




УНИВЕРЗИТЕТ „СВ. КИРИЛ И МЕТОДИЈ“ - СКОПЈЕ

ФАКУЛТЕТ ЗА ЕЛЕКТРОТЕХНИКА И
ИНФОРМАЦИСКИ ТЕХНОЛОГИИ



м-р Марија Марковска

**КЛАСИФИКАЦИЈА НА НАРУШУВАЊАТА НА НАПОНСКИТЕ
СИГНАЛИ ВО ЕЛЕКТРОЕНЕРГЕТСКАТА МРЕЖА ВО РЕАЛНО
ВРЕМЕ**

- ДОКТОРСКА ДИСЕРТАЦИЈА-

Скопје, 2020 година

Ментор: **Проф. д-р Димитар Ташковски**
Универзитет “Св. Кирил и Методиј” – Скопје
Факултет за електротехника и информациски технологии

Членови на комисијата: **Претседател: Проф. д-р Владимир Димчев**
Универзитет “Св. Кирил и Методиј” – Скопје
Факултет за електротехника и информациски технологии

Проф. д-р Јосиф Косев
Универзитет “Св. Кирил и Методиј” – Скопје
Факултет за електротехника и информациски технологии

Проф. д-р Зоран Ивановски
Универзитет “Св. Кирил и Методиј” – Скопје
Факултет за електротехника и информациски технологии

Проф. д-р Владимир Катиќ
Универзитет во Нови Сад, Р. Србија
Факултет за технички науки

Дата на одбрана: _____

Дата на промоција: _____

Научна област: Дигитално процесирање на сигнали

МАРИЈА МАРКОВСКА

КЛАСИФИКАЦИЈА НА НАРУШУВАЊАТА НА НАПОНСКИТЕ СИГНАЛИ ВО ЕЛЕКТРОЕНЕРГЕТСКАТА МРЕЖА ВО РЕАЛНО ВРЕМЕ

АПСТРАКТ:

Паметните мрежи на иднината се состојат од голем број на дисперзирани уреди, генератори и потрошувачи на електрична енергија, кои генерираат огромна количина на податоци. Тоа ја зголемува потребата на електроенергетскиот сектор од соодветни хардверски и софтверски алатки кои ќе овозможат интеграција на релевантни дигитални технологии, со цел оптимизација во управувањето и одржувањето на електроенергетскиот систем. Еден од најголемите предизвици во овој систем е да се обезбеди непрекинато напојување со електрична енергија чиј квалитет е во согласност со однапред пропишани стандардизирани параметри.

Ефектите на нарушениот квалитет на напонот може да доведат до појава на голем број технички проблеми, како прегревање, дефекти па дури и предвремено стареење на уредите. Тие може да го попречат секојдневното, безбедно функционирање на критичната инфраструктура. Исто така, тие може да резултираат во значајни финансиски загуби. Од таа причина квалитетот на напонот претставува важен проблем за неговите корисници, особено за индустријата. Неговата цена е висока и се зголемува како што се зголемува и бројот на неговите нарушувања. Оттука се јавува потреба за континуирано мониторирање, детекција, класификација и анализа на нарушувањата во напонските сигнали. Сето тоа би било многу поефикасно доколку се одвива во реално време. И покрај напредокот на науката и техниката, развојот на систем кој може да обезбеди брза детекција, класификација и карактеризација на еднократни и повеќекратни нарушувања со висока точност и кој ефикасно може да се справи со различни нивоа на шум, со цел да се подобри одржувањето на уредите и стабилноста на електроенергетската мрежа, сеуште е предизвик. Токму тоа претставува и предмет на истражување во овој труд.

КЛУЧНИ ЗБОРОВИ:

Квалитет на напон, извлекување на карактеристики, класификација, вејвлет трансформација, имплементација во реално време

MARIJA MARKOVSKA

**REAL-TIME CLASSIFICATION OF VOLTAGE DISTURBANCES IN THE
POWER GRID**

ABSTRACT:

Future's power grids consist of an increasing number of dispersed energy generation and consumption devices, which generate large amount of data. That increases the electricity sector's need of proper hardware and software tools that will enable integration of relevant digital technologies in order to optimize the management and maintenance of the energy system. One of the biggest challenges in this system is to continuously ensure power supply, which quality is in accordance with some predefined standardized parameters.

The effects of the disturbed voltage quality can lead to large number of technical problems, such as overheating, defects and even early aging of the equipment. They may affect the everyday, secure operation of the critical infrastructure. They may also result in significant financial losses. From that reason, the quality of the power is of great importance for its consumers, especially for the industry. Its price is high and it is rising as the number of the disturbances is increasing. Hence, there is a need of continuous monitoring, detection, classification and analysis of the voltage disturbances. All that would be much more efficient if it is performed in real time. Despite the continuous progress in the science and technology, the development of a system that would provide fast detection, classification and characterization of single and combined disturbances with high accuracy, and which could efficiently handle different noise levels, in order to improve the maintenance of the devices and the stability of the power grid, is still a challenge. That challenge represents the main subject of research in this paper.

KEY WORDS:

Voltage quality, feature extraction, classification, wavelet transform, real-time implementation

Посветено на моето семејство.

СОДРЖИНА

ЛИСТА НА КРАТЕНКИ.....	IV
ЛИСТА НА СЛИКИ.....	V
ЛИСТА НА ТАБЕЛИ.....	IX
ГЛАВА 1 ВОВЕД.....	11
1.1 МОТИВАЦИЈА ЗА ИЗРАБОТКА НА ДОКТОРСКАТА ДИСЕРТАЦИЈА.....	11
1.2 ПРЕДМЕТ НА ИСТРАЖУВАЊЕ НА ДОКТОРСКАТА ДИСЕРТАЦИЈА.....	13
1.3 ЦЕЛИ И ПРИДОБИВКИ ОД ИСТРАЖУВАЊЕТО	14
1.4 СТРУКТУРА НА ДОКТОРСКАТА ДИСЕРТАЦИЈА	15
ГЛАВА 2 ВОВЕД ВО КВАЛИТЕТ НА ЕЛЕКТРИЧНА ЕНЕРГИЈА И КВАЛИТЕТ НА НАПОН.....	18
2.1 КВАЛИТЕТ НА ЕЛЕКТРИЧНА ЕНЕРГИЈА И КВАЛИТЕТ НА НАПОН.....	20
2.2 ПРЕГЛЕД НА НАРУШУВАЊАТА НА КВАЛИТЕТОТ НА ЕЛЕКТРИЧНАТА ЕНЕРГИЈА.....	23
2.2.1 Варијации во напонот и струјата	23
2.2.2 Настани во напонот и струјата.....	25
2.3 ПРЕГЛЕД НА СТАНДАРДИТЕ ЗА КВАЛИТЕТ НА ЕЛЕКТРИЧНА ЕНЕРГИЈА	26
2.4 МОНИТОРИРАЊЕ И АНАЛИЗА НА КВАЛИТЕТОТ НА НАПОНОТ	27
ГЛАВА 3 ИЗВЛЕКУВАЊЕ НА КАРАКТЕРИСТИКИ ОД НАПОНСКИТЕ СИГНАЛИ	29
3.1 БАНКИ НА ФИЛТРИ	30
3.1.1 Двоканална банка на филтри	31
3.1.2 Максимално децимирани двоканални банки на филтри со структура на “половично разгрането дрво”.....	35
3.2 ДИСКРЕТНА ВЕЈВЛЕТ ТРАНСФОРМАЦИЈА	37
3.3 ВЕЈВЛЕТ-БАЗИРАНИ КАРАКТЕРИСТИКИ.....	38
ГЛАВА 4 КЛАСИФИКАЦИЈА НА НАРУШУВАЊАТА НА НАПОНСКИТЕ СИГНАЛИ	42
4.1 МАШИНА СО НОСЕЧКИ ВЕКТОРИ.....	43
4.1.1 Машина со носечки вектори за линеарно разделив проблем	43
4.1.2 Машина со носечки вектори за линеарно неразделив проблем	44

4.1.3	Повеќеќласен класификациски проблем со SVM.....	45
4.2	ДРВО НА ОДЛУЧУВАЊЕ	46
4.2.1	Индукција на дрво на одлучување.....	47
4.2.2	Критериум за избор на карактеристика за поделба	49
4.2.3	Прекин на растот на дрвото и поткастрување на дрвото	51
4.3	СЛУЧАЈНА ШУМА	52
4.4	ФОРМИРАЊЕ НА МНОЖЕСТВА ОБУЧУВАЊЕ И ТЕСТИРАЊЕ.....	55
ГЛАВА 5 ИЗБОР НА ОПТИМАЛЕН АЛГОРИТАМ ЗА ИЗВЛЕКУВАЊЕ НА КАРАКТЕРИСТИКИ		58
5.1	ОПТИМАЛНА КОМБИНАЦИЈА НА ВЕЈВЛЕТ-БАЗИРАНИ КАРАКТЕРИСТИКИ ЗА 7 КЛАСИ НА НАРУШУВАЊА	60
5.1.1	Со примена на SVM алгоритам.....	60
5.1.2	Со примена на DT алгоритам.....	62
5.1.3	Со примена на RF алгоритам	63
5.2	ИЗБОР НА ОПТИМАЛНА КОМБИНАЦИЈА НА ВЕЈВЛЕТ-БАЗИРАНИ КАРАКТЕРИСТИКИ ЗА 11 КЛАСИ НА НАРУШУВАЊА.....	64
5.2.1	Со примена на SVM алгоритам.....	64
5.2.2	Со примена на DT алгоритам.....	65
5.2.3	Со примена на RF алгоритам	66
5.3	СПОРЕДБА НА РЕЗУЛТАТИТЕ И ИЗБОР НА ГЕНЕРАЛЕН ОПТИМАЛЕН АЛГОРИТАМ ЗА ИЗВЛЕКУВАЊЕ НА КАРАКТЕРИСТИКИ.....	67
ГЛАВА 6 ИЗБОР НА НАЈСООДВЕТЕН АЛГОРИТАМ ЗА КЛАСИФИКАЦИЈА.....		70
6.1	Класификација на 7 класи на нарушувања на напонските сигнали	70
6.2	Класификација на 11 класи на нарушувања на напонските сигнали	72
6.3	СПОРЕДБА НА РЕЗУЛТАТИТЕ И ИЗБОР НА НАЈСООДВЕТЕН АЛГОРИТАМ ЗА КЛАСИФИКАЦИЈА.....	73
6.4	ВЕРИФИКАЦИЈА НА ТОЧНОСТА ВО КЛАСИФИКАЦИЈА НА ИЗБРАНИОТ АЛГОРИТАМ ЗА ИЗВЛЕКУВАЊЕ НА КАРАКТЕРИСТИКИ И ИЗБРАНИОТ КЛАСИФИКАТОР.....	76
ГЛАВА 7 ИМПЛЕМЕНТАЦИЈА НА ОПТИМИЗИРАН КЛАСИФИКАТОР ЗА ДЕТЕКЦИЈА И КЛАСИФИКАЦИЈА НА НАРУШУВАЊАТА НА НАПОНСКИТЕ СИГНАЛИ ВО РЕАЛНО ВРЕМЕ.....		81

7.1	ИМПЛЕМЕНТАЦИЈА НА ОПТИМАЛЕН АЛГОРИТАМ ЗА ИЗВЛЕКУВАЊЕ НА КАРАКТЕРИСТИКИ ВО LABVIEW	82
7.2	ИМПЛЕМЕНТАЦИЈА НА ОПТИМИЗИРАН АЛГОРИТАМ ЗА КЛАСИФИКАЦИЈА ВО LABVIEW	84
7.2.1	Оптимизација на алгоритмот за класификација	86
7.2.2	Тестирање на оптимизираниот класификатор.....	90
7.2.3	Имплементација оптимизираниот класификатор во LabVIEW	94
7.3	СИСТЕМ ЗА КЛАСИФИКАЦИЈА НА НАРУШУВАЊАТА НА НАПОНСКИТЕ СИГНАЛИ ВО РЕАЛНО ВРЕМЕ.....	96
7.3.1	Детекција на премин преку нулата.....	98
7.3.2	Запис и прикажување на класифицираните нарушувања	100
7.3.3	Време за процесирање на имплементираниот систем	100
7.4	ПРЕДЕН ПАНЕЛ НА ИМПЛЕМЕНТАЦИЈАТА.....	101
7.5	ВЕРИФИКАЦИЈА НА ИМПЛЕМЕНТИРАНИОТ СИСТЕМ	102
7.6	СПОРЕДБА НА ИМПЛЕМЕНТИРАНИОТ СИСТЕМ СО СИСТЕМИ ПРЕДЛОЖЕНИ ВО ЛИТЕРАТУРАТА	105
ГЛАВА 8	ЗАКЛУЧОК	108
ПРИЛОГ А	КОД ЗА ПРЕМИН ОД PYTHON ВО C ЗА ИМПЛЕМЕНТАЦИЈА НА RF ВО LABVIEW.....	111
ЛИСТА НА ОБЈАВЕНИ ТРУДОВИ ОД ОБЛАСТА НА ДОКТОРСКАТА ДИСЕРТАЦИЈА		115
КОРИСТЕНА ЛИТЕРАТУРА.....		117

Листа на кратенки

Кратенка	Значење на англиски	Значење на македонски
CART	Classification and regression tree	Дрво за класификација и регресија
DFT	Discrete Fourier transform	Дискретна Фуриеова трансформација
DT	Decision tree	Дрво на одлучување
DWT	Discrete wavelet transform	Дискретна вејвлет трансформација
EMC	Electromagnetic compatibility	Електромагнетна компатибилност
IEC	International Electrotechnical Commission	-
IEEE	Institute of Electrical and Electronics Engineers	-
LabVIEW	Laboratory Virtual Instrument Engineering Workbench	-
MATLAB	Matrix Laboratory	-
PES	Power & Energy Society	-
RF	Random forest	Случајна шума
SNR	Signal-to-noise ratio	Соодност на сигнал-шум
STFT	Short-time Fourier Transform	Фуриеова трансформација со прозорец
SVM	Support vector machine	Машина со носечки вектори
WT	Wavelet transform	Вејвлет трансформација

Листа на слики

Слика 2-1. Структура на електроенергетски систем.....	18
Слика 2-2. Модерна структура на електроенергетски систем	19
Слика 2-3. Број на публикации презентирани во базата на IEEE од 1995 до 2018 година кои го обработуваат терминот “Квалитет на електрична енергија”	20
Слика 2-4. Број на публикации презентирани во базата на IEEE од 1995 до 2018 година кои го обработуваат терминот “Квалитет на напон”	21
Слика 3-1. Пример за стационарен сигнал (напонски фликер).....	29
Слика 3-2. Пример за нестационарен сигнал (прекин во напонот)	30
Слика 3-3. Банка на филтри: (а) Дел за анализа; (б) Дел за синтеза.....	31
Слика 3-4. Двоканална банка на филтри.....	31
Слика 3-5. Фреквенциски карактеристики на филтрите за анализа: (а) Кога карактеристиките на филтрите не се преклопуваат; (б) Кога карактеристиките на филтрите се преклопуваат	32
Слика 3-6. Дел за анализа со структура на “половично разгрането дрво” каде $Ga(z)$ претставува ниско пропустен филтер, а $Ha(z)$ високо пропустен филтер....	35
Слика 3-7. Еквивалентна структура на делот за анализа.....	36
Слика 3-8. Дел за синтеза со структура на “половично разгрането дрво” каде $Gs(z)$ претставува ниско пропустен филтер, а $Hs(z)$ високо пропустен филтер	36
Слика 3-9. Еквивалентна структура на делот за синтеза.....	36
Слика 3-10. Типични амплитудни одзиви на филтрите за анализа и синтеза кај банките на филтри со структура на половично разгрането дрво.....	37
Слика 3-11. Структура на дискретна вејвлет трансформација во две нивоа.....	38
Слика 3-12. Пример за нестационарен сигнал (осцилаторна преодна појава во напонот)	39
Слика 3-13. Декомпозиција со примена на DWT во 6 нивоа	39
Слика 4-1. Дефинирање на хипер-рамнини за линеарно разделив проблем	44
Слика 4-2. Дефинирање на хипер-рамнини за линеарно неразделив проблем	45
Слика 4-3. (а) Дрво на одлучување; (б) Множество на примероци за обучување на дрвото.....	46

Слика 4-4. Бинарно дрво на одлучување за класификација на пет класи.....	48
Слика 4-5. Множество на примероци за обучување на дрво на одлучување	50
Слика 4-6. Структура на случајна шума.....	52
Слика 4-7. Сумирање на крајниот резултат на класификацијата кај алгоритмот на случајна шума	54
Слика 5-1. Резултати добиени при примена на SVM алгоритам за класификација во случај на 7 класи на нарушувања.....	61
Слика 5-2. Резултати добиени при примена на DT алгоритам за класификација во случај на 7 класи на нарушувања.....	62
Слика 5-3. Резултати добиени при примена на RF алгоритам за класификација во случај на 7 класи на нарушувања.....	63
Слика 5-4. Резултати добиени при примена на SVM алгоритам за класификација во случај на 11 класи на нарушувања.....	64
Слика 5-5. Резултати добиени при примена на DT алгоритам за класификација во случај на 11 класи на нарушувања.....	65
Слика 5-6. Резултати добиени при примена на RF алгоритам за класификација во случај на 11 класи на нарушувања.....	66
Слика 5-7. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на SVM алгоритам за класификација во случај на 7 класи.....	68
Слика 5-8. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на SVM алгоритам за класификација во случај на 11 класи.....	68
Слика 5-9. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на DT алгоритам за класификација во случај на 7 класи.....	68
Слика 5-10. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на DT алгоритам за класификација во случај на 11 класи.....	69
Слика 5-11. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на RF алгоритам за класификација во случај на 7 класи	69
Слика 5-12. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на RF алгоритам за класификација во случај на 11 класи	69
Слика 6-1. Резултати добиени за 7 класи на нарушувања при примена на SVM алгоритам за класификација	70
Слика 6-2. Резултати добиени за 7 класи на нарушувања при примена на DT алгоритам за класификација	71

Слика 6-3. Резултати добиени за 7 класи на нарушувања при примена на RF алгоритам за класификација	71
Слика 6-4. Резултати добиени за 11 класи на нарушувања при примена на SVM алгоритам за класификација	72
Слика 6-5. Резултати добиени за 11 класи на нарушувања при примена на DT алгоритам за класификација	72
Слика 6-6. Резултати добиени за 11 класи на нарушувања при примена на RF алгоритам за класификација	73
Слика 6-7. Избор на оптимален алгоритам за класификација во случај на 7 класи	74
Слика 6-8. Избор на оптимален алгоритам за класификација во случај на 11 класи	75
Слика 6-9. Графички приказ на резултатите добиени од споредбата на комплетниот алгоритам предложен во овој труд и алгоритмите предложени во реф. [60].....	79
Слика 7-1. Блок дијаграм за имплементација на предложениот алгоритам за извлекување на карактеристики во LabVIEW	83
Слика 7-2. Дијаграм на тек на предложениот алгоритам за класификација.....	85
Слика 7-3. Вејвлет базирани карактеристики наспроти нивната релативна важност во класификацијата.....	87
Слика 7-4. Одбирање на соодветен опсег на вредности за дел од параметрите на RF1 алгоритмот за класификација	88
Слика 7-5. Одбирање на соодветен опсег на вредности за дел од параметрите на RF2 и RF3 алгоритмите за класификација	89
Слика 7-6. Блок дијаграм за имплементација на предложениот алгоритам за класификација во LabVIEW	95
Слика 7-7. Блок-дијаграмот за имплементацијата на системот за класификација на нарушувања во напонските сигнали во реално време	96
Слика 7-8. Блок дијаграм за реализација на предложената имплементација во LabVIEW и на NI MyRIO-1900.....	97
Слика 7-9. Блок дијаграм за имплементација на детектор за премин преку нулата во LabVIEW.....	98
Слика 7-10. Напонски сигнали со различни почетни фази без примена на детектор за премин преку нулата.....	99
Слика 7-11. Напонски сигнали со различни почетни фази со примена на детектор за премин преку нулата	99

Слика 7-12. Блок дијаграм за имплементација на запис на нарушувањата и прикажување во LabVIEW.....	100
Слика 7-13. Преден панел на системот за класификација на нарушувања на напонските сигнали во реално време.....	102
Слика 7-14. Ланец за верификација на системот за класификација на нарушувања на напонските сигнали во реално време.....	102

Листа на табели

Табела 3-1. Математички дефиниции за карактеристики базирани на DWT	40
Табела 5-1. 11 класи на нарушувања на напонот и нивни ознаки	59
Табела 5-2. Ознаки за вејвлет базираните карактеристики	60
Табела 5-3. Резултати добиени при примена на SVM алгоритам за класификација во случај на 7 класи на нарушувања	61
Табела 5-4. Резултати добиени при примена на DT алгоритам за класификација во случај на 7 класи на нарушувања	62
Табела 5-5. Резултати добиени при примена на RF алгоритам за класификација во случај на 7 класи на нарушувања	63
Табела 5-6. Резултати добиени при примена на SVM алгоритам за класификација во случај на 11 класи на нарушувања	64
Табела 5-7. Резултати добиени при примена на DT алгоритам за класификација во случај на 11 класи на нарушувања	65
Табела 5-8. Резултати добиени при примена на RF алгоритам за класификација во случај на 11 класи на нарушувања	66
Табела 6-1. 7 класи на нарушувања на напонот и нивните ознаки	76
Табела 6-2. Споредба на предложените алгоритми за извлекување на карактеристики и класификација во случај на 7 класи со алгоритми предложени во литературата	77
Табела 6-3. 11 класи на нарушувања и нивните ознаки	77
Табела 6-4. Споредба на предложените алгоритми од овој труд во случај на 10 класи без шум со алгоритми предложени во литературата	78
Табела 6-5. Споредба на предложените алгоритми од овој труд во случај на 10 класи и SNR од 20 dB со алгоритми предложени во литературата	78
Табела 6-6. Споредба на предложените алгоритми од овој труд во случај на 10 класи и SNR од 30 dB шум со алгоритми предложени во литературата	79
Табела 7-1. 21 нарушувања на напонските сигнали и нивните ознаки	84
Табела 7-2. Оптимален избор за влезните параметри на RF1 алгоритмот за класификација	88
Табела 7-3. Оптимален избор за влезните параметри на RF2 и RF3 алгоритмите за класификација	89

Табела 7-4. Резултати добиени за тестирање на точноста во класификацијата и времето за класифицирање на класификаторот RF1.....	90
Табела 7-5. Резултати добиени за тестирање на точноста во класификацијата на класификаторот RF2.....	91
Табела 7-6. Резултати добиени за тестирање на точноста во класификацијата на класификаторот RF3.....	91
Табела 7-7. Резултати добиени за тестирање на точноста во класификацијата на предложениот оптимизиран алгоритам за класификација.....	92
Табела 7-8. Дел од матрицата на конфузија добиена за сигнали кои се фазно поместени еден од друг, пропратени со шум за SNR од 30~50 dB и при примена на оптимизиран алгоритам за класификација.....	93
Табела 7-9. Резултати за процентот на точност во класификација за сигнали добиени по примена на детекторот за премин преку нулата.....	100
Табела 7-10. Време на проесирање на имплементацијата на системот во реално време.....	101
Табела 7-11. Резултати од верификацијата на системот за детекција и класификација на нарушувања во напонските сигнали.....	104
Табела 7-12. Споредбена анализа на системот за детекција и класификација на напонски нарушувања предложен во овој труд со системи предложени во литературата.....	106

Глава 1

Вовед

1.1 Мотивација за изработка на докторската дисертација

Со зголемената употреба на нелинеарни електрични уреди, честата појава на грешки како резултат на временски непогоди, влијанија од животната средина или пак човечки грешки, проблемот на нарушен квалитет на електричната енергија станува сè посериозен. Дополнително, побарувањата за намалена емисија на јаглерод во околината ги гледаат паметните мрежи како ефективно решение. Тие ја намалуваат употребата на нафта и гас и истовремено го забрзуваат продирањето на обновливите извори на електрична енергија. Иако зголемената свест за одржлив развој е главниот поттик за искористување на овие извори, променливите карактеристики на ветерот и сончевата енергија носат огромни предизвици за безбедно и стабилно работење на електроенергетската мрежа [1]-[3]. Согласно со тоа, обновливите извори дополнително ја нагласуваат потребата за следење на квалитетот на електричната енергија.

Квалитетот на електричната енергија се однесува на голем опсег на варијации и настани кои се појавуваат во напонот и струјата. Квалитет кој ги задоволува стандардизираните параметри значи конзистентност на напојувањето, што претставува клучен фактор за градење на сигурна електроенергетска мрежа. Од друга страна пак, доколку квалитетот значително отстапува од стандардизираните параметри и доколку не се следи континуирано, истиот со текот на времето може да има сериозно влијание врз крајните корисници. Една карактеристика на нарушувањата на квалитетот е дека секундарните последици се многу пати подраматични во споредба со ефектите врз постројките за производство, пренос и дистрибуција на електричната енергија. Причина за тоа е домино-ефектот, кој може да произлезе од меѓусебно поврзување на одреден дел или на целата критична инфраструктура. Оттука следи дека нарушениот квалитет не резултира само со “гаснење на светлата”, туку влијае врз регулацијата на сообраќајот, транспортот, здравството, снабдувањето со вода, телекомуникациите, финансиските услуги и сè останато што е дел од нашето секојдневие.

Нарушениот квалитет на напонот и струјата претставува значаен проблем и за бизнис секторот, особено за индустријата. Доведува до намалување на ефикасноста во производството, а во најлош случај може да предизвика и целосен прекин на истото. Цената на нарушениот квалитет е висока, што се должи пред сè на фактот дека неговите ефекти доведуваат до оштетување на опремата, зголемени активности за нејзино одржување и го скратуваат нејзиниот работен век. Сето тоа резултира во значајни финансиски загуби. Според истражувањето презентирани во [4], анализирајќи осум европски земји, се покажува дека трошоците поради незадоволителниот квалитет на

електричната енергија во анализираните земји претставува 25 милијарди евра од економијата на Европската Унија, за годината во која е спроведено истражувањето. Над 90% од овие финансиски загуби се токму во индустријата.

Во согласност со горенаведеното, стабилното и веродостојно напојување е од голема важност. Оттука следи дека електроенергетскиот сектор има потреба од континуирано мониторирање, детекција, анализа и препознавање на нарушувањата во напонските и струјните сигнали на различни локации во електроенергетската мрежа. За таа цел се јавува потреба од примена на напредни инструментациски и мерни методи и хардверско и софтверско инженерство за развој на децентрализиран систем за мониторирање и анализа, каде секој јазол од мрежата ќе биде потенцијална локација за поставување на уред кој ќе го следи квалитетот на електричната енергија. Тука може да најдат примена и виртуелните инструменти, кои се особено актуелни во последните години [5]-[10].

Системи за мониторирање на квалитетот на електричната енергија веќе постојат. Кај поголемиот дел од нив поставените мерни уреди служат само за снимање на сировите сигнали за понатамошна анализа, каков што е случајот со системите презентирани во [11]-[17]. Кај овие системи, поради комплексноста на електроенергетската мрежа, се генерира огромна количина на мерни податоци. Тоа ја отежнува анализата и преносот на податоците. Истовремено се јавува потреба и од големи мемориски ресурси за нивно складирање. Други децентрализираните системи освен што ги снимаат сировите сигнали овозможуваат и нивно процесирање во реално време, со што даваат пресметани стандардизирани индикатори за квалитетот на електричната енергија. Примери за такви системи се презентирани во [18]-[21]. Како и да е, ни едните ни другите системи не овозможуваат класификација на нарушувањата на напонот и струјата во реално време. Класификацијата во реално време ќе овозможи брзо откривање на причината за настанатото нарушување и брзо отстранување на проблемите кои истото ги предизвикало. Исто така би овозможила и снимање само на нарушените сирови сигнали и формирање на база од реални напонски сигнали.

Постоењето на јавно достапна база составена од нарушени напонски сигнали снимени со добар квалитет претставува недостаток во оваа област [22]. Важноста на податоците во одржувањето на електроенергетската мрежа сè повеќе и повеќе се зголемува. За развој на системи и алгоритми најчесто се употребуваат симулирани сигнали според определени математички дефиниции. Тие иако се блиски до реалните, сепак секогаш постојат навидум мали но значителни разлики. На пример, според стандардите номиналната фреквенција на напонот и струјата е 50 Hz односно 60 Hz. Како и да е, во реалниот електроенергетски систем, како резултат на незабележливите но секогаш присутни варијации во фреквенцијата таа речиси никогаш не е еднаква на нејзината номинална вредност. Овие ситни отстапувања влијаат врз точноста на системот за детекција и класификација, кога истиот ќе се примени во реална електроенергетска мрежа. Согласно со тоа, истражувањата, развојот, и иновациите во областа на анализата на нарушувањата на електричната енергија имаат потреба од

достапност до бази на податоци кои би биле што е можно пореални. Од суштинско значење е да се соберат значителни количини на релевантни податоци со цел да се овозможи експериментирање и анализа на предложените алгоритми и нивна успешна употреба и дисеминација во пракса.

За развој на децентрализиран пристап, како и за понатамошно формирање на база, се јавува потреба од моќен дигитален процесор на кој ќе се имплементираат алгоритми за детекција и класификација, со ниска комплексност и висока точност. И покрај напредокот на техниките за машинско учење и дигитална обработка на сигнали во областа на квалитет на електрична енергија, развојот на такви алгоритми сеуште е отворено прашање и предизвик за истражувачите. Развојот и имплементацијата на овие алгоритми претставува и наш предизвик и главна мотивација за изработка на оваа докторска дисертација.

1.2 Предмет на истражување на докторската дисертација

Предмет на истражувањето во рамките на оваа дисертација е развој, тестирање и имплементација на систем за детекција и класификација на нарушувањата на напонските сигнали во реално време. Системот ќе овозможи континуирано мониторирање на квалитетот на електричната енергија, брза детекција и класификација на еднократни и повеќекратни нарушувања со висока точност, ефикасно справување со шум и континуирано запишување на настанатите нарушувања. Сето тоа ќе биде постигнато со помош на:

- **Развој на алгоритам за оптимално извлекување на карактеристики базиран на вејвлет трансформација:** Голем број на истражувачи имаат предложено различни алгоритми за извлекување на карактеристики од нарушените сигналите. Сепак, одбирањето на соодветните карактеристики со цел да се постигне ефикасна детекција на нарушувањата сеуште претставува отворено прашање. Во овој труд ќе биде предложен алгоритам за оптимално извлекување на карактеристики. Алгоритамот ќе формира вектор на карактеристики со мали димензии кој ќе овозможи детекција на нарушувањата со висока точност. Тоа директно ќе влијае врз времетраењето на целиот процес за извлекување на карактеристиките како и врз имплементацијата на целиот систем. Од големиот број на предложени процесирачки алатки, алгоритамот ќе се базира на дискретна вејвлет трансформација (DWT). Тоа пред сè се должи на нејзините особини кои ја прават погодна за анализа на различни преодни појави присутни во електроенергетскиот систем.
- **Развој на оптимизиран алгоритам за класификација на еднократни и повеќекратни нарушувања кој ефикасно се справува со шум:** Сигналите кои се добиени од уредите за мониторирање често пати се придружени со шум кој

вovedува грешки при процесот на класификација. Согласно со тоа, преку истражувања и споредби на различни класификатори ќе биде избран класификатор кој ќе се одликува со висока точност во класификација при различен број на класи и при различно ниво на шум присутен во сигналите. Истиот ќе овозможи препознавање на еднократни нарушувања и на комбинации од две, три и четири нарушувања. Дополнително, предложениот алгоритам за класификација ќе биде оптимизиран. Оптимизацијата директно ќе влијае на времетраењето на процесот на класификација и на имплементацијата на алгоритмот во реално време.

- **Имплементација на предложените алгоритми за извлекување на карактеристики и класификација во реално време:** Предложените алгоритми за извлекување на карактеристики и за класификација ќе бидат имплементирани на процесор кој ќе овозможи нивна работа во реално време. Оваа имплементација, заедно со апликација развиена во LabVIEW ќе овозможи развој на систем за детекција и класификација на нарушувањата на напонот со висок процент на точност во реално време.

1.3 Цели и придобивки од истражувањето

Основната цел на истражувањето е да придонесе за континуирано мониторирање на квалитетот на напонот и континуирана класификација на настанатите нарушувања, што пак во иднина би придонело за одржување на стабилноста и доверливоста на електроенергетскиот систем. Тоа ќе биде постигнато преку развој на систем за детекција и класификација на нарушувањата на напонските сигнали во реално време кој ќе се базира на оптимално извлекување на карактеристики и оптимизирана класификација.

Цели на истражувањето се:

1. Да се истакне потребата од квалитет на електричната енергија кој ги задоволува стандардизираните параметри и потребата од негово континуирано мониторирање и анализа;
2. Да се истакне потребата од детекција и класификација на нарушувањата на напонот со висок процент на точност и во реално време;
3. Преку истражувања и споредби да се развие оптимален алгоритам за извлекување на карактеристики кој ќе формира вектор на карактеристики со мали димензии;
4. Преку истражување и споредба да се избере соодветен алгоритам за класификација кој овозможува класификација на различни еднократни и повеќекратни стандардизирани нарушувања и ќе може да се справи со шум присутен во напонските сигнали;

5. Да се оптимизира алгоритмот за класификација, согласно барањата за негова имплементација во реално време, а тоа се: висок процент на точност во класификација и ниска комплексност;
6. Со помош на алгоритмот за извлекување на карактеристики и оптимизираниот алгоритам за класификација да се реализира имплементација која ќе овозможи класификација на 21 класа на нарушувања со висок процент на точност;
7. Имплементацијата да се примени во експериментални сценарија и да се тестира со сигнали генерирани во MATLAB;
8. Да се реализира имплементацијата на процесор со помош на LabVIEW околина со што ќе се добие систем кој ќе овозможи детекција и класификација на нарушувањата на напонот во реално време;
9. Системот да се верифицира со помош на експериментален ланец кој ќе овозможи репродуцирање на генерирани сигнали како истите да се реални и измерени директно од електроенергетската мрежа;
10. Да се направи споредба на развиениот систем со други системи за иста намена кои се предложени во последните години и се достапни во литературата.

Главниот придонес на оваа дисертација е класификација на нарушувањата присутни во напонот од електроенергетската мрежа во реално време. Тоа ќе биде постигнато со развој на систем за детекција и класификација на нарушувањата кој се заснова на оптимален алгоритам за извлекување на карактеристики и оптимизиран алгоритам за класификација на еднократни и повеќекратни нарушувања со висок процент на точност и отпорен на шум.

