



УНИВЕРЗИТЕТ У НОВОМ САДУ  
ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА У  
НОВОМ САДУ

---



Лука Мејић

# Методe аутоматске конфигурације софт сензора

ДОКТОРСКА ДИСЕРТАЦИЈА

Нови Сад, 2019.



УНИВЕРЗИТЕТ У НОВОМ САДУ • ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА  
21000 НОВИ САД, Трг Доситеја Обрадовића 6

## КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА

Редни број, <b>РБР:</b>	
Идентификациони број, <b>ИБР:</b>	
Тип документације, <b>ТД:</b>	Монографска документација
Тип записа, <b>ТЗ:</b>	Текст, штампани материјал
Врста рада, <b>ВР:</b>	Докторска дисертација
Аутор, <b>АУ:</b>	Лука Мејић
Ментор, <b>МН:</b>	др Војин Илић, ванредни професор
Наслов рада, <b>НР:</b>	Методе аутоматске конфигурације софтверског сензора
Језик публикације, <b>ЈП:</b>	Српски
Језик извода, <b>ЈИ:</b>	Српски/Енглески
Земља публикације, <b>ЗП:</b>	Република Србија
Уже географско подручје, <b>УГП:</b>	АП Војводина
Година, <b>ГО:</b>	2019
Издавач, <b>ИЗ:</b>	Ауторски репринт
Место и адреса, <b>МА:</b>	Факултет техничких наука, 21 000 Нови Сад, Трг Доситеја Обрадовића 6
Физички опис рада, <b>ФО:</b> (поглавља/страна/ цитата/табела/слика/графика/прилога)	9/88/64/22/29/0/0
Научна област, <b>НО:</b>	Електротехничко и рачунарско инжењерство
Научна дисциплина, <b>НД:</b>	Аутоматика и управљање системима
Предметна одредница/Кључне речи, <b>ПО:</b>	Софтверски сензори, вештачке неуронске мреже са радијално базираним функцијама, оптималан сет улаза у софтверски сензор, кашњење улаза, аутоматска конфигурација
<b>УДК</b>	
Чува се, <b>ЧУ:</b>	Библиотека Факултета техничких наука, Универзитет Нови Сад
Важна напомена, <b>ВН:</b>	
Извод, <b>ИЗ:</b>	Математички модели за естимацију тешко мерљивих величина називају се софтверским сензорима. Процес формирања софтверског сензора није тривијалан и квалитет естимације тешко мерљиве величине директно зависи од начина формирања. Недомаћи постојећих алгоритама за формирање спречавају аутоматску конфигурацију софтверског сензора. У овом раду су реализовани нови алгоритми који имају за сврху аутоматизацију конфигурације софтверског сензора. Реализовани алгоритми решавају проблеме проналазке оптималног сета улаза у софтверски сензор и кашњења сваког од њих као и одабира структуре и начина обуке софтверског сензора заснованих на вештачким неуронским мрежама са радијално базираним функцијама.
Датум прихватања теме, <b>ДП:</b>	30.05.2019.
Датум одбране, <b>ДО:</b>	
Чланови комисије, <b>КО:</b>	Председник: др Никола Јорговановић, редовни професор
	Члан: др Александар Ердељан, редовни професор
	Члан: др Страхиња Дошен, ванредни професор
	Члан: др Дубравка Бојанић, ванредни професор
	Члан: др Дарко Станишић, доцент
	Члан, ментор: др Војин Илић, ванредни професор
	Потпис ментора



## KEY WORDS DOCUMENTATION

Accession number, <b>ANO</b> :		
Identification number, <b>INO</b> :		
Document type, <b>DT</b> :	Monographic documentation	
Type of record, <b>TR</b> :	Text, printed material	
Contents code, <b>CC</b> :	PhD thesis	
Author, <b>AU</b> :	Luka Mejić	
Mentor, <b>MN</b> :	Vojin Ilić, PhD, associate professor	
Title, <b>TI</b> :	Methods for automatic configuration of soft sensors	
Language of text, <b>LT</b> :	Serbian	
Language of abstract, <b>LA</b> :	Serbian/ English	
Country of publication, <b>CP</b> :	Republic of Serbia	
Locality of publication, <b>LP</b> :	AP of Vojvodina	
Publication year, <b>PY</b> :	2019	
Publisher, <b>PB</b> :	Autor reprint	
Publication place, <b>PP</b> :	Faculty of Technical Sciences, 21 000 Novi Sad, Trg DositejaObradovića 6	
Physical description, <b>PD</b> : <small>(chapters/pages/ref./tables/pictures/graphs/appendixes)</small>	9/88/64/22/29/0/0	
Scientific field, <b>SF</b> :	Electrical and Computer Engineering	
Scientific discipline, <b>SD</b> :	Automation and Control Systems	
Subject/Key words, <b>S/KW</b> :	Soft sensors, artificial radial basis function networks, optimal set of soft sensor inputs, dead time, automatic configuration	
<b>UC</b>		
Holding data, <b>HD</b> :	Library of the Faculty of Technical Sciences, University of Novi Sad	
Note, <b>N</b> :		
Abstract, <b>AB</b> :	Mathematical models that are used for estimation of variables that can not be measured in real time are called soft sensors. Creation of soft sensor is a complex process and quality of estimation depends on the way soft sensor is created. Restricted applicability of existing algorithms is preventing automatic configuration of soft sensors. This paper presents new algorithms that are providing automatic configuration of soft sensors. Presented algorithms are capable of determining optimal subset of soft sensor inputs and their time delays, as well as optimal architecture and automatic training of the soft sensors that are based on artificial radial basis function networks.	
Accepted by the Scientific Board on, <b>ASB</b> :	30.05.2019.	
Defended on, <b>DE</b> :		
Defended Board, <b>DB</b> :		
President:	Nikola Jorgovanović, PhD, full professor	Mentor's sign
Member:	Aleksandar Erdeljan, PhD, full professor	
Member:	Strahinja Došen, PhD, associate professor	
Member:	Dubravka Bojanić, PhD, associate professor	
Member:	Darko Stanišić, PhD, assistant professor	
Member, Mentor:	Vojin Ilić, PhD, associate professor	

# Захвалница

Пре свега, желим да се захвалим свом ментору и колегама уз помоћ чијих коментара, смерница и критика је квалитет ове докторске дисертације доведен на виши ниво. Част је бити у таквом тиму.

Највећу захвалност ипак дугујем својој породици, девојци и осталим најближим на свакодневној безрезервној подршци и љубави.

Лука Мејић

# Садржај

1	Увод	1
2	Процес добијања цемента	7
2.1	Ток материјала . . . . .	8
2.2	Млин . . . . .	10
2.3	Сепаратор . . . . .	13
2.4	Квантификовање финоће цемента . . . . .	15
3	Индустријски софт сензори	17
4	Алгоритам за одређивање оптималног скупа улаза у софт сензор и кашњења сваког од њих	24
4.1	Алгоритам за одређивање улаза базиран на теорији информација . . . . .	25
4.2	Оптимизациони алгоритам претраге простора скупова улазних сигнала и њихових кашњења . . . . .	28
5	Софт сензори засновани на вештачким неуронским мрежама са радијално базираним функцијама	32
5.1	Архитектура вештачких неуронских мрежа са радијално базираним функцијама . . . . .	33
5.2	Хибридни алгоритам обуке вештачких неуронских мрежа са радијално базираним функцијама . . . . .	35

6	Примена алгоритма за одређивање оптималног скупа улаза у софт сензор и кашњења сваког од њих	41
6.1	Верификација алгоритма употребом познатог скупа најбољих сигнала . . . . .	41
6.2	Примена алгоритма на реалним процесима производње цемента . . . . .	45
7	Примена хибридног алгоритма обуке вештачких неуронских мрежа са радијално базираним функцијама	58
7.1	Процес са композитним узорковањем . . . . .	60
7.2	Процес са спот узорковањем . . . . .	70
8	Анализа постигнутих резултата	80
9	Закључак	84
	Библиографија	89

## Списак скраћеница

АМО	- алгоритам максимизације очекивања
АООСУССК	- алгоритам за одређивање оптималног скупа улаза у софт сензор и кашњења сваког од њих
АОУТИ	- алгоритам одређивања улаза заснован на теорији информација
ВНМ-РБФ	- вештачке неуронске мреже са радијално базираним функцијама
ГА	- генетски алгоритам
ДПЦА	- динамичка анализа основних компоненти
КМ	- кластеризација методом К-средњих вредности
$P_{KY/CY}$	- процес са композитним/спот узорковањем
ПЦА	- анализа основних компоненти
РФ	- Росенброкова функција
$C_{1/2/3/4/5}^{P_{KY/CY}}$	- $P_{KY/CY}$ Скуп сигнала 1/2/3/4/5
$C_{1/2/3}^{RF}$	- РФ Скуп сигнала 1/2/3
САГ	- средња апсолутна грешка
СМ	- самоорганизујуће мапе
$CF_{1/2/3}^{P_{KY/CY}}$	- $P_{KY/CY}$ Софт сензор 1/2/3
X1/2/3/4	- хипотеза 1/2/3/4
ХК	- хијерархијска кластеризација

## Списак слика

2.1	Упрошћена шема процеса добијања цемента . . . . .	8
2.2	Попречни пресек хоризонтално постављеног млина . . . . .	11
2.3	Трајекторија кугли унутар различитих комора . . . . .	12
2.4	Попречни пресек сепаратора високог степена ефикасности, преузет из [18] . . . . .	14
4.1	Алгоритам тока сигнала рачунарске имплементације функ- ције оцене квалитета . . . . .	31
5.1	Архитектура вештачке неуронске мреже са радијално бази- раним функцијама . . . . .	33
5.2	Алгоритам тока сигнала рачунарске имплементације кла- стеризације методом К-средњих вредности . . . . .	36
5.3	Алгоритам тока сигнала рачунарске имплементације хибрид- ног алгоритма обуке вештачких неуронских мрежа са ради- јално базираним функцијама . . . . .	40
6.1	Конвергенција генетског алгоритма и раст количине ин- формација - Росенброкова функција . . . . .	44
6.2	Графичка репрезентација различитих типова узорковања .	47
6.3	Конвергенција оптимизационог алгоритма у случају одаби- ра скупа сигнала $C_1^{Пкy}$ . . . . .	50



6.4	Кумулативна количина информација о финоћи цемента коју садрже сигнали одређени предложеним алгоритмом (обележено црвеном континуалном линијом) и сигнали изабрани у раду [41] (обележено плавом испрекиданом линијом) - $\Pi_{\text{КУ}}$ . . . . .	52
6.5	Конвергенција оптимизационог алгоритма у случају одабира сигнала $C_4^{\text{ПСУ}}$ . . . . .	55
6.6	Кумулативна количина информација о финоћи цемента коју садрже сигнали одређени предложеним алгоритмом (обележено црвеном континуалном линијом) и сигнали приближно закашњени (обележено плавом испрекиданом линијом) - $\Pi_{\text{СУ}}$ . . . . .	57
7.1	Конвергенција хибридног алгоритма обуке у случају коришћења сигнала из Табеле 6.5 - $\text{Сф}C_1^{\text{ПКУ}}$ . . . . .	62
7.2	Конвергенција хибридног алгоритма обуке у случају коришћења сигнала из Табеле 6.6 - $\text{Сф}C_2^{\text{ПКУ}}$ . . . . .	63
7.3	Упоредни приказ естимација $\text{Сф}C_1^{\text{ПКУ}}$ и $\text{Сф}C_2^{\text{ПКУ}}$ над делом валидационог скупа . . . . .	64
7.4	Упоредни приказ естимација $\text{Сф}C_1^{\text{ПКУ}}$ и $\text{Сф}C_3^{\text{ПКУ}}$ над делом валидационог скупа . . . . .	66
7.5	Упоредни приказ естимација $\text{Сф}C_1^{\text{ПКУ}}$ и $\text{Сф}C_3^{\text{ПКУ}}$ над делом валидационог скупа уколико је сигнал ротационе брзине сепаратора зашумљен . . . . .	68
7.6	Упоредни приказ делова естимација у реалном времену $\text{Сф}C_1^{\text{ПКУ}}$ и $\text{Сф}C_3^{\text{ПКУ}}$ при тромесечној евалуацији . . . . .	69
7.7	Конвергенција хибридног алгоритма обуке у случају коришћења сигнала из Табеле 6.9 - $\text{Сф}C_1^{\text{ПСУ}}$ . . . . .	71
7.8	Конвергенција хибридног алгоритма обуке у случају коришћења сигнала из Табеле 6.10 - $\text{Сф}C_2^{\text{ПСУ}}$ . . . . .	72
7.9	Упоредни приказ естимација $\text{Сф}C_1^{\text{ПСУ}}$ и $\text{Сф}C_2^{\text{ПСУ}}$ над делом валидационог скупа . . . . .	73

7.10	Упоредни приказ естимација $SfC_1^{Pcsy}$ и $SfC_3^{Pcsy}$ над делом валидационог скупа . . . . .	75
7.11	Упоредни приказ естимација $SfC_1^{Pcsy}$ и $SfC_3^{Pcsy}$ над делом валидационог скупа када је сигнал ротационе брзине сепаратора зашумљен . . . . .	77
7.12	Упоредни приказ делова естимација у реалном времену $SfC_1^{Pcsy}$ и $SfC_3^{Pcsy}$ при тромесечној евалуацији . . . . .	78
8.1	Упоредни приказ квалитета естимација софт сензора истих архитектура, а различитог одабира улазних сигнала и њихових кашњења - $SfC_1^{Pkv}$ и $SfC_2^{Pkv}$ (са леве стране) и $SfC_1^{Pcsy}$ и $SfC_2^{Pcsy}$ (са десне стране) . . . . .	81
8.2	Упоредни приказ квалитета естимација софт сензора различитих архитектура, а истог одабира улазних сигнала и њихових кашњења - $SfC_1^{Pkv}$ и $SfC_3^{Pkv}$ (са леве стране) и $SfC_1^{Pcsy}$ и $SfC_3^{Pcsy}$ (са десне стране) . . . . .	82
8.3	Упоредни приказ квалитета естимација софт сензора различитих архитектура, а истог одабира улазних сигнала и њихових кашњења током тромесечне евалуације - $SfC_1^{Pkv}$ и $SfC_3^{Pkv}$ (горе) и $SfC_1^{Pcsy}$ и $SfC_3^{Pcsy}$ (доле) . . . . .	83

## Списак табела

2.1	Стандардни сигнали који се мере током процеса млевења цемента . . . . .	10
4.1	Матрица сигнала и њихових реплика . . . . .	27
6.1	Случајно изабрани сигнали и њихова кашњења за Росенброкову функцију . . . . .	42
6.2	Скупови сигнала одређени алгоритмом за Росенброкову функцију . . . . .	43
6.3	Кандидати за улазе у софт сензор - $P_{КУ}$ . . . . .	48
6.4	Број појављивања сваког подскупа сигнала - $P_{КУ}$ . . . . .	49
6.5	Сигнали и њихова кашњења - $C_1^{P_{КУ}}$ . . . . .	49
6.6	Скуп сигнала над којим је заснована естимација у раду [41]	51
6.7	Кандидати за улазе у софт сензор - $P_{СУ}$ . . . . .	53
6.8	Број појављивања сваког подскупа сигнала - $P_{СУ}$ . . . . .	53
6.9	Сигнали и њихова кашњења - $C_4^{P_{СУ}}$ . . . . .	56
6.10	Сигнали закашњени на основу визуелне инспекције - $P_{СУ}$ .	56
7.1	Преглед креираних софт сензора - $P_{КУ}$ . . . . .	61
7.2	Средња апсолутна грешка естимације $SfC_1^{P_{КУ}}$ и $SfC_2^{P_{КУ}}$ .	65
7.3	Средња апсолутна грешка естимације $SfC_1^{P_{КУ}}$ и $SfC_3^{P_{КУ}}$ .	65
7.4	Средња апсолутна грешка естимације $SfC_1^{P_{КУ}}$ и $SfC_3^{P_{КУ}}$ у случају зашумљеног сигнала ротационе брзине сепаратора	67
7.5	Средња апсолутна грешка естимације $SfC_1^{P_{КУ}}$ и $SfC_3^{P_{КУ}}$ током сваког месеца тромесечне евалуације . . . . .	70

Списак табела

---

7.6	Преглед креираних софт сензора - $\Pi_{\text{C}\Sigma}$ . . . . .	70
7.7	Средња апсолутна грешка естимације $\text{CfC}_1^{\Pi_{\text{C}\Sigma}}$ и $\text{CfC}_2^{\Pi_{\text{C}\Sigma}}$ .	74
7.8	Средња апсолутна грешка естимације $\text{CfC}_1^{\Pi_{\text{C}\Sigma}}$ и $\text{CfC}_3^{\Pi_{\text{C}\Sigma}}$ .	74
7.9	Средња апсолутна грешка естимације $\text{CfC}_1^{\Pi_{\text{C}\Sigma}}$ и $\text{CfC}_3^{\Pi_{\text{C}\Sigma}}$ када је сигнал ротационе брзине сепаратора зашумљен . . .	76
7.10	Средња апсолутна грешка естимације $\text{CfC}_1^{\Pi_{\text{C}\Sigma}}$ и $\text{CfC}_3^{\Pi_{\text{C}\Sigma}}$ током сваког месеца тромесечне евалуације . . . . .	79

# ГЛАВА 1

## Увод

Развојем технологије долази до све веће потражње за подизањем квалитета индустријских производа. У већини случајева ово није нимало једноставан задатак и захтева употребу лабораторијских анализа како би биле добијене вредности величина које представљају показатеље квалитета. Нажалост, лабораторијске анализе није могуће извршити у реалном времену и исте уносе значајна кашњења у динамику управљања индустријским процесима. Због претходно наведеног, неопходно је обезбедити другачији систем за мерење и анализу величина које нису мерљиве у реалном времену.

У многим индустријским процесима постоји потреба за претходно поменутиим лабораторијским анализама. Често су величине које захтевају овакве анализе од изузетне важности за индустријске процесе и управљање неким деловима процеса се заснива на истим. Самим тим, кашњење, које употреба лабораторијских анализа уноси, постаје главни узрочник неблаговремених реакција у управљању, које могу довести и до хаваријског стања процеса од интереса. Из овог разлога се посебна пажња посвећује развоју алгоритама за мерење или естимацију вредности величина показатеља квалитета у реалном времену.

Један од начина естимирања вредности величина јесте употреба прин-

ципа софт сензора. Наиме, математички модели који се употребљавају за естимацију величине од интереса називају се софт сензорима или виртуелним сензорима [1]. Софт сензори су нашли своју примену у широком опсегу индустријских процеса, од електрана, преко рафинерија и хемијске индустрије, па све до рударства, производње хране, итд [2, 3, 4, 5, 6, 7]. Формирање истих засновано је на историјским вредностима, како величине од интереса, тако и осталих процесних величина које су у корелацији са посматраном тешко мерљивом величином.

