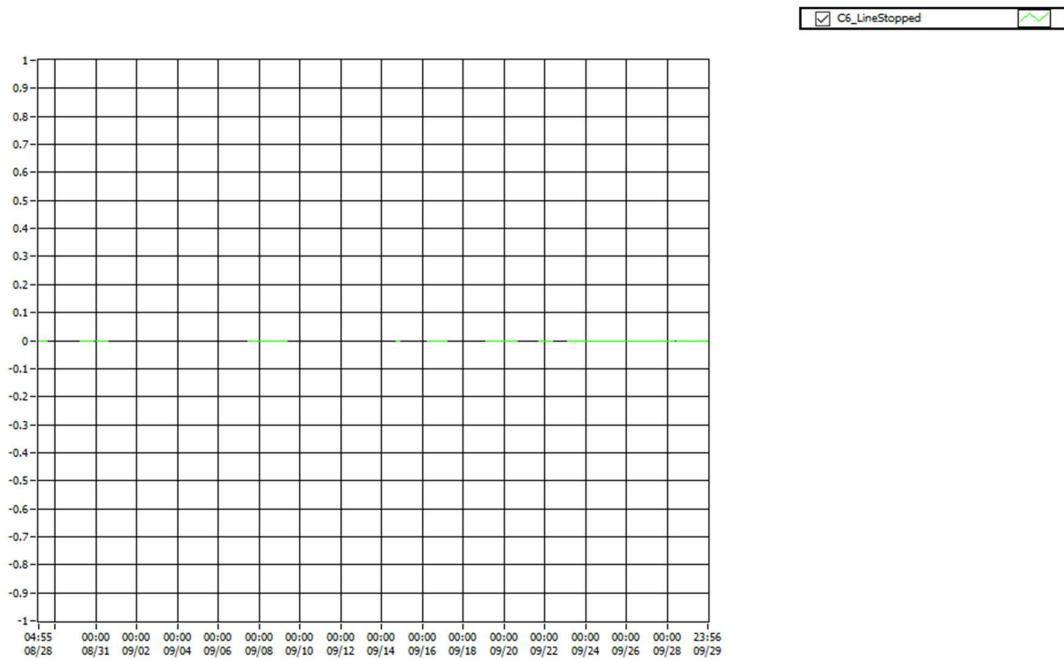
Slika 97. Vizuelni prikaz uticajnog parametra KorPendPosleB2



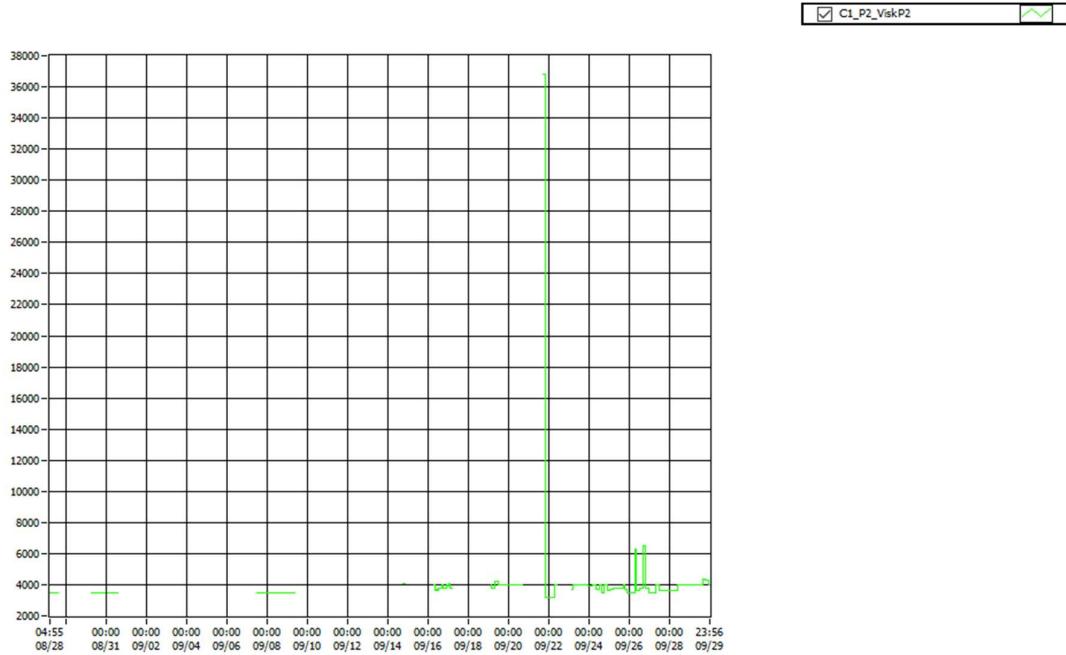
Slika 98. Vizuelni prikaz uticajnog parametra KorPendPreB2



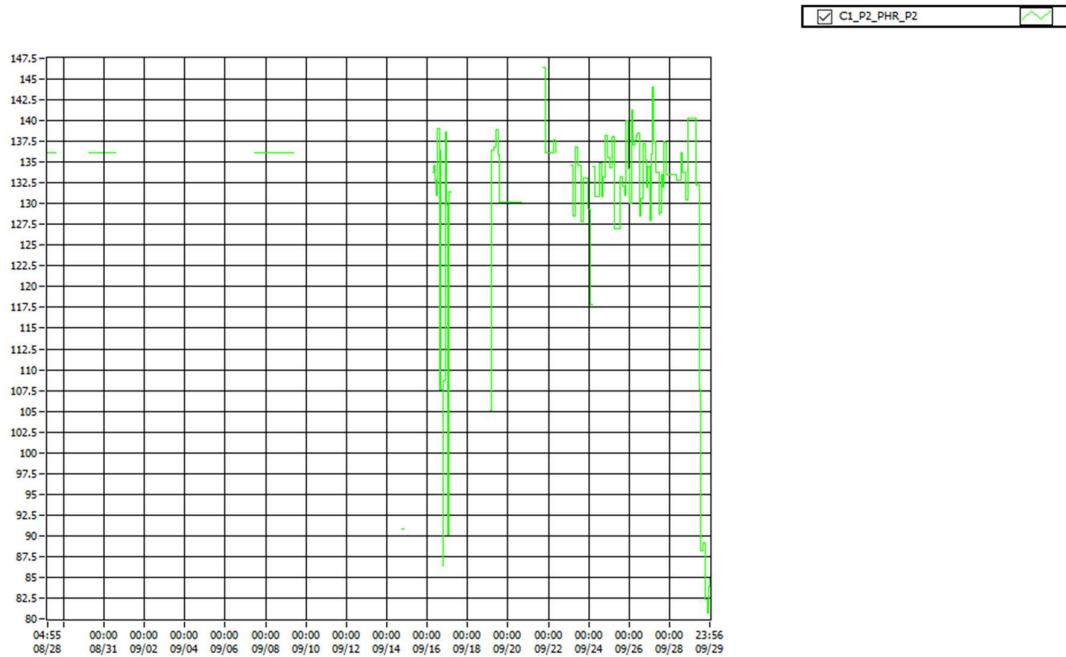
Slika 99. Vizuelni prikaz uticajnog parametra LineSpeed



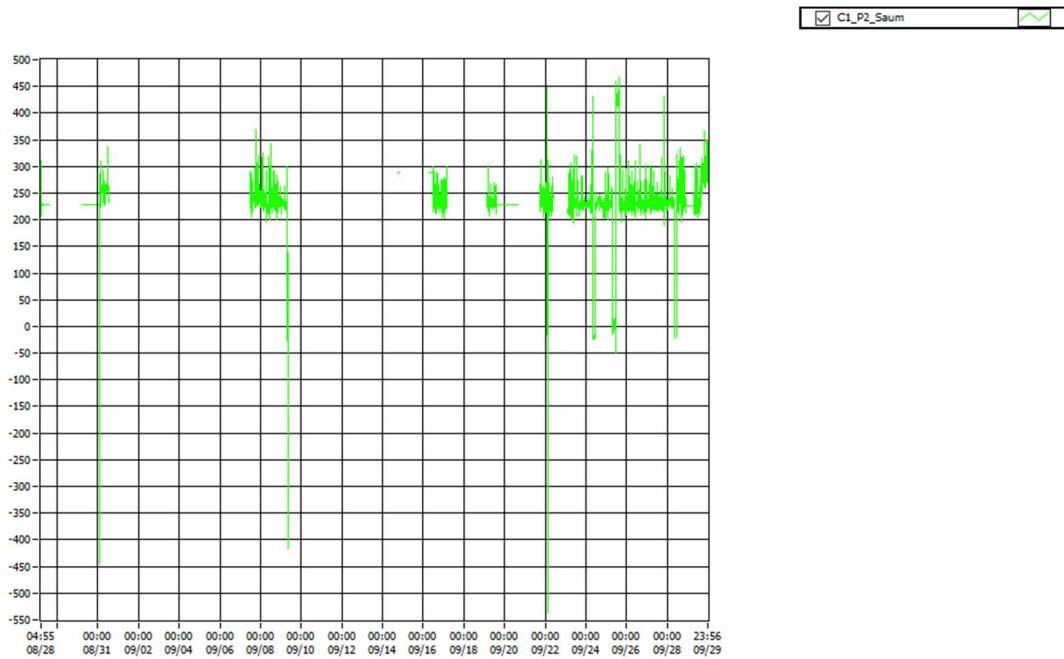
Slika 100. Vizuelni prikaz uticajnog parametra LineStopped



Slika 101. Vizuelni prikaz uticajnog parametra ViskP2



Slika 102. Vizuelni prikaz uticajnog parametra PHR_P2



Slika 103. Vizuelni prikaz uticajnog parametra Saum

Vizuelni prikaz prikupljenih podataka uticajnih procesnih parametara daje informaciju o njihovoj prirodi. Priroda podataka podrazumeva postojanje, odnosno nepostojanje, određenih neusaglašenosti od uobičajenih vrednosti procesnih parametara generisanih tokom proizvodnog procesa. **Na osnovu vizuelnog prikaza podataka ustanovljeno je u većini slučajeva da vrednosti prikupljenih podataka pružaju informaciju kada se u proizvodnom sistemu nisu javile greške kvaliteta finalnog proizvoda.** Stoga, prikupljeni podaci predstavljaju neizbalansiran skup podataka, koji sadrži pretežno „dobre“ podatke i jako mali broj „loših“ podataka koji pružaju informaciju o greškama kvaliteta. Prikupljeni neizbalansirani skup podataka je dalje pripremljen i obrađen u skladu sa koracima faze 4 - *Priprema i obrada prikupljenih podataka*. Svaki od definisanih koraka su detaljno predstavljeni u narednim potpoglavljima.

5.3.4.1. Eliminacija nedoslednih, konstantnih i podataka sa šumom

Eliminacija nedoslednih, konstantnih i podataka sa šumom izvršena je manuelno gde su pregledani svi .csv fajlovi prikupljeni u fazi 3 - *Identifikacija uticajnih parametara i prikupljanje podataka* - razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara. Razlog nastanka nedoslednih, konstantnih i podataka sa šumom tokom proizvodnog procesa jeste loše očitavanje stvarnih vrednosti parametara zbog prekida u komunikaciji između povezanih uređaja primenom OPC UA protokola ili netačnog očitavanja stvarnih vrednosti parametara primenom senzora.

U skladu sa definisanim korakom, uklonjeni su svi podaci koji imaju konstante i nedosledne vrednosti, gde je vršeno brisanje redova unutar skupa podataka (odnosno, unutar .csv fajla), ali isto tako eliminisani su i celi fajlovi gde je utvrđeno postojanje neodgovarajućih podataka. Eliminacija celih fajlova predstavlja kombinaciju brisanja i redova i kolona istovremeno zbog određenih defekata u prikupljenim podacima.

Nakon sprovedenog koraka eliminacije nedoslednih, konstantnih i podataka sa šumom, broj fajlova je smanjem sa 6.534 na **3.802 .csv fajla**. Važno je napomenuti da broj podataka unutar svakoj fajla nije ostao na predefinisanih 300 uzoraka usled eliminacije nedoslednih, konstantnih i podataka sa šumom. Na osnovu toga, konstatovano je da je nakon završenog koraka 1 - *Eliminacije nedoslednih, konstantnih i podataka sa šumom* preostalo ukupno **1.140.600 podataka**.

5.3.4.2. Dodavanje vrednosti nepotpunim podacima

Detaljnog vizuelnom analizom preostalih prikupljenih podataka je utvrđeno da ne postoje nepotpune vrednosti podataka. Iz tog razloga korak 2 - *Dodavanje vrednosti nepotpunim podacima* u okviru faze 3 RONP modela nije sproveden iz razloga što nije bilo potrebe za dodavanjem vrednosti nepotpunim podacima.

5.3.4.3. Redukcija broja prikupljenih procesnih parametara

Na osnovu verifikacije RONP modela u industrijskom okruženju, smanjenje dimenzionalnosti se vrši pomoću statističke tehnike korelace analize za smanjenje broja nezavisnih promenljivih na osnovu koreacionog koeficijenta, gde je na taj način izvršeno pojednostavljanje skupa podataka. Razlog zašto nije urađenja redukcija broja prikupljenih procesnih parametara nekom drugom statističkom tehnikom jeste taj što *rezultati dobijeni nizom urađenih eksperimenata nisu bili zadovoljavajući*.

Kriterijum za način primene korelace analize je sproveden na osnovu vrednosti koreacionog koeficijenta. Primenom ovog kriterijuma eliminisani su procesni parametri koji su dali vrednost koreacionog koeficijenta 0 u korelaciji sa samim sobom ili gde je vrednost koreacionog koeficijenta za dva procesna parametra prešla vrednosti 0,9.

Međutim, napravljen je izuzetak za procesni parametar *LineSpeed* (gde je vrednost koreacionog koeficijanta bila 0,971288) nakon analize dobijenih rezultat sa ekspertima iz posmatranog proizvodnog sistema gde je sprovedena primena modela u industrijskom okruženju. Razlog pravljenja izuzetka je taj što brzina proizvodne linije igra jako važnu ulogu prilikom nastanka grešaka kvaliteta, gde male promene u brzini mogu da dovedu do velikih defekata na finalnom proizvodu.

Nakon sprovedene korelaceione analize eliminisana su tri procesna parametra, i to:

- *Zazor_GV2_desna* – vrednost korelacionog koeficijenta sa samim sobom je bila 0,
- *Zazor_GV2_leva* – vrednost korelacionog koeficijenta sa samim sobom je bila 0,
- *LineStopped* – vrednost korelacionog koeficijenta sa samim sobom je bila 0 (ovaj parametar je služio kao okidač za modifikaciju u koraku 5 - *Prikupljanje podataka uticajnih parametara, faza 3 - Identifikacija uticajnih parametara i prikupljanje podataka*).

Stoga, **broj uticajnih procesnih parametara je redukovani sa 15 na 12** primenom korelaceione analize. Rezultati korelaceione analize su prikazani na slici 104.

	Multi trace statistic_C1_P2_Temperatura_GV2_Range	Multi trace statistic_C1_P2_Temperatura_B2_Range	Multi trace statistic_C1_P2_Temperatura_CV2_Range	Multi trace statistic_C1_P2_Temperatura_PB2_Range	Multi trace statistic_C1_P2_ThBD_Range	Multi trace statistic_C1_P2_ThBG_Range	Multi trace statistic_C1_P2_KorPendPoseB2_Range	Multi trace statistic_C1_P2_KorPendPrmB2_Range	Multi trace statistic_C6_LineSpeed_Range	Multi trace statistic_C1_P2_ViskP2_Range	Multi trace statistic_C1_P2_PHR_P2_Range	Multi trace statistic_C1_P2_K_Range	Multi trace statistic_C1_P2_L_Range
22556	1	1	0.153201	0.333453	1	0.187342	0.431982	1	0.295919	0.451173	0.394976	1	
29374	0.118427	0.129012	0.263182	0.117262	0.179784	0.356232	0.442451	0.798744	0.0868365	0.15314	0.109009	0.124219	0.124929
29375	0.0801241	0.157265	0.276058	0.112137	0.0801241	0.0801241	0.139981	0.121401	0.0264834	0.0728802	-0.0204107	-0.00851763	0.684095
37847	0.0264834	0.0189764	0.0189764	0.125461	0.0264834	0.00548988	-0.0250876	-0.0168413	0.0264834	-0.0066054	-0.0066054	-0.0130889	0.660196
37971	0.0250657	-0.0250876	-0.0250876	-0.0066054	-0.0066054	-0.00548988	-0.0130889	-0.000925564	-0.000925564	-0.000925564	-0.000925564	-0.00303652	0.971288

Slika 104. Rezultat korelaceione analize urađen pomoću Real-time Statistics Diagnosis Tool softvera, MELIPC MI5000

5.3.4.4. Definisanje zavisnog parametra

Zavisni parametar za posmatrani proizvodni sistem je definisan na osnovu određenog tipa problema u proizvodnom sistemu. Izlazna vrednost procesnih parametara je definisana u saradnji sa ekspertima iz posmatranog proizvodnog sistema i ima binarne vrednosti, iz razloga što je problem definisan kao klasifikacioni. Zavisni parametar ima definisanu vrednost 0 kada finalni proizvod nema defekte u vidu lošeg kvaliteta. Odnosno, zavisni parametar ima definisanu vrednost 1 kada finalni proizvod ima defekte u vidu lošeg kvaliteta. Generisanje zavisnog parametra je izvršeno u .csv formatu podataka.

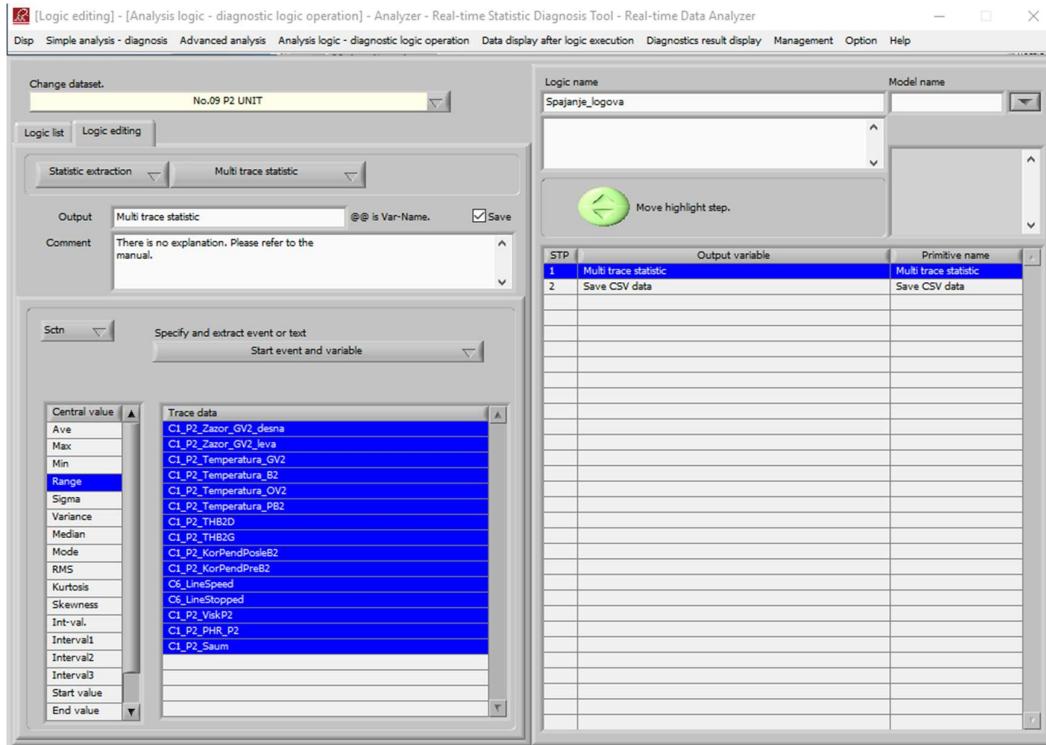
Za period prikupljanja podataka počev od 28. avgusta 2020. godine, pa sve do 29. septembra 2020. zabeleženo je da 5 finalnih proizvoda lošeg kvaliteta, na osnovu kojih je vrednost zavisnog parametra bila 1 (slika 105). Podaci o finalnim proizvodima lošeg kvaliteta su dobijeni tek nakon završenog proizvodnog procesa.

B	C	D	E	F	G	H	I	J	K	L	
1	Material group descrip	production_date	Na P2	Na Stampi	avev	length	Defect code	Masina	Gubitak	Klaster	14. Gub
22556	LEGEND 4.00	28-09-20 20:32	28-09-20 19:44	28-09-20 19:50	16	11.92 2L	Premazivanje 2	V14-PVC	1 1		
29374	DELTA 2,50	2020-09-16 11:13:28.087	2020-09-16 10:43:28.087	2020-09-16 10:47:28.087	26	30.48 2G	Premazivanje 2	V14-PVC	1 1		
29375	DELTA 2,50	16-09-20 11:12	16-09-20 10:42	16-09-20 10:46	26	30.03 2G	Premazivanje 2	V14-PVC	1 1		
37847	START 3,00	31-08-20 10:21	30-08-20 04:41	30-08-20 04:41	26	38 2F	Premazivanje 2	V14-PVC	1 1		
37971	START 3,00	30-08-20 19:48	30-08-20 19:18	30-08-20 19:22	26	12.54 2F	Premazivanje 2	V14-PVC	1 1		

Slika 105. Definisanje zavisnog parametra na osnovu informacija o lošem kvalitetu finalnog proizvoda u periodu od 28. avgusta do 29. septembra 2020. godine

5.3.4.5. Optimizacija i kreiranje precizno odabranog skupa podataka za razvoj matematičkog modela

Sprovodenjem koraka 5 - *Optimizacija i kreiranje precizno odabranog skupa podataka za razvoj matematičkog modela* izvršeno je optimizovanje prikupljenih podataka uticajnih nezavisnih procesnih parametara su korišćenjem statističke metode *Opseg*. Metoda *Opseg* predstavlja razliku između maksimalne i minimalne vrednosti unutar određenog skupa podataka (u ovom slučaju unutar .csv fajla). Korišćenjem metode *Opseg* svaki .csv fajl je analiziran nakon čega je dobijena vrednost razlike između maksimalnih i minimalnih vrednosti. Drugim rečima, pomoću metode *Opseg* urađena je optimizacija kako bi se 3.802 .csv fajlova sveli na jedan jedinstveni .csv fajl. Taj jedinstveni .csv fajl u sebi sadrži informacije o svih 3.802 .csv fajlova. Optimizacija je urađena primenom softvera *Real-time Statistic Diagnosis Tool*, što je prikazano na slici 106.