Се очекува вака развиениот систем во иднина да биде применлив во реални сценарија, каде ќе резултира во брза детекција и точна класификација на нарушувањата на напонските сигнали. Тоа би придонело до континуирано одржување на квалитетот на напонот во електроенергетската мрежа, а со тоа и до стабилно напојување. Придобивките од ваквиот систем би имале влијание во повеќе сфери од секојдневието, но пред сè би имале значително влијание врз економијата.

1.4 Структура на докторската дисертација

Оваа докторска дисертација е составена од осум глави, кои го следат развојот на системот кој ќе овозможи класификација на нарушувањата на напонот во реално време, тргнувајќи од потребите за ваков систем па се до негова верификација и споредба со други системи за иста намена кои постојат во литературата.

Првата глава претставува вовед во проблемите кои може да ги предизвика нарушениот квалитет на електричната енергија и ја истакнува потребата од негово

континуирано мониторирање и анализа. Содржи преглед на досегашни постигнувања во областа на мониторирање на квалитетот на напонот и класификација на неговите нарушувања во реално време и истовремено ги посочува недостатоците и предизвиците во истата.

Во втората глава е даден преглед во областа на квалитет на електрична енергија. Презентирани се термините кои најчесто се употребуваат, истакнати се потребите за дефинирање на квалитетот и дефинирани се феномените кои се појавуваат во напонот и струјата. Исто така, во оваа глава е даден преглед на некои од стандардите кои се од суштинско значење за понатамошните истражувања презентирани во докторскиот труд.

Третата глава се однесува на извлекувањето на карактеристиките од напонските сигнали. Поточно, во оваа глава е даден кус преглед на дел од областа дигитално процесирање на сигнали кој се однесува на банки на филтри и нивна примена во дискретната вејвлет трансформација. Оваа трансформација претставува алатка која ќе се применува за добивање на така наречените вејвлет-базирани карактеристики. Тие карактеристики овозможуваат детекција на нарушувањата присутни во напонските сигнали и го формираат векторот на карактеристики кој има значајна улога во процесот на класификација

Во четвртата глава се презентирани најчесто применуваните алгоритми за класификација на нарушувањата на напонските сигнали, а кои се дел од областа машинско учење. Истите алгоритми се применети во истражувањата кои се дел од докторскиот труд. Исто така, во оваа глава се дадени математички модели на нарушувањата на напонот со помош на кои се формираат множества на сигнали потребни за обучување и тестирање на презентираниите алгоритми за класификација.

Во петтата глава се презентирани резултати од истражувањата за избор на оптимална комбинација на вејвлет-базирани карактеристики, со примена на сите алгоритми за класификација презентирани во четвртата глава. За целите на истражувањата, употребени се различен број на класи на нарушувања и нарушени сигнали со и без присуство на шум. Избраната оптимална комбинација овозможува висока точност во класификацијата, а притоа формира вектор на карактеристики со мали димензии.

Во шестата глава се презентирани резултати од истражувањата и споредбите наменети за избор на најсоодветен алгоритам за класификација, од алгоритмите презентирани во четвртата глава. Како и во петтата глава, така и во оваа за целите на истражувањата применети се различен број на класи на нарушени напонски сигнали со и без шум. По изборот на соодветниот алгоритам кој се одликува со висока точност во класификацијата и кој е отпорен на шум, целата техника за класификација заедно со формирањето на векторот на карактеристики е споредена со други техники презентирани во литературата. Преку споредбата се докажува ефикасноста на техниката предложена во овој труд.

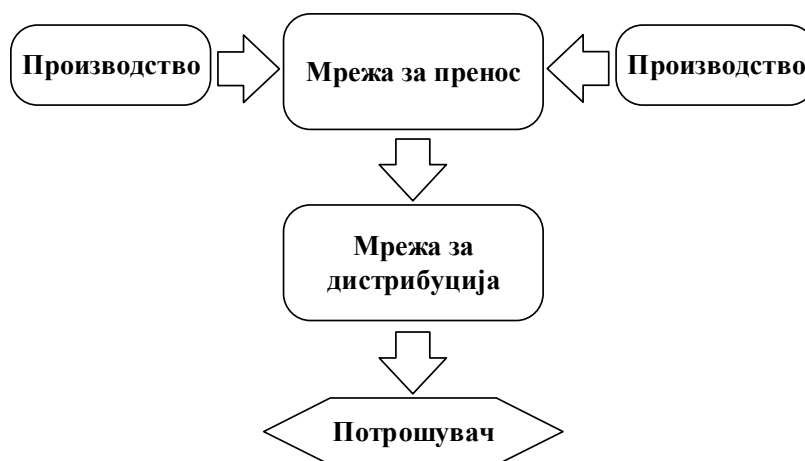
Во седмата глава се сумирани резултатите од петтата и шестата глава. Направена е оптимизација на избраниот алгоритам за класификација со цел да се намали неговата комплексност. Со помош на добиениот оптимизиран класификатор развиен е систем за детекција и класификација на нарушувања присутни во напонот во реално време. Најпрво, направено е тестирање на предложениот класификатор со сигнали кои се генерирани во MATLAB и презентирани се добиените резултати. Потоа, направена е верификација на системот за класификација со примена на експериментален ланец кој овозможува репродукција на генерирани сигнали како истите да се реално измерени директно од електроенергетската мрежа. Со добиените резултати се потврдува верификацијата. Во оваа глава е презентирана и споредбена анализа на развиениот систем со други системи за иста намена дадени во литературата. Со резултатите уште еднаш се потврдува ефикасноста на системот и неговата предност над другите системи кои се дел од споредбата.

Во осмата глава се изложени заклучоците од целокупните истражувања презентирани во докторскиот труд. Истакнат е придонесот на трудот во областа на квалитет на електрична енергија од аспект на анализа на нарушувањата на напонските сигнали. Дополнително, во оваа глава се дадени насоки за понатамошни идни истражувања за подобрување на предложениот систем и негова примена во реални сценарија.

Глава 2

Вовед во квалитет на електрична енергија и квалитет на напон

Зголемената потреба од електрична енергија, што пред сè се должи на современиот начин на живот, го прави светот целосно зависен од електроенергетските системи. Работата, слободното време, грижата за здравјето, економијата како и целата наша егзистенција зависи од континуирано напојување со електрична енергија. Тоа подразбира непрекината работа на електроенергетскиот систем. Структурата на еден таков систем, разгледувана во голем број книги и истражувања од областа на квалитет на електрична енергија е прикажана на Слика 2-1.



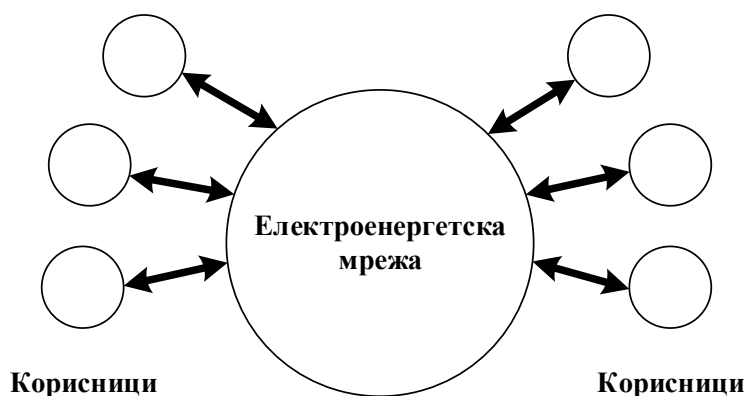
Слика 2-1. Структура на електроенергетски систем

Согласно со прикажаната структура, електричната енергија се произведува во големи генераторски станици на релативно мал број локации, системот за пренос овозможува пренесување на произведената електрична енергија од различните станици до пошироките области, додека пак дистрибутивната мрежа овозможува дистрибуција на електричната енергија од преносните електроенергетски постројки до крајните потрошувачи.

Во последните години, како резултат на развојот на електроенергетскиот сектор, овој модел на електроенергетски систем полесно исчезнува. Иако од технички аспект промените не се сеуште многу големи, се појавува поинаков начин на размислување кој има потреба од нов начин на разгледување на овие системи:

- Воведување на либерализација во електроенергетската индустрија, што значи дека електроенергетскиот систем повеќе не може да се третира како една целина. Во голем број земји производството на електричната енергија е комплетно либерализирано или пак се стреми да стане такво. Секоја електроенергетска компанија е економски независна, дури иако од електроенергетска гледна точка е составен дел од некој поголем систем;
- Зголемување на потребата од производство на електрична енергија кое не и штети на природата, односно искористување на обновливите извори на електрична енергија, кое доведува до употреба на помали генераторски единици. Ова така наречено дистрибуирано производство често пати не е поврзано со системот за пренос туку е директно поврзано со системот за дистрибуција на електрична енергија.
- Зголемување на барањата на потрошувачите за сигурност и квалитет во напојувањето, што го принудува мрежниот оператор што е можно повеќе да се придржува кон истите.

Претходно наведените факти резултираат во една нова модерна структура на електроенергетските системи прикажана на Слика 2-2.



Слика 2-2. Модерна структура на електроенергетски систем


Иако моменталната структура на поголемиот дел од системите е како на Слика 2-1, иднината води кон структурата дадена на Слика 2-2. Електроенергетската мрежа прикажана на втората слика може истовремено да биде мрежа за пренос, за дистрибуција и за индустрија. На пример, корисници на преносната мрежа може да бидат генераторски станици, мрежи за дистрибуција, големи индустриски потрошувачи кои би произведувале или би користеле електрична енергија или други мрежи за пренос на електрична енергија. Кај мрежите за дистрибуција корисници се главно крајните потрошувачи кои само користат електричната енергија, но исто така корисници може да

бидат и мрежи за пренос како и мали постројки за производство на електрична енергија. Во ваквата структура сите корисници се еднакви, без разлика дали произведуваат електрична енергија или се само потрошувачи. Целта на мрежата е да овозможи транспорт на електричната енергија, или во економска смисла, да овозможи трансакција помеѓу корисниците.

Во една ваква структура квалитетот на електричната енергија има многу важна улога бидејќи се однесува токму на интеракцијата помеѓу мрежата и нејзините корисници.

2.1 Квалитет на електрична енергија и квалитет на напон


Квалитетот на електричната енергија претставува многу значаен аспект во снабдувањето со истата, особено од средината на 1990 години. Интересот во областа која го покрива овој термин расте аналогно на развојот на електроенергетските системи, кој беше претходно споменат. Тоа може да се воочи и од графиконот даден на Слика 2-3, каде е претставен бројот на публикации презентирани во базата на IEEE кои го споменуваат овој термин, од 1995 година до 2018 година.



Слика 2-3. Број на публикации презентирани во базата на IEEE од 1995 до 2018 година кои го обработуваат терминот “Квалитет на електрична енергија”

Како и да е, тоа не значи дека претходно не се правени истражувања во оваа област. Терминот за првпат бил спомнат во истражување презентирано во 1968 година во Соединетите Американски Држави [23]. Таму се дава забележливо добар преглед на областа, вклучувајќи и употреба на опрема за мониторирање. Во речиси исто време бил споменат и терминот “Квалитет на напон” во Скандинавските земји [24] и во Советскиот

Сојуз [25]. Употребата на овој термин исто така расте со текот на годините, што може да се забележи од Слика 2-4.



Слика 2-4. Број на публикации презентирани во базата на IEEE од 1995 до 2018 година кои го обработуваат терминот “Квалитет на напон”

Постојат различни мислења во однос на тоа кој термин е најсоодветен за опис на интеракцијата помеѓу електроенергетскиот систем и корисниците. Освен двата претходно споменати, постојат и други термини кои може да се сретнат низ литературата. Во продолжение дадени се куси дефиниции за најчесто употребуваниите:

- **Квалитет на напон** - се однесува на девијациите на напонскиот сигнал од неговиот идеален бранов облик. Идеалниот напон е синусоидална функција со константна фреквенција и константна амплитуда. Гледано од технички аспект, може да се интерпретира како квалитет на продуктот кој е испорачан од електроенергетското претпријатие до потрошувачот.
- **Квалитет на струја** - се однесува на отстапување на брановиот облик на струјата од неговата идеална форма. Идеалната струја, исто како и напонот, е синусоидална функција со константна фреквенција и амплитуда. Дополнителен услов е оваа синусоида да биде во фаза со напонот од напојувањето. Во тој случај, ако квалитет на напон е она што производителот го испорачува на корисникот, тогаш квалитетот на струјата е она што корисникот го добива од производителот. Бидејќи напонот и струјата се строго поврзани, доколку напонот или струјата отстапува од идеалниот облик многу е тешко другиот да биде идеален.
- **Квалитет на електрична енергија** - претставува комбинација од квалитет на напон и квалитет на струја. Согласно со тоа, квалитетот на електричната енергија

се однесува на отстапувањето на брановиот облик на напонот и/или струјата од неговата идеална форма.

- **Квалитет на напојување** - се однесува на квалитетот на напон кој беше претходно дефиниран и дополнително делот од интеракцијата помеѓу производителот и потрошувачот кој не е технички, како на пример брзината со која производителот реагира на жалбите на потрошувачот, или транспарентноста во тарифната структура.
- **Квалитет на потрошувачка** - се однесува на квалитетот на струјата кој беше претходно дефиниран, дополнет на пример со тоа колку временски точно потрошувачот ја подмирува сметката за електрична енергија.
- **Електромагнетна компатибилност** - Во ИЕС стандардите се употребува терминот електромагнетна компатибилност. Според стандардот ИЕС 61000-1-1 [26], “електромагнетна компатибилност е способност на опремата или системот да функционира задоволително во неговата електромагнетна околина без да воведува интолерантни електромагнетни нарушувања на останатите уреди во таа околина.” Првиот дел “способност ... да функционира ... во неговата ... околина” се поклопува со дефиницијата за квалитет на напон, додека делот “воведува ... нарушувања” се поклопува со претходно наведената дефиниција за поимот квалитет на струја.

Иако истражувачите не можат да се согласат околу терминот кој ја опишува интеракцијата помеѓу електроенергетскиот систем и неговите корисници, сите се согласни околу важноста на истата. Постојат голем број на причини за интересот во оваа област:

- Опремата станува се помалку толерантна на нарушувања во напонот, производствените процеси се помалку толерантни на неправилното работење на опремата, и компаниите стануваат помалку толерантни на прекините кои настануваат во производството. Сето тоа доведува до зголемени финансиски трошоци кои може да бидат резултат и на многу кратко нарушување во напонот.
- Опремата произведува повеќе нарушувања во струјата отколку вообичаено.
- Либерализацијата на електроенергетската индустрија доведува до зголемена потреба од индикатори на квалитет на електрична енергија.
- Со либерализацијата електричната енергија се третира како продукт кој треба континуирано да биде мерен, предвиден, гарантиран, подобруван, итн.

2.2 Преглед на нарушувањата на квалитетот на електричната енергија

Како што беше споменато претходно, квалитетот на електричната енергија се однесува на отстапување на брановиот облик на напонот и/или струјата од идеалниот. Овие отстапувања се нарекуваат “феномени во квалитетот на електричната енергија” или “нарушувања на квалитетот на електричната енергија”. Нарушувањата претставуваат значаен проблем во интеракцијата помеѓу електроенергетскиот систем и корисниците. Истите главно се делат на два типа, кои вообичаено се третираат на различен начин:

- Карактеристиките на напонот или струјата (на пример фреквенцијата) никогаш не се егзактно еднакви на нивната номинална или посакувана вредност. Малите отстапувања од номиналната вредност се нарекуваат *варијации во напонот* или *варијации во струјата*. Особината на секоја варијација е дека има некаква вредност во секој момент од времето, на пример фреквенцијата никогаш не е точно еднаква на 50 Hz или 60 Hz. Од таа причина мониторирањето на варијациите треба да биде континуирано.
- Повремено напонот или струјата значително отстапува од номиналниот или идеалниот бранов облик. Овие ненадејни отстапувања се нарекуваат *настани*. Таков пример е ненадејното паѓање на вредноста на напонот на нула, како резултат на промена на положбата на прекинувач во електричното коло.

2.2.1 Варијации во напонот и струјата

Варијациите во напонот и струјата се однесуваат на релативно малите отстапувања на нивните карактеристики од своите номинални или идеални вредности. Две основни карактеристики се амплитудата и фреквенцијата. Според средната вредност, вредноста на амплитудата и фреквенцијата на напонот е еднаква на номиналната вредност, но всушност тие не се никогаш точно еднакви. Во продолжение е даден преглед на најчестите варијации кои настануваат во напонот и струјата.

- *Варијации во амплитудата на напонот* - претставуваат зголемување и намалување на амплитудата на напонот како резултат на промени во оптоварувањето во дистрибутивниот систем, како на пример вклучување или исклучување на кондензаторски банки и реактори.
- *Варијации во фреквенцијата на напонот* - како амплитудата така и фреквенцијата на напонот не е константна. Варијациите во фреквенцијата на напонот се јавуваат како резултат на неурамнотеженоста помеѓу потрошувачката и производството.
- *Варијации во амплитудата на струјата* – вообичаено и струјата нема константна амплитуда. Варијациите во амплитудата на напонот се резултат на варијациите во амплитудата на струјата. Овие варијации играат важна улога во

дизајнирањето на системите за дистрибуција. Системот треба да биде дизајниран за максималната амплитуда на струјата, додека приходите на производителот воглавно се базирани на средната вредност на амплитудата на струјата.

- **Варијации во фазата на струјата** - во идеален случај напонот и струјата се во фаза. Во таков случај се овозможува ефикасен пренос на активна енергија и на тој начин најевтин систем за дистрибуција.
- **Несиметрија на напонот и струјата** - несиметрија, или трифазна несиметрија е феномен кој се појавува во трифазните системи, во кои ефективните вредности на напонот или фазните агли помеѓу последователните фази не се еднакви. Примарниот извор на несиметрија на напонот е неурамнотежено оптоварување. Тоа може да биде резултат на нееднаква распределба на нисконапонските потрошувачи на трите фази, но најчесто е поради големо оптоварување на една од трите фази.
- **Флуктуации на напонот** - доколку амплитудата на напонот варира, обично варира и протокот на електрична енергија кон опремата. Доколку варијациите се доволно големи или во одреден критичен опсег на фреквенции тоа може да влијае директно врз работењето на опремата. Случаите во кој варијациите на напонот влијаат врз потрошувачите се ретки, со исклучок на сијалиците. Доколку осветлувањето на сијалицата варира со фреквенции помеѓу 1 Hz и 10 Hz, нашите очи се многу осетливи на тоа и над одредена амплитуда резултатното треперење на сијалицата може да стане прилично вознемирувачко. Всушност осетливоста на човечкото око го објаснува интересот за овој феномен. Брзите варијации во амплитудата на напонот се нарекуваат *напонски флуктуации*, додека визуелниот феномен кој нашиот мозок го перцепира се нарекува *фликер*. Од таму доаѓа и терминот “*напонски фликер*” кој всушност е скратена верзија од терминот “*напонски флуктуации кои доведуваат до фликери на светлината.*”
- **Хармониска дисторзија на напонот** - брановиот облик на напонот всушност никогаш не претставува синусоидална функција со константа фреквенција. Овој феномен се нарекува хармониска дисторзија на напонот или само дисторзија на напонот. Кога претпоставуваме дека брановиот облик е периодичен, истиот може да се опише како сума од синусоиди со фреквенции кои се цел број пати од основната фреквенција. Компонентите кои не се основна фреквенција се нарекуваат хармониска дисторзија. Хармониската дисторзија обично е ограничена на неколку проценти при кои опремата може да функционира нормално. Но повремено се јавуваат и високи хармоници кои предизвикуваат дефекти кај уредите. Ова може да претставува особено голем проблем за индустријата каде има многу осетливи уреди.

- **Хармониска дисторзија на струјата** - претставува комплементарен феномен на хармониска дисторзија на напонот и е нарушување на квалитетот на струјата. Хармониската дисторзија на напонот и струјата се поврзани.
- **Интерхармониски компоненти на напонот и струјата** - некои уреди воведуваат струјни компоненти со фреквенција која не е цел број пати од основната. Овие компоненти на струјата се нарекуваат “*интерхармониски компоненти*”. Нивната амплитуда обично е многу мала за да би предизвикала некакви проблеми, но понекогаш може да возбудат неочекувани резонанции помеѓу индуктивитетот на трансформаторот и кондензаторските банки.
- **Периодични засеци на напонот** – Секое намалување на напонот кое трае помалку од половина циклус од основната фреквенција се нарекува напонски засек.
- **Високо фреквенциски шум во напонот** - напонот за напојување може да содржи и компоненти кои не се воопшто периодични. Овие компоненти се нарекуваат шумови, иако гледано од страната на потрошувачот, сите претходно наведени нарушувања всушност претставуваат некој вид на шум.

2.2.2 Настани во напонот и струјата

Настаните се нарушувања кои се појавуваат еднаш во одредено време, односно не се повторуваат периодично. Се разликуваат едни од други според две важни карактеристики, отстапувањето на амплитудата на напонот или струјата од нејзината номинална вредност и времетраењето на настанот вклучувајќи го и потребното “време на опоравување.” Во продолжение накусо ќе бидат разгледани различни типови на настани. Настаните во квалитетот на електричната енергија се нарушувања кои може да доведат до прекин на работата на уредите, прекин на производствените постројки и производството како и загрозување на работата на целиот електроенергетски систем. Настаните кои ќе бидат разгледани се однесуваат на настани во напонот бидејќи тие претставуваат проблем за крајните корисници. Но може слична листа да се издвои и за настаните во струјата со нивните можни влијанија врз енергетскиот систем.

- **Прекин на напонот** - е состојба во која напонот на приклучоците за напојување е речиси еднаков на нула, односно амплитудата на напонот е помала од 10% од номиналната амплитуда.
- **Напонски пропад** - претставува намалување на амплитудата на напонот помеѓу 90% и 10% од основната вредност, проследена со враќање на првобитната вредност по краток временски период.
- **Напонски скок** - претставува зголемување на амплитудата на напонот помеѓу 110% и 180% од основната вредност.

- **Напонски шилци** - имаат иста дефиниција како напонските скокови, само со поголема амплитуда и времетраење помало од 1 ms.
- **Преодни појави** - настани со многу кратко времетраење, обично еден циклус од основната фреквенција на напонот или помалку. Дури и многу кратки напонски пропади се нарекуваат преодни појави или напонски засеци. Овие брзи напонски настани може да се поделат во *импулсивни преодни појави* и *осцилаторни преодни појави*.

2.3 Преглед на стандардите за квалитет на електрична енергија

Во согласност со горенаведените факти, веќе со децении постојат стандарди кои го дефинираат квалитетот на електричната енергија. Речиси секоја држава употребува стандард кој ги дефинира границите во кои фреквенцијата и амплитудата на напонот е дозволено да варираат. Други стандарди ги ограничуваат хармониските дисторзии на напонот и струјата, напонските флукуации и времетраењето на прекините. Постојат три главни причини за развој на стандардите за квалитет на електрична енергија.

1. **Дефинирање на номинална околина.** Хипотетички пример за таков стандард е: “Брановиот облик на напонот треба да биде синусоида со фреквенција од 50 Hz и ефективна вредност од 230 V.” Ваквиот стандард не е практичен бидејќи е речиси невозможно да се одржат фреквенцијата и амплитудата точно до тие вредности. Поради тоа, стандардите кои постојат содржат термини како “номинален напон” или “деклариран напон”. Многу попрактична верзија на претходно наведениот стандард е “Номиналната фреквенција треба да биде 50 Hz и номиналниот напон треба да биде 230 V”, што е извадок од текстот на Европскиот стандард EN 50160 [27]. Дефинирањето на номинален напон и фреквенција не кажува ништо за реалното опкружување. За таа цел треба да е познато отстапувањето од номиналната вредност. Повеќето земји имаат стандард кој ги дефинира дозволените варијации во ефективната вредност на напонот, обично во опсегот од 90% до 110% од номиналната вредност.
2. **Дефинирање на терминологија.** Групата на стандарди има за цел да даде точни дефиниции на различни феномени, како нивните карактеристики би требало да бидат измерени и како опремата треба да биде тестирана за отпорноста на нив. Целта на овој дел е да се овозможи комуникација помеѓу различните партнери во полето на квалитет на електрична енергија. Тоа осигурува дека, на пример, резултатите од две мерења на квалитетот на електричната енергија може лесно да се споредат и дека отпорноста на опремата ќе може да се спореди со описот на околината. Хипотетички пример е “Времетраење на напонски пропад е времето за кое ефективната вредност на напонот е помала од 90% од неговата номинална вредност. Времетраењето на напонскиот пропад треба да биде

прикажано во секунди. Ефективната вредност треба да се одредува на секој половина-циклус.” И IEEE Std. 1159 [28] и EN 50160 даваат ваков тип на дефиниции.

- 3. Ограничување на бројот на проблеми настанати поради квалитетот на електричната енергија.** Ограничувањето на проблемите кои настануваат поради нарушениот квалитет на електричната енергија е крајната цел на целокупната работа во областа на квалитет на електрична енергија. Проблемите можат да бидат намалени со ограничување на количината на нарушувања предизвикани од опремата, преку подобрување на перформансот на напојувањето и преку производство на опрема помалку чувствителна на нарушувањата на напонот. Сите методи за ублажување бараат технички решенија кои може да се имплементираат независно од стандардите. Но соодветната стандардизација ќе овозможи важни иницијативи за имплементација на техничките решенија. Соодветната стандардизација исто така ќе го реши проблемот одговорен за настанатото нарушување. Таков стандард на пример е стандардот за хармоници IEC-61000-3-2 [29] кој ја ограничува количината на хармониски дисторзии во струјата предизвикани од опремата. IEEE има добра препорачана практика за ограничување на хармониската дисторзија, IEEE 519 [30], која дава ограничувања и за хармониците во струјата воведени од потрошувачите и хармониците во напонот испорачан од производителот.

2.4 Мониторирање и анализа на квалитетот на напонот

Во овој труд ќе се насочиме кон класификација на нарушувањата во напонот, кои како што беше претходно споменато се тесно поврзани и со нарушувањата во струјата. Постојат повеќе важни причини зошто е потребно континуирано да се следи квалитетот на напонот. Главната причина која ги поткрепува сите останати е финансиската загуба, особено ако електромагнетните појави влијаат негативно врз потрошувачите кои се дел од некаков процес. Ефектите на нарушениот квалитет врз опремата и процесите вклучуваат неправилно работење, оштетување, нарушување на процесите и голем број на други аномалии. Ваквите аномалии се скапи, бидејќи работата на процесите се прекинува ненадејно и мора што е можно побрзо истите да продолжат со работа. Покрај тоа, оштетувањето на опремата и последователната поправка чини и време. Исто така може да дојде и до оштетување на продуктот, што бара негово рециклирање или отфрлање, кое пак исто така претставува финансиски проблем.

Во прилог на решавањето на проблемите кои се јавуваат кај опремата е и формирање на база од нарушени напонски сигнали со кои ќе се испитува толеранцијата и чувствителноста на опремата. Ваквата база може да биде основа за развој на компатибилност на опремата како и спецификации за понатамошни нејзини подобрувања. Исто така базата може да се примени и за подобрување на целиот

електроенергетски систем. Проблемите со компатибилноста на опремата може да доведат до серозна опасност по безбедноста на луѓето како резултат на нејзино неправилно работење и целосен дефект.


Со цел правилно да се мониторираат, анализираат и класифицираат нарушувањата, потребно е мерењето на напонот да се спроведува според однапред пропишани стандарди. Во стандардот IEC 61000-4-30 [31] се препорачува основниот мерен интервал за мерење на амплитудата на напонот да биде во временски интервал од 10 циклуси за основна фреквенција од 50 Hz и временски интервал од 12 циклуси за основна фреквенција од 60 Hz, што резултира во 200 ms. Притоа мерните прозорци да бидат последователни и да не се преклопуваат.

Мониторирањето и класификацијата на нарушувањата на напонот е потребно да се одвиваат во реално време. Брзото препознавање на настанатите нарушувања ќе придонесе до навремено откривање на причината зошто настанало одредено нарушување и брза реакција за решавање на проблемот. Тоа ќе спречи до појава на поголеми дефекти во електроенергетската мрежа и ќе резултира во финансиска заштеда. Класификацијата во реално време исто така може да влијае и врз формирањето на потребната база на напонски сигнали. Истата би овозможила снимање само на нарушените сирови сигнали со што ќе се намали потребата од големи мемориски ресурси за складирање на податоците како и од сложени методи за нивен пренос.

Глава 3

Извлекување на карактеристики од напонските сигнали


Извлекувањето на карактеристиките е најважниот дел од системот за детекција и класификација на нарушувањата на напонот и струјата. Се применува за препознавање на специфичните карактеристики од коефициентите добиени со трансформација на оригиналниот сигнал. Во претходната глава беа разгледани различни нарушувања на квалитетот на електричната енергија кои беа групирани во две групи, варијации и настани. Како што беше напоменато, варијациите претставуваат мали отстапувања од номиналните посакувани вредности на синусоидата на напонот и струјата. Согласно со тоа тие припаѓаат во групата на стационарни сигнали. Според дефиниција, сигналот е стационарен кога статистички гледано тој е временски непроменлив. На пример, средната вредност и варијансата на сигналот не се менуваат со текот на времето. Пример за стационарен сигнал е прикажан на Слика 3-1.



Слика 3-1. Пример за стационарен сигнал (напонски фликер)

Спротивно на стационарните сигнали, доколку статистички гледано сигналот варира со текот на времето, тогаш тој е нестационарен. Настаните во квалитет на електричната енергија предизвикуваат нестационарност во напонскиот или струјниот сигнал. Пример за нестационарен сигнал е даден на Слика 3-2.

Како што може да се забележи, амплитудата има неочекуван пад. Пред и после падот сигналот е стационарен. Како и да е, разгледувајќи го целиот временски прозорец, сигналот е нестационарен.



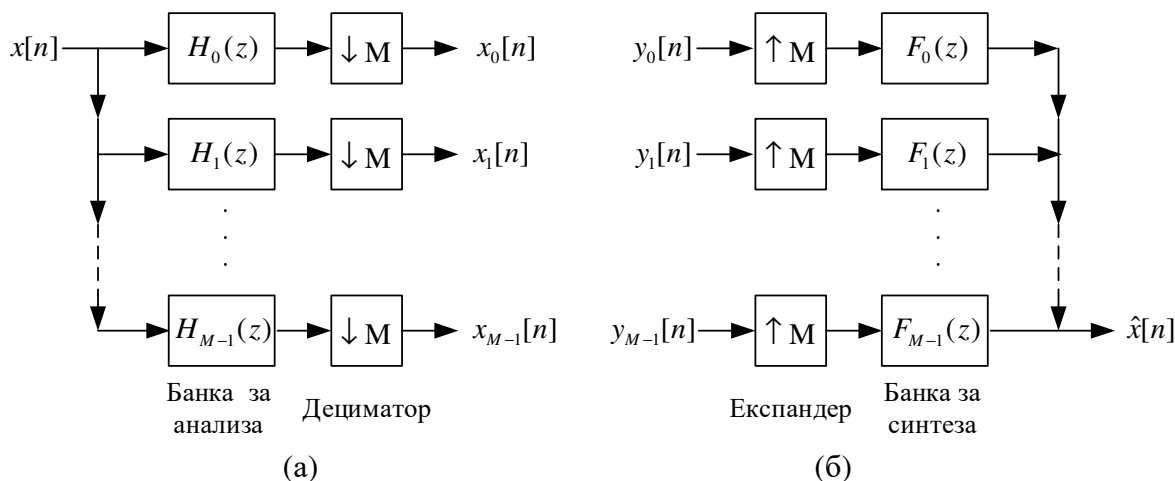
Слика 3-2. Пример за нестационарен сигнал (прекин во напонот)

Во анализата на реални напонски и струјни сигнали, стриктно стационарни сигнали ретко постојат. Дури и кога системот работи под нормални услови, без нарушувања, статистиките за амплитудата и фреквенцијата на напонот и струјата може многу споро но сепак со текот на времето да се менуваат. Согласно со тоа, потреба е алатка која ќе овозможи точна анализа на сигналите истовремено и во временски и во фреквенциски домен. По повеќегодишни истражувања се покажало дека таква алатка е дискретната вејвлет трансформација [32], [33]. Истата може да се интерпретира во структура на дрво на максимално децимирани банки на филтри [34], [35]. За да може да се разгледа вејвлет трансформацијата, најпрво ќе бидат разгледани банките на филтри.

3.1 Банки на филтри

Банката на дигитални филтри претставува множество од филтри кои имаат заеднички влез и заеднички излез. Истата може да биде банка на филтри за анализа чии филтри во продолжение ќе бидат означувани со $H_k(z)$ како што е прикажано на Слика 3-3 под (а) и банка на филтри за синтеза чии филтри ќе бидат означувани со $F_k(z)$ прикажани на Слика 3-3 под (б).

Банката за анализа прави декомпозиција на влезниот сигнал $x[n]$ во M сигнали $x_k[n]$ кои најчесто се нарекуваат подсигнали. Добиените подсигнали се пропуштаат низ дециматори со цел да се направи промена на фреквенцијата на дискретизација и да се намали комплексноста на процесирањето. Децимираните сигнали најчесто се кодираат и се испраќаат. Од страната на приемникот, во делот за синтеза, на подсигналите им се прави експанзија и се пропуштаат низ филтрите за синтеза. Излезните сигнали добиени од филтрите за синтеза се рекомбинираат со што на крај се добива реконструираниот сигнал $\hat{x}[n]$.




Слика 3-3. Банка на филтри: (а) Дел за анализа; (б) Дел за синтеза

Банките на филтри може да имаат структура која се состои од два канали или од повеќе канали. Структурата на банката е позната како максимално децимирана доколку факторите на дециматорот и експандерот се еднакви на бројот на опсези во кои се врши декомпозиција и реконструкција на сигналот, односно со бројот на канали на банката. Според тоа, банката на Слика 3-3 со M канали претставува максимално децимирана банка на филтри, бидејќи факторот на децимација и експанзија е еднаков на M .

3.1.1 Двоканална банка на филтри

Основната структура на двоканалната банка на филтри е прикажана на Слика 3-4. Нејзината улога е да направи декомпозиција на влезниот сигнал $x[n]$ во два подсигнали кои имаат ист по широчина опсег, со употреба на филтер пропусник на ниски фреквенции за анализа $H_0(z)$ и филтер пропусник на високи фреквенции за анализа $H_1(z)$, и реконструкција на влезниот сигнал со употреба на филтер пропусник на ниски фреквенции за синтеза $F_0(z)$ и филтер пропусник на високи фреквенции за синтеза $F_1(z)$. Двоканалната банка прикажана на сликата претставува максимално децимирана банка бидејќи факторите на децимација и експанзија се еднакви на 2.