Процедуру формирања софт сензора могуће је поделити у неколико корака:

- Прикупљање и анализа података
- Избор улазних сигнала који садрже највише информација о жељеном излазном сигналу
- Избор структуре софт сензора
- Обука софт сензора
- Валидација софт сензора

Сваки од горе поменутих корака представља самосталну целину, па самим тим формирање софт сензора није једноставан процес, а уједино је и временски захтеван. У великом броју научних радова је наглашена комплексност и важност правилне реализације сваког од корака формирања софт сензора [8, 9, 10, 11, 12, 13, 14]. Такође је показано да начин формирања директно утиче на квалитет естимације. Стога су аутори радова [8, 9, 10, 11] тражили нове и упоређивали постојеће алгоритме за одређивање улазних сигнала који обезбеђују квалитетну естимацију софт сензора. Формирано је неколико различитих алгоритама, али је њихова примена изузетно ограничена. Само један од њих, оригинално представљен у [15], је могуће применити пре креирања софт сензора, док сви остали дају меру квалитета улазних сигнала или у фази обуке софт сензора или у фази примене. У [15] је представљена и потенцијална примена

приказаног алгоритма за одређивање кашњења улазних сигнала, али због итеративног извођења самог алгоритма, није истовремено могуће одређивати и најбоље улазне сигнале и њихова кашњења. Наиме, у процесима који су просторно дистрибуирани, промена вредности већине сигнала за закашњењем утиче на финални производ и стога је потребно одредити и најбоље улазне сигнале и кашњење сваког од њих. Употреба алгоритма из [15] за поменуту сврху је ограничена само на системе где су најбољи улазни сигнали унапред познати и мали је број сигнала са непознатим кашњењем (аутори су показали случај где постоје само два сигнала са непознатим кашњењем). Представљени недостаци постојећих алгоритама за одређивање улазних сигнала спречавају њихову примену за формирање софт сензора у процесима где постоје транспортни путеви. Као што је претходно поменуто, у оваквим процесима постоји потреба за истовременим одређивањем најбољих улазних сигнала и њихових кашњења и због тога постојећи алгоритми нису директно применљиви. Аутори радова [12, 13, 14] су показали да на квалитет естимације тешко мерљиве величине утиче и избор структуре и начин обуке софт сензора. За обуку софт сензора заснованих на вештачким неуронским мрежама са радијално базираним функцијама је у научној литератури могуће пронаћи два типа алгоритама [13, 14, 16, 17]. Први тип подешава параметре софт сензора употребом градијентног метода и метода пропагације грешке уназад [13, 14]. Директна зависност између броја радијалних функција у структури софт сензора и грешке естимације не постоји, те је код овог типа обуке потребно унапред дефинисати структуру што спречава аутоматско формирање софт сензора. Други тип обуке је заснован на коришћењу неког од алгоритама кластеризације података за одређивање центара радијалних функција, затим одређивању ширина тих функција на основу просторне дистрибуираности кластера и, на крају, употреби метода најмање квадратне грешке за одређивање тежине сваке радијалне функције [16, 17]. Иако је овај тип обуке потпуно аутоматски, недостатак је што се поменути начин одређивања ширина радијалних функција не гарантује минимална грешка естимације.

Представљени недостаци постојећих алгоритама спречавају аутоматизацију процеса формирања софт сензора. Стога је циљ овог рада креирање нових алгоритама који обезбеђују аутоматизовање, а самим тим и упрошћење, овог поступка. Поменути алгоритми применљиви су у широком спектру индустријских процеса, а употреба истих обезбеђује висок квалитет естимације формираног софт сензора.

Развој алгоритама за аутоматску конфигурацију се може поделити на два дела:

- Формирање алгорита за избор улазних сигнала и њихових кашњења који садрже највише информација о жељеном излазу
- Употреба информација добијених у претходном делу за естимацију тешко мерљиве величине коришћењем вештачких неуронских мрежа са радијално базираним функцијама

Први део обухвата први и други корак формирања софт сензора тј. прикупљање и анализу података и избор улазних сигнала који садрже највише информација о жељеном излазу. Други део обухвата преостала три корака формирања софт сензора. Резултат првог дела представља алгоритам за аутоматски избор улазних сигнала и њихових кашњења који поседују највише информација о тешко мерљивој величини. Овај алгоритам базиран је на генетском алгоритму и теорији информација. Резултат другог дела представља аутоматски алгоритам обуке вештачких неуронских мрежа са радијално базираним функцијама, који се заснива на алгоритму кластеризације методом  $K$ -средњих вредности (енгл. *k-means*), методу најмање квадратне грешке, градијентном методу и методу пропагације грешке уназад.

Приказане методе аутоматске конфигурације софт сензора су базиране на следећим хипотезама:

- Спрегом генетског алгорита и алгорита за одређивање количине информација коју потенцијални улазни сигнали садрже о сигналу



који представља излаз је могуће пронаћи скуп сигнала и њихових кашњења који би обезбедили квалитетну естимацију софт сензора. (X1)

- Вештачке неуронске мреже са радијално базираним функцијама је могуће користити у естимацији вредности тешко мерљивих величина индустријских процеса. (X2)
- Хибридни алгоритам обуке вештачких неуронских мрежа са радијално базираним функцијама заснован на кластеризацији података, градијентом методу и методу пропагације грешке уназад ће конвергирати. (X3)
- Софт сензори засновани на вештачким неуронским мрежама са радијално базираним функцијама ће бити минимално осетљиви на шум у улазним сигнаlima, који је неизбежни део већине мерења у индустријским процесима. (X4)

На основу постављених хипотеза, главни научни допринос овог рада се огледа у развоју алгоритама који би упростили креирање софт сензора и обезбедили висок квалитет естимације тешко мерљивих величина.

Рад је организован у девет поглавља.

Друго поглавље даје теоријске основе технологије процеса производње цемента, као тест окружења реализованих алгоритама. Приказани су физички принципи млевења цемента, као и начини одређивања и репрезентације вредности финоће цемента.

У трећем поглављу дат је опсежан преглед стања области формирања и употребе софт сензора. Приказани су проблеми са којима су се аутори сусретали приликом имплементације софт сензора, као и недостаци постојећих алгоритама.

Четврто поглавље даје детаљну анализу реализованог алгорита за избор улазних сигнала и њихових кашњења.

У петом поглављу је приказан хибридни алгоритам обуке софт сензора заснованих на вештачким неуронским мрежама са радијално базираним функцијама.

У шестом поглављу је приказана верификација и валидација алгорита за одређивање оптималног скупа улазних сигнала и њихових кашњења.

Седмо поглавље приказује примену реализованих алгоритама у процесу формирања софт сензора за естимацију финоће цемента.

Анализа добијених резултата заједно са дискусијом истих, приказана је у осмом поглављу.


Закључна разматрања као и правци даљег истраживања су приказани у деветом поглављу.

## Процес добијања цемента

Ради бољег разумевања потребе овог истраживања и лакшег разумевања добијених резултата, у овом поглављу приказан је процес добијања цемента. Детаљан опис процеса дат је у [18].

Кључни процес у добијању цемента у препознатљивом, прашкастом облику, јесте млевење разних сировинских материјала зарад добијања хомогеног прашка. Међу сировинским материјалима, количински је доминантан клинкер. Током процеса млевења тежи се значајном смањивању величине честица клинкера. Потреба за редукцијом величине честица произилази из тога да величина честица директно одређује брзину хидратације материјала, потребу за водом, а напоследку чврстоћу и композитност финалног производа – бетона. Повећавањем финоће цемента се побољшавају и особине финалног производа, као што су период везивања и почетна чврстоћа [19], међутим, повећава се и количина утрошене енергије. Стога је потребно постићи финоћу честица финалног производа - цемента, која обезбеђује тражене спецификације, а захтева минималан утрошак енергије.

## 2.1 Ток материјала



Слика 2.1: Упрощена шема процеса добијања цемента

Шематски приказ система за млевење цемента приказан је на Слици 2.1. На шеми су стрелицама приказани токови кретања материјала у процесу, а нумерички су означене и појединачне целине процеса.

У тачно одређеним размерама, које су дефинисане рецептуром фабрике за сваки тип цемента, клинкер и остали сировински материјали се допремају транспортним путевима од силоса, у којима су складиштени, до улаза у млин. У млину се ове сировине мељу од 10 до 40 минута, у зависности од типа цемента и фабрике. Цемент, који представља резултат процеса млевења, се транспортним путевима, који најчешће укључују кофичасте транспортере, допрема до места на ком је потребно одвојити цемент који испуњава услове спецификације жељеног типа од оног који не испуњава. Уређај за раздвајање честица назива се сепаратор. Део цемента који не испуњава услове спецификације, враћа се транспортним путевима у млин како би био додатно млевен. Део цемента који испуњава услове спецификације транспортује се до силоса и даље се дистрибуира као финални производ. На транспортном путу до силоса узимају се узорци како би лабораторијски била одређена финоћа производа. Ово је прво место на ком се одређује квалитет добијеног цемента и квалитет се одређује лабораторијском анализом због чега вредност финоће није могуће добити у реалном времену и врло често, услед тога, долази до закашњењих реакција у управљању сепаратором.

Неке од стандардних величина које представљају параметре процеса млевења цемента и мере се у реалном времену, приказане су у Табели 2.1. Кључни делови процеса млевења, млин, сепаратор, као и принципи лабораторијске анализе, биће детаљније описани у наредним потпоглављима.


Табела 2.1: Стандардни сигнали који се мере током процеса млевења цемента

Назив сигнала
Снага мотора млина
Поврат од сепаратора
Ротациона брзина сепаратора
Температура производа на излазу из млина
Притисак након млина
Притисак након сепаратора
Притисак испред млина
Ниво напуњености прве коморе млина
Ниво напуњености друге коморе млина
Количина сировина на улазу у млин
Снага мотора транспортера производа на излазу
Количина клинкера на улазу у млин
Количина шљаке на улазу у млин
Количина кречњака на улазу у млин
Количина гипса на улазу у млин
Укупна количина материјала на улазу у млин
Температура ваздуха након млина
Температура ваздуха након филтера

## 2.2 Млин


У процесу млевења цемента најчешће је у употреби млин чија је унутрашњост испуњена челичним куглама. Овај млин је хоризонтално постављен и врло често се састоји из више комора. У оквиру различитих комора налазе се челичне кугле различитих промера дуж тока материјала – од оних већег промера до оних мањег. Овим се обезбеђује постепено уситњавање сировина и, самим тим, постизање веће ефикасности. Структура оваквог млина, као и осталих типова који се користе у процесу прои-

зводње цемента, описана је у [20]. Попречни пресек хоризонталног млина испуњеног челичним куглама приказан је на Слици 2.2.



Слика 2.2: Попречни пресек хоризонтално постављеног млина

Хоризонтални млин се ротира око своје осе услед рада једног или више мотора и тиме долази до покретања челичних кугли унутар комора а затим се енергија кугли користи за уситњавање материјала. Унутрашња конструкција сваке коморе – оплата, дефинише трајекторију кретања кугли. Тако је, на пример, могуће контролисати да ли ће за уситњавање материјала бити употребљена претежно ударна сила кугли – карактеристично за иницијалне коморе млинова, или ће се употребљавати претежно трење између кугли, што је карактеристично за финалне коморе млинова и мање промере челичних кугли. Могуће трајекторије кугли су приказане на Слици 2.3, где је смер обртања млина означен црвеном стрелицом, трајекторија кугли у првим коморама млина наранџастом бојом, а у последњим коморама сивом бојом.



Слика 2.3: Трајекторија кугли унутар различитих комора




## 2.3 Сепаратор

Сепарација је доминантан процес у издвајању цемента који ће представљати финални производ. Наиме, потребно је крупније честице, које не задовољавају критеријуме дефинисане одређеним типом цемента, одвојити од оних које те критеријуме задовољавају. Како би сепарација била извршена, потребно је деловати силом која је директно пропорционална величини честице на коју делује. Ниједан тип сепарације се не заснива на употреби само једне силе, већ је то увек спрега њих неколико. У цементној индустрији се појављује неколико различитих типова сепаратора, а ваздушни сепаратори се по заступљености издвајају. Функционисање ваздушног сепаратора се заснива на употреби следећих сила [18]:

- Гравитациона сила
- Сила аеродинамичког отпора
- Центрифугална сила
- Сила судара

Данас је једна од доминантних грана истраживања у сфери цементне индустрије управо повећање ефикасности сепаратора [21]. Тренутна достигнућа у овој сфери довела су до креирања сепаратора високог степена ефикасности (енгл. *high efficiency*) [22] који ради на принципу ротора. Основни делови оваквог типа сепаратора приказани су на Слици 2.4.



Слика 2.4: Попречни пресек сепаратора високог степена ефикасности, преузет из [18]

До сепарације долази услед комбинованог деловања протока ваздуха који пролази кроз сепаратор и ротационог кретања ротора. Наиме, на месту обележеном са А на Слици 2.4 се убацује материјал у сепаратор. Тај материјал пада на плочу кружног облика која ротира, а која се назива дистрибуциона плоча. Честице материјала услед ротације дистрибуционе плоче и центрифугалне силе падају са ивице у простор који се назива зона раздвајања (обележена је нотацијом Б на Слици 2.4). Унутар зоне раздвајања, на сваку од честица делују силе гравитације и аеродинамичког отпора, као и центрифугална сила. Интезитет сваке од ових сила директно је пропорционалан величини (пречнику) честице. Од односа ових сила, које су последица брзине обртања ротора сепаратора и брзине протока ваздуха кроз сепаратор, директно зависи да ли ће се свака појединачна

честица кретати ка средини ротора (нотација В) или ка ободу сепаратора (нотација Г). Јасно је да ће честице мање величине тежити средини ротора док ће оне веће бити усмерене ка ободу сепаратора. Граница у величини честица дефинисана је брзином обртања сепаратора и брзином протока ваздуха кроз сепаратор. Комбиновањем ова два параметра дефинише се карактеристика сепаратора која се назива  $D50$ .  $D50$  представља величину честице за коју је вероватноћа 50% да ће бити усмерена ка ободу сепаратора и 50% да ће бити усмерена ка средини ротора.

Као што је приказано на Слици 2.4, честице које бивају увучене у саму унутрашњост сепаратора се даље транспортују као финални производ, док се оне које остају на ободу шаљу назад у млин у виду поврата.

Проблем сепарације унутар сепаратора није могуће у потпуности физички сагледати, јер, поред свих поменутих сила, на честице делује и сила судара до које долази услед континуалног убацивања честица материјала у сепаратор. Ова сила је зависна од типа материјала и просечне величине и облика честица, стога је током континуалне производње потребно мењати или брзину обртања ротора сепаратора или брзину протока ваздуха како би била задовољена константна финоћа финалног материјала.

## 2.4 Квантификовање финоће цемента

У литератури се појављује неколико начина одређивања финоће прашкастих материјала [23]. У овом раду приказана су два начина, пошто се они најчешће појављују у цементној индустрији.

Пре саме лабораторијске анализе, потребно је узети узорак материјала над којим ће се вршити лабораторијска анализа. Начин узимања узорака се често разликује од постројења до постројења, међутим, могуће га је поделити на два типа – спот и композитан. Спот узорковање подразумева да се читав узорак материјала узме у једном временском тренутку и да се над таквим ради лабораторијска анализа. Композитан узорак представља узорак материјала који је прикупљан током дужег временског ин-

тервала (обично израженог у минутима). Ово је обично имплементирано употребом пужног транспортера, који има константну брзину и задужен је да транспортује део финалног производа и пуни простор предвиђен за узорак. Самим тим, резултат лабораторијске анализе над композитним узорком представља средњу вредност финоће током временског интервала који је потребан пужном транспортеру да креира узорак, док резултат лабораторијске анализе над спот узорком представља финоћу материјала у тачно одређеном временском тренутку у ком је узорак узет.

Над узорком, узетим на било који од горе поменутих начина, врши се лабораторијска анализа неком од стандарних метода. Већина стандарних лабораторијских метода подразумева мерење масе узорка, затим пропуштање узорка кроз сита где је промер рупа познат и напоследку мерење масе дела узорка који је било прошао кроз сито, било остао на ситу. Стандардни промер рупа на ситима која су у употреби је 35, 45 и 90  $\mu\text{m}$ . У овом случају, мера финоће цемента је изражена у процентима и могуће ју је израчунати као

$$\text{финоћа}[\%] = 100\% - \frac{\text{маса остатка}}{\text{укупна маса}} \cdot 100\% \quad (2.1)$$

Из претходне формуле, могуће је уочити да финији материјал заправо има већу вредност финоће јер је тежња да што мање материјала остане на ситу.

Напретком технологије дошло је до развоја ласерских мерача финоће прашкастих материјала, који заправо мере дифракцију ласерских зрака који су пропуштени кроз прашкасти материјал и на основу тога израчунавају финоћу истог. Оно што је карактеристично за овакав вид одређивања финоће јесте да се финоћа углавном одређује над спот узорцима, али чак ни употребом ласерских мерача није могуће добити вредности финоће у реалном времену.

## Индустријски софт сензори

Софт сензори представљају математичке моделе који се користе за естимацију вредности различитих величина које представљају показатеље стања процеса [1]. Као такви, нашли су изузетну примену у индустрији [24]. Софт сензори се креирају на основу историјских вредности скупа процесних величина и служе као замена за физичке сензоре или лабораторијске анализе. За креирање софт сензора који ће вршити квалитетну естимацију, није довољно само употребити историјске вредности насумичних сигнала, насумичну топологију и било који начин обуке софт сензора.

Одабир претходно поменутих параметара представља комплексан процес који захтева како време, тако и познавање самог процеса у ком ће софт сензор бити примењен [25]. Велик број софт сензора који се користе у индустрији, заснива се на принципима моделовања методом црне кутије, међутим, потребно је изабрати да ли користити статички или динамички, линеарни или нелинеарни модел, што директно зависи од поља примене софт сензора и количине и начина прикупљања података. Након одабира структуре модела, потребно је изабрати процесне варијабле које ће бити коришћене као улази. У овом кораку је од изузетне важности познавање процеса примене софт сензора. Скуп потенцијалних улаза би требало да садржи све сигнале који директно или индиректно могу имати утицај

на сигнал који је потребно естимирати. За постизање најбољег квалитета естимације, почев од скупа потенцијалних улаза, потребно је одредити скуп међусобно независних сигнала који утичу на сигнал који ће се наћи на излазу. Чак и поред коректног одабира независних сигнала, квалитет естимације софт сензора може бити незадовољавајућ. У овим случајевима, потребно је размотрити, и на неки начин укључити у модел, и тачна временска кашњења утицаја промене сваког од сигнала који се користе као улази у модел, на промену сигнала који ће представљати излаз.

У великом броју индустријских процеса, који су просторно дистрибуирани и садрже транспорт материјала дуж разних транспортних путева, утицај промене сигнала показатеља стања на промену особина финалног производа не мора бити тренутан већ може бити закашњен [26, 27, 28]. Приликом моделовања таквих процеса статичким моделима, узимање кашњења у обзир има велику улогу, јер сама математика модела не води рачуна о кашњењима сигнала. Другим речима, приликом обуке модела транспортних система код којих кашњење није узето у обзир, може доћи до или стварања непостојећих или нестварања постојећих зависности међу сигнаlima, што ће за последицу имати невалидну естимацију. Информације о приближним временским кашњењима међу сигнаlima могуће је добити од стране стручног лица, задуженог за надзор процеса. Међутим, за постизање најквалитетније естимације жељене процесне величине, потребно је што тачније одредити вредности ових кашњења за сваки од сигнала који се нађу на улазу софт сензора.

У неким случајевима, временско кашњење између сигнала је могуће одредити посматрањем историјских вредности истих. Довољно је пронаћи тренутак кад је дошло до промене у сигналу који представља улаз софт сензора и уочити колико је времена било потребно да та промена пропагира до промене сигнала који представља излаз софт сензора. Овакав начин одређивања кашњења најлакше је применити приликом покретања процеса из стања у ком је процес био заустављен, али га је у неким случајевима могуће применити и током континуалне продукције, увођењем малих

промена у жељени сигнал и посматрајући шта се дешава са сигналом који представља излаз. Са друге стране, кашњење међу неким сигналнима могуће је само приближно одредити или уопште није могуће одредити. Пример из индустрије цемента јесте заснован на томе да се цемента добија при млевењу материјала у млину у трајању од 10 до 40 минута [29]. При креирању софт сензора који би естимирао финоћу цемента на излазу млина, потребно је анализирати процесне величине које представљају показатеље стања процеса млевења. Једна од тих величина, а која би могла да има утицај на финални производ, јесте и струја мотора млина. Материјал се меље неко време у млину и, стога, није могуће одредити коју вредност струје мотора млина узети у обзир за естимацију - да ли ону са почетка процеса млевења, ону са краја или неку између. Велики број истраживача бавио се решавањем сличног проблема. Тако се, на пример, у литератури појављује неколико метода који решавају проблеме одређивања скупа улазних сигнала и њихових кашњења за линеарне статичке и динамичке моделе. Алгоритам који се издваја назван је динамичком анализом основних компоненти (енгл. *dynamic principal component analysis*) (ДПЦА) и представљен је у [30]. Овај алгоритам директно одређује ред система и формира динамички линеарни модел система који у себи садржи временско кашњење. Базиран је на методу анализе основних компоненти (енгл. *principal component analysis*) (ПЦА) над којим је матрица података формирана и од временски закашњених инстанци свих улазних сигнала. Алгоритам се изводи итеративно, а закашњене инстанце сигнала се додају докле год постоји линеарна веза у матрици података. Побољшање ДПЦА представљено је у [31], где су аутори представили прецизнији начин одређивања броја закашњених инстанци и омогућили избор различитог броја закашњених инстанци за сваки од улазних сигнала. Примена овог метода на системе где постоји велика количина информација коју је потребно обрадити приказана је у [32].