Slika 106. Optimizacija .csv fajlova korišćenjem statističke metode Opseg za kreiranje jednog jedinstvenog .csv fajla

Nakon optimizacije sprovedeno je manuelno povezivanje vrednosti prikupljenih procesnih parametara sa vrednostima zavisnog parametra, kako bi se kreirao precizno odabran skup podataka za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara.

5.3.4.6. Rezultati Faze 4

Rezultati faze 4 - *Priprema i obrada prikupljenih podataka za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara* predstavlja izlaznu informaciju nakon njenog završetka, odnosno nakon uspešnog sprovođenja svih njenih koraka, u vidu pripremljenog skupa podataka za razvoj modela. Rezultati faze 4 - *Priprema i obrada prikupljenih podataka* su prikazani u tabeli 20.

Tabela 20. Sumirani rezultati Faze 4

Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu		
Faza 4	Priprema i obrada prikupljenih podataka	
Napomena:	Na osnovu vizuelnog prikaza prikupljenih podataka ustanovljeno je da prikupljene vrednosti procesnih parametara predstavljaju <i>neizbalansiran skup podataka</i> , koji sadrži pretežno dobre podatke i jako mali broj loših podataka koji pružaju informaciju o greškama kvaliteta.	
RB	Korak	Rezultat
1.	Eliminacija nedoslednih, konstantnih i podataka sa šumom	Smanjen broj .csv fajla sa 6.534 na 3.802, gde broj podataka unutar svakoj fajl varira usled eliminacije nedoslednih, konstantnih i podataka sa šumom.
2.	Dodavanje vrednosti nepotpunim podacima	NIJE SPROVEDEN – ne postoje nepotpune vrednosti procesnih parametara.
3.	Redukcija broja prikupljenih procesnih parametara	Broj uticajnih procesnih parametara je redukovana sa 15 na 12 primenom korelace analize.
4.	Definisanje zavisnog parametra	Zavisni parametar je definišan i ima binarne vrednosti (0 označava dobar, a 1 označava nedovoljan kvalitet) generisan u .csv formatu. Broj zabeleženih grešaka kvaliteta je 4.
5.	Optimizacija i kreiranje precizno odabranog skupa podataka za razvoj matematičkog modela	Prikupljeni podaci uticajnih nezavisnih procesnih parametara su optimizovani koristeći statističku metodu <i>Opseg</i> kako bi se 3.802 .csv fajla sveli na jedan jedinstveni .csv fajl. Taj jedinstveni .csv fajl u sebi sadrži informacije o svih 3.802 .csv fajlova. Spajanje jedinstvenog csv. fajla sa generisanim .csv fajlom zavisnog parametra.

5.3.5. Faza 5: Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka

Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara je urađen na osnovu prikupljenih procesnih parametara odabranog proizvodnog sistema procesne industrije. S obziron na činjenicu da prikupljeni i obrađeni skup podataka predstavlja neizbalansiran skup podataka, ta informacija je predstavljala osnov za dalji tok razvoja matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara. Matematički model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu je razvijen primenom dve različite metode napredne analitike kako si se izvršila komparativna analiza dobijenih rezultata. Oprema korišćena za razvoj modela jeste:

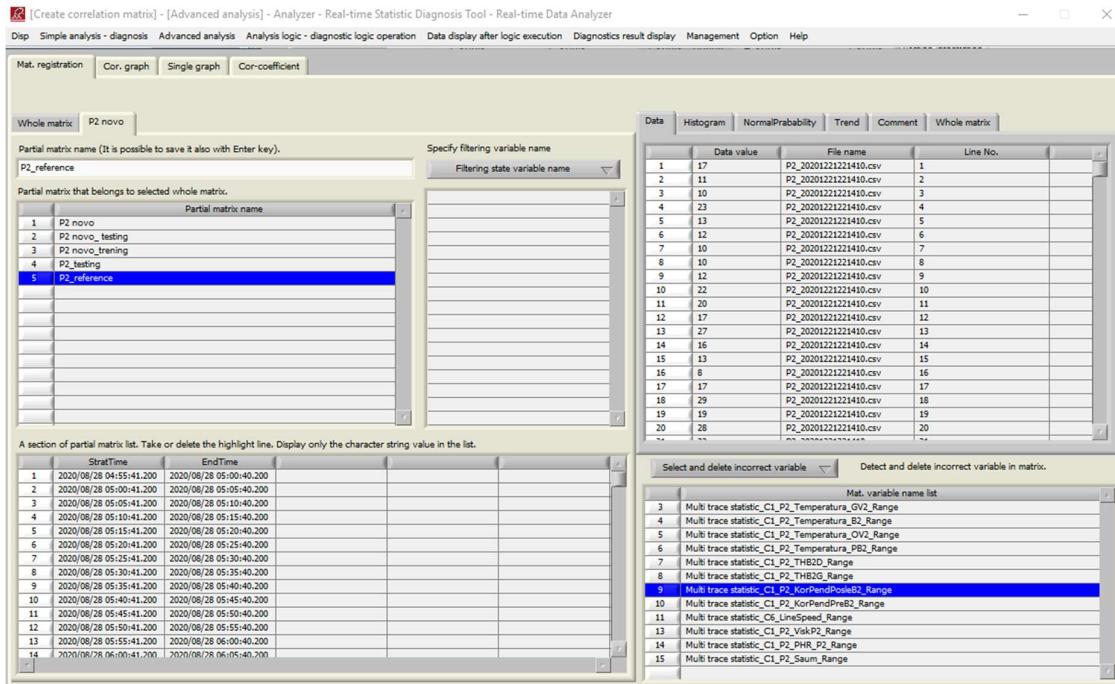
- industrijski računar MELIPC MI5000, zasnovanog na *Edge* sistemu računarske tehnologije primenom softvera *Real-time Statistics Diagnosis Tool*, i
- personalni računar sa operativnim sistemom *Windows® 10* primenom softvera *Jupyter Notebook* zasnovanog na programskom jeziku *Python*.

Rezultat uspešno završene faze 5 - *Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka* jeste matematički model razvijen praćenjem predefinisanih koraka, gde tačnost modela treba da iznosi preko 95%, kako bi se smatralo da model ima izuzetno visoku tačnost. Svaki od definisanih koraka su detaljno predstavljeni u narednim potpoglavljkima.

5.3.5.1. Metodologija za podelu izabrane grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela

Primenjena metodologija za podelu podataka na podatke za razvoj modela i podatke za testiranje matematičkog modela je odnos 80/20. Na osnovu toga pripremljen i obrađen skup izabrane grupe podataka je podeljen tako da se u izabranoj grupi podataka za razvoj modela nalazi 80% podataka, dok će se u skupu podataka za testiranje matematičkog modela nalazi 20%.

Prema tome, napravljenje su dve matrice sa podacima, nazvane: *P2_reference* i *P2_testing* (slika 107). Matrica *P2_reference* sadrži **3.042 podatka**, odnosno 80% od ukupnog broja prikupljenih podataka, i odnosi se na podatke potrebne za razvoj matematičkog modela. Matrica *P2_testing* sadrži preostalih 760 podataka, odnosno 20% od ukupnog broja prikupljenih podataka, i koristi se u narednoj fazi RONP modela, *Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara*.



Slika 107. Podela izabrane grupe podataka na podatke za razvoj modela i podatke za testiranje matematičkog modela primenom odnosa 80/20

5.3.5.2. Odabir metoda i tehnika za razvoj matematičkog RONP modela

Odabir metoda i tehnika napredne analitike za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara urađen je na osnovu definisanog zavisnog parametra i njegovih binarnih vrednosti (gde 0 označava dobar, a 1 označava loš kvalitet finalnog proizvoda). Prema konceptualnom RONP modelu (slika 34) izvršena je komparativna analiza dobijenih rezultata odabranih metoda napredne analitike. Komparativna analiza je urađena na osnovu poređenja dobijenih rezultata gde su korišćene tehnike napredne statističke metode i tehnike mašinskog učenja.

Odabrana tehnika napredne statističke metode je Mahalanobis-Taguči sistem iz razloga što je definisan zavisni parametar sadrži binarni tip podataka, sa jedne strane, dok neizbalansiranost prikupljenog skupa podataka potvrđuje potrebu za korišćenjem ove tehnike sa druge strane.

Tehnika mašinskog učenja koja je ekvivalentna MTS tehnički napredne statističke metode jeste OCSVM koja je upravo iz tog razloga i izabrana kako bi se razvio matematički model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu.

5.3.5.3. Razvoj matematičkog modela u proizvodnim sistemima pomoću izabrane grupe podataka za razvoj modela i primenom izabrane metode i tehnike napredne analitike

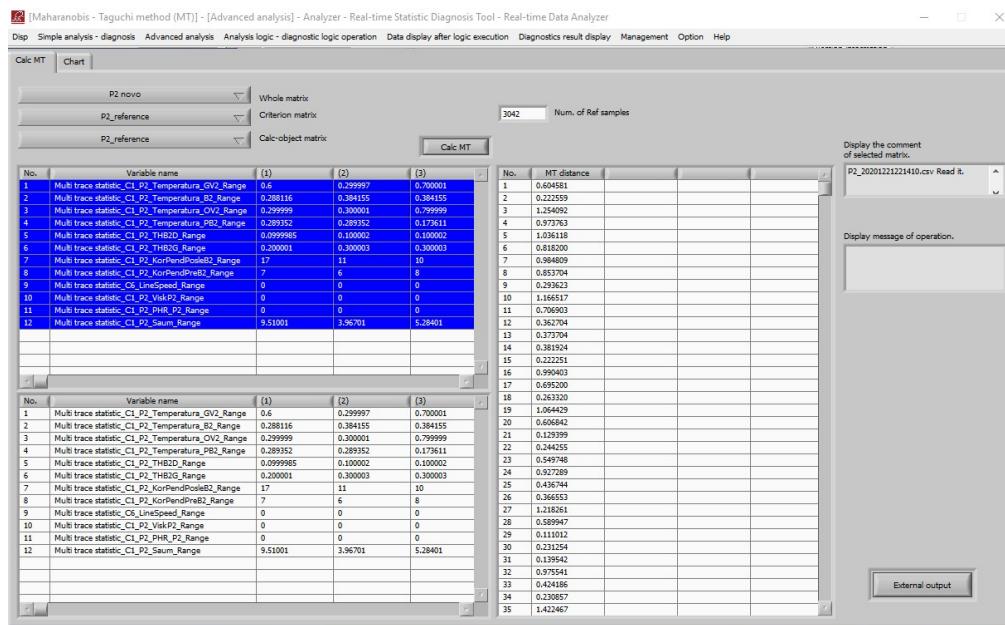
Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu procesne industrije urađen je na dva načina, i to primenom:

- napredne statističke metode koristeći tehniku MTS, i
- metode mašinskog učenja koristeći tehniku OCSVM.

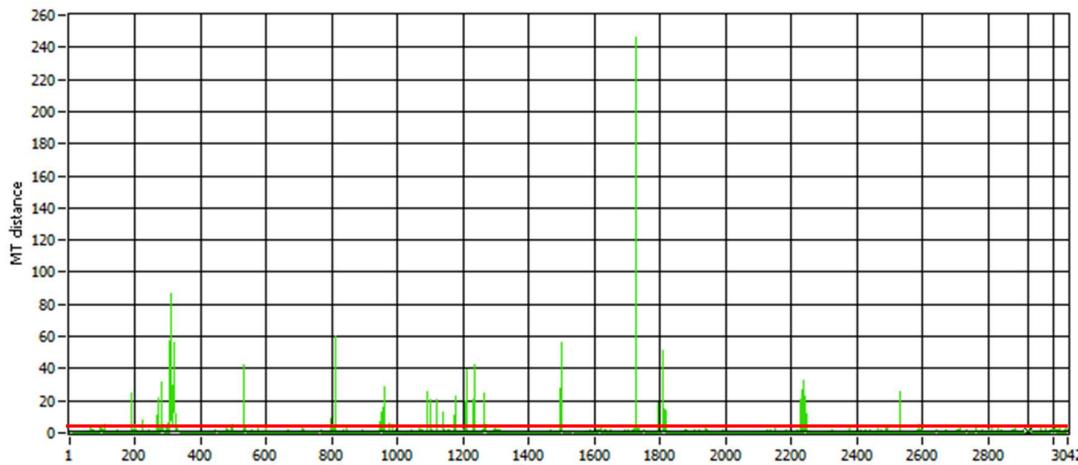
5.3.5.3.1. Razvoj matematičkog RONP modela primenom MTS tehnike napredne statističke metode

Prvi način razvoja matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara urađen je korišćenjem softverskog rešenja *Real-time Statistic Diagnosis Tool* za primenu MTS tehnike napredne statističke metode. Za razvoj matematičkog modela korišćena su 3.042 podataka, prikupljena i obrađena u fazama 2-4 za razvoj RONP, koji predstavljaju referentne vrednosti.

Na slici 108 se vide rezultati Mahalanobisove udaljenosti razvijenog modela, gde je definisana granica postavljena na 4, dok je vizuelizacija dobijenih rezultata prikazana na slici 109. Na osnovu definisane granice dobijena je tačnost modela od **97,21%**. Dobijena tačnost predstavlja izuzetno visoku tačnost modela kao indikator rada razvijenog matematičkog modela primenom MTS tehnike.



Slika 108. Rezultati Mahalanobisove udaljenosti razvijenog matematičkog RONP modela primenom MTS tehnike napredne statističke metode



Slika 109. Vizuelni prikaz rezultata Mahalanobisove udaljenosti razvijenog matematičkog RONP modela primenom MTS tehnike napredne statističke metode

5.3.5.3.2. Razvoj matematičkog RONP modela primenom OCSVM tehnike mašinskog učenja

Za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara na osnovu OCSVM tehnike mašinskog učenja korišćeno je softversko rešenje *Jupyter Notebook* korišćenjem programskog jezika *Python* (slika 110). Prilikom razvoja matematičkog modela korišćena su 3.042 podataka, odnosno korišćeni su isti podaci kao i za razvoj matematičkog modela primenom MTS tehnike kako bi kasnija komparacija matematičkih modela bila validna.

Na osnovu razvijenog matematičkog modela primenom OCSVM tehnike mašinskog učenja dobijena je tačnost modela od **97,07%** gde je frakcija između gornje i donje granice podešena na vrednost 0,03, dok je gama vrednost podešena na 0,01. Dobijena tačnost predstavlja izuzetno visoku tačnost modela kao indikator rada razvijenog matematičkog modela primenom OCSVM tehnike.

```
In [1]: %matplotlib inline
import numpy as np
import pandas as pd
from sklearn import utils
import matplotlib

data = pd.read_csv(r"F:\Doktorat\Doktorska disertacija\12. eksperiment 28.08-28.09\P2\Novi model - izbaceni logovi\P2_20201221.csv")

In [2]: data.loc[data['output'] == "normal.", "output"] = 0
data.loc[data['output'] != "normal.", "output"] = 1

target = data['output']

outliers = target[target == 1]
print("outliers.shape", outliers.shape)
print("outlier fraction", outliers.shape[0]/target.shape[0])

data.drop(["output", "output"], axis=1, inplace=True)

data.shape

outliers.shape (3802,)
outlier fraction 1.0

Out[2]: (3802, 12)

In [3]: from sklearn.model_selection import train_test_split
train_data, test_data, train_target, test_target = train_test_split(data, target, train_size = 0.8002)
train_data = pd.read_csv(r"F:\Doktorat\Doktorska disertacija\12. eksperiment 28.08-28.09\P2\Novi model - izbaceni logovi\P2_20201221.csv")
train_data.shape

Out[3]: (3042, 13)

In [4]: from sklearn import svm

model = svm.OneClassSVM(nu=0.03, kernel='rbf', gamma=0.001)
model.fit(train_data)

Out[4]: OneClassSVM(gamma=0.001, nu=0.03)

In [5]: from sklearn import metrics
preds = model.predict(train_data)
targs = train_target
print("accuracy: ", metrics.accuracy_score(targs, preds))

accuracy: 0.9707429322813939
```

Slika 110. Rezultat razvijenog matematičkog RONP modela primenom OCSVM tehnike mašinskog učenja sa prikazom definisanih parametara

5.3.5.4. Rezultati Faze 5

Rezultati faze 5 - *Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka* predstavlja izlaznu informaciju nakon njenog završetka, odnosno nakon uspešnog sprovođenja svih njenih koraka, u vidu pripremljenog skupa podataka za razvoj matematičkog modela. Rezultati faze 5 - *Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka* su prikazani u tabeli 21.

Tabela 21. Sumirani rezultati Faze 5

<i>Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu</i>			
<i>Faza 5</i>	<i>Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka</i>		
<i>RB</i>	<i>Korak</i>	<i>Rezultat</i>	
1.	Metodologija za podelu izabrane grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje matematičkog modela	Podaci su podeljeni na osnovu odnosa 80/20, gde podaci za razvoj matematičkog modela sadrže 80% od ukupnog broja podataka, tačnije 3.042 podatka.	
2.	Odabir metoda i tehnika za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara	Napredna statistička metoda:	MTS
		Metoda mašinskog učenja:	OCSVM
3.	Razvoj matematičkog modela u proizvodnim sistemima pomoću izabrane grupe podataka za razvoj modela i primenom izabrane metode i tehnike napredne analitike	<i>Tačnost razvijenog matematičkog modela</i>	
		MTS	97,21%
		OCSVM	97,07%

5.3.6. Faza 6: Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara

Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara je urađeno u odabranom proizvodnom sistemu procesne industrije. Skup podataka korišćen za testiranje razvijenog matematičkog modela podeljen je na osnovu odnosa 80/20 i sadrži 20% podataka od ukupnog broja prikupljenih i obrađenih podataka.

Matematički model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu je testiran primenom dve različite metode napredne analitike pomoću kojih su i razvijeni matematički modeli kako si se izvršila komparativna analiza dobijenih rezultata. Oprema korišćena za testiranje matematičkog modela jeste:

- industrijski računar MELIPC MI5000, zasnovanog na *Edge* sistemu računarske tehnologije primenom softvera *Real-time Statistics Diagnosis Tool*, i
- personalni računar sa operativnim sistemom *Windows*® primenom softvera *Jupyter Notebook* zasnovanog na programskom jeziku *Python*.

Rezultat završene faze 6 - *Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* nakon urađenih svih definisanih koraka (predstavljeni u narednim potpoglavlјima) jeste testiran matematički model sa tačnošću preko 95% gde je izvršena komparativna analiza dobijenih rezultata. Testirani matematički model koji je dao bolje rezultate izabran je kao referentni model spreman za validaciju u odabranom proizvodnom sistemu na osnovu kojeg je primenjen model u industrijskom okruženju u trenutku generisanja podataka tokom proizvodnog procesa.

5.3.6.1. *Testiranje matematičkog modela pomoću podataka za testiranje*

Skup podataka korišćen za testiranje matematičkog modela podeljen je na osnovu odnosa 80/20 (poglavlje 5.3.6.) gde se u skupu podataka za testiranje matematičkog modela nalazi 20% podataka od ukupnog broja prikupljenih i obrađenih podataka. Odnosno, za testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara korišćeno je **760 podataka**, sačuvanih u matrici *P2_testing*.

5.3.6.2. *Procena performansi matematičkog RONP modela primenom tehnika testiranja*

Procena performansi matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara razmatrane su tehnike za procenu performansi razvijenog modela na osnovu definisanog klasifikacionog problema. Korišćene tehnike za procenu performansi matematičkog modela zasnovanih na klasifikacionim problemima jesu *tačnosti* i *greška* modela. Takođe, pored određivanja *tačnosti* i *greške* matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemima, na osnovu matrice konfuzije izvršeno je i određivanje *odziva* i *preciznosti* testiranog modela.

U nastavku su prikazani rezultati performansi matematičkog modela razvijenog primenom MTS tehnike, kao i rezultati performansi matematičkog modela razvijenog primenom OCSVM.

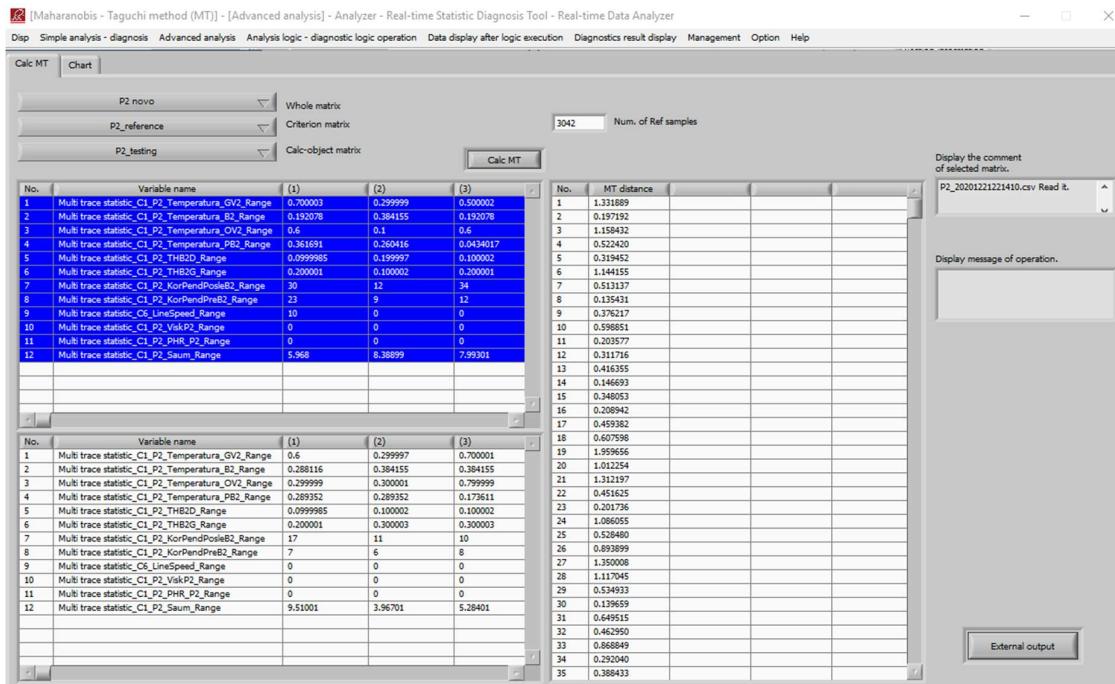
5.3.6.2.1. *Procena performansi matematičkog RONP modela razvijenog primenom MTS tehnike napredne statističke metode*

Na osnovu matrice konfuzije (tabela 22) prema definisanom eksperimentu u industrijskom okruženju, tačnost testiranog matematičkog modela razvijenog primenom MTS tehnike napredne statističke metode iznosi 98,29%, dok greška iznosi 1,71%. Na slici 111 se vide rezultati Mahalanobisove udaljenosti testiranog matematičkog modela, gde je definisana granica postavljena na 4. Na slici 112 je vizuelno prikazano odstupanje od definisane granične vrednosti Mahalanobisove udaljenosti.

