

УНИВЕРЗИТЕТ У БЕОГРАДУ

ЕЛЕКТРОТЕХНИЧКИ ФАКУЛТЕТ

ДЕНИС М. ИЛИЋ

**Дијагностика стања електроизолационих  
система синхроних генератора заснована  
на вештачкој интелигенцији**

-ДОКТОРСКА ДИСЕРТАЦИЈА-

Београд, 2022.



UNIVERSITY OF BELGRADE

SCHOOL OF ELECTRICAL ENGINEERING

DENIS M. ILIĆ

**Synchronous Generators Electrical Insulation  
System Condition Diagnostic Based on  
Artificial Intelligence**

-DOCTORAL DISSERTATION-

Belgrade, 2022.

*Ова страна је намерно остављена празна*

## **ПОДАЦИ О МЕНТОРУ И ЧЛАНОВИМА КОМИСИЈЕ**

### **Ментор:**

Др Милета Жарковић, доцент  
(Универзитет у Београду, Електротехнички факултет)

### **Чланови комисије:**

др Милета Жарковић, доцент  
(Универзитет у Београду, Електротехнички факултет)

др Златан Стојковић, редовни професор  
(Универзитет у Београду, Електротехнички факултет)

др Саша Милић, научни саветник  
(Електротехнички институт "Никола Тесла")

др Зоран Лазаревић, редовни професор у пензији  
(Универзитет у Београду, Електротехнички факултет)

др Александар Ракић, редовни професор  
(Универзитет у Београду, Електротехнички факултет)

Датум усмене одбране: 29.12.2022.

*Ова страна је намерно остављена празна*

## **Наслов докторске дисертације: Дијагностика стања електроизолационих система синхроних генератора заснована на вештачкој интелигенцији**

### Резиме

Синхрони генератори представљају базну снагу и стуб електроенергетских система модерног света. Повољни техноекономски утицај правовременог и одговарајућег одржавања ових машина је од изузетног значаја на свеукупну поузданост електроенергетског система и последично на економску стабилност једног електропривредног предузећа.

Током развоја електроенергетике као привредне гране развијали су се и различити приступи одржавања електроопреме. У фази развоја електрификације и недовољног познавања природе и начина утицаја различитих фактора на механизме развоја квара одржавање се вршило хаваријски, односно након испада. Временом су устаљени фиксни временски интервали за сервисно одржавање електроенергетске опреме које је представља планско одржавање. У последњих 2 деценије прибегавало се оптимизацији временски заснованог планског одржавања (*Time Based Maintenance* - TBM).

Оптимизација је потпомогнута развојем бројних метода за континуално и повремено праћење стања синхроних генератора, вршењем испитивања или праћењем помоћу уграђених сензора. Оваква оптимизација је условила развој тзв. одржавања према стању (*Condition Based Maintenance* - CBM). Примена оваквог начина одржавања се показала исплативом, с обзиром да се избегавају трошкови замене елемената који нису похабани, што се свакако дешавало при одржавању у фиксним временским интервалима, када обим изведених сервисних радова често није био прилагођен стварном стању опреме.

У циљу поуздане примене CBM модела одржавања, неопходно је познавати стварно стање опреме, с обзиром да је ово основни податак при доношењу одлуке о обиму и тренутку имплементације сервисних радњи. У току свог радног века синхрони генератори су изложени деловању тзв. TEAM фактора, удруженог утицаја температурног, електричног, амбијенталног и механичког фактора старења електричног изолационог система (ЕИС). Изолациони системи представљају прилично чест проблем и разлог испада синхроних генератора. Нпр, према истраживању међународног комитета Цигре, проблеми повезани са ЕИС хидрогенератора представљају 56% од укупног броја испада, док је према другом извору код турбогенератора овај удео нешто нижи, 23%. С обзиром да је деградација ЕИС у погонским условима практично неизбежна, од изузетне је важности препознати благовремено убрзане процесе деградације и предупредити изненадне испаде. Како би се ови процеси идентификовали, врше се електрична испитивања и евентуално праћење уграђених континуалних уређаја за надгледање стања.

Уобичајне методе електричних испитивања статорских намотаја подразумевају мерење електричног отпора изолације, мерење фактора диелектричних губитака и капацитета, мерење интезитета парцијалних пражњења, испитивања повишеним наизменичним и/или једносмерним напоном. Методе којима се обично тестирају роторски намотаји подразумевају мерење електричног отпора изолације, мерење импедансе намотаја ротора, провера међузавојне изолације импулсном методом.

Потешкоће које овај рад третира настају управо у фази тумачења резултата извршених електричних профилактских испитивања. Наиме, постојећи међународни стандарди у великој мери дефинишу процедуре извођења појединих мерења имерне инструменте.