У научној литератури је могуће пронаћи и алгоритме за одређивање улазних сигнала и њихових кашњења код нелинеарних модела, међутим, у поређењу са методама за линеарне моделе, примена им је изузетно огра-

ничена. У раду [15] приказује се један метод за избор улазних сигнала у моделовању процеса употребом вештачких неуронских мрежа. Приказани метод назван је алгоритмом одређивања улаза користећи теорију информација (енгл. *information theoretic subset selection*) (АОУТИ) и заправо квантификује колико је информација о жељеном излазу додато додавањем сваког потенцијалног улазног сигнала. У истом раду, приказана је и примена представљеног алгоритма на одређивању кашњења улазних сигнала над простим хемијским процесом који садржи само два улаза. Аутори су направили по осам реплика сваког од улазних сигнала, од којих је свака била закашњења за по један временски интервал у односу на претходну, и итеративно су одредили која комбинација два сигнала садржи највише информација о излазном сигналу хемијског процеса. У раду [8] приказана је упоредна анализа четири метода за одређивање скупа сигнала који би требало да представља оптималан скуп улаза у модел. Од свих поређених алгоритама, једино АОУТИ је могуће користити пре самог формирања модела. Остала три алгоритма дају меру подобности сигнала или у фази обуке модела или у крајњој фази евалуације. Тема радова [9], [10] и [11] је такође утицај сигнала у моделовању, међутим, како и ту представљени алгоритми дају меру количине информација након фазе креирања модела, као такви нису погодни за коришћење у комплексним проблемима. Алгоритам којим је могуће одредити кашњење између два сигнала представљен је у раду [33]. Приказани алгоритам заправо представља генерализован метод крос корелације и могуће га је користити само на уском спектру проблема – када два сигнала заправо представљају различито закашњене реплике једног те истог сигнала. Представљање и упоређивање постојећих метода за израчунавање и естимацију кашњења сигнала приказано је и у [34, 35, 36]. Приказани алгоритми су применљиви само на системе до другог реда који имају највише два улазна сигнала и као такве их није могуће користити за решавање проблема велике димензионалности који су неминовни у процесној индустрији.

Велик број софт сензора који су нашли своју примену у индустри-



ји заснован је на нелинеарним моделима, јер је уз помоћ њих могуће моделовати системе које у себи садрже високе степене нелинеарности [37, 38, 39, 40, 41]. У овим моделовањима, заснованим на принципима црне кутије, могуће је користити различиту архитектуру софт сензора, почев од вештачких неуронских мрежа [37, 40, 41], преко вектора подршке (енгл. *support vector*) [39], па све до хибридниh неуро-фази модела [38]. Приказани софт сензори могу представљати било статичке било динамичке моделе, међутим, велик део софт сензора коришћених у индустрији представља искључиво статичке моделе. Разлог овоме јесте природа процеса и заправо лежи у начину добијања вредности процесних величина. Наиме, софт сензори углавном служе као замена за лабораторијску анализу и естимирају неку особину финалног производа посматраног процеса [38, 39, 40, 41]. Немогућност креирања динамичких модела заснована је у томе да не постоје мерења свих процесних величина бележена у реалном времену и да вредности неких од њих заправо представљају резултат лабораторијске анализе узорака чије је време одабирања врло често изражено у сатима. Са друге стране, постоје и процеси у којима постоје мерења свих процесних величина бележена у реалном времену, али је време одабирања велико и тиме се директно спречава креирање динамичког модела таквог процеса.

Вештачке неуронске мреже представљају један тип нелинеарних модела који је данас изузетно заступљен. Потенцијалне структуре истих биле су теме разних научних истраживања. Једна од структура вештачких неуронских мрежа која је данас заступљена јесте структура заснована на радијално базираним функцијама [42]. Ова структура вештачких неуронских мрежа је постала популарна међу истраживачима због постојања изузетно брзог начина обуке истих [43]. Превасходно се овакав тип вештачких неуронских мрежа користи у решавању проблема класификације, јер је, због саме топологије, истима могуће врло лако постићи висок степен тачности класификације [44, 45, 46]. Међутим, ове вештачке неуронске мреже могуће је употребити и за регресију. Једна од примена на решава-

њу проблема регресије приказана је у [47]. Аутори су се бавили естимацијом и предикцијом чврстоће бетона. Чврстоћа је естимирана употребом вештачких неуронских мрежа са радијално базираним функцијама, на основу вредности неколико сигнала који су добијени из лабораторијске поставке. Иако су постигнути добри резултати, експериментална поставка употребљена у приказаном раду није стандардна у индустрији, и због неопходности додатних сензора, читав систем није лако имплементирати. Такође, услед потребе за вршењем експеримента са циљем добијања вредности сигнала улаза у софт сензор, вредност чврстоће бетона није могуће естимирати у реалном времену. Примена вештачких неуронских мрежа са радијално базираним функцијама у области предвиђања поплава приказана је у радовима [48] и [49]. Аутори су за улазе изабрали величине које представљају мере количине падавина у претходном временском периоду и на основу тога су успевали да остваре изузетно добре предикције. Софт сензори засновани на радијално базираним функцијама коришћени су и за моделовање понашања битних показатеља стања  $CO_2$  резервоара [50]. Као што су аутори напоменули, разлог одабира оваквог типа софт сензора био је заснован на томе да је исте могуће изузетно брзо и лако обучити како би се постигли квалитетни резултати. Као што је и напоменуто у приказаним радовима, квалитет естимације софт сензора директно је повезан и са начином обуке истог, што оправдава тему овог истраживања.

Конвенционални начини обуке вештачких неуронских мрежа са радијално базираним функцијама свде се на груписање (кластеризација) података са циљем одређивања центара радијалних функција, затим одређивање ширина истих на основу просторне дистрибуираности група (кластера) и, на крају, одређивање тежина сваког излаза из радијалних функција употребом методе најмањег квадрата [16, 17]. Стога је у раду [49], поред већ поменуте примене оваквог типа софт сензора, упоређена и употреба различитих начина кластеризације у процесу обуке софт сензора. Упоређена су два начина кластеризације и постигнути резултати показују да је употребом алгоритма К-средњих вредности (енгл. *k-means*) постигнут већи степен финалне тачности естимације. Рад [51] представља

преглед и упоређивање постојећих алгоритама кластеризације који могу бити употребљени у процесу обуке вештачких неуронских мрежа у циљу одређивања центара радијално базираних функција. Упоређена су четири алгорита – метод К-средњих вредности (енгл. *k-means*) (КМ), хијерархијска кластеризација (енгл. *hierarchial clustering*) (ХК), самоорганизујуће (енгл. *self organization*) (СМ) мапе и алгоритама максимизације очекивања (енгл. *expectation maximization*) (АМО). Закључак рада је да је најпрецизнија кластеризација над малим скупом података вршена СМ алгоритмом, док су КМ и АМО показали подједнако добру кластеризацију великог скупа података. Побољшање и конкретан начин имплементације алгорита кластеризације методом К-средњих вредности представљени су у [52]. Битност тачног одређивања броја и структуре радијалних функција код софт сензора заснованих на вештачким неуронским мрежама са радијално базираним функцијама приказана је у раду [12]. У истом раду упоређен је квалитет излаза софт сензора у случају тачног одабира радијалних функција и у случају нетачног.

Поред конвенционалног, брзог начина обуке вештачких неуронских мрежа са радијално базираним функцијама, исте је могуће обучавати и алгоритмом пропагације грешке уназад и градијетним методом [13, 14]. Потребно је математички одредити како промена било којег од параметара овог типа софт сензора утиче на грешку на излазу и итеративно подешавати све параметре за сваки појединачни податак из скупа података у односу на постигнуту грешку. Овакав вид обуке софт сензора није брз и питање које се појављује у научној литератури јесте када престати са обуком, а да мрежа не буде нити подобучена нити преобучена. Такође, код оваквог типа обуке, потребно је унапред прецизирати број радијалних функција на којима ће бити базирана вештачка неуронска мрежа, јер није могуће пронаћи директну математичку зависност овог броја и постигнуте грешке излаза.

Због наведених недостатака постојећих алгоритама обуке, постављен је и циљ овог рада који представља развој хибридног алгорита који комбинује бенефите брзог и конвенционалног начина обуке.

## Алгоритам за одређивање оптималног скупа улаза у софт сензор и кашњења сваког од њих

Прегледом научне литературе и раније приказаних проблема, јасно се може видети потреба за унапређењем постојећих алгоритама формирања софт сензора. Као што је могуће видети из приказаног, недостаци постојећих алгоритама се огледају у проблему одабира скупа улазних сигнала и њихових кашњења. Алгоритам који је приказан у оквиру овог рада превазилази све горе поменуте недостатке и представља оригинални научни допринос у области софт сензора [53].

АОУТИ [15] представљен у претходном поглављу се показао као веома добар за одређивање количине информација коју потенцијални сигнали улаза у вештачку неуронску мрежу носе о потенцијалном излазу [41, 54]. Као што је и показано у раду где је алгоритам представљен, исти је могуће користити за одређивање кашњења улаза у систем. Међутим, за ову примену, потребно је да сигнали улаза буду унапред познати. Још једно ограничење јесте да број улаза код којих је непознато кашњење не може бити велики (у раду је представљен проблем када систем има само два

улаза са непознатим кашњењем). Проблем постојећег алгоритма јесте што је током поступка потребно проћи кроз све комбинације сигнала како би била одређена комбинација над којом је могуће најквалитетније естимирати тешко мерљиву величину. Проблем ескалира када је број непознатих велики.

Управо због претходно наведеног проблема, постављена је хипотеза овог истраживања да је могуће употребити неки глобални начин претраживања у спрези са АОУТИ, како би проблем проласка кроз све комбинације улазних сигнала био превазиђен. За глобални начин претраживања изабран је генетски алгоритам (ГА) [55], јер је исти показао изузетне перформансе у проналаску оптималног решења комплексних проблема [56, 57, 58, 59]. У оквиру функције оцене квалитета (енгл. *fitness*) генетског алгоритма налазила се једна имплементација АОУТИ, описана у наредном делу овог поглавља. Комплетан алгоритам имплементиран је у оквиру пакета *Matlab 2015a*<sup>1</sup>.

## 4.1 Алгоритам за одређивање улаза базиран на теорији информација

АОУТИ је заснован на теорији информација и квантификује количину нових информација добијену потенцијалним додавањем новог улаза у софт сензор. Како би алгоритам могао бити коришћен на континуалним сигналима, потребно је радни опсег сваког сигнала поделити у коначан број подопсега (подеока). Након тога могуће је израчунати вероватноћу да се сигнал  $x$  налази у подопсегу  $x_i$  на основу (4.1), где  $N_i$  представља број колико се пута  $x$  нашао у интервалу  $x_i$ , а  $N$  укупан број опсервација.

$$p_i = p(x = x_i) = \frac{N_i}{N} \quad (4.1)$$

---

<sup>1</sup> [www.mathworks.com/products/matlab.html](http://www.mathworks.com/products/matlab.html)

На основу претходне једначине, могуће је израчунати ентропију сигнала  $x$  користећи (4.2).

$$H(x) = - \sum_{i=1}^M p_i \cdot \ln(p_i) \quad (4.2)$$

Заједничка вероватноћа два сигнала представља вероватноћу да је истовремено сигнал  $x$  у опсегу  $x_i$  и сигнал  $y$  у опсегу  $y_j$  и рачуна се као:

$$p_{ij} = p(x = x_i, y = y_j) = \frac{N_{ij}}{N} \quad (4.3)$$

где  $N_{ij}$  представља број појављивања те комбинације, а  $N$  укупан број опсервација. На основу овога могуће је израчунати и заједничку ентропију два сигнала као:

$$H(x, y) = - \sum_{i=1}^M p_{ij} \cdot \ln(p_{ij}) \quad (4.4)$$

Користећи претходне једначине,  $ADC$  коефицијент, који представља меру зависности два сигнала  $x$  и  $y$ , израчунава се као:

$$ADC(y|x) = 1 + \frac{H(x) - H(x, y)}{H(y)} \quad (4.5)$$

$ADC(y|x)$  даје меру о количини информација из сигнала  $y$  коју садржи сигнал  $x$ . Вредност овог коефицијента је у опсегу  $[0, 1]$ , где вредност 0 значи да  $x$  уопште не садржи корисне информације о  $y$ , а вредност 1 значи да је могуће у потпуности одредити сигнал  $y$  на основу сигнала  $x$ . Мера зависности више потенцијалних улазних сигнала  $x_1, \dots, x_n$  и жељеног излазног сигнала  $y$ , рачуна се слично једначини (4.5), где је све ентропије које зависе од сигнала  $x$  потребно заменити са заједничком ентропијом више сигнала  $x_1, \dots, x_n$  и резултујућа једначина приказана је у (4.6).

$$ADC(y|x_1, \dots, x_n) = 1 + \dots \frac{H(x_1, \dots, x_n) - H(x_1, \dots, x_n, y)}{H(y)} \quad (4.6)$$

Идеја предвиђеног истраживања јесте креирање више реплика сваког од потенцијалног улазног сигнала, где би свака реплика била различито временски закашњена у односу на оригинал. Након тога, употребом ГА и АОУТИ над свим сигнаlima, и оригиналним и репликама, биће пронађен подскуп иницијалног скупа сигнала који садржи највише информација о сигналу који је потребно естимирати.

Дефинисање иницијалног скупа који би садржао и оригиналне сигнале и реплике могуће је креирањем матрице димензија  $m \times 2$ , где прва колона представља идентификатор оригиналног сигнала а друга број временских јединица колико би тај сигнал требао бити закашњењ. На овај начин, свака врста формиране матрице дефинише потенцијални сигнал. Може се приметити да, уколико постоји  $s$  оригиналних сигнала и сваки од сигнала може бити закашњен од 0 до  $d$  временских јединица, овако формирана матрица садржи укупно  $m = s \times d$  врста. Максимално кашњење свих сигнала,  $d$ , је параметар конкретног процеса примене софтверног сензора. Табеларна репрезентација ове матрице приказана је у Табели 4.1.

Табела 4.1: Матрица сигнала и њихових реплика

Идентификатор оригинала	Кашњење
$ID_1$	0
$ID_1$	1
...	...
$ID_1$	$d - 1$
$ID_1$	$d$
$ID_2$	0
...	...
$ID_2$	$d$
...	...
$ID_s$	$d$

## 4.2 Оптимизациони алгоритам претраге простора скупова улазних сигнала и њихових кашњења

Проблем претраге простора скупова улазних сигнала и њихових кашњења није тривијалан, и могуће га је решити употребом генетског алгоритма, као глобалног начина претраге.

Функција оцене квалитета (енгл. *fitness*) генетског алгоритма је формирана тако да алгоритам тражи оптималан скуп од  $n$  сигнала од свих кандидата за улазе, где је  $n$  конфигурабилан параметар. Циљ функције оцене квалитета јесте да пронађе што мањи скуп сигнала који задовољава тражени услов. Тражени услов је да сигнали заједно садрже минимално ону количину информација о жељеном излазном сигналу која се сматра довољном за посматрани процес.

Самим тим, један геном генетског алгоритма се формира тако да садржи  $n$  целобројних вредности. Свака вредност у оквиру генома заправо представља индекс врсте из претходно описане матрице у Табели 4.1. Тиме се добија да је једним геномом дефинисано  $n$  потенцијалних улазних сигнала за које је потребно проверити колико информација о сигналу излаза садрже.

За одређивање количине информација коју сигнали дефинисани геномом садрже о излазу коришћен је претходно описан АОУТИ. До укупне количине информација долази се итеративно, како би било одређено колико нових информација је добијено додавањем сваког новог сигнала. Итерације иду следећим редоследом: одређивање количине информација коју први сигнал носи, затим коју носе први и други, затим први, други и трећи итд.

Да би скуп од што мање сигнала који задовољава претходно представљен услов био пронађен, функција оцене квалитета је креирана тако да се заправо максимизује сума кумулативне количине информација из претходно описаних итерација. Количина информација не може бити негативна и може само да расте, те је овим обезбеђено да се фаворизују што



мањи скупови улаза који задовољавају тражени услов. Из овог разлога, креиране су две казнене функције. Једна пенализује излаз функције оцене квалитета, који је сума кумулативне количине информација, уколико је вредност количине информација коју садрже сви сигнали дефинисани геномом мања од границе  $a$ . Параметар  $a$  заправо дефинише количину информација која се за циљани процес примене софтверног сензора може сматрати као довољна. Вредност овог параметра би требало да буде блиска 100%. Друга казнена функција пенализује излаз у односу на то у којој је итерацији задовољена тражена количина информација  $a$  (колико сигнала је потребно да би се достигла количина информација  $a$ ). Казнене функције,  $C_1$  и  $C_2$ , дате су једначинама (4.7) и (4.8). Параметар  $p$  представља коефицијент кажњавања,  $n$  укупан број сигнала дефинисаних геномом, а  $min\_ind()$  представља функцију која враћа минималан број сигнала, дефинисаних конкретним геномом, потребних да се задовољи услов унутар заграда. Вредност коефицијента  $p$  би требало да буде у опсегу  $[0, 1]$ , где се нижом вредношћу више пенализује излаз функције оцене квалитета. Израз (4.9) приказује како се излаз функције оцене квалитета рачуна. Знак минус се појављује из разлога што је генетски алгоритам у оквиру *Matlab2015a* програмског пакета дизајниран да тражи минимум функције оцене квалитета.