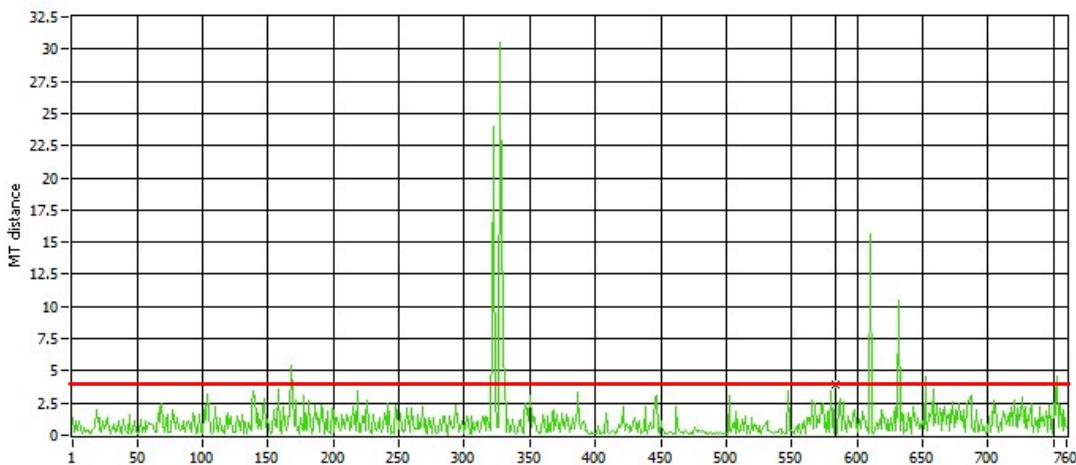
Tabela 22. Matrica konfuzije dobijena na osnovu rezultatata testiranog matematičkog RONP modela primenom MTS tehnike

MATRICA KONFUZIJE		STVARNE VREDNOSTI	
PREDVIĐENE VREDNOSTI		Negativni podaci	Pozitivni podaci
	Negativni podaci	0	12
	Pozitivni podaci	1	747

Takođe, na osnovu matrice konfuzije (tabela 22) odziv testiranog matematičkog modela razvijenog primenom MTS tehnike napredne statističke metode iznosi 98,41%, dok njegova preciznost iznosi 99,87%. Zbog praktične primenljivosti matematičkog modela korišćenjem MTS tehnike izračunata je *F1 mera* čija vrednost iznosi 99,13%. Važno je napomenuti da su svi prethodno definisani parametri razvoja matematičkog modela (potpoglavlje 5.3.5.3.1.) primenom MTS ostali nepromenjeni prilikom njegovog testiranja.



Slika 111. Rezultati Mahalanobisove udaljenosti testiranog matematičkog RONP modela primenom MTS tehnike napredne statističke metode



Slika 112. Vizuelni prikaz odstupanja analiziranih vrednosti od definisane granične vrednosti Mahalanobisove udaljenosti postavljenje na 4

5.3.6.2.2. Procena performansi matematičkog RONP modela razvijenog primenom OCSVM tehnike mašinskog učenja

Prema definisanom eksperimentu, na osnovu matrice konfuzije (tabela 23), tačnost testiranog matematičkog modela primenom OCSVM tehnike mašinskog učenja iznosi 96,32%, dok greška iznosi 3,68% (slika 113). Odziv testiranog matematičkog modela razvijenog primenom OCSVM tehnike mašinskog učenja iznosi 96,32%, dok njegova preciznost iznosi 100% (slika 111).

Zbog praktične primenljivosti matematičkog modela korišćenjem OCSVM tehnike izračunata je *F1 mera* čija vrednost iznosi 98,12%. Važno je napomenuti da su svi prethodno definisani parametri razvoja matematičkog modela (potpoglavlje 5.3.5.3.2.) primenom OCSVM ostali nepromenjeni kod njegovog testiranja.

Tabela 23. Matrica konfuzije dobijena na osnovu rezultata testiranog matematičkog RONP modela primenom OCSVM tehnike

MATRICA KONFUZIJE		STVARNE VREDNOSTI	
PREDVIĐENE VREDNOSTI		<i>Negativni podaci</i>	<i>Pozitivni podaci</i>
	<i>Negativni podaci</i>	0	0
	<i>Pozitivni podaci</i>	28	732

```
In [1]: %matplotlib inline
import numpy as np
import pandas as pd
from sklearn import utils
import matplotlib

data = pd.read_csv(r"F:\Doktorat\Doktorska disertacija\12. eksperiment 28.08-28.09\P2\Novi model - izbaceni logovi\P2_20201221.csv")

In [2]: data.loc[data['output'] == "normal.", "output"] = 0
data.loc[data['output'] != "normal.", "output"] = 1

target = data['output']

outliers = target[target == 1]
print("outliers.shape", outliers.shape)
print("outlier fraction", outliers.shape[0]/target.shape[0])

data.drop(["output", "output"], axis=1, inplace=True)

data.shape

outliers.shape (3802,)
outlier fraction 1.0

Out[2]: (3802, 12)

In [3]: from sklearn.model_selection import train_test_split
train_data, test_data, train_target, test_target = train_test_split(data, target, train_size = 0.8002)
train_data = pd.read_csv(r"F:\Doktorat\Doktorska disertacija\12. eksperiment 28.08-28.09\P2\Novi model - izbaceni logovi\P2_20201221.csv")
train_data.shape

Out[3]: (3042, 13)

In [4]: from sklearn import svm

model = svm.OneClassSVM(nu=0.03, kernel='rbf', gamma=0.001)
model.fit(train_data)

Out[4]: OneClassSVM(gamma=0.001, nu=0.03)

In [5]: from sklearn import metrics
preds = model.predict(train_data)
targs = train_target
print("accuracy: ", metrics.accuracy_score(targs, preds))

accuracy:  0.9707429322813939

In [6]: test_data = pd.read_csv(r"F:\Doktorat\Doktorska disertacija\12. eksperiment 28.08-28.09\P2\Novi model - izbaceni logovi\P2_20201221.csv")
test_data.shape

Out[6]: (760, 13)

In [7]: preds = model.predict(test_data)
targs = test_target
print("accuracy: ", metrics.accuracy_score(targs, preds))
print("precision: ", metrics.precision_score(targs, preds))
print("recall: ", metrics.recall_score(targs, preds))
print("f1 score: ", metrics.f1_score(targs, preds))

accuracy:  0.9631578947368421
precision:  1.0
recall:  0.9631578947368421
f1 score:  0.9812332439678284
```

Slika 113. Rezultat testiranog matematičkog RONP modela primenom OCSVM tehnike mašinsnog učenja sa prikazom definisanih parametara

5.3.6.3. Analiza dobijenih rezultata matematičkog RONP modela

Analiza dobijenih rezultata razvijenog i testiranog matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara je urađena komparativnom metodom gde su u tabeli 23 prikazani rezultati faza 5 i 6.

Na osnovu komparacije rezultata prikazanih u tabeli 24 jasno je da je matematički model razvijen pomoću MTS tehnike napredne statistike za nijansu nadmašio performanse matematičkog modela razvijenog primenom OCSVM tehnike mašinskog učenja kod tačnosti, greške i odziva. Što se tiče rezultata preciznosti, matematički model razvijen pomoću OCSVM tehnike je pokazao bolji rezultat. Prilikom odabira matematičkog modela koji će se koristiti u fazi 7 - *Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* uzeta je u obzir činjenica da se RONP model validira u industrijskom okruženju.

Tabela 24. Komparativna analiza rezultata razvijenog i testiranog matematičkog RONP modela u proizvodnom sistemu

Faza	Analiza	Napredne analitičke metode	
		Napredna statistika	Mašinsko učenje
		MTS	OCSVM
5: Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka	Tačnost	97,21%	97,07%
6: Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara	Tačnost	98,29%	96,32%
	Greška	1,71%	3,68%
	Odziv	98,41%	96,32%
	Preciznost	99,87%	100%
	F1 mera	99,13%	98,12%

Stoga, bilo je neophodno poređenje i *F1 mere* za oba matematička modela. Poređenjem F1 mere, kao mere izbalansiranosti preciznosti i odziva, matematički model razvijen primenom MTS tehnike je pokazao bolji rezultat. Stoga, *model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu razvijen primenom MTS je implementiran u posmatranom proizvodnom sistemu gde se prate njegove performanse u trenututku prikupljanja podataka.*

5.3.6.4. Rezultati Faze 6

Rezultati faze 6 - *Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* predstavlja izlaznu informaciju nakon njenog završetka, odnosno nakon uspešnog sprovođenja svih njenih koraka, u vidu testiranog modela spremnog za validaciju u odabranom proizvodnom sistemu. Rezultati faze 6 - *Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara* su prikazani u tabeli 25.

Tabela 25. Sumirani rezultati Faze 6

Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu

<i>Faza 6 Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara</i>							
<i>RB</i>	<i>Korak</i>	<i>Rezultat</i>					
1.	Testiranje matematičkog modela pomoću podataka za testiranje	Podaci su podeljeni na osnovu odnosa 80/20, gde podaci za testiranje matematičkog modela sadrže 20% od ukupnog broja podataka, tačnije 760 podataka.					
2.	Procena performansi matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara primenom tehnika testiranja		<i>Tačnost</i>	<i>Greška</i>	<i>Odziv</i>	<i>Preciznost</i>	<i>F1 mera</i>
		MTS	98,29%	1,71%	98,41%	99,87%	99,13%
3.	Analiza dobijenih rezultata matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara	OCSVM	96,32%	3,68%	96,32%	100%	98,12%
		Komparativna analiza dobijenih rezultata je pokazala da je matematički model razvijen primenom MTS nadmašio performanse modela razvijenog primenom OCSVM. Matematički model razvijen primenom MTS tehnike napredne statistike je odabran za validaciju u posmatranom proizvodnom sistemu.					

5.3.7. Faza 7: Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu

Prema fazama RONP modela odlučeno je da se validacija razvijenog modela vrši primenom **Mahalanobis-Tagući** tehnike napredne statističke metode u posmatranom proizvodnom sistemu. Validacija matematičkog RONP modela u industrijskom okruženju posmatranog proizvodnog sistema se primenjuje za definisanu grupu proizvoda, gde je cilj

detekcija nedovoljno dobrog kvaliteta proizvoda nastalog na osnovu neusaglašenosti procesih parametara. Detekcija je izvršena određivanjem:

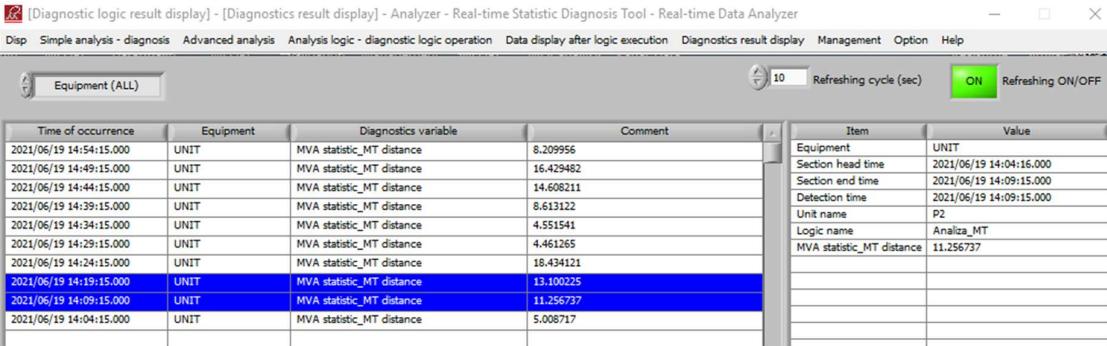
- **opreme koja se koristila:**
 - hardver – MELIPC MI5000 industrijski računar zasnovan na Edge sistemu računarske tehnologije;
 - programabilni logički kontroleri – PLC;
 - softver za detekciju odstupanja od definisane granice Mahalanobisove udaljenosti – *Real-time Statistic Diagnosis Tool*;
 - softver za slanje povratne informacije nazad u proizvodni sistem – *Real-time Flow Designer*;
 - softver za prikupljanje podataka sa senzora i instrumenata lociranih na udaljenim stanicama i za prenos i prikazivanje tih podata – SCADA;
- **perioda validacije u okviru kojeg će se pratiti rad RONP modela:**
 - 19. jun 2021, od 09:00 do 21:00 časa je praćeno da li su se javila obaveštenja o prelasku definisane granice razvijenog modela za rano otkrivanje neusaglašenosti procesnih parametara; kao rezultat dobijenih obaveštenja vrši se provera o nastalim greškama kvaliteta na odabranoj grupi proizvoda u posmatranom proizvodnom sistemu. Tokom definisanog perioda validacije generisani broj podataka iznosi 145 .csv fajlova sa po 300 podataka za svaki uticajni procesni parametar. Dakle validacija matematičkog modela je urađena na 43.500 procesnih podataka.

5.3.7.1. *Rano otkrivanje neusaglašenosti procesnih parametara primenom Edge sistema računarske tehnologije i procena performansi validiranog modela primenom MTS tehnike napredne statističke metode*

Rano otkrivanje neusaglašenosti procesnih parametara je sprovedeno pomoću *Edge* sistema računarske tehnologije primenom razvijenog matematičkog modela korišćenjem MTS tehnike napredne statističke metode na osnovu definisane granice Mahalanobisove udaljenosti. Na osnovu toga, korišćenjem softvera *Real-time Statistic Diagnosis Tool* je izvršeno detektovanje odstupanja definisane granice Mahalanobisove udaljenosti u odnosu na referentnu vrednost koja je postavljena na 4. Drugim rečima, softver beleži neusaglašenost procesnih parametara primenom matematičkog modela koja dovodi do prekoračenja definisane granice Mahalanobisove udaljenosti, što uslovjava nastanak proizvoda lošeg ili nedovoljno dobrog kvaliteta.

Procena performansi za validaciju matematičkog modela za rano otkrivanje neusaglašenosti procensih parametara je sprovedena na generisanom sirovom skupu podataka. To znači da generisani skup podataka nije prethodno pripremljen niti obrađen. Validacija u industrijskom okruženju posmatranog proizvodnog sistema je urađena na generisаних 145 .csv fajlova sa po 300 podataka za svaki uticajni procesni parametar, gde je izvršeno praćenje proizvodnog sistema u periodu od 12 sati.

Na osnovu toga, model je detektovao 44 neusaglašenosti procesih parametara. Neke od detektovanih grešaka su prikazane na slici 114. Svaka detektovana neusaglašenost procesnih parametara obuhvata vremenski interval od 5 minuta, što dalje implicira da rano otkrivanje neusaglašenosti odgovara vremenu tačnog trenutka generisanja podataka, odnosno trenutku generisanja .csv fajla.

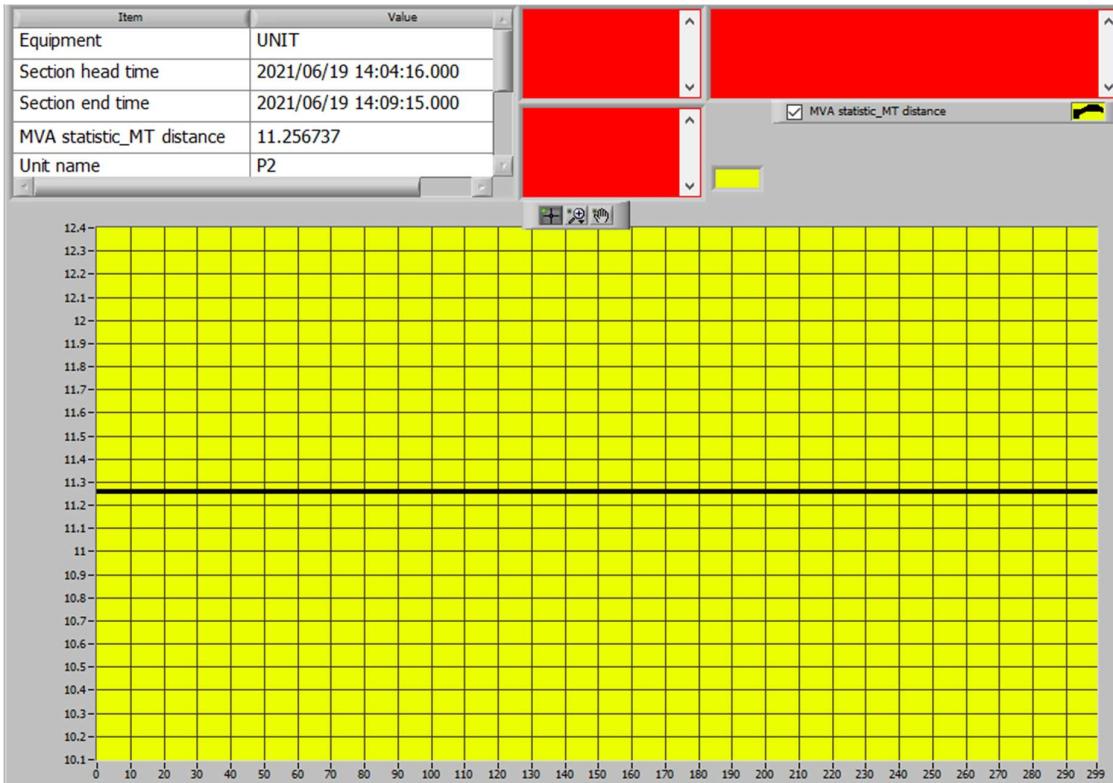


The screenshot shows a software window titled '[Diagnostic logic result display] - [Diagnostics result display] - Analyzer - Real-time Statistic Diagnosis Tool - Real-time Data Analyzer'. The main area displays a table of detected anomalies. The columns are: Time of occurrence, Equipment, Diagnostics variable, Comment, Item, and Value. The table contains 14 rows of data. The last three rows, which are highlighted with a blue selection bar, represent the anomalies shown in the caption. The 'Comment' column for these rows shows '13.100225', '11.256737', and '5.008717' respectively. The 'Value' column shows '11.256737' for all three rows.

Time of occurrence	Equipment	Diagnostics variable	Comment	Item	Value
2021/06/19 14:54:15.000	UNIT	MVA statistic_MT distance	8.209956	Equipment	UNIT
2021/06/19 14:49:15.000	UNIT	MVA statistic_MT distance	16.429482	Section head time	2021/06/19 14:04:16.000
2021/06/19 14:44:15.000	UNIT	MVA statistic_MT distance	14.608211	Section end time	2021/06/19 14:09:15.000
2021/06/19 14:39:15.000	UNIT	MVA statistic_MT distance	8.613122	Detection time	2021/06/19 14:09:15.000
2021/06/19 14:34:15.000	UNIT	MVA statistic_MT distance	4.551541	Unit name	P2
2021/06/19 14:29:15.000	UNIT	MVA statistic_MT distance	4.461265	Logic name	Analiza_MT
2021/06/19 14:24:15.000	UNIT	MVA statistic_MT distance	18.434121	MVA statistic_MT distance	11.256737
2021/06/19 14:19:15.000	UNIT	MVA statistic_MT distance	13.100225		
2021/06/19 14:09:15.000	UNIT	MVA statistic_MT distance	11.256737		
2021/06/19 14:04:15.000	UNIT	MVA statistic_MT distance	5.008717		

Slika 114. Detektovane neusaglašenosti procesih parametara primenom razvijenog modela MTS tehnike napredne statističke metode

Detektovanje neusaglašenosti procesnih parametara je prikazano u vidu iskakajućeg prozora na računaru u trenutku generisanja svakog pojedinačnog .csv fajla (slika 115) koje je praćeno i zvučnim signalom. Iskakajući prozor i zvučni signal predstavljaju upozorenje da treba da se obrati pažnja na rano otkrivanje nastanka neusaglašenosti procesnih parametara što dovodi do nastanka proizvoda lošeg i nedovoljno dobrog kvaliteta, te je potrebno da se u skladu sa tim i proaktivno reaguje.



Slika 115. Iskakajući prozor kao upozorenje o ranoj neusaglašenosti procesnih parametara odgovornih za nastanak proizvoda lošeg i nedovoljno dobrog kvaliteta

Nakon što je završen definisani period validacije od 12 sati, izvršena je i analiza proizvoda koji su u datom vremenskom periodu izašli sa proizvodne linije. Analiza je pokazala da su registrovana dva proizvoda lošeg ili nedovoljno dobrog kvaliteta koji su se dogodili na definisanoj lokaciji proizvodne linije, odnosno na mašini P2. Na slici 116 je prikazana tabela sa označenim proizvodima lošeg ili nedovoljno dobrog kvaliteta koji su se pojavili u periodu kada je rađena validacija matematičkog modela. Na osnovu toga se zaključuje da je matematički model prepoznao nastale proizvode lošeg ili nedovoljno dobrog kvaliteta.

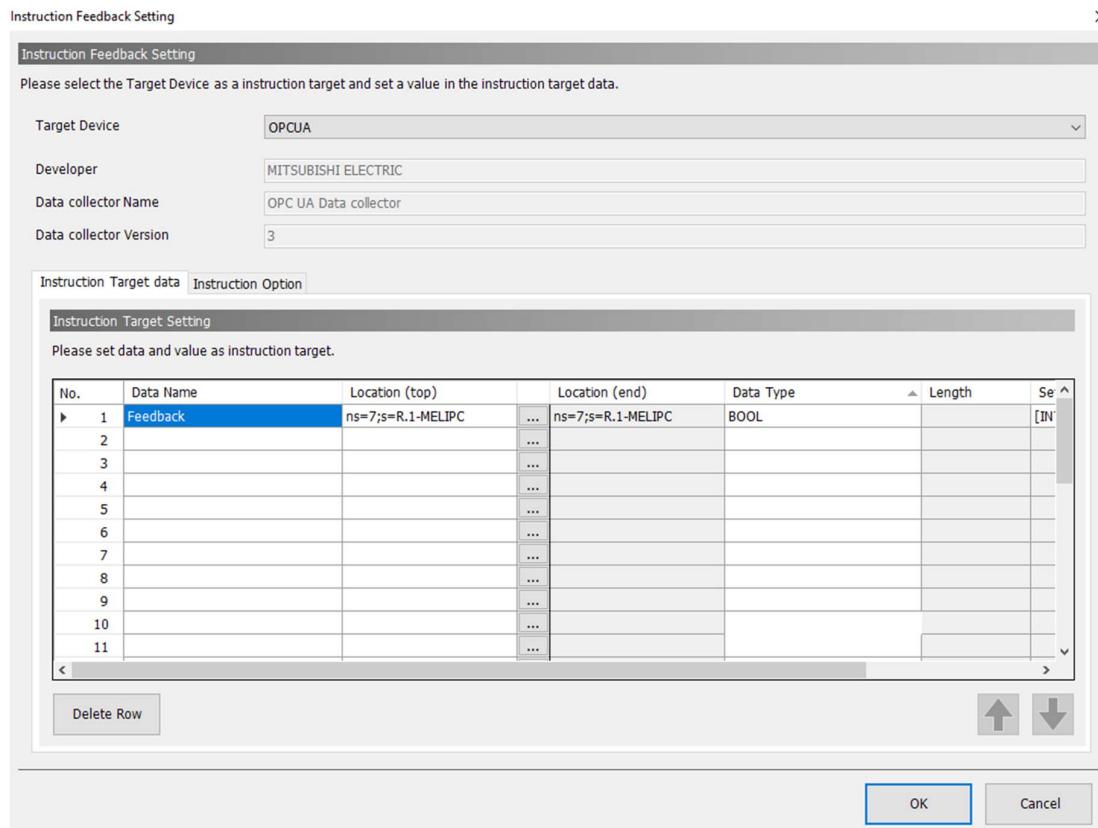
Takođe, radi dokazivanja povezanosti nastalih proizvoda lošeg ili nedovoljno dobrog kvaliteta tokom proizvodnog procesa sa detektovanim neusaglašenosti procesnih parametara od strane razvijenog modela, na slici 114 su plavom bojom naznačene detektovane neusaglašenosti primenom matematičkog modela. Sa slike 114 se uočava da vreme detektovanja neusaglašenosti predstavlja vreme generisanja .csv fajla. Međutim, vreme nastanka neusaglašenosti procesnih parametara koje dovode do proizvoda lošeg ili nedovoljno dobrog kvaliteta može da nastane i 5 minuta ranije koliko je potrebno da se generiše jedan .csv fajl.