Међутим критеријуми дијагностике за поједине методе најчешће нису приказани. Због разноврсности примењених технологија различитих произвођача, као и напретка у развоју ЕИС, стандардима често нису дефинисани универзални гранични критеријуми мерених величина. Такође, није довољно протумачити једну мерену величину да би се донео закључак о дијагностици комплетног ЕИС синхорног генератора, већ је потребно узети у обзир што већи број мерних величина како би се што објективније донела оцена дијагностике. У сврху тога у раду су коришћене напредне методе вештачке интелигенције на бази података са искуственим оценама стања ЕИС синхорног генератора.

У раду је приказана анализа могућности савремених алата вештачке интелигенције за процену стања ЕИС синхроних генератора. Упоредном употребом различитих алата и метода машинског учења закључци о тачности модела базираних на фази логичком резонувању, вештачким неуралним мрежама у различитим изведбама су изведени.

Кључне речи: синхрони генератори, дијагностика стања, машинско учење, вештачка интелигенција

**Научна област:** Техничке науке - Електротехника

Ужа научна област: Електроенергетски системи

УДК: 621.3



**Dissertation thesis:** Synchronous Generators Electrical Insulation System Condition Diagnostic Based on Artificial Intelligence

Abstract

Synchronous generators represent the base power and pillar of the power systems of the modern world. The favorable techno-economic impact of timely and appropriate maintenance of these machines is of great importance for the overall reliability of the power system and consequently for the economic stability of an electric power company.

During the development of the electric power industry as an economic branch, various approaches to the maintenance of electrical equipment were developed. In the phase of electrification development and insufficient knowledge of the nature and manner of influence of various factors on the mechanisms of fault development, maintenance was performed in an emergency, ie after a failure. Over time, fixed time intervals for service maintenance of the power industry have been established, and in the last 2 decades, optimization of that solution has been developed. Optimization has been supported by the development of many methods for continuous and intermittent monitoring, testing and monitoring using built-in sensors. This optimization has conditioned the development of the so-called Condition Based Maintenance (CBM). The application of this method of maintenance proved to be cost-effective, as it avoids the cost of replacing elements that are not worn out, which certainly happened during maintenance at fixed intervals when the scope of service work was often not adjusted to the actual condition of the equipment. To reliably apply the CBM maintenance model, it is necessary to know the actual condition of the equipment, since this is the basic information when deciding on the scope and timing of the implementation of service activities.

During their working life, synchronous generators are exposed to the so-called. TEAM factor, the combined influence of temperature, electrical, ambient and mechanical aging factor of electrical insulation system (EIS). Isolation systems are a fairly common problem and the reason for the failure of synchronous generators. For example, according to a study by the Cigre International Committee, problems related to EIS hydro generators account for 56% of the total number of outages, while according to another source, this share of turbogenerators is slightly lower, 23%.

Since the degradation of EIS in operating conditions is practically inevitable, it is extremely important to recognize timely accelerated degradation processes and prevent sudden outages. To diagnose these processes, electrical tests are performed and possible monitoring of the installed continuous devices for monitoring the condition.

Common methods of electrical testing of stator windings include measuring the electrical resistance of the insulation, measuring the dielectric loss and capacity factors, measuring the intensity of partial discharges, and testing with increased AC and/or DC voltage. Methods that usually test rotor windings include measuring the electrical resistance of the insulation, measuring the impedance of the rotor windings, and checking the inter-winding insulation by the pulse method.

The difficulties that this paper treats arise precisely in the phase of interpreting the results of performed electrical prophylactic tests. Namely, the existing international standards largely define the procedures for performing certain measurements and define measuring instruments. However, the criteria for individual methods are usually not presented. Due to the diversity of applied technologies of different manufacturers, as well as the progress in the development of EIS, the standards often do not define universal criteria.

The paper presents an analysis of the possibilities of modern artificial intelligence tools for assessing the state of EIS synchronous generators. By comparative use of different tools and methods of machine learning, conclusions about the accuracy of models based on the fuzzy logical reasoning, and artificial neural networks in different designs were derived.

Keywords: synchronous generators, condition diagnostics, machine learning, artificial intelligence

Scientific field: Technical sciences - Electrical engineering

Scientific subfield: Power systems

UDK: 621.3

## Захвалница

*Једно велико хвала супрузи Нини и мојим девојкама, Магдалени и Дајани, без којих никада не би нашао довољно мотивације да овај рад завршим до краја.*

*Захваљујем се мојој породици, родитељима, на разумевању за све тренутке које сам провео сконцентрисан само на овај рад.*

*Велико хвала дугујем мојим менторима, доц. др Милети Жарковићу и др Саши Милићу на несебичном труду, утрошеном времену и доприносу са којим је овај рад значајно унапређен.*

*Напоследку, искрено се захваљујем колегама са РН410 Центра за електромерења ЕТИ Никола Тесла Београд, који су нашли снаге да употпуне моје заузеће писањем дисертације својим несебичним ангажовањем.*