$$C_1 = p \cdot (max(ADCs) < a) \quad (4.7)$$

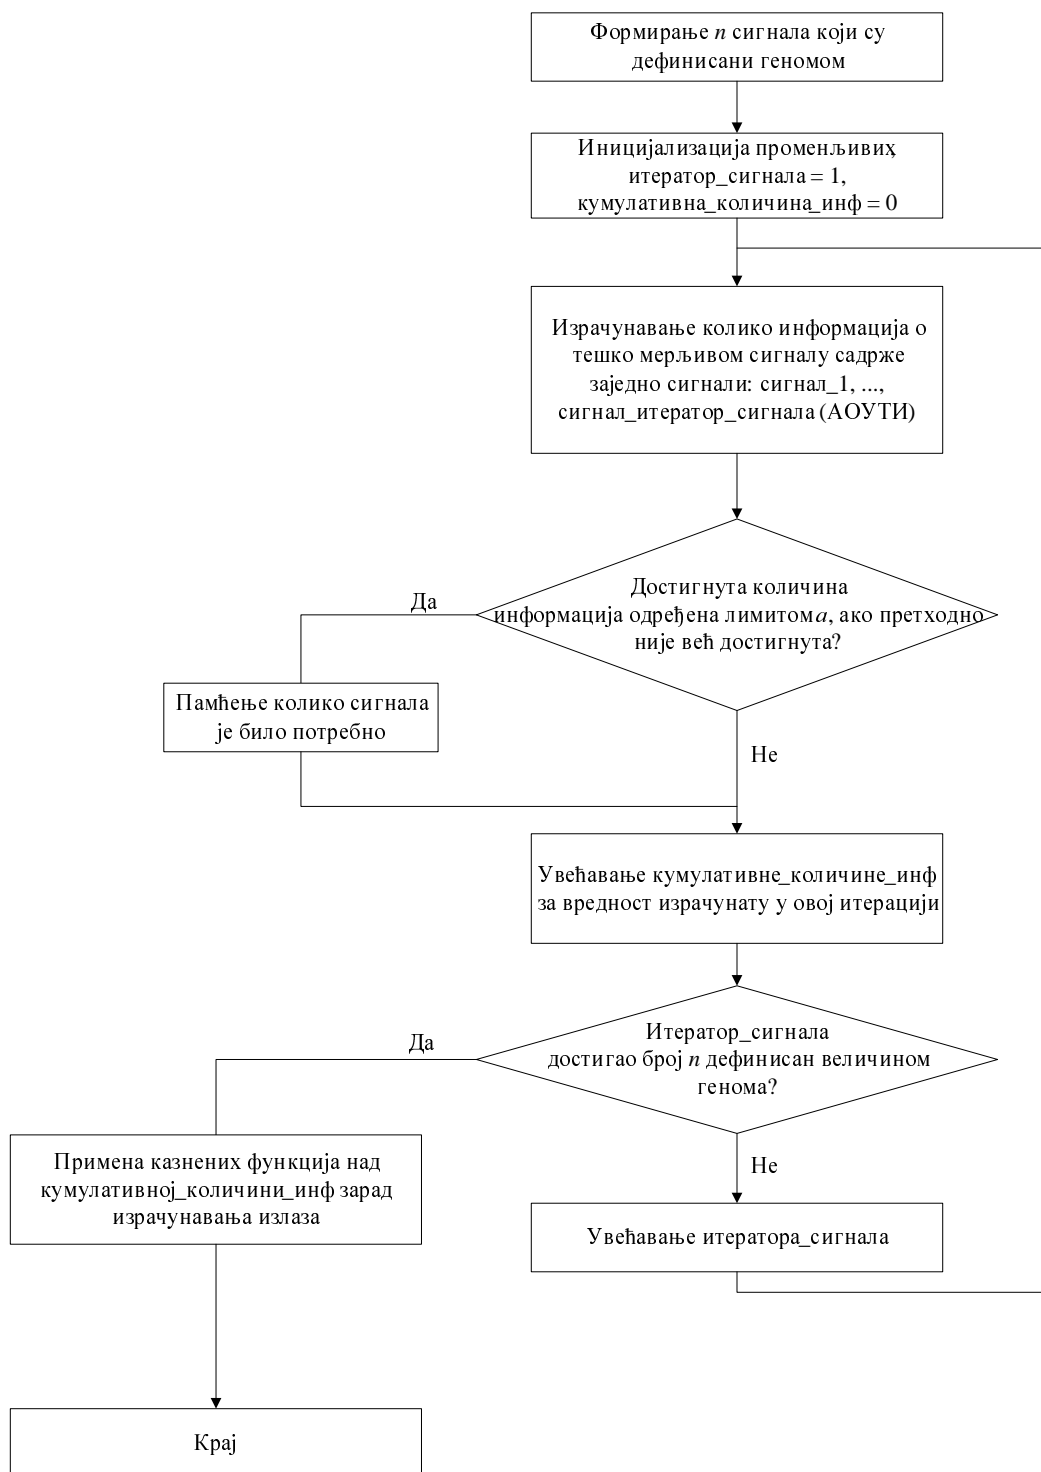
$$C_2 = \frac{n \cdot (max(ADCs) \geq a)}{min\_ind(ADCs \geq a)} \quad (4.8)$$

$$fitness = -(C_1 + C_2) \cdot \sum_{i=1}^n ADCs \quad (4.9)$$

Приликом неколико извршавања алгоритма на проблему посматраном у овом истраживању, утврђено је да се најбољи резултати постижу уколико коефицијент  $p$  има вредност 0.1 а коефицијент  $a$  вредност 95%. Такође, вредности параметара генетског алгоритма које су се показале као најбоље су:

- величина иницијалне популације: 200 генома
- елитизам: 20% популације
- однос мутација: 95%
- заустављање уколико нема промене: 200 генерација
- максималан број генерација: 500

Алгоритам тока сигнала рачунарске имплементације функције оцене квалитета приказан је на Слици 4.1.



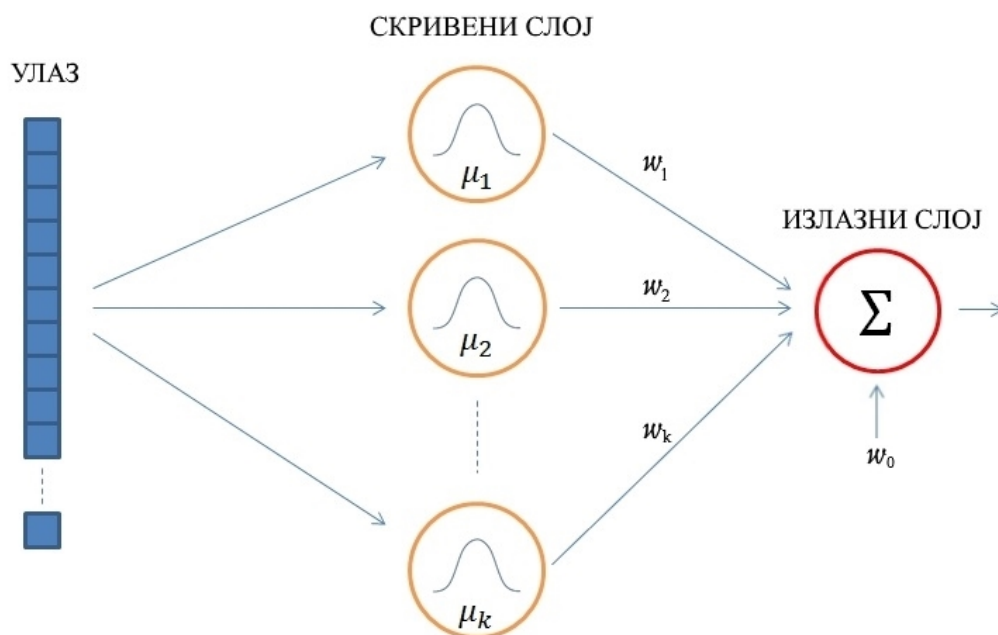
Слика 4.1: Алгоритам тока сигнала рачунарске имплементације функције оцене квалитета

## Софт сензори засновани на вештачким неуронским мрежама са радијално базираним функцијама

Анализом актуелног стања у области софт сензора, може се приметити да се, у естимацији тешко мерљивих величина, све већа пажња посвећује вештачким неуронским мрежама са радијално базираним функцијама (ВНМ-РБФ). Квалитет естимације ВНМ-РБФ директно је зависан од саме топологије мрежа и начина обуке. Да би ова два кључна корака била аутоматски конфигурисана, предложен је хибридни алгоритам који представља саставни и оригинални део ове тезе. Потреба за аутоматским алгоритмом и бенефити предложеног алгоритма ће бити представљени у наредном потпоглављу, где ће, пре свега, бити објашњена архитектура и основни принципи ВНМ-РБФ. Након тога, предложени хибридни алгоритам и начин имплементације истог ће бити детаљно описани.

## 5.1 Архитектура вештачких неуронских мрежа са радијално базираним функцијама

Основна архитектура ВМ-РБФ је увек трослојна. Овакав вид неуронских мрежа се увек заснива на улазном слоју (улазу), скривеном нелинеарном слоју и излазном слоју, као што је и приказано на Слици 5.1.



Слика 5.1: Архитектура вештачке неуронске мреже са радијално базираним функцијама

Карактеристично за ВМ-РБФ је то да се улаз посматра као једна тачка у вишедимензионалном простору, где је број димензија простора дефинисан бројем сигнала на основу чијих вредности се естимација врши. Конкретна позиција те тачке у вишедимензионалном простору одређена је вредностима сваког од сигнала који се налазе на улазу у вештачку неуронску мрежу.

Скривени слој се састоји од  $i$  неурона који садрже радијално базиране функције. Сваки од тих неурона описује један део претходно поменутог вишедимензионалног простора. У сваком скривеном неурону налази се Гаусова функција окарактерисана центром и ширином. Излаз ове функције представља меру удаљености центра Гаусове функције и тачке која је дефинисана вредностима улаза у вештачку неуронску мрежу. Један начин описивања овакве активационе функције скривених неурона, који је коришћен током овог истраживања, приказан је у (5.1), где  $c_i$  представља центар Гаусове функције  $i$ -тог неурона скривеног слоја, а  $\sigma_i$  ширину исте.

$$\phi_i(x) = e^{-\frac{\|x - c_i\|^2}{2\sigma_i^2}} \quad (5.1)$$

Излазни слој оваквог типа неуронске мреже увек има линеарну активациону функцију:

$$y = \sum_{i=1}^k w_i \cdot \phi_i + w_0 \quad (5.2)$$

где  $\phi_i$  представља излаз из  $i$ -тог неурона скривеног слоја.

Поред тежина  $w_i$ , чије се одређивање у току обуке своди на метод најмањих квадратних грешака, центри и ширине Гаусових функција у скривеном слоју су једини параметри оваквог вида неуронских мрежа. Одређивање броја и вредности центара се обично врши неком од метода кластеризације, а затим се ширине радијално базираних функција одређују на основу просторне дистрибуције кластера.

Досадашњи начином одређивања ширина радијално базираних функција се не постиже обученост вештачких неуронских мрежа која гарантује минималну грешку естимације. Увођењем хибридног алгорита обуке превазилази се горе поменути недостатак.

## 5.2 Хибридни алгоритам обуке вештачких неуронских мрежа са радијално базираним функцијама

Анализом радова обрађених у току овог истраживања, могуће је креирати хибридни алгоритам обуке ВНМ-РБФ, који би се базирао на груписању података методом К-средњих вредности (енгл. *k-means*), методу најмање квадратне грешке, методу пропагације уназад и градијентном методу. Помоћу прва два метода би се одређивали центри радијално базираних функција и тежине излаза из истих, док би употребом друга два била вршена корекција ширина радијално базираних функција.

### 5.2.1 Груписање података методом К-средњих вредности

Груписање података (кластеризација) методом К-средњих вредности представља најкоришћенији начин груписања података. Иако је сам метод прилично лако имплементирати, показао се као веома ефикасан, о чему говоре радови обрађени у трећем поглављу.

Кораци груписања података овом методом приказани су на Слици 5.2.



Слика 5.2: Алгоритам тока сигнала рачунарске имплементације кластеризације методом К-средњих вредности

### 5.2.2 Градијентни метод и пропација грешке уназад

Комбинација градијентног метода и метода пропације грешке уназад је нашла изузетну примену у обуци вештачких неуронских мрежа заснованих на перцептронима (енгл. *feed-forward*). Ова комбинација заснива се на два основна корака која је потребно применити на сваку опсервацију



из обучавајућег скупа података:

- израчунавање естимираног излаза на основу тренутне конфигурације мреже и вредности улаза у тој опсервацији, и на основу тога, пронаћи грешку између естимиране и стварне вредности те опсервације
- кориговање конфигурације и параметара вештачке неуронске мреже на основу израчунате грешке и градијентног метода

За имплементацију градијентног метода и метода пропације грешке уназад потребно је дефинисати на који начин ће бити вршена корекција тренутне конфигурације вештачке неуронске мреже. Потребно је дефинисати функцију грешке која ће бити минимизована током алгорита обуке, а затим одредити утицај промене сваког од подесивих параметара вештачке неуронске мреже на ту функцију. Најчешће употребљавана функција грешке коју је потребно минимизовати приказана је у (5.3) као  $cost\_fn$ , где  $N$  представља број опсервација у скупу за обуку,  $y$  и  $x$  стварну вредност излаза и вредности улаза у текућој опсервацији, ретроспективно, а  $f(x)$  естимирану вредност излаза на основу текуће опсервације.

$$cost\_fn = \sum_{i=1}^N \frac{(y_i - f(x_i))^2}{2} \quad (5.3)$$

Употребом комбинације градијентног метода и метода пропације грешке уназад врши се подешавање ширина радијално базираних функција у скривеним неуронима. Из овог разлога, потребно је пронаћи утицај промене ширине сваке радијално базиране функције на промену функције чијој се минимизацији тежи. Математички је то могуће записати као  $\frac{d\ cost\_fn}{d\ \sigma_j}$ , где  $\sigma_j$  представља ширину радијалне функције  $j$ -ог скривеног неурона. Функција грешке није представљена као директно зависна од ширина радијалних функција, потребно је претходно поменути израз представити уз помоћ израза (5.2), као што је приказано у (5.4).

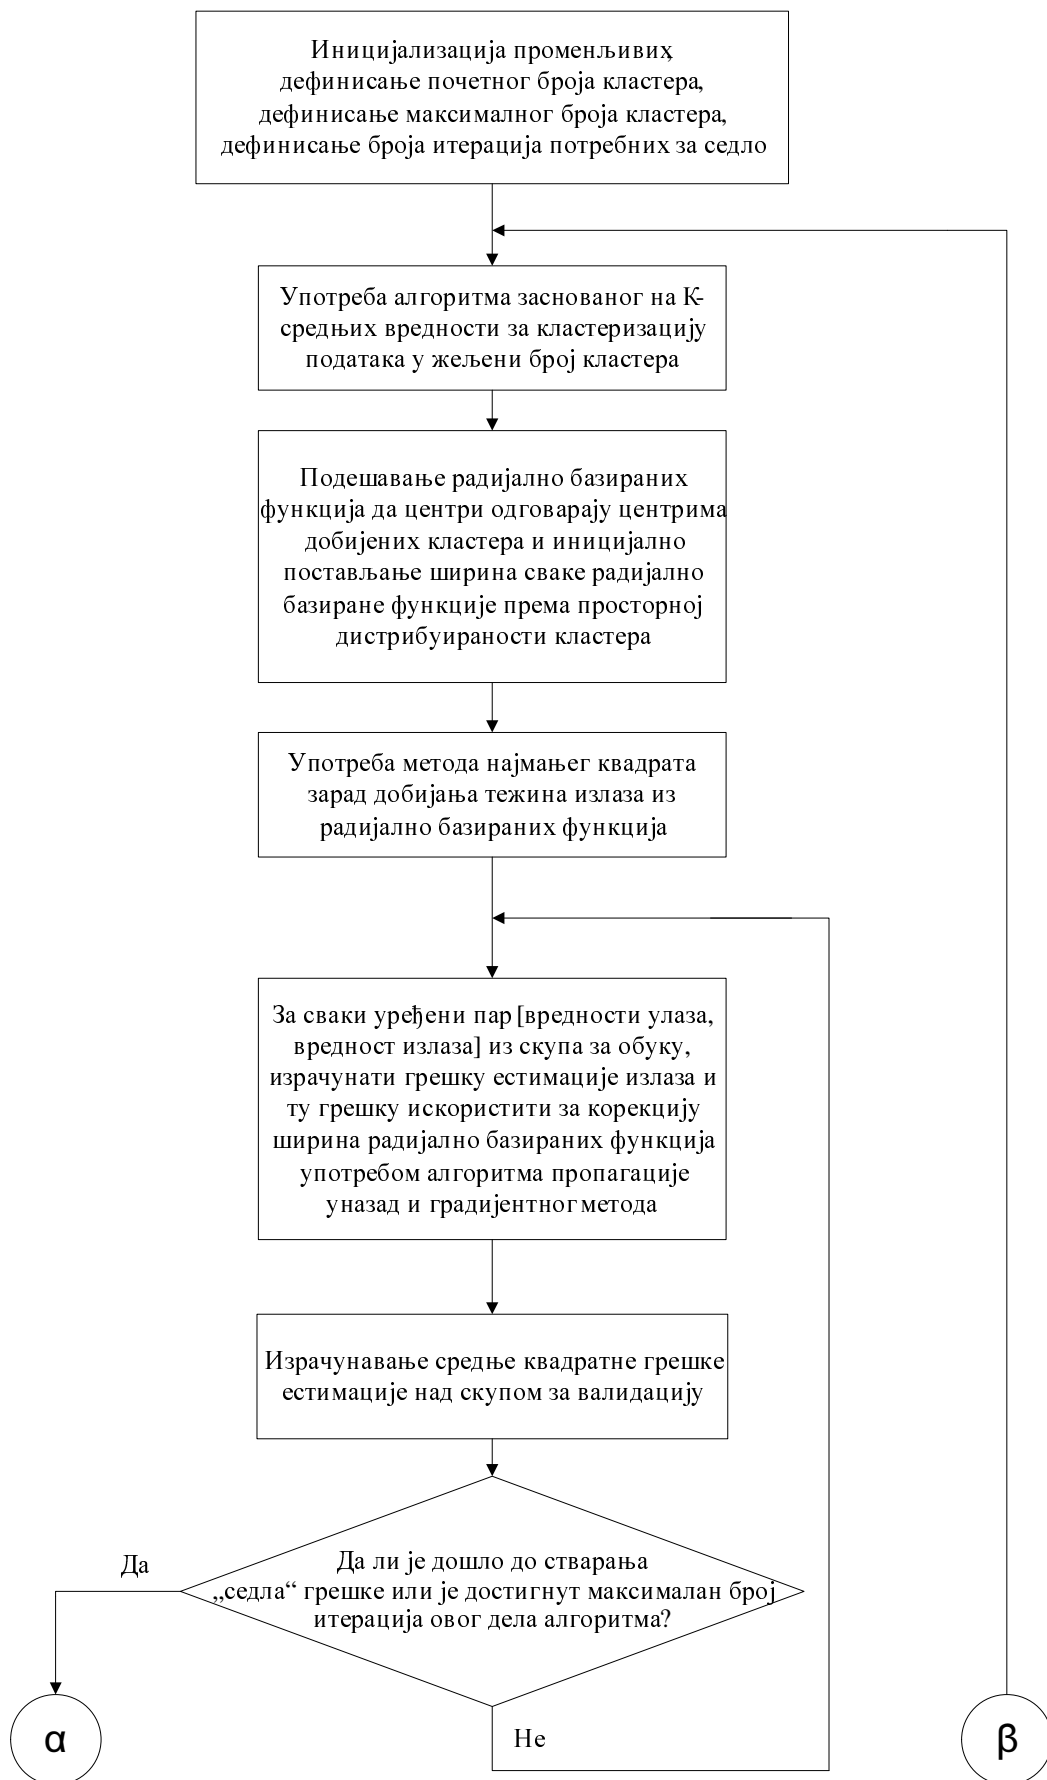
$$\begin{aligned}
 \frac{d \text{cost\_fn}}{d \sigma_j} &= \frac{d \text{cost\_fn}}{d f(x_i)} \cdot \frac{d f(x_i)}{d \sigma_j} = \frac{d \text{cost\_fn}}{d f(x_i)} \cdot \frac{d f(x_i)}{d \phi_j(x_i)} \cdot \frac{d \phi_j(x_i)}{d \sigma_j} \\
 &= -(y_i - f(x_i)) \cdot w_j \cdot \frac{d \left( e^{-\frac{\|x_i - c_j\|^2}{2\sigma_j^2}} \right)}{d \sigma_j} \\
 &= -(y_i - f(x_i)) \cdot w_j \cdot e^{-\frac{\|x_i - c_j\|^2}{2\sigma_j^2}} \cdot \frac{4\sigma_j \cdot \|x_i - c_j\|^2}{4\sigma_j^4} \\
 &= -(y_i - f(x_i)) \cdot w_j \cdot \phi_j(x_i) \cdot \frac{\|x_i - c_j\|^2}{\sigma_j^3} \tag{5.4}
 \end{aligned}$$

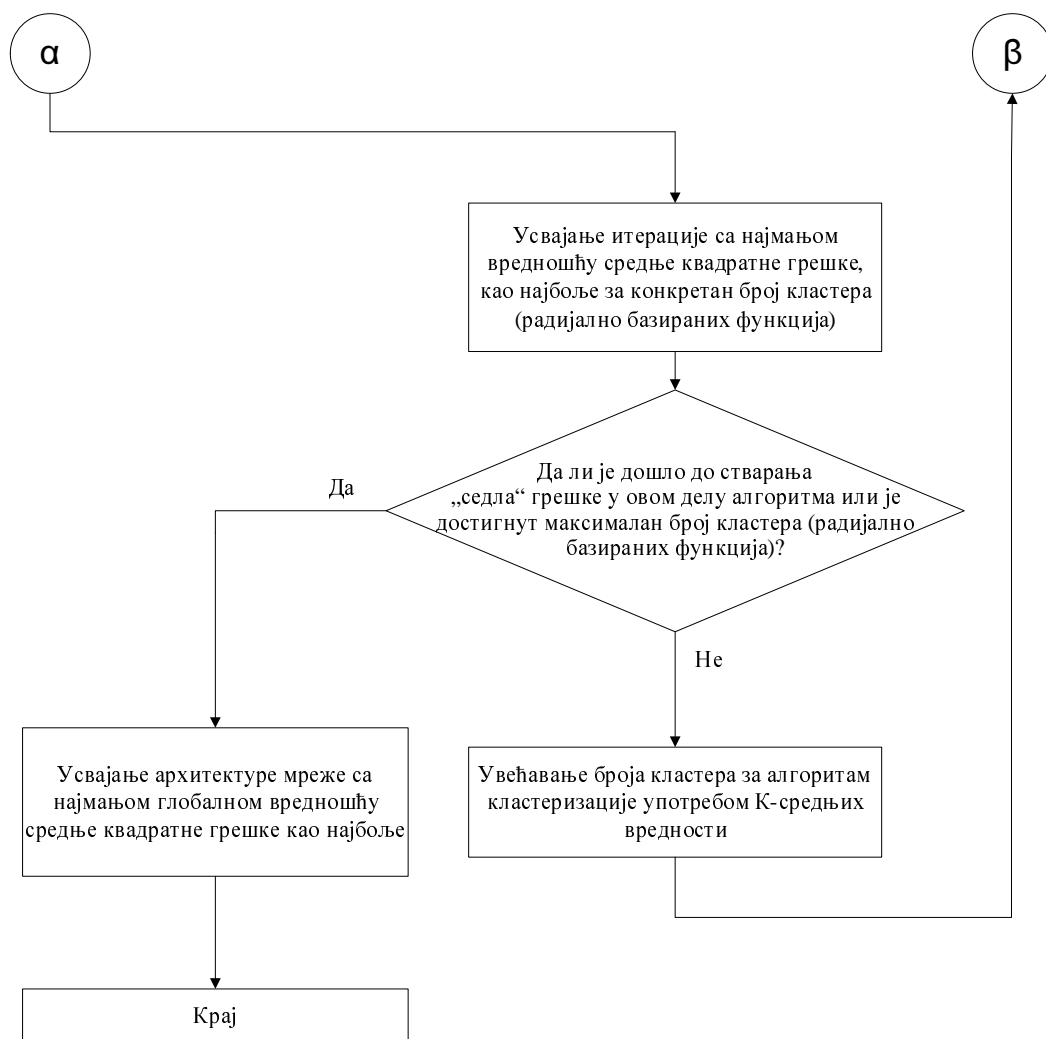
Након што је одређен утицај промене ширина радијалних функција на оптимизациону функцију грешке, могуће је извршити корекцију ширина - обуку. Стандардно је да се обука врши са коефицијентом учења  $\eta$  чија вредност припада опсегу  $[0, 1]$  и одређује степен корекције сваке ширине. Коначан израз промене ширине сваке појединачне радијалне функције приказан је у (5.5).

$$\Delta\sigma_j = \eta \cdot \frac{d \text{cost\_fn}}{d \sigma_j} \tag{5.5}$$

### 5.2.3 Имплементација предложеног хибридног алгоритама обуке

На основу претходне анализе, могуће је имплементирати хибридни алгоритама обуке вештачких неуронских мрежа са радијално базираним функцијама. Алгоритама тока сигнала рачунарске имплементације предложеног хибридног алгоритама обуке, приказан је на Слици 5.3.