	A	B	C	D	E	F	G	H	I	J
1	batch	tip + sirina	tip+sirina+dezen	datum	vreme	brzii	Im	greska	masina	tip gubitki
26275	BR01740949	START 4,00	START 4,00 FLORIDA 2 2K	2021/06/19	14:08:33	22.85	21 2R	Premazivanje 2	V14-PVC	
26276	BR01740950	START 4,00	START 4,00 FLORIDA 2 2K	2021/06/19	14:15:05	22.85	17.2 2R	Premazivanje 2	V14-PVC	

Slika 116. Dva registrovana proizvoda lošeg ili nedovoljno dobrog kvaliteta od strane posmatranog proizvodnog sistema

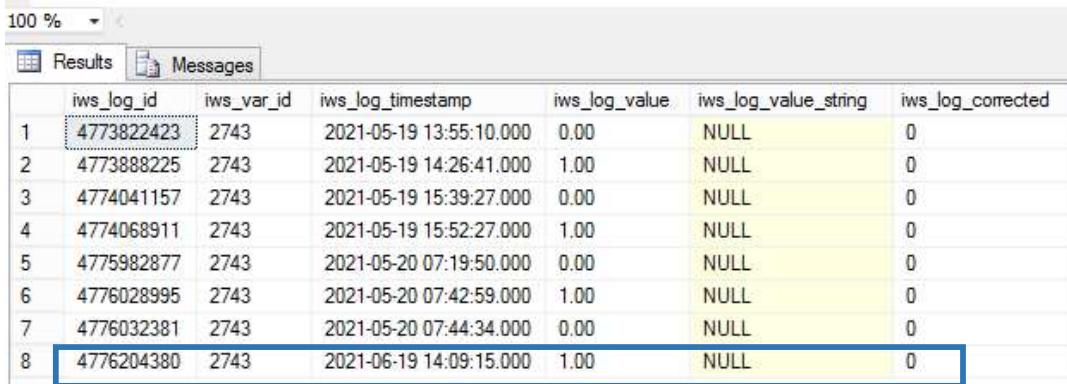
5.3.7.2. Automatizacija analize procesnih parametara u trenutku njihovog prikupljanja primenom Edge sistema računarske tehnologije

Automatizacija analize procesnih parametara u trenutku njihovog prikupljanja predstavlja povratnu informaciju. Povratna informacija označava slanje signala nazad na PLC uređaj preko SCADA sistema nakon ranog detektovanja neusaglašenosti procesnih parametara koristeći razvijeni matematički RONP model. Slanje povratne informacije je omogućeno primenom Edge sistema računarske tehnologije i korišćenjem softvera *Real-time Flow Designer*. Kako bi se poslala povratna informacija nazad na PLC, bilo je neophodno definisati novi parametar, nazvan *Feedback* (slika 117), definisan kao binarni tip podatka u Edge sistemu računarske tehnologije. Međutim, da bi se izvršilo **zapisivanje nove vrednosti parametra Feedback**, bilo je neophodno i njegovo definisanje unutar SCADA sistema.



Slika 117. Definisani parametar Feedback binarnog tipa

Parametar *Feedback* se aktivira kada matematički model za rano otkrivanje neusaglašenosti procesnih parametara da informaciju da je Mahalanobisova udaljenost prekoračila definisanu graničnu vrednost. U datom trenutku, u SCADA sistemu se vrši promena vrednosti parametra *Feedback*, odnosno njegova vrednost se menja na 1 (slika 118) pa se ta informacija automatski šalje nazad na PLC uređaj.



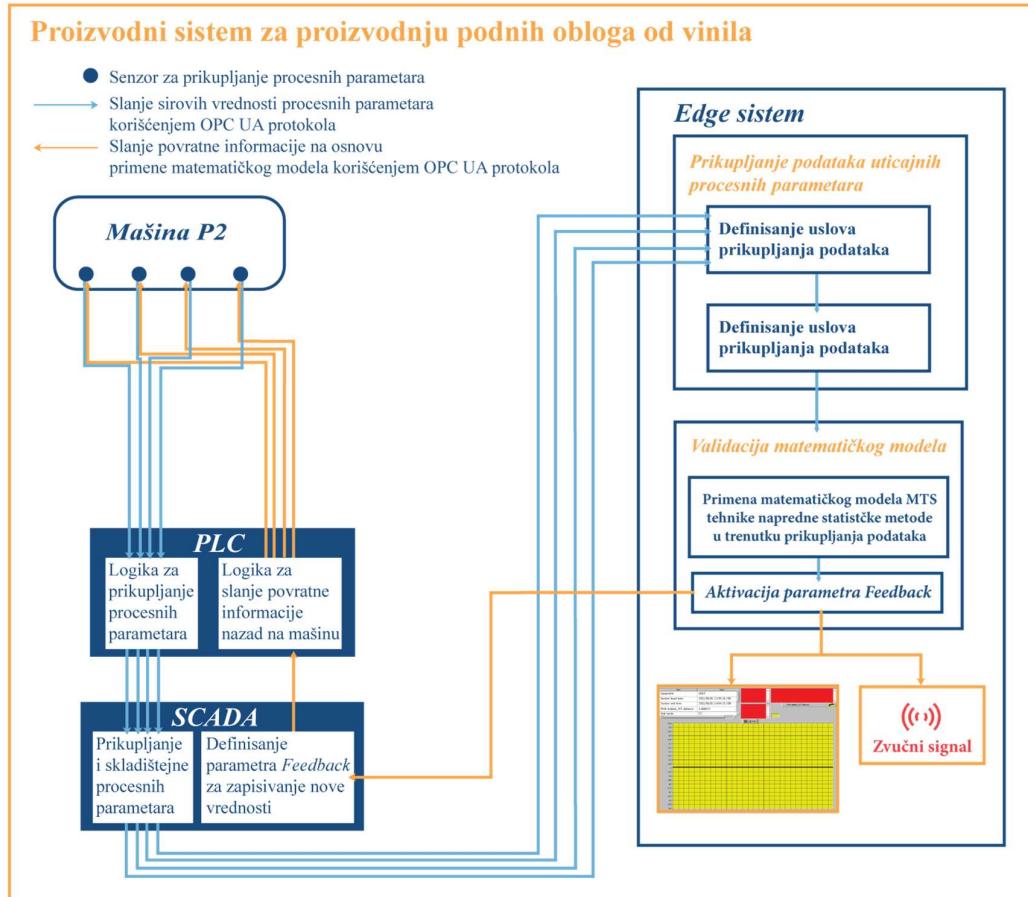
	iws_log_id	iws_var_id	iws_log_timestamp	iws_log_value	iws_log_value_string	iws_log_corrected
1	4773822423	2743	2021-05-19 13:55:10.000	0.00	NULL	0
2	4773888225	2743	2021-05-19 14:26:41.000	1.00	NULL	0
3	4774041157	2743	2021-05-19 15:39:27.000	0.00	NULL	0
4	4774068911	2743	2021-05-19 15:52:27.000	1.00	NULL	0
5	4775982877	2743	2021-05-20 07:19:50.000	0.00	NULL	0
6	4776028995	2743	2021-05-20 07:42:59.000	1.00	NULL	0
7	4776032381	2743	2021-05-20 07:44:34.000	0.00	NULL	0
8	4776204380	2743	2021-06-19 14:09:15.000	1.00	NULL	0

Slika 118. Promenjena i zabeležena nova vrednost parametra *Feedback* na osnovu matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u posmatranom proizvodnom sistemu

Promena vrednosti parametra *Feedback* u SCADA sistemu predstavlja **aktivacioni element** na osnovu kojeg se vrši **ponovno vraćanje (resetovanje) vrednosti svih uticajnih procesnih parametara na njihove definisane srednje vrednosti u PLC uređaju**. Razlog zašto se vrši resetovanje vrednosti svih uticajnih procesnih parametara jeste taj što postoji mogućnost detektovanja neusaglašenost procesnih parametara čak i u slučaju da se sve vrednosti parametara nalaze unutar definisanih tolerancija. Ponovno podešene vrednosti se dalje šalju na mašinu P2 sa ciljem postizanja automatizovane analize procesnih podataka u posmatranom proizvodnom sistemu. Proces automatizacije ranog otkrivanja neusaglašenosti procesnih parametara u posmatranom proizvodnom sistemu šematski je prikazan na slici 119.

Sa slike 119 se jasno vidi da je automatizovanje analize procesnih podataka u trenutku njihovog prikupljanja postignuto implementacijom razvijenog matematičkog modela MTS tehnike napredne statističke metode u *Edge* sistem računarske tehnologije gde se na osnovu detektovanih neusaglašenosti procesnih parametara aktivira parametar *Feedback*. Aktivacija parametra *Feedback* ima dvojaku ulogu da:

- oglasi alarmni sistem kao upozorenje operaterima na proizvodnoj liniji da obrate pažnju na nastalu neusaglašenost procesnih parametara i ustanove potencijani uzrok nastanka, i
- pošalje signal nazad na PLC uređaj, preko SCADA sistema, gde se vrši ponovno vraćanje vrednosti svih uticajnih procesnih parametara na njihove definisane srednje vrednosti na osnovu kreirane logike.



Slika 119. Automatizovana analiza ranog otkrivanja neusaglašenosti procesnih parametara u posmatranom proizvodnom sistemu

Na ovaj način je ostvareno automatizovanje analize procesnih parametara ranim otkrivanjem nastalih neusaglašenosti, odnosno otkrivanjem neusaglašenosti procesnih parametara u trenutku njihovog prikupljanja u proizvodnom sistemu.

5.3.7.3. Rezultati Faze 7

Rezultati faze 7 - *Validacija razvijenog modela za rano otkrivanje neusaglašenosti procesnih parametara* predstavlja fazu RONP modela koja kao izlaznu informaciju daje podatak da li je detektovana neusaglašenost procesnih parametara na osnovu koje nastaju proizvodi lošeg ili nedovoljno dobrog kvaliteta. Takođe, rezultat ove faze jeste i postizanje automatizovane analize procesnih parametara slanjem informacije preko SCADA sistema i PLC uređaja nazad na samu mašinu u proizvodnom sistemu u trenutku detektovanja definisane neusaglašenosti. Rezultati faze 7 - *Validacija razvijenog modela za rano otkrivanje neusaglašenosti procesnih parametara* su prikazani u tabeli 26.

Tabela 26. Sumirani rezultati Faze 7

<i>Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu</i>		
<i>Faza 7</i>	<i>Validacija razvijenog modela za rano otkrivanje neusaglašenosti procesnih parametara</i>	
<i>RB</i>	<i>Korak</i>	<i>Rezultat</i>
1.	Rano otkrivanje neusaglašenosti procesnih parametara	Matematički model je detektovao 2 neusaglašenosti procesnih parametara koje su dovele do nastanka 2 proizvoda lošeg ili nedovoljno dobrog kvaliteta u proizvodnom sistemu na mašini P2.
2.	Automatizacija analize procesnih parametara u trenutku njihovog prikupljanja primenom <i>Edge</i> sistema računarske tehnologije	Primenom <i>Edge</i> sistema računarske tehnologije postignuta je automatizovana analiza procesnih parametara za rano otkrivanje neusaglašenosti u proizvodnom sistemu u trenutku njenog detektovanja slanjem povratne informacije o resetovanju vrednosti svih uticajnih procesnih parametara.

6. DISKUSIJA REZULTATA

Predstavljeni konceptualni RONP model je razvijen sa ciljem unapređenja proizvodnih sistema na osnovu ranog otkrivanja neusaglašenosti procesnih parametara. Rano otkrivanje neusaglašenosti procesnih parametara predstavlja otkrivanje neusaglašenosti procesnih parametara u trenutku njihovog prikupljanja tokom proizvodnog procesa primenom fazi eksperimentnih sistema i metoda napredne analitike. RONP model se pokazao kao uspešan prilikom praktične primene iz razloga što je zasnovan na egzaktnim i realnim podacima generisanim tokom proizvodnog procesa. Na datom primeru verifikacije modela u proizvodnom sistemu procesne industrije pokazana je i dokazana upotrebljiva vrednost razvijenog RONP modela.

Nakon verifikacije RONP modela u posmatranom proizvodnom sistemu može se pristupiti diskusiji postignutih rezultata. Rezultati razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu su dobijeni na osnovu istraživanja i praktične primene u industrijskom okruženju. Istraživanje je sprovedeno primenom eksperimentalne metode u proizvodnom sistemu iz procesne industrije, čija delatnost obuhvata proizvodnju podnih obloga od vinila. Proizvod se proizvodi i isporučuje u obliku rolne, što uslovljava postojanje kontinualne proizvodnje u vidu proizvodne linije. Verifikacija RONP modela je sprovedena primenom definisanih faza detaljno opisanih u poglavljiju *4. Razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima*.

Prilikom verifikacije RONP modela pristupljeno je prvoj fazi. Prva faza RONP modela obuhvata određivanje karakteristika proizvodnog sistema, definisanje funkcije cilja proizvodnog sistema i procena stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara kao preduslov za sprovođenje narednih faza. Preciznije, ova faza je okarakterisana kao *eliminatorični faktor prilikom razvoja RONP modela*.

Prema karakteristikama proizvodnog sistema, vodeći se Klasifikacijom delatnosti sa nazivima, šiframa i opisima delatnosti Republike Srbije, ustanovljeno je da odabrani proizvodni sistem pripada prerađivačkoj industriji za oblast proizvodnje proizvoda od gume i plastike, namenjeno proizvodnji predmeta od plastike za građevinarstvo. Naredni korak obuhvata analizu karakteristika programa proizvodnje koje su određene na osnovu strukture delova po osnovnim dimenzijama, strukture delova po složenosti proizvoda i količinskoj analizi programa proizvodnje. Dobijeni rezultati analize karakteristika programa proizvodnje ukazuju na činjenicu da je proizvod predstavnik proizvod „Force“. Međutim, razmišljana prilikom razvoja RONP modela su išla u sledećem pravcu:

- ukoliko se model bude razvio samo na osnovu jednog proizvoda (proizvoda predstavnika), period prikupljanja podataka će se značajno odužiti;

- procesni parametri za jedan proizvod u posmatranom proizvodnom sistemu su sporo promenljivi, što može da dovede do homogenosti skupa podataka;
- ukoliko se budu prikupljali podaci isključivo za jedan proizvod, postoji mogućnost da se ne javе nikakve neusaglašenosti procesnih parametara tokom njegove proizvodnje, te da ne postoji nikakva informacija o lošem ili nedovoljno dobrom kvalitetu proizvoda.

U skladu sa ovim razmatranjem rešeno je da se ne bira proizvod predstavnik, već grupa proizvoda koji imaju iste karakteristike, gde karakteristike predstavljaju kriterijum na osnovu kojeg se vrši grupisanje proizvoda. Grupa proizvoda je izabrana na osnovu **sličnih vrednosti tolerancija uticajnih procesnih parametara**. Za predstavnika proizvodnog programa izabrana je grupa proizvoda koja ima **66%** udela u ukupnoj godišnjoj količini proizvodnje, što obuhvata 2/3 celokupnog proizvodnog programa. Uvezši u obzir odabranu predstavničku grupu proizvoda proizvodnog programa za posmatrani proizvodni sistem definisana je funkcija cilja kao *unapređenje kvaliteta odabrane grupe proizvoda radi smanjenja broja finalnih proizvoda koji ne zadovoljavaju zahtevani nivo kvaliteta*. Kao poslednji korak prve faze RONP modela, procenjen je stepen spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara primenom fazi ekspertnog sistema. Na osnovu razvijenog fazi ekspertnog sistema i definisanih kriterijuma, dobijena je vrednost koja govori da je stepen spremnosti proizvodnog sistema **53,5%**. To ukazuje na činjenicu da je proizvodni sistem spreman za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametar, gde je stepen spremnosti određen kao **prihvatljiv**. Ali isto tako se može zaključiti da se posmatrani proizvodni sistemi nalazi bliže donje granice prihvatljivosti. Razlog leži prevashodno u tome što je **nivo automatizacije proizvodnog sistema u datom momentu** određen kao **dovoljan**, pošto su zaposleni eksperti taj nivo procenili na oko 50%. Drugim rečima, proizvodna linija nije u potpunosti automatizovana, iako je postavljen cilj da se u skorijoj budućnosti automatizuje veći deo linije kako bi se izbegao uticaj čoveka na proizvodni proces koji potencijalno dovodi do nastanka neusaglašenosti. Ono što predstavlja neočekivani faktor prilikom procene trenutnog stanja proizvodnog sistema, jeste razmatranje primene naprednih tehnologija Industrije 4.0. Prvenstveno se to odnosi na tehnologije koje doprinose digitalizaciji i automatizaciji sa ciljem unapređenja proizvodnog procesa i kvaliteteta proizvoda. Tehnologije koje su razmatrane jesu BDA, IoT, i Edge ili Cloud sistemi računarske tehnologije. Međutim, prilikom intervjua zaposlenih u posmatranom proizvodnom sistemu, pokazan je veliki otpor operatera na proizvodnoj liniji za implementaciju naprednih tehnologija. To potvrđuje zapažanje iz rada [7] koje kaže da su radnici ti koji pružaju otpor za usvajanje inovativnih i naprednih rešenja za unapređenje proizvodnog sistema, procesa ili kvaliteteta proizvoda. Otpor je uslovjen promenama koje bi od operatera zahtevale da:

- prihvate novi pristup gledanja na unapređenje sistema, procesa i kvalitet proizvoda i
- učestvuju u obrazovnom programu koji obuhvata primenu novih naprednih tehnologija, kako bi se upoznali sa metodama i tehnikama koje će se primenjivati.

Međutim, na osnovu dobijenih rezultata prve faze razvoja modela zaključeno je da se mogu sprovesti naredne faze RONP modela.

Druga faza obuhvata definisanje problema neusaglašenosti u posmatranom proizvodnom sistemu. Definisanje problema neusaglašenosti predstavljalo je jednu od zahtevnijih stavki prilikom verifikacije RONP modela. Razlog tome jeste teška postavka problema u proizvodnom sistemu gde je reč o izuzetno složenom proizvodnom procesu. Složenost proizvodnog procesa ogleda se u *povezanosti svih procesnih parametara na celoj proizvodnoj liniji*, gde je za cilj definisano **rano detektovanje proizvoda lošeg ili nedovoljno dobrog kvaliteta primenom RONP modela**. „*Povezanost procensih parametara*“ podrazumeva da neusaglašenosti procesnih parametara nastalih npr. na početku proizvodne linije, dovode do nastanka uočenog proizvoda lošeg ili nedovoljno dobrog kvaliteta na sasvim drugom mestu. To dovodi do nepreciznosti prilikom odlučivanja o mestu gde je tačna lokacija nastanka određene neusaglašenosti. Stoga, u takvoj situaciji, gde je proizvodni proces izuzetno složenog karaktera, teško je uzeti u razmatranje celu proizvodnu liniju kao lokaciju nastanka neusaglašenosti. Zato se pristupilo definisanju klastera mašina (potpoglavlje 5.1. *Lokacija za eksperimentalini rad*), gde „*klaster*“ obuhvata skup mašina za koje je ekspertnom analizom zaključeno da neusaglašenost procesih parametara na jednoj mašini potencijalno može da dovede i do nastanka proizvoda lošeg ili nedovoljno dobrog kvaliteta na drugoj mašini (s tim da je postavljen uslov da maštine moraju da se grupišu logičkim redosledom tehnoloških operacija).

Daljom analizom lokacije nastanka neusaglašenosti u vidu lošeg ili nedovoljno dobrog kvaliteta proizvoda, došlo se do zaključka da je u prvom klasteru, tačnije na mašini P2, detektovan najveći broj proizvoda lošeg ili nedovoljno dobrog kvaliteta tokom prethodnog perioda proizvodnje. Ali isto tako, posmatrajući problem *povezanosti procensih parametara* ustanovljeno je da je povezanost procesnih parametara na odabranoj mašini svedena na minimum. Dalje, posmatrajući kriterijum nivoa automatizacije (tabela 13), mašina P2 ima izuzetno visok nivo automatizacije prema proceni eksperata. Stoga, ta lokacija je uzeta kao lokacija nastanka neusaglašenosti parametara u proizvodnom sistemu, gde je definisani problem klasifikacione prirode.

U okviru verifikacije RONP modela, treća faza podrazumeva identifikaciju uticajnih parametara i prikupljanje podataka koji dovode do nastanka neusaglašenosti procesnih parametara. Prema rezultatima faze 1 RONP modela, gde se prevashodno misli na karakteristike programa proizvodnje na osnovu kojih je odabrana grupa proizvoda predstavnika, i faze 2 RONP modela, gde se uzela u obzir definisana lokacija nastanka neusaglašenosti, definisani su i uticajni procesni parametri. Broj definisanih uticajnih procesnih parametara za izabranu grupu proizvoda na mašini P2 iznosi 15. Nakon toga, usledilo je prikupljanje podataka uticajnih procesnih parametara u trenutku njihovog generisanja.