## СПИСАК СЛИКА У РАДУ:

Слика 1 СТАТИСТИКА КВАРОВА СИНХРОНИХ МАШИНА: А) SIGRE ИСТРАЖИВАЊЕ О КВАРОВИМА НА ХИДРОГЕНЕРАТОРИМА [5], Б) СТАТИСТИКА КВАРОВА ТУРБОГЕНЕРАТОРА [6], В) СТАТИСТИКА КВАРОВА ВЕЛИКИХ СИНХРОНИХ МАШИНА ОД СТРАНЕ ОСИГУРАВАЈУЋЕГ ДРУШТВА[7] .....	- 2 -
Слика 2 ПРИМЕРИ А) НЕУНИФОРМНОГ И Б) ЈЕДНЕ СЕКЦИЈЕ УНИФОРМНОГ НАМОТАЈА .....	- 7 -
Слика 3 ПРИКАЗ РЕБЕЛ (RÖBEVL) СТАТОРСКОГ ШТАПА: А) ПРИКАЗ ЕЛЕМЕНТАРНИХ ПРОВОДНИКА РЕБЕЛ ШТАПА ПРЕ ОБЛАГАЊА ОСНОВНОМ ИЗОЛАЦИЈОМ, Б) ГОТОВИ СТАТОРСКИ ШТАПОВИ, В) ПОПРЕЧНИ ПРЕСЕК СТАТОРСКОГ ШТАПА СА ШУПЉИМ ПРОВОДНИЦИМА ЗА ПРОТОК РАСХЛАДНЕ ВОДЕ .....	- 7 -
Слика 4 ПРИКАЗ РАЗЛИЧИТИХ КОНСТРУКЦИЈА РОТОРА СИНХРОНИХ МАШИНА: А) ЦИЛИНДРИЧНИ, Б) СА ИСТАКНУТИМ ПОЛОВИМА....	- 8 -
Слика 5 ПРИМЕР ЗАВИСНОСТИ ФАКТОРА ДИЕЛЕКТРИЧНИХ ГУБИТАКА САВРШЕНОГ И РЕАЛНОГ ЕИС .....	- 18 -
Слика 6 ОДЗИВИ РОТОРСКОГ НАМОТАЈА ПРИСУТНИМ МЕЂУЗАВОЈНИМ КРАТКИМ СПОЈЕВИМА НА ИМПУЛСНУ ПОБУДУ СНИМЉЕНА НА ОБА КЛИЗНА ПРСТЕНА И РАЗЛИКА ОВА ДВА СИГНАЛА .....	- 20 -
Слика 7 ЕВОЛУЦИЈА СТРАТЕГИЈА ОДРЖАВАЊА .....	- 21 -
Слика 8 ИНДУСТРИЈСКЕ РЕВОЛУЦИЈЕ КРОЗ ИСТОРИЈУ .....	- 25 -
Слика 9 РЕЛАЦИЈЕ ИЗМЕЂУ ПОЈЕДИНИХ ПОЈМОВА ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ .....	- 28 -
Слика 10 ПРИКАЗ ОСНОВНОГ АЛГОРИТМА ПОСТУПКА КРЕИРАЊА СИСТЕМА ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ .....	- 29 -
Слика 11 БЛОК ШЕМА УОБИЧАЈНОГ ФАЗИ ЛОГИЧКОГ КОНТРОЛЕРА .....	- 31 -
Слика 12 ПРИКАЗ БИОЛОШКОГ НЕУРОНА .....	- 33 -
Слика 13 ПРИКАЗ ВЕШТАЧКОГ НЕУРОНА .....	- 35 -
Слика 14 ПРИКАЗ FEED FORWARD ПОТПУНО ПОВЕЗАНЕ НЕУРАЛНЕ МРЕЖЕ СА ЈЕДНИМ УЛАЗНИМ И ЈЕДНИМ ИЗЛАЗНИМ СЛОЈЕМ И ЈЕДНИМ САКРИВЕНИМ СЛОЈЕМ .....	- 35 -
Слика 15 ПРИКАЗ АУТОЕНКОДЕРСКЕ НЕУРАЛНЕ МРЕЖЕ .....	- 37 -
Слика 16 ПРИМЕР СТАБЛА ОДЛУКЕ О КУПОВИНИ НЕКРЕТНИНЕ .....	- 40 -
Слика 17 ПРОЦЕНТУАЛНИ УДЕО ПОЈЕДИНИХ ОЦЕНА У УКУПНОМ СКУПУ ПОДАТАКА .....	- 43 -
Слика 18 АЛГОРИТАМ РАЗВОЈА ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА .....	- 47 -
Слика 19 УПОРЕДНИ ПРИКАЗ ГРЕШАКА ПОКАЗИВАЊА ЗА ЗАВРШНА ТРИ МОДЕЛА .....	- 48 -