Слика 5.3: Алгоритам тока сигнала рачунарске имплементације хибридног алгоритма обуке вештачких неуронских мрежа са радијално базираним функцијама

## Примена алгоритма за одређивање оптималног скупа улаза у софт сензор и кашњења сваког од њих

Алгоритам за одређивање оптималног скупа улаза у софт сензор и кашњења сваког од њих примењен је на два типа система. Први систем коришћен је за верификацију алгоритма на унапред познатом скупу најбољих сигнала и њихових кашњења. Ово је урађено како би била потврђена успешност претраге простора скупова улаза и њихових кашњења. Друга примена приказаног алгоритма је на реалним процесима добијања цемента. Код реалних процеса је непознат оптималан скуп сигнала и њихових кашњења и тиме је предложени алгоритам од изузетне користи.

### 6.1 Верификација алгоритма употребом познатог скупа најбољих сигнала

У овом делу истраживања, креиран је нелинеарни модел који има неколико улаза и један излаз. Излаз из модела ће за алгоритам представљати сигнал од интереса. Вредности излазног сигнала су израчунате довођењем

вредности изабраних сигнала са изабраним кашњењем на улазе у модел. Креирани модел заснован је на вишедимензионалној Росенброковој функцији (РФ) [60], чија форма је, за  $N$  улаза, приказана једначином (6.1).

$$f(x) = \sum_{i=1}^{N-1} [100 \cdot (x_{i+1} - x_i^2) + (1 - x_i)^2], \quad (6.1)$$

$$x = [x_1, x_2, \dots, x_N]$$

У циљу креирања скупа података за верификацију предложеног алгоритма, одлучено је да Росенброкова функција буде петодимензионална. Улазни сигнали и њихова кашњења изабрани су употребом функције случајне расподеле. Ови сигнали изабрани су из скупа од 16 сигнала чије су вредности прикупљене током континуалне продукције једног индустријског процеса. Како конкретни називи сигнала за овај део истраживања нису неопходни, исти ће бити означени нотацијом сигнал<sub>1</sub>, сигнал<sub>2</sub>, ..., сигнал<sub>16</sub>. Случајно одабрани сигнали и њихова кашњења приказани су у Табели 6.1.

Табела 6.1: Случајно изабрани сигнали и њихова кашњења за Росенброкову функцију

Назив сигнала	Кашњење
сигнал <sub>2</sub>	7
сигнал <sub>4</sub>	20
сигнал <sub>7</sub>	1
сигнал <sub>9</sub>	19
сигнал <sub>10</sub>	25

Након израчунавања вредности излаза модела над свим опсервацијама улазних сигнала приказаних у Табели 6.1, креирани су и уређени парови [вредности улаза, вредност излаза] над којима ће алгоритам представљен у овом раду бити тестиран.

Алгоритам одређивања улаза и њихових кашњења који садрже највише информација о излазу из модела примењен је на скупу свих потенци-

јалних улазних сигнала. При примени алгоритма, претпостављено је да сваки од 16 приказаних сигнала може бити закашњен од 0 до максимално 40 целобројних временских интервала. Алгоритам је извршен пет пута са циљем провере доследности добијених резултата.

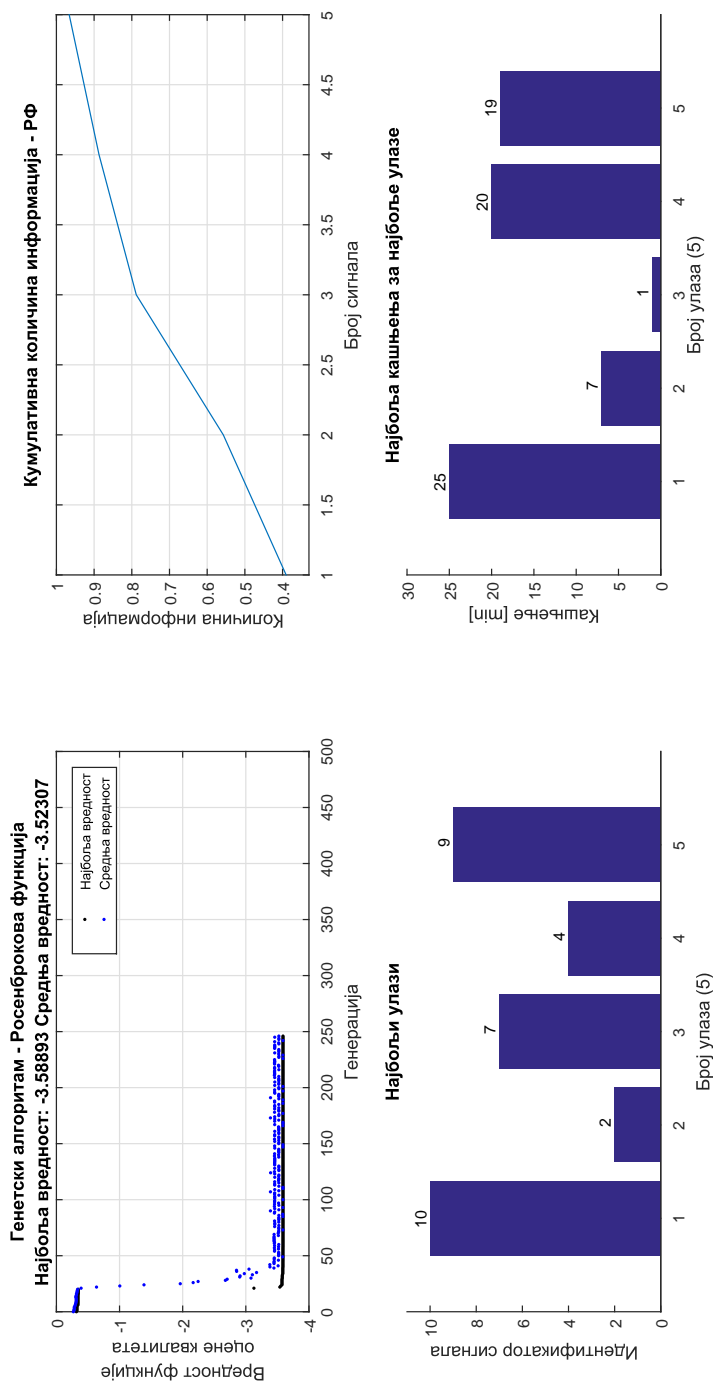
Током претходно поменутих извршавања алгоритма, добијена су три различита скупа сигнала и њихових кашњења, за које је алгоритам одредио да садрже највише информација о излазу. Број понављања свих скупова сигнала приказан је у Табели 6.2.

Табела 6.2: Скупови сигнала одређени алгоритмом за Росенброкову функцију

Назив скупа	Бр. понављања
РФ Скуп сигнала 1 ( $C_1^{P\Phi}$ )	3
РФ Скуп сигнала 2 ( $C_2^{P\Phi}$ )	1
РФ Скуп сигнала 3 ( $C_3^{P\Phi}$ )	1

Скупови приказани у Табели 6.2 су се међусобно поклапали 80%, односно 4 сигнала и њихова кашњења били су заједнички свим скуповима. Узрок разликовања скупова изазван је међусобном процесном зависношћу сигнала сигнал<sub>1</sub>, сигнал<sub>2</sub>, ..., сигнал<sub>16</sub> добијених из континуалне продукције индустријског процеса.

$C_1^{P\Phi}$ , који се међу резултатима поновио највише пута, представљао је заправо и једини тачан скуп за овај систем, јер се 100% поклапао са сигналима из Табеле 6.1. Ковергенцију оптимизационог алгоритма када се на излазу појављивао скуп  $C_1^{P\Phi}$ , могуће је приметити на Слици 6.1. Раст информација о излазном сигналу настао додавањем сваког сигнала из  $C_1^{P\Phi}$  такође је приказан на Слици 6.1. Тамо је могуће приметити да је алгоритмом одређено да сигнали из  $C_1^{P\Phi}$  садрже укупно 98% информација о сигналу од интереса.



Слика 6.1: Конвергенција генетског алгоритма и раст количине информација - Росенброкова функција



## 6.2 Примена алгоритма на реалним процесима производње цемента

Након што је утврђено да приказани алгоритам постиже квалитетне резултате, исти је примењен на процесима производње цемента. Као што је претходно већ поменуто, најважнија особина цемента, који је финални производ овог процеса, јесте његова финоћа. Вредности ове величине добијају се лабораторијском анализом и стога финоћа цемента спада у тешко мерљиве величине. Из тог разлога, предложени алгоритам је примењен на величинама које се мере у реалном времену у процесу млевења цемента, са циљем одређивања сигнала и њихових кашњења који поседују највише информација о финоћи цемента. На основу вредности пронађених сигнала и њихових кашњења, могуће је вршити естимацију финоће цемента у реалном времену.

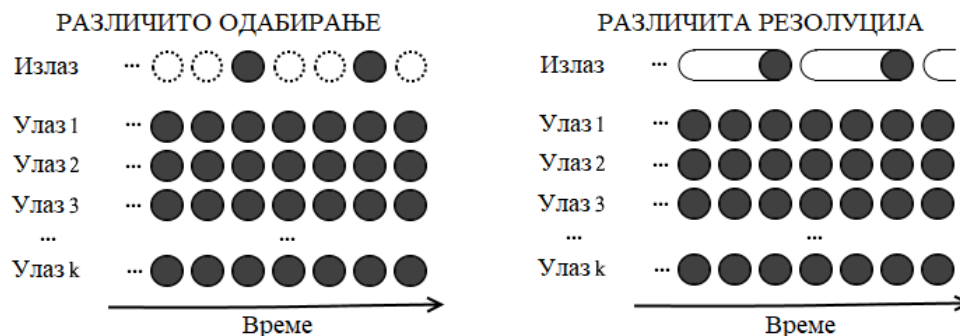
Алгоритам предложен у овом раду примењен је на подацима из два процеса млевења цемента, који се међусобно разликују у начину вршења лабораторијске анализе. Ови процеси млевења цемента ће у даљем тексту бити названи Процес са композитним узорковањем ( $P_{KY}$ ) и Процес са спот узорковањем ( $P_{CY}$ ). Алгоритам је у оба случаја примењен на подацима који су добијени током континуалне производње цемента у трајању од 12 месеци. Подаци су прво обрађени како би биле одстрањене невалидне ситуације (енгл. *outliers*), а затим су организовани у матрице.

### 6.2.1 Обрада података

За излазни сигнал од интереса и сваког кандидата за улаз дефинисани су радни опсези вредности који су стандардни током нормалне продукције цемента. Ово је урађено посматрањем историјских података и уз консултације са стручним лицима задуженим за надгледање процеса. Вредности свих сигнала које су ван дефинисаних опсега су обрисане, јер се сматра да је у тим моментима или дошло до квара неког од сензора или је процес био потпуно заустављен. Подаци су затим организовани у матрице

димензија  $t \times 2$ . Свака матрица заправо представља вредности сигнала у времену где вредности прве колоне одговарају временским тренуцима, а друга представља вредност сигнала у конкретном временском тренутку. Периода одабирања свих сигнала који представљају кандидате за улазе је 1 минут.

За лабораторијску анализу, која се врши са циљем добијања вредности финоће цемента, потребно је одређено време. Ово време разликује се од постројења до постројења. Када су трајања лабораторијских анализа утврђена, потребно је сваки временски тренутак у ком је уписана вредност финоће цемента умањити за утврђени период. Ово је потребно урадити како би ти временски тренуци заправо представљали тренутке кад је узет узорак за лабораторијску анализу, а не тренутке када је лабораторијска анализа завршена. Као што је у другом поглављу и описано, узорци могу бити композитни и спот. У случају композитног узорака, код ког се материјал прикупља током одређеног временског периода па тек онда врши анализа, финоћа цемента заправо представља средњу вредност финоће током тог временског периода. Проблем обраде података у случају моделовања оваквих процеса приказан је у радовима [61] и [62], где је назван проблемом различите резолуције (енгл. *multiresolution*). Према ауторима, код овог типа проблема, неопходно је вредности сваког појединачног сигнала кандидата за улаз заменити са средњом вредношћу тог сигнала током временског периода у ком је узорак креиран. Моделовање процеса у ком се лабораторијска анализа врши над спот узорком у литератури се појављује као проблем различитог одабирања (енгл. *multirate*) [63, 64], где су приказани основни принципи обраде података код оваквих типова процеса. На Слици 6.2 могуће је приметити графичку репрезентацију опсервација свих сигнала у случају композитних узорака и у случају спот узорака, где су опсервације сигнала означене кругом испуњеним црном бојом.



Слика 6.2: Графичка репрезентација различитих типова узорковања

У оквиру наредних потпоглавља биће приказани резултати предложеног алгоритма на подацима добијеним из оба претходно поменути типа процеса. У оквиру П<sub>КУ</sub>, лабораторијска анализа врши се над композитним узорком, где је трајање креирања узорка 30 минута и лабораторијска анализа се врши сваких сат времена. У оквиру П<sub>СУ</sub>, лабораторијска анализа је вршена над спот узорком на сваких 12 минута. У случају оба индустријска процеса, оптимизациони алгоритам претраге простора скупова улазних сигнала и њихових кашњења је извршаван 10 пута и пронађено је неколико скупова сигнала и њихових кашњења који могу бити сматрани за најбоље. И овог пута је примећено да постоје велика преклапања међу скуповима. Сигнали који се у различитим скуповима не поклапају су заправо повезани у процесу. Пример је појава закашњеног сигнала количине сировог материјала на улазу млина и сигнала количине поврата из млина у неким скуповима, док се у другим скуповима уместо тога јављује закашњени сигнал укупне количину материјала у млину, што је заправо исто, јер сума количине сировог материјала и количине поврата представља укупну количину материјала.

У случају оба процеса биће представљене количине информација које садрже сигнали изабрани од стране предложеног алгоритма и сигнали који су изабрани применом стандардних процедура из научне литературе.

## 6.2.2 Процес са композитним узорковањем

Сви сигнали који представљају кандидате за улазе у софт сензор у случају процеса са композитним узорковањем (ПКУ) приказани су у Табели 6.3. Предложени алгоритам извршен је 10 пута на историјским подацима сигнала из Табеле 6.3, како би пронашао подскуп од 10 сигнала и њихових кашњења који садрже највећу количину информација о сигналу финоће цемента. Неколико скупова сигнала и њихових кашњења су одређени као најбољи. Број појављивања сваког од тих скупова приказан је у Табели 6.4. Примећено је да се сви скупови изабрани од стране алгоритма поклапају 70%.

Табела 6.3: Кандидати за улазе у софт сензор - ПКУ

Идентификатор	Назив сигнала
1	Снага главног мотора млина
2	Поврат
3	Ротациона брзина сепаратора
4	Температура производа на излазу из млина
5	Притисак након млина
6	Притисак након сепаратора
7	Притисак пре млина
8	Електрично уво коморе 1
9	Електрично уво коморе 2
10	Количина сировина на улазу у млин
11	Снага мотора кофичастог транспортера
12	Вага клинкера
13	Вага шљаке
14	Вага кречњака
15	Вага гипса
16	Укупна количина материјала на улазу у млин
17	Температура ваздуха након млина
18	Температура ваздуха након филтера

Табела 6.4: Број појављивања сваког подскупа сигнала -  $\Pi_{КУ}$


Назив подскупа	Бр. појављивања
$\Pi_{КУ}$ Скуп сигнала 1 ( $C_1^{\Pi_{КУ}}$ )	6
$\Pi_{КУ}$ Скуп сигнала 2 ( $C_2^{\Pi_{КУ}}$ )	2
$\Pi_{КУ}$ Скуп сигнала 3 ( $C_3^{\Pi_{КУ}}$ )	2

Скуп сигнала  $C_1^{\Pi_{КУ}}$  се са највећом вероватноћом појављује на излазу оптимизационог алгоритма претраге простора скупова улазних сигнала и њихових кашњења у  $\Pi_{КУ}$ . Из овог разлога, резултати приказани у оквиру овог потпоглавља односе се управо на овај скуп сигнала.

На Слици 6.3 могуће је приметити на који је начин конвергирао оптимизациони алгоритам претраге простора скупова улазних сигнала и њихових кашњења приликом појављивања  $C_1^{\Pi_{КУ}}$  на излазу. На истој слици је могуће приметити и који су сигнали садржани у скупу сигнала  $C_1^{\Pi_{КУ}}$  као и кашњења сваког од њих. Детаљнији опис сваког од сигнала који се налази у  $C_1^{\Pi_{КУ}}$  приказан је у Табели 6.5.

Табела 6.5: Сигнали и њихова кашњења -  $C_1^{\Pi_{КУ}}$

Идентификатор	Назив сигнала	Кашњење [m]
10	Количина сировина на улазу у млин	19
9	Електрично уво коморе 2	19
2	Поврат	25
5	Притисак након млина	14
7	Притисак пре млина	28
2	Поврат	1
3	Ротациона брзина сепаратора	0
9	Електрично уво коморе 2	1
8	Електрично уво коморе 1	18
4	Темп. производа на излазу из млина	2




Слика 6.3: Конвергенција оптимизационог алгоритма у случају одабира скупа сигнала  $C_1^{\Pi_{KV}}$

Количина информација коју сигнали скупа  $C_1^{ПКУ}$  садрже је упоређена са количином информација коју садрже сигнали изабрани у раду [41]. Разлог овоме лежи у томе да су аутори тог рада посматрали готово исти индустријски процес. Имена сигнала и њихова кашњења над којима је заснована естимација у [41] приказани су у оквиру Табеле 6.6.