Prikupljanje uticajnih procesnih podataka je omogućeno primenom *Edge* sistema računarske tehnologije. Razlog zašto je odlučeno da se primenjuje tehnologija zasnovana na *Edge* sistemu računarske tehnologije, a ne na *Cloud* ili *Fog* sistemima jeste taj što je *Edge* tehnologija prevashodno i razvijena isključivo za potrebe industrije. Tačnije, *Edge* sistemi se upotrebljavaju unutar samih proizvodnih sistema gde se podaci prikupljaju na mestu njihovog generisanja tokom proizvodnog procesa (što omogućava i kasniju analizu procesnih podataka u trenutku njihovog prikupljanja). Ali isto tako, primena *Edge* sistema zahteva razvoj matematičkog modela na malom i precizno odabranog skupu podataka. Zbog toga, definisani vremenski period prikupljanja procesnih parametara u trajanju od 33 dana je izabran iz dva razloga:

- po planu i program proizvodnje, u tom vremenskom periodu su se veći deo vremena proizvodili proizvodi koji pripadaju odabranoj grupi proizvoda, i
- zbog ograničenja *Edge* sistema računarske tehnologije.

Dobijeni rezultati ove faze pokazuju da je broj prikupljenih podataka primenom *Edge* sistema računarske tehnologije za definisani vremenski period prikupljanja iznosio 1.960.200 podataka. Broj prikupljenih podataka ukazuje na činjenicu da ograničenja *Edge* sistema računarske tehnologije nisu imala negativan uticaj.

Četvrta faza razvoja modela – faza pripreme i obrade prikupljenih podataka je usledima nakon završene faze 3 RONP modela. Priprema i obrada podataka je izvršena pomoću *Edge* sistema računarske tehnologije. Na osnovu vizuelnog prikaza podataka ustanovljeno je da se veći deo vrednosti procesnih parametara nalazi unutar definisanih tolerancija procesnih parametara od strane eksperata. Prema tome, prikupljene vrednosti procesnih parametara predstavljaju neizbalansiran skup podataka koji većinski sadrži podatke o proizvodnji finalnih proizvoda "A" klase i jako mali broj „loših“ podataka koji pružaju informaciju o lošem ili nedovoljno dobrom kvalitetu proizvoda. Daljim praćenjem i razradom koraka u ovoj fazi RONP modela, ukupan broj prikupljenih podataka se znatno smanjio. Razlog tome jeste:

- eliminacija nedoslednih, konstantnih i podataka sa šumom što je dovelo do smanjenja ukupnog broja prikupljenih podataka za približno 50%, i
- redukcija broja prikupljenih procesnih parametara, što je dovelo do smanjenja ukupnog broja uticajnih procesnih parametara.

Zatim, definisan je zavisni parametar binarnog karaktera koji daje informaciju kada su se javile gleške kvaliteta u prikupljenom skupu podataka. Binarni karakter zavisnog parametra je izabran radi jednostavnije klasifikacije proizvoda. Na osnovu toga urađena je i optimizacija i kreiranje precizno odabranog skupa podataka spremnog za fazu razvoja matematičkog modela.

Razvoj matematičkog modela podrazumeva primenu neke od napredne analitičke metode. Međutim, u svrhu procene performansi matematičkog modela za rano otkrivanje

neusaglašenosti procesnih parametara i poređenje rezultata dobijenih različitim analitičkim metodama, razvijena su dva modela:

- prvi model je razvijen primenom napredne statističke metode, tačnije korišćenjem MTS tehnike;
- drugi model je razvijen primenom metode mašinskog učenja, tačnije korišćenjem OCSVM tehnike.

Razlog poređenja MTS i OCSVM tehnike jeste taj što su ove tehnike ekvivalentne jedna drugoj, gde se obe koriste pri odsustvu izbalansiranog skupa podataka. U fazi razvoja modela MTS tehnika napredne statističke metode je nadmašila tačnost modela baziranog na tehnički mašinskog učenja. Rezultat je nadmašen za 0,14%. To nam dalje govori da, iako je trend da metode mašinskog učenja daju bolje rezultate od naprednih statističkih metoda, napredna statistika ima sve veću primenu za rešavanje konkretnih inženjerskih problema analizom procesnih podataka.

Rezultat testiranja matematičkog modela je potvrdio analizu u prethodnoj fazi, gde je matematički model razvijen primenom MTS tehnike opet nadmašio performanse matematičkog model razvijenog primenom OCSVM tehnike i to sa tačnošću modela za 1,97%. Takođe, matematički model zasnovan na MTS tehnički je pokazao bolje rezultate i kod procene greške i odziva modela. Jedino gde je matematički model razvijen primenom OCSVM tehnike pokazao bolji rezultat jeste kod određivanja preciznosti modela i to za 0,13% u odnosu na rezultat dobijen korišćenjem MTS tehnike. Iz tog razloga izračunata je i mera izbalansiranosti preciznosti i odziva, odnosno F1 mera, kako bi poređenje matematičkih modela bilo validno. Rezultat F1 mere je pokazao da matematički model razvijen primenom MTS tehnike daje bolji rezultat za 1,01%. Stoga, iako je matematički model razvijen MTS tehnike imao manju preciznost od OCSVM, u svim ostalim procenama je nadmašio performanse tehnike mašinskog učenja.

Stoga, primena modela u industrijskom okruženju ukazuje da statističke tehnike, uprkos svojoj jednostavnosti, mogu biti podjednako moćne kao tehnike mašinskog učenja, i mogu se uzeti u obzir za otkrivanje i dijagnozu anomalija u proizvodnim sistemima. Pored toga, dobijeni rezultati su donekle i očekivani s obzirom na činjenicu da MTS tehnika predstavlja standardnu statističku analizu za unapređenje kvaliteta proizvoda ili procesa. To predstavlja dovoljan razlog da model razvijen primenom MTS tehnike napredne statističke metode bude izabran za validaciju u proizvodnom sistemu za proizvodnju podnih obloga.

Sama validacija matematičkog modela u proizvodnom sistemu podrazumevala je implementaciju matematičkog modela u proizvodnom sistemu u trenutku prikupljanja procesnih podataka, a samim tim i finalno potvrđivanje razvijene metodologije konceptualnog RONP modela. Tokom validacije postavljeni su određeni ciljevi istraživanja u svrhu

potvrđivanja postavljenih hipoteza. Validacijom razvijenog modela, kao postavljenim prvim ciljem, **hipoteza 1:**

Moguće je razviti model za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima, je potvrđena.

Validacija razvijenog modela u posmatranom proizvodnom sistemu je primenjena za definisanu grupu proizvoda sa ciljem detekcije lošeg ili nedovoljno dobrog kvaliteta proizvoda nastalog na osnovu neusaglašenosti procesnih parametara. U skladu sa ovim ciljem, model je detektovao 44 neusaglašenosti procesnih parametara, nakon čega je usledila analiza dobijenih rezultata zajedno sa ekspertima iz posmatranog proizvodnog sistema. Na osnovu analize zaključeno je da su se u **vremenskom periodu validacije u posmatranom proizvodnom sistemu proizvela 2 proizvoda koji su okarakterisana kao škart koji se dogodio na mašini P2** (slika 116), gde je **razvijeni matematički model ispravno detektovao te dve neusaglašenosti procesnih parametara koje su dovele do nastanka proizvoda nedovoljno dobrog kvaliteta** (slika 114).

Daljom analizom ustanovljen je razlog zašto je matematički model detektovao značajno više neusaglašenosti procesnih parametara koji ukazuju na proizvode lošeg ili nedovoljno dobrog kvaliteta u odnosu sa stvaran škart. Usled postojanja kontinualne proizvodnje u vidu proizvodne linije, neusaglašenosti koje su detektovane od strane razvijenog matematičkog modela, *potencijalno dovode do grešaka kvaliteta na drugim mašinama*. Odnosno, velik broj detektovanih neusaglašenosti procesnih parametara primenom matematičkog modela nije nužan pokazatelj da će se proizvodi lošeg ili nedovoljno dobrog kvaliteta javiti isključivo na mašini P2, već postoji mogućnost nastanka takvih proizvoda i na nekoj drugoj mašini tokom proizvodnog procesa. Primer za takvu situaciju jeste detektovanje neusaglašenosti procesnih parametara na mašini P2, dok su eksperti proizvod lošeg kvaliteta zapazili na mašini P5. Ova činjenica ukazuje na to da je pojavu grešaka kvaliteta moguće detektovati ranim otkrivanje neusaglašenosti procesnih parametara na mašini P2 i proaktivnim reagovanjem u proizvodnom sistemu kako bi se izbegao nastanak proizvoda lošeg kvaliteta i na drugim mašinama.

Nastavkom analize detektovanih neusaglašenosti procesnih parametara zajedno sa ekspertima iz proizvodnog sistema, ustanovljeno je da je matematički model detektovao neusaglašenosti procesnih parametara koje dovode i do tzv. **sistemskih grešaka**. Sistemske greške pojavljuju se, na primer, na početku proizvodnje nove serije dok se vrši kalibracija mašina, što *uslovjava opravdani nastanak proizvoda lošeg ili nedovoljno dobrog kvaliteta*. Iako sistemske greške predstavljaju proizvode lošeg ili nedovoljno dobrog kvaliteta, uslovljavajući time nastanak škarta, koje model za rano otkrivanje neusaglašenosti procesnih parametara detektuje, one su u ovom istraživanju izuzete iz daljih razmatranja, jer su kao takve očekivane tokom proizvodnog procesa. Takođe, analiza je pokazala da vrednosti pojedinih procesnih

parametara nisu bili u okviru definisanih tolerancija, već da su se javila mnoga iskakanja. Ta iskakanja su uslovila detektovanje neusaglašenosti procesnih parametara primenom razvijenog matematičkog modela, iako to ne predstavlja nužan uslov nastanka proizvoda lošeg ili nedovoljno dobrog kvaliteta. U svakom slučaju, primena razvijenog matematičkog modela omogućava rano otkrivanje neusaglašenosti procesnih parametara na definisanoj lokaciji za definisau grupu proizvoda, a samim tim i smanjenje nastanka proizvoda lošeg ili nedovoljno dobrog kvaliteta proaktivnim reagovanjem. Na osnovu obrazloženog, **hipoteza 2** koja glasi:

Primenom razvijenog modela moguće je smanjiti gubitke u vidu lošeg ili nedovoljno dobrog kvaliteta proizvoda (škarta) ranim otkrivanjem neusaglašenosti procesnih parametara, je potvrđena.

Nakon uspešnog detektovanja neusaglašenosti procesnih parametara u proizvodnom sistemu na mašini P2, naredni cilj jeste bio automatizacija analize procesnih parametara u trenutku njihovog prikupljanja. Jedan od razloga zašto se težilo ka automatizovanoj analizi procesnih parametara jeste smanjenje uticaja ljudskog faktora prilikom donošenja odluka tokom proizvodnog procesa. Automatizacija analize procesnih parametara u trenutku njihovog prikupljanja je omogućena slanjem povratne informacije primenom *Edge* sistema računarske tehnologije aktivacijom parametra *Feedback*. Parametar *Feedback* se aktivira u trenutku kada matematički model da informaciju da je Mahalanobisova udaljenost prekoračila definisanu graničnu vrednost, na osnovu čega se oglašava alarm za detekciju neusaglašenosti i izbacuje obaveštavajući prozor. U tom trenutku se njegova nova vrednost automatski menja unutar SCADA sistema i šalje nazad na PLC. U PLC uređaju se vrši **ponovno vraćanje vrednosti svih uticajnih procesnih parametara na njihove definisane srednje vrednosti na osnovu kreirane logike unutar samog uređaja**. Razlog ponovog vraćanja vrednosti svih uticajnih procesnih parametara jeste taj što postoji mogućnost nastanka neusaglašenost procesnih parametara čak i u slučaju da nijedna vrednost parametara nije izašla izvan definisanog opsega tolerancija. Na ovaj način, automatizacijom analize procesnih parametara kreiran je samoodlučujući CPS sistem, sačinjen od fizičkih komponenti (proizvodnih mašina, PLC uređaja i *Edge* sistema računarske tehnologije) i softvera u koji je implementiran matematički model MTS tehnike napredne statističke metode i SCADA softvera, kao virtualnih komponenti povezanih preko OPC UA protokola IoT mreže. U ovom samoodlučujućem CPS sistemu odluke se donose isključivo na osnovu generisanih vrednosti uticajnih procesnih parametara primenom razvijenog matematičkog modela što dalje rezultira praktičnom primenom koncepta Industrije 4.0 u posmatranom proizvodnom sistemu procesne industrije. Shodno tome, **hipoteza 3**:

Primenom razvijenog modela moguće je automatizovati analizu procesnih parametara u trenutku njihovog prikupljanja, je potvrđena.

7. ZAKLJUČAK

Unapređenje proizvodnih sistema je samo po sebi veliki izazov. Ukoliko se tome doda i činjenica da je unapređenje proizvodnih sistema procesne industrije dostiglo visok nivo primenom kontinualnih unapređenja, ostavljajući mali prostor za dalja unapređenja, taj zadatak postaje još teži. Međutim, upravo taj „mali prostor za dalja unapređenja“ predstavlja izazov, a ujedno i priliku za naučnoistraživački rad. Imajući to u vidu, ova doktorska disertacija se bavi unapređenjem proizvodnih sistema procesne industrije sa stanovišta eliminacije gubitaka.

Gubici u proizvodnim sistemima ne moraju nužno da se odnose na fizički vidljive probleme, već i probleme u vidu neiskorišćenih procesnih podataka koji se svakodnevno generišu u velikom broju tokom proizvodnih procesa. Neiskorišćeni procesni podaci zauzimaju prostor u bazama podataka, bez potencijala da se dobije korisna informacija u svrhu unapređenja proizvodnog sistema. Danas je opšte poznata činjenica da je adekvatnom analizom procesnih podataka moguće otkriti i otkloniti većinu problema nastalih tokom proizvodnih procesa izazvanih neusaglašenošću procesnih parametara. Međutim, nedostatak adekvatnih metoda primenjenih u proizvodnim sistemima je očigledan. Razlog nedostatka primenjenih metoda u proizvodnim sistemima jeste velika složenost proizvodnog procesa sa potrebom kompanije za ranim otkrivanjem i otklanjanjem neusaglašenosti procesnih parametara, tačnije u trenutku njihovog prikupljanja ili u vremenu približnom tom trenutku.

Kako bi se prevazišao ovaj jaz, razvijen je konceptualni model za rano otkrivanje neusaglašenosti procesnih parametara (RONP) sa ciljem unapređenja proizvodnih sistema (slika 34). Ovaj konceptualni model predložen u ovoj doktorskoj disertaciji, pruža kvalitativne opise ističući sve veze koje postoje u realnim procesima proizvodnih sistema procesne industrije sa akcentom na rano otkrivanje neusaglašenosti procesnih parametara na osnovu procesnih podataka generisanih tokom proizvodnih procesa.

RONP model predstavlja hibridni model baziran na upotrebi fazi ekspertnih sistema i metoda napredne analitike, čiji je razvoj podeljen u sedam faza, i to:

- Faza 1: Procena trenutnog stanja proizvodnog sistema;
- Faza 2: Definisanje problema neusaglašenosti u proizvodnom sistemu;
- Faza 3: Identifikacija uticajnih parametara i prikupljanje podataka;
- Faza 4: Priprema i obrada prikupljenih podataka;
- Faza 5: Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka;
- Faza 6: Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara;

- Faza 7: Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara.

Faza 1 - Procena trenutnog stanja proizvodnog sistema: Prva faza RONP modela zahtevala je razmatranje osnovnih karakteristika proizvodnog sistema, funkcije cilja kompanije kao i procenu stepena spremnosti proizvodnog sistema za razvoj modela za rano otkrivanje neusaglašenosti procesnih parametara kako bi se doneo zaključak o podobnosti sistema za razvoj modela. Stoga, ova faza ujedno predstavlja eliminatorični faktor prilikom razvoja modela. Odnosno, primenom fazi ekspertnog sistema se vrši procena trenutnog stanja proizvodnog sistema u vidu stepena spremnosti proizvodnog sistema za razvoj RONP modela. Stepen spremnosti proizvodnog sistema je definisan preko kriterijuma, i to: strategija kompanije, ljudski resursi, upravljački pristupi, podaci, nivo automatizacije i napredne tehnologije. Svaki od kriterijuma predstavlja organizacioni aspekt proizvodnog sistema kao neophodan uslov kako bi se pristupilo daljim fazama razvoja modela. Na osnovu vrednosti kriterijuma, samo proizvodni sistemi koji ostvare prihvatljiv ili visok nivo spremnosti, mogu da nastave sa daljim fazama razvoja modela. U suprotnom, neophodno je izvršiti promene unutar proizvodnih sistema sa ciljem poboljšanja i unapređenja trenutnog stanja prema definisanim kriterijumima.

Faza 2 - Definisanje problema neusaglašenosti u proizvodnom sistemu: Kvalitet razvoja modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima je, u najvećoj meri, uslovljen preciznim definisanjem problema neusaglašenosti. U predloženom RONP modelu definisanje se radi primenom metode intervjuja sa ekspertima iz proizvodnog sistema. Razlog primene metode intervjuja sa ekspertima jeste poznavanje toka proizvodnog procesa, kao i poznavanje inženjerskih problema sa kojima se svakodnevno suočavaju. Međutim, u većini slučajeva je neophodno ponovno razmatranje postavke definisanog problema, jer njegova preciznost direktno utiče na rezultat RONP modela. Stoga, da bi se izvršilo što preciznije definisanje problema neusaglašenosti u proizvodnim sistemima definisani su tačni koraci sprovođenja ove faze – preciziranje vrste neusaglašenosti, određivanje lokacije nastanka neusaglašenosti i određivanje tipa problema neusaglašenosti.

Faza 3 - Identifikacija uticajnih parametara i prikupljanje podataka: Prema definisanom problemu vrši se identifikacija uticajnih parametara i prikupljanje procesnih podataka. Uticajni parametri predstavljaju procesne parametre za koje se smatra da utiču na pojavu definisanog problema koji uslovljava nastanak neusaglašenosti. Identifikacijom svih uticajnih procesnih parametara omogućeno je prikupljanje podataka generisanih tokom proizvodnog procesa. Faza identifikacije uticajnih parametara i prikupljana podataka RONP modela je sprovedena primenom sledećih definisanih koraka – definisanje kriterijuma za identifikaciju uticajnih parametara, identifikacija uticajnih parametara, dostupnost uticajnih parametara, određivanje tipa podataka uticajnih parametara i prikupljanje podataka uticajnih parametara. Prikupljanje se vrši primenom napredne tehnologije Industrije 4.0, tačnije

korišćenjem *Edge* sistema računarske tehnologije, koje je omogućilo prikupljanje podataka u tačnom vremenu njihovog generisanja.

Faza 4 - Priprema i obrada prikupljenih podataka: Prikupljeni podaci podrazumevaju polaznu osnovu za pripremu i obradu prikupljenih podataka, kao narednu fazu prilikom razvoja RONP modela. Priprema i obrada podrazumeva korišćenje različitih matematičkih metoda za optimizaciju prikupljenog skupa podataka obuhvatajući korake – eliminacija nedoslednih, konstantnih i podataka sa šumom, dodavanje vrednosti nepotpunim podacima, redukcija broja prikupljenih procesnih parametara, definisanje zavisnog parametra i optimizacija i kreiranje precizno odabranog skupa podataka za razvoj matematičkog modela. Razlog pripreme i obrade prikupljenih procesnih podataka jeste povećanje kvaliteta prikupljenog skupa procesnih podataka.

Faza 5 - Razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara pomoću izabrane grupe podataka: Razvoj matematičkog modela je definisan metodologijom za podelu izabrane grupe podataka na podatke za razvoj matematičkog modela i podatke za testiranje razvijenog modela, odabirom metoda i tehnika za razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara i razvojem matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnim sistemima pomoću izabrane grupe podataka za razvoj modela i primenom izabrane metode i tehnike napredne analitike. Metode napredne analitike su podeljene na napredne statističke metode i metode mašinskog učenja. U okviru naprednih statističkih metoda moguće je korišćenje tehniki:

- višeparametarska linearna regresija (MLR),
- logistička regresija (LR),
- Mahalanobis-Taguči sistem (MTS).

Kao ekvivalentne njima, odabранe tehnike metoda mašinskog učenja su sledeće:

- metoda potpornih vektora za regresiju (SVR),
- metoda potpornih vektora za klasifikaciju korišćenjem izbalansiranog skupa podataka (SVM),
- metoda potpornih vektora za klasifikaciju korišćenjem neizbalansiranog skupa podataka (OCSVM).

Odabir metoda napredne analitike i gore navedenih tehnika se vrši isključivo na osnovu prirode skupa prikupljenih podataka.

Faza 6 - Testiranje matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara: Zadatak faze testiranja modela jeste određivanje u kojoj meri razvijeni matematički model za rano otkrivanje neusaglašenosti procesnih parametara odgovara

stvarnim slučajevim (očekivanim rezultatima) koji se događaju tokom proizvodnog procesa. To se određuje primenom koraka – testiranje matematičkog modela pomoću podataka za testiranje definisanih u fazi 5 RONP modela, procena performansi matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara primenom tehnika testiranja i analiza dobijenih rezultata matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara. Rezultat završene faze jeste testiran model spreman za validaciju u proizvodnom sistemu.

Faza 7 - Validacija matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara: Validacija RONP modela predstavlja fazu potvrđivanja modela. Potvrđivanje RONP modela se vrši primenom prethodno definisanih faza, s tim da je neophodno obezbediti analizu procesnih podataka u trenutku njihovog prikupljanja (ili vremenu što približnije tom trenutku). Validacija se vrši na osnovu metode eksperimenta u industrijskom okruženju sa ciljem potvrđivanja ispravnosti i univerzalnosti razvijene metodologije RONP modela i daljeg testiranja performansi razvijenog matematičkog modela u posmatranom proizvodnom sistemu. Ovi ciljevi se realizuju praćenjem koraka validacije RONP modela – rano otkrivanje neusaglašenosti procesnih parametara i procena performansi validiranog matematičkog modela primenom metoda napredne analitike i automatizacija analize procesnih parametara u trenutku njihovog prikupljanja. Dobijeni rezultati validacije predstavljaju praktično potvrđen i primjenjen RONP model u industrijskom okruženju.