Слика 3-4. Двоканална банка на филтри

Реконструираниот сигнал $\hat{x}[n]$ е подложен на три типа на грешки кои може да се појават при пропуштање на $x[n]$ низ банката. Тие грешки се: изобличување на сигналот како резултат на преклопување на спектрите, амплитудно изобличување и фазно изобличување. Овие три типа на изобличувања се должат на фактот дека филтрите $H_0(z)$, $H_1(z)$, $F_0(z)$ и $F_1(z)$ не се идеални.

Поголемиот дел од апликациите бараат реконструираниот сигнал да биде што е можно “поблизу” до оригиналниот. Согласно со тоа банките се дизајнираат така што се минимизираат или во идеален случај се елиминираат овие изобличувања, се со цел да се постигне систем за совршена реконструкција на влезниот сигнал или барем систем кој ќе овозможи реконструкција близу до совршената.

3.1.1.1 Ефект на преклопување на спектрите и негово поништување

За да се покаже ефектот на преклопување на спектрите на Слика 3-5 прикажани се два можни случаи за облиците на фреквенциските карактеристики на филтрите за анализа. Под (а) прикажан е случај кога карактеристиките $|H_0(e^{j\omega T})|$ и $|H_1(e^{j\omega T})|$ не се преклопуваат. Бидејќи слабењето во околина на $\pi/2$ е големо, ефектот на преклопување на спектрите нема големо влијание. Под (б) пак прикажан е вториот случај при кој фреквенциските карактеристики на филтрите се преклопуваат. Во општ случај, секој сигнал би можел да има значителна енергија за дадениот опсег која би го надминала идеалниот пропустен опсег на филтерот. Децимацијата на подсигналите во таков случај ќе резултира со преклопување на спектрите без разлика на тоа колку се добри непропустните опсези на филтрите.



Слика 3-5. Фреквенциски карактеристики на филтрите за анализа: (а) Кога карактеристиките на филтрите не се преклопуваат; (б) Кога карактеристиките на филтрите се преклопуваат

Од пракса е познато дека изборот на филтрите дадени на Слика 3-5 под (а) го решава проблемот на појава на преклопување на спектрите. Но дури и ако успее истиот да се надмине со соодветен дизајн на филтрите за синтеза $F_0(z)$ и $F_1(z)$, сепак тоа ќе

резултира со сериозно засилување на шумот. Оттаму следи дека изборот на филтрите дадени под (б) е можеби најпрактично решение.

Влезно-излезната релација на двоканалната банка на филтри од Слика 3-4 е дадена со равенството:

$$\hat{X}(z) = \frac{1}{2} [H_0(z)F_0(z) + H_1(z)F_1(z)]X(z) + \frac{1}{2} [H_0(-z)F_0(z) + H_1(-z)F_1(z)]X(-z) \quad (3.1)$$

Првиот дел од равенката го опишува пренесувањето на сигналот низ системот, додека вториот дел ја претставува грешката воведена од преклопување на спектрите. Условите за совршена реконструкција на влезниот сигнал гласат:

$$H_0(z)F_0(z) + H_1(z)F_1(z) = 2z^{-N} \quad (3.2)$$

$$H_0(-z)F_0(z) + H_1(-z)F_1(z) = 0 \quad (3.3)$$

каде N е редот на ниско пропустниот филтер $H_0(z)$. Согласно со (3.3) следи дека за да се овозможи совршена реконструкција на влезниот сигнал, компонентата која ја претставува грешката при преклопување на спектрите во (3.1) мора да биде еднаква на нула. Наједноставен начин да се постигне тоа е следниот избор на филтрите за синтеза:

$$F_0(z) = H_1(-z), \quad F_1(z) = -H_0(-z). \quad (3.4)$$

Со ваквиот избор условот (3.3) е исполнет и ефектот на преклопување на спектрите е поништен. За излезниот сигнал од банката се добива:

$$\hat{X}(z) = \frac{1}{2} [H_0(z)F_0(z) + H_1(z)F_1(z)]X(z) = z^{-N}X(z). \quad (3.5)$$

3.1.1.2 Ефект на амплитудно и фазно изобличување

Да претпоставиме дека филтрите се избрани како во (3.4) за да банката е ослободена од ефектот на преклопување на спектрите. Тогаш следи:

$$\hat{X}(z) = T(z)X(z). \quad (3.6)$$

Оттука, сигналот $\hat{x}[n]$ е подложен на амплитудно и фазно изобличување.

$$T(z) = \frac{1}{2} [H_0(z)F_0(z) + H_1(z)F_1(z)], \quad (3.7)$$

се нарекува преносна функција на целиот систем при елиминирано преклопување на спектрите. Ако го употребиме изразот даден во (3.4) се добива:

$$T(z) = \frac{1}{2} [H_0(z)H_1(-z) - H_1(z)H_0(-z)]. \quad (3.8)$$

Знаејќи $T(e^{j\omega T}) = |T(e^{j\omega T})|e^{j\phi(\omega T)}$, следи:

$$\hat{X}(e^{j\omega}) = |T(e^{j\omega T})|e^{j\phi(\omega T)} X(e^{j\omega T}) \quad (3.9)$$

Освен ако $T(z)$ е сепропустен филтер (на пример $|T(e^{j\omega T})| = d \neq 0$ за сите вредности на ωT), може да се каже дека $\hat{X}(e^{j\omega T})$ е подложен на амплитудно изобличување. Слично, освен ако $T(z)$ има линеарна фаза (тоа значи дека $\phi(\omega T) = a + b\omega T$ за $a, b = const$), $\hat{X}(e^{j\omega T})$ е подложен на фазно изобличување.

3.1.1.3 Ортогоналост помеѓу филтрите во двоканалната банка

Изборот на филтерот $H_1(z)$ остана непознат. Истиот може да се избере така да важи:

$$H_1(z) = -z^{-N}H_0(-z). \quad (3.10)$$

Условот за ваквиот избор е редот на филтерот $H_0(z)$, N , да е непарен. Доколку повторно се навратиме кај условот за совршена реконструкција и изборот на филтрите синтеза (3.4) така што ефектот на преклопувањето на спектрите би бил поништен, за овие филтри ќе се добие:

$$F_0(z) = z^{-N}H_0(z^{-1}), \quad F_1(z) = z^{-N}H_1(z^{-1}). \quad (3.11)$$

Согласно со (3.10) и (3.11) следи дека целата банка на филтри може комплетно да се дефинира преку филтерот $H_0(z)$. Соодветно избраниот филтер $H_0(z)$ ќе овозможи совршена реконструкција и ќе доведе до ортогоналност помеѓу филтрите во банката.

Нека производите на филтрите $H_0(z)F_0(z)$ и $H_1(z)F_1(z)$ во (3.5) се еднакви на $P_0(z)$ и $P_1(z)$, соодветно, со што се добива:

$$P_0(z) = z^{-N}H_0(z^{-1})H_0(z), \quad P_1(z) = -z^{-N}H_0(-z^{-1})H_0(-z) \quad (3.12)$$

Дефинираме нормализиран производ на филтри како:

$$P(z) = z^N P_0(z) = H_0(z^{-1})H_0(z) \quad (3.13)$$

Со вака дефинираниот производ и имајќи ги на ум (3.2) и (3.12) се добива:

$$P(z) + P(-z) = 2 \quad (3.14)$$

што претставува спектрална факторизација на halfband филтер. На единечната кружница $z = e^{j\omega T}$, производот $H_0(e^{-j\omega T})H_0(e^{j\omega T})$ е квадрат од амплитудата на $H_0(z)$:

$$P(e^{j\omega T}) = \sum_{-N}^N p(n)e^{-jn\omega T} = \left| \sum_{-N}^N h(n)e^{-jn\omega T} \right|^2 \quad (3.15)$$

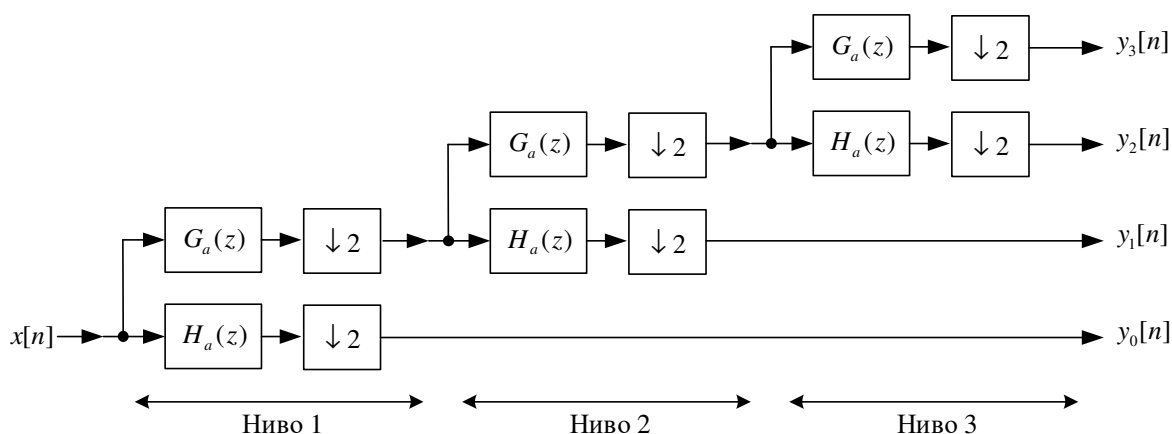
Halfband коефициентите се $p(n) = p(-n)$ за непарни вредности на n и $p(n) = 0$ за парни вредности на n , освен за $p(0) = 1$. Согласно со тоа, може да се дизајнира $P(z)$ и со негова факторизација да се добие $H_0(z)$. Оваа симетрична факторизација резултира во ортогонална банка на филтри со совршена реконструкција, која е основата на ортогонална вејвлет трансформација.

3.1.2 Максимално децимирани двоканални банки на филтри со структура на “половично разгрането дрво”


Постојат два типа на структура на дрво на максимално децимираните двоканални банки кои можат да бидат употребени во мултирезолуциската анализа на сигналот. Едниот тип е структура на “целосно разгрането дрво”, а другиот тип е структура на “половично разгрането дрво.”

3.1.2.1 Структура на “половично разгрането дрво”

На Слика 3-6 прикажан е делот за анализа од структурата на “половично разгрането дрво.” Таа е еквивалентна со структурата прикажана на Слика 3-7, која претставува четриканална структура каде факторот на децимација не е еднаков за секој канал. Но и покрај тој факт таа сеуште претставува максимално децимиран систем.

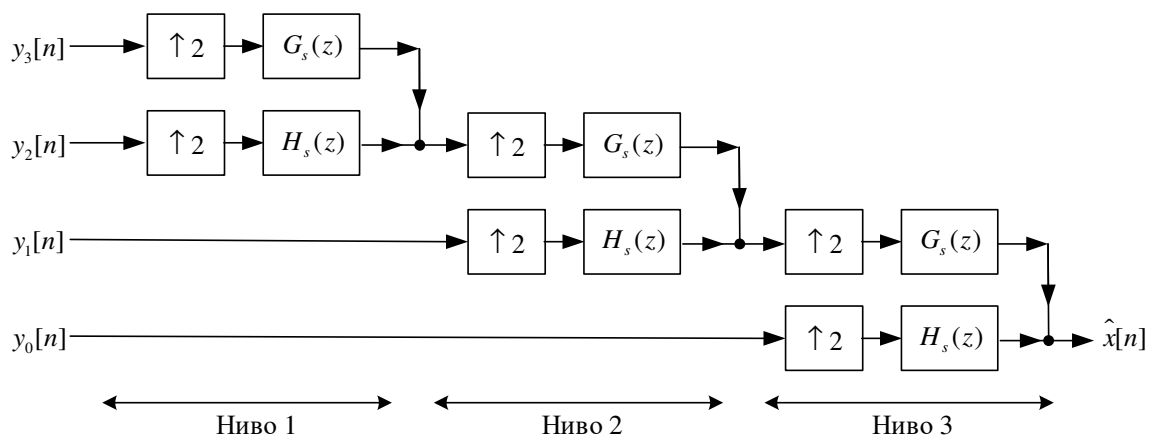


Слика 3-6. Дел за анализа со структура на “половично разгрането дрво” каде $G_a(z)$ претставува ниско пропустен филтер, а $H_a(z)$ високо пропустен филтер




Слика 3-7. Еквивалентна структура на делот за анализа

На Слика 3-8 прикажан е делот за синтеза од структурата на “половично разгрането дрво”, а на Слика 3-9 прикажана е неговата еквивалентната структура.




Слика 3-8. Дел за синтеза со структура на “половично разгрането дрво” каде $G_s(z)$ претставува ниско пропустен филтер, а $H_s(z)$ високо пропустен филтер



Слика 3-9. Еквивалентна структура на делот за синтеза

На Слика 3-10 прикажани се типичните амплитудни одзиви на филтрите за анализа и синтеза кај претходно споменатите банки на филтри. Од сликата може да се заклучи дека филтрите од различните нивоа на банката имаат неуниформни фреквенциски опсежи.



Слика 3-10. Типични амплитудни одзиви на филтрите за анализа и синтеза кај банките на филтри со структура на половично разгрането дрво

Делот за анализа од ваквата структура на банки на филтри ќе биде употребен за имплементација на конвенционална вејвлет трансформација и истиот може да биде проширен во повеќе нивоа.


3.2 Дискретна вејвлет трансформација

Еднодимензионалната дискретна вејвлет трансформација е дадена со

$$DWT[m, n] = \frac{1}{\sqrt{a_0^m}} \sum_{k=-\infty}^{\infty} f[k] \psi \left[\frac{k - nb_0 a_0^m}{a_0^m} \right] \quad (3.16)$$

каде што функцијата ψ ја претставува основната функција или мајка вејвлет, додека пак a_0 и b_0 ги претставуваат параметрите на скалирање и на поместување, соодветно. Со изборот $a_0 = 2$ и $b_0 = 1$ се добива двоканална ортогонална вејвлет трансформација. Во ваков случај конвенционалната DWT може да се имплементира многу лесно и брзо со употреба на техниките на банки на филтри со дрвенеста структура, поточно структура на “половично разгрането дрво”. Беше кажано дека банката на филтри се употребува за да направи декомпозиција на влезниот сигнал во посакуваниот број на нивоа со употреба на ниско пропустен филтер чија преносна функција е $H_0(z)$ и високо пропустен филтер чија преносна функција е $H_1(z)$. Коefициентите кои се добиваат на излез од ниско пропустниот филтер се нарекуваат коefициенти на апроксимација, додека пак оние кои се добиваат на излез од високо пропустниот филтер се нарекуваат коefициенти на детали. Делот со пониска фреквенција, или коefициентите на апроксимација, влегуваат

во наредното ниво и повторно се пропуштаат низ пар од ниско пропустен и високо пропустен филтер. Постапката се повторува повеќе пати во зависност од апликацијата како и од должината на влезниот сигнал. Како резултат се добива логаритамска декомпозиција на фреквенцискиот спектар на влезниот сигнал. На Слика 3-11 прикажана е декомпозиција на влезниот сигнал во две нивоа.




Слика 3-11. Структура на дискретна вејвлет трансформација во две нивоа

3.3 Вејвлет-базирани карактеристики

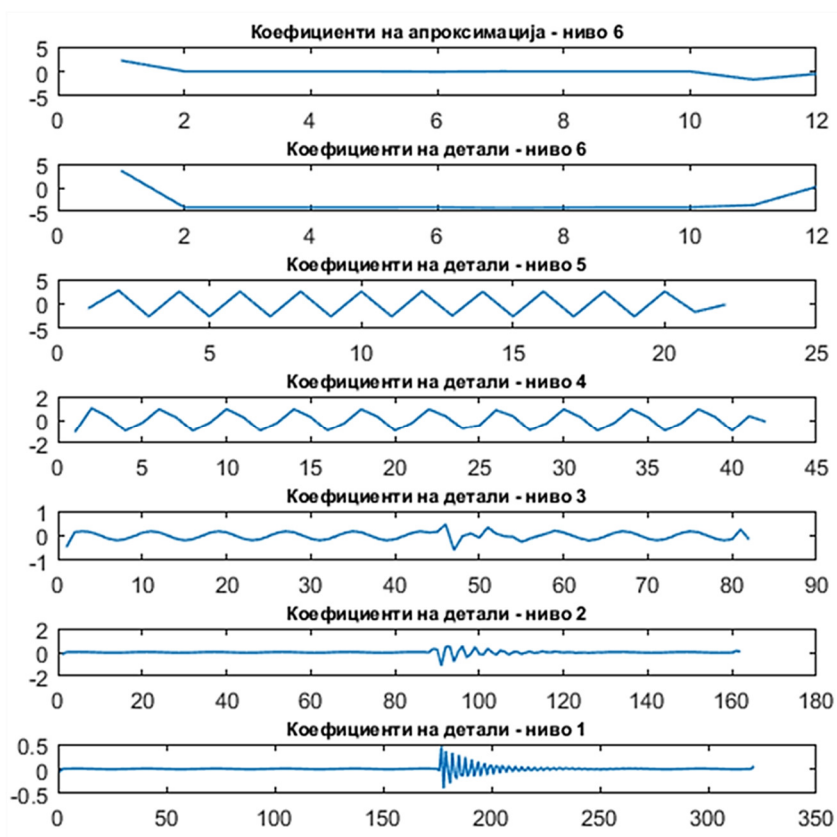
Во процесот на извлекување на карактеристики, нарушените напонски сигнали се разложуваат со употреба на DWT. Вејвлет трансформација всушност е мерка за сличноста помеѓу основната вејвлет функција, или уште така наречениот мајка вејвлет, и сигналот кој се носи на влез. Поради тоа изборот на соодветниот вејвлет филтер е еден од клучните фактори за успешна примена на вејвлет трансформација. Како општо правило за препознавање на брзи транзиентни нарушувања во сигналите, пократките филтри се предлагаат како подобра опција, додека пак за нарушувања кои се засноваат на спори транзиенти филтрите со поголем број на коефициенти се презентирани како особено добри [36], [37]. Оттука следи дека изборот на најсоодветен вејвлет филтер за детекција и класификација на нарушувањата на електричната енергија не е воопшто лесна задача. Во овој труд како најсоодветен филтер е избран Daubechies4 вејвлет филтерот, како еден од најупотребуваните филтри за оваа намена [38].

Бројот на нивоа на декомпозиција на влезниот сигнал, l е исто така од големо значење. Изборот на овој број воглавно влијае на две работи. Поголем број на нивоа на декомпозиција значи повеќе пресметки, што значи дека ќе биде и потребно подолго време за да се извршат истите. Од друга страна пак, изборот на поголемо l подразбира повеќе информации во системот за класификација, односно поголем вектор на карактеристики, и на тој начин ќе придонесе до поголема точност. Експерименталните резултати покажуваат дека зголемувањето на бројот на нивоа после $l = 6$ не влијае драматично врз точноста на алгоритмот за класификација [38]. Поради тоа во овој труд е земено бројот на нивоа на декомпозиција да биде $l = 6$.

На Слика 3-12 прикажан е пример за нестационарен сигнал, поточно осцилаторна преодна појава во напонот, додека пак неговата декомпозиција со примена на DWT во шест нивоа е прикажана на Слика 3-13.



Слика 3-12. Пример за нестационарен сигнал (осцилаторна преодна појава во напонот)



Слика 3-13. Декомпозиција со примена на DWT во 6 нивоа

Од сликата може да се воочи како DWT ги двои високите од ниските фреквенции, двојно го намалува бројот на примероци во секое наредно нивно на декомпозиција и прави успешна локализација на настанатото нарушување. Со помош на коефициентите на детали од секое ниво на декомпозиција и коефициентите на апроксимација од последното ниво на декомпозиција се извлекува векторот на карактеристики. Презентирани се различни техники на извлекување на карактеристики кои ги применуваат вејвлет-базираните карактеристики дадени во Табела 3-1.

Табела 3-1. Математички дефиниции за карактеристики базирани на DWT

Карактеристики базирани на DWT	Математички дефиниции
Енергија	$E_i = \frac{1}{N} \sum_{j=1}^N C_{ij} ^2$
Средна вредност	$\mu_i = \frac{1}{N} \sum_{j=1}^N C_{ij}$
Стандардна девијација	$\sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (C_{ij} - \mu_{ij})^2}$
Искривување	$SK_i = \sqrt{\frac{1}{6N} \sum_{j=1}^N \left(\frac{C_{ij} - \mu_{ij}}{\sigma_i} \right)^3}$
Шенонова ентропија	$SE_i = - \sum_{j=1}^N C_{ij}^2 \log(C_{ij}^2)$
Корен од средна квадратна вредност	$rms_i = \sqrt{\frac{1}{N} \sum_{j=1}^N C_{ij}^2}$
Куртозис	$KRT_i = \sqrt{\frac{N}{24} \left(\frac{1}{N} \sum_{j=1}^N \left(\frac{C_{ij} - \mu_{ij}}{\sigma_i} \right)^4 - 3 \right)}$
Ентропија на логаритамска енергија	$LOE_i = \sum_{j=1}^N \log(C_{ij}^2)$
Ентропија на норма	$NE_i = \sum_{j=1}^N (C_{ij})^P, 1 \leq P$

Во равенките дадени во табелата, $i = 1, 2, 3, \dots, l$ го претставува нивото на декомпозиција, C_{ij} се однесува на коефициентите на детали од секое ниво на декомпозиција и на коефициентите на апроксимација од последното ниво, додека пак N е бројот на тие коефициенти.

Извлекувањето на карактеристиките од нарушениот сигнал, овозможува информација која помага да се препознае грешката одговорна за присутното нарушување. Согласно со тоа, извлекувањето на карактеристиките е најважната компонента при дизајнирањето на еден интелигентен систем за класификација, бидејќи дури и најдобриот класификатор нема да дава најточни резултати доколку карактеристиките не се соодветно одбрани. Како и да е, брзото и прецизно извлекување на карактеристики е сеуште отворено прашање.

Глава 4

Класификација на нарушувањата на напонските сигнали

Во Глава 2 беше даден преглед на нарушувањата на напонот, додека во Глава 3 беше презентирана техника за извлекување на карактеристики од напонските сигнали. За да се исполни крајната цел на дисертацијата, а тоа е развој на систем за класификација на нарушувањата во напонот во реално време, потребен е алгоритам за класификација (класификатор) кој ќе биде обучен од даден вектор на карактеристики да го препознае нарушувањето присутно во напонскиот сигнал.

Задачата на обучувањето е да се формира алгоритам користејќи множество за обучување S , со цел да се класифицира y како излез од обучениот алгоритам, за даден влез x . Множеството S е дефинирано како $\{(x_i, y_i), i = 1, \dots, N\}$, каде x_i претставува p -димензионален вектор на карактеристики, во оваа глава именуван како примерок, кој е влез во системот, додека y_i претставува посакуван излез од системот за класификација, односно посакуваната класа. За излезот од системот важи дека $y_i \in C = \{c_1, c_2, \dots, c_k\}$, каде C претставува множество на класи на нарушувања во напонот, додека c_k е ознака на соодветната класа.

Согласно истакнатата цел, потребно е класификаторот да се одликува со висок процент на точност, брзина во класификацијата и робустност. Точноста ја изразува способноста на алгоритмот правилно да го класифицира новиот, невиден примерок. Брзината се однесува на комплексноста на пресметките или бројот на чекори кои ќе бидат изведени при експлоатација на алгоритмот, додека пак робустноста се однесува на способноста на алгоритмот да се справи со шум присутен во сигналите. Уште една важна особина на класификаторот е интерпретабилноста, што се однесува на можноста за интерпретација на алгоритмот во форма разбирлива за човекот.

Во областа на квалитет на електрична енергија предложени се повеќе алгоритми од областа на машинско учење кои овозможуваат автоматска класификација на нарушувањата на напонот и струјата. Некои од најчесто употребените класификатори, се експертските системи базирани на множество од правила (анг. rule-based expert systems) [39], класификатори базирани на фази-логика (анг. fuzzy logic) [40], вештачки невронски мрежи (анг. artificial neural networks) [41], машина со носечки вектори (SVM) [42]-[44], дрво на одлучување (DT) [45], [46], алгоритам на случајна шума (RF) [47],[48].

Од споменатите алгоритми, во овој труд ќе бидат применети машина со носечки вектори, дрво на одлучување и алгоритам на случајна шума. Овие алгоритми претставуваат алгоритми за надгледувано учење. Кај надгледуваното учење, “учителот”

при обуката ги задава класите за дадените примероци и се обидува при процесот на учење да ги нагоди параметрите на алгоритмот така што грешката во класификацијата да е што е можно помала.

4.1 Машина со носечки вектори

Машина со носечки вектори претставува обучен систем кој употребува множество на хипотези со линеарни функции во многудимензионален простор на примероци. Поточно SVM алгоритмот се обидува да најде хипер-рамнина која ќе го максимизира растојанието помеѓу две класи, истовремено минимизирајќи ги грешките над множеството за обука [49]. SVM класификаторите во основа се бинарни класификатори и имаат единствен излез врз база на кој се одредува дали примерокот е или не е припадник на одредена класа. Нивната обука се изведува со множество примероци од кои секој е карактеризиран или како позитивен или како негативен примерок за класата за која се гради SVM моделот.

4.1.1 Машина со носечки вектори за линеарно разделив проблем

Нека е дадено множество за обучување во форма $\{x_i, y_i\}, i = 1, \dots, l$, каде важи $y_i \in C = \{-1, 1\}$. По претпоставка постои хипер-рамнина, H , која ги дели позитивните од негативните примероци. Точките кои лежат на хипер-рамнината ја задоволуваат релацијата:

$$H: w \cdot x - b = 0, \quad (4.1)$$


каде w е нормалата на H , $b/\|w\|$ е нормалното растојание на H од координатниот почеток и $\|w\|$ ја претставува евклидовата норма на w . Нека со d_1 е означено најмалото растојание од H до најблискиот примерок кој припаѓа на класата 1, додека со d_{-1} е означено најмалото растојание од H до најблискиот примерок кој припаѓа на класата -1. Оттука може да се дефинира маргина на делбената хипер-рамнина како растојание еднакво на $d_1 + d_{-1}$. Во случај кога примероците се линеарно разделиви, како што е прикажано на Слика 4-1, алгоритмот за обука ја бара делбената рамнина со најголема маргина. Истото формулирано на друг начин гласи: Нека сите примероци за обука ги задоволуваат следните ограничувања:

$$x_i \cdot w + b \geq 1 \text{ за } y_i = +1 \quad (4.2)$$

$$x_i \cdot w + b \leq -1 \text{ за } y_i = -1 \quad (4.3)$$

$$y_i(x_i \cdot w + b) \geq 1 \text{ за } \forall i. \quad (4.4)$$

Точките за кои што важат равенствата (4.2) и (4.3) ги дефинираат паралелните хипер-рамнини $H_1: x_i \cdot w + b = 1$ и $H_2: x_i \cdot w + b = -1$ и се нарекуваат носечки вектори. Растојанието помеѓу овие хипер-рамнини и H е дефинирано како $1/\|w\|$. Согласно со тоа маргината е $2/\|w\|$. Притоа треба да се истакне дека хипер-рамнините H_1 и H_2 се паралелни и во просторот помеѓу нив нема примероци за обука. Оттука следи дека со минимизација на $\|w\|^2$ може да се најде пар на хипер-рамнини кои даваат максимална маргина, притоа запазувајќи го ограничувањето дадено во (4.4).



Слика 4-1. Дефинирање на хипер-рамнини за линеарно разделив проблем

Сето она што беше истакнато се сведува на следниот оптимизациски проблем:

$$\text{минимизирај го } \frac{1}{2} \|w\|^2 \quad (4.5)$$

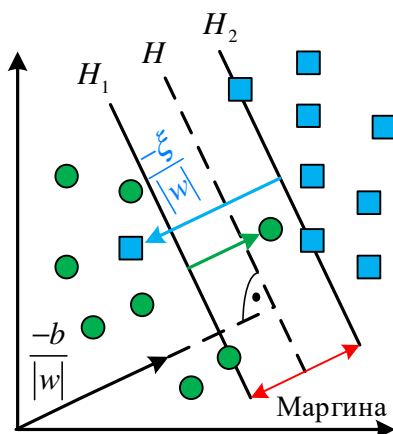
$$\text{под услов } y_i(x_i \cdot w + b) \geq 1, i = 1, \dots, l. \quad (4.6)$$

Оттука, w и b кои го решаваат дадениот проблем ја одредуваат функцијата на одлучување на класификаторот:

$$f(x) = \text{sgn}(w \cdot x + b). \quad (4.7)$$

4.1.2 Машина со носечки вектори за линеарно неразделив проблем

Линеарно неразделивиот проблем е проблем каде примероците не можат да се разделат со хипер-рамнина, односно не постои хипер-рамнина за која примероците од едната класа би биле од едната страна, а примероците од другата класа од другата страна на рамнината. Таков линеарно неразделив проблем е прикажан на Слика 4-2.



Слика 4-2. Дефинирање на хипер-рамнини за линеарно неразделив проблем

За да се овозможи решавање на ваков проблем, потребно е да се ублажат ограничувањата (4.2) и (4.3) со воведување на дополнителна цена во целната функција. Тоа може да биде изведено со воведување на позитивни “ублажувачки” променливи $\xi_i, i = 1, \dots, l$ во ограничувањата кои сега го добиваат обликот:

$$x_i \cdot w + b \geq 1 - \xi_i \text{ за } y_i = +1 \quad (4.8)$$

$$x_i \cdot w + b \leq -1 + \xi_i \text{ за } y_i = -1 \quad (4.9)$$

$$\xi_i \geq 0, \forall i. \quad (4.10)$$

Според даденото, за да се појави примерок од погрешна класа треба ξ_i да стане поголемо од 1. Вредноста на $\sum_i \xi_i$ ја претставува горната граница на грешки при обучувањето. Природен начин за вградување на дополнителна цена на чинење за овие грешки е да се промени целната функција која се минимизира од $\|w\|^2/2$ во $\|w\|^2/2 + C(\sum_i \xi_i)^k$, каде параметарот C го избира корисникот.

Овој начин на решавање на проблемот ќе овозможи добивање на оптимална делбена хипер-рамнина на најголема маргина и на тој начин обучување на SVM алгоритам со примероци кои не можат да бидат линеарно разделени.

4.1.3 Повеќекласен класификациски проблем со SVM


Како што веќе беше истакнато, SVM класификаторите по природа се бинарни класификатори. Но во голем број практични проблеми, како и во оваа дисертација, постојат повеќе од две класи каде задачата е да се одреди припадноста во една од нив. Постојат две насоки на решавање на овој проблем. Едната е концептуално проширување на самиот класификатор за да може да се справи со повеќе класи, а другата да се употребат повеќе бинарни класификатори кои ќе формираат еден класификатор. Кај

повеќекласната класификација со употреба на повеќе бинарни SVM класификатори постојат два пристапа: еден-против-сите (анг. one-against-all) и еден-против-еден (анг. one-against-one). Од наш интерес е пристапот еден-против-еден.

Според овој пристап се конструираат $k(k - 1)/2$ класификатори (по еден за секој пар на различни класи) од кои секој се обучува на примероците кои припаѓаат на двете соодветни класи. На тој начин секој од класификаторите се обучува да решава бинарен проблем и секој класификатор гласа за одредена класа. Крајната одлука е класата со најголем број на гласови. Недостаток е фактот дека може две класи да добијат најголем еднаков број на гласови. Во тој случај најизгласана класа е онаа која прва се појавува во низата од класи. Сепак, SVM алгоритмот за класификација кој се применува во оваа дисертација се базира на еден-против-еден стратегијата.

4.2 Дрво на одлучување

Дрво на одлучување се смета за еден од најпопуларните алгоритми за класификација на податоци. Истражувачи од разни научно-технички дисциплини како што се статистика, машинско учење, препознавање на облици итн. се занимаваат со проблемот наречен индукција на дрво на одлучување врз основа на расположливи податоци. Дрвото на одлучување се состои од корен, односно јазол кој нема влезни гранки. Сите останати јазли имаат точно по една влезна гранка. Јазол кој има излезна гранка се нарекува внатрешен јазол или уште познат како јазол на одлучување. Јазол кој нема излезна гранка се нарекува лист. Јазолот на одлучување може да има две или повеќе разгранувања. Јазолот од кој се разгрануваат гранките уште се нарекува и јазол – родител, додека јазлите во кои влегуваат гранките се нарекуваат јазли – деца. На Слика 4-3 прикажан е пример за дрво на одлучување од лева страна кое е обучено со множеството на примероци за обучување од десната страна.



Слика 4-3. (а) Дрво на одлучување; (б) Множество на примероци за обучување на дрвото

Множеството се состои од две класи на примероци, кругови и квадрати. Примероците се опишани со две карактеристики m и n . Јазол е местото каде се поставува прашање од типот $n < n_1$? каде n е целната карактеристика во однос на кој се прави поделба во јазолот. Разгранувањата на јазолот се одговорите на поставеното прашање, во случајот од сликата тоа се Да или Не, кои уште се нарекуваат и предикати на поделбата. Листовите претставуваат резултат од класификацијата или крајна одлука на дрвото, според сликата крајната одлука е или круг или квадрат. Согласно со тоа, секој лист од дрвото е придружен со класа.

Во дрвата на одлучување, секој внатрешен јазол ги дели влезните примероци во два или повеќе подпростори, во зависност од бројот на разгранувања, а во согласност со одредени дискретни функции од вредностите на карактеристиките. Во наједноставен случај, секој примерок би содржел по една карактеристика, така што множеството на примероци би било поделено според разгледуваната карактеристика. Откога дрвото е формирано, доделувањето на класа на секој влезен примерок се врши преку поминување на примерокот низ целото дрво почнувајќи од коренот па се до одреден лист.

4.2.1 Индукција на дрво на одлучување

Механизмите за индукција на дрво на одлучување се алгоритми кои автоматски го формираат дрвото врз база на дадено множество за обучување. Во поголемиот број од случаите целта е да се пронајде дрво на одлучување такво да грешката при класификација е минимална. Може да се дефинира и друга целна функција, на пример : најмалиот број на јазли кои дрвото треба да ги има или најмалата длабочина која дрвото треба да ја достигне. Формирањето на оптимално дрво на одлучување врз основа на дадени податоци се смета за тешка задача [50], [51]. Формирањето на дрвото на одлучување може да биде од почетниот јазол (коренот) па надолу кон листовите или пак од дното па нагоре. Постојат неколку алгоритми индукција на дрвата од коренот кон листовите. Тоа се ID3 [45], C4.5 [52] и CART [53]. Овие алгоритми го формираат дрвото со рекурзивен пристап, познат како “подели па владеј”. Во продолжение е дадено резиме на општата формулација на индукција на дрво на одлучување.