Табела 6.6: Скуп сигнала над којим је заснована естимација у раду [41]

Идентификатор	Назив сигнала	Кашњење [m]
9	Електрично уво коморе 2	0
12	Вага клинкера	30
5	Снага главног мотора млина	15
11	Снага мотора кофичастог транспортера	0
4	Темп. производа на излазу из млина	0
3	Ротациона брзина сепаратора	0

Разлике у количинама информација о финоћи цемента у  $ПКУ$  коју садрже сигнали и њихова кашњења одређени приказаним алгоритмом и сигнали и њихова кашњења који су предложени у раду [41], могуће је приметити на Слици 6.4. На истој слици могуће је приметити да сигнали и њихова кашњења одређени предложеним алгоритмом садрже много више информација о финоћи цемента у  $ПКУ$  од сигнала који су изабрани на основу стандардних процедура пронађених у научној литератури. Такође је могуће приметити да је доминантна количина информација садржана у првих седам сигнала, који носе 99% информација.



Слика 6.4: Кумулативна количина информација о финоћи цемента коју садрже сигнали одређени предложеним алгоритмом (обележено црвеном континуалном линијом) и сигнали изабрани у раду [41] (обележено плавом испрекиданом линијом) -  $P_{ку}$

### 6.2.3 Процес са спот узорковањем

Сигнали кандидати за улазе у софт сензор за естимацију финоће цемента у процесу са спот узорковањем ( $P_{су}$ ) приказани су у Табели 6.7. Скупови сигнала и њихових кашњења који су се нашли на излазу услед 10 извршавања предложеног алгоритма на сигналима из Табеле 6.7 приказани су у Табели 6.8. У истој табели приказан је број појављивања сваког скупа сигнала на излазу оптимизационог алгоритма. У случају  $P_{су}$ , скупови су се међусобно преклапали 60%. Резултати који су приказани у овом потпоглављу везани су уз скуп сигнала  $C_4^{P_{су}}$ , јер  $C_4^{P_{су}}$  носи највећу вероватноћу тачности избора сигнала за поменућу примену. Јаснији опис сигнала садржаних у скупу  $C_4^{P_{су}}$  приказан је у Табели 6.9.



Табела 6.7: Кандидати за улазе у софт сензор - П<sub>СУ</sub>


Идентификатор	Назив сигнала
1	Брзина вентилатора рецикулације
2	Електрично уво коморе 1
3	Паметни сензор напуњености коморе 1
4	Паметни сензор напуњености коморе 2
5	Снага мотора кофичастог транспортера 1
6	Снага мотора кофичастог транспортера 2
7	Ротациона брзина сепаратора
8	Снага главног мотора млина 1
9	Снага главног мотора млина 2
10	Вага гипса
11	Вага шљаке
12	Притисак након филтера
13	Температура ваздуха након млина
14	Температура ваздуха након филтера
15	Притисак након млина
16	Вага клинкера
17	Температура производа на излазу из млина
18	Поврат
19	Укупна количина материјала на улазу у млин

Табела 6.8: Број појављивања сваког подскупа сигнала - П<sub>СУ</sub>

Назив подскупа	Бр. појављивања
П <sub>СУ</sub> Скуп сигнала 1 ( $C_1^{П_{СУ}}$ )	1
П <sub>СУ</sub> Скуп сигнала 2 ( $C_2^{П_{СУ}}$ )	2
П <sub>СУ</sub> Скуп сигнала 3 ( $C_3^{П_{СУ}}$ )	1
П <sub>СУ</sub> Скуп сигнала 4 ( $C_4^{П_{СУ}}$ )	5
П <sub>СУ</sub> Скуп сигнала 5 ( $C_5^{П_{СУ}}$ )	1

Начин конвергенције оптимизационог алгоритма, као и идентификатори најбољих сигнала и њихова кашњења када се скуп сигнала  $S_4^{Псу}$  нашао на излазу, приказани су на Слици 6.5.

Пре саме примене алгоритма на подацима из  $Псу$ , временска кашњења сваког сигнала који је приказан у Табели 6.7 су приближно утврђена. Ово је урађено посматрањем историјских података и анализом дужине трајања сваког дела процеса млевења цемента. Посматрани  $Псу$  је карактеристичан и значајно се разликује од  $Пку$  па у научној литератури не постоје резултати са којима би количина информација коју носе сигнали скупа  $S_4^{Псу}$  могла бити упоређена. Због претходно наведеног разлога, упоређена је количина информација о финоћи цемента која је садржана у  $S_4^{Псу}$  и количина коју садрже сигнали из  $S_4^{Псу}$  уколико су приближно закашњени. Разлике у количинама информација могуће је приметити на Слици 6.6. Као и у случају  $Пку$ , могуће је приметити да скуп сигнала одабран оптимизационим алгоритмом,  $S_4^{Псу}$ , садржи већу количину информација о финоћи цемента од скупа сигнала са којим је упоређен. Такође је приметно да је доминантан део информација коју  $S_4^{Псу}$  носи, садржан у првих 7 сигнала и да он износи 98%. Као што је већ напоменуто, циљ је пронаћи што мањи скуп сигнала који садржи што више информација о жељеном сигналу излаза, те се бенефит приказаног алгоритма у случају  $Псу$  огледа у томе да првих 7 сигнала  $S_4^{Псу}$  садрже значајно већу количину информација од првих 7 сигнала скупа са којим су упоређени.



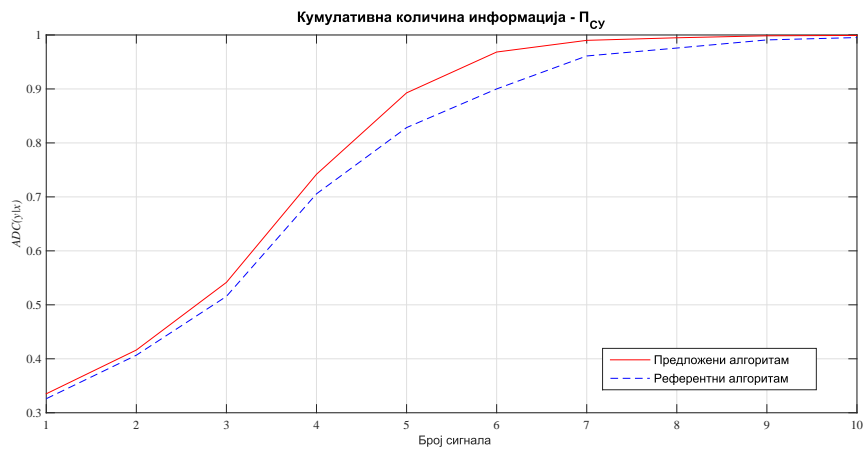
Слика 6.5: Конвергенција оптимизационог алгоритма у случају одабира сигнала  $C_4^{Псу}$

Табела 6.9: Сигнали и њихова кашњења -  $C_4^{ПСУ}$

Идентификатор	Назив сигнала	Кашњење [m]
11	Вага шљаке	23
6	Снага мотора кофичастог транспортера 2	13
9	Снага главног мотора млина 2	4
8	Снага главног мотора млина 1	3
8	Снага главног мотора млина 1	15
9	Снага главног мотора млина 2	20
7	Ротациона брзина сепаратора	2
18	Поврат	31
9	Снага главног мотора млина 2	11
9	Снага главног мотора млина 2	35

Табела 6.10: Сигнали закашњени на основу визуелне инспекције -  $ПСУ$

Идентификатор	Назив сигнала	Кашњење [m]
11	Вага шљаке	23
6	Снага мотора кофичастог транспортера 2	10
9	Снага главног мотора млина 2	1
8	Снага главног мотора млина 1	1
8	Снага главног мотора млина 1	15
9	Снага главног мотора млина 2	20
7	Ротациона брзина сепаратора	1
18	Поврат	3
9	Снага главног мотора млина 2	10
9	Снага главног мотора млина 2	35



Слика 6.6: Кумулативна количина информација о финоћи цемента коју садрже сигнали одређени предложеним алгоритмом (обележено црвеном континуалном линијом) и сигнали приближно закашњени (обележено плавом испрекиданом линијом) -  $P_{су}$

## Примена хибридног алгоритма обуке вештачких неуронских мрежа са радијално базираним функцијама

Приказани хибридни алгоритам обуке ВМ-РБФ могуће је употребити у комбинацији са алгоритмом за одређивање оптималног скупа улаза у софт сензор и кашњења сваког од њих. Из овог разлога, примена хибридног алгоритма обуке извршена је на резултатима добијеним у претходном поглављу.

У оба посматрана реална индустријска процеса, креирана су по три софт сензора. Архитектура два софт сензора је заснована на вештачким неуронским мрежама са радијално базираним функцијама које су обучене приказаним хибридним алгоритмом обуке. Трећи софт сензор је базиран на архитектури вештачких неуронских мрежа заснованој на перцептронима (енгл. *feed-forward*).

Један од два софт сензора заснована на ВМ-РБФ формиран је над сигнаlima и њиховим кашњењима који су резултат предложеног алгоритма за одређивање оптималног скупа сигнала и кашњења. Други софт сензор је формиран над сигнаlima који су одређени стандардним про-

цедурама из научне литературе. Разлог креирања ова два софт сензора јесте верификација резултата алгоритма за одређивање оптималног скупа сигнала и кашњења у практичној примени.

Параметри обуке оба софт сензора заснована на ВНМ-РБФ одређени су емпиријски и следе:

- број кластера: варијабилан од 5 до 50 са кораком 1
- максималан број итерација пропагације уназад: 200
- заустављање алгоритма пропагације уназад: 6 узастопних итерација пораст грешке над валидационим скупом
- заустављање читавог алгоритма: 6 узастопних итерација кластеризације пораст најмање грешке алгоритма пропагације уназад
- коефицијент брзине учења: 0.15

Софт сензор архитектуре вештачке неуронске мреже засноване на перцептронима формиран је над сигналима и њиховим кашњењима који су одређени алгоритмом предложеним у овом раду. Структура овог софт сензора садржи један скривени слој са 6 перцептрона. Софт сензор је обучен користећи Левенберг-Марквард алгоритам пропагације грешке уназад који је, у комбинацији са поменутом структуром, показао квалитетне резултате за овај тип проблема [41]. Циљ креирања овог типа софт сензора јесте упоређивање резултата постигнутих различитим архитектурама и тестирање квалитета предложеног хибридног алгоритма обуке.

Сви креирани софт сензори обучени су да врше естимацију финоће цемента. Скуп података за обуку садржао је 3600 опсервација где је 60% података искоришћено за саму обуку, а 40% за валидацију. Као што је већ приказано, током овог истраживања посматрана су два процеса производње цемента који имају различите карактеристике. Ради лакшег праћења резултата ово поглавље подељено је на два потпоглавља, а свако од потпоглавља представља резултате постигнуте у једном процесу производње

цемента. Оба посматрана процеса детаљније су описана у претходним поглављима и то, поглављу бр. 2 и 4.

За оба посматрана процеса производње цемента, упоређене су естимације финоће цемента:

- кад су сигнали и њихова кашњења одређени користећи предложени алгоритам и кад су сигнали и њихова кашњења одређени стандардним процедурама (архитектура и начин обуке оба софт сензора су исти)
- у случају да је начин одабира улазних сигнала и њихових кашњења исти али су архитектура и начин обуке софт сензора различити (ВНМ-РБФ и вештачке неуронске мреже базиране на перцептронима)

Приликом упоређивања различитих архитектура и начина обуке софт сензора дата је и упоредна анализа робусности оба софт сензора и анализа "старења" софт сензора до ког долази услед различитих промена и хабања у самом индустријском процесу.

Квантификовање квалитета естимације сваког софт сензора извршено је израчунавањем средње апсолутне грешке естимације. Овај израз приказан је у (7.1), где  $MAE$  представља средњу апсолутну грешку,  $ys$  естимацију софт сензора а  $yl$  представља стварну вредност добијену лабораторијском анализом.

$$MAE = \frac{\sum_{i=1}^n |ys_i - yl_i|}{n} \quad (7.1)$$

## 7.1 Процес са композитним узорковањем

Софт сензори за естимацију финоће цемента који су креирани у процесу са композитним узорковањем ( $\Pi_{КУ}$ ) приказани су у Табели 7.1. Тамо је могуће видети ближи опис архитектуре, начина обуке и начина одабира улаза и њихових кашњења за сваки од софт сензора. Софт сензор 1




( $\text{СфС}_1^{\text{ПКУ}}$ ) је потпуно базиран на алгоритмима приказаним у овом раду, архитектура Софт сензора 2 ( $\text{СфС}_2^{\text{ПКУ}}$ ) је базирана на ВНМ-РБФ и приказаном алгоритму обуке док је избор улаза и кашњења извршен употребом референтних алгоритама из научне литературе, а архитектура Софт сензора 3 ( $\text{СфС}_3^{\text{ПКУ}}$ ) је заснована на вештачким неуронским мрежама са перцептронима док су улази и њихова кашњења одређени алгоритмом приказаним у овом раду.

Табела 7.1: Преглед креираних софт сензора - ПКУ


Назив	Архитектура и обука	Сигнали и кашњења
Софт сензор 1 ( $\text{СфС}_1^{\text{ПКУ}}$ )	приказани алг.	приказани алг.
Софт сензор 2 ( $\text{СфС}_2^{\text{ПКУ}}$ )	приказани алг.	референтни алг.
Софт сензор 3 ( $\text{СфС}_3^{\text{ПКУ}}$ )	референтни алг.	приказани алг.

### 7.1.1 Примена резултата алгоритма за одређивање оптималног скупа сигнала и њихових кашњења у естимацији

На Сликама 7.1 и 7.2 приказане су конвергенције алгоритама обуке у случају  $\text{СфС}_1^{\text{ПКУ}}$  и  $\text{СфС}_2^{\text{ПКУ}}$ , ретроспективно. У горњем делу слика приказане су промене грешака приликом повећавања броја кластера током обуке. У доњем делу слика могуће је приметити промене грешака у извођењу алгоритма пропагације уназад за назначени броја кластера. У облику црвене звезде обележене су тачке [итерација, грешка] на оба графика, где су постигнуте најмање средње апсолутне грешке на валидационом скупу.




Слика 7.1: Конвергенција хибридног алгоритма обуке у случају коришћења сигнала из Табеле 6.5 -  $SFC_1^{ПКУ}$



Слика 7.2: Конвергенција хибридног алгоритма обуке у случају коришћења сигнала из Табеле 6.6 -  $SfC_2^{ПКУ}$

На Слици 7.3 дат је упоредни приказ естимација  $SfC_1^{ПКУ}$  и  $SfC_2^{ПКУ}$  над делом валидационог скупа. Квалитет естимација оба софт сензора над читавим валидационим скупом утврђен средњом апсолутном грешком дат је у Табели 7.2.



Слика 7.3: Упоредни приказ естимација  $SfC_1^{ПКУ}$  и  $SfC_2^{ПКУ}$  над делом валидационог скупа

Табела 7.2: Средња апсолутна грешка естимације  $SfC_1^{Пкy}$  и  $SfC_2^{Пкy}$


Назив	Средња апсолутна грешка естимације
$SfC_1^{Пкy}$	0.03406
$SfC_2^{Пкy}$	0.04483

### 7.1.2 Упоређивање естимација вештачких неуронских мрежа са радијално базираним функцијама и вештачких неуронских мрежа базираних на перцептронима

На Слици 7.4 могуће је приметити разлике у естимацијама  $SfC_1^{Пкy}$  и  $SfC_3^{Пкy}$  над делом валидационог скупа. Квалитет естимација оба софт сензора над читавим валидационим скупом утврђен средњом апсолутном грешком дат је у Табели 7.3. Како на Слици 7.4, тако и у Табели 7.3, могуће је приметити да софт сензор креиран алгоритмима предложеним у овом раду постиже квалитетнију естимацију.

Табела 7.3: Средња апсолутна грешка естимације  $SfC_1^{Пкy}$  и  $SfC_3^{Пкy}$

Назив	Средња апсолутна грешка естимације
$SfC_1^{Пкy}$	0.03406
$SfC_3^{Пкy}$	0.03620



Слика 7.4: Упоредни приказ естимација  $SFC_1^{ПКУ}$  и  $SFC_3^{ПКУ}$  над делом валидационог скупа

### Упоредивање робусности


Као што је већ напоменуто, упоређивање робусности вештачких неуронских мрежа са радијално базираним функцијама, са вештачким неуронским мрежама заснованим на перцептронима извршено је на два начина. Први начин јесте довођењем шума на неки од улаза и праћењем квалитета естимације, а други је праћење ”застаревања” модела при употреби истих у реалном времену.

Једна од најбитнијих величина које директно утичу на финоћу цемента је ротациона брзина сепаратора, и стога је ради упоређивања робусности, одлучено да на тај сигнал буде доведен бели шум амплитуде 3% радног опсега самог сигнала. На Слици 7.5 приказан је упоредни приказ естимација  $SfC_1^{Пкв}$  и  $SfC_3^{Пкв}$  над делом валидационог скупа уколико се на сигналу ротационе брзине сепаратора појави поменути шум. Средње апсолутне грешке естимација  $SfC_1^{Пкв}$  и  $SfC_3^{Пкв}$  у овом случају приказане су у Табели 7.4.

Неминовно је да током континуалне производње долази до хабања неких механичких делова самог процеса и управо то хабање уноси промене у процес. Из овог разлога, упоређене су естимације вршене вештачким неуронским мрежама са радијално базираним функцијама и вештачким неуронским мрежама заснованим на перцептронима у реалном времену током 3 месеца. У оквиру Слике 7.6 приказане су естимације током првог месеца од креирања и обуке модела, током другог и током трећег месеца. У Табели 7.5 могуће је приметити вредности средње апсолутне грешке (САГ)  $SfC_1^{Пкв}$  и  $SfC_3^{Пкв}$  током сваког од периода.


Табела 7.4: Средња апсолутна грешка естимације  $SfC_1^{Пкв}$  и  $SfC_3^{Пкв}$  у случају зашумљеног сигнала ротационе брзине сепаратора

Назив	Средња апсолутна грешка естимације
$SfC_1^{Пкв}$	0.04170
$SfC_3^{Пкв}$	0.05631



Слика 7.5: Упоредни приказ естимација  $SFC_1^{ПКУ}$  и  $SFC_3^{ПКУ}$  над делом валидационог скупа уколико је сигнал ротационе брзине сепаратора зашумљен





Слика 7.6: Упоредни приказ делова естимација у реалном времену  $SFC_1^{ПКУ}$  и  $SFC_3^{ПКУ}$  при тромесечној евалуацији

Табела 7.5: Средња апсолутна грешка естимације  $SfC_1^{ПКУ}$  и  $SfC_3^{ПКУ}$  током сваког месеца тромесечне евалуације

Назив	САГ Први м.	САГ Други м.	САГ Трећи м.
$SfC_1^{ПКУ}$	0.04901	0.05426	0.07934
$SfC_3^{ПКУ}$	0.05210	0.05695	0.07721

## 7.2 Процес са спот узорковањем

Софт сензори креирани за естимацију финоће цемента у процесу са спот узорковањем ( $П_{СУ}$ ) са описом архитектуре и начином обуке и начином одабира улаза и њихових кашњења приказани су у Табели 7.6. Детаљнији начин тумачења табеле дат је у претходном потпоглављу.


Табела 7.6: Преглед креираних софт сензора -  $П_{СУ}$

Назив	Архитектура и обука	Сигнали и кашњења
Софт сензор 1 ( $SfC_1^{П_{СУ}}$ )	приказани алг.	приказани алг.
Софт сензор 2 ( $SfC_2^{П_{СУ}}$ )	приказани алг.	референтни алг.
Софт сензор 3 ( $SfC_3^{П_{СУ}}$ )	референтни алг.	приказани алг.


### 7.2.1 Примена резултата алгоритма за одређивање оптималног скупа сигнала и њихових кашњења у естимацији

На Сликама 7.7 и 7.8 приказане су конвергенције предложеног хибридног алгоритма обуке за  $SfC_1^{П_{СУ}}$  и  $SfC_2^{П_{СУ}}$ , ретроспективно. Као и у претходном потпоглављу, у горњем делу слика приказане су промене грешака приликом повећавања броја кластера током обуке. Доњи део слике представља промену грешке током алгоритма пропагације грешке уназад над итерацијом са оптималним бројем кластера. У облику црвене звездице обележене су тачке [итерација, грешка] на оба графика где су најмање

средње апсолутне грешке над валидационим скупом.