Verifikacija modela za rano otkrivanje neusaglašenosti procesnih parametara u proizvodnom sistemu: Praktična primena RONP modela je sprovedena u industrijskom okruženju. Primena modela je sprovedena eksperimentalnom metodom u proizvodnom sistemu za proizvodnju podnih obloga od vinila što je uslovilo razvoj matematičkog modela za rano otkrivanje neusaglašenosti procesnih parametara na osnovu prikupljenog skupa procesnih podataka generisanih tokom proizvodnog procesa. Prema fazama razvoja RONP modela i definisanom eksperimentu, razvijena su dva matematička modela primenom različitih metoda napredne analitike: metoda napredne statistike i metoda mašinskog učenja. Doprinos ove doktorske disertacije se ogleda i u sprovedenoj komparativnoj analizi koristeći MTS tehniku napredne statistike i, njoj ekvivalentnu, OCSVM tehniku mašinskog učenja, gde se obe tehnike koriste za razvoj matematičkog modela na osnovu neizbalansiranog skupa podataka. Rezultati komparativne analize su pokazali da je MTS tehnika napredne statističke metode nadmašila rezultat tačnosti matematičkog modela baziranog na tehnici mašinskog učenja za 0,14%. Prilikom testiranja matematičkog modela dobijeni rezultat je potvrdio analizu iz prethodne faze. Odnosno, rezultat testiranja je pokazao da je matematički model razvijen primenom MTS tehnike opet nadmašio performanse matematičkog modela razvijenog primenom OCSVM tehnike u vidu tačnosti modela za 1,97%, ali i kod procene greške i odziva modela. Jedino gde je matematički model razvijen primenom OCSVM tehnike pokazao bolji rezultat jeste kod određivanja preciznosti modela i to za 0,13% u odnosu na rezultat dobijen

MTS tehnikom. Međutim, uzimajući u obzir F1 meru, kao meru izbalansiranosti preciznosti i odziva, dokazano je da matematički model razvijen primenom MTS tehnike daje bolji rezultat za 1,01%. To dalje ukazuje da stav da metode mašinskog učenja daju bolje rezultate od naprednih statističkih metoda, ne mora nužno uvek da bude tačan. Odnosno, metode napredne statistike imaju sve veću primenu za rešavanje konkretnih inženjerskih problema analizom procesnih podataka, što i govore nedavno objavljena istraživanja [22], [174], [250].

Na osnovu dobijenih rezultata tokom verifikacije može se zaključiti da razvijeni RONP model predstavlja efikasan alat za rano otkrivanje neusaglašenosti procesnih parametara koji uslovjavaju nastanak grešaka kvaliteta u vidu škarta. Pored ranog otkrivanja neusaglašenosti procesnih parametara, upotrebom razvijenog modela omogućena je automatizovana analiza procesnih parametara u trenutku njihovog prikupljanja korišćenjem industrijskog računara zasnovanog na primeni *Edge* sistema računarske tehnologije. Praktičnom primenom modela u proizvodnom sistemu je potvrđena i njegova fleksibilnost koja se ogleda u prilagođavanju promenama unutar proizvodnog procesa (npr. uvođenje novih tipova proizvoda koji spadaju u relevantnu grupu proizvoda). Takođe, razvijena metodologija RONP modela može se koristiti u različitim proizvodnim sistemima za njihovo unapređenje.

S obzirom da je verifikacija RONP modela rađena na osnovu inženjerskog problema, ulazeći dublje u analize došlo se do problema pojave *lažnih alarmi*. Prilikom razgovora o rezultatima sa ekspertima iz kompanije, zaključeno je da su u sistemu, pored grešaka u vezi sa kvalitetom proizvoda, prisutne i **sistemske greške** (odnose se na opravdani nastanak grešaka kvaliteta proizvoda). Razvijeni matematički model nije predviđao samo probleme sa kvalitetom proizvoda već i sistemske greške, koje su prvobitno klasifikovane kao lažni alarmi, iako se odnose na greške kvaliteta nastale tokom procesa konfiguracije mašina. Takođe, razvijeni matematički model je detektovao i neusaglašenosti procesnih parmetara koji dovode i do pojave proizvoda lošeg ili nedovoljno dobrog kvaliteta na drugim mašinama u okviru proizvodne linije.

Na osnovu praktične primene i eksperimentalnog dokazivanja došlo se do zaključka da je RONP model omogućio kreiranje CPS okruženja u posmatranom proizvodnom sistemu gde je izvršeno integrisanje proizvodnih mašina, industrijskog računara i PLC uređaja, kao fizičkih komponenti sistema, i softverskih rešenja za automatizovanu analizu procesnih podataka i SCADA sistema, kao virtuelnih komponenti povezanih preko OPC UA protokola, kao standarda IoT mreže. Integrisanje je omogućeno primenom naprednih tehnologija Industrije 4.0, kao što su IoT mreža, *Edge* sistem računarske tehnologije i metoda napredne analitike. To dalje implicira da razvijeni RONP model predstavlja inovativno i univerzalno rešenje koje omogućava praktičnu primenu koncepta Industrije 4.0 u proizvodnim sistemima procesne industrije.

Dalji pravci istraživanja u oblasti ranog otkrivanja neusaglašenosti procesnih parametara biće usmereni ka istraživanju unapređenja proizvodnih sistema u pravcu smanjenja ili eliminacije sistemskih grešaka, ali isto tako i na automatizovanju analize procesnih podataka na celoj proizvodnoj liniji. Takođe, izvršiće se testiranje u drugim proizvodnim sistemima procesne industrije u cilju dodatnog potvrđivanja fleksibilnosti i univerzalnosti razvijene metodologije RONP modela. Pored navedenog, s obzirom na činjenicu da se konceptualni RONP model oslanja na ekspertsко znanje primenom fazi ekspertnih sistema u kombinaciji sa naprednim analitičkim metodama korišćenjem *Edge* sistema računarske tehnologije, dalji pravci istraživanja biće usmereni i na dalji razvoj i usavršavanje metodologije kako bi model mogao da bude primenjiv i u predstojećoj industrijskoj revoluciji, odnosno Industriji 5.0.

8. LITERATURA

- [1] V. Reljić, "Daljinsko upravljanje digitalnom pneumatikom u konceptu Industrije 4.0," Fakultet tehničkih nauka, Univerzitet Novi Sad, 2020.
- [2] D. Zelenović, I. Čosić, R. Maksimović, i A. Maksimović, *Priručnik za projektovanje proizvodnih sistema – pojedinačni prilaz*, 1. izdanje. Fakultet tehničkih nauka u Novom Sadu, 2003.
- [3] D. Zelenović, *Projektovanje proizvodnih sistema*, 3. izdanje. Fakultet tehničkih nauka u Novom Sadu, 2003.
- [4] I. Čosić, D. Šešlja, i Predrag Vidicki, *Osnove industrijskog inženjerstva i menadžmenta – sistemski prilaz*, 3. izdanje. Fakultet tehničkih nauka u Novom Sadu, 2020.
- [5] T. Grünberg, "A review of improvement methods in manufacturing operations," 2003.
- [6] E. Hobsbawm, *Doba revolucije*. 1987.
- [7] B. Bajić, A. Rikalović, N. Suzić, and V. Piuri, "Industry 4.0 Implementation Challenges and Opportunities: A Managerial Perspective," *IEEE Syst. J.*, vol. 15, no. 1, pp. 546–559, 2021.
- [8] H. Mohajan, "The Second Industrial Revolution has Brought Modern Social and Economic Developments," *J. Soc. Sci. Humanit.*, vol. 6, no. 98209, pp. 1–14, 2020.
- [9] G. K. Kanji, "Total quality management: the second industrial revolution," *Total Qual. Manag.*, vol. 1, no. 1, pp. 3–12, 1990.
- [10] D. Regodić i D. Cvetković, *Automatizacija, proizvodni sistemi i računarski integrisana proizvodnja*, 1. izdanje. Univerzitet Singidunum Departman za inženjerski menadžment, Beograd, 2011.
- [11] I. Beker, S. Morača, M. Lazarević, D. Šević, Z. Tešić, A. Rikalović, i V. Radlovački, *LEAN sistem*, 1. izdanje. Fakultet tehničkih nauka u Novom Sadu, 2017.
- [12] Y. Lu, "Industry 4.0: A survey on technologies, applications and open research issues," *J. Ind. Inf. Integr.*, vol. 6, pp. 1–10, 2017.
- [13] B. Li, B. Hou, W. Yu, X. Lu, and C. Yang, "Applications of artificial intelligence in intelligent manufacturing: a review," *Front. Inf. Technol. Electron. Eng.*, vol. 18, no. 1, pp. 86–96, 2017.
- [14] M. Milosavljević, *Veštačka inteligencija*. Univerzitet Singidunum, Beograd, 2019.
- [15] P. J. Mosterman and J. Zander, "Industry 4.0 as a Cyber-Physical System study," *Softw. Syst. Model.*, vol. 15, no. 1, 2015.

- [16] C. Garrido-Hidalgo, D. Hortelano, L. Roda-Sanchez, T. Olivares, M. C. Ruiz, and V. Lopez, "IoT Heterogeneous Mesh Network Deployment for Human-in-the-Loop Challenges Towards a Social and Sustainable Industry 4.0," *IEEE Access*, vol. 6, no. 8, pp. 28417–28437, 2018.
- [17] M. Tanasković, *Internet stvari*, 1. izdanje. Univerzitet Singidunum, Beograd, 2020.
- [18] Y. Chen, H. Chen, A. Gorkhali, Y. Lu, Y. Ma, and L. Li, "Big data analytics and big data science: a survey," *J. Manag. Anal.*, vol. 3, no. 1, pp. 1–42, 2016.
- [19] A. Caggiano, "Cloud-based manufacturing process monitoring for smart diagnosis services," *Int. J. Comput. Integr. Manuf.*, vol. 31, no. 7, pp. 612–623, 2018.
- [20] N. Bačanin Džakula i I. Štrumberger, *Klaud računarstvo*, 1. izdanje. Univerzitet Singidunum, Beograd, 2018.
- [21] B. Bajić, I. Čosić, B. Katalinić, S. Morača, M. Lazarević, and A. Rikalović, "Edge Computing Vs. Cloud Computing: Challenges And Opportunities In Industry 4.0," in *30th Daaam International Symposium on Intelligent Manufacturing and Automation*, 2019, pp. 864–871.
- [22] B. Bajić, N. Suzić, N. Simeunović, S. Morača, and A. Rikalović, "Real-time Data Analytics Edge Computing Application for Industry 4.0: The Mahalanobis-Taguchi Approach," *Int. J. Ind. Eng. Manag.*, vol. 11, no. 3, pp. 146–156, 2020.
- [23] S. S. Kamble, A. Gunasekaran, and S. A. Gawankar, "Sustainable Industry 4.0 framework: A systematic literature review identifying the current trends and future perspectives," *Process Saf. Environ. Prot.*, vol. 117, pp. 408–425, 2018.
- [24] M. Ghobakhloo, "The future of manufacturing industry: a strategic roadmap," *J. Manuf. Technol. Manag.*, vol. 29, no. 6, pp. 910–936, 2018.
- [25] M. Piccarozzi, B. Aquilani, and C. Gatti, "Industry 4.0 in management studies: A systematic literature review," *Sustain.*, vol. 10, no. 10, pp. 1–24, 2018.
- [26] D. Preuveneers, "The intelligent industry of the future: A survey on emerging trends, research challenges and opportunities in Industry 4.0," *J. Ambient Intell. Smart Environ.*, vol. 9, no. 3, pp. 287–298, 2017.
- [27] H. S. Kang, J. Y. Lee, S. Choi, H. Kim, J.H. Park, J.Y. Son, B.H. Kim, and S.D. Noh, "Smart manufacturing: Past research, present findings, and future directions," *Int. J. Precis. Eng. Manuf. - Green Technol.*, vol. 3, no. 1, pp. 111–128, 2016.
- [28] S. Wang, J. Wan, D. Li, and C. Zhang, "Implementing Smart Factory of Industrie 4.0: An Outlook," *Int. J. Distrib. Sens. Networks*, vol. 12, pp. 1–10, 2016.
- [29] M. Türkeş, I. Oncioiu, H. Aslam, A. Marin-Pantelescu, D. Topor, and S. Căpuşneanu, "Drivers and Barriers in Using Industry 4.0: A Perspective of SMEs in Romania," *Processes*, vol. 7, no. 3, p. 153, 2019.

- [30] B. Nikolić, J. Ignjatić, N. Suzić, B. Stevanov, and A. Rikalović, “Predictive Manufacturing Systems in Industry 4.0: Trends, Benefits and Challenges,” in *28TH DAAAM International Symposium on Intelligent Manufacturing and Automation*, 2017, pp. 769–802.
- [31] A. Humayed, J. Lin, F. Li, and B. Luo, “Cyber-Physical Systems Security - A Survey,” *IEEE Internet Things J.*, vol. 4, no. 6, pp. 1802–1831, 2017.
- [32] R. Y. Zhong, X. Xu, E. Klotz, and S. T. Newman, “Intelligent Manufacturing in the Context of Industry 4.0: A Review,” *Engineering*, vol. 3, no. 5, pp. 616–630, 2017.
- [33] L. Atzori, A. Iera, and G. Morabito, “The Internet of Things: A survey,” *Comput. Networks*, vol. 54, no. 15, pp. 2787–2805, 2010.
- [34] S. Tiwari, H. M. Wee, and Y. Daryanto, “Big data analytics in supply chain management between 2010 and 2016: Insights to industries,” *Comput. Ind. Eng.*, vol. 115, pp. 319–330, 2018.
- [35] P. Mell and T. Grance, *The NIST Definition of Cloud Computing*, vol. 15. National Institute of Standards and Technology, Information Technology Laboratory, 2011, pp. 1–7.
- [36] W. Shi, J. Cao, Q. Zhang, Y. Li, and L. Xu, “Edge Computing: Vision and Challenges,” *IEEE Internet Things J.*, vol. 3, no. 5, pp. 637–646, 2016.
- [37] S. Khan, S. Parkinson, and Y. Qin, “Fog computing security: a review of current applications and security solutions,” *J. Cloud Comput.*, vol. 6, no. 1, 2017.
- [38] K. Bilal, O. Khalid, A. Erbad, and S. U. Khan, “Potentials, trends, and prospects in edge technologies: Fog, cloudlet, mobile edge, and micro data centers,” *Comput. Networks*, vol. 130, pp. 94–120, 2018.
- [39] I. Odun-Ayo, R. Goddy-Worlu, V. Geteloma, and E. Grant, “A Systematic Mapping Study of Cloud, Fog, and Edge/Mobile Devices Management, Hierarchy Models and Business Models,” *Adv. Sci. Technol. Eng. Syst. J.*, vol. 4, no. 2, pp. 91–101, 2019.
- [40] A. M. Rahmani, T. N. Gia, B. Negash, A. Anzanpour, I. Azimi, M. Jiang, and P. Liljeberg, “Exploiting smart e-Health gateways at the edge of healthcare Internet-of-Things: A fog computing approach,” *Futur. Gener. Comput. Syst.*, vol. 78, pp. 641–658, 2018.
- [41] S. Choi, K. Jung, and S. Do Noh, “Virtual reality applications in manufacturing industries: Past research, present findings, and future directions,” *Concurr. Eng. Res. Appl.*, vol. 23, no. 1, pp. 40–63, 2015.
- [42] A. W. W. Yew, S. K. Ong, and A. Y. C. Nee, “Towards a griddable distributed manufacturing system with augmented reality interfaces,” *Robot. Comput. Integrat. Manuf.*, vol. 39, pp. 43–55, 2016.

- [43] A. Moktadir, S. M. Ali, S. Kusi-sarpong, and A. A. Shaikh, "Assessing challenges for implementing Industry 4.0: Implications for process safety and environmental protection," *Process Saf. Environ. Prot.*, vol. 117, pp. 730–741, 2018.
- [44] A. Al-Fuqaha, "Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications," *IEEE Commun. Surv. Tutorials*, vol. 1, no. 2, pp. 78–95, 2013.
- [45] A. L. Buczak and E. Guven, "A Survey of Data Mining and Machine Learning Methods for Cyber Security Intrusion Detection," *IEEE Commun. Surv. Tutorials*, vol. 18, no. 2, pp. 1153–1176, 2016.
- [46] A. Meroño-Peñuela, A. Ashkpour, M. van Erp, K. Mandemakers, L. Breure, A. Scharnhorst, S. Schlobach, and F. van Harmelen, "Semantic technologies for historical research: A survey," *Semant. Web*, vol. 6, no. 6, pp. 539–564, 2014.
- [47] V. Janev and S. Vraneš, "Applicability assessment of Semantic Web technologies," *Inf. Process. Manag.*, vol. 47, no. 4, pp. 507–517, 2011.
- [48] S. H. Huang, P. Liu, A. Mokasdar, and L. Hou, "Additive manufacturing and its societal impact: A literature review," *Int. J. Adv. Manuf. Technol.*, vol. 67, no. 5–8, pp. 1191–1203, 2013.
- [49] M. K. Thompson, G. Moroni, T. Vaneker, G. Fadel, R. I. Campbell, I. Gibson, A. Bernard, J. Schulz, P. Graf, B. Ahuja, and F. Martina, "Design for Additive Manufacturing: Trends, opportunities, considerations, and constraints," *CIRP Ann. - Manuf. Technol.*, vol. 65, no. 2, pp. 737–760, 2016.
- [50] S. Ford and M. Despeisse, "Additive manufacturing and sustainability: an exploratory study of the advantages and challenges," *J. Clean. Prod.*, vol. 137, pp. 1573–1587, 2016.
- [51] ASTM International, *Standard Terminology for Additive Manufacturing Technologies (F2792-12a)*. ASTM International, West Conshohocken, USA, 2013, pp. 1–3.
- [52] B. Bajić, N. Suzić, N. Simeunović, S. Morača, and A. Rikalović, "Toward Real-time Data Analytics Application for Industry 4.0," in *18th International Scientific Conference on Industrial Systems (IS'20)*, 2020, pp. 1–8.
- [53] M. Götz and B. Jankowska, "Adoption of Industry 4.0 Technologies and Company Competitiveness: Case Studies from a Post-Transition Economy," *Foresight STI Gov.*, vol. 14, no. 4, pp. 61–78, 2020.
- [54] F. E. Garcia-Muiña, R. González-Sánchez, A. M. Ferrari, and D. Settembre-Blundo, "The Paradigms of Industry 4.0 and Circular Economy as Enabling Drivers for the Competitiveness of Businesses and Territories: The Case of an Italian Ceramic Tiles Manufacturing Company," *Soc. Sci.*, vol. 7, no. 12, pp. 1–31, 2018.
- [55] V. Vulanović, D. Stanivuković, B. Kamberović, N. Radaković, R. Maksimović, V. Radlovački, i M. Šilobad, *Metode i tehnike unapređenja procesa rada*. FTN - Institut za

- Industrijsko inženjering i menadžment, IIS - Istraživački i tehnološki centar, Novi Sad, 2003.
- [56] N. Suzić, C. Forza, A. Trentin, and Z. Aničić, "Implementation guidelines for mass customization: current characteristics and suggestions for improvement," *Prod. Plan. Control*, vol. 29, no. 10, pp. 856–871, 2018.
 - [57] N. Suzić, E. Sandrin, S. Suzić, C. Forza, A. Trentin, and Z. Aničić, "Implementation Guidelines for Mass Customization: A Researcher-Oriented View," *Int. J. Ind. Eng. Manag.*, vol. 9, no. 4, pp. 229–243, 2018.
 - [58] W. Xia and J. Sun, "Simulation guided value stream mapping and lean improvement: A case study of a tubular machining facility," *J. Ind. Eng. Manag.*, vol. 6, no. 2, pp. 456–476, 2013.
 - [59] R. Panat, V. Dimitrova, T. S. Selvamuniandy, K. Ishiko, and D. Sun, "The application of Lean Six Sigma to the configuration control in Intel's manufacturing R&D environment," *Int. J. Lean Six Sigma*, vol. 5, no. 4, pp. 444–459, 2014.
 - [60] J. Darlington, M. Francis, P. Found, and A. Thomas, "Design and implementation of a Drum-Buffer-Rope pull-system," *Prod. Plan. Control Manag. Oper.*, vol. 26, no. 6, pp. 37–41, 2015.
 - [61] P. Jirasukprasert, J. A. Garza-Reyes, V. Kumar, and M. K. Lim, "A Six Sigma and DMAIC application for the reduction of defects in a rubber gloves manufacturing process," *Int. J. Lean Six Sigma*, vol. 5, no. 1, pp. 2–21, 2014.
 - [62] B. G. Mwanza and C. Mbohwa, "Design of a Total Productive Maintenance Model for Effective Implementation: Case Study of a Chemical Manufacturing Company," *Procedia Manuf.*, vol. 4, pp. 461–470, 2015.
 - [63] A. P. Lacerda, A. R. Xambre, H. M. Alvelos, A. Pedro, A. R. Xambre, and H. M. Alvelos, "Applying Value Stream Mapping to eliminate waste: a case study of an original equipment manufacturer for the automotive industry," *Int. J. Prod. Res.*, vol. 23, no. 1, pp. 1708–1720, 2016.
 - [64] A. U. Rehman, M. Alkhatani, and U. Umer, "Multi Criteria Approach to Measure Leanness of a Manufacturing Organization," *IEEE Access*, vol. 6, pp. 20987–20994, 2018.
 - [65] S. G. Ponnambalam and N. Subramanian, "Implementation of lean manufacturing and lean audit system in an auto parts manufacturing industry – an industrial case study," *Int. J. Comput. Integr. Manuf.*, vol. 31, no. 2, pp. 1–16, 2017.
 - [66] V. Gupta, R. Jain, M. L. Meena, and G. S. Dangayach, "Six-sigma application in tire-manufacturing company: a case study," *J. Ind. Eng. Int.*, vol. 14, no. 3, pp. 511–520, 2018.
 - [67] S. M. O. Vieira and R. B. Lopes, "Improving production systems with lean: a case study in a medium-sized manufacturer," *Int. J. Ind. Syst. Eng.*, vol. 33, no. 2, pp. 162–180, 2019.