Слика 20 ПРИЛАГОЂЕНА ИМПОРТОВАНА ФУНКЦИЈА ПРИПАДНОСТИ ЗА ВРЕДНОСТИ ЕЛЕКТРИЧНОГ ОТПОРА ИЗОЛАЦИЈЕ ОЗНАЧЕНА НАРАНЧАСТОМ БОЈОМ .....	- 49 -
Слика 21 ФАЗИ ЛОГИЧКИ ЕКСПЕРТСКИ СИСТЕМ НА БАЗИ МАМДАНИ СИСТЕМА ЗАКЉУЧИВАЊА СА 6 УЛАЗНИХ ВЕЛИЧИНА И ЈЕДНИМ ИЗЛАЗОМ .....	- 49 -
Слика 22 ФУНКЦИЈЕ ПРИПАДНОСТИ ЗА 6 УЛАЗНИХ ВЕЛИЧИНА ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА .....	- 50 -
Слика 23 ПРИКАЗ ФУНКЦИЈЕ ПРИПАДНОСТИ ИЗЛАЗНЕ ВРЕДНОСТИ - ИНДЕКСА СТАЊА ГЕНЕРАТОРА .....	- 51 -
Слика 24 ВРЕДНОСТИ ИЗЛАЗНЕ ВЕЛИЧИНЕ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА У ФУНКЦИЈИ ПОЧЕТНЕ ВРЕДНОСТИ ТГД И СТАРОСТИ МАШИНЕ .....	- 52 -
Слика 25 ВРЕДНОСТИ ИЗЛАЗНЕ ВЕЛИЧИНЕ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА У ФУНКЦИЈИ ПОЧЕТНЕ ВРЕДНОСТИ ТГД И ПАРЦИЈАЛНИХ ПРАЖЊЕЊА .....	- 52 -
Слика 26 ВРЕДНОСТИ ИЗЛАЗНЕ ВЕЛИЧИНЕ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА У ФУНКЦИЈИ МАКСИМАЛНЕ ВРЕДНОСТИ ПРИРАШТАЈА ТГД ПАРЦИЈАЛНИХ ПРАЖЊЕЊА .....	- 53 -
Слика 27 ВРЕДНОСТИ ИЗЛАЗНЕ ВЕЛИЧИНЕ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА У ФУНКЦИЈИ ЕЛЕКТРИЧНОГ ОТПОРА ИЗОЛАЦИЈЕ НАМОТАЈА СТАТОРА И ИНДЕКСА АПСОРПЦИЈЕ .....	- 53 -
Слика 28 МАТРИЦА ЗБУЊЕНОСТИ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА .....	- 54 -
Слика 29 УПОРЕДНИ ПРИКАЗ РЕЗУЛТАТА ЕКСПЕРТСКЕ АНАЛИЗЕ И ПРОРАЧУНА ФАЗИ ЛОГИЧКОГ МОДЕЛА НА БАЗИ ОД 20 МОДЕЛОВАНИХ РЕЗУЛТАТА .....	- 55 -
Слика 30 ГРЕШКА ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА НА ПРОРАЧУНУ ЗА 20 МОДЕЛОВАНИХ РЕЗУЛТАТА .....	- 56 -
Слика 31 КОНФИГУРАЦИЈА ВЕШТАЧКЕ НЕУРАЛНЕ МРЕЖЕ ЗА ПРОЦЕНУ СТАЊА ГЕНЕРАТОРА .....	- 59 -
Слика 32 ПРОЦЕС КРЕИРАЊА ВЕШТАЧКЕ НЕУРАЛНЕ МРЕЖЕ ЗА ПРОЦЕНУ СТАЊА ЕИС СИНХРОНИХ ГЕНЕРАТОРА .....	- 61 -
Слика 33 МАТРИЧНИ ПРИКАЗ ГРЕШАКА МРЕЖЕ ЗА СВАКИ ПОДСКУП ПОДАТАКА – <i>CONFUSION MATRIX</i> .....	- 62 -
Слика 34 ПРИКАЗ РОС ФУНКЦИЈЕ (RECEIVER OPERATING CHARACTERISTICS) .....	- 63 -
Слика 35 ХИСТОГРАМ ГРЕШКЕ .....	- 63 -
Слика 36 УПОРЕДНИ ПРИКАЗ РЕЗУЛТАТА ВЕШТАЧКЕ НЕУРАЛНЕ МРЕЖЕ И ЕКСПЕРТА .....	- 65 -
Слика 37 ГРЕШКА ПРОРАЧУНА ОЦЕНЕ СТАЊА СИНХРОНИХ ГЕНЕРАТОРА НА СКУПУ ЗА ТЕСТИРАЊЕ .....	- 65 -