Обопштен алгоритам за индукција на дрво на одлучување:

input: S % Множество за обучување на дрвото

BuildTree() % Алгоритам за индукција на дрвото

$T = 0$; % T е дрвото на одлучување

Одбери го најдобриот критериум за поделба;

$T =$ Креирај јазол на одлучување и означи го со целна карактеристика за поделба;

$T =$ Додај гранка на јазолот за секој предикат на поделбата и означи ја;

За секоја додадена гранка {

S = множество на податоци добиено по поделбата на оригиналното множество S ;

If по оваа патека е стигнато до крај **then**

T' = Креирај лист и означи го соодветна класа;

else

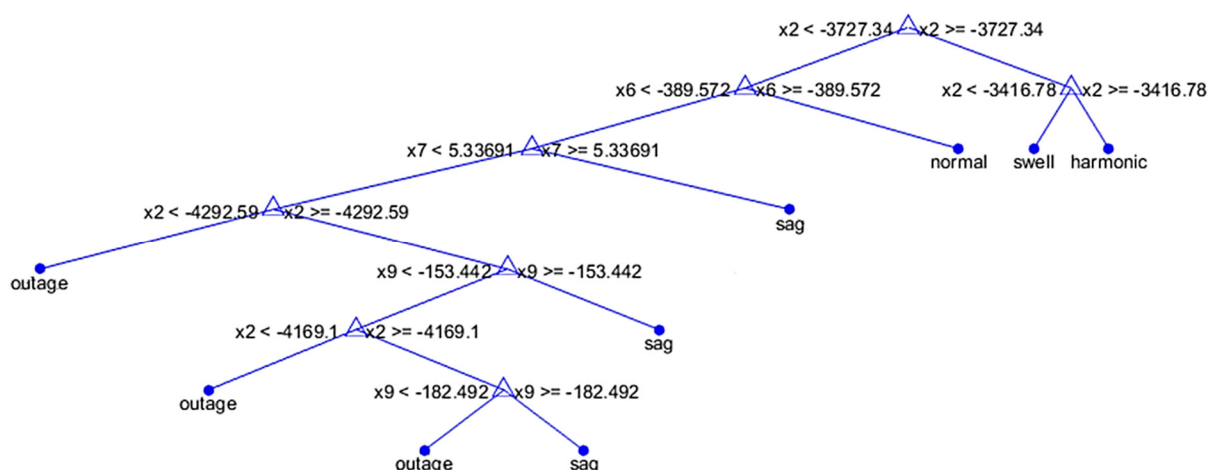
$T' = \text{BuildTree}(S)$ % Продолжи по патеката;

T = Додади го T' на гранката;

}

return: T

Дрвата на одлучување применети за истражувањата кои се дел од оваа дисертација се базираат на CART алгоритам. Овој алгоритам се карактеризира со индукција на бинарни дрва на одлучување, односно секој внатрешен јазол на дрвото се разгранува во две гранки. На Слика 4-4 прикажано е дрво на одлучување за класификација на пет класи на примероци, креирано со употреба на споменатиот алгоритам. Триаголниците претставуваат јазли, при што кај секој јазол е дадена целната карактеристика која влијае на поделбата од вкупно 14 карактеристики, од x_1 до x_{14} .



Слика 4-4. Бинарно дрво на одлучување за класификација на пет класи

Едни од најважните фактори кои влијаат врз индукцијата на дрвото се:

- Големина на множеството за обука;
- Критериум за избор на карактеристика за поделба;
- Критериум за прекин на растот на дрвото на одлучување.

Во однос на големината на множеството за обука, доколку множеството е многу мало, тогаш постои голема веројатност дрвото да нема висок процент на точност во

класификацијата при примена на нови множества. Доколку пак множеството е многу големо постои ризик од претерано нагудување (анг. *overfitting*). Тоа значи дека формираното дрво одлично ќе одговара на множеството на обучување, но нема да даде задоволителна точност во класификацијата при примена на нови множества на примероци. Критериумите за избор на карактеристика за поделба и прекин на растот на дрвото се разгледани во продолжение.

4.2.2 Критериум за избор на карактеристика за поделба

Кај најголемиот број бинарни дрва на одлучување, внатрешниот јазол прави поделба на влезните примероци во две подмножества врз основа на функција од вредноста на една карактеристика, која уште ја нарекуваме целна карактеристика. Најчесто критериумот со кој се избира таа карактеристика се базира на мерка за нечистотијата (анг. *impurity*) во новите множества добиени при поделбата. Колку е поголема разноврсноста на класите на примероците во дадено множество, толку е поголема нечистотијата во истото. Од друга страна пак, за чисто множество на примероци се смета она множество во кое сите примероци припаѓаат на една класа. Во овој труд, како мерка за нечистотија се употребува ентропија [54]. Истата низ литературата може да се сретне и како вкрстена ентропија или девијација.

Ентропијата е дефинирана како:

$$Entropy(\text{јазол}) = - \sum_{i=1}^k p_{c_i} \log_2 p_{c_i} \quad (4.11)$$


каде p_{c_i} ја означува веројатноста примероци од класата $c_i, i = 1, \dots, k$, да припаѓаат во множеството на примероци кое е дел од јазолот. Ентропијата потекнува од теорија на информации. Колку е поголема нејзината вредност толку повеќе информација има во множеството. На пример, за дадено множество составено од примероци кои припаѓаат само на една класа вредноста на ентропијата би била $Entropy = -1 \cdot \log_2 1 = 0$. Согласно со тоа, таквото множество е сосема “чисто”, но не дава никаква информација и истото не би можело да се примени за обучување на дрво на одлучување. Од друга страна пак, доколку е дадено множество кое има еднаков број на примероци кои припаѓаат во две различни класи, тогаш за ентропијата би се добило $Entropy = -0.5 \cdot \log_2 0.5 - 0.5 \cdot \log_2 0.5 = 1$. Со тоа се покажува максимална нечистотија во множеството што го прави добро множество за обучување на дрво на одлучување.

Критериумот кој избира услов за поделба во јазолот базиран на ентропија се нарекува информациска добивка (анг. *Information gain*). Истиот е дефиниран како:

$$InformationGain = Entropy(\text{родител}) - [averageEntropy(\text{деца})] \quad (4.12)$$

Како овој критериум го избира условот за поделба може да се објасни преку пример.

Пример: Нека е дадено множество за обука прикажано на Слика 4-7, кое се состои од 25 примероци кои припаѓаат на две класи, круг и квадрат (10 кругови и 15 квадрати).



Слика 4-5. Множество на примероци за обучување на дрво на одлучување

Доколку ја пресметаме ентропијата на јазолот – родител (во случајов тоа би бил коренот) ќе се добие:

$$Entropy(\text{родител}) = -\frac{10}{25} \log_2 \frac{10}{25} - \frac{15}{25} \log_2 \frac{15}{25} = 0.97$$

Поделбата на множеството во коренот од дрвото може да се направи врз основа на две карактеристики, боја и точка, каде како услов може да се постави прашање: Дали примерокот е црвен? или Дали примерокот има точка?.

Нека првата поделба е по бојата на примерокот. Јазлите - деца кои ќе се добијат од јазолот - родител ќе ги именуваме како црвен и син јазол. Во црвениот јазол ќе има 5 примероци од класата круг и 10 од класата квадрат, додека во синиот јазол ќе има 5 кругови и 5 квадрати.

$$Entropy(\text{црвен}) = -\frac{5}{15} \log_2 \frac{5}{15} - \frac{10}{15} \log_2 \frac{10}{15} = 0.92$$

$$Entropy(\text{син}) = -\frac{5}{10} \log_2 \frac{5}{10} - \frac{5}{10} \log_2 \frac{5}{10} = 1$$

$$AverageEntropy(\text{деца}) = \frac{15}{25} \cdot 0.92 + \frac{10}{25} \cdot 1 = 0.95$$

$$InformationGain(\text{боја}) = 0.97 - 0.95 = 0.02$$

Доколку поделбата се направи по карактеристиката точка. Јазлите - деца ќе бидат “со точка” и “без точка”. Во јазолот “со точка” ќе има 3 примероци од класа круг и 4 од класа квадрат, додека во јазолот “без точка” ќе има 7 кругови и 11 квадрати. По сите пресметки за информациската добивка ќе се добие:

$$InformationGain(\text{точка}) = 0.97 - 0.967 = 0.003$$

Согласно со добиените резултати, критериумот за поделба ќе ја избере поделбата во однос на карактеристиката “боја” бидејќи истата дава поголема информациска добивка.

4.2.3 Прекин на растот на дрвото и поткастрување на дрвото

Истражувачите секогаш се стремат за формирање на поедноставни дрва на одлучување бидејќи истите се сметаат за поинтерпретабилни. Сложеноста на дрвото има големо влијание врз неговата точност. Најчесто сложеноста на дрвото се мери преку:

- вкупен број на јазли;
- вкупен број на листови;
- длабочина на дрвото;
- употребениот број на карактеристики.

Фазата на растење на дрвото се одвива се додека не е исполнет некој критериум за прекин на растот. Некои од условите кои обично се применуваат за прекин на растот на дрвото се:

- Сите примероци кои учествуваат во креирањето на дрвото имаат иста вредност за целната карактеристика;
- Постигната е максималната длабочина на дрвото;
- Бројот на примероци во крајниот јазол (листот) е помал од минималниот број на примероци кои може да ги има јазол на одлучување;
- Ако јазолот се подели, бројот на примероци во јазлите – деца ќе биде помал од минималниот број на примероци за јазол – дете;

Критериуми за прекин на растот на дрвото се применуваат со цел да се избегне негово претерано нагодување.

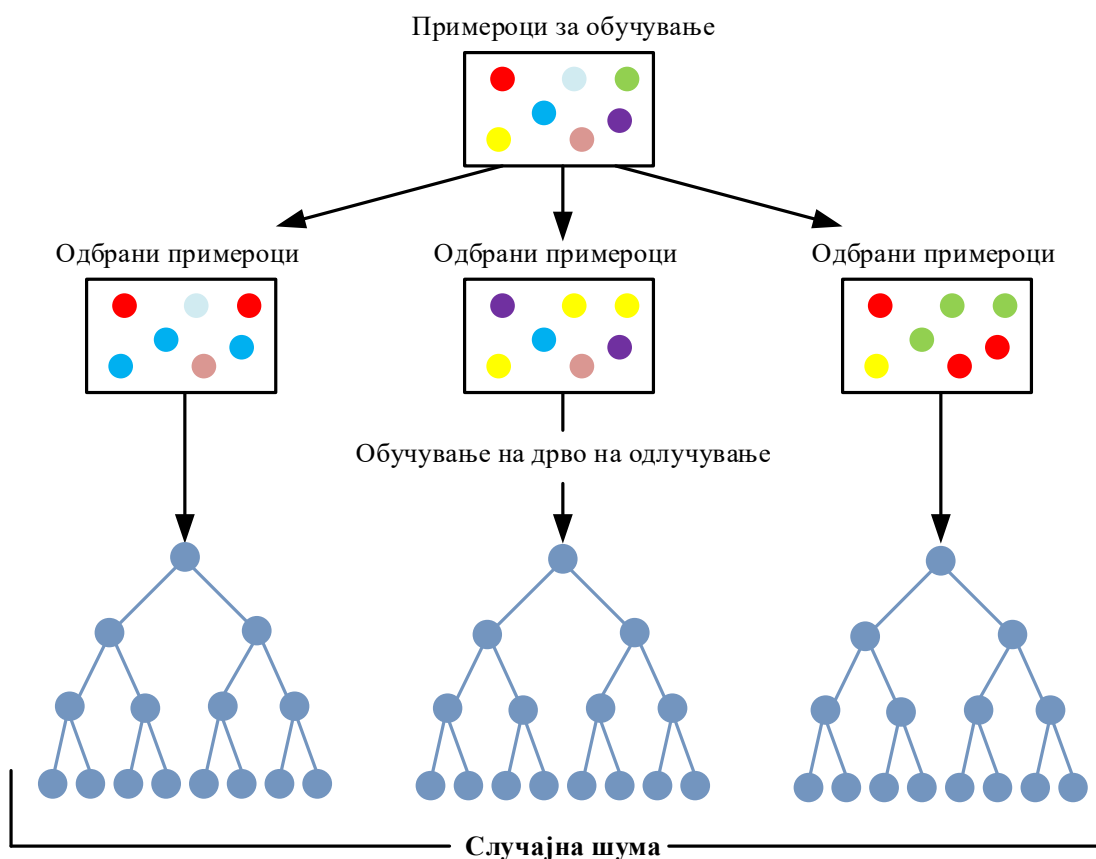
Покрај овие услови, дополнително се применуваат и методи за поткастрување на дрвото, чија цел е да се постигне компромис помеѓу точноста и сложеноста на дрвото. Во процесот на поткастрување, иницијалното стебло се разгледува како комплетно точно. Постојат различни техники за поткастрување. Многу од нив се применуваат со движење низ јазлите од коренот па надолу, или пак од дното кон коренот. Јазолот ќе биде поткастрен доколку во таква ситуација се подобрува одреден критериум.

Во овој труд се применува поткастрување со примена на алгоритам за пресметка на класификациска грешка при вкрстена валидација, достапен во MATLAB преку функцијата `cvloss()`. Истиот ја пресметува класификациската грешка при класификацијата на секое поддрво добиено со поткастрување на оригиналното дрво, за десет различни комбинации на множествата за обучување и тестирање. Од добиените

Класификациски грешки се пресметува стандардна распределба на грешката. Како резултат функцијата дава скалар за најдоброто ниво на поткастрување, за кое грешката од опсегот на стандардната распределба има минимална вредност.

4.3 Случајна шума

Алгоритмот на случајна шума претставува ансамбл од повеќе дрва на одлучување. Согласно со тоа, теоретското разгледување на случајната шума се надоврзува на она што беше презентирано во претходната потточка за дрвата на одлучување. Основната структура на овој алгоритам е прикажана на Слика 4-6.



Слика 4-6. Структура на случајна шума

4.3.1.1 Принцип на работа на алгоритмот

RF алгоритмот е дефиниран како:

$$\{f(x, \delta_k), k = 1, \dots\} \quad (4.13)$$

каде $f(x, \delta_k)$ претставува класификатор со структура на дрво, x е влезното множество на примероци за обука, δ_k се k множества на примероци одбрани од множеството x , и секое од тие k множества го одредува формирањето на посебно дрво на одлучување. Притоа треба да се нагласи дека секое од тие δ_k множества има исти димензии како и множеството x . Формирањето на меѓусебно релативно независни дрва е клучот на овој алгоритам, бидејќи на тој начин дрвата се заштитуваат едни со други од своите индивидуални грешки во класификацијата. За поедноставување на записот на поединечните дрва на одлучување, се воведува:

$$f_k(x) = f(X, \delta_k). \quad (4.14)$$

Два начини на формирање на меѓусебно независните дрва:

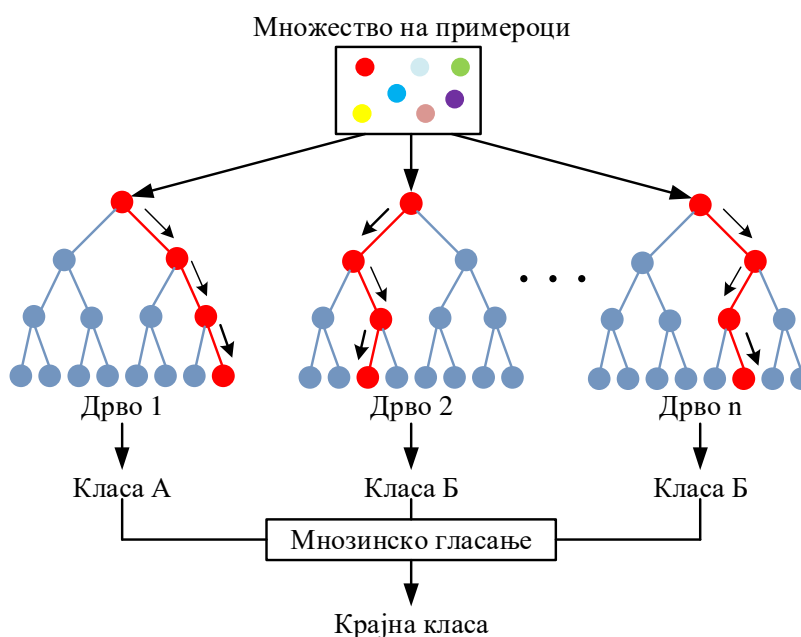
- Основниот принцип на RF алгоритмот се базира на случајно одбирање на примероци од оригиналното множество за обучување и формирање на δ_k подмножества за обука, така што избирањето се прави со замена. Оваа постапка се нарекува bootstrap aggregating или скратено bagging. Што во принцип значи тоа: Нека на пример е дадено оригинално множество за обучување на случајната шума $x = \{1,2,3,4,5,6\}$. За вака дадено множества постапката bagging би можела да формира множество $\delta_1 = \{1,2,2,4,5,5\}$ за обучување на дрвото на одлучување T_1 или множество $\delta_2 = \{1,1,2,2,5,6\}$ за обучување на дрвото на одлучување T_2 . Новоформираните множества за обучување имаат исти димензии како и оригиналното множество, но елементите односно примероците не им се идентично исти. Се земаат сите примероци од оригиналното множество и на некои им се прави замена (затоа може да се види дека некои недостасуваат, а некои се повторуваат). На тој начин се формираат случајни и меѓусебно независни множества за обучување на дрвата во шумата. Тоа е првата фаза каде се воведува случајност во алгоритмот. Втората случајност е воведена кај јазлите од дрвата на одлучување. Имено, секој јазол од вкупниот број на карактеристики во примероците случајно одбира m карактеристики кои учествуваат во исполнување на критериумот за поделба во јазолот. Вообичаено се одбира тој број да биде $m = \sqrt{\text{број на карактеристики}}$.
- Вториот начин на формирање на дрвата на одлучување се добива доколку во наредувањето на RF алгоритмот се одбере “bootstrap=False”. Во тој случај се изоставува првата фаза на случајност кај алгоритмот. Чекорот на одбирање на δ_k случајни вектори ќе биде прескокнат и целото оригинално множество за обука ќе учествува во формирање на секое од дрвата. Иако овој чекор е прескокнат, сепак алгоритмот се одликува со случајност и дрвата на одлучување кои го сочинуваат нема да бидат еднакви. Тоа се должи на претходно воведената втора фаза на случајност, односно на изборот на m карактеристики кои учествуваат во

исполнување на критериумот за поделба во секој од јазлите кај секое од дрвата во шумата.

За целите на истражувањата кои се дел од оваа дисертација применети се и двата начини на формирање на дрвата во случајната шума.

Сложеноста на алгоритмот зависи од истите параметри од кои зависи и сложеноста на едно дрво на одлучување и кои беа истакнати претходно. Дополнително врз сложеноста на овој алгоритам влијае и бројот на дрва во шумата. Вообичаено важи дека како што се зголемува бројот на дрвата во шумата, така се зголемува и точноста на класификаторот. Сепак големиот број на дрва може да влијае врз неговата имплементација за различни цели. Затоа е потребно да се постигне компромис помеѓу бројот на дрва и точноста на класификаторот.

При процесот на класификација на нови примероци, RF класификаторот ги сумира резултатите од секое дрво и како резултат ја дава класата која добила најголем број на гласови. Процесот на добивање на крајниот резултат е прикажан на Слика 4-7.



Слика 4-7. Сумирање на крајниот резултат на класификацијата кај алгоритмот на случајна шума

4.3.1.2 Конвергенција на грешката на генерализација на алгоритмот

Класификациската способност на RF класификаторот може да се мери преку анализа на неговата грешка на генерализација. За дадено множество на дрва на одлучување $f_1(x), f_2(x), \dots, f_k(x)$, и за множество за обука добиено со одбирање на примероци од оригиналното множество (x, y) , се дефинира функција на маргина како:

$$mg(x, y) = av_k I(f_k(x) = y) - \max_{j \neq y} av_k I(f_k(x) = j) \quad (4.15)$$

каде $I(\cdot)$ претставува индикаторска функција, $av_k(\cdot)$ е средна вредност, y ја претставува точна класа на која припаѓа примерокот, j било која друга класа. Функцијата на маргина дава број за кој просечниот број на гласови за точната класа го надминува просечниот број на гласови за која било друга класа. Колку што е поголема маргината толку е подобра изведбата на класификаторот. Грешката на генерализација е дефинирана како:

$$PE^* = P_{x,y}(mg(x, y) < 0) \quad (4.16)$$

каде индексите x, y покажуваат дека веројатноста се пресметува за оригиналното множество за обука кое се однесува на целата шума.

Како што бројот на дрва се зголемува, веројатноста конвергира кон:

$$\lim_{k \rightarrow \infty} PE^* = P_{x,y}(P_\delta(f(x, \delta) = y) - \max_{j \neq y} P_\delta(f(x, \delta) = j) < 0). \quad (4.17)$$

Овој резултат објаснува зошто RF алгоритмот не може претерано да се нагоди како што се зголемува бројот на дрва, туку предизвикува константна вредност на PE^* .

4.4 Формирање на множества обучување и тестирање

Со цел да се обучи одреден алгоритам за класификација да распознава различни нарушувања во напонските сигнали, потребно е множество од сигнали за обучување. Пожелно е тоа множество да има голем број на различни нарушувања, кои се појавуваат во различен период од временскиот прозорец, со цел класификаторот да може секое случајно нарушување да го препознава со поголема точност. Согласно со тоа, за класификаторот да биде соодветно обучен, потребна е база од многубројни снимени нарушени напонски сигнали. Непостоењето на таква база моментално претставува недостаток во областа на класификација на нарушувањата на квалитетот на електричната енергија.

За да може да се прават истражувања за изборот на соодветен алгоритам на извлекување на карактеристики и соодветен класификатор за класификација на нарушувањата во напонските сигнали, употребени се сигнали генерирани во MATLAB. Нарущувањата се генерирани според математички дефиниции кои се во согласност со стандардите кои беа споменати во Глава 2. Математичките дефиниции се дадени во продолжение. Во сите дефиниции, T претставува основен период, во зависност од основната фреквенција.

- **Номинален напон:**

$$x(t) = \sin(\omega t) \quad (4.18)$$

со параметри: $f = 50 \text{ Hz}$ и $\omega = 2\pi f$.

- **Пропад:**

$$x(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (4.19)$$

со параметри: $0.1 \leq \alpha \leq 0.9$ и $T \leq t_2 - t_1 \leq 9T$.

- **Скок:**

$$x(t) = [1 + \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (4.20)$$

со параметри: $0.1 \leq \alpha \leq 0.8$ и $T \leq t_2 - t_1 \leq 9T$.

- **Прекин:**

$$x(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (4.21)$$

со параметри: $0.9 \leq \alpha \leq 1$ и $T \leq t_2 - t_1 \leq 9T$.

- **Фликер:**

$$x(t) = [1 + \alpha \sin(2\pi\beta t)] \sin(\omega t) \quad (4.22)$$

со параметри: $0.1 \leq \alpha \leq 0.2$ и $5 \text{ Hz} \leq \beta \leq 20 \text{ Hz}$.

- **Осцилаторна преодна појава:**

$$x(t) = \sin(\omega t) + \alpha \exp(-(t - t_1)\tau) (u(t - t_1) - u(t - t_2)) \sin(2\pi f_n t) \quad (4.23)$$

со параметри: $0.1 \leq \alpha \leq 0.8$, $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$, $0.5T_n \leq t_2 - t_1 \leq 3T_n$
и $300 \text{ Hz} \leq f_n \leq 900 \text{ Hz}$.

- **Хармоници:**

$$x(t) = \alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t) \quad (4.24)$$

со параметри: $0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.1$, $\sum \alpha_i^2 = 1$.

- **Засек:**

$$x(t) = \sin(\omega t) - \operatorname{sgn}(\sin(\omega t)) \left\{ \sum_{k=0}^9 k [u(t - (t_1 + 0.2n)) - u(t - (t_2 + 0.2n))] \right\} \quad (4.25)$$

со параметри: $0.1 \leq k \leq 0.4$, $0 \leq t_1, t_2 \leq 0.5T$ и $0.01T \leq t_2 - t_1 \leq 0.05T$.

- **Шилец:**

$$x(t) = \sin(\omega t) + \operatorname{sgn}(\sin(\omega t)) \left\{ \sum_{k=0}^9 k [u(t - (t_1 + 0.2n)) - u(t - (t_2 + 0.2n))] \right\} \quad (4.26)$$

со параметри: $0.1 \leq k \leq 0.4$, $0 \leq t_1, t_2 \leq 0.5T$ и $0.01T \leq t_2 - t_1 \leq 0.05T$.

За истражувањата кои ќе бидат презентирани во понатамошниот дел од овој труд, употребени се различен број на класи, добиени како комбинација од овие дефиниции. Согласно со дефинициите, за секоја класа на нарушување има неколку параметри кои ја дефинираат, чии што вредности припаѓаат во даден опсег. Со цел генерирањето на сигналите да биде случајно, за секој опсег дефиниран е вектор од кој случајно се одбира една вредност. На пример, кај класата на нарушување “напонски пропад” за параметарот α дефиниран е вектор на вредности помеѓу 0.1 и 0.9 со чекор 0.0001. При генерирањето на секој сигнал кој е означен со оваа класа случајно се одбира една вредност од векторот. На ист начин се одбираат и останатите параметри кои ја дефинираат класата. Истата постапка е направена и за останатите класи, без разлика дали станува збор за еднократно или повеќекратно нарушување. На тој начин е воведена случајност и разноликост помеѓу генерираните сигнали. Основната фреквенција за сите сигнали е 50 Hz, додека пак фреквенцијата на одбирање на примероци зависи од потребите на одделните истражувања.

Глава 5

Избор на оптимален алгоритам за извлекување на карактеристики

Извлекувањето на соодветните карактеристики од нарушените напонски и струјни сигнали е “клучот” кој овозможува брза и точна класификација. Праксата досега покажала дека дури и најточниот алгоритам за класификација нема да даде задоволителни резултати доколку во процесот на формирање на векторот на карактеристики, карактеристиките не се соодветно одбрани. Според голем број истражувачи не постои сомнеж дека е потребно множество од подобри карактеристики со цел да се постигне висока точност во класификацијата, бидејќи перформансот на класификаторот зависи директно од векторот кој ги содржи извлечените карактеристики. Векторот треба да е формиран така да има што е можно помали димензии, бидејќи тоа влијае на брзината на класификацијата, но истовремено да биде доволно голем и да содржи важни карактеристики бидејќи тоа влијае на точноста на класификацијата. Соодносот брзина - точност ја има главната улога во развојот на алгоритам за одбирање на карактеристики од нарушените сигнали. И покрај напредокот во техниките за обработка на сигналот, соодветната селекција при извлекувањето на карактеристиките отсекогаш била предизвик [55], [56], и тоа сеуште е така.

Во литературата презентирани се различни алгоритми за формирање на векторот на карактеристики кои ги избираат “подобрите” карактеристики од дадено множество. Како и да е, сите тие алгоритми воведуваат дополнителни пресметки и на тој начин го зголемуваат времето потребно да се извршат истите. Како што беше напоменато во Глава 3, од наш интерес се алгоритмите кои се засноваат на вејвлет-базираните карактеристики. Во [38], [57]-[59] презентирани се техники за извлекување на карактеристики употребувајќи само една вејвлет-базирана карактеристика. На пример во [59] употребена е нормираната ентропија, додека пак во останатите се употребува енергијата. Во [60] се употребуваат три од дадените девет карактеристики: енергија, стандардна девијација и Шенонова ентропија. Во [61] употребени се сите девет вејвлет-базирани карактеристики.

Целта на овој дел од истражувањата кои се опфатени во овој труд е формирање на оптимален вектор на карактеристики, преку изнаоѓање на оптимална комбинација составена од дел од претходно споменатите вејвлет-базирани карактеристики. Резултатите од почетните истражувања во таа насока се презентирани во [62] и [63]. Со добиените резултати се покажа дека висока точност во класификацијата може да се постигне и со помал број на карактеристики, наместо да се употребуваат сите девет. Од добиените заклучоци произлезе идејата за подетално испитување на ефикасноста на вејвлет-базираните карактеристики, што е темелот на овој труд.

Со цел пронајде оптимална комбинација, испитана е точноста на сите можни комбинации на вејвлет базираните карактеристики, во случај на 7 и 11 класи на нарушувања, со примена на три различни алгоритми за класификација. Дополнително, испитувањето е направено и за напонски сигнали на кои е додаден бел Гаусов шум за сооднос сигнал-шум (SNR) од 20 dB, 30 dB, 40 dB и 50 dB. Мерните сирови сигнали често пати се придружени со шум кој влијае врз извлекувањето на важните карактеристики и ја деградира способноста на системот за мониторирање. Од таа причина се јавува потреба од алгоритам за извлекување на карактеристики кој се одликува со висока точност во класификацијата речиси за секоја можна вредност на SNR за додадениот бел Гаусов шум.

За намените на истражувањето генерирани се две множества на напонски сигнали составени од 7 и 11 класи на нарушувања, согласно со математичките дефиниции презентирани во делот 4.4. Класите на нарушувањата кои се употребени, заедно со нивните ознаки, се дадени во Табела 5-1. Од секоја класа се генерирани по 1000 сигнали за обучување и 1000 сигнали за тестирање. За генерирањето е употребена фреквенција на одбирање на примероци од 3.2 kHz. Секој сигнал се состои од 10 периоди, за основна фреквенција од 50 Hz, што резултира во вкупно 640 примероци.

Табела 5-1. 11 класи на нарушувања на напонот и нивни ознаки

Нарушувања на напонот	Ознака за класа
Номинален напон	D1
Скок	D2
Пропад	D3
Хармоници	D4
Прекин	D5
Пропад + Хармоници	D6
Скок + Хармоници	D7
Фликер	D8
Осцилаторна преодна појава	D9
Засек	D10
Шилец	D11

Бидејќи станува збор за сите можни комбинации на карактеристиките, добиено е обемно множество на резултати. Од сите резултати, во наредните потточни презентирани се некои од највисоките проценти на точност во класификацијата добиени за секоја поединечна должина на комбинациите. Во резултатите, вејвлет-базираните карактеристики се означени согласно со ознаките дадени во Табела 5-2.

Табела 5-2. Ознаки за вејвлет базираните карактеристики

Ознака	Карактеристики базирани на DWT
f1	Енергија
f2	Средна вредност
f3	Стандардна девијација
f4	Искривување
f5	Шенонова ентропија
f6	Корен од средна квадратна вредност
f7	Куртозис
f8	Ентропија на логаритамска енергија
f9	Ентропија на норма

5.1 Оптимална комбинација на вејвлет-базирани карактеристики за 7 класи на нарушувања

Најпрво направен е избор на оптимална комбинација на вејвлет-базирани карактеристики во случај на 7 класи на нарушувања со примена на SVM, DT и RF алгоритмите за класификација. Класите кои се применуваат се со ознаки од D1 до D7 согласно со Табела 5-1.

5.1.1 Со примена на SVM алгоритам

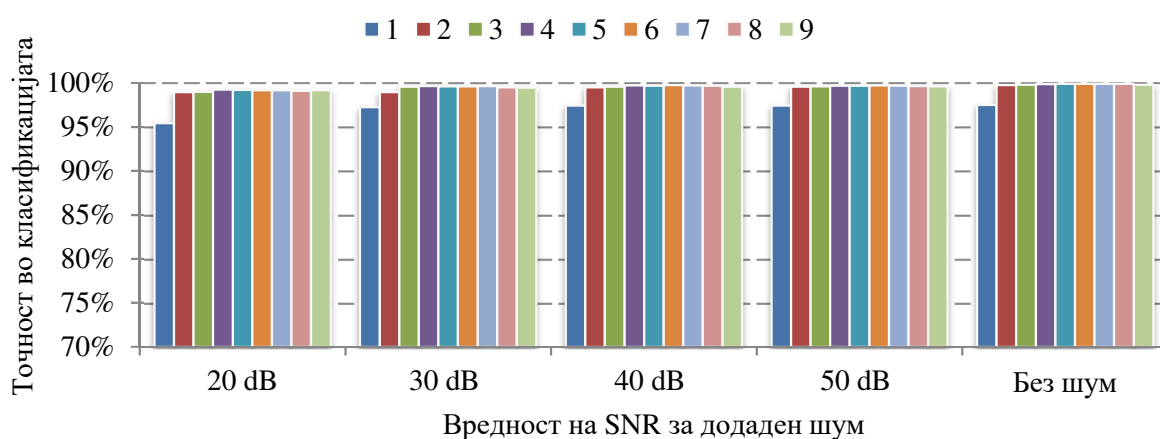
SVM моделот за класификација е развиен во MATLAB со употреба на библиотеката “libSVM” [64], која подржува класификација на повеќе класи. Резултатите добиени од примената на овој алгоритам за класификација се презентирани во Табела 5-3. За подобра визуелизација на резултатите, истите се графички прикажани на Слика 5-1. Броевите од табелата дадени во колоните означени со “f” го означуваат бројот на вејвлет-базирана карактеристика. Резултатите од точноста во класификацијата се претставени во проценти.

Од прикажаните резултати може да се заклучи дека за 7 класи, при примена на SVM алгоритмот за класификација, после комбинацијата составена од две вејвлет базирани карактеристики па се до онаа составена од девет карактеристики, точностите во

класификацијата се речиси идентични, без разлика дали сигналот е без шум или пак придружен со бел Гаусов шум за различни вредности на SNR.