- [68] S. Choudhary, R. Nayak, M. Dora, and N. Mishra, “SI-TBL: an integrated lean and green approach for improving sustainability performance: a case study of a packaging manufacturing SME in the U.K.,” *Prod. Plan. Control*, vol. 30, no. 5–6, pp. 353–368, 2019.
- [69] W. Dong, S. Yong, B. Shen, S. Lin, H. Loong, C. Pin, and S. G. Ponnambalam, “Adaptive analytical approach to lean and green operations,” *J. Clean. Prod.*, vol. 235, pp. 190–209, 2019.
- [70] R. S. Peruchi, P. R. Junior, T. G. Brito, A. P. Paiva, P. P. Balestrassi, and L. M. M. Araújo, “Integrating Multivariate Statistical Analysis Into Six Sigma DMAIC Projects : A Case Study on AISI 52100 Hardened Steel Turning,” *IEEE Access*, vol. 8, pp. 34246–34255, 2020.
- [71] A. A. Abdallah, “How Can Lean Manufacturing Lead the Manufacturing Sector during Health Pandemics Such as COVID 19: A Multi Response Optimization Framework,” *Comput. Mater. Contin.*, vol. 66, no. 2, pp. 1397–1410, 2021.
- [72] M. Donauer, P. Peças, and A. Azevedo, “Identifying nonconformity root causes using applied knowledge discovery,” *Robot. Comput. Integrat. Manuf.*, vol. 36, pp. 84–92, 2015.
- [73] Y. Li, Q. Chang, G. Xiao, and J. Arinez, “Data-Driven Analysis of Downtime Impacts in Parallel Production Systems,” *IEEE Trans. Autom. Sci. Eng.*, vol. 12, no. 4, pp. 1541–1547, 2015.
- [74] A. Simeone, Y. Luo, E. Woolley, S. Rahimifard, and C. Boe, “A decision support system for waste heat recovery in manufacturing,” *CIRP Ann. - Manuf. Technol.*, vol. 65, pp. 21–24, 2016.
- [75] F. Pask, P. Lake, A. Yang, H. Tokos, and J. Sadhukhan, “Sustainability indicators for industrial ovens and assessment using Fuzzy set theory and Monte Carlo simulation,” *J. Clean. Prod.*, vol. 140, part, pp. 1217–1225, 2016.
- [76] M. Dorio, F. J. Fernandez, M. Félix, and G. Santos, “ERP-machining centre integration: a modular kitchen production case study,” *Procedia Manuf.*, vol. 13, pp. 1159–1166, 2017.
- [77] J. Auer, N. Bey, and J.-M. Schäfer, “Combined Life Cycle Assessment and Life Cycle Costing in the Eco-Care-Matrix: A case study on the performance of a modernized manufacturing system for glass containers,” *J. Clean. Prod.*, vol. 141, pp. 99–109, 2017.
- [78] H. Rezazadeh and A. Khiali-miab, “A two-layer genetic algorithm for the design of reliable cellular manufacturing systems,” *Int. J. Ind. Eng. Comput.*, vol. 8, pp. 315–332, 2017.
- [79] X. Ou, S. Member, Q. Chang, J. Zou, and S. Member, “Modeling and Performance Diagnostics of Composite Work Cells with Gantry,” *IEEE Trans. Autom. Sci. Eng.*, vol. 5, no. 3, pp. 1230–1242, 2018.

- [80] S. M. Zahraee, J. M. Rohani, and K. Y. Wong, "Application of Computer Simulation Experiment and Response Surface Methodology for Productivity Improvement in a Continuous production line: Case Study" *J. King Saud Univ. - Eng. Sci.*, vol. 30, no. 3, pp. 207–217, 2018.
- [81] S. Tamminen, E. Ferreira, H. Tiensuu, H. Helaakoski, V. Kyllönen, J. J. Röning, E. Puukko, and J. Röning, "An online quality monitoring tool for information acquisition and sharing in manufacturing: requirements and solutions for the steel industry," *Int. J. Ind. Syst. Eng.*, vol. 33, no. 3, pp. 291–313, 2019.
- [82] L. Berrah, V. Clivillé, J. Montmain, and G. Mauris, "The Contribution concept for the control of a manufacturing multi-criteria performance improvement," *J. Intell. Manuf.*, vol. 30, pp. 47–58, 2019.
- [83] M. Straka and R. Lenort, "Improvement of logistics in manufacturing system by the use of simulation modelling: A real industrial case study," *Adv. Prod. Eng. Manag.*, vol. 15, pp. 18–30, 2020.
- [84] E. Laudante, A. Greco, M. Caterino, and M. Fera, "Human – Robot Interaction for Improving Fuselage Assembly Tasks: A Case Study," *Appl. Sci.*, vol. 10, no. 5757, pp. 1–17, 2020.
- [85] R. Miskiewicz and R. Wolniak, "Practical Application of the Industry 4.0 Concept in a Steel Company," *Sustainability*, vol. 12, no. 14, pp. 1–21, 2020.
- [86] A. Papetti, F. Gregori, M. Pandolfi, M. Peruzzini, M. Germani, and V. Pietro, "A method to improve workers' well-being toward human-centered connected factories," *J. Comput. Des. Eng.*, vol. 7, pp. 1–14, 2020.
- [87] J. Wang, Y. Liu, S. Ren, C. Wang, and W. Wang, "Evolutionary game based real-time scheduling for energy-efficient distributed and flexible job shop," *J. Clean. Prod.*, no. January, p. 126093, 2021.
- [88] B. Wang, "The Future of Manufacturing: A New Perspective," *Engineering*, vol. 4, no. 5, pp. 722–728, 2018.
- [89] K. Alexopoulos, K. Sipsas, E. Xanthakis, S. Makris, and D. Mourtzis, "An industrial Internet of things based platform for context-aware information services in manufacturing," *Int. J. Comput. Integr. Manuf.*, vol. 31, no. 11, pp. 1111–1123, 2018.
- [90] K. S. Kiangala and Z. Wang, "Initiating predictive maintenance for a conveyor motor in a bottling plant using industry 4.0 concepts," *Int. J. Adv. Manuf. Technol.*, vol. 97, no. 9–12, pp. 3251–3271, 2018.
- [91] D. Mourtzis, S. Fotia, N. Boli, and P. Pittaro, "Product-service system (PSS) complexity metrics within mass customization and Industry 4.0 environment," *Int. J. Adv. Manuf. Technol.*, vol. 97, no. 1–4, pp. 91–103, 2018.

- [92] J. Molka-Danielsen, P. Engelseth, and H. Wang, "Large scale integration of wireless sensor network technologies for air quality monitoring at a logistics shipping base," *J. Ind. Inf. Integr.*, vol. 10, pp. 20–28, 2018.
- [93] O. Blanco-Novoa, T. M. Fernandez-Carames, P. Fraga-Lamas, and M. A. Vilar-Montesinos, "A Practical Evaluation of Commercial Industrial Augmented Reality Systems in an Industry 4.0 Shipyard," *IEEE Access*, vol. 6, no. c, pp. 8201–8218, 2018.
- [94] P. O'Donovan, K. Leahy, K. Bruton, and D. T. J. O'Sullivan, "An industrial big data pipeline for data-driven analytics maintenance applications in large-scale smart manufacturing facilities," *J. Big Data*, vol. 2, no. 1, pp. 1–26, 2015.
- [95] A. Rikalović, N. Suzić, B. Bajić, and V. Piuri, "Industry 4.0 Implementation Challenges and Opportunities: A Technological Perspective," *IEEE Syst. J.*, pp. 1–14, 2021.
- [96] P. Tamás, "Process Improvement Trends for Manufacturing Systems in Industry 4.0," *Acad. J. Manuf. Eng.*, vol. 14, no. 4, p. 7, 2016.
- [97] B. Bajić, A. Rikalović, and S. Morača, "Challenges of Big Data Analytics in Industry 4.0," in *SPIN'19 LIN transformacija i digitalizacija privrede Srbije*, 2019, pp. 20–27.
- [98] N. Khan, I. Yaqoob, I. A. T. Hashem, Z. Inayat, W. K. M. Ali, M. Alam, M. Shiraz, and A. Gani, "Big Data: Survey, Technologies, Opportunities, and Challenges," *Sci. World J.*, pp. 1–18, 2014.
- [99] J. Lee, H. A. Kao, and S. Yang, "Service innovation and smart analytics for Industry 4.0 and big data environment," in *Product Services Systems and Value Creation. Proceedings of the 6th CIRP Conference on Industrial Product-Service Systems*, 2014, vol. 16, pp. 3–8.
- [100] A. Oussous, F. Z. Benjelloun, A. Ait Lahcen, and S. Belfkih, "Big Data technologies: A survey," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 30, no. 4, pp. 431–448, 2018.
- [101] Y. Riahi and S. Riahi, "Big Data and Big Data Analytics: concepts, types and technologies," *Int. J. Res. Eng.*, vol. 5, no. 9, pp. 524–528, 2018.
- [102] B. Bajić, I. Čosić, M. Lazarević, N. Sremčev, and A. Rikalović, "Machine Learning Techniques for Smart Manufacturing: Applications and Challenges in Industry 4.0," in *9th International Scientific and Expert Conference TEAM 2018*, 2018, pp. 29–38.
- [103] I. A. T. Hashem, I. Yaqoob, N. B. Anuar, S. Mokhtar, A. Gani, and S. Ullah Khan, "The rise of 'big data' on cloud computing: Review and open research issues," *Inf. Syst.*, vol. 47, pp. 98–115, 2015.
- [104] P. K. R. Maddikunta, Q. Pham, B. Prabadevi, N. Deepa, K. Dev, T. R. Gadekallu, R. Ruby, and M. Liyanage, "Industry 5.0: A survey on enabling technologies and potential applications," *J. Ind. Inf. Integr.*, vol. In press, pp. 1–32, 2021.
- [105] L. Breiman, J. Friedman, C. J. Stone, and R. Olshen, *Classification and regression trees*, no. 2. 2012.

- [106] U. Sivarajah, M. M. Kamal, Z. Irani, and V. Weerakkody, "Critical analysis of Big Data challenges and analytical methods," *J. Bus. Res.*, vol. 70, no. August, pp. 263–286, 2017.
- [107] J. Lenz, T. Wuest, and E. Westkämper, "Holistic approach to machine tool data analytics," *J. Manuf. Syst.*, vol. 48, pp. 180–191, 2018.
- [108] X. Li and J. Wan, "Proactive caching for edge computing-enabled industrial mobile wireless networks," *Futur. Gener. Comput. Syst.*, vol. 89, pp. 89–97, 2018.
- [109] V. Jirkovsky, M. Obitko, P. Kadera, and V. Marik, "Toward Plug&Play Cyber-Physical System Components," *IEEE Trans. Ind. Informatics*, vol. 14, no. 6, pp. 2803–2811, 2018.
- [110] A. Theorin, K. Bengtsson, J. Provost, M. Lieder, C. Johnsson, T. Lundholm, and B. Lennartson, "An event-driven manufacturing information system architecture for Industry 4.0," *Int. J. of Production Res.*, vol. 55, no. 5, pp. 1297–1311, 2017.
- [111] F. Pisani, V. M. do Rosario, and E. Borin, "Fog vs. Cloud Computing: Should i stay or should i go?," *Futur. Internet*, vol. 11, no. 2, pp. 1–31, 2019.
- [112] Y. Ai, M. Peng, and K. Zhang, "Edge Computing technologies for Internet of Things: A Primer," *Digit. Commun. Networks*, vol. 4, no. 2, pp. 77–86, 2018.
- [113] C. Puliafito, E. Mingozzi, F. Longo, A. Puliafito, and O. Rana, "Fog Computing for the Internet of Things: A Survey," *ACM Trans. Internet Technol.*, vol. 19, no. 2, pp. 1–41, 2019.
- [114] T. Wuest, D. Weimer, C. Irgens, and K. D. Thoben, "Machine learning in manufacturing: Advantages, challenges, and applications," *Prod. Manuf. Res.*, vol. 4, no. 1, pp. 23–45, 2016.
- [115] A. Botta, W. De Donato, V. Persico, and A. Pescapé, "Integration of Cloud computing and Internet of Things: A Survey," *Futur. Gener. Comput. Syst.*, vol. 56, pp. 684–700, 2016.
- [116] M. Sarstedt and E. Mooi, "Regression Analysis," in *A Concise Guide to Market Research*, 1st ed., Berlin: Springer, 2014, pp. 193–233.
- [117] Mitsubishi Electric Corporation, "Data Analysis Introduction Guidebook," Lecture, Nagoya, Japan, 2018.
- [118] B. Ratner, *Statistical and Machine Learning Data Mining*, 3rd ed. CRC press, 2017.
- [119] G. A. Susto, A. Schirru, S. Pampuri, S. McLoone, and A. Beghi, "Machine learning for predictive maintenance: A multiple classifier approach," *IEEE Trans. Ind. Informatics*, vol. 11, no. 3, pp. 812–820, 2015.
- [120] D. Gupta, *Applied analytics through case studies using SAS and R*, 1st ed. Apress, 2018.
- [121] Z. Milosevic, W. Chen, A. Berry, and F. A. Rabhi, "Real-Time Analytics," in *Big Data: Principles and Paradigms*, no. 2016, 2016, pp. 39–61.
- [122] Y. Cui, S. Kara, and K. C. Chan, "Manufacturing big data ecosystem: A systematic

- literature review,” *Robot. Comput. Integr. Manuf.*, vol. 62, no. In press, pp. 1–20, 2020.
- [123] L. Columbus, “Real-Time Data Is The Future Of Smart Manufacturing,” *Forbes*, 2019. [Online]. Available: <https://www.forbes.com/sites/louiscolumbus/2019/12/18/real-time-data-is-the-future-of-smart-manufacturing/#768c45c26ec0>. [Accessed: 23-Jul-2020].
- [124] Y. Zhang, W. Wang, N. Wu, and C. Qian, “IoT-Enabled Real-Time Production Performance Analysis and Exception Diagnosis Model,” *IEEE Trans. Autom. Sci. Eng.*, vol. 13, no. 3, pp. 1318–1332, 2016.
- [125] C. Qian, Y. Zhang, C. Jiang, S. Pan, and Y. Rong, “A real-time data-driven collaborative mechanism in fixed-position assembly systems for smart manufacturing,” *Robot. Comput. Integr. Manuf.*, vol. 61, no. In press, pp. 1–13, 2020.
- [126] M. Veinović, G. Šimić, A. Jevremović, i M. Tair, *Baze podataka*, 1. izdanie. Univerzitet Singidunum, Beograd, 2018.
- [127] M. Nacchia, F. Fruggiero, A. Lambiase, and K. Bruton, “A Systematic Mapping of the Advancing Use of Machine Learning Techniques for Predictive Maintenance in the Manufacturing Sector,” *Appl. Sci.*, pp. 1–34, 2021.
- [128] N. K. Ming, N. Philip, and S. Sahlan, “Proactive and predictive maintenance strategies and application for instrumentation & control in oil & gas industry,” *Int. J. Integr. Eng.*, vol. 11, no. 4, pp. 119–130, 2019.
- [129] M. Čosović and S. Obradović, “BGP anomaly detection with balanced datasets,” *Teh. Vjesn.*, vol. 25, no. 3, pp. 766–775, 2018.
- [130] M. Kursad Uçar, M. Nour, H. Sindi, and K. Polat, “The Effect of Training and Testing Process on Machine Learning in Biomedical Datasets,” *Math. Probl. Eng.*, vol. 2020, pp. 1–17, 2020.
- [131] F. Provost, “Machine Learning from Imbalanced Data Sets 101 Extended Abstract,” 2000.
- [132] Z. Kang, C. Catal, and B. Tekinerdogan, “Machine learning applications in production lines: A systematic literature review,” *Comput. Ind. Eng.*, vol. 149, p. 106773, 2020.
- [133] J. Klikowski and M. Woźniak, “Employing one-class svm classifier ensemble for imbalanced data stream classification,” in *International Conference on Computational Science*, 2020, pp. 117–127.
- [134] R. Batuwita and V. Palade, “Class imbalance learning methods for support vector machines,” in *Imbalanced Learning: Foundations, Algorithms, and Applications*, 2013, pp. 83–99.
- [135] S. L. Yadav and A. Sohal, “Review Paper on Big Data Analytics in Cloud Computing,” *Int. J. Comput. Trends Technol.*, vol. 49, no. 3, pp. 156–160, 2017.

- [136] C. Wu, R. Buyya, and K. Ramamohanarao, “Big Data Analytics = Machine Learning + Cloud Computing,” *Big Data Princ. Paradig.*, pp. 3–38, 2016.
- [137] S. Singh and A. Yassine, “IoT Big Data Analytics with Fog Computing for Household Energy Management in Smart Grids,” in *SGIoT 2018 - 2nd EAI International Conference on Smart Grid and Internet of Things*, 2018, no. August, pp. 1–44.
- [138] L. Atzori, A. Iera, and G. Morabito, “The Internet of Things: A survey,” *Comput. Networks*, vol. 54, no. 15, pp. 2787–2805, 2010.
- [139] I. Toma, E. Simperl, and G. Hench, “A joint roadmap for semantic technologies and the internet of things,” *Proc. 3rd STI Roadmapping Work.*, no. January, pp. 1–5, 2009.
- [140] Z. Milosević, W. Chen, A. Berry, and F. A. Rabhi, “Real-Time Analytics,” in *Big Data: Principles and Paradigms*, 2016, pp. 39–61.
- [141] G. P. Bhandari and R. Gupta, “An Overview of Edge/Cloud Computing Architecture with its Issues and Challenges,” in *Advancing Consumer-Centric Fog Computing Architectures*, 2018, pp. 1–37.
- [142] M. M. Naeem, H. Mahar, F. Memon, and M. Siddique, “Cluster Computing Vs Cloud Computing: A Comparison and An Overview,” *Sci. Int.*, vol. 28, no. 6, pp. 5267–5271, 2016.
- [143] Q. K. Kadhim, R. Yusof, and H. S. Mahdi, “A Review Study on Cloud Computing Issues Related content,” in *1st International Conference on Big Data and Cloud Computing (ICoBiC) 2017*, 2018, pp. 1–11.
- [144] L. M. Vaquero and L. Rodero-Merino, “Finding your way in the fog: Towards a comprehensive definition of fog computing,” *Comput. Commun. Rev.*, vol. 44, no. 5, pp. 27–32, 2014.
- [145] M. Mukherjee, R. Matam, L. Shu, L. Maglaras, M. A. Ferrag, N. Choudhury, and V. Kumar, “Security and Privacy in Fog Computing: Challenges,” *IEEE Access*, vol. 5, pp. 19293–19304, 2017.
- [146] B. Tang, Z. Chen, G. Hefferman, S. Pei, T. Wei, H. He, and Q. Yang, “Incorporating Intelligence in Fog Computing for Big Data Analysis in Smart Cities,” *IEEE Trans. Ind. Informatics*, vol. 13, no. 5, pp. 2140–2150, 2017.
- [147] F. Hussain and A. Al-Karkhi, “Big Data and Fog Computing,” in *Internet of Things*, 2017.
- [148] S. Yi, C. Li, and Q. Li, “A survey of fog computing: Concepts, applications and issues,” in *Proceedings of the International Symposium on Mobile Ad Hoc Networking and Computing (MobiHoc)*, 2015.
- [149] N. R. Draper and H. Smith, *Applied Regression Analysis*, 3rd. 1998.
- [150] D. Borman, *Statistics 101*. 2018.
- [151] N. H. Bingham and J. M. Fry, *Regression: Linear Models in Statistics*. 2010.

- [152] C. F. Peng, L. H. Ho, S. B. Tsai, Y. C. Hsiao, Y. Zhai, Q. Chen, L. C. Chang, and Z. Shang, “Applying the Mahalanobis-Taguchi System to improve tablet PC production processes,” *Sustain.*, vol. 9, no. 9, pp. 1–17, 2017.
- [153] X. Xiao, D. Fu, Y. Shi, and J. Wen, “Optimized Mahalanobis – Taguchi System for High-Dimensional Small Sample Data Classification,” vol. 2020, 2020.
- [154] N. Matloff, *Statistical Regression and Classification: From Linear Modeling to Machine Learning*. Taylor & Francis, 2017.
- [155] S. Weisberg, “Linear Hypothesis: Regression (Basics),” in *International Encyclopedia of the Social & Behavioral Sciences: Second Edition*, Second Edi., vol. 13, Elsevier, 2015, pp. 153–156.
- [156] Stanford Weisberg, *Applied linear regression*, 3rd ed. John Wiley & Sons, 2005.
- [157] M. Gülcür and B. Whiteside, “A study of micromanufacturing process fingerprints in micro-injection moulding for machine learning and Industry,” 2021.
- [158] M. Rodríguez-Martín, J. G. Fueyo, D. Gonzalez-Aguilera, F. J. Madruga, R. García-Martín, A. L. Muñoz, and J. Pisonero, “Predictive models for the characterization of internal defects in additive materials from active thermography sequences supported by machine learning methods,” *Sensors (Switzerland)*, vol. 20, no. 14, pp. 1–26, 2020.
- [159] N. A. Fountas, P. Kostazos, H. Pavlidis, V. Antoniou, D. E. Manolakos, and N. M. Vaxevanidis, “Experimental investigation and statistical modelling for assessing the tensile properties of FDM fabricated parts,” *Procedia Struct. Integr.*, vol. 26, no. 2019, pp. 139–146, 2020.
- [160] C. Blume, S. Blume, S. Thiede, and C. Herrmann, “Data-driven digital twins for technical building services operation in factories: A cooling tower case study,” *J. Manuf. Mater. Process.*, vol. 4, no. 4, 2020.
- [161] R. B. Darlington and A. F. Hayes, *Regression Analysis and Linear Models: Concepts, Applications, and Implementation*. 2017.
- [162] R. Christensen, *Analysis of Variance, Design, and Regression*, 2nd ed. CRC press, 2016.
- [163] D. T. Larose and C. D. Larose, *Data Mining and Predictive Analytics*, 2nd ed. Wiley, 2015.
- [164] D. Nettleton, *Commercial Data Mining: Processing, Analysis and Modeling for Predictive Analytics Projects*. Morgan Kaufmann, 2014.
- [165] S. B. Green, “How Many Subjects Does It Take To Do A Regression Analysis,” *Multivariate Behav. Res.*, vol. 26, no. 3, pp. 499–510, 1991.
- [166] J. Cohen, P. Cohen, S. G. West, and L. S. Aiken, *Applied Multiple Regression/Correlation Analysis for the Behavioral Sciences*, Treće. 2003.
- [167] A. D. Gordon, *Classification*, 2nd ed. 1999.