Слика 7.7: Конвергенција хибридног алгоритма обуке у случају коришћења сигнала из Табеле 6.9 -  $SFC_1^{Псу}$



Слика 7.8: Конвергенција хибридног алгоритма обуке у случају коришћења сигнала из Табеле 6.10 -  $SFC_2^{Псу}$

На Слици 7.9 дат је упоредни приказ естимација  $SFC_1^{Псу}$  и  $SFC_2^{Псу}$  над делом валидационог скупа. Квалитет естимација оба софт сензора над читавим валидационим скупом утврђен средњом апсолутном грешком дат је у Табели 7.7.



Слика 7.9: Упоредни приказ естимација  $SfC_1^{псу}$  и  $SfC_2^{псу}$  над делом валидационог скупа

Табела 7.7: Средња апсолутна грешка естимације  $SfC_1^{Псу}$  и  $SfC_2^{Псу}$


Назив	Средња апсолутна грешка естимације
$SfC_1^{Псу}$	0.02162
$SfC_2^{Псу}$	0.04891

### 7.2.2 Упоређивање естимација вештачких неуронских мрежа са радијално базираним функцијама и вештачких неуронских мрежа базираних на перцептронима

На Слици 7.10 могуће је приметити разлике у естимацијама  $SfC_1^{Псу}$  и  $SfC_3^{Псу}$  над делом валидационог скупа. Квалитет естимације оба софт сензора над читавим валидационим скупом утврђен средњом апсолутном грешком дат је у Табели 7.8. Као и у случају  $П_{КУ}$ , на Слици 7.10 и у Табели 7.8, могуће је приметити да софт сензор креиран алгоритмима предложеним у овом раду постиже квалитетнију естимацију.

Табела 7.8: Средња апсолутна грешка естимације  $SfC_1^{Псу}$  и  $SfC_3^{Псу}$

Назив	Средња апсолутна грешка естимације
$SfC_1^{Псу}$	0.02162
$SfC_3^{Псу}$	0.02303



Слика 7.10: Упоредни приказ естимација  $SFC_1^{ПСУ}$  и  $SFC_3^{ПСУ}$  над делом валидационог скупа

### Упоредивање робусности

Као и у случају претходног процеса, упоређивање робусности вештачких неуронских мрежа са радијално базираним функцијама, са вештачким неуронским мрежама заснованим на перцептронима извршено је на два начина. Први је опет био довођење шума на неки од улаза и упоређивањем квалитета естимације, док је други упоређивање ”застаревања” модела при употреби истих у реалном времену.


Из разлога поменутих у претходном потпоглављу, сигнал ротационе брзине сепаратора је зашумљен шумом амплитуде 3% радног опсега самог сигнала. На Слици 7.11 је могуће видети упоредне приказе естимација  $SfC_1^{Псy}$  и  $SfC_3^{Псy}$  над делом валидационог скупа након довођења шума на улазни сигнал. Средње апсолутне грешке естимације оба софт сензора у овом случају приказане су у Табели 7.9.

Упоредене су естимације у реалном времену током 3 месеца вршене вештачким неуронским мрежама са радијално базираним функцијама и вештачким неуронским мрежама базираним на перцептронима. На Слици 7.12 приказане су естимације током првог месеца од креирања и обуке модела, током другог и током трећег месеца. У Табели 7.10 могуће је приметити вредности средње апсолутне грешке (САГ) естимација  $SfC_1^{Псy}$  и  $SfC_3^{Псy}$  током сваког од периода.

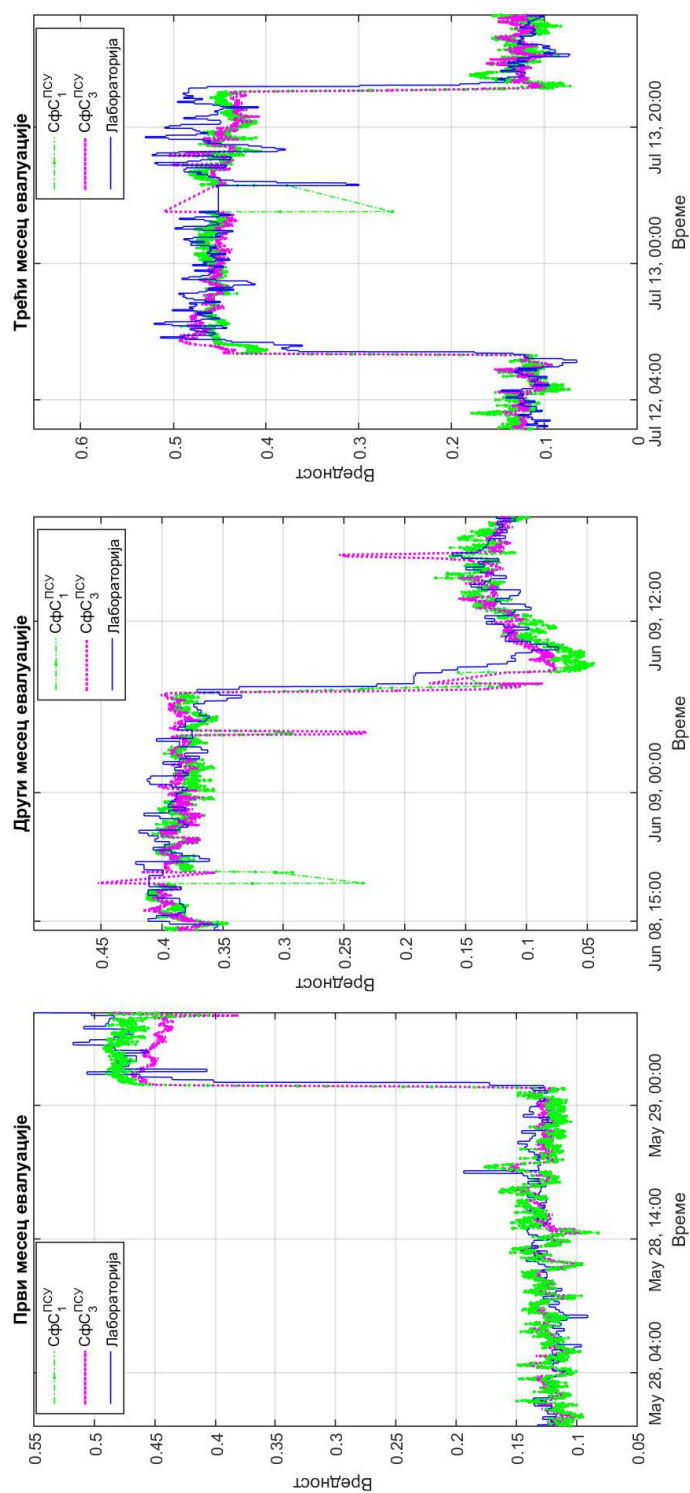
Табела 7.9: Средња апсолутна грешка естимације  $SfC_1^{Псy}$  и  $SfC_3^{Псy}$  када је сигнал ротационе брзине сепаратора зашумљен

Назив	Средња апсолутна грешка естимације
$SfC_1^{Псy}$	0.03420
$SfC_3^{Псy}$	0.04173





Слика 7.11: Упоредни приказ естимација  $Sfc_1^{psu}$  и  $Sfc_3^{psu}$  над делом валидационог скупа када је сигнал ротационе брзине сепаратора зашумљен



Слика 7.12: Упоредни приказ делова естимација у реалном времену  $SfC_1^{ПСУ}$  и  $SfC_3^{ПСУ}$  при тромесечној евалуацији

Табела 7.10: Средња апсолутна грешка естимације  $SfC_1^{II_{cy}}$  и  $SfC_3^{II_{cy}}$  током сваког месеца тромесечне евалуације


Назив	САГ Први м.	САГ Други м.	САГ Трећи м.
$SfC_1^{II_{cy}}$	0.0277	0.03974	0.06220
$SfC_3^{II_{cy}}$	0.0295	0.04069	0.06308

## Анализа постигнутих резултата

У приказаним резултатима, могуће је приметити да софт сензори креирани употребом алгоритама који су приказани у овом раду постижу боље резултате у оба тестирана процеса, у односу на софт сензоре креиране употребом референтних алгоритама из научне литературе.

На основу верификације алгорита за одређивање оптималног скупа улаза у софт сензор и кашњења сваког од њих (АООСУССК) у процесима производње цемента, могуће је приметити да је употребом АООСУССК постигнут виши квалитет естимације финоће цемента у поређењу са одабиром улаза и кашњења према стандардним процедурама из научне литературе. У Табелама 7.2 и 7.7 квантификовани су квалитети естимација софт сензора истих архитектура али различитих начина избора улазних сигнала и њихових кашњења. Упоредни приказ квалитета естимација ових софт сензора у оба посматрана процеса дат је на Слици 8.1. Посебно у случају примене АООСУССК у процесу са спот узорковањем ( $P_{CY}$ ), постигнут је значајно већи квалитет естимације финоће цемента. Узрок тога јесте да се у оквиру  $P_{CY}$ , квантификовање финоће врши над спот узорцима и од изузетне је важности тачно одређивање кашњења сваког улазног сигнала. У случају процеса са композитним узорковањем ( $P_{KY}$ ), финоћа је одређивана користећи композитне узорке, те су софт сензори креирани

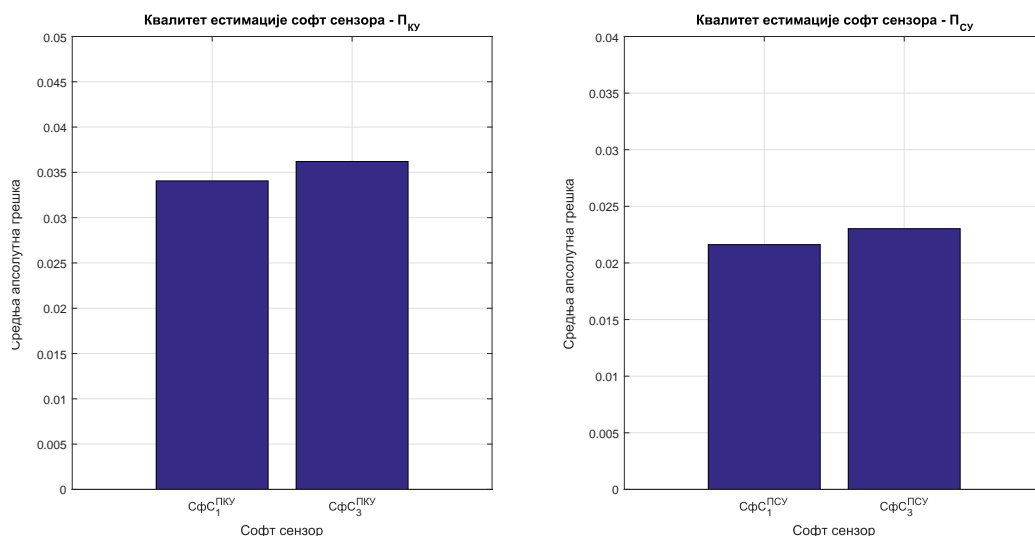
овде отпорнији на непрецизно одређена кашњења улазних сигнала јер финална вредност финоће представља просечну финоћу за време креирања узорка.



Слика 8.1: Упоредни приказ квалитета естимација софт сензора истих архитектура, а различитог одабира улазних сигнала и њихових кашњења -  $SFC_1^{PKY}$  и  $SFC_2^{PKY}$  (са леве стране) и  $SFC_1^{PSY}$  и  $SFC_2^{PSY}$  (са десне стране)

У оквиру овог рада су представљени и резултати употребе вештачких неуронских мрежа са радијално базираним функцијама (ВНМ-РБФ) у регресији, који су упоређени са употребом вештачких неуронских мрежа базираних на перцептронима. ВНМ-РБФ су обучаване оригиналним, хибридном алгоритмом обуке. На основу Табела 7.3 и 7.8 формиран је упоредни приказ квалитета естимација софт сензора различитих структура приказан на Слици 8.2. Из приказаног, могуће је закључити да је, над валидационим скупом, постигнута квалитетнија естимација софт сензора приликом употребе ВНМ-РБФ и предложеног, хибридног алгоритма обуке. Такође је тестирана и робусност обе структуре вештачких неуронских мрежа. Ово је извршено вештачким довођењем шума на један од улаза и посматрањем грешака у естимацији. Вредности средњих апсолут-

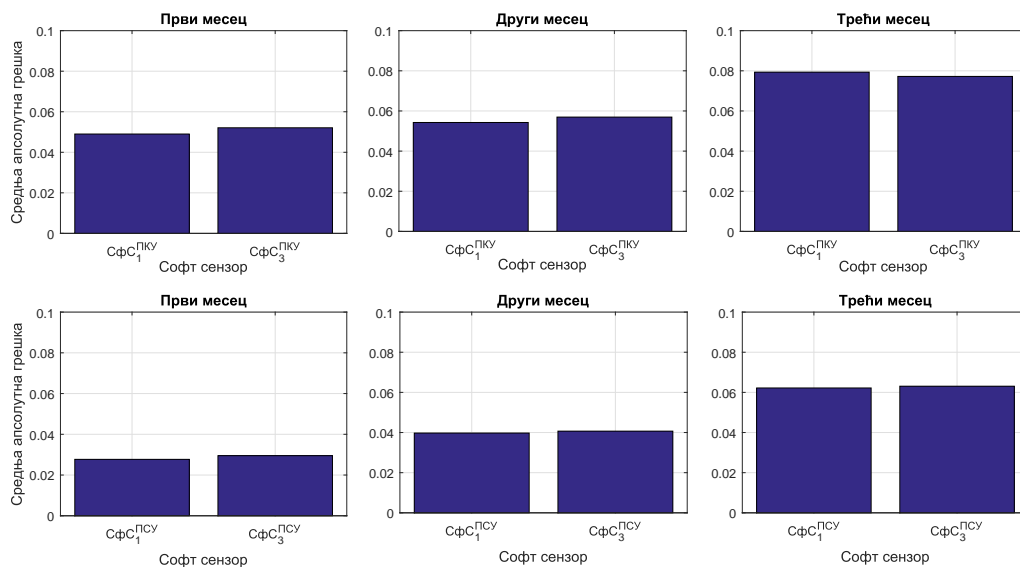
них грешака естимација оба типа софт сензора при тестирању робусности у  $\Pi_{ку}$  и  $\Pi_{су}$  приказани су у Табелама 7.4 и 7.9, ретроспективно. У истим табелама могуће је приметити да софт сензори структуре и начина обуке предложених у овом раду постижу квалитетнију естимацију, односно, већу робусност.



Слика 8.2: Упоредни приказ квалитета естимација софт сензора различитих архитектура, а истог одабира улазних сигнала и њихових кашњења -  $\text{СфС}_1^{\Pi_{ку}}$  и  $\text{СфС}_3^{\Pi_{ку}}$  (са леве стране) и  $\text{СфС}_1^{\Pi_{су}}$  и  $\text{СфС}_3^{\Pi_{су}}$  (са десне стране)

Као што су аутори [18] приметили, услед неминовног хабања механичких делова постројења током времена долази и до промена у процесу. Ово доводи до "застаревања" креираних модела и стога су обе структуре софт сензора тестиране на ову појаву. Средње апсолутне грешке естимација софт сензора различитих структура током сваког месеца тромесечне евалуације приказане су у Табели 7.5 и Табели 7.10, за  $\Pi_{ку}$  и  $\Pi_{су}$ , ретроспективно. На основу тога креиран је упоредни приказ постигнутих резултата на Слици 8.3. Могуће је приметити да не постоји значајна разлика софт сензора различитих структура са овог становишта посматрања и да ниједан од посматраних софт сензора није отпоран на неминовне проме-

не посматраног процеса. Овај недостатак могуће је превазићи употребом реобуке [18].



Слика 8.3: Упоредни приказ квалитета естимација софт сензора различитих архитектура, а истог одабира улазних сигнала и њихових кашњења током тромесечне евалуације -  $\text{СФС}_1^{\text{ПКУ}}$  и  $\text{СФС}_3^{\text{ПКУ}}$  (горе) и  $\text{СФС}_1^{\text{ПСУ}}$  и  $\text{СФС}_3^{\text{ПСУ}}$  (доле)

## Закључак

Величине које су од изузетне важности за индустријске процесе често нису мерљиве у реалном времену. Анализом научне литературе, уочено је да се тежи проналаску начина благовременог добијања опсервација величина које нису мерљиве у реалном времену, јер је, врло често, читаво управљање процесом засновано на вредностима тих показатеља стања процеса. Један приступ решавању овог проблема јесте употреба математичких модела - софт сензора, помоћу којих је могуће естимирати вредности тешко мерљивих величина на основу вредности неких других процесних величина које су мерљиве у реалном времену.

Процес креирања софт сензора није тривијалан и потребно је правилно извести неколико комплексних корака. За неке од корака није довољно само познавање научне области софт сензора, већ је потребно и доменско знање процеса примене истог. Уколико у неком од корака дође чак и до ситног пропуста, то може имати за последицу велики утицај на квалитет естимације величине од интереса. Управо из тог разлога је током овог истраживања акценат био стављен на креирање алгоритама који би омогућили једноставније формирање софт сензора, чиме би се смањила могућност настајања грешки.

Развој алгоритама за једноставније формирање софт сензора је поде-



љен на два дела, где је алгоритме који представљају резултате сваког дела могуће применити и независно једне од других. Свакако, кроз оба дела истраживања, реализовани су алгоритми који покривају и аутоматизују процес креирања софт сензора од почетка до краја.

У овом раду, као један од резултата истраживања, представљен је алгоритам за одређивање оптималног скупа сигнала улаза и њихових кашњења који би обезбеђивали висок квалитет естимације жељене величине. Овај алгоритам представља потпуно аутоматски процес који значајно умањује досадашњу потребу за доменским знањем области у којој се софт сензор примењује. Приказано је да је један од кључних корака при формирању софт сензора избор сигнала на чијим вредностима је естимација софт сензора базирана. Код система где постоје транспортни путеви, понекад ни тачан избор сигнала није довољан већ је потребно, на неки начин, пронаћи и укључити у структуру софт сензора кашњење утицаја сваког од улазних сигнала на сигнал који се естимира. У научној литератури, аутори су се бавили решавањем овог проблема, међутим, сви приказани алгоритми имају ограничења која сужавају њихову примену. Алгоритам приказан у овом раду превазилази уочене недостатке постојећих алгоритама и заснива се на алгоритму теорије информација (енгл. *information theoretic subset selection*) [15], генетском алгоритму и историјским вредностима свих сигнала који представљају потенцијалне улазе. Пре примене алгоритма на реалним подацима из процесне индустрије, предложени алгоритам је тестиран на симулираном процесу где су постигнути изванредни резултати. Битно је приметити да предложени алгоритам посматра систем као црну кутију, те је широке примене и није ограничен само на моделовање дистрибуираних индустријских процеса, већ може бити употребљен за креирање различитих типова софт сензора.

Други резултат истраживања је алгоритам који имплементира аутоматски избор топологије вештачких неуронских мрежа са радијално базираним функцијама и врши обуку истих. Наиме, алгоритми које је могуће пронаћи у научној литератури или нису потпуно аутоматизовани или не гарантују оптималну обуку. Реализовани аутоматски алгоритам пред-

ставља хибридни алгоритам који је базиран на кластеризацији употребом  $K$ -средњих вредности, методу најмање квадратне грешке, градијентном методу и методу пропагације грешке уназад. Комбинацијом претходно поменутих алгоритама значајно су умањени уочени недостаци постојећих алгоритама. Приказани алгоритам се изводи итеративно. Током сваке итерације алгоритам кластеризације помоћу  $K$ -средњих вредности коришћен је за одређивање центара радијалних функција. Њихове тежине су одређиване методом најмање квадратне грешке, а ширине радијалних функција су кориговане спрегом градијентног метода и метода пропагације грешке уназад.