Слика 38 ПРИКАЗ АРХИТЕКТУРЕ КРЕИРАНОГ АУТОЕНКОДЕРА .....	- 68 -
Слика 39 ПРОЦЕС КРЕИРАЊА АУТОЕНКОДЕРА ЗА ПРОЦЕНУ СТАЊА ЕИС СИНХРОНИХ ГЕНЕРАТОРА.....	- 69 -
Слика 40 ПРИКАЗ ГРЕШКЕ У ЗАВИСНОСТИ ОД РЕДНОГ БРОЈА ИТЕРАЦИЈЕ .....	- 70 -
Слика 41 АНФИС ЕКСПЕРТСКИ СИСТЕМ ЗА ПРОЦЕНУ СТАЊА ЕИС СИНХРОНИХ ГЕНЕРАТОРА .....	- 74 -
Слика 42 ПРОЦЕС КРЕИРАЊА АНФИС ЕКСПЕРТСКОГ СИСТЕМА.....	- 75 -
Слика 43 КРЕИРАНИ АНФИС ЕКСПЕРТСКИ СИСТЕМ ЗА ПРОЦЕНУ СТАЊА ГЕНЕРАТОРА .....	- 76 -
Слика 44 ФУНКЦИЈЕ ПРИПАДНОСТИ ЗА ПОЈЕДИНЕ УЛАЗНЕ ВЕЛИЧИНЕ ДЕФИНИСАНЕ АЛГОРИТМОМ АНФИС-А.....	- 77 -
Слика 45 ВРЕДНОСТИ ИЗЛАЗНЕ ВЕЛИЧИНЕ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА У ФУНКЦИЈИ ПОЧЕТНОГ ФАКТОРА ДИЕЛЕКТРИЧНИХ ГУБИТАКА И СТАРОСТИ МАШИНЕ .....	- 78 -
Слика 46 ВРЕДНОСТИ ИЗЛАЗНЕ ВЕЛИЧИНЕ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА У ФУНКЦИЈИ ПОЧЕТНОГ ФАКТОРА ДИЕЛЕКТРИЧНИХ ГУБИТАКА И МАКСИМАЛНОГ ПРИРАШТАЈА ФАКТОРА ДИЕЛЕКТРИЧНИХ ГУБИТАКА .....	- 78 -
Слика 47 ВРЕДНОСТИ ИЗЛАЗНЕ ВЕЛИЧИНЕ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА У ФУНКЦИЈИ ЕЛЕКТРИЧНОГ ОТПОРА ИЗОЛАЦИЈЕ И ИНТЕЗИТЕТА ПАРЦИЈАЛНИХ ПРАЖЊЕЊА.....	- 79 -
Слика 48 ВРЕДНОСТИ ИЗЛАЗНЕ ВЕЛИЧИНЕ ФАЗИ ЛОГИЧКОГ ЕКСПЕРТСКОГ СИСТЕМА У ФУНКЦИЈИ ПОЧЕТНОГ ФАКТОРА ДИЕЛЕКТРИЧНИХ ГУБИТАКА И ИНДЕКСА АПСОРПЦИЈЕ ЕИС .....	- 79 -
Слика 49 УПОРЕДНИ РЕЗУЛТАТИ ЕКСПЕРТА И РЕЗУЛТАТИ АНФИС ЕКСПЕРТСКОГ СИСТЕМА .....	- 81 -
Слика 50 ГРЕШКА ПРОЦЕНЕ АНФИС ЕКСПЕРТСКОГ СИСТЕМА НА ПРИМЕРУ ОД 10 ГЕНЕРАТОРА .....	- 81 -
Слика 51 УПОРЕДНИ ПРИКАЗ РЕЗУЛТАТА АНФИС ЕКСПЕРТСКОГ СИСТЕМА И ОЦЕНА ЕКСПЕРТА НА СКУПУ ОД 20 МОДЕЛОВАНИХ ПОДАТАКА .....	- 83 -
Слика 52 АЛГОРИТАМ КОРИШЋЕН ПРИ КРЕИРАЊУ СТАБЛА ОДЛУКЕ КАО ЕКСПЕРТСКОГ СИСТЕМА ЗА ПРОЦЕНУ СТАЊА ГЕНЕРАТОРА .	- 86 -
Слика 53 КЛАСИФИКАЦИОНО СТАБЛО ЗА ПРОЦЕНУ СТАЊА ЕИС ГЕНЕРАТОРА.....	- 87 -
Слика 54 МАТРИЦА КОНФУЗИЈЕ КЛАСИФИКАЦИОНОГ СТАБЛА ЗА ПРЕДИКЦИЈУ СТАЊА ЕИС СИНХРОНИХ ГЕНЕРАТОРА .....	- 88 -
Слика 55 ПРИКАЗ ROC КАРАКТЕРИСТИКА ЗА КАТЕГОРИЈУ ДОБРИХ, СУМЊИВИХ И ЛОШИХ РЕЗУЛТАТА .....	- 88 -
Слика 56 ПРИКАЗ ГРЕШАКА ПРИ ПРЕДИКЦИЈИ НА СКУПУ ОД 538 УЗОРАКА.....	- 90 -
Слика 57 УПОРЕДНИ ПРИКАЗ ОЦЕНА ЕКСПЕРТА И МОДЕЛА НА БАЗИ СТАБЛА ОДЛУКЕ НА СКУПУ ОД 20 МОДЕЛОВАНИХ РЕЗУЛТАТА ИСПИТИВАЊА ГЕНЕРАТОРА .....	- 90 -
Слика 58 ГРЕШКА МОДЕЛА ЗАСНОВАНОГ НА СТАБЛУ ОДЛУКЕ НА БАЗИ ОД 20 МОДЕЛОВАНИХ ПОДАТАКА.....	- 91 -
Слика 59 УПОРЕДНИ ПРИКАЗ РЕЗУЛТАТА КРЕИРАНИХ МОДЕЛА НА МОДЕЛОВАНОЈ БАЗИ ПОДАТАКА.....	- 94 -
Слика 60 ФАКТОР КОРЕЛАЦИЈЕ НИЗА ВРЕДНОСТИ ПРОРАЧУНАТИХ МОДЕЛИМА МАШИНСКОГ УЧЕЊА И ОЦЕНА ДОДЕЉЕНИХ ОД СТРАНЕ ЕКСПЕРТА.....	- 95 -
Слика 61 МАПА РИЗИКА ЕКСПЛОАТАЦИЈЕ, ОДНОСНО МАПА ПРИОРИТЕТА ЗА ОДРЖАВАЊЕ.....	- 97 -
Слика 62 ПРИМЕР МАТРИЦЕ КОНФУЗИЈЕ МОДЕЛА .....	- 133 -