Табела 5-3. Резултати добиени при примена на SVM алгоритам за класификација во случај на 7 класи на нарушувања

Бр.	20 dB		30 dB		40 dB		50 dB		Без шум	
	f	(%)	f	(%)	f	(%)	f	(%)	f	(%)
1	5	95.44	5	97.24	5	97.44	5	97.43	5	97.49
2	1,8	98.96	5,8	99.41	5,8	99.51	1,8	99.57	1,8	99.76
3	1,5,8	99.01	1,5,8	99.56	1,5,8	99.59	1,7,8	99.60	1,5,8	99.80
4	1,5,7,8	99.24	1,5,8,9	99.64	1,5,7,8	99.73	1,5,8,9	99.67	1,5,7,8	99.87
5	1,5,6,8,9	99.20	1,5,6,7,8	99.63	1,2,5,6,8	99.70	1,5,6,8,9	99.70	1,5,6,8,9	99.89
6	1,2,3,5,7,8	99.19	1,2,5,6,7,8	99.71	1,2,3,5,7,8	99.74	1,3,5,6,7,8	99.71	1,2,6,7,8,9	99.91
7	1,3,4,5,6,8,9	99.19	1,2,3,5,6,7,8	99.66	1,2,6,5,6,7,8	99.71	1,2,3,5,6,7,8	99.67	1,2,4,5,6,8,9	99.91
8	1,2,3,5,6,7,8,9	99.11	1,2,3,4,5,6,7,8	99.50	1,2,3,5,6,7,8,9	99.67	1,2,3,5,6,7,8,9	99.64	1,2,3,5,6,7,8,9	99.91
9	СИТЕ	99.19	СИТЕ	99.47	СИТЕ	99.56	СИТЕ	99.63	СИТЕ	99.79



Слика 5-1. Резултати добиени при примена на SVM алгоритам за класификација во случај на 7 класи на нарушувања

Употребата на девет вејвлет базирани карактеристики во секое ниво на декомпозиција резултира во вектор составен од 63 карактеристики. Тоа, споредено со вектор составен од 14 карактеристики, кој би се добил доколку се употребуваат само две вејвлет базирани карактеристики во процесот на извлекување, ќе има значително зголемено време потребно за извршување на пресметките. Токму овој компромис помеѓу времето и точноста на класификаторот може да игра клучна улога во имплементирање на алгоритмот за класификација во реално време. Согласно со тоа, комбинацијата составена од две вејвлет-базирани карактеристики, на пример “f1, f8” или “f5, f8”, дава

висока точност во класификацијата, а е составена од мал број на карактеристики, што ја прави оптимална комбинација во случај кога е применет SVM класификаторот.

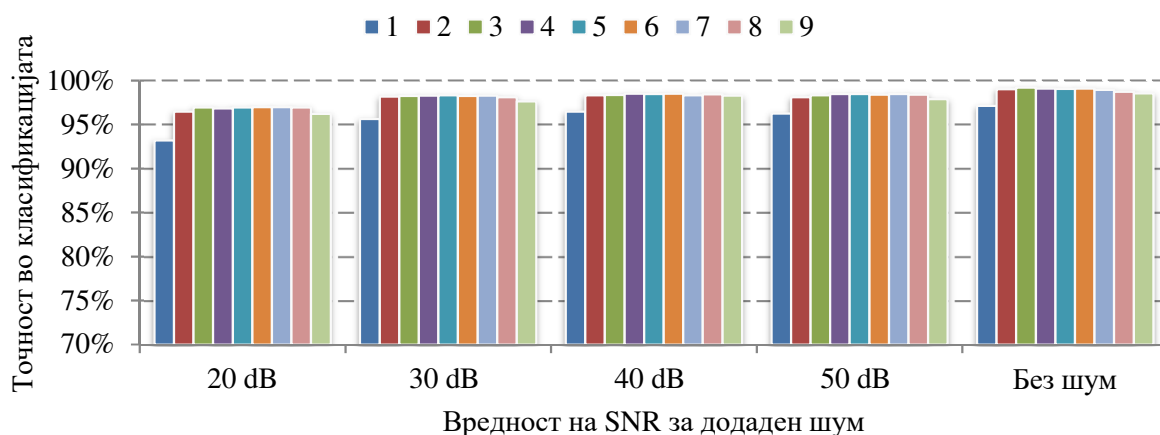
5.1.2 Со примена на DT алгоритам

Во Табела 5-4 и на Слика 5-2 презентирани се резултатите добиени при примена на DT класификаторот. Критериумот за поделба е “ентропија” за сите дрва, додека нивото на кастреење е одбрано за секое дрво одделно со помош на вкрстена валидација.

Во согласност со презентираните резултати, оптимална комбинација на карактеристики кога се употребува DT класификаторот и кога се прави класификација на 7 класи е комбинацијата на две карактеристики, на пример Шенонова ентропија и ентропија на логаритамска енергија (“f5, f8”).

Табела 5-4. Резултати добиени при примена на DT алгоритам за класификација во случај на 7 класи на нарушувања

Бр.	20 dB		30 dB		40 dB		50 dB		Без шум	
	f	(%)	f	(%)	f	(%)	f	(%)	f	(%)
1	5	93.21	5	95.63	5	96.47	5	96.26	5	97.11
2	5,8	96.47	5,8	98.17	5,8	98.33	5,8	98.10	5,8	99.01
3	5,7,8	96.93	1,5,8	98.24	1,5,8	98.37	1,5,8	98.34	5,6,8	99.21
4	2,4,5,8	96.83	1,3,5,8	98.29	3,5,7,8	98.50	3,5,7,8	98.46	2,4,5,8	99.10
5	5,6,7,8,9	96.96	1,2,3,5,8	98.33	2,3,5,7,8	98.47	1,4,5,6,8	98.47	4,5,6,8,9	99.07
6	2,4,5,7,8,9	97.00	1,2,3,5,7,8	98.26	1,2,3,5,7,8	98.50	1,3,5,7,8,9	98.41	2,4,5,6,8,9	99.10
7	2,4,5,6,7,8,9	97.00	1,2,3,5,7,8,9	98.31	1,2,4,5,6,8,9	98.34	1,2,3,5,7,8,9	98.46	1,2,4,5,6,8,9	98.96
8	2,3,4,5,6,7,8,9	96.96	1,2,3,4,5,6,8,9	98.11	1,2,3,4,5,6,7,8	98.44	1,2,3,5,6,7,8,9	98.41	1,2,4,5,6,7,8,9	98.74
9	СИТЕ	96.21	СИТЕ	97.64	СИТЕ	98.30	СИТЕ	97.89	СИТЕ	98.54



Слика 5-2. Резултати добиени при примена на DT алгоритам за класификација во случај на 7 класи на нарушувања

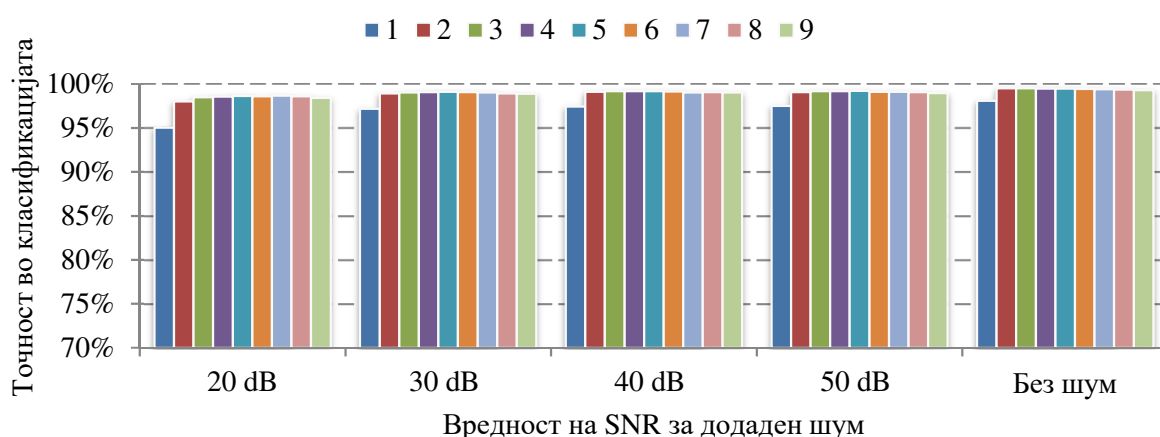
5.1.3 Со примена на RF алгоритам

Во Табела 5-5 и на Слика 5-3 прикажани се едни од највисоките проценти на точност при примена на RF алгоритмот за класификација. Моделот е формиран со bagging постапка, со 100 дрва на одлучување во шумата.

Од презентираниите резултати може да се воочи дека процентите на точност во класификацијата кои ги даваат комбинациите на две и три карактеристики се речиси еднакви освен за SNR од 20 dB каде комбинацијата на три карактеристики дава малку повисок процент на точност. Согласно со тоа, во случај на 7 класи и примена на RF алгоритмот може да заклучи дека комбинацијата на карактеристиките Шенонова ентропија и ентропија на логаритамска енергија (“f5, f8”) претставува оптимална комбинација.

Табела 5-5. Резултати добиени при примена на RF алгоритам за класификација во случај на 7 класи на нарушувања

Бр.	20 dB		30 dB		40 dB		50 dB		Без шум	
	f	(%)	f	(%)	f	(%)	f	(%)	f	(%)
1	5	95.01	5	97.16	5	97.44	5	97.51	8	98.07
2	5,8	98.01	5,8	98.91	5,8	99.09	5,8	99.07	1,8	99.50
3	5,7,8	98.49	3,5,8	99.04	3,5,8	99.19	3,5,8	99.16	1,7,8	99.51
4	5,6,7,8	98.57	3,5,8,9	99.07	3,5,8,9	99.19	3,5,8,9	99.17	1,5,6,8	99.47
5	3,5,6,7,8	98.63	2,3,5,8,9	99.09	3,5,6,8,9	99.19	3,5,6,8,9	99.20	1,2,5,6,8	99.46
6	2,3,5,7,8,9	98.60	2,3,5,6,8,9	99.06	2,3,5,6,8,9	99.14	2,3,5,6,8,9	99.10	1,3,5,7,8,9	99.44
7	2,3,4,5,7,8,9	98.66	1,2,3,5,6,7,8	99.03	2,3,4,5,7,8,9	99.04	2,3,5,6,7,8,9	99.11	1,2,3,5,6,7,8	99.40
8	2,3,4,5,6,7,8,9	98.59	1,2,3,5,6,7,8,9	98.93	1,2,3,5,6,7,8,9	99.07	1,2,3,5,6,7,8,9	99.06	1,2,3,5,6,7,8,9	99.36
9	СИТЕ	98.40	СИТЕ	98.87	СИТЕ	99.04	СИТЕ	98.97	СИТЕ	99.30



Слика 5-3. Резултати добиени при примена на RF алгоритам за класификација во случај на 7 класи на нарушувања

5.2 Избор на оптимална комбинација на вејвлет-базирани карактеристики за 11 класи на нарушувања


Пристапот за избор на оптимален алгоритам за извлекување на карактеристики за 11 класи на еднократни и повеќекратни нарушувања на напонските сигнали е идентичен со оној за 7 класи. Исто така идентична е и конфигурацијата на соодветните класификатори. Тука се применуваат сите класи кои се дадени во Табела 5-1.

5.2.1 Со примена на SVM алгоритам

Во Табела 5-6 и на Слика 5-4 прикажани се резултатите добиени при примена на SVM алгоритмот за класификација.

Табела 5-6. Резултати добиени при примена на SVM алгоритам за класификација во случај на 11 класи на нарушувања

Бр.	20 dB		30 dB		40 dB		50 dB		Без шум	
	f	(%)	f	(%)	f	(%)	f	(%)	f	(%)
1	1	77.18	1	84.36	1	86.09	5	85.76	5	94.85
2	1,5	84.15	1,5	89.21	1,5	91.85	5,7	92.49	5,8	97.24
3	1,5,9	85.12	1,5,9	90.35	1,5,9	92.65	1,5,7	94.04	5,7,8	97.99
4	1,4,5,9	85.12	1,4,5,9	90.34	1,5,7,8	92.88	1,5,7,9	94.91	1,5,7,8	98.13
5	1,4,5,7,9	85.39	1,4,5,7,8	90.48	1,4,5,7,8	92.79	1,5,6,7,9	94.64	1,4,5,7,8	98.09
6	1,2,5,6,7,9	85.55	1,3,4,5,6,9	90.47	1,2,5,6,7,9	93.00	1,4,5,6,7,9	94.75	1,3,4,5,7,8	98.12
7	1,3,4,5,6,7,9	85.51	1,3,4,5,6,7,9	90.56	1,2,3,5,7,8,9	93.58	1,2,3,4,5,6,7	94.56	1,2,3,5,7,8,9	98.12
8	1,2,3,4,5,6,7,9	85.54	1,2,3,4,5,6,7,9	90.59	1,2,3,4,5,6,7,9	93.32	1,2,3,4,5,6,7,9	94.91	1,3,4,5,6,7,8,9	98.04
9	СИТЕ	83.30	СИТЕ	90.63	СИТЕ	93.19	СИТЕ	93.98	СИТЕ	98.11



Слика 5-4. Резултати добиени при примена на SVM алгоритам за класификација во случај на 11 класи на нарушувања

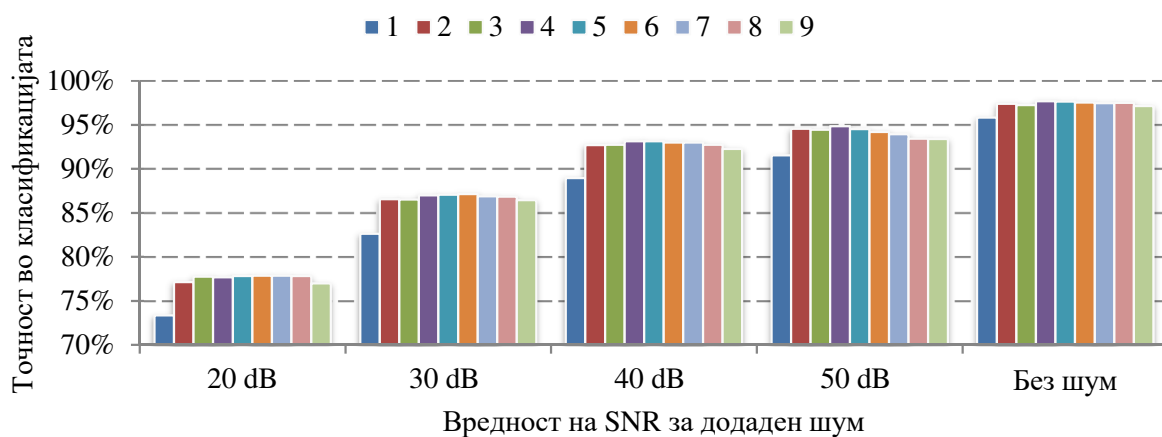
Од презентираниите резултати може да се воочи дека комбинацијата на три карактеристики дава за околу 1% повисока точност од комбинацијата составена од две карактеристики. Во согласност со тоа може да се каже дека во случај на SVM алгоритам и 11 класи оптимална е комбинацијата составена од три вејвлет-базирани карактеристики, на пример “f1,f5,f7”, “f1,f5,f9” или “f5,f7,f8”.

5.2.2 Со примена на DT алгоритам

Во наредната Табела 5-7 презентирани се едни од највисоките проценти на точност добиени за DT класификаторот. Истите се прикажани на Слика 5-5.

Табела 5-7. Резултати добиени при примена на DT алгоритам за класификација во случај на 11 класи на нарушувања

Бр.	20 dB		30 dB		40 dB		50 dB		Без шум	
	f	(%)	f	(%)	f	(%)	f	(%)	f	(%)
1	5	73.35	5	82.64	5	88.96	5	91.55	5	95.82
2	5,7	77.15	5,7	86.54	5,7	91.66	5,8	94.58	1,8	97.40
3	5,7,9	77.75	5,7,9	86.51	3,4,5	92.76	5,7,8	94.45	5,7,8	97.25
4	3,5,6,7	77.69	1,3,7,9	86.98	3,5,8,9	93.13	2,5,7,8	94.85	5,6,8,9	97.70
5	3,4,5,7,9	77.83	1,3,5,6,7	87.07	3,5,6,8,9	93.15	4,5,7,8,9	94.54	1,5,6,8,9	97.66
6	2,3,4,5,6,7	77.86	1,3,5,6,7,9	87.15	1,2,4,6,8,9	92.99	2,4,5,6,7,8	94.21	1,2,4,6,8,9	97.54
7	1,2,3,4,5,7,9	77.86	1,2,3,5,6,7,8	86.87	2,3,4,5,6,8,9	92.99	2,4,5,6,7,8,9	93.95	1,2,3,4,6,8,9	97.49
8	1,2,3,4,5,6,7,9	77.83	1,2,3,4,5,6,7,9	86.86	1,2,3,4,5,6,7,9	92.75	1,2,3,4,5,6,7,8	93.45	1,2,3,4,5,6,8,9	97.51
9	СИТЕ	76.98	СИТЕ	86.45	СИТЕ	92.28	СИТЕ	93.40	СИТЕ	97.15



Слика 5-5. Резултати добиени при примена на DT алгоритам за класификација во случај на 11 класи на нарушувања

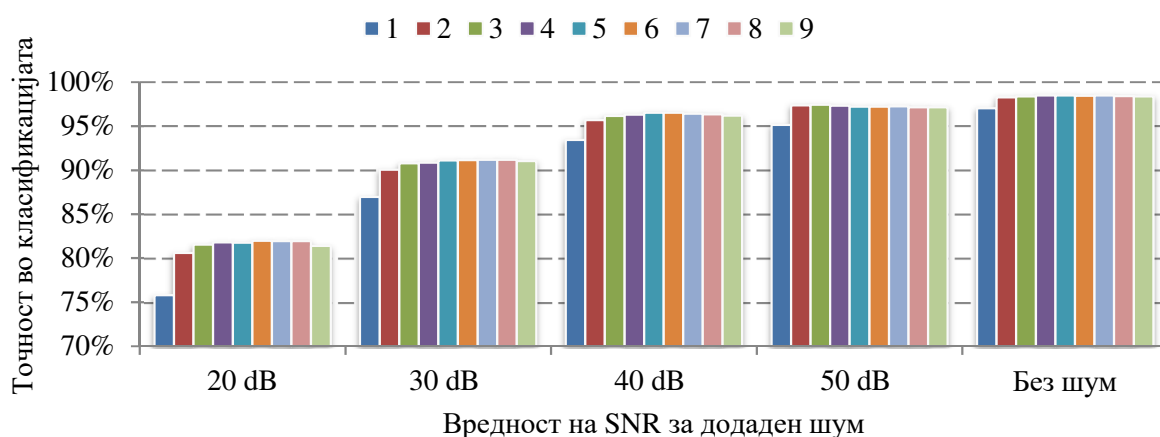
Во овој случај од презентираниите резултати може да се забележи дека комбинацијата на две карактеристики некогаш дава повисок процент на точност од онаа на три карактеристики. Според тоа комбинацијата на две карактеристики, на пример “f5, f7”, или на три карактеристики, на пример “f5, f7, f8” или “f5, f7, f9”, претставува оптимална комбинација за DT алгоритмот за класификација во случај на 11 класи на нарушувања на напонските сигнали.

5.2.3 Со примена на RF алгоритам

Исто како и за претходните алгоритми на класификација, во Табела 5-8 и на Слика 5-6 прикажани се резултатите за RF класификаторот.

Табела 5-8. Резултати добиени при примена на RF алгоритам за класификација во случај на 11 класи на нарушувања

Бр.	20 dB		30 dB		40 dB		50 dB		Без шум	
	f	(%)	f	(%)	f	(%)	f	(%)	f	(%)
1	1	75.78	1	86.96	5	93.46	5	95.15	5	97.06
2	5,7	80.58	5,7	90.06	5,8	95.69	5,8	97.36	5,8	98.30
3	3,5,7	81.55	3,5,7	90.80	3,5,7	96.17	5,7,8	97.43	5,7,8	98.38
4	3,5,7,9	81.79	3,5,7,9	90.85	2,5,7,8	96.33	2,5,7,8	97.32	2,5,6,8	98.49
5	1,5,7,8,9	81.76	3,5,6,7,8	91.13	1,2,5,7,8	96.53	3,5,6,7,8	97.21	1,5,6,7,8	98.50
6	1,2,3,5,7,8	81.99	1,2,3,4,5,7	91.15	2,3,4,5,7,8	96.54	2,3,4,5,7,8	97.24	2,3,6,7,8,9	98.48
7	1,2,3,5,6,7,8	81.93	1,2,3,5,6,7,8	91.20	2,3,4,5,6,7,8	96.43	2,3,4,5,6,7,8	97.25	1,3,5,6,7,8,9	98.50
8	1,3,4,5,6,7,8,9	81.94	1,2,3,4,5,7,8,9	91.17	1,2,3,4,5,6,7,8	96.35	1,2,4,5,6,7,8,9	97.17	1,2,4,5,6,7,8,9	98.43
9	СИТЕ	81.39	СИТЕ	91.03	СИТЕ	96.20	СИТЕ	97.15	СИТЕ	98.38



Слика 5-6. Резултати добиени при примена на RF алгоритам за класификација во случај на 11 класи на нарушувања

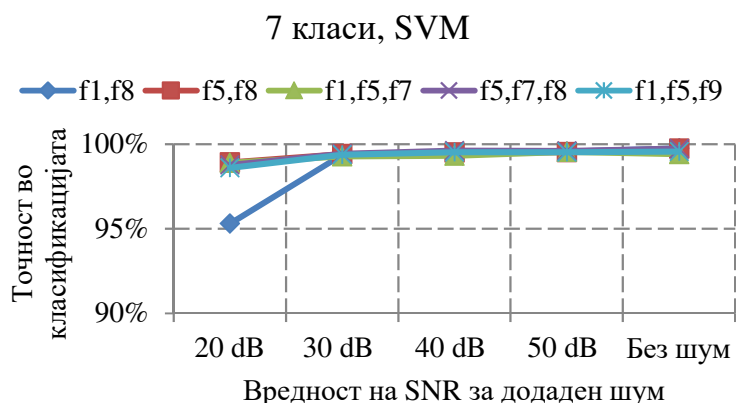
Од прикажаните резултати е воочливо дека разликата во процентот на точност помеѓу комбинациите од две или три карактеристики е мала. Сепак, во општ случај може да се каже комбинацијата од три вејвлет базирани карактеристики, на пример “f3, f5, f7” или “f5, f7, f8” претставува оптимална комбинација.

5.3 Споредба на резултатите и избор на генерален оптимален алгоритам за извлекување на карактеристики


Во претходните потточки на делот 5.2 беа презентирани резултатите од ефективноста на вејвлет базирани карактеристики и нивните комбинации брз точноста на класификацијата во случај на три различни класификатори, различни вредности на SNR за додаден шум, и 7 и 11 класи на еднократни повеќекратни нарушувања. Целта на наредната споредба е да се избере оптимален алгоритам за извлекување на карактеристики кој ќе важи за различен број на класи и различни вредности на SNR. Споредбата е направена преку графичко прикажување на точностите во класификацијата добиени за избраните оптимални комбинации на вејвлет базирани карактеристики за сите три типа на алгоритми за класификација. На Слика 5-7 и Слика 5-8, прикажани се резултатите за SVM алгоритмот, во случај на 7 и 11 класи соодветно. На Слика 5-9 и Слика 5-10 прикажани се резултатите за DT алгоритмот за класификација, во случај на 7 и 11 класи. И на Слика 5-11 и Слика 5-12 прикажани се резултатите добиени при примена на RF алгоритмите, повторно за 7 и 11 класи.

Во согласност со прикажаните резултати, најмалку бројна и најчеста комбинација е комбинацијата од две вејвлет базирани карактеристики “f5,f8”. Истата, освен за SVM и 11 класи, дава речиси највисок процент на точност во споредба со другите комбинации за сите вредности на SNR. Според тоа, оваа комбинација претставува оптимална комбинација која ќе се применува за истражувањата во Глава 6. Сепак тука треба да се напомене дека доколку се очекува повисоко ниво на шум во сигналите како и во случај на зголемен број на класи кои учествуваат во процесот на класификација, комбинацијата од три вејвлет-базирани карактеристики “f5, f7, f8” претставува подобар избор.


Од добиените резултати може да се забележи дека најнефективните вејвлет-базирани карактеристики се оние кои се засноваат на ентропија [65]. Ентропијата, како што беше и претходно споменато, претставува инваријантна статистика од повисок ред. Често е употребувана во теоријата на информации и во областа на обработка на сигнали. Дава важни информации при анализата на нестационарни сигнали. Ја карактеризира неизвесноста во изворот на информации, што е карактеристично за нарушените напонски сигнали, и таа особина ја прави најнефективна вејвлет-базирана карактеристика.




Слика 5-7. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на SVM алгоритам за класификација во случај на 7 класи




Слика 5-8. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на SVM алгоритам за класификација во случај на 11 класи




Слика 5-9. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на DT алгоритам за класификација во случај на 7 класи



Слика 5-10. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на DT алгоритам за класификација во случај на 11 класи



Слика 5-11. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на RF алгоритам за класификација во случај на 7 класи



Слика 5-12. Избор на оптимална комбинација на вејвлет базирани карактеристики при примена на RF алгоритам за класификација во случај на 11 класи


Глава 6

Избор на најсоодветен алгоритам за класификација


По изборот на оптимална комбинација на вејвлет-базирани карактеристики, следниот чекор е избор на оптимален број на сигнали за обучување на секој од алгоритмите за класификација, како и избор на најсоодветен класификатор. За истражувањето на влијанието на бројот на сигнали за обучување применети се десет различни множества, каде има од 200 до 2000 сигнали од секоја класа, со чекор од 200 сигнали. Истражувањето е направено за различни вредности на SNR за додадениот шум во сигналите, за 7 и 11 класи на еднократни и повеќекратни нарушувања, во случај на три различни класификатори. Освен што на тој начин ќе се одреди најсоодветниот број на сигнали за обучување, резултатите ќе овозможат и избор на најсоодветниот класификатор.

6.1 Класификација на 7 класи на нарушувања на напонските сигнали


Процентите на точност во класификација за 7 класи на нарушувања, кога се применети SVM, DT и RF алгоритмите се прикажани на Слика 6-1, Слика 6-2 и Слика 6-3, соодветно.



Слика 6-1. Резултати добиени за 7 класи на нарушувања при примена на SVM алгоритам за класификација



Слика 6-2. Резултати добиени за 7 класи на нарушувања при примена на DT алгоритам за класификација




Слика 6-3. Резултати добиени за 7 класи на нарушувања при примена на RF алгоритам за класификација


Бројот на сигнали применети за обучување на алгоритмот за класификација како што влијае врз точноста на алгоритмот исто така влијае и на неговата комплексност. Согласно со тоа, соодветно научениот класификатор би требало да достигнува максимална точност, што може да се постигне за дадениот вектор на карактеристики, а притоа бројот на сигнали за учење да е што е можно помал. Во согласност со овој компромис помеѓу точноста и комплексноста, евидентно е дека 1000 сигнали по класа е оптималниот број за обучување на SVM, DT и RF класификаторите во случај на 7 класи на нарушувања на напонските сигнали.

6.2 Класификација на 11 класи на нарушувања на напонските сигнали


На Слика 6-4, Слика 6-5 и Слика 6-6 презентирани се резултатите добиени од истражувањето во случај на 11 класи на еднократни и повеќекратни нарушувања.



Слика 6-4. Резултати добиени за 11 класи на нарушувања при примена на SVM алгоритам за класификација



Слика 6-5. Резултати добиени за 11 класи на нарушувања при примена на DT алгоритам за класификација



Слика 6-6. Резултати добиени за 11 класи на нарушувања при примена на RF алгоритам за класификација


Од прикажаните резултати воочливо е дека за SVM класификаторот 400 сигнали по класа е оптимален број на сигнали за обучување. За број на сигнали поголем од 400 има значителни варијации во процентот на точност како што тој број се менува.

Според резултатите, за DT класификаторот број од 1400 сигнали за учење по класа дава речиси највисок процент на точност за секоја од вредностите на SNR.


Заклучокот за RF алгоритмот за класификација е ни помалку ни повеќе еднаков со оној за 7 класи на нарушувања, 1000 сигнали по класа е оптимален број на сигнали за обучување на класификаторот. Од прикажаните слики исто така е евидентно дека RF класификаторот овозможува најстабилни резултати, споредено со другите класификатори. Имено, нема значајни промени во процентот на точност на класификацијата како што бројот на сигнали се менува, без разлика дали сигналите се без шум или пак пропратени со бел Гаусов шум.

6.3 Споредба на резултатите и избор на најсоодветен алгоритам за класификација

Со цел појасно да се воочи разликата во влијанието на бројот на сигнали за обучување врз алгоритмот за класификација, како и да се одбере најсоодветен класификатор, направени се дополнителни споредби на добиените резултати. Споредбите на резултатите за 7 и 11 класи на нарушувања прикажани се на Слика 6-7 и Слика 6-8, соодветно.



Слика 6-7. Избор на оптимален алгоритам за класификација во случај на 7 класи



Слика 6-8. Избор на оптимален алгоритам за класификација во случај на 11 класи

Како што може да се забележи од сликите, за 7 класи на нарушувања на напонските сигнали во најголемиот дел од случаите процентот на точност на RF класификаторот е повисок од оној на DT класификаторот, а е малку понизок од процентот на точност на SVM алгоритмот за класификација. За 11 класи RF резултира со највисок процент на точност во класификација. И покрај фактот дека оптималниот број на сигнали за SVM е 400, процентот на точност за вредности на SNR од 30 dB, 40 dB и 50 dB е значајно понизок од процентот на точност во класификацијата на RF класификаторот. Во согласност со тоа, и како резултат на фактот дека RF има најстабилни резултати и за 7 и за 11 класи на нарушувања, може да се заклучи дека RF алгоритмот за класификација, обучен со 1000 сигнали по класа, претставува оптимален алгоритам за класификација и истиот ќе се применува во останатите истражувања кои се дел од оваа докторска дисертација.

6.4 Верификација на точноста во класификација на избраниот алгоритам за извлекување на карактеристики и избраниот класификатор

Верификацијата е направена за комбинацијата f1, f8, која беше избрана како оптимална. Доколку за оваа комбинација се потврди висок процент на точност, тогаш може да кажеме дека точноста во класификацијата за f5, f7, f8 е со сигурност потврдена.

За целта на верификацијата на предложените алгоритми, во MATLAB се генерирани две множества на различни напонски сигнали согласно со математичките дефиниции презентирани во делот 4.4. Во истиот дел беше наведена и постапката за случаен избор на вредностите на параметрите, со цел да се постигне разновидност помеѓу сигналите. За генерирањето употребени се исти опсеци на параметрите како оние во трудовите со чии резултати ќе биде направена споредба. Тоа ја прави споредбата веродостојна.

Во првото множество се разгледуваат 7 класи на нарушувања, вклучувајќи го и случајот кога во напонскиот сигнал не е присутно нарушување. Во Табела 6-1 дадени се соодветните класи заедно со нивните ознаки

Табела 6-1. 7 класи на нарушувања на напонот и нивните ознаки

Нарушување	Ознака за класа
Номинален напон	C1
Скок	C2
Пропад	C3
Хармоници	C4
Прекин	C5
Пропад + Хармоници	C6
Скок + Хармоници	C7

Секој сигнал се состои од 10 периоди, за основна фреквенција од 50 Hz и фреквенција на одбирање на примероци од 12.8 kHz. На тој начин секој сигнал содржи 2560 примероци. Обучувањето на RF класификаторот е направено со 200 сигнали од секоја класа. Во Табела 6-2 презентирани се резултатите добиени со алгоритмите од овој труд и алгоритмите предложени во литературата.

Табела 6-2. Споредба на предложените алгоритми за извлекување на карактеристики и класификација во случај на 7 класи со алгоритми предложени во литературата

Класа	Реф. [59]	Реф. [58]	Реф. [57]	Овој труд
C1	100	100	100	100
C2	97	100	96.5	94.5
C3	76.5	87	88	100
C4	100	100	100	99
C5	90	80.5	85.5	100
C6	71.5	97	100	99
C7	98	100	100	100
Вкупно	90.4	94.93	95.71	98.93

Од презентираниите резултати може да се забележи дека перформансот на алгоритмите предложени во овој труд го надминува перформансот на референцираните алгоритми.

Второто множество на нарушени напонски сигнали се состои од 10 класи на нарушувања презентирани во Табела 6-3.

Табела 6-3. 11 класи на нарушувања и нивните ознаки

Нарушување	Ознака за класа
Напонски пропад	V1
Скок	V2
Прекин	V3
Осцилаторна преодна појава	V4
Хармоници	V5
Пропад + Хармоници	V6
Скок + Хармоници	V7
Засек	V8
Шилец	V9
Фликер	V10

Секој сигнал се состои од 10 периоди, за основна фреквенција од 50 Hz и фреквенција на одбирање на примероци од 3.2 kHz. Согласно со тоа секој сигнал содржи 640 примероци. Во Табела 6-4 дадени се резултатите од процентот на точност во

класификацијата (%CA) и стапката на погрешно класифицирани класи (%MC) на алгоритмите предложени во овој труд, и алгоритмите предложени во [60], за сигнали без шум, додека во Табела 6-5 и Табела 6-6 за сигнали пропратени со бел Гаусов шум за SNR од 20 dB и 30 dB, соодветно.

Табела 6-4. Споредба на предложените алгоритми од овој труд во случај на 10 класи без шум со алгоритми предложени во литературата

	Класа	Реф. [60]		Овој труд
		SVM	DT	
MC (%)	V1	0	0	0.07
	V2	0	0	0.01
	V3	1.48	0	0.07
	V4	0	0	0.01
	V5	0	1.28	0
	V6	0.04	0	0.02
	V7	1.71	0.08	0.02
	V8	1.02	0.46	0.03
	V9	3.11	0	0.06
	V10	2.33	1.76	0
%CA	Вкупно	88.52	96.67	99.08


Табела 6-5. Споредба на предложените алгоритми од овој труд во случај на 10 класи и SNR од 20 dB со алгоритми предложени во литературата

	Класа	Реф. [60]		Овој труд
		SVM	DT	
MC (%)	V1	0	0	0.18
	V2	13.92	1.16	0.12
	V3	10.48	2.32	0.11
	V4	0	2.19	0.03
	V5	26.41	1.28	0.02
	V6	0.04	0	0.05
	V7	10.74	6.08	0.03
	V8	6.91	3.46	0.26
	V9	11.11	2.3	0.22
	V10	23.33	1.76	0.19
%CA	Вкупно	81.52	89.95	95.89

Табела 6-6. Споредба на предложените алгоритми од овој труд во случај на 10 класи и SNR од 30 dB шум со алгоритми предложени во литературата

	Класа	Реф. [60]		Овој труд
		SVM	DT	
MC (%)	V1	2.1	0	0.11
	V2	2.52	0.63	0.04
	V3	1.7	0	0.08
	V4	0.1	2.53	0.05
	V5	6.21	1.45	0
	V6	0	0	0.05
	V7	1.03	0.04	0.01
	V8	4.53	3.12	0.1
	V9	2.31	2.19	0.15
	V10	4.12	0	0.08
% CA	Вкупно	84.03	91.81	98.03

Со цел подобро да се воочи разликата во процентите на точност во класификацијата кои ги дава нашиот комплетен алгоритам (алгоритмот за извлекување на карактеристики заедно со алгоритмот за класификација) и алгоритмите предложени во литературата истите се прикажани и графички на Слика 6-9.