Претходно поменути резултати спрегнути су и искоришћени за креирање софт сензора за естимацију финоће цемента који представља финални производ млевења сировина у кугличном млину. Изузетно важан фактор у индустрији цемента представља финоћа крајњег производа, јер велик део карактеристика финалне примене цемента зависи управо од ове величине. Тренутно се опсервације овог параметра добијају лабораторијском анализом и самим тим је и време добијања вредности истог неретко изражено у сатима. Како постоји неколико начина узорковања цемента и квантификовања финоће истог, у овом раду обрађена су два различита типа процеса производње цемента који су најчешће у употреби.

У сваком од два посматрана процеса производње цемента креирано је по неколико софт сензора са циљем квантификовања бенефита сваког реализованог алгоритма.

За квантификовање бенефита алгоритма за одређивање оптималног скупа сигнала улаза и њихових кашњења креирана су два софт сензора у оба посматрана процеса. Оба креирана софт сензора имају исту структуру, али су код једног улази одабрани према алгоритму предложеном у овом раду, а код другог одабрани стандардним начинима које је могуће пронаћи у научној литератури. Могуће је приметити да су у оба тест окружења постигнути бољи резултати употребом алгоритма за одређивање оптималног скупа сигнала улаза и њихових кашњења.

Употреба софт сензора заснованих на ВНМ-РБФ и реализованог хибридног начина обуке упоређена је са употребом софт сензора заснованих на вештачким неуронским мрежама базираним на перцептронима. Софт сензори су коришћени за естимацију финоће цемента. Упоређен је квалитет естимација софт сензора различитих структура као и њихова робусност на неке стандардне појаве у индустрији. Упоређени су квалитети естимација софт сензора приликом појаве шума на улазним сигналнима и "застаревање" параметара софт сензора у времену, које је примећено у обрађеној научној литератури.

На основу приказаних резултата, могуће је уочити да софт сензори који су креирани употребом алгоритама предложених у овом раду постижу квалитетније резултате у оба посматрана процеса, у односу на софт сензоре креиране стандардним процедурама. Тиме су доказане постављене хипотезе Х1, Х2 и Х3. Бенефити употребе предложених алгоритама изразито су уочљиви у случају  $\Pi_{\text{СУ}}$ , јер је у оквиру тог процеса квантификавање финоће цемента вршено над спот узроком и овај софт сензор је изузетно осетљив на потенцијалне грешке при формирању. Такође су се софт сензори засновани на ВНМ-РБФ показали робуснијима на шум који је неминован у индустријским процесима у поређењу са вештачким неуронским мрежама базираним на перцептронима, чиме је доказана постављена хипотеза Х4. Ипак, ни овде предложеним алгоритмима за креирање софт сензора није решен проблем "застаревања" параметара и реобука је самим тим неминовна.

Главни бенефит предложених алгоритама и ВНМ-РБФ јесте аутоматска конфигурација оптималне архитектуре софт сензора, јер се у досадашњој научној литератури проблем избора архитектуре софт сензора заснованих на вештачким неуронским мрежама решавао емпиријски.

Постигнути су квалитетни резултати у естимацији финоће цемента током континуалне продукције у два процеса производње цемента, те би наредни кораци у истраживању били примена реализованих алгоритама у естимацији тешко мерљивих величина у другим процесима, па чак и у

другим индустријама где би употреба софт сензора такође имала бенефите. Током истраживања дошло је и до стварања идеје имплементације напредног управљања процесима заснованог на софт сензорима и ову идеју је дефинитивно потребно дубље обрадити, али то излази ван граница дефинисаних темом ове докторске дисертације.

## Библиографија

- [1] Fortuna, L., Graziani, S. and Xibilia, M.G., 2007. Soft Sensors for Monitoring and Control of Industrial Processes, Springer-Verlag London Ltd., London, ISBN:978-1-84628-480-9, <https://doi.org/10.1007/978-1-84628-480-9>
- [2] Fortuna, L., Rizzo, A., Sinatra, M. and Xibilia, M.G., 2003. Soft Analyzers for Sulphur Recovery Unit, *Control Eng. Practice* 11 (12), 1491-1500, [https://doi.org/10.1016/S0967-0661\(03\)00079-0](https://doi.org/10.1016/S0967-0661(03)00079-0)
- [3] Clark, R.N. and Setzer, W., 1980. Sensor fault detection in a system with random disturbances, *IEEE Trans. Aerospace and Electronic Systems* 16 (4), 468-473, <https://doi.org/10.1109/TAES.1980.308976>
- [4] Améstica, R., González, J., Menacho, J. and Barria J., 1993. On-line estimation of fine and coarse ore water grinding rate and discharge rates in semiautogenous grinding mills, *Proc. XVIII International Mineral Processing Congress* 1 (4), 109-115
- [5] Abeykoon, C., 2014. A Novel Soft Sensor for Real-Time Monitoring of the Die Melt Temperature Profile in Polymer Extrusion, *IEEE Trans. on Industrial Electronics* 61 (12), 7113-7123, <https://doi.org/10.1109/TIE.2014.2321345>
- [6] Wang, D., Liu, J. and Srinivasan R., 2010. Data-Driven Soft Sensor Approach for Quality Prediction in a Refining

- Process, IEEE Trans. on Industrial Informatics 6 (1), 11-17, <https://doi.org/10.1109/TII.2009.2025124>
- [7] Mohler, I., Andrijic, Z. and Bolf N., 2010. Soft sensors model optimization and application for the refinery real-time prediction of toluene content, Chemical Engineering Communications 205 (3), 411-421, <https://doi.org/10.1080/00986445.2017.1399124>
- [8] Papadokonstantakis, S., Macheferb, S., Schnitzleinb, K. and Lygeros, A., 2005. Variable selection and data preprocessing in NN modeling of complex chemical processes, Computers & Chemical Engineering 29(7), 1647-1659, <https://doi.org/10.1016/j.compchemeng.2005.01.004>
- [9] Papadokonstantakis, S., Lygeros, A. and Jacobsson, S., 2006. Comparison of recent methods for inference of variable influence in neural networks, Neural Networks 19, 500-513, <https://doi.org/10.1016/j.neunet.2005.09.002>
- [10] Zobel, C. and Cook, D., 2011. Evaluation of neural network variable influence measures for process control, Engineering Applications of Artificial Intelligence 24, 803-812, <https://doi.org/10.1016/j.engappai.2011.03.001>
- [11] Mohammadi, S., 2017. A new test for the significance of neural network inputs, Neurocomputing 273, 304-322, <https://doi.org/10.1016/j.neucom.2017.08.007>
- [12] Benoudjit, N. and Verleysen, M., 2003. On the Kernel Widths in Radial-Basis Function Networks. Neural Processing Letters 18(2), 139-154, <https://doi.org/10.1023/A:1026289910256>
- [13] Fernandez-Redondo, M., Torres-Sospedra, J. and Hernandez-Espinosa, C., 2006. Training Radial Basis Functions by Gradient Descent. The 2006 IEEE International Joint Conference on Neural Network Proceedings 2006, Vancouver, Canada

- 
- [14] Krayiannis, N., 1999. Reformulated Radial Basis Neural Networks Trained by Gradient Descent. *IEEE Trans. on Neural Networks* 10(3), 657-671, <https://doi.org/10.1109/72.761725>
- [15] Sridhar, D., Bartlett, E. and Seagrave, R., 1998. Information theoretic subset selection for neural network models, *Computers & Chemical Engineering* 22(4), 613-626, [https://doi.org/10.1016/S0098-1354\(97\)00227-5](https://doi.org/10.1016/S0098-1354(97)00227-5)
- [16] Tarassenko, I. and Roberts, S., 1994. Supervised and unsupervised learning in radial basis function classifiers. *IEEE Proceedings - Vision, Image and Signal Processing* 141(4), 210-216, <https://doi.org/10.1049/ip-vis:19941324>
- [17] Sarimveis, H., Alexandridis, A. and Bafas, G., 2003. A fast training algorithm for RBF networks based on subtractive clustering. *Neurocomputing* 51, 501-505, [https://doi.org/10.1016/S0925-2312\(03\)00342-4](https://doi.org/10.1016/S0925-2312(03)00342-4)
- [18] Stanišić, D., 2014. Metode soft senzora sa primenom u tehnološkom procesu proizvodnje cementa. Doktorska disertacija, Univerzitet u Novom Sadu
- [19] Lamond, J.F. and Pielert, J.H., 2006. Significance of Tests and Properties of Concrete and Concrete-Making Materials. ASTM International 2006, West Conshohocken, United States of America
- [20] Mejeoumov, G.G., 2007. Improved cement quality and grinding efficiency by means of closed mill circuit modeling. Doktorska disertacija, Texas A&M University
- [21] Madloola, N.A., Saidura, R., Hossaina, M.S. and Rahimb, N.A., 2011. A critical review on energy use and savings in the cement industries. *Renewable and Sustainable Energy Reviews* 15, 2042-2060, <https://doi.org/10.1016/j.rser.2011.01.005>

- [22] Herrmann, C., 1986. Increased Cement Grinding Efficiency by Using High-Efficiency Separators. *IEEE Trans. on Industry Applications* 22(2), 330-337, <https://doi.org/10.1109/TIA.1986.4504722>
- [23] Arvaniti, E. et al., 2014. Determination of particle size, surface area, and shape of supplementary cementitious materials by different techniques, *Materials and Structures* 48, 3687-3701, <https://doi.org/10.1617/s11527-014-0431-3>
- [24] Kadleca, P., Gabrysa, B. and Strandtb, S., 2009. Data-driven Soft Sensors in the process industry, *Computers & Chemical Engineering* 33(4), 795-814, <https://doi.org/10.1016/j.compchemeng.2008.12.012>
- [25] Gomm, J., Williams, D., Evans, J. and Doherty, S., 1997. Neural network applications in process modelling and predictive control, *Transactions of the institute of measurement and control* 19(4), 175-184, <https://doi.org/10.1177/014233129701900402>
- [26] Schneider, D.M., 1988. Control of Processes with Time Delays, *IEEE Trans. on Industry Applications* 24(2), 186-191, <https://doi.org/10.1109/28.2854>
- [27] Wu, L., Lam, H., Zhao, Y. and Shu, Z., 2015. Time-Delay Systems and Their Applications in Engineering, *Mathematical Problems in Engineering* 2015, 1-3, <https://doi.org/10.1155/2015/246351>
- [28] Chiasson J. and Loiseau J.J., 2007. Applications of Time Delay Systems, Springer-Verlag London Ltd., London, <https://doi.org/10.1007/978-3-540-49556-7>
- [29] Roblot, E., Grosseau, P., Guilhot, B., Classen, B., Haehnel, C. and Gaffet, E., 2005. A study on the action mechanisms of grinding aids used for clinker comminution, Conference: Process of Industrials Minerals PIM 2005.
- [30] Ku, W., Storer, R.H. and Georgakis, C., 1995. Disturbance Detection and Isolation by Dynamic Principal Component Analysis,



- Chemometrics and Intelligent Laboratory Systems 30(1), 179-196, [https://doi.org/10.1016/0169-7439\(95\)00076-3](https://doi.org/10.1016/0169-7439(95)00076-3)
- [31] Rato, T. J. and Reis, M. S., 2013. Defining the structure of DPCA models and its impact on process monitoring and prediction activities, *Chemometrics and Intelligent Laboratory Systems* 125, 74-86, <https://doi.org/10.1016/j.chemolab.2013.03.009>
- [32] Rato, T. J. and Reis, M. S., 2013. Advantage of Using Decorrelated Residuals in Dynamic Principal Component Analysis for Monitoring Large-Scale Systems, *Industrial & Engineering Chemistry Research* 52(38), 13685-13698, <https://doi.org/10.1021/ie3035306>
- [33] Hertz, D. and Azaria, M., 1985. Time delay estimation between two phase shifted signals via generalized cross-correlation methods, *Signal Processing* 8(2), 235-257, [https://doi.org/10.1016/0165-1684\(85\)90076-3](https://doi.org/10.1016/0165-1684(85)90076-3)
- [34] Haken, J., Wainwright, M. and Smith, R., 1977. A problem of accuracy of mathematical dead-time estimation, *Journal of Chromatography A* 133(1), 1-6, [https://doi.org/10.1016/S0021-9673\(00\)89199-2](https://doi.org/10.1016/S0021-9673(00)89199-2)
- [35] Bi, Q., Cai, W.J., Lee, E.L., Wang, Q.G., Hang, C.C. and Zhang, Y., 1999. Robust identification of first-order plus dead-time model from step response, *Control Engineering Practice* 7(1), 71-77, [https://doi.org/10.1016/S0967-0661\(98\)00166-X](https://doi.org/10.1016/S0967-0661(98)00166-X)
- [36] Smith, R., Haken, J. and Wainwright, M., 1985. Estimation of dead time and calculation of kovats indices, *Journal of Chromatography A* 334, 95-127, [https://doi.org/10.1016/S0021-9673\(00\)80268-X](https://doi.org/10.1016/S0021-9673(00)80268-X)
- [37] Fortuna, L., Graziani, S. and Xibilia, M.G., 2005. Virtual instruments in refineries, *IEEE Instrumentation & Measurement Magazine* 8(4), 26-34, <https://doi.org/10.1109/MIM.2005.1518619>
- [38] Luo, J.X. and Shao, H.H., 2005. Developing soft sensors using hybrid soft computing methodology: a neurofuzzy system based on

- rough set theory and genetic algorithms, *Soft Computing* 10(1), 54-60, <https://doi.org/10.1007/s00500-005-0465-0>
- [39] Yan, W., Shao, H. and Wang, X., 2004. Soft sensing modeling based on support vector machine and Bayesian model selection, *Computers & Chemical Engineering*, 28(8), 1489-1498, <https://doi.org/10.1016/j.compchemeng.2003.11.004>
- [40] Pani, A.K., Vadlamudi, V.K. and Mohanta, H.K., 2013. Development and comparison of neural network based soft sensors for online estimation of cement clinker quality, *ISA Transactions* 52(1), 19-29, <https://doi.org/10.1016/j.isatra.2012.07.004>
- [41] Stanišić, D., Jorgovanović, N., Popov, N. and Čongradac, V., 2015., Soft sensor for real-time cement fineness estimation, *ISA Transactions* 55, 250-259, <https://doi.org/10.1016/j.isatra.2014.09.019>
- [42] Park, J. and Sandberg, W., 1991 Universal approximation using radial basis functions network. *Neural Computation* 3, 246-257, <https://doi.org/10.1162/neco.1991.3.2.246>
- [43] Dash, C.S.K., Behera, A.K., Dehuri, S. and Cho, S.B., 2016 Radial basis function neural networks: A topical state-of-the-art survey. *Open Computer Science* 2016,33-63, <https://doi.org/10.1515/comp-2016-0005>
- [44] Er, M., Wu, S., Lu, J. and Toh, H., 2002. Face recognition with radial basis function (RBF) neural networks. *IEEE Transactions on Neural Networks* 13(3), 697-710, <https://doi.org/10.1109/TNN.2002.1000134>
- [45] Janik, P. and Lobos, T., 2006. Automated Classification of Power-Quality Disturbances Using SVM and RBF Networks. *IEEE Transactions on Power Delivery* 21(3), 1663-1669, <https://doi.org/10.1109/TPWRD.2006.874114>
- [46] Roy, A., Govil, S. and Miranda, R. 1995. An algorithm to generate radial basis function (RBF)-like nets for classification problems. *Neural Networks* 8(2), 179-201, [https://doi.org/10.1016/0893-6080\(94\)00064-S](https://doi.org/10.1016/0893-6080(94)00064-S)

- [47] Alexandridisa, A., Triantisa, D., Stavrakasa, I. and Stergiopoulou, C., 2012. A neural network approach for compressive strength prediction in cement-based materials through the study of pressure-stimulated electrical signals. *Construction and Building Materials* 30, 294-300, <https://doi.org/10.1016/j.conbuildmat.2011.11.036>
- [48] Fernando, D. and Jayawardena, A., 1998. Runoff Forecasting Using RBF Networks with OLS Algorithm. *Journal of Hydrologic Engineering* 3(3), [https://doi.org/10.1061/\(ASCE\)1084-0699\(1998\)3:3\(203\)](https://doi.org/10.1061/(ASCE)1084-0699(1998)3:3(203))
- [49] Jayawardena, A. and Fernando, D., 1998. Use of Radial Basis Function Type Artificial Neural Networks for Runoff Simulation. *Computer-Aided Civil and Infrastructure Engineering* 13(2), <https://doi.org/10.1111/0885-9507.00089>
- [50] Tatar, A., Shokrollahi, A., Mesbah, M., Rashed, S., Arabloo, M. and Bahadori, A., 2013. Implementing Radial Basis Function Networks for modeling CO<sub>2</sub>-reservoir oil minimum miscibility pressure. *Journal of Natural Gas Science and Engineering* 15, 82-92, <https://doi.org/10.1016/j.jngse.2013.09.008>
- [51] Abbas, O., 2008. Comparisons Between Data Clustering Algorithms. *International Arab Journal of Information Technology* 5(3), 320-335
- [52] Kanungo, T. et al., 2002. An efficient k-means clustering algorithm: analysis and implementation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 24(7), 881-892, <https://doi.org/10.1109/TPAMI.2002.1017616>
- [53] Mejić, L., Stanisić, D., Ilić, V., Jakovljević, B. and Jorgovanović, N., 2019. A novel algorithm for dead time estimation between soft sensor inputs and output. *Computers & Chemical Engineering* 124, 153-161, <https://doi.org/10.1016/j.compchemeng.2019.02.012>

- [54] Chang, J., Lu, S. and Chiu, Y., 2007. Dynamic modeling of batch polymerization reactors via the hybrid neural-network rate-function approach. *Chemical Engineering Journal* 130(1), 19-28. <https://doi.org/10.1016/j.cej.2006.11.011>
- [55] Goldberg, D.E., 1989. *Genetic Algorithms In Search, Optimization, and Machine Learning*, Addison-Wesley Longman Publishing Co., Inc. Boston, MA, ISBN:0201157675
- [56] Caponetto, R., Fortuna, L., Graziani, S. and Xibilia, M., 1993. Genetic algorithms and applications in system engineering: a survey, *Trans. of the institute of measurement and control* 15(3), 143-156, <https://doi.org/10.1177/014233129301500305>
- [57] Onnen, C., Babuska, R., Kaymak, U.G. and Sousa, J., 1997. Genetic algorithms for optimization in predictive control, *Control Engineering Practice* 5(10), 1363-1372, [https://doi.org/10.1016/S0967-0661\(97\)00133-0](https://doi.org/10.1016/S0967-0661(97)00133-0)
- [58] Schwefel, H.P., 1995. *Evolution and Optimum Seeking*, John Wiley & Sons, Inc. New York, NY, ISBN:0471571482
- [59] Coello, C.A., Gomes, R.H. and Antonio, L.M., 2018. Fundamentals of Evolutionary Optimization: Single- and Multiobjective Problems, *Wiley Encyclopedia of Electrical and Electronics Engineering*, 1-16, <https://doi.org/10.1002/047134608x.w8369>
- [60] Rosenbrock, H.H., 1960. An Automatic Method for Finding the Greatest or Least Value of a Function, *The Computer Journal* 3(3), 175-184, <https://doi.org/10.1093/comjnl/3.3.175>
- [61] Rato, T. J. and Reis, M. S., 2017. Multiresolution Soft Sensors (MR-SS): A New Class of Model Structures for Handling Multiresolution Data, *Industrial & Engineering Chemistry Research* 56, 3640-3654, <https://doi.org/10.1021/acs.iecr.6b04349>

- 
- [62] Rato, T. J. and Reis, M. S., 2018. Building Optimal Multiresolution Soft Sensors for Continuous Processes, *Industrial & Engineering Chemistry Research* 57, 9750-9765, <https://doi.org/10.1021/acs.iecr.7b04623>
- [63] Tangirala, A.K., Li, D., Patwardhan, R., Shah, S.L. and Chen, T., 1999. Issues in multirate process control, Conference: In *American Control Conference 1999.*, San Diego, California, <https://doi.org/10.1109/ACC.1999.786576>
- [64] Li, D., Shah, S.L. and Chen, T., 2001. Identification of fast-rate models from multirate data, *International Journal of Control* 74, 680-689, <https://doi.org/10.1080/00207170010018904>