**СПИСАК ТАБЕЛА У РАДУ:**

ТАБЕЛА 1 ПРЕПОРУЧЕНЕ ГРАНИЧНЕ ВРЕДНОСТИ ИЗОЛАЦИОНОГ ОТПОРА $R_{60}$ СТАТОРСКОГ НАМОТАЈА [13] .....	- 15 -
ТАБЕЛА 2 ПРЕПОРУЧЕНЕ ГРАНИЧНЕ ВРЕДНОСТИ ИЗОЛАЦИОНОГ ОТПОРА $R_{60}$ И КОЕФИЦИЈЕНТА АПСОРПЦИЈЕ $K_A$ РОТОРСКОГ НАМОТАЈА [13].....	- 16 -
ТАБЕЛА 3 ПРЕПОРУЧЕНЕ ГРАНИЧНЕ ВРЕДНОСТИ ФАКТОРА ДИЕЛЕКТРИЧНИХ ГУБИТАКА $TGD$ СТАТОРСКОГ НАМОТАЈА НА $20^{\circ}C$ ПРЕМА ГРУПАМА КВАЛИТЕТА ЗА ОБРТНЕ МАШИНЕ (ТП-32) .....	- 18 -
ТАБЕЛА 4 ОРИЕНТАЦИОНЕ ВРЕДНОСТИ ИНТЕНЗИТЕТА ПРИВИДНОГ НАЕЛЕКТРИСАЊА $PD$ ПРЕМА ГРУПАМА КВАЛИТЕТА ЗА ОБРТНЕ МАШИНЕ .....	- 19 -
ТАБЕЛА 5 ПРИМЕР ИЗРАЧУНАТИХ "ИНДЕКСА СТАЊА" ГЕНЕРАТОРА ЗА РАЗЛИЧИТЕ УЛАЗНЕ ВРЕДНОСТИ.....	- 55 -
ТАБЕЛА 6 ПРИМЕР ФОРМИРАЊА КОНАЧНЕ ОЦЕНЕ ИЗ ПРОРАЧУНАТИХ ВРЕДНОСТИ ВЕШТ. НЕУРАЛНЕ МРЕЖЕ .....	- 64 -
ТАБЕЛА 7 ПРИМЕР ПРЕДИКЦИЈЕ СТАЊА АУТОЕНКОДЕРА .....	- 71 -
ТАБЕЛА 8 ПРИКАЗ РЕЗУЛТАТА АУТОЕНКОДЕРА .....	- 71 -
ТАБЕЛА 9 ПРИМЕР РЕЗУЛТАТА ПРЕДИКЦИЈЕ ANFIS СИСТЕМА .....	- 80 -
ТАБЕЛА 10 ПРИМЕР РЕЗУЛТАТА АНФИС ЕКСПЕРТСКОГ СИСТЕМА НА СКУПУ ОД 20 МОДЕЛОВАНИХ ПОДАТАКА О СТАЊУ ГЕНЕРАТОРА .....	- 82 -
ТАБЕЛА 11 УПОРЕДНИ ПРИКАЗ РЕЗУЛТАТА ЕКСПЕРТА И СТАБЛА ОДЛУКЕ .....	- 89 -
ТАБЕЛА 12 УПОРЕДНИ ПРИКАЗ ПРЕДНОСТИ И МАНА СВАКОГ ОД КОРИШЋЕНИХ МОДЕЛА.....	- 93 -
ТАБЕЛА 13 ПРИКАЗ РЕЗУЛТАТА ПРЕДИКЦИЈА СВИХ КРЕИРАНИХ МОДЕЛА НА СКУПУ ЗА ТЕСТИРАЊЕ ОД 20 МОДЕЛОВАНИХ РЕЗУЛТАТА .....	- 94 -
ТАБЕЛА 14 ПРИКАЗ ПРОРАЧУНАТИХ ИНДЕКСА СТАЊА ЗА SVM И RBM МОДЕЛ ОДРЖАВАЊА .....	- 97 -