Слика 6-9. Графички приказ на резултатите добиени од споредбата на комплетниот алгоритам предложен во овој труд и алгоритмите предложени во реф. [60]

Од прикажаната слика може да се заклучи дека алгоритмите предложени во овој труд имаат повисок процент на точност во класификацијата и пониска стапка на погрешно препознаени класи.

Со презентираниите резултати се верифицира точноста и оптималноста на предложените алгоритми. Во согласност со тоа истите ќе бидат применети во останатите истражувања кои се дел од оваа докторска дисертација.

Глава 7

Имплементација на оптимизиран класификатор за детекција и класификација на нарушувањата на напонските сигнали во реално време

Квалитетот на напонските сигнали е од големо значење за веродостојноста на електроенергетската мрежа. Оттука следи дека континуираното мониторирање на напонот на одбрани локации во мрежата, вклучувајќи процесирање на измерените сигнали и детекција и класификација на нарушувањата во реално време, е потребно за соодветна проценка на неговиот квалитет. Проценката ќе овозможи навремена реакција за санирање на причините кои доведуваат до нарушувања на квалитетот. Тоа ќе придонесе до стабилен и безбеден електроенергетски систем. За да се овозможи децентрализирана детекција и класификација во реално време потребни се алгоритми со ниска комплексност и висока точност, што беше и целта на истражувањата кои беа презентирани во претходните глави од овој труд.

Голем број истражувања од оваа област се насочени кон автоматска класификација само во случај на еднократни нарушувања [66]-[70]. Но тоа не е типичен случај бидејќи многу често во делот од сигналот опфатен од прозорецот за анализа присутни се повеќекратни нарушувања. Тие предизвикуваат тешкотии во процесот на идентификација што се должи на присутноста на карактеристики од различни нарушувања. Тоа бара повнимателно пред-процесирање и посложена класификација, бидејќи постои можност за погрешна пресметка на карактеристиките, грешна евалуација и ниска точност во класификацијата [71]. Согласно со тоа, предложени се различни алгоритми за класификација каде се земаат во предвид и комбинации од две, три, па и повеќе нарушувања. На пример алгоритмите за класификација презентирани во [38], [55], [57]-[61] и [72]-[77] земаат во предвид класи кои се комбинација од две нарушувања. Во [78] предложен е алгоритам за класификација каде во предвид се земаат класи кои се комбинација од три нарушувања.

Во оваа глава од трудот ќе биде презентирана имплементација во реално време на оптимизиран класификатор за детекција и класификација на нарушувања на напонските сигнали. За развојот на класификаторот употребена е LabVIEW околина, додека имплементацијата во реално време е направена на NI MyRIO-1900. Класификаторот има можност за препознавање на 21 класа на еднократни и повеќекратни нарушувања, каде

класи добиени како комбинација од четири нарушувања се земени во предвид. За развој на класификаторот, најпрво беше развиена негова прототип верзија презентирани во [79].

7.1 Имплементација на оптимален алгоритам за извлекување на карактеристики во LabVIEW

По многуте истражувања презентирани во Глава 5 се покажа дека комбинацијата на две вејвлет базирани карактеристики Шенонова ентропија и ентропија на логаритамска енергија претставува оптимална комбинација која дава висока точност во детекцијата и во класификацијата на нарушувањата. Но беше кажано дека доколку е потребно да се класифицираат поголем број на класи или доколку се очекува повисоко ниво на шум, тогаш е препорачливо да се употреби комбинација на три вејвлет базирани карактеристики, Шенонова ентропија, куртозис и ентропија на логаритамска енергија. Бидејќи класификаторот ќе биде наменет за класификација на 21 класа на нарушувања, ќе биде применета комбинацијата на три карактеристики. Математичките равенки кои ги дефинираа овие карактеристики се:

$$SE_i = - \sum_{j=1}^N C_{ij}^2 \log(C_{ij}^2) \quad (7.1)$$

$$KRT_i = \sqrt{\frac{N}{24} \left(\frac{1}{N} \sum_j \left(\frac{C_{ij} - \mu_i}{\sigma_i} \right)^4 - 3 \right)} \quad (7.2)$$

$$LOE_i = \sum_{j=1}^N \log(C_{ij}^2) \quad (7.3)$$

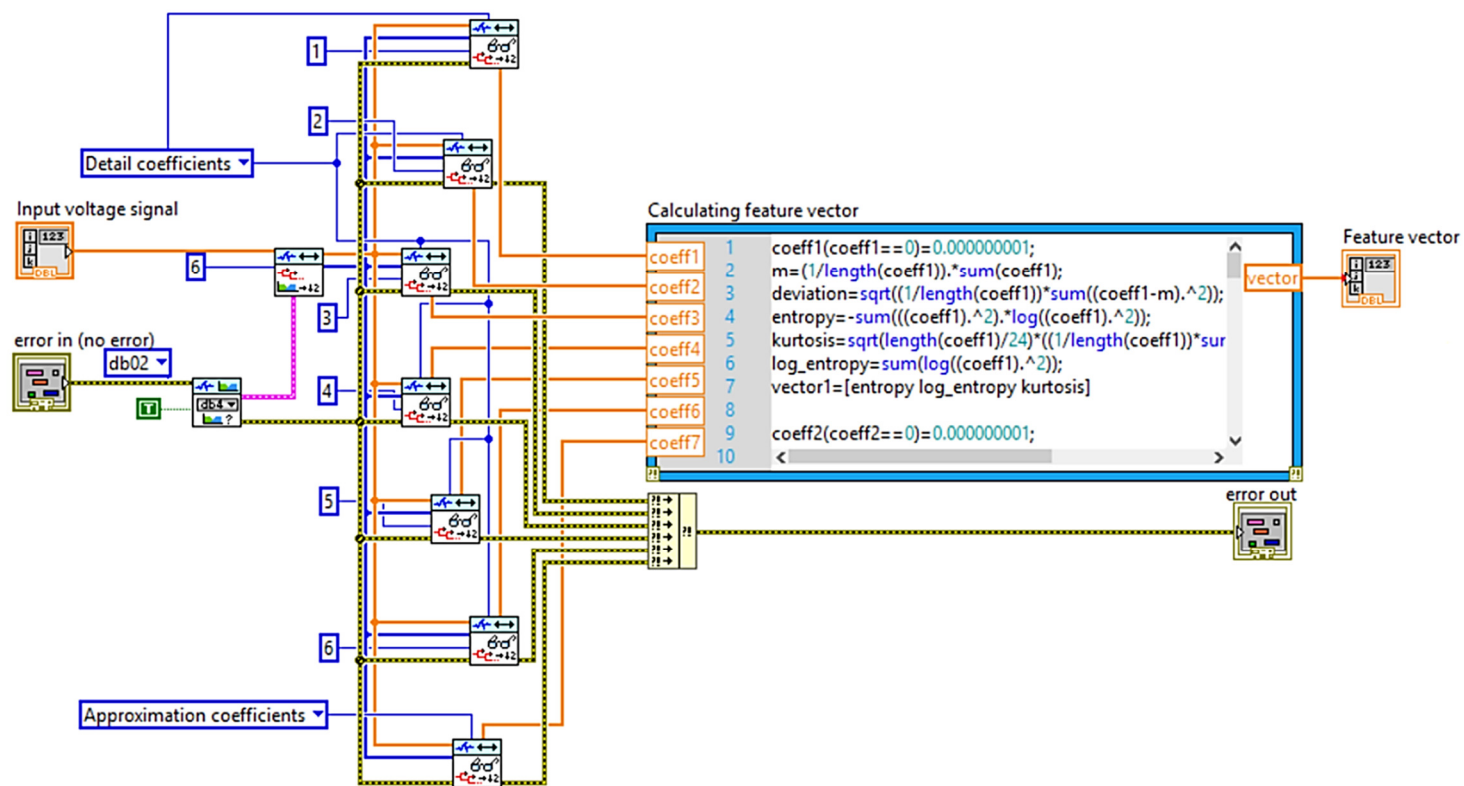
каде како што беше кажано

$$\mu_i = \frac{1}{N} \sum_{j=1}^N C_{ij} \quad (7.4)$$

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (C_{ij} - \mu_{ij})^2} \quad (7.5)$$

претставуваат средна вредност и стандардна девијација соодветно. Како и во сите претходни истражувања, во имплементацијата е избрано бројот на нивоа на декомпозиција на DWT да биде $l = 6$, а како матичен вејвлет “Daubechies 2” со четири коефициенти.

Блок дијаграмот на имплементацијата во LabVIEW е прикажан на Слика 7-1.



Слика 7-1. Блок дијаграм за имплементација на предложениот алгоритам за извлекување на карактеристики во LabVIEW

Истата е реализирана со примена на алатките за напредно процесирање на сигнали (Advanced Signal Processing Toolkit.) Овие алатки овозможуваат извршување на кодот на хардвер во реално време, што е и главната цел на имплементацијата. Како што беше напоменато добиените вејвлет коефициенти се употребуваат за пресметка на вејвлет базираните карактеристики. Во оваа имплементација, карактеристиките се пресметуваат со помош на јазли наречени “MathScript Node”, чиј што код исто така може да се извршува хардвер за работа во реално време.

7.2 Имплементација на оптимизиран алгоритам за класификација во LabVIEW

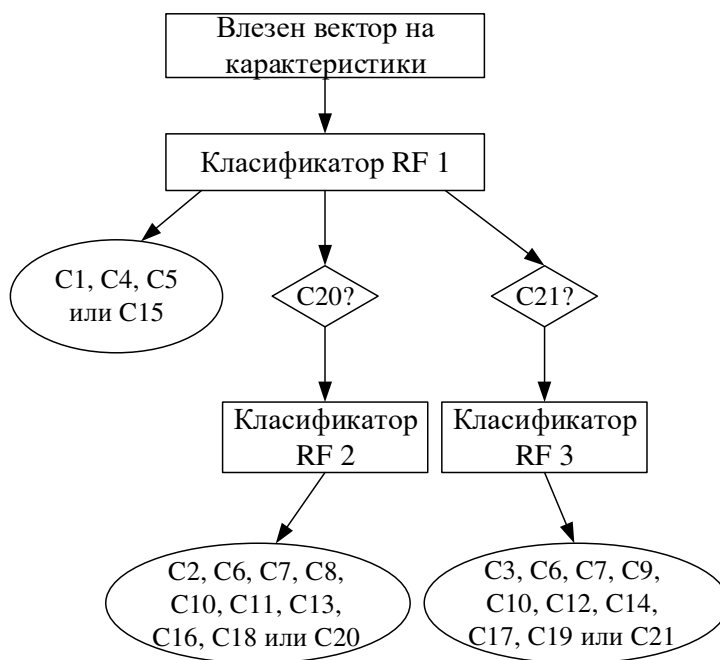
Резултатите од истражувањата кои беа презентирани во Глава 6 покажаа дека RF алгоритмот претставува најсоодветен алгоритам кој се одликува со висок процент на точност во класификацијата и добро се справува со различно ниво на шум. Согласно со тоа, за имплементацијата во реално време употребен е овој алгоритам за класификација. За обучување и тестирање на алгоритмот, применети се 21 класа на еднократни и повеќекратни нарушувања, кои заедно со нивните ознаки се презентирани во Табела 7-1.

Табела 7-1. 21 нарушувања на напонските сигнали и нивните ознаки

Нарушувања на напонот	Ознаки за класа
Номинален напон	C1
Пропад	C2
Скок	C3
Прекин	C4
Импулсивна преодна појава/ Шилец	C5
Осцилаторна преодна појава	C6
Хармоници	C7
Хармоници + Пропад	C8
Хармоници + Скок	C9
Фликер	C10
Фликер + Пропад	C11
Фликер + Скок	C12
Пропад + Осцилаторна преодна појава	C13
Скок + Осцилаторна преодна појава	C14
Засек	C15
Хармоници + Пропад + Фликер	C16
Хармоници + Скок + Фликер	C17
Хармоници + Проп + Осцилаторна преодна појава	C18
Хармоници + Скок + Осцилаторна преодна појава	C19
Хармоници + Пропад + Фликер + Осцилаторна преодна појава	C20
Хармоници + Скок + Фликер + Осцилаторна преодна појава	C21

Од секоја класа се генерирани по 1000 напонски сигнали, со помош на генераторот презентирани во [80]. Фреквенцијата на земање на примероци за секој од сигналите е 3.2 kHz и во секој сигнал се вклучени 10 циклуси. Основната фреквенција е 50 Hz.

Како резултат на големиот број на класи, алгоритмот за класификација има потреба од голем број дрва на одлучување. Колку што бројот на дрва е поголем, толку точноста на класификаторот е повисока. Но од друга страна, додавањето на голем број дрва може да го успори процесот на учење и да ја зголеми комплексноста на класификаторот, што не е во прилог на имплементацијата во реално време. Согласно со тоа, потребно е да се направи баланс помеѓу точноста и комплексноста на класификаторот со цел истиот да работи во реално време. Истото може лесно да се постигне доколку алгоритмот за класификација се состои од неколку RF класификатори учени на помал број класи. Согласно со тоа, во оваа имплементација, алгоритмот за класификација се базира на три помалку комплексни RF класификатори. Предложениот алгоритам за класификација може да класифицира 21 класа на еднократни и повеќекратни нарушувања. Дијаграмот на тек на алгоритмот е прикажан на Слика 7-2.



Слика 7-2. Дијаграм на тек на предложениот алгоритам за класификација

Како што може да се забележи од дијаграмот, класификаторот RF1 е обучен за препознавање на шест класи на нарушувања, додека RF2 и RF3 се обучени за препознавање на 10 класи на нарушувања. Доколку најгласана класа од дрвата за одлучување во RF1 е класата C20, тогаш векторот на карактеристики се проследува кон класификаторот RF2, доколку најгласана класа е класата C21 тогаш векторот се

проследува кон RF3, инаку најгласана класа е некоја од класите C1, C4, C5 или C15 и процесот на класификација завршува.


Како што беше истакнато и претходно, постојат различни параметри на RF алгоритмот кои директно влијаат врз неговата моќ за предвидување и го олеснуваат процесот на обучување. Такви се: Број на предвидувачи или дрва на одлучување, максималната длабочина на секое дрво, максималниот број на карактеристики кои учествуваат во процесот на формирање на дрво, минималниот број на примероци за гранење, минималниот број на примероци по лист, критериум за поделба, итн. Поради тоа, со цел да се предвиди најсоодветната вредност или пак типот за одреден параметар, направено е подесување на хипер-параметрите со алгоритам за оптимизација.

7.2.1 Оптимизација на алгоритмот за класификација

Оптимизацијата на параметрите на алгоритмот за класификација се смета за најчувствителен дел во развојот на модел за машинско учење. Речиси и е невозможно да се предвидат оптималните параметри на моделот во процесот на неговиот развој. Тоа е причината поради која истражувачот си игра со параметрите на моделот, со цел да ги оптимизира. Оптимизацијата на параметрите е заснована повеќе на експериментални резултати отколку на теорија, и поради тоа најдобриот начин да се одредат оптималните подесувања на моделот е да се пробаат различни комбинации и да се испита перформансот за секоја од нив.

Алгоритмот базиран на пребарување низ мрежа од параметри претставува традиционален начин за извршување на таква оптимизација. Подразбира сеопфатно пребарување низ мануелно специфицирано множество од параметри на алгоритмот за машинско учење. Овој алгоритам мора да биде воден од некоја мерка за неговиот перформанс, а тоа најчесто е вкрстена-валидација на множеството за учење [81]. Бидејќи просторот на параметри може да вклучи и параметри кои може да имаат и неограничени вредности, потребна е дискретизација и мануелно поставување на граници пред да се примени алгоритмот. Овој алгоритам се соочува со големи димензии, но често се извршува паралелно [82].

Првиот чекор во оптимизацијата е да се испита важноста на секоја карактеристика употребена во процесот на класификација. Доколку важноста на некоја карактеристика е многу мала во споредба со другите карактеристики, или еднаква на нула, тогаш таа карактеристика може да се занемари. За таа цел на Слика 7-3 прикажан е графикот на релативна важност наспроти вејвлет-базирана карактеристика. Бројот кој стои до соодветната ознака на карактеристиката го претставува нивото на декомпозиција од кое е добиена карактеристиката, додека “approx” се однесува на карактеристиката добиена од коефициентите за апроксимација.

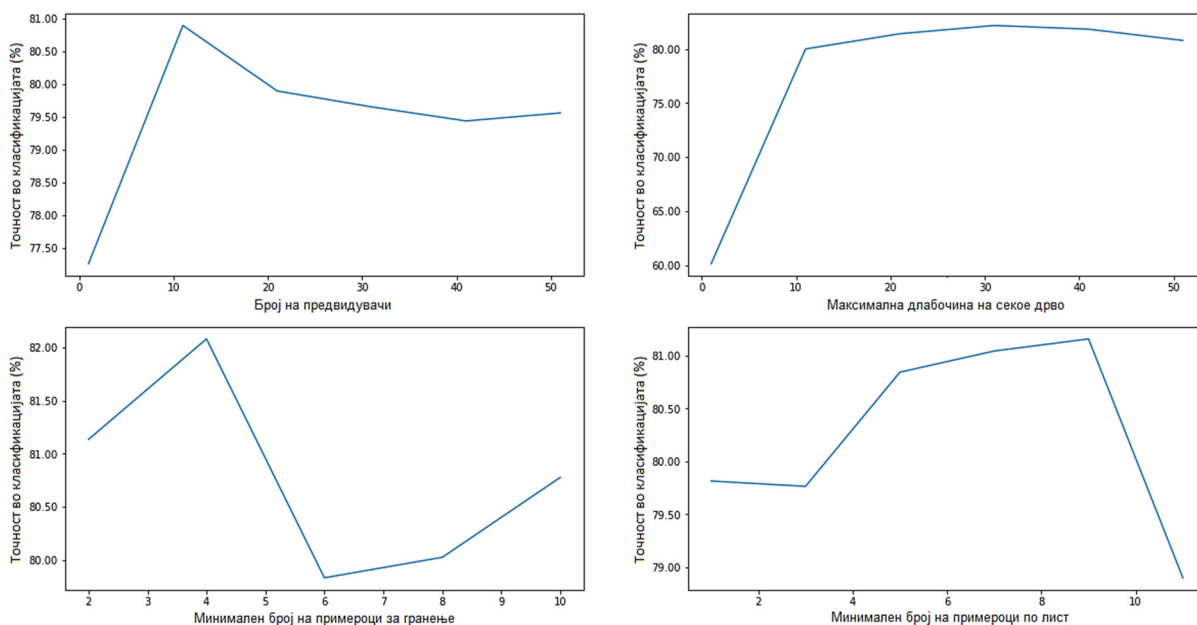


Слика 7-3. Вејвлет базирани карактеристики наспроти нивната релативна важност во класификацијата

Од графикот може да се забележи дека нема значителни разлики во важноста на карактеристиките врз класификацијата. Од таа причина сите карактеристики учествуваат во понатамошниот процес на оптимизација.

Нареден чекор е примена на алгоритмот за класификација. Бидејќи алгоритмот се состои од три посебни класификатори, потребно е да се направи оптимизација на параметрите за секој класификатор одделно. Четири од параметрите кои го дефинираат RF алгоритмот може да имаат широк опсег на вредности. Тоа се бројот на предвидувачи или дрва во шумата, минимален број на примероци за гранење, максимална длабочина на секое дрво и минимален број на примероци по лист. Со цел да се намали времето кое му е потребно на алгоритмот за оптимизација да ги одреди оптималните вредности за овие параметри, најпрво графички е претставен соодносот помеѓу процентот на точност во класификација и нивната вредност. Графичкиот приказ за RF1 алгоритмот за класификација за сите четири параметри е прикажан на Слика 7-4.

Од графиците може да се одреди опсег на вредности за секој параметар. На пример вредноста на максималната длабочина на секое дрво во шумата расте помеѓу 0 и 30, а потоа опаѓа. Согласно со тоа пребарувањето низ мрежата за овој параметар е ограничено во опсегот помеѓу 10 и 30 дрва. Минималниот број на примероци по лист расте помеѓу 3 и 9 примероци. Оттука. За овој параметар е одбран тој опсег на вредности. Слични одлуки се направени и за останатите параметри со цел да се стеснат опсезите на нивните вредности.



Слика 7-4. Одбирање на соодветен опсег на вредности за дел од параметрите на RF1 алгоритмот за класификација

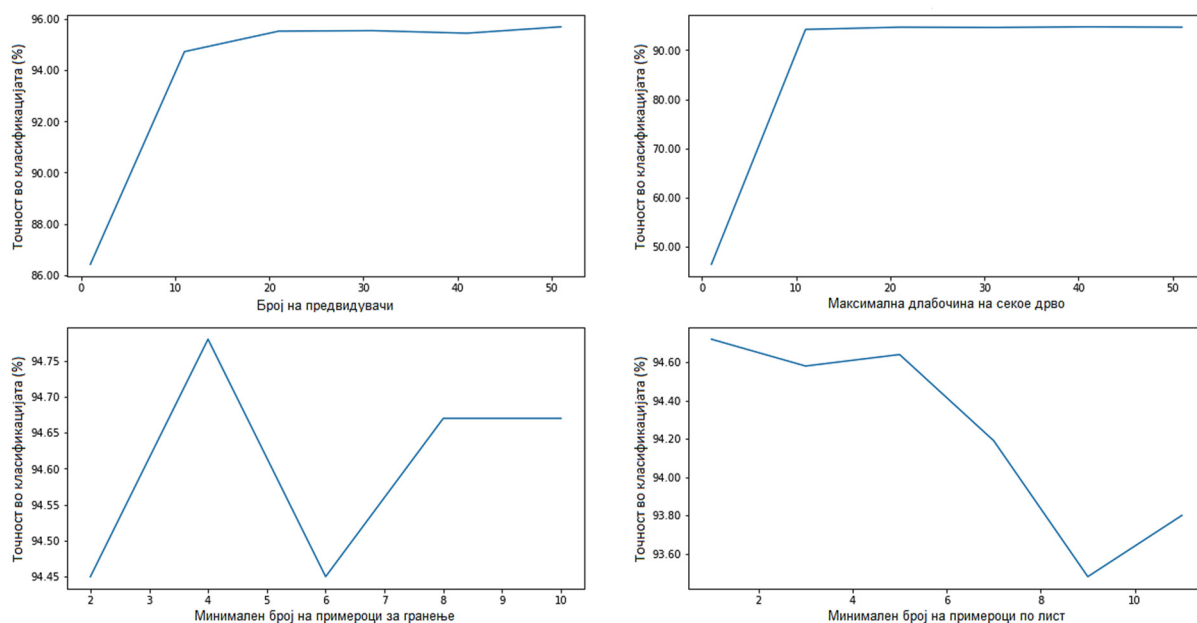
Дополнително на параметрите чии што графици се дадени, во процесот на оптимизација вклучени се уште два други параметри, а тоа се типот на критериумот за поделба и максималниот број на карактеристики кои учествуваат во избор на критериумот за поделба. Овие параметри немаат широки опсези на вредности и поради тоа нема потреба графички да се разгледуваат. Влезните параметри на RF1 алгоритмот добиени со процесот на оптимизација се прикажани во Табела 7-2. Истите се употребени за конфигурирање на крајниот алгоритам за класификација.

Табела 7-2. Оптимален избор за влезните параметри на RF1 алгоритмот за класификација

Параметри на RF1 алгоритмот за класификација	Оптимален избор
n_estimators (број на естиматори)	10
max_features (максимален број на карактеристики)	'log2'
max_depth (максимална длабочина)	18
criterion (критериум за поделба)	'entropy'
min_samples_split (минимален број на примероци по поделок)	4
min_samples_leaf (минимален број на примероци по лист)	7

Истата постапка на оптимизација е направена и за останатите два класификатори, RF2 и RF3. Оптимизацијата за двата класификатори е идентична бидејќи во процесот на

класификација учествуваат ист број на класи. Резултатите добиени за соодносот помеѓу процентот на точност во класификација и вредноста на четирите параметри се прикажани на Слика 7-5. Врз основа на стеснетите опсези на нивните вредности и примената на процесот на оптимизација, добиени се оптимални вредности кои се презентирани во Табела 7-3.



Слика 7-5. Одбирање на соодветен опсег на вредности за дел од параметрите на RF2 и RF3 алгоритмите за класификација

Табела 7-3. Оптимален избор за влезните параметри на RF2 и RF3 алгоритмите за класификација

Параметри на RF1 и RF2 класификаторите	Оптимален избор
n_estimators (број на естиматори)	10
max_features (максимален број на карактеристики)	'log2'
max_depth (максимална длабочина)	22
criterion (критериум за поделба)	'entropy'
min_samples_split (минимален број на примероци по поделок)	4
min_samples_leaf (минимален број на примероци по лист)	2

Со оптимално нагодување на параметрите согласно двете табели развиен е оптимизиран класификатор за класификација на 21 класа на нарушувања.

7.2.2 Тестирање на оптимизираниот класификатор

За целите на тестирањето на класификаторот применети се сигнали генерирани во MATLAB со помош на истиот генератор со кој беа генерирани и сигналите за обучување.

Најпрво, тестирана е точноста во класификацијата посебно за секој од трите класификатори. Направено е тестирање и споредба на резултатите помеѓу два различни типа на множества. Едното множество го сочинуваат сигнали кои имаат еднаква почетна фаза, додека пак другото го сочинуваат сигнали со различни почетни фази. Применетото фазно поместување е случајно и може да биде која било вредност помеѓу $-\pi$ и π радијани. Во реалните системи секогаш постои присуство на шум. Согласно со тоа, истите сигнали се синтетизирани со еднакво распределен бел Гаусов шум за вредности на SNR од 40~50 dB и 30~50 dB. Освен процентот на точност, за целите на споредбата и воочување на влијанието на оптимизацијата, измерени се времињата на класификација на неоптимизираниот и оптимизираниот класификатор потребни за извршување на класификација на еден сигнал. Резултатите добиени за класификаторот RF1 се презентирани во Табела 7-4.

Табела 7-4. Резултати добиени за тестирање на точноста во класификацијата и времето за класифицирање на класификаторот RF1.

Сигнали	Без оптимизација		Со оптимизација	
	Без фазно поместување	Со фазно поместување	Без фазно поместување	Со фазно поместување
Без шум	88.89%	88.47%	88.81%	88.22%
40~50 dB	88.12%	86.53%	87.52%	85.74%
30~50 dB	86.17%	84.32%	86.11%	83.45%
Време на извршување во Python	≈ 39,86 ms		≈ 3.09 ms	

Од добиените резултати може да се забележи дека во случај кога напонските сигнали имаат еднакви почетни фази, точноста во класификацијата е повисока отколку во случај кога почетните фази се разликуваат. Тоа се должи на фактот дека поместените фази воведуваат висок степен на случајност во сигналите. Со намалување на вредноста на SNR за додадениот шум во сигналите исто така се намалува точноста во класификацијата. Доколку пак резултатите се погледнат од страна на оптимизацијата, може да се забележи дека таа ја намалува точноста во класификацијата за помалку од 1%. Тоа е резултат на бројот на дрва на одлучување кои го сочинуваат RF класификаторот. Неоптимизираниот алгоритам се состои од 100 дрва, и тоа е оној алгоритам кој го предлага самиот Python. Во теоретскиот дел за алгоритамот на случајна шума беше напоменато дека бројот на дрва ја зголемува точноста, но истовремено и комплексноста на класификаторот. Тоа може да се заклучи и од измереното време на класификација во Python. Времето кое му

е потребно на оптимизираниот класификатор, кој се состои од десет дрва, да направи класификација на даден сигнал е десет пати пократко од времето кое му е потребно на неоптимизираниот класификатор, што може да влијае врз неговата имплементација во реално време.

Во Табела 7-5 и Табела 7-6 презентирани се резултатите добиени од тестирањето на точноста во класификацијата и времето на процесот на класификација за RF2 и RF3 соодветно.

Табела 7-5. Резултати добиени за тестирање на точноста во класификацијата на класификаторот RF2

Сигнали	Без оптимизација		Со оптимизација	
	Без фазно поместување	Со фазно поместување	Без фазно поместување	Со фазно поместување
Без шум	96.88%	95.72%	96.84%	95.25%
40~50 dB	92.52%	90.17%	92.16%	89.86%
30~50 dB	89.07%	86.09%	88.24%	85.33%
Време на извршување во Python	≈ 15.68 ms		≈ 0.59 ms	

Табела 7-6. Резултати добиени за тестирање на точноста во класификацијата на класификаторот RF3

Сигнали	Без оптимизација		Со оптимизација	
	Без фазно поместување	Со фазно поместување	Без фазно поместување	Со фазно поместување
Без шум	97.07%	96.01%	96.74%	95.62%
40~50 dB	93.19%	91.34%	92.6%	90.98%
30~50 dB	89.24%	87.28%	88.94%	86.39%
Време на извршување во Python	≈ 15.85 ms		≈ 0.61 ms	

Евидентно е дека во случај на овие два класификатори оптимизацијата го скратува времето на класификација за повеќе од 20 пати. Генерално, може да се заклучи дека применетиот алгоритам за пребарување низ мрежа го намалува времето на класификација на класификаторот како резултат на намалување на неговата комплексност. Од друга страна пак, оптимизацијата нема значително влијание врз точноста во класификацијата.

Од резултатите исто така може да се забележи дека процентот на точност во класификацијата на RF1 е помал од оние добиени за RF2 и RF3, иако RF1 е трениран за помал број на класи на нарушувања на напонските сигнали. Тоа се должи на големата

сличност помеѓу компонентите на класите C20 и C21. И двете класи содржат фликери, хармоници и осцилаторни преодни појави.

Во Табела 7-7 презентирани се резултатите од класификацијата добиени со примена на предложениот алгоритам за класификација составен од сите три класификатори.

Табела 7-7. Резултати добиени за тестирање на точноста во класификацијата на предложениот оптимизиран алгоритам за класификација

Сигнали	Без оптимизација		Со оптимизација	
	Без фазно поместување	Со фазно поместување	Без фазно поместување	Со фазно поместување
Без шум	96.68%	95.29%	96.48%	94.72%
40~50 dB	91.94%	88.57%	91.36%	87.74%
30~50 dB	87.28%	83.27%	86.78%	82.36%
Време на извршување во Python	≈ 56.68 ms		≈ 5.45 ms	

Блансот помеѓу времето на класификација и процентот на точност ја оправдува употребата на процесот за оптимизација. Тука треба да се истакне дека оптимизацијата генерално може да биде од корист и кај други алгоритми за класификација кои се применуваат во областа на квалитет на електрична енергија презентирани во литературата. Таа ќе придонесе до зголемување на нивната ефикасност.

Од презентираниите резултати повторно е воочливо дека фазното поместување помеѓу сигналите ја намалува точноста во класификацијата. Повеќето класификатори кои се предлагаат во областа на класификација на нарушувањата на електричната енергија се обучуваат на сигнали кои имаат еднаква почетна фаза, односно почнуваат од 0 радијани. Во реалните мерења, поради постојано присутните варијации во фреквенцијата, измерените сигнали често се фазно поместени еден од друг. Согласно со тоа, детекцијата на моментот кога амплитудата на сигналот ја преминува нулата значи хардверско или софтверско решение кое, доколку не се имплементира, има големо влијание врз точноста во класификација. Доколку класификаторот е учен само на сигнали кои имаат почетна фаза еднаква на нула, тогаш скоро секој сигнал кој има фаза поместена од нулата ќе биде погрешно класифициран. Бројот на погрешни класификации би бил многу помал доколку класификаторот е учен на сигнали со различни фази.

Нивото на шум присутно во мерните сигнали е случајно. Поради тоа класификаторот треба да биде обучен така да може да се справи со шум за различни вредности на SNR. Во овој случај шумот значително го намалува процентот на точност на алгоритмот за класификација, поради големиот број на класи. Како и да е, доколку погледнеме во делот од матрицата на конфузија добиена за сигнали со фазно поместување пропратени со шум за SNR од 30~50 dB и при примена на оптимизиран класификатор, презентирани во

Табела 7-8, може да се заклучи дека во случај на класи кои претставуваат комбинација од повеќе компоненти на нарушувања, барем една компонента е секогаш точно препознаена.

Табела 7-8. Дел од матрицата на конфузија добиена за сигнали кои се фазно поместени еден од друг, пропратени со шум за SNR од 30~50 dB и при примена на оптимизиран алгоритам за класификација

••	C16	C17	C18	C19	C20	C21
C1	0	0	0	0	0	0
C2	8	0	0	0	0	0
C3	0	0	0	0	0	0
C4	2	0	1	0	0	0
C5	0	0	0	0	0	0
C6	0	0	4	1	0	2
C7	4	0	6	2	6	4
C8	135	0	69	2	14	0
C9	0	106	3	103	1	18
C10	0	0	0	0	0	0
C11	17	0	0	0	1	0
C12	0	3	0	0	0	0
C13	4	0	59	0	42	0
C14	0	5	1	35	1	13
C15	0	0	4	0	0	0
C16	793	5	9	0	72	1
C17	5	812	0	17	1	114
C18	3	0	678	9	189	1
C19	0	9	11	721	2	126
C20	29	0	154	1	662	4
C21	0	60	1	109	9	720

На пример, ако се погледне бројот на сигнали од класата Хармоници + Скок + Фликер + Осцилаторна преодна појава (C21), 126 од 1000 сигнали се препознаени како Хармоници + Скок + Осцилаторна преодна појава (C19), 114 се препознаени како Хармоници + Скок + Фликер (C17), 13 се препознаени како Скок + Осцилаторна преодна појава (C14), 18 се препознаени како Хармоници + Скок (C9) итн. Како и да е, нула од сигналите се класифицирани како Хармоници + Пропад (C8), или како Пропад + Осцилаторна преодна појава (C13) или како Засек (C15). Согласно со овој заклучок, може да се каже дека предложениот алгоритам за класификација има висок процент на точност во класификацијата дури и во случај кога напонските сигнали се пропратени со бел Гаусов шум за SNR од 30~50 dB.