- [168] D. Michie, D. J. Spiegelhalter, C. C. Taylor, and J. Campbell, *A method to quantify deviations from assay linearity*. 1994.
- [169] A. Qamar, M. A. Hall, D. Chicksand, and S. Collinson, “Quality and flexibility performance trade-offs between lean and agile manufacturing firms in the automotive industry,” *Prod. Plan. Control*, vol. 31, no. 9, pp. 723–738, 2020.
- [170] M. C. Yesilli and F. A. Khasawneh, “On transfer learning of traditional frequency and time domain features in turning,” *ASME 2020 15th Int. Manuf. Sci. Eng. Conf. MSEC 2020*, vol. 2, pp. 1–12, 2020.
- [171] A. Abdullahi, N. A. Samsudin, M. R. Ibrahim, M. S. Aripin, S. K. A. Khalid, and Z. A. Othman, “Towards IR4.0 implementation in e-manufacturing: Artificial intelligence application in steel plate fault detection,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 20, no. 1, pp. 430–436, 2020.
- [172] E. Ghasemi, A. Aghaie, and E. A. Cudney, “Mahalanobis Taguchi system: A review,” *Int. J. Qual. Reliab. Manag.*, vol. 32, no. 3, pp. 291–307, 2015.
- [173] T. Asakura, W. Yashima, K. Suzuki, and M. Shimotou, “Anomaly detection in a logistic operating system using the mahalanobis-taguchi method,” *Appl. Sci.*, vol. 10, no. 12, 2020.
- [174] T. Watanabe, I. Kono, and H. Onozuka, “Anomaly detection methods in turning based on motor data analysis,” *Procedia Manuf.*, vol. 48, no. 2019, pp. 882–893, 2020.
- [175] J. D. Kelleher, B. Mac Namee, and A. D’Arcy, *Fundamentals of Machine Learning for Predictive Data Analytics*, 1st ed. The MIT Press, 2015.
- [176] E. A. Cudney, D. Drain, K. Paryani, and N. Sharma, “A Comparison of the Mahalanobis-Taguchi System to A Standard Statistical Method for Defect Detection,” *J. Ind. Syst. Eng.*, vol. 2, no. 4, pp. 250–258, 2009.
- [177] P. C. Mahalanobis, “On the generilised distance in statistics,” *Proc. Natl. Inst. Sci. India*, vol. 2, no. 1, pp. 49–55, 1936.
- [178] G. Taguchi, S. Chowdhury, and Y. Wu, *Taguchi’s Quality Engineering Handbook*. 2007.
- [179] K. Arai and T. Ueda, “Data Analysis for Stabilizing Product Quality and the Mahalanobis Taguchi (MT) Method,” 2016.
- [180] P. Hu, S. Dhelim, H. Ning, and T. Qiu, “Survey on fog computing: architecture, key technologies, applications and open issues,” *J. Netw. Comput. Appl.*, vol. 98, no. September, pp. 27–42, 2017.
- [181] B. Yenidünya, “Robust Design With Binary Response Using Mahalanobis Taguchi System,” 2009.
- [182] S. Raschka i V. Mirjalili, *Python mašinsko učenje*, 3rd ed.,. 2020.
- [183] O. Abdelrahman and P. Keikhosrokiani, “Assembly Line Anomaly Detection and Root

- Cause Analysis Using Machine Learning,” *IEEE Access*, vol. 8, pp. 189661–189672, 2020.
- [184] J. Đ. Novaković, *Rešavanje klasifikacionih problema mašinskog učenja*, 1st ed., vol. 4. Fakultet tehničkih nauka u Čačku, 2013.
- [185] D. Abbott, *Applied Predictive Analytics: Principles and Techniques for the Professional Data Analyst*, 1st ed. Wiley, 2014.
- [186] H. Khalid, “Implementation of artificial neural network to achieve speed control and power saving of a belt conveyor system,” *Eastern-European J. Enterp. Technol.*, vol. 2, no. 2, pp. 44–53, 2021.
- [187] H. Tercan, P. Deibert, and T. Meisen, “Continual learning of neural networks for quality prediction in production using memory aware synapses and weight transfer,” *J. Intell. Manuf.*, pp. 1–10, 2021.
- [188] C.-C. Lin and H.-Y. Tseng, “A neural network application for reliability modelling and condition-based,” *Int J Adv Manuf Technol*, vol. 23, pp. 174–179, 2005.
- [189] G. Hackeling, *Mastering Machine Learning with scikit-learn*, 1st ed. Packt Publishing, 2014.
- [190] K. L. Du, “Clustering: A neural network approach,” *Neural Networks*, vol. 23, pp. 89–107, 2010.
- [191] A. Rikalović, “Razvoj modela za izbor lokacije proizvodnih sistema,” 2014.
- [192] C. Cortes and V. Vapnik, “Support-Vector Networks,” *Mach. Learn.*, vol. 297, pp. 273–297, 1995.
- [193] Y. G. Oh, M. Busogi, K. Ransikarbum, D. Shin, D. Kwon, and N. Kim, “Real-time quality monitoring and control system using an integrated cost effective support vector machine,” *J. Mech. Sci. Technol.*, vol. 33, no. 12, pp. 6009–6020, 2019.
- [194] M. Nikolić i A. Zečević, *Mašinsko učenje*. 2019.
- [195] I. H. Sarker, “Machine Learning: Algorithms, Real - World Applications and Research Directions,” *SN Comput. Sci.*, vol. 2, no. 160, pp. 1–21, 2021.
- [196] Z. Hu, Z. Hu, and X. Du, “One-class support vector machines with a bias constraint and its application in system reliability prediction,” *Artif. Intell. Eng. Des. Anal. Manuf.*, vol. 33, no. 3, pp. 346–358, 2019.
- [197] B. Scholkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson, “Estimating the Support of a High-Dimensional Distribution,” *Neural Comput.*, vol. 13, pp. 1443–1471, 2001.
- [198] A. Bounsiar and M. G. Madden, “One-Class Support Vector Machines Revisited,” pp. 31–34, 2014.
- [199] C. Li, D. Cabrera, F. Sancho, M. Cerrada, R. Sánchez, and E. Estupinan, “From fault detection to one-class severity discrimination of 3D printers with one-class support

- vector machine,” *ISA Trans.*, 2020.
- [200] N. Shahid, I. H. Naqvi, and S. Bin Qaisar, “One-class support vector machines: analysis of outlier detection for wireless sensor networks in harsh environments,” *Artif. Intell. Rev.*, vol. 43, no. 4, pp. 515–563, 2015.
- [201] K. Zope, K. Singh, S. H. Nistala, A. Basak, P. Rathore, and V. Runkana, “Anomaly Detection and Diagnosis in Manufacturing Systems: A Comparative Study of Statistical, Machine Learning and Deep Learning Techniques,” *Proc. Annu. Conf. Progn. Heal. Manag. Soc.*, vol. 11, no. 1, pp. 1–10, 2019.
- [202] G. Cohen, M. Hilario, and C. Pellegrini, “One-Class Support Vector Machines with a Conformal Kernel. A Case Study in Handling Class Imbalance,” in *Lecture Notes in Computer Science* , 2004, no. May 2014, pp. 1–10.
- [203] M. Award and R. Khanna, *Efficient Learning Machines*.
- [204] H. Cai, J. Feng, F. Zhu, Q. Yang, X. Li, and J. Lee, “Adaptive Virtual Metrology Method Based on Just-in-time Reference and Particle Filter for Semiconductor Manufacturing,” *Measurement*, p. 108338, 2020.
- [205] S. Jueyendah, M. Lezgy-nazargah, H. Eskandari-naddaf, and S. A. Emamian, “Predicting the mechanical properties of cement mortar using the support vector machine approach,” no. April, 2021.
- [206] L. Breiman, “Random Forests,” *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001.
- [207] L. Breiman, “Random Forests,” 2001.
- [208] M. Schonlau and R. Y. Zou, “The random forest algorithm for statistical learning,” *Stata J.*, vol. 20, no. 1, pp. 3–29, 2020.
- [209] L. Pavlović, D. B. Stojanović, M. Kresoja, S. Stjepanović, S. Orlović, i M. Bojović, “Razvoj modela potencijalne distribucije vrsta pomoću metoda mašinskog učenja,” *Topola No 199/200*, vol. 199/200, pp. 167–175, 2017.
- [210] W. Sillvan, *Machine Learning For Beginners Guide Algorithms: Decision Tree & Random Forest Introduction*. 2017.
- [211] R. Li, M. Jin, and V. C. Paquit, “Materials & Design Geometrical defect detection for additive manufacturing with machine learning models,” *Mater. Des.*, vol. 206, p. 109726, 2021.
- [212] H. Zhou, K. Yu, Y. Chen, and H. Hsu, “A Hybrid Feature Selection Method RFSTL for Manufacturing Quality Prediction Based on a High Dimensional Imbalanced Dataset,” vol. XX, 2021.
- [213] Z. Shahbazi, “Smart Manufacturing Real-Time Analysis Based on Blockchain and Machine Learning Approaches,” 2021.
- [214] S. Ayvaz and K. Alpay, “Predictive maintenance system for production lines in

- manufacturing: A machine learning approach using IoT data in real-time,” *Expert Syst. Appl.*, vol. 173, no. September 2020, p. 114598, 2021.
- [215] J. Lukasiewicz, “O logice trojwartosciowej,” *Ruch Filoz.*, vol. 5, 1920.
- [216] L. A. Zadeh, “Fuzzy sets,” *Inf. Control*, vol. 8, pp. 338–353, 1965.
- [217] Z. Radovanović, A. Rikalović, N. Ralević, Z. Tešić, N. Simeunović, and B. Bajić, “Fuzzy Expert System for Risk Assessment after Nipple-Sparing Mastectomy in Breast Cancer Patients,” *EUROCON 2019 - 18th Int. Conf. Smart Technol.*, 2019.
- [218] L. Felipe, L. Oct, P. Ivson, R. Goyannes, D. Luiz, M. de Nascimento, J. A. Garza-reyes, “A fuzzy rule-based industry 4.0 maturity model for operations and supply chain management,” *Int. J. Prod. Econ.*, vol. 231, no. July 2020, 2021.
- [219] Y. H. Choi, G. Y. Na, and J. Yang, “Fuzzy-inference-based decision-making method for the systematization of statistical process capability control,” *Comput. Ind.*, vol. 123, p. 103296, 2020.
- [220] V. E. Mirzakhanov, “Value of fuzzy logic for data mining and machine learning: A case study,” *Expert Syst. Appl.*, vol. 162, p. 113781, 2020.
- [221] J. W. Koo, S. W. Wong, G. Selvachandran, H. V. Long, and L. H. Son, “Prediction of Air Pollution Index in Kuala Lumpur using fuzzy time series and statistical models,” *Air Qual. Atmos. Heal.*, vol. 13, no. 1, pp. 77–88, 2020.
- [222] G. Panić, “Razvoj namenskog sistema fazi logike za primenu u sistemima za upravljanje xml dokumentima,” 2013.
- [223] S. Škrbić, “Upotreba fazi logike u relacionim bazama podataka,” 2008.
- [224] J. Ren, *Fuzzy Logic in Control Fuzzy Logic*. 1995.
- [225] C. von Altrock, “Fuzzy Logic in Automotive Engineering,” *Circut Cellat INK - the computer application journal*, no. 88, pp. 1–9, 1997.
- [226] V. M. Gajović and M. V. Paunović, “Primena fazi matematike u oceni rizika u osiguranju,” *Tok. osiguranja*, vol. 1, pp. 7–22, 2018.
- [227] P. Vadapalli, “Fuzzy Inference System: Overview, Applications, Characteristics, Structure & Advantages,” *Up Grad*, 2021. [Online]. Available: <https://www.upgrad.com/blog/fuzzy-inference-system/>.
- [228] C. C. Lee, “Fuzzy Logic in Control Systems: Fuzzy Logic Controller, Part II,” *IEEE Trans. Syst. Man. Cybern.*, vol. 20, no. 2, pp. 419–435, 1990.
- [229] “Uredba o klasifikaciji delatnosti,” *Službenom Glas. Republike Srb.*, vol. 54, 2010.
- [230] I. Engineering, “Analysis of companies’ digital maturity by 2 hesitant fuzzy linguistic MCDM methods,” *J. Intell. Fuzzy Syst.*, vol. 38, no. 1, pp. 1119–1132, 2019.
- [231] A. Schumacher, S. Erol, and W. Sihn, “A maturity model for assessing Industry 4.0

- readiness and maturity of manufacturing enterprises,” *Procedia CIRP*, vol. 52, pp. 161–166, 2016.
- [232] “Industrie 4.0-Readiness-Check,” *Impuls-Stiftung des VDMA*, 2021. [Online]. Available: <https://www.industrie40-readiness.de/index.php>. [Accessed: 27-Apr-2021].
- [233] D. Dikhanbayeva, S. Shaikholla, Z. Suleiman, and A. Turkyilmaz, “Assessment of Industry 4.0 Maturity Models by Design Principles,” *Sustain.*, vol. 12, no. 9927, pp. 1–22, 2020.
- [234] M. P. Ciano, P. Dallasega, G. Orzes, and T. Rossi, “One-to-one relationships between Industry 4.0 technologies and Lean Production techniques: a multiple case study,” *Int. J. Prod. Res.*, vol. 59, no. 5, pp. 1386–1410, 2021.
- [235] M. Ebrahimi, A. Baboli, and E. Rother, “The evolution of world class manufacturing toward Industry 4.0: A case study in the automotive industry,” *IFAC-PapersOnLine*, vol. 52, no. 10, pp. 188–194, 2019.
- [236] A. C. Pereira, J. Dinis-Carvalho, A. C. Alves, and P. Arezes, “How Industry 4.0 can enhance lean practices,” *FME Trans.*, vol. 47, no. 4, pp. 810–822, 2019.
- [237] G. L. Tortorella and D. Fettermann, “Implementation of industry 4.0 and lean production in brazilian manufacturing companies,” *Int. J. Prod. Res.*, vol. 56, no. 8, pp. 2975–2987, 2018.
- [238] S. Singh, B. Mahanty, and M. K. Tiwari, “Framework and modelling of inclusive manufacturing system,” *Int. J. Comput. Integr. Manuf.*, vol. 32, no. 2, pp. 105–123, 2018.
- [239] Z. Li, Y. Wang, and K. S. Wang, “Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario,” *Adv. Manuf.*, vol. 5, no. 4, pp. 377–387, 2017.
- [240] I. K. Fodor, “A survey of dimension reduction techniques,” *Library (Lond.)*, vol. 18, no. 1, pp. 1–18, 2002.
- [241] I. T. Jollife and J. Cadima, “Principal component analysis: A review and recent developments,” *Philos. Trans. R. Soc. A Math. Phys. Eng. Sci.*, vol. 374, no. 2065, pp. 1–16, 2016.
- [242] I. Hull, *Machine Learning for Economics and Finance in TensorFlow 2*. 2021.
- [243] T. Cleff, “Factor Analysis,” in *Applied Statistics and Multivariate Data Analysis for Business and Economics*, 2019, pp. 433–446.
- [244] A. Smith, F. Gu, and A. D. Ball, “An Approach to Reducing Input Parameter Volume for Fault Classifiers.”
- [245] Z. Shahbazi and Y.-C. Byun, “Integration of Blockchain, IoT and Machine Learning for Multistage Quality Control and Enhancing Security in Smart Manufacturing,” *Sensors (Switzerland)*, vol. 21, no. 1467, pp. 1–21, 2021.

- [246] C. A. Escobar and R. Morales-menendez, “Machine learning techniques for quality control in high conformance manufacturing environment,” vol. 10, no. 2, pp. 1–16, 2018.
- [247] K. Kammerer, B. Hoppenstedt, R. Pryss, S. Stökler, J. Allgaier, and M. Reichert, “Anomaly Detections for Manufacturing Systems Based on Sensor Data — Insights into Two Challenging Real-World Production Settings,” *Sensors (Switzerland)*, vol. 19, no. 5370, pp. 1–18, 2019.
- [248] A. Gholamy, V. Kreinovich, and O. Kosheleva, “Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation,” 2018.
- [249] V. Miškovic, “Primena metoda mašinskog učenja u procesu razvoja informacionih sistema,” in *Naučni skup sa međunarodnim učešćem Sinergija 2010*, 2010, pp. 185–191.
- [250] M. El-Banna, “Modified Mahalanobis-Taguchi System for Imbalance Data Classification,” *Comput. Intell. Neurosci.*, vol. 2017, 2017.

Овај Образац чини саставни део докторске дисертације, односно докторског уметничког пројекта који се брани на Универзитету у Новом Саду. Попуњен Образац укоричити иза текста докторске дисертације, односно докторског уметничког пројекта.

План третмана података

Назив пројекта/истраживања
Модел за рано откривање неусаглашености процесних параметара у производним системима
Назив институције/институција у оквиру којих се спроводи истраживање
a) Факултет техничких наука, Универзитет у Новом Саду б) Производни систем процесне индустрије за производњу подних облога од винила
Назив програма у оквиру ког се реализује истраживање
Истраживање је реализовано за потребе израде докторске дисертације на Департману за индустриско инжењерство/инжењерски менаџмент.
1. Опис података
1.1 Врста студије <i>Укратко описати тип студије у оквиру које се подаци прикупљају</i> Студија спроведена у оквиру дисертације је обухватила експериментално истраживање у циљу емпиријске верификације предложеног теоријског модела за рано откривање неусаглашености процесних параметара у производним системима. 1.2 Врсте података а) квантитативни б) квалитативни 1.3. Начин прикупљања података а) анкете, упитници, тестови б) клиничке процене, медицински записи, електронски здравствени записи в) генотипови: навести врсту _____ г) административни подаци: навести врсту _____ д) узорци ткива: навести врсту _____ ђ) снимци, фотографије: навести врсту _____ е) текст, навести врсту _____

ж) мапа, навести врсту _____

з) остало: процесни подаци прикупљени из производног система

1.3 Формат података, употребљене скале, количина података

1.3.1 Употребљени софтвер и формат датотеке:

- a) Excel фајл, датотека .csv
- b) SPSS фајл, датотека _____
- c) PDF фајл, датотека _____
- d) Текст фајл, датотека _____
- e) JPG фајл, датотека _____
- f) Остало, датотека _____

1.3.2. Број записа (код квантитативних података)

а) број варијабли: 15

б) број мерења (испитаника, процена, снимака и сл.): 1.960.200 процесних података

1.3.3. Поновљена мерења

а) да

б) не

Уколико је одговор да, одговорити на следећа питања:

- а) временски размак између поновљених мера је два месеца
- б) варијабле које се више пута мере односе се на утицајне процесне параметре
- в) нове верзије фајлова који садрже поновљена мерења су именоване као LOG2

Напомене: Мерења су понављана у циљу спровођења нових експеримената коришћењем процесних података.

Да ли формати и софтвер омогућавају дељење и дугорочну валидност података?

а) Да

б) Не

Ако је одговор не, образложити _____

2. Прикупљање података

2.1 Методологија за прикупљање/генерисање података

2.1.1. У оквиру ког истраживачког нацрта су подаци прикупљени?

а) експеримент, навести тип: експеримент у производном систему процесне индустрије

б) корелационо истраживање, навести тип _____

ц) анализа текста, навести тип: систематски преглед релевантне литературе

д) остало, навести шта _____

2.1.2 Навести врсте мерних инструмената или стандарде података специфичних за одређену научну дисциплину (ако постоје).

Сензори на машинама у производном систему, PLC уређаји, Индустриски рачунар заснован на Edge систему рачунарске технологије

2.2 Квалитет података и стандарди

2.2.1. Третман недостајућих података

а) Да ли матрица садржи недостајуће податке? Да **Не**

Ако је одговор да, одговорити на следећа питања:

а) Колики је број недостајућих података? _____

б) Да ли се кориснику матрице препоручује замена недостајућих података? Да **Не**

в) Ако је одговор да, навести сугестије за третман замене недостајућих података

2.2.2. На који начин је контролисан квалитет података? Описати

Подаци су припремљени и обрађени у складу са предложеном методологијом за развој модела за рано откривање неусаглашености процесних параметара.

2.2.3. На који начин је извршена контрола уноса података у матрицу?

Подаци су се аутоматски записивали у матрицу у тренутку њиховог генерисања.

3. Третман података и пратећа документација

3.1. Третман и чување података

3.1.1. Подаци ће бити депоновани у личну архиву кандидаткиње Bojanе Bajiћ.

3.1.2. URL адреса _____

3.1.3. DOI _____

3.1.4. Да ли ће подаци бити у отвореном приступу?

a) Да

b) Да, али после ембарга који ће трајати до _____

c) Не

Ако је одговор не, навести разлог: Подаци су власништво производног система за производњу подних облога од винила и не представљају јавно доступне податке.

3.1.5. Подаци неће бити депоновани у репозиторијум, али ће бити чувани.

Образложение

Подаци, на основу којих је рађен експериментални део доктората, неће бити депоновани у репозиторијум из разлога што нису приватно власништво кандидаткиње Бојане Бајић, већ припадају правном лицу, те ће у складу са тим бити чувани у личној архиви кандидаткиње.

3.2 Метаподаци и документација података

3.2.1. Који стандард за метаподатке ће бити примењен?

3.2.1. Навести метаподатке на основу којих су подаци депоновани у репозиторијум.

Ако је потребно, навести методе које се користе за преузимање података, аналитичке и процедуралне информације, њихово кодирање, детаљне описе варијабли, записа итд.

3.3 Стратегија и стандарди за чување података

3.3.1. До ког периода ће подаци бити чувани у репозиторијуму? **Неограничено**

3.3.2. Да ли ће подаци бити депоновани под шифром? Да **Не**

3.3.3. Да ли ће шифра бити доступна одређеном кругу истраживача? Да **Не**

3.3.4. Да ли се подаци морају уклонити из отвореног приступа после извесног времена?

Да **Не**

Образложити

4. Безбедност података и заштита поверљивих информација

Овај одељак МОРА бити попуњен ако ваши подаци укључују личне податке који се односе на учеснике у истраживању. За друга истраживања треба такође размотрити заштиту и сигурност података.

4.1 Формални стандарди за сигурност информација/података

Истраживачи који спроводе испитивања с људима морају да се придржавају Закона о заштити података о личности (https://www.paragraf.rs/propisi/zakon_o_zastiti_podataka_o_licnosti.html) и одговарајућег институционалног кодекса о академском интегритету.

4.1.2. Да ли је истраживање одобрено од стране етичке комисије? Да **Не**

Ако је одговор Да, навести датум и назив етичке комисије која је одобрила истраживање

4.1.2. Да ли подаци укључују личне податке учесника у истраживању? Да **Не**

Ако је одговор да, наведите на који начин сте осигурали поверљивост и сигурност информација везаних за испитанике:

- a) Подаци нису у отвореном приступу
 - б) Подаци су анонимизирани
 - ц) Остало, навести шта
-
-

5. Доступност података

5.1. Подаци ће бити

- a) јавно доступни
- б) доступни само у скромном кругу истраживача у одређеној научној области
- ц) затворени

Ако су подаци доступни само у скромном кругу истраживача, навести под којим условима могу да их користе:

Ако су подаци доступни само уском кругу истраживача, навести на који начин могу приступити подацима:

5.4. Навести лиценцу под којом ће прикупљени подаци бити архивирани.

ауторство – некомерцијално - без прераде

6. Улоге и одговорност

6.1. Навести име и презиме и мејл адресу власника (аутора) података

Бојана Бајић, bojana.bajic@uns.ac.rs

6.2. Навести име и презиме и мејл адресу особе која одржава матрицу с подацима

Бојана Бајић, bojana.bajic@uns.ac.rs

6.3. Навести име и презиме и мејл адресу особе која омогућује приступ подацима другим истраживачима

Бојана Бајић, bojana.bajic@uns.ac.rs