**ЛИСТА СКРАЋЕНИЦА КОРИШЋЕНИХ У РАДУ**

ЕИС	-	Електрични изолациони систем
ТВМ	-	Time Based Maintenance
СВМ	-	Condition Based Maintenance
РВМ	-	Risk Based Maintenance
ТЕАМ	-	Temperature, Electrical, Ambient and Mechanical (factor)
ЕЕС	-	Електроенергетски систем
ПП	-	Парцијална пражњења
АНФИС	-	Адаптивни неуро-фази инферентни систем
ФЛС	-	Фази логички систем
Un	-	Номинални напон машине
HI	-	Health Index - индекс

## Садржај

1. Увод.....	- 1 -
1.1 МОТИВАЦИЈА .....	- 1 -
1.2 ДЕФИНИСАЊЕ ПРОБЛЕМА .....	- 2 -
1.3 ОБРАЗЛОЖЕЊЕ ПРЕДЛОЖЕНОГ РЕШЕЊА .....	- 3 -
1.4 КОНЦЕПЦИЈА ДОКТОРСКОГ РАДА.....	- 3 -
2. Изолациони системи синхроних генератора и фактори старења .....	- 5 -
2.1 ИЗОЛАЦИОНИ СИСТЕМИ СТАТОРСКИХ НАМОТАЈА .....	- 5 -
2.2 ВРСТЕ СТАТОРСКИХ НАМОТАЈА ПРЕМА КОНСТРУКЦИЈИ ЕИС.....	- 6 -
2.3 ИЗОЛАЦИОНИ СИСТЕМИ РОТОРСКИХ НАМОТАЈА.....	- 8 -
2.4 ФАКТОРИ СТАРЕЊА ЕИС НАМОТАЈА .....	- 9 -
2.4.1 ТЕРМИЧКА НАПРЕЗАЊА.....	- 9 -
2.4.2 ЕЛЕКТРИЧНА НАПРЕЗАЊА .....	- 10 -
2.4.3 АМБИЈЕНТАЛНА НАПРЕЗАЊА .....	- 11 -
2.4.4 МЕХАНИЧКА НАПРЕЗАЊА .....	- 12 -
2.4.5 ВИШЕСТРУКА НАПРЕЗАЊА.....	- 13 -
3. Методе испитивања изолационих система синхроних генератора.....	- 14 -
3.1 МЕРЕЊЕ ЕЛЕКТРИЧНОГ ОТПОРА ИЗОЛАЦИЈА НАМОТАЈА СТАТОРА И РОТОРА .....	- 15 -
3.2 МЕРЕЊЕ ФАКТОРА ДИЈЕЛЕКТРИЧНИХ ГУБИТАКА.....	- 17 -
3.3 МЕРЕЊЕ ИНТЕЗИТЕТА ПАРЦИЈАЛНИХ ПРАЖЊЕЊА .....	- 19 -
3.4 КОНТРОЛА МЕЂУЗАВОЈНЕ ИЗОЛАЦИЈЕ НАМОТАЈА РОТОРА .....	- 20 -
3.5 МЕТОДЕ ОДРЖАВАЊА ЕЛЕКТРОЕНЕРГЕТСКЕ ОПРЕМЕ.....	- 21 -
4. Методе вештачке интелигенције .....	- 24 -
4.1 ВРСТЕ ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ .....	- 27 -
4.2 ФАЗИ ЕКСПЕРТСКИ СИСТЕМИ.....	- 30 -
4.3 НЕУРАЛНЕ МРЕЖЕ.....	- 33 -
4.4 АУТОЕНКОДЕРСКЕ НЕУРАЛНЕ МРЕЖЕ.....	- 37 -
4.5 ANFIS – ADAPTIVE NEURAL – FUZZY INFERENCE SYSTEM.....	- 39 -
4.6 СТАБЛО КЛАСИФИКАЦИЈЕ–CLASSIFICATION TREE.....	- 39 -
4.7 АНАЛИЗА ДОСТУПНИХ ПОДАТАКА.....	- 42 -
5. Фази логички експертски систем.....	- 44 -
5.1 ПРИПРЕМА ПОДАТАКА .....	- 44 -
5.2 КРЕИРАЊЕ МОДЕЛА.....	- 45 -
5.3 ПРЕДИКЦИЈА СТАЊА НА ОСНОВУ МОДЕЛА .....	- 54 -
6. Вештачка неурална мрежа.....	- 57 -
6.1. ПРИПРЕМА ПОДАТАКА .....	- 57 -
6.2. КРЕИРАЊЕ И ЕВАЛУАЦИЈА МОДЕЛА.....	- 59 -
6.3. ПРЕДИКЦИЈА СТАЊА НА ОСНОВУ МОДЕЛА .....	- 64 -
7. Аутоенкодерска неурална мрежа .....	- 66 -
7.1 ПРИПРЕМА ПОДАТАКА .....	- 66 -
7.2 КРЕИРАЊЕ И ЕВАЛУАЦИЈА МОДЕЛА.....	- 68 -
7.3 ПРЕДИКЦИЈА СТАЊА НА ОСНОВУ МОДЕЛА .....	- 71 -
8. ANFIS - Adaptive Neural Fuzzy Inference system.....	- 73 -
8.1 ПРИПРЕМА ПОДАТАКА .....	- 73 -
8.2 КРЕИРАЊЕ И ЕВАЛУАЦИЈА МОДЕЛА.....	- 74 -
8.3 ПРЕДИКЦИЈА СТАЊА НА ОСНОВУ МОДЕЛА .....	- 80 -
9. Стабло одлучивања - <i>Decision tree</i> .....	- 84 -
9.1 ПРИПРЕМА ПОДАТАКА .....	- 84 -
9.2 КРЕИРАЊЕ И ЕВАЛУАЦИЈА МОДЕЛА.....	- 85 -
9.3 ПРЕДИКЦИЈА СТАЊА НА ОСНОВУ МОДЕЛА .....	- 89 -