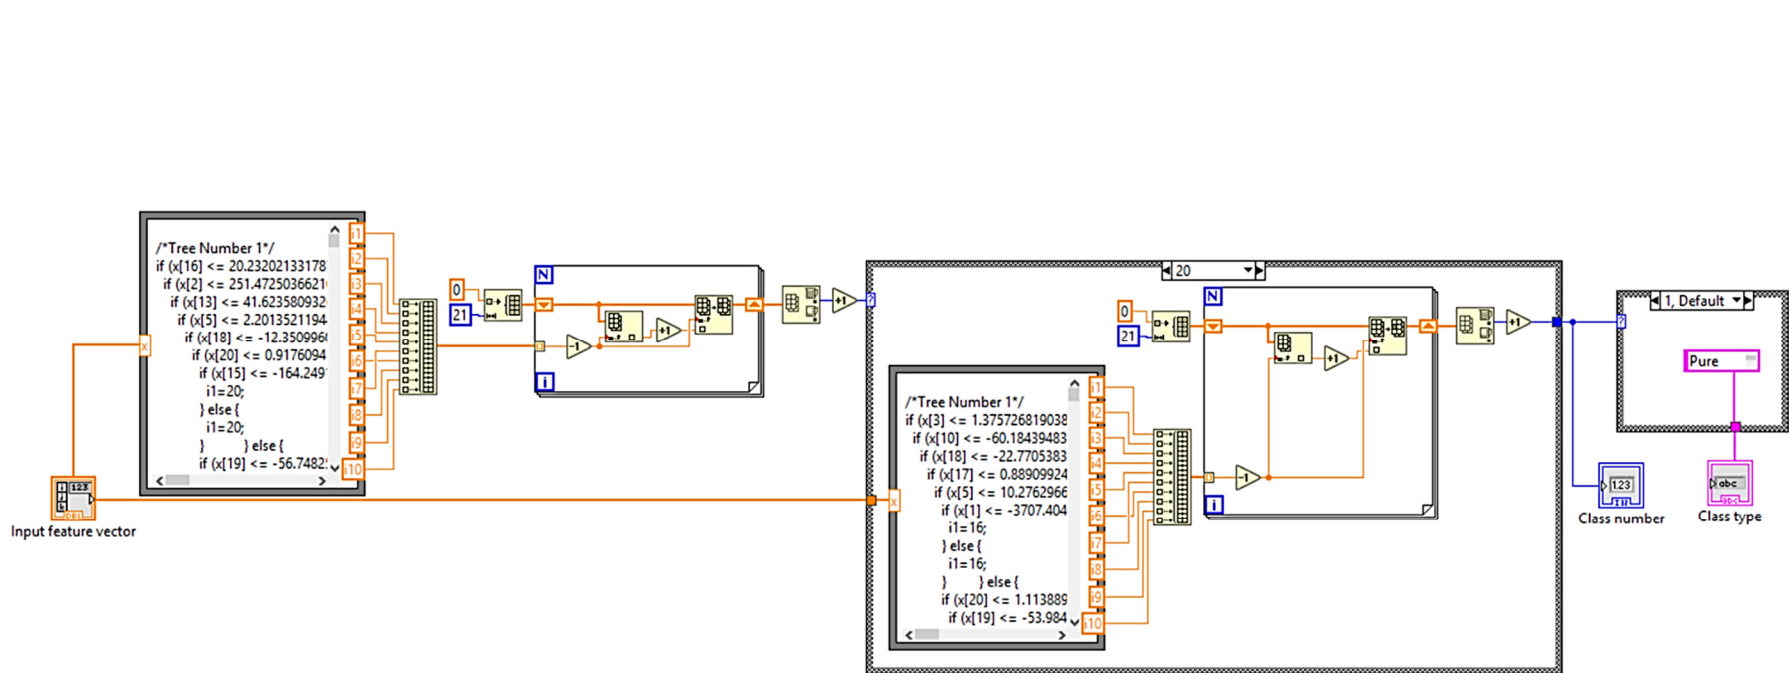
Согласно со стандардот IEEE Std 1159-1995 [28] шумот присутен во мерните сигнали има типична амплитуда од 0-1% од основната амплитуда на напонскиот сигнал. Според тоа и според направена анализа на графици на сигнали со шум за различни вредности на SNR, базирана на визуелна споредба, се покажува дека класификатор обучен на сигнали пропратени со бел Гаусов шум за SNR од 40~50 dB е соодветен да ги задоволи барањата за класификација отпорна на шум. Класификаторот обучен на сигнали пропратени со шум за вредности на SNR од 30~50 dB, може да се примени во поретки случаи.

Во насока на ефектот на оптимизација од Табела 7-7 евидентно е дека за поголем број на класи на нарушувања, оптимизацијата освен што го поедноставува моделот исто така го зголемува процентот на точност во класификацијата. Тоа овозможува имплементација на алгоритмот за класификација во реално време со висока точност.

7.2.3 Имплементација оптимизираниот класификатор во LabVIEW

Блок дијаграмот за имплементацијата на оптимизираниот класификатор во LabVIEW е прикажан на Слика 7-6. Како што може да се забележи од сликата, класификаторот е имплементиран со употреба на јазли наречени “Formula Nodes”. Множеството од правила за секое дрво на одлучување во RF класификаторот е интерпретирано од Python во C код, кој што е применет во јазлите. Кодот кој ја овозможува оваа интерпретација е даден во делот Прилог А. Левиот јазол се однесува на RF1 класификаторот. Доколку најизгласана класа од страна на овој класификатор е класата C20, тогаш соодветниот вектор на карактеристики се носи на влез од вториот јазол за класификаторот RF2. Доколку најизгласана класа од RF1 е C21 тогаш векторот на карактеристики е донесен на влезот од третиот јазол. Доколку пак најизгласана класа е некоја од преостанатите класи, тогаш таа класа е одлуката што ја донел класификаторот.

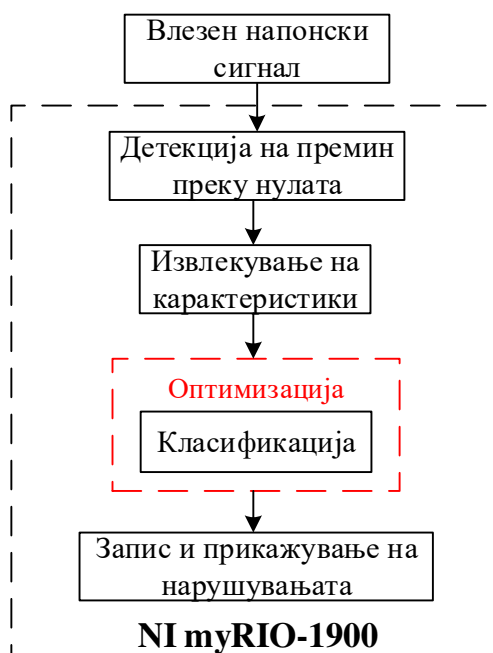
Ова е пример за имплементација на RF алгоритам за класификација за кој што не постои достапна алатка во LabVIEW. Овој начин на имплементација може да се примени и за други цели на класификацијата во други области на истражување, развој и тестирање.



Слика 7-6. Блок дијаграм за имплементација на предложениот алгоритам за класификација во LabVIEW

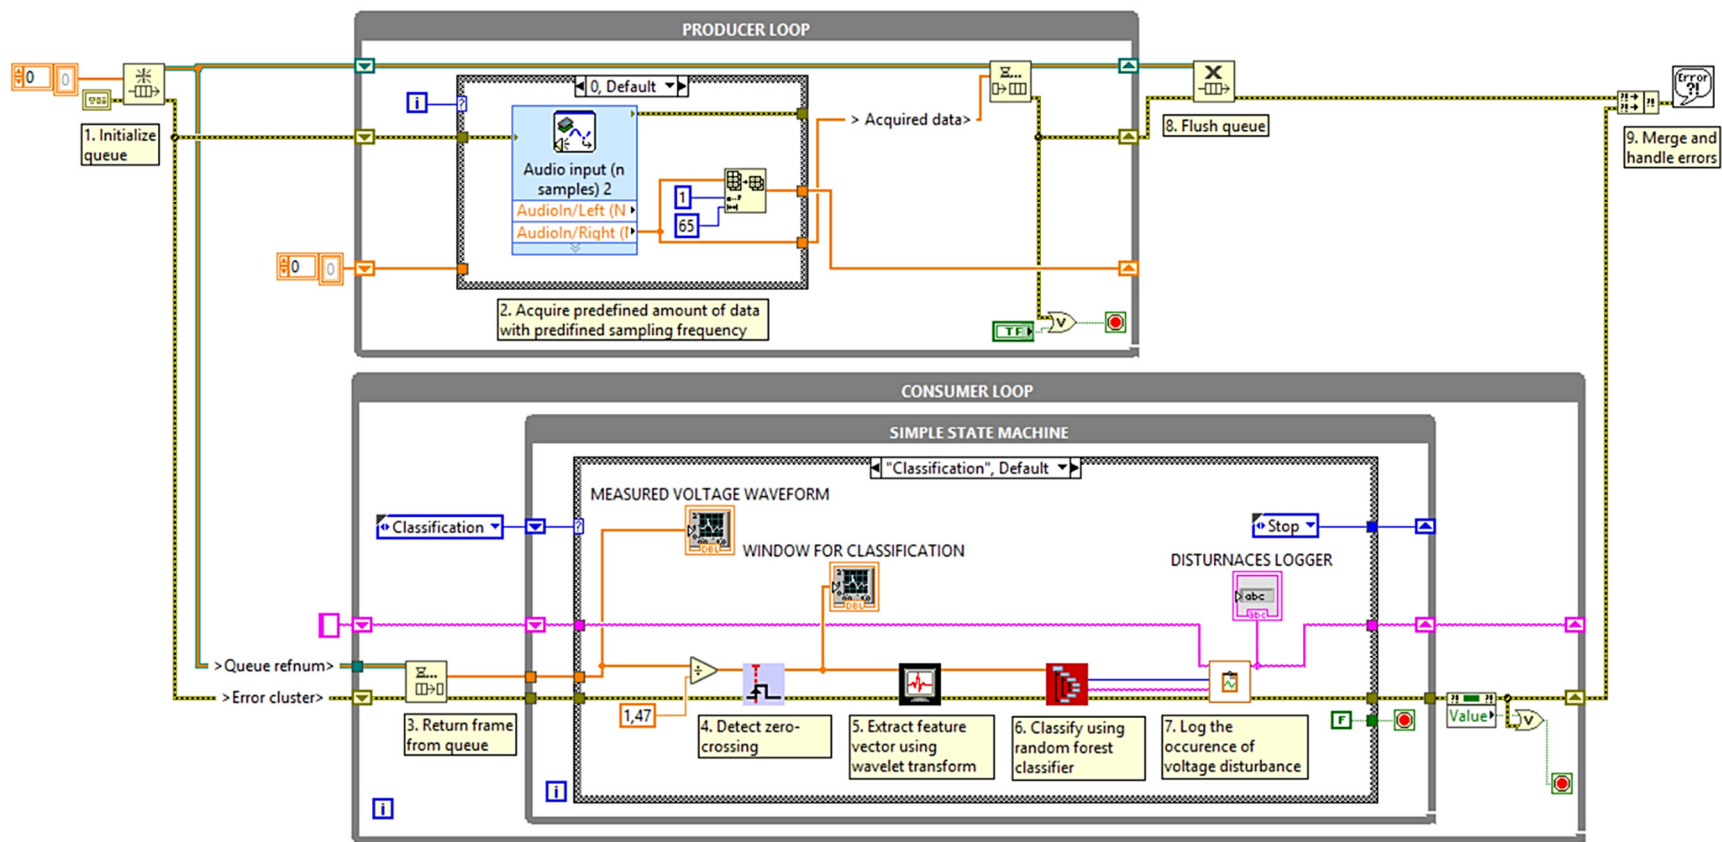
7.3 Систем за класификација на нарушувањата на напонските сигнали во реално време

Блок-дијаграмот на имплементацијата на системот во LabVIEW е даден на Слика 7-7. Може да се забележи дека имплементацијата се состои од четири чекори. Некои од нив беа претходно објаснети, додека останатите ќе бидат објаснети во продолжение на овој дел.



Слика 7-7. Блок-дијаграмот за имплементацијата на системот за класификација на нарушувања во напонските сигнали во реално време

Имплементацијата е направена на NI myRIO-1900 [83]. Се заснова на програмската архитектура производител-потрошувач, прикажана на Слика 7-8. Оваа архитектура е пример за синхронизација помеѓу два процеси, кои делат заеднички бафер со фиксна големина. Во оваа имплементација, улогата на производителот е прибирање на напонски сигнали со фреквенција на земање примероци од 3.2 kHz. Потрошувачот ги добива податоците од производителот, по една рамка во единица време со должина од 640 примероци. Ваквата архитектура дава сигурност дека производителот нема да проба да додаде нови податоци во баферот додека тој е полн и потрошувачот нема да проба да превземе податоци од празен бафер.



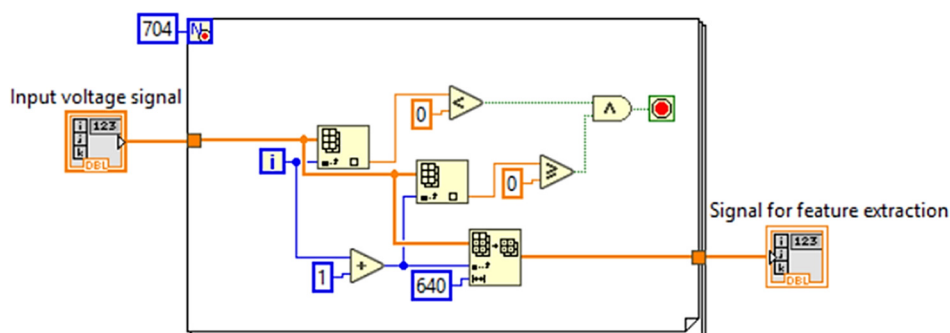
Слика 7-8. Блок дијаграм за реализација на предложената имплементација во LabVIEW и на NI MyRIO-1900

Во овој случај, производителот претставува едноставна машина на состојби, со две состојби именувани како “classification” и “stop calculation and wait for producer data.” Детекцијата на премин преку нулата, извлекувањето на карактеристиките и алгоритмот за класификација се имплементирани во состојбата “classification” со, примена на подвиртуелни инструменти (SubVIs). Постои уште еден подвиртуелен инструмент во оваа состојба кој се употребува за запишување и исцртување на настанатите нарушувања на предниот панел.

7.3.1 Детекција на премин преку нулата

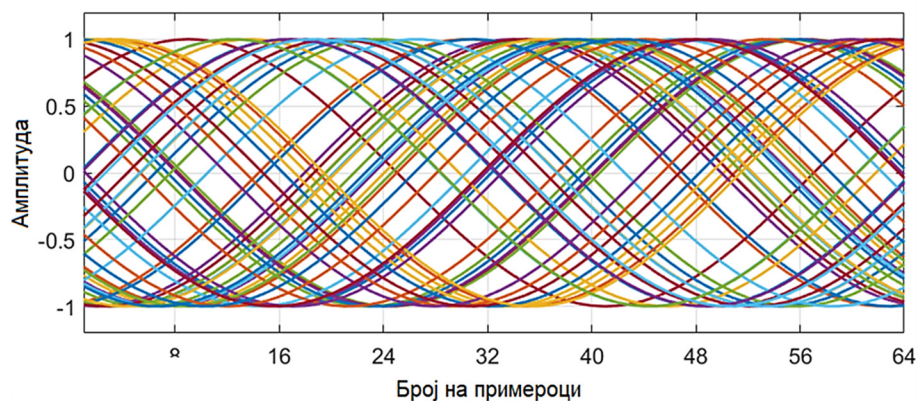
Детектирањето на моментот кога амплитудата на сигналот ја преминува нулата и почнува да расте претставува важен пред-процесирачки чекор во областа на класификација на нарушувањата на електричната енергија. Со претходно презентирани резултати се покажа дека фазното поместување значително ја намалува точноста во класификацијата како резултат на големиот степен на случајност во сигналите. Поради тоа, системот за класификација треба да биде обучен на голем број на сигнали кои би го опфатиле скоро секое можно фазно поместување и на тој начин точноста би се зголемила. Како и да е, тоа исто така ќе ја зголеми и комплексноста на алгоритмот за класификација и би можело да доведе до негова невозможна имплементација на хардвер за работа во реално време.

Друг начин да се реши овој проблем е развој на софтверско решение за детекција на премин преку нулата. Овој детектор би овозможил сите сигнали кои се донесени на влезот од процесот за извлекување на карактеристики да имаат речиси еднакви фази. Тоа ќе резултира во значително помал опсег на фазни поместувања помеѓу влезните сигнали. Колку што опсегот е помал, толку точноста во класификацијата би била поголема. Имплементација на едно такво решение во LabVIEW е прикажано на Слика 7-9.

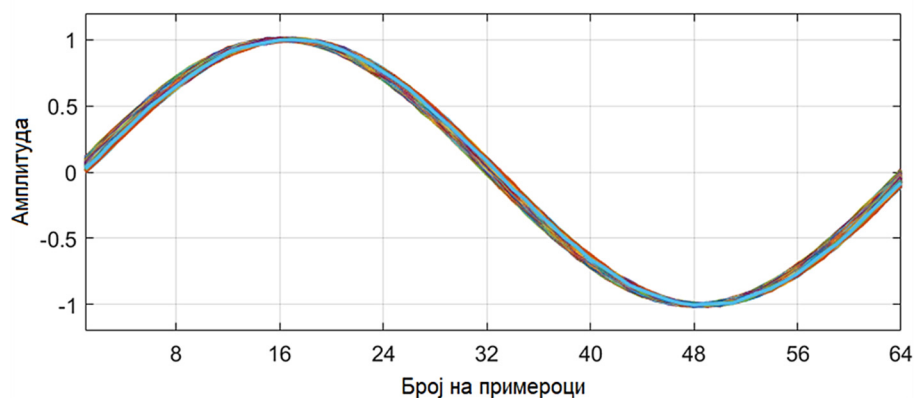


Слика 7-9. Блок дијаграм за имплементација на детектор за премин преку нулата во LabVIEW

Како што може да се заклучи од сликата, детекторот се базира на споредба на две последователни вредности од низата која го претставува влезниот сигнал. Разликата помеѓу оригиналните сигнали и оние добиени на излез од детекторот може да се воочи од Слика 7-10 и Слика 7-11, соодветно



Слика 7-10. Напонски сигнали со различни почетни фази без примена на детектор за премин преку нулата



Слика 7-11. Напонски сигнали со различни почетни фази со примена на детектор за премин преку нулата

По примената на детекторот за премин преку нулата, различноста во фазите е намалена. Оттука, применет е нов опсег на фазни поместувања за учење на класификаторот. Согласно со Слика 7-11 истиот е помеѓу $-\pi/24$ и 0 радијани. Како новиот опсег на фазни поместувања влијае врз точноста во класификацијата може да се утврди преку повторно тестирање на класификаторот. Добиените резултати се презентирани во Табела 7-9.

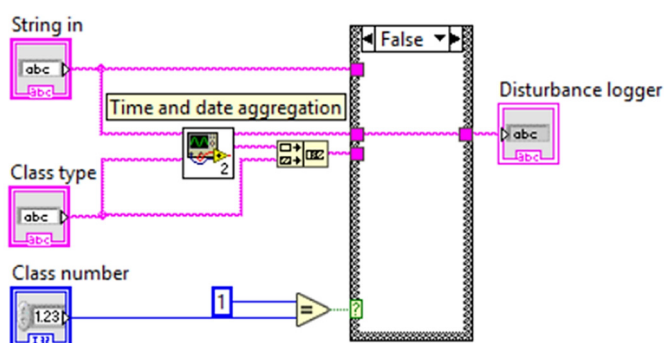
Табела 7-9. Резултати за процентот на точност во класификација за сигнали добиени по примена на детекторот за премин преку нулата

Сигнали	Фазно поместување помеѓу $-\pi$ и π радијани	Фазно поместување помеѓу $-\pi/24$ и 0 радијани
Без шум	94.72%	96.21%
40~50 dB	87.74%	90.74%
30~50 dB	82.36%	85.88%

Согласно со резултатите може да се заклучи дека новиот опсег на фазни поместувања овозможува класификација со висок процент на точност. Така учениот класификатор е подготвен за класификација на реални сигнали од реални мерења.

7.3.2 Запис и прикажување на класифицираните нарушувања

Последниот процес во состојбата “classification” е записот и прикажувањето на настанатите нарушувања во напонските сигнали. Имплементацијата на истиот е прикажана на Слика 7-12. Овој процес овозможува континуирано запишување на предниот панел на типот на настанатото нарушување како и времето и датумот кога се појавило истото.



Слика 7-12. Блок дијаграм за имплементација на запис на нарушувањата и прикажување во LabVIEW

7.3.3 Време за процесирање на имплементираниот систем

Согласно со препораките во стандардот IEC 61000-4-30 основниот мерен интервал би требало да биде 10 циклуси за основна фреквенција од 50 Hz или 12 циклуси за систем со основна фреквенција од 60 Hz, што резултира во мерен прозорец со должина од 200 ms. Оттука, производителот од претходно споменатата архитектура производител-потрошувач потребно е да прибира податоци на секои 200 ms за да може системот за класификација да работи во реално време. За да се постигне тоа, процесирачкото време на потрошувачот треба да биде помало од 200 ms.

Кога сите процеси кои овозможуваат класификација на 21 класа на нарушувања на напонските сигнали се имплементирани на процесор, потребно е да се провери дали ги исполнуваат барањата за работа во реално време. За таа цел измерено е процесирачкото време на секој процес. Добиените резултати се презентирани во Табела 7-10.

Табела 7-10. Време на процесирање на имплементацијата на системот во реално време

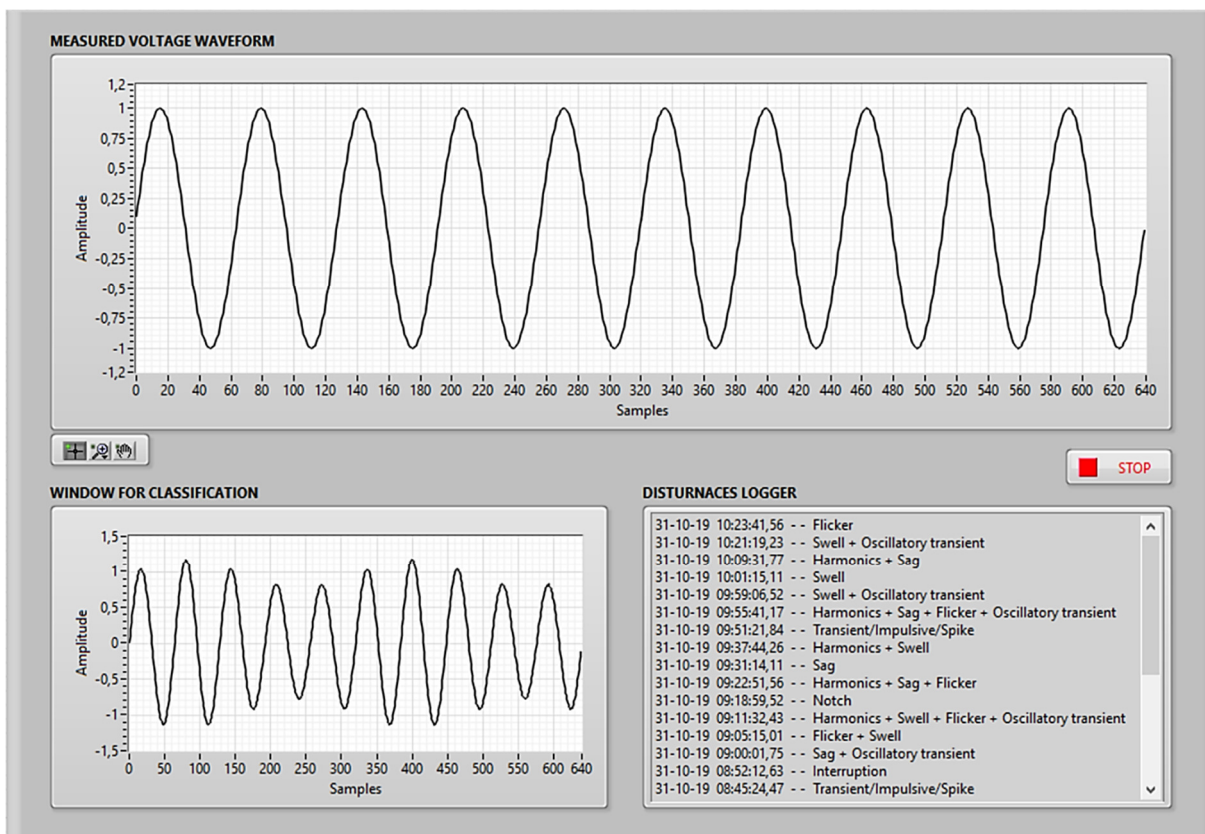
Процес	Време на процесирање [ms]
Детекција на премин преку нулата	0.24
Извлекување на карактеристики	5
Класификација	0.16
Запис и прикажување	0.14
Целосно време	5.54

Од табелата е евидентно дека вкупното време за извршување на пресметките од страна на потрошувачот е околу 5.54 ms. Тоа е значително пократко во споредба со бараните 200 ms. Оттука, предложената имплементација на оптимизиран класификатор на нарушувања на напонските сигнали ги исполнува барањата за класификација во реално време.

Направен е обид за имплементација на неоптимизираниот класификатор во реално време на NI MyRIO-1900, со цел да се направи споредба помеѓу времињата на процесирање на двете имплементации. Како резултат на комплексноста на неоптимизираниот класификатор, поточно големата количина на код вметнат во јазолот (Formula node) во LabVIEW, имплементацијата не може дури ни да се искомпајлира. Се јавува грешка дека компајлерот нема доволно меморија, и се запира процесот. Со тоа уште еднаш се докажува придобивката од процесот на оптимизација.

7.4 Преден панел на имплементацијата

Предниот панел на системот за детекција и класификација на нарушувањата на напонот во реално време е прикажан на Слика 7-13. На него континуирано се прикажува брановиот облик на напонот кој што се мери и класифицира, времето и датумот кога се појавило одредено нарушување во мерниот прозорец од напонот како и брановиот облик на нарушениот напонски сигнал.



Слика 7-13. Преден панел на системот за класификација на нарушувања на напонските сигнали во реално време

7.5 Верификација на имплементираниот систем

Имплементираниот систем е верифициран со примена на експериментален ланец прикажан на Слика 7-14.



Слика 7-14. Ланец за верификација на системот за класификација на нарушувања на напонските сигнали во реално време

Експерименталниот ланец ги репродуцира генерираните напонски сигнали како реални сигнали измерени од електроенергетската мрежа. Гледајќи од лево кон десно, ланецот се состои од виртуелен генератор на напонски сигнали презентираан во [84]. Излезот од генераторот е влез на картичка за аквизиција (DAQ) NI 6218 [85]. Картичката има аналогни излезни канали со максимален излезен напон од ± 10 V. Излезот од картичката е поврзан со влезот на засилувач презентираан во [86]. Засилувачот е наменет за засилување на напонските сигнали и со тоа овозможува нивно репродуцирање како реални сигнали. Сигналите кои се добиваат на излез од картичката не можат директно да се употребуваат за тестирање на системот за детекција и класификација на нарушувања во напонските сигнали. Истите треба да бидат засилени до номиналната вредност на напонот во електроенергетската мрежа од 230 V. Засилениот напон се носи на влезот од модулот за кондиционирање презентираан во [87]. Овој модул овозможува галванска изолација, филтрирање итн. и го прилагодува излезниот напонски сигнал со соодветни параметри. Излезот од модулот за кондиционирање, кој е во опсегот од ± 5 V, е влез на DAQ модулот на NI myRIO-1900. Излезот од DAQ модулот е влез во системот за детекција и класификација на нарушувања на напонот во реално време.

Употребувајќи го презентираниот експериментален ланец, генерирани се 20 различни нарушени напонски сигнали. Генерирањето е направено со случаен избор на вредности за параметрите на нарушувањата од дефинираните опсези. Генерираните сигнали се репродуцирани како реални и се класифицирани во реално време. Резултатите од верификацијата се презентирани во Табела 7-11.

Од резултатите може да се забележи дека 19 од 20 настани се точно класифицирани. Само класификацијата на Настан 4 е погрешна. Како и да е, сите компоненти од вистинскиот настан се препознаени. Согласно со тоа, оваа верификација докажува дека предложената имплементација е способна да работи во реално време и да врши класификација на еднократни и повеќекратни нарушувања на напонските сигнали со висока точност.

Табела 7-11. Резултати од верификацијата на системот за детекција и класификација на нарушувања во напонските сигнали

Настан	Вистинска класа	Предвидена класа
Настан 1	Фликер	Фликер
Настан 2	Хармоници + Скок	Хармоници + Скок
Настан 3	Импулсивна преодна појава/ Шилец	Импулсивна преодна појава/ Шилец
Настан 4	Хармоници + Скок + Осцилаторна преодна појава	Хармоници + Скок + Фликер + Осцилаторна преодна појава
Настан 5	Прекин	Прекин
Настан 6	Фликер + Пропад	Фликер + Пропад
Настан 7	Пропад	Пропад
Настан 8	Хармоници + Пропад + Осцилаторна преодна појава	Хармоници + Пропад + Осцилаторна преодна појава
Настан 9	Засек	Засек
Настан 10	Хармоници + Пропад + Фликер	Хармоници + Пропад + Фликер
Настан 11	Хармоници + Скок + Фликер + Осцилаторна преодна појава	Хармоници + Скок + Фликер + Осцилаторна преодна појава
Настан 12	Фликер + Скок	Фликер + Скок
Настан 13	Осцилаторна преодна појава	Осцилаторна преодна појава
Настан 14	Хармоници + Скок + Фликер	Хармоници + Скок + Фликер
Настан 15	Пропад + Осцилаторна преодна појава	Пропад + Осцилаторна преодна појава
Настан 16	Хармоници + Скок + Фликер	Хармоници + Скок + Фликер
Настан 17	Пропад + Осцилаторна преодна појава	Пропад + Осцилаторна преодна појава
Настан 18	Скок	Скок
Настан 19	Хармоници + Пропад + Фликер + Осцилаторна преодна појава	Хармоници + Пропад + Фликер + Осцилаторна преодна појава
Настан 20	Хармоници + Пропад	Хармоници + Пропад

7.6 Споредба на имплементираниот систем со системи предложени во литературата

Направена е споредбена анализа помеѓу имплементираниот систем и други системи за класификација на нарушувањата на напонските сигнали во реално време кои се достапни во литературата. Анализата е презентирана во Табела 7-12. Два од презентираниите системи имаат процент на точност во класификацијата при тестирање повисок од 99%, но истите разработуваат мал број на класи со мал број на повеќекратни нарушувања. Споредбата покажува дека само една од презентираниите имплементации овозможува детектирање на преминот преку нула. Претходно беше истакнато дека таквата детекција е од голема важност за класификација на реални сигнали, како резултат на фазните поместувања. Во однос на процентот на точност на класификацијата во реално време, само референцата [88] презентира таков тип на резултати. Споредено со тие резултати, системот за детекција и класификација презентирани во овој труд има за 15% повисока точност во класификацијата, иако разгледува 15 класи повеќе каде некои се и комбинација од четири нарушувања. Резултатите од процесирачкото време покажуваат дека имплементираниот систем има забележливо најкратко време на процесирање, споредено со останатите имплементации.

Трудот [77] презентира имплементација во реално време за класификација на 12 класи на нарушувања, каде десет од класите претставуваат еднократни нарушувања а две се комбинација од две нарушувања. Процентот на точност во класификацијата добиен при тестирање на класификаторот е над 98.6%. Хардверот кој се употребува за реално временската имплементација вклучува Xilinx Spartan XC6SLX16 FPGA и DSP TMS320C6748 процесор. За оваа имплементација дадена е информација само за една класификација во реално време направена за тестирање на ефикасноста на хардверот и софтверот, со време на процесирање од 0.935 s.

Трудот [91] разгледува сличен број на класи на нарушувања како имплементацијата во оваа дисертација. Презентира систем за класификација во реално време на 20 класи, каде 14 се повеќекратни со максимална комбинација од три нарушувања. Процентот на точност во класификацијата при тестирањето е над 97%, но само процесот на детекција на нарушувањата е имплементиран на реално-временски процесор (NI cRIO 9076), додека извлекувањето на карактеристиките и класификацијата се направени на преносен компјутер. Исто така не е дадено процесирачко време за предложената имплементација. Како резултат на малиот број на информации споделени од страна на двете споменати имплементации, не е возможна комплетна споредба со истите и поради тоа не се вметнати во табелата.

Табела 7-12. Споредбена анализа на системот за детекција и класификација на напонски нарушувања предложен во овој труд со системи предложени во литературата

Реф.	Хардвер употребен за имплементација во реално време	Број на класи на нарушувања за тестирање	Точност од тестирањето	Детекција на премин преку нулата	Број на класи за верификација во реално време	Точност во реално време	Време на извршување на пресметките
[88]	DSP TMS320VC6475, ARM Cortex-M4 processor MK60DN512VLQ10	9 (7 еднократни, 2 повеќекратни) макс. комб. од 2 нарушувања	99.3%	/	5 еднократни нарушувања	≥ 80%	13.4 ms
[89]	Xilinx Spartan 6 FPGA, Raspberry Pi 3	10 (8 еднократни, 2 повеќекратни) макс. комб. од 2 нарушувања	94.7%	/	/	/	40.5 ms
[90]	Xilinx Spartan XC2S200PQ208 FPGA, DSP TMS320C6713	11 (8 еднократни, 3 повеќекратни) макс. комб. од 2 нарушувања	> 99.27%	Да	Не е даден, Се употребува Fluke 6100A	/	≈ 50 ms
Овој труд	(FPGA and RT processor) NI MyRIO-1900	21 (9 еднократни, 12 повеќекратни) макс. комб. од 4 нарушувања	96.48%	Да	20 (8 еднократни, 12 повеќекратни) макс. комб. од 4 нарушувања	95%	5.54 ms

Од споредбената анализа може да се заклучи дека имплементацијата предложена во овој труд разгледува најголем број на класи, прави детекција на преминот преку нулата и има најкратко време на процесирање. Сепак, за да може споредбата да биде најрелевантна, потребно е да се применат сигнали за обучување на алгоритмите за класификација генерирани од ист генератор, ист број на класи на нарушувања како и ист тип на класи.

Глава 8

Заклучок

Квалитетот на електричната енергија се однесува на широк спектар на нарушувања кои се јавуваат во напонските и струјните сигнали и кои директно влијаат врз стабилноста и континуитетот на напојувањето со кое крајните корисници се снабдуваат. Нарушениот квалитет на напонот во најлош случај може да доведе до целосен прекин во снабдувањето со истиот, што има значајно влијание врз целата критичната инфраструктура. Прекилот во напојувањето подразбира пречка во работењето на болниците и грижата за здравјето, во организацијата и регулирањето на сообраќајот, во работата на банките и финансиските услуги, во снабдувањето со вода итн. Сето тоа може да доведе до релативен хаос. Оттука следи дека континуираното мониторирање на квалитетот на напонот и класификацијата на неговите нарушувања на повеќе локации во реално време е од клучно значење за безбедноста и стабилноста на енергетскиот систем. За развојот на децентрализиран систем, потребен е развој на класификатор кој ќе овозможи класификација во реално време на различни нарушувања на напонот. За да може да се направи имплементација во реално време потребни се алгоритми за извлекување карактеристики и класификација со ниска комплексност и висок процент на точност. Развојот на такви алгоритми е отворено прашање во областа на анализа на квалитет на електрична енергија и претставува предизвик за голем број истражувачи. Тој предизвик беше главна мотивација за изработка на оваа докторска дисертација.

Имено, главната цел на докторската дисертација беше да се добие оптимален алгоритам за извлекување на карактеристики и алгоритам за класификација кој се одликува со висок процент на точност, отпорен на шум. Истите да бидат применети за развој на систем за класификација на напонски нарушувања во реално време. Во насока на остварување на целта беа направени голем број истражувања:

- во областа на квалитет на електрична енергија за одредување на нарушувањата кои се јавуваат во електроенергетскиот систем;
- во областа на дигитално процесирање на сигнали за избор на соодветна алатка за извлекување на карактеристики;
- во областа на машинско учење за избор на неколку класификатори со цел избор на најсоодветен класификатор кој ќе одговори на барањата.

По направените истражувања, соодветните избори беа софтверски имплементирани. Беа имплементирани и математичките дефиниции за генерирање на голем број множества на нарушени напонски сигнали. Со примена на софтверските решенија беа спроведени различни истражувања, тестирања, споредбени анализи:

- Комбинирање на различни вејвлет-базирани карактеристики при различен број на класи и тестирање на комбинациите. Споредба на добиените резултати и одредување на најоптималната комбинација која формира вектор на карактеристики со мали димензии;
- Примена на три класификатори, со примена на оптималната комбинација на карактеристики. Нивно тестирање за различен број на сигнали и класи за обучување и различни нивоа на шум. Споредба на добиените резултати и одредување на најсоодветен класификатор, отпорен на шум и со највисок процент на точност во класификацијата;
- Оптимизација на одбраниот класификатор за класификација на 21 класа на еднократни и повеќекратни нарушувања. Тестирање на сигнали со и без шум и сигнали со и без фазно поместување. Тестирање на времето кое му е потребно на класификаторот да изврши класификација на еден сигнал и споредба со неоптимизираниот класификатор.

Со добиените резултати се покажа дека оптимизацијата е оправдана. Согласно со тоа, оптимизираниот класификатор беше имплементиран на NI MyRIO-1900 со примена на LabVIEW околина за детекција и класификација во реално време. На тој начин беше развиен систем за класификација на нарушувања на напонските сигнали во реално време. Со цел да се покаже ефикасноста на системот и да се докаже дека се реализирани поставените цели беше направена:

- Верификација на развиениот систем со примена на експериментален ланец кој овозможува репродуцирање на генерираните напонски сигнали како да се измерени директно од електроенергетската мрежа;
- Споредба на развиениот систем со системи предложени во литературата, во поглед на процентот на точност, бројот на класи кои може да се класифицираат, времето на процесирање.

Крајниот резултат од сите истражувања, анализи, оптимизација и имплементација е систем за детекција и класификација на еднократни и повеќекратни нарушувања на напонските сигнали во реално време. Со тоа дисертацијата успешно се справи со зацртаниот предизвик и даде соодветен одговор на истиот.

Резултати од истражувањата во рамките на докторската дисертација беа објавени во 12 трудови презентирани на домашни и меѓународни конференции и меѓународни списанија и со тоа достапни за пошироката јавност.

• **Насоки за идна истражувачка работа**

Областа на која припаѓа докторската дисертација нуди многу можности за истражувања и понатамошни подобрувања на развиениот систем. Насоките на идната истражувачка работа ќе бидат:

- Дополнување на системот со можност за континуирано снимање на нарушените напонски сигнали. Снимените сигнали ќе може да се употребат за дополнителни анализи, како и за формирање на база од напонски нарушувања која е недостаток во оваа област. Би било многу подобро кога обучувањето на класификаторот се прави со реални сигнали. Согласно со тоа, снимените реални сигнали може да се применат за континуирано подобрување на алгоритмите за извлекување на карактеристики и класификација со што уште повеќе ќе се зголеми точноста на системот.
- Примена на имплементацијата за развој на децентрализиран систем за мониторирање на квалитетот на напонот на повеќе локации во електроенергетската мрежа и во реално време, кој ќе известува за појава на нарушување на одредена локација. Таквиот систем ќе има директен придонес кон стабилноста на електроенергетската мрежа и непрекинато работење на критичната инфраструктура.

Прилог А

Код за премин од Python во C за имплементација на RF во LabVIEW

За потребите на овој труд развиен е код кој овозможува модел на случајна шума дефиниран во Python да биде интерпретиран во C код и запишан вој .txt фајл. На овој начин се овозможува имплементација на алгоритмот на случајна шума во LabVIEW, за кој не постои достапна алатка. Во прилог е даден кодот за интерпретација на RF1 класификаторот презентирани во делот 7.2.

```
01. # Дефинирање на векторот на карактеристики
02. features = ['x[0]', 'x[1]', 'x[2]', 'x[3]', 'x[4]', 'x[5]', 'x[6]',
03.            'x[7]', 'x[8]', 'x[9]', 'x[10]', 'x[11]', 'x[12]', 'x[13]',
04.            'x[14]', 'x[15]', 'x[16]', 'x[17]', 'x[18]', 'x[19]', 'x[20]']
05.
06. # Дефинирање на главната функција за премин од Python во C код
07. def tree_to_pseudo(tree, feature_names, q):
08.
09.     left = tree.tree_.children_left
10.     right = tree.tree_.children_right
11.     threshold = tree.tree_.threshold
12.     features = [feature_names[i] for i in tree.tree_.feature]
13.     text_file.write("\n /*Tree Number {}/ \n".format(q+1))
14.
15. # Рекурзивна функција за изминување низ секое дрво
16. def recurse(left, right, threshold, features, node, depth=0):
17.     indent = " " * depth
18.     if (threshold[node] != -2):
19.         text_file.write("{} if ({} <= {}) {{ \n".format(indent,
20.                                                         features[node], threshold[node]))
21.         if left[node] != -1:
22.             recurse (left, right, threshold, features, left[node],
23.                     depth+1)
24.         text_file.write("{} }} else {{ \n".format(indent))
25.         if right[node] != -1:
26.             recurse (left, right, threshold, features,
27.                     right[node], depth+1)
28.         text_file.write("{} }}".format(indent))
29.     else:
30.         n=np.argmax(tree.tree_.value[node])
31.         if n==0:
32.             m=1;
33.         elif n==1:
34.             m=4;
35.         elif n==2:
36.             m=5;
37.         elif n==3:
38.             m=15;
```

```
39.         elif n==4:
40.             m=20;
41.         else:
42.             m=21;
43.             text_file.write("{} i{}={}; \n".format(indent,q+1,m))
44.
45.             recurse(left, right, threshold, features, 0)
46.
47. text_file = open("RF1.txt", "w")
48.
49. # Повикување на главната функцијата
50. # clf1 е името на развиениот модел во Python
51. for q in range(0,10):
52.     tree_to_pseudo(clf1[q], features,q)
```

Интерпретацијата во С код на RF2 класификаторот, презентирани во делот 7.2 е овозможена со следниот Python код:

```
01. # Дефинирање на векторот на карактеристики
02. features = ['x[0]', 'x[1]', 'x[2]', 'x[3]', 'x[4]', 'x[5]', 'x[6]',
03.            'x[7]', 'x[8]', 'x[9]', 'x[10]', 'x[11]', 'x[12]', 'x[13]',
04.            'x[14]', 'x[15]', 'x[16]', 'x[17]', 'x[18]', 'x[19]', 'x[20]']
05.
06. # Дефинирање на главната функција за премин од Python во С код
07. def tree_to_pseudo1(tree, feature_names,q):
08.
09.     left = tree.tree_.children_left
10.     right = tree.tree_.children_right
11.     threshold = tree.tree_.threshold
12.     features = [feature_names[i] for i in tree.tree_.feature]
13.     text_file.write("\n /*Tree Number {}*/ \n".format(q+1))
14.
15. # Рекурзивна функција за изминување низ секое дрво
16. def recurse(left, right, threshold, features, node, depth=0):
17.     indent = " " * depth
18.     if (threshold[node] != -2):
19.         text_file.write("{} if ({} <= {}) {{ \n".format(indent,
20.                                                         features[node],threshold[node]))
21.         if left[node] != -1:
22.             recurse (left, right, threshold, features, left[node],
23.                     depth+1)
24.         text_file.write("{} }} else {{ \n".format(indent))
25.         if right[node] != -1:
26.             recurse (left, right, threshold, features,
27.                     right[node], depth+1)
28.         text_file.write("{} }}".format(indent))
29.     else:
30.         n=np.argmax(tree.tree_.value[node])
31.         if n==0:
32.             m=2;
33.         elif n==1:
34.             m=6;
35.         elif n==2:
36.             m=7;
```

```
37.         elif n==3:
38.             m=8;
39.         elif n==4:
40.             m=10
41.         elif n==5:
42.             m=11;
43.         elif n==6:
44.             m=13;
45.         elif n==7:
46.             m=16;
47.         elif n==8:
48.             m=18;
49.         elif n==9:
50.             m=20;
51.             text_file.write("{} i{}={}; \n".format(indent,q+1,m))
52.
53.         recurse(left, right, threshold, features, 0)
54.
55. text_file = open("RF2.txt", "w")
56.
57. # Повикување на главната функцијата
58. # clf2 е името на развиениот модел во Python
59. for q in range(0,10):
60.     tree_to_pseudo1(clf2[q], features,q)
```

Интерпретацијата на RF3 класификаторот е овозможена со следниот Python код:

```
01. # Дефинирање на векторот на карактеристики
02. features = ['x[0]', 'x[1]', 'x[2]', 'x[3]', 'x[4]', 'x[5]', 'x[6]',
03.            'x[7]', 'x[8]', 'x[9]', 'x[10]', 'x[11]', 'x[12]', 'x[13]',
04.            'x[14]', 'x[15]', 'x[16]', 'x[17]', 'x[18]', 'x[19]', 'x[20]']
05.
06. # Дефинирање на главната функција за премин од Python во C код
07. def tree_to_pseudo2(tree, feature_names,q):
08.
09.     left = tree.tree_.children_left
10.     right = tree.tree_.children_right
11.     threshold = tree.tree_.threshold
12.     features = [feature_names[i] for i in tree.tree_.feature]
13.     text_file.write("\n /*Tree Number {}*/ \n".format(q+1))
14.
15. # Рекурзивна функција за изминување низ секое дрво
16. def recurse(left, right, threshold, features, node, depth=0):
17.     indent = " " * depth
18.     if (threshold[node] != -2):
19.         text_file.write("{} if ({} <= {}) {{ \n".format(indent,
20.                features[node],threshold[node]))
21.         if left[node] != -1:
22.             recurse (left, right, threshold, features, left[node],
23.                    depth+1)
24.         text_file.write("{} }} else {{ \n".format(indent))
25.         if right[node] != -1:
26.             recurse (left, right, threshold, features,
27.                    right[node], depth+1)
28.         text_file.write("{} }}".format(indent))
```

```
29.         else:
30.             n=np.argmax(tree.tree_.value[node])
31.             if n==0:
32.                 m=3;
33.             elif n==1:
34.                 m=6;
35.             elif n==2:
36.                 m=7;
37.             elif n==3:
38.                 m=9;
39.             elif n==4:
40.                 m=10
41.             elif n==5:
42.                 m=12;
43.             elif n==6:
44.                 m=14;
45.             elif n==7:
46.                 m=17;
47.             elif n==8:
48.                 m=19;
49.             elif n==9:
50.                 m=21;
51.                 text_file.write("{} i{}={}; \n".format(indent,q+1,m))
52.
53.         recurse(left, right, threshold, features, 0)
54.
55.     text_file = open("RF3.txt", "w")
56.
57.     # Повикување на главната функцијата
58.     # clf3 е името на развиениот модел во Python
59.     for q in range(0,10):
60.         tree_to_pseudo2(clf3[q], features,q)
```

Листа на објавени трудови од областа на докторската дисертација

1. **M. Markovska**, D. Taskovski, Z. Kokolanski, V. Dimchev and B. Velkovski, "Real-Time Implementation of Optimized Power Quality Events Classifier," in *IEEE Transactions on Industry Applications*, (Early Access), DOI: 10.1109/TIA.2020.2991950, pp. 1-12, 2020.
2. **M. Markovska** and D. Taskovski, "On the choice of optimal methods for feature extractions and classification of voltage disturbances", in *Journal of Electrical Engineering and Information Technologies*, vol. 4, no. 1-2, pp. 15-27, 2019.
3. B. Velichkovska, **M. Markovska**, H. Gjoreski and D. Taskovski, "Classifying Power Quality Disturbances in Noisy Conditions using Machine Learning", *Information Society, Slovenian Conference on Artificial Intelligence*, Ljubljana, Slovenia, 2019, pp. 1-4.
4. **M. Markovska** and D. Taskovski, "Recognition of voltage disturbances in the power grid: challenges and solutions", *MAKO CIGRE 2019*, Ohrid, Macedonia, 2019, pp. 1-10.
5. **M. Markovska**, D. Taskovski, V. Dimchev and B. Velkovski, "Optimized Power Quality Events Classifier," *2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, Genova, Italy, 2019, pp. 1-6.
6. **M. Markovska** and D. Taskovski, "Efficient feature extraction and classification of power quality disturbances", in *Journal of Electrical Engineering and Information Technologies*, vol. 3, no. 1-2, pp. 13-20, 2018.
7. **M. Markovska** and D. Taskovski, "On the choice of training signals for optimal power quality disturbances classification", in *Proceedings of 14th ETAI*, Struga, Macedonia, 2018, pp. 1-6.
8. **M. Markovska** and D. Taskovski, "The effectiveness of wavelet based features on power quality disturbances classification in noisy environment," *2018 18th International Conference on Harmonics and Quality of Power (ICHQP)*, Ljubljana, 2018, pp. 1-6.
9. **M. Markovska** and D. Taskovski, "On the choice of wavelet based features in power quality disturbances classification," *2017 IEEE International Conference on Environment and Electrical Engineering and 2017 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, Milan, 2017, pp. 1-6.
10. **M. Markovska** and D. Taskovski, "Optimal wavelet based feature extraction and classification of power quality disturbances using random forest," *IEEE EUROCON 2017 -17th International Conference on Smart Technologies*, Ohrid, 2017, pp. 855-859.
11. **M. Markovska** and D. Taskovski, "Efficient implementation of QMF filter bank for power harmonic analysis on digital signal processor", in *Journal of Electrical Engineering*, vol. 16, no. 4, pp. 319-327, 2016.

12. **M. Markovska**, A. Buckovska, and D. Taskovski, “Comparative study of ARIMA and Holt-Winters statistical models for prediction of energy consumption”, in *Proceedings of 13th ETAI*, Struga, Macedonia, 2016, pp. 1-6.

Користена литература

- [1] K. Rahimi, S. Mohajeryami and A. Majzoobi, "Effects of photovoltaic systems on power quality," in *Proceedings of the 2016 North American Power Symposium*, Denver, CO, USA, 18–20 September 2016, pp. 1–6.
- [2] X. Liang, "Emerging Power Quality Challenges Due to Integration of Renewable Energy Sources," in *IEEE Transactions on Industry Applications*, vol. 53, no. 2, pp. 855-866, March-April 2017.
- [3] W. Webin and M. Peng, "A Data Mining Approach Combining K-Means Clustering with Bagging Neural Network for Short-term Wind Power Forecasting," *IEEE Internet of Things Journal*, vol. 4, no. 4, pp. 2327-4662, 2017.
- [4] H. G. Beleiu, I. Beleiou, S.G. Pavel and C.P. Darab, "Management of Power Quality Issues from an Economic Point of View," *Sustainability*, vol. 10, no.7, pp. 2326, 2018.
- [5] M. R. Sindhu, G. N. Manjula and T. N. P. Nambiar, "Development of LabVIEW based harmonic analysis and mitigation scheme with shunt active filter for power quality enhancement," *International Journal of Recent Technology and Engineering*, vol. 2, no. 5, pp. 71–78, 2013.
- [6] J. G. de la Rosaa, A. A. Péreza, J. C. Salasa, J. M. Fernándeza and A. M. Muñoza, "A novel virtual instrument for power quality surveillance based in higher-order statistics and case-based reasoning," *Measurement*, vol. 45, no. 7, pp. 1824–1835, 2012.
- [7] R. Saxena, A. K. Swami and S. Mathur, "A power quality signal generator in LabVIEW Environment," *International Conference on Advances in Electronics, Electrical and Computer Science Engineering – EEC 2012*, 2012, pp. 36–39.
- [8] W. Zhu, W. Y. Ma, Y. Gui and H. F. Zhang, "Modelling and simulation of PQ disturbance based on Matlab," *International Journal of Smart Grid and Clean Energy*, vol. 2, no.1, pp. 18–24, 2013.
- [9] S. Caldara, S. Nuccio and C. Spataro, "A virtual instrument for measurement of flicker," in *IEEE Transactions on Instrumentation and Measurement*, vol. 47, no. 5, pp. 1155-1158, 1998.
- [10] Y. Huping and B. Zhipeng, "The power quality monitoring system based on virtual instrument," *Fourth World Congress on Software Engineering*, 2009, pp. 243–245.
- [11] W. E. Brumsickle, D. M. Divan, G. A. Luckjiff, J. W. Freeborg and R. L. Hayes, "Operational experience with a nationwide power quality and reliability monitoring system," *38th IAS Annual Meeting on Conference Record of the Industry Applications Conference, 2003.*, Salt Lake City, UT, USA, 2003, pp. 1063-1067 vol.2.
- [12] P. Daponte, M. Di Penta and G. Mercurio, "TransientMeter: a distributed measurement system for power quality monitoring," in *IEEE Transactions on Power Delivery*, vol. 19, no. 2, pp. 456-463, April 2004.

- [13] D. Divan, G. A. Luckjiff, W. E. Brumsickle, J. Freeborg and A. Bhadkamkar, "A grid information resource for nationwide real-time power monitoring," in *IEEE Transactions on Industry Applications*, vol. 40, no. 2, pp. 699-705, March-April 2004.
- [14] P. K. Lee and L. L. Lai, "A Practical Approach to Wireless GPRS On-Line Power Quality Monitoring System," *2007 IEEE Power Engineering Society General Meeting*, Tampa, FL, 2007, pp. 1-7.
- [15] P. K. Lee and L. L. Lai, "A practical approach to wireless Power Quality, Energy and Facilities Monitoring System," *2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*, Pittsburgh, PA, 2008, pp. 1-3.
- [16] C. Kocatepe, B. Kekezoglu, A. Bozkurt, R. Yumurtac, A. Inan, O. Arkan, M. Baysal and Y. Akkaya, "Survey of power quality in Turkish national transmission network," *Turkish Journal of Electrical Engineering & Computer Sciences*, vol. 21, pp. 1880-1892, 2013.
- [17] S. Di Pasquale, S. Giarnetti, F. Leccese, D. Trinca, M. Cagnetti and M. Caciotta, "A Distributed Web-Based System for Temporal and Spatial Power Quality Analysis," *In Power Quality Issues in Distributed Generation*, In Tech: Rijeka, Croatia, 2015.
- [18] L. Cristaldi, A. Ferrero and S. Salicone, "A distributed system for electric power quality measurement," in *IEEE Transactions on Instrumentation and Measurement*, vol. 51, no. 4, pp. 776-781, August 2002.
- [19] S. -. S. Tsai and C. C. Luo, "Synchronized Power-Quality Measurement Network With LAMP," in *IEEE Transactions on Power Delivery*, vol. 24, no. 1, pp. 484-485, January 2009.
- [20] A. Carta, N. Locci and C. Muscas, "GPS-Based System for the Measurement of Synchronized Harmonic Phasors," in *IEEE Transactions on Instrumentation and Measurement*, vol. 58, no. 3, pp. 586-593, March 2009.
- [21] T. Demirci, A. Kalaycioglu, D. Kucuk, O. Salor, M. Guder, S. Pakhuylu et al., "Nationwide real-time monitoring system for electrical quantities and power quality of the electricity transmission system," in *IET Generation, Transmission & Distribution*, vol. 5, no. 5, pp. 540-550, May 2011.
- [22] IEEE PES Task Force on Open Data Sets: <https://site.ieee.org/pes-iss/files/2017/07/ODS-Call-for-Open-Data-Sets.pdf>
- [23] H. H. Kajihara, "Quality power for electronics," *Electro-Technology*, vol. 82, no. 5, pp. 46, 1968.
- [24] P. M. Knoller and L. Lonnstam, "Voltage quality and voltage tendency recorders," *Siemens-Review*, vol. 36, no. 8, pp. 302-303, 1969.
- [25] B. A. Kostadinov and G. L. Bagiev, "Financial losses due to determination of voltage quality," *Electric-Technology-USSR*, vol. 1, pp. 119-123, 1970.
- [26] Electromagnetic compatibility (EMC), Part 1, Section 1: Application and interpretation of fundamental definitions and terms, IEC 61000-1-1.
- [27] EN 50160, Voltage characteristics of electricity supplied by public distribution systems, 1999.

- [28] Recommended practice for monitoring electric power quality, IEEE Std. 1159-1995.
- [29] Electromagnetic compatibility (EMC), Part 3, Section 2: Limits for harmonic current emission, IEC 61000-3-2.
- [30] Recommended practice and requirements for harmonic control in electrical power systems, ANSI/ IEEE Std. 519-1992.
- [31] Electromagnetic compatibility (EMC), Part 4, Section 30: Power quality measurement methods, IEC 61000-4-30.
- [32] Z. L. Gaing, "Wavelet-based neural network for power disturbance recognition and classification," in *IEEE Transactions on Power Delivery*, vol. 19, no. 4, pp. 1560-1568, October 2004.
- [33] J. G. Decanini, M. S. Tonelli-Neto, F. C. Malange and C. R. Minussi, "Detection and classification of voltage disturbances using a fuzzy-artmap-wavelet network," *Electric Power Systems Research*, vol. 81, no. 12, pp. 2057–2065, 2011.
- [34] Vaidyanathan, P., "Multirate systems and filter banks", Prentice-Hall, 1993.
- [35] G. Strang and T. Nguyen, "Wavelets and Filter Banks", Wellesley-Cambridge Press, Cambridge, MA, 1996.
- [36] S. Santoso, E. J. Powers, W. M. Grady and P. Hofmann, "Power quality assessment via wavelet transform analysis," in *IEEE Transactions on Power Delivery*, vol. 11, no. 2, pp. 924-930, April 1996.
- [37] E. Y. Hamid, Z. I. Kawasaki, H. Yoshida and H. Doi, "Wavelet analysis of voltage disturbances for power quality applications", *Transaction of the Institute of Electrical Engineering of Japan*, vol. 122-B, no. 2, pp. 323–330, 2002.
- [38] A. Milchevski and D. Taskovski, "Classification of power quality disturbances using wavelet transform and SVM decision tree," *11th International Conference on Electrical Power Quality and Utilisation*, Lisbon, 2011, pp. 1-5.
- [39] E. Styvaktakis, M. H. J. Bollen and I. Y. H. Gu, "Expert system for classification and analysis of power system events," in *IEEE Transactions on Power Delivery*, vol. 17, no. 2, pp. 423-428, April 2002.
- [40] P. K. Dash, S. Mishra, M. A. Salama and A. C. Liew, "Classification of power system disturbances using a fuzzy expert system and a Fourier linear combiner," in *IEEE Transactions on Power Delivery*, vol. 15, no. 2, pp. 472-477, April 2000.
- [41] I. Monedero, C. Leon, J. Roperro, A. Garcia, J. M. Elena and J. C. Montano, "Classification of Electrical Disturbances in Real Time Using Neural Networks," in *IEEE Transactions on Power Delivery*, vol. 22, no. 3, pp. 1288-1296, July 2007.
- [42] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines and other kernel-based learning methods*, Cambridge University Press, Cambridge, United Kingdom, 2000.
- [43] P. Janik and T. Lobos, "Automated classification of power-quality disturbances using SVM and RBF networks," in *IEEE Transactions on Power Delivery*, vol. 21, no. 3, pp. 1663-1669, July 2006.

- [44] J. C. Platt, N. Cristianini and J. Shawe-Taylor, "Large Margin DAGs for Multiclass Classification", *Advances in Neural Information Processing Systems*, vol. 12, pp. 547-553, 2000.
- [45] J. R. Quinlan, "Induction of decision trees," *Machine Learning*, vol. 1, pp. 81-106, 1986.
- [46] P. K. Ray, S. R. Mohanty, N. Kishor and J. P. S. Catalão, "Optimal Feature and Decision Tree-Based Classification of Power Quality Disturbances in Distributed Generation Systems," in *IEEE Transactions on Sustainable Energy*, vol. 5, no. 1, pp. 200-208, January 2014.
- [47] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, pp. 5-32, 2001.
- [48] T. Li, B. Ni, X. Wu, Q. Gao, Q. Li and D. Sun, "On random hyper-class random forest for visual classification," *Neurocomputing*, vol. 172, pp. 281-289, 2016.
- [49] Д. Ѓорѓевиќ, "Комбинирање на класификатори за препознавање на броеви напишани на рака," Докторска дисертација, Универзитет "Св. Кирил и Методиј" – Скопје, Електротехнички факултет, Скопје, 2004.
- [50] L. Hyafil and R. L. Rivest, "Constructing optimal binary decision trees is NP-complete," *Information Processing Letters*, vol. 5, no. 1, pp. 15-17, 1976.
- [51] H. Zantema and H. L. Bodlaender, "Finding Small Equivalent Decision Trees is Hard," *International Journal of Foundations of Computer Science*, vol. 11, no. 2, pp. 343-354, 2000.
- [52] J. R. Quinlan, *C4.5: Programs for Machine Learning*, Morgan Kaufmann, Los Altos, 1993.
- [53] L. Breiman, J. Friedman, R. Olshen and C. Stone, "Classification and Regression Trees," Wadsworth International Group, 1984.
- [54] J. R. Quinlan, "Simplifying decision trees," *International Journal of Man-Machine Studies*, vol. 27, pp. 221-234, 1987.
- [55] O. P. Mahela, A. G. Shaik and N. Gupta, "A critical review of detection and classification of power quality events," *Renewable and Sustainable Energy Reviews*, vol. 41, pp. 495-505, 2015.
- [56] N. Huang, G. Lu, G. Cai, D. Xu, J. Xu, F. Li and L. Zhang, "Feature Selection of Power Quality Disturbance Signals with an Entropy-Importance-Based Random Forest," *Entropy*, vol. 18, no. 2, pp. 44, 2016.
- [57] T. K. Abdel-Galil, M. Kamel, A. M. Youssef, E. F. El-Saadany and M. M. A. Salama, "Power quality disturbance classification using the inductive inference approach," *IEEE Transactions on Power Delivery*, vol. 19, no. 4, pp. 1812-1818, October 2004.
- [58] H. He and J. A. Starzyk, "A self-organizing learning array system for power quality classification based on wavelet transform," *IEEE Transactions on Power Delivery*, vol. 21, no. 1, pp. 286-295, January 2006.
- [59] M. Uyara, S. Yildirim and M.T. Gencoglu, "An effective wavelet-based feature extraction method for classification of power quality disturbance signals," *Electric Power Systems Research*, vol. 78, pp. 1747-1755, October 2008.

- [60] S. Upadhyaya and S. Mohanty, "Localization and Classification of Power Quality Disturbances using Maximal Overlap Discrete Wavelet Transform and Data Mining based Classifiers," *Elsevier, IFAC – Papers On Line*, vol. 49, pp. 437–442, 2016
- [61] H. Erişti, Ö. Yıldırım, B. Erişti and Y. Demir, "Optimal feature selection for classification of the power quality events using wavelet transform and least squares support vector machines," *International Journal of Electrical Power & Energy Systems*, vol. 49, pp. 95–103, July 2013.
- [62] M. Markovska and D. Taskovski, "Optimal wavelet based feature extraction and classification of power quality disturbances using random forest," *IEEE EUROCON 2017 -17th International Conference on Smart Technologies*, Ohrid, 2017, pp. 855-859.
- [63] M. Markovska and D. Taskovski, "On the choice of wavelet based features in power quality disturbances classification," *2017 IEEE International Conference on Environment and Electrical Engineering and 2017 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, Milan, 2017, pp. 1-6
- [64] Интернет страна: <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>
- [65] C. E. Shannon, "A mathematical theory for communication", *Bell Syst. Tech. J.*, vol. 27, no. 3, pp. 379–423, 1948.
- [66] H. Kim, J. Lee, J. Choi and G. Chung, "Power disturbance classifier using wavelet-based neural network," *2006 37th IEEE Power Electronics Specialists Conference*, Jeju, 2006, pp. 1-6.
- [67] F. Zhao and R. Yang, "Power-Quality Disturbance Recognition Using S-Transform," in *IEEE Transactions on Power Delivery*, vol. 22, no. 2, pp. 944-950, April 2007.
- [68] S. Mishra, C. N. Bhende and B. K. Panigrahi, "Detection and Classification of Power Quality Disturbances Using S-Transform and Probabilistic Neural Network," in *IEEE Transactions on Power Delivery*, vol. 23, no. 1, pp. 280-287, January 2008.
- [69] M.-H. Wang and Y.-F. Tseng, "A novel analytic method of power quality using extension genetic algorithm and wavelet transform," *Expert Systems with Applications*, vol. 38, pp. 12491-12496, September 2011.
- [70] D. Saxena, K. S. Verma and S. N Singh, "Power quality event classification: an overview and key issues," *International Journal of Engineering Science and Technology*, vol. 2, pp. 186-199, 2010.
- [71] D. De Yong, S. Bhowmik and F. Magnago, "An effective Power Quality classifier using Wavelet Transform and Support Vector Machines," *Expert Systems with Applications*, vol. 42, pp. 6075-608, September 2015.
- [72] N. Huang, H. Peng, G. Cai and J. Chen, "Power quality disturbances feature selection and recognition using optimal multi-resolution fast S-transform and CART algorithm," *Energies*, vol. 9, no. 11, pp. 927-948, 2016.
- [73] U. Singh and S. N. Singh, "Detection and classification of PQ disturbances based on time-frequency-scale transform," *IET Science, Measurement & Technology*, vol. 11, pp. 802-810, 2017.

- [74] H. H. Wang, P. Wang and T. Liu, "Power quality disturbance classification using the S-transform and probabilistic neural network," *Energies*, vol. 10, no. 1, pp. 107, 2017.
- [75] M. Saini and R. Beniwal, "Detection and classification of power quality disturbances in wind-grid integrated system using fast time-time transform and small residual-extreme learning machine," *International Transactions on Electrical Energy Systems*, vol. 28, pp. 1-23, 2018.
- [76] J. R. Razo-Hernandez, M. Valtierra-Rodriguez, J. P. Amezquita-Sanchez, D. Granados-Lieberman, J. F. Gomez-Aguilar and J. J. Rangel-Magdaleno, "Homogeneity-PMU-based method for detection and classification of power quality disturbances," *Electronics*, vol. 7, pp. 433, 2018.
- [77] D. Cai, K. Li, S. He, Y. Li and Y. Luo, Y, "A highly accurate and fast power quality disturbances classification based on dictionary learning sparse decomposition," *Transactions of the Institute of Measurement and Control*, vol. 41, no. 1, pp. 145–155, 2018.
- [78] E. G. Ribeiro, G. L. Dias, B. H. G. Barbosa and D. D. Ferreira, "Real-time system for automatic classification of power quality disturbances," *2016 17th International Conference on Harmonics and Quality of Power (ICHQP)*, Belo Horizonte, 2016, pp. 908-913.
- [79] M. Markovska, D. Taskovski, V. Dimchev and B. Velkovski, "Optimized Power Quality Events Classifier," *2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, Genova, Italy, 2019, pp. 1-6.
- [80] R. Igual, C. Medrano, F. J. Arcega, G. Mantescu, "Mathematical model of power quality disturbances", Mendeley Data, v1, 2017.
- [81] C.-W. Hsu, C.-C. Chang and C.-J. Lin, "A practical guide to support vector classification," Department of Computer Science National Taiwan University, 2003.
- [82] J. Bergstra, and Y. Bengio, "Random Search for Hyper-Parameter Optimization," *Journal of Machine Learning Research*, vol. 13, pp. 281–305, 2012.
- [83] Интернет страна: <http://www.ni.com/pdf/manuals/376047c.pdf>
- [84] D. Zivanovic, M. Simic, Z. Kokolanski, D. Denic, V. Dimcev, "Generation of long-time complex signals for testing the instruments for detection of voltage quality disturbances", *Measurement Science Review*, vol. 18, pp. 41-51, 2018.
- [85] Интернет страна: <https://www.ni.com/pdf/manuals/375199d.pdf>
- [86] Z. Kokolanski, C. Gavrovski, I. Mircevska, V. Dimcev and M. Simic, "On the design of power quality signal amplifier," *2016 XXV International Scientific Conference Electronics (ET)*, Sozopol, 2016, pp. 1-4.
- [87] V. Dimcev, D. Taskovski, Z. Kokolanski, D. Denic, D. Zivanovic and M. Simic, "Signal conditioning for power quality," *11th International Conference on Electrical Power Quality and Utilisation*, Lisbon, 2011, pp. 1-5.
- [88] J. Li, Z. Teng, Q. Tang and J. Song, "Detection and Classification of Power Quality Disturbances Using Double Resolution S-Transform and DAG-SVMs," in *IEEE*

Transactions on Instrumentation and Measurement, vol. 65, no. 10, pp. 2302-2312, October 2016.

- [89] M. Gok and I. Sefa, "Research and Implementation of a USB Interfaced Real-Time Power Quality Disturbance Classification System," *Advances in Electrical and Computer Engineering*, vol.17, no.3, pp.61-70, 2017.
- [90] S. He, K. Li and M. Zhang, "A Real-Time Power Quality Disturbances Classification Using Hybrid Method Based on S-Transform and Dynamics," in *IEEE Transactions on Instrumentation and Measurement*, vol. 62, no. 9, pp. 2465-2475, September 2013.
- [91] E. G. Ribeiro, T. M. Mendes, G. L. Dias, E. R.S. Faria, F. M. Viana, B. H. G. Barbosa and D. D. Ferreira, "Real-time system for automatic detection and classification of single and multiple power quality disturbances," *Measurement*, vol. 128, pp. 276-283, 2018.