10. Анализа модела и могућности примене .....	- 92 -
10.1 УПОРЕДНА АНАЛИЗА КРЕИРАНИХ ЕКСПЕРТСКИХ СИСТЕМА НА БАЗИ ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ.....	- 93 -
10.2 ОДРЖАВАЊЕ ПРЕМА СТАЊУ И ОДРЖАВАЊЕ ПРЕМА РИЗИКУ .....	- 96 -
11. Закључак и будући рад.....	- 99 -
11.1 ЗАКЉУЧАК.....	- 100 -
11.2 ПЕРСПЕКТИВА ПРИМЕНЕ И ДАЉИ РАЗВОЈ .....	- 101 -
ЛИТЕРАТУРА .....	- 102 -
Прилог 1 – База реалних података коришћена у раду .....	- 110 -
Прилог 2 База дефинисаних правила фази експертског система .....	- 113 -
Прилог 3 Програмски код вештачке неуралне мреже .....	- 115 -
Прилог 4 Приказ дела базе података употребљених за тренирање аутоенкодера .....	- 127 -
Прилог 5 Код за тренирање аутоенкодера у програмском пакету Матлаб .....	- 128 -
Прилог 6 Приказ вештачке базе употребљене за тестирање система и резултата појединих експертских система .....	- 130 -
Прилог 7 Кôд којим је креиран АНФИС експертски систем .....	- 131 -
Прилог 8 – Алати за процену квалитета примењених система и грешке при тренирању система .	- 132 -
Прилог 9 – Код функције којим је креирана прилагођена функција припадности .....	- 135 -
БИОГРАФСКИ ПОДАЦИ О АУТОРУ ДИСЕРТАЦИЈЕ.....	- 136 -
ИЗЈАВА О АУТОРСТВУ .....	- 137 -
ИЗЈАВА О ИСОВЕТНОСТИ ШТАМПАНЕ И ЕЛЕКТРОНСКЕ ВЕРЗИЈЕ ДОКТОРСКОГ РАДА .....	- 138 -
ИЗЈАВА О КОРИШЋЕЊУ .....	- 139 -

# 1. Увод

---

## 1.1 Мотивација


Поуздано и квалитетно снабдевање електричном енергијом представљају важне модерне императиве у секторима управљања, одржавања и експлоатације електроенергетског система (ЕЕС) [1; 2]. Нарочито у садашњости потпуно зависној од електричне енергије [3].

Још од свог зачећа, крајем 19-ог века, електрификација се заснивала на претварању механичке енергије у електричну енергију [4]. Синхрони генератори (у даљем тексту: генератори) су, стога, свакако један од најважнијих елемената у структури електроенергетских система с обзиром да готово искључиво представљају базну снагу ЕЕС-а целе планете. С обзиром да огромну улогу имају и у будућности, у обновљивим и чистим изворима који су у замаху развоја, без сумње се може тврдити да у ближој будућности може доћи до експанзије потребе и развоја нових генератора електричне енергије у форми обртних машина.

Имајући увид у снажне негативне ефекте по стабилност и поузданост ЕЕС-а које могу проузроковати изненадни испади синхроних генератора посебна пажња се поклања одржавању и благовременом планирању сервисних и инвестиционих активности којима би се животни век ових машина очувао унутар пројектованог и по могућству продужио без угрожавања поузданости [4-7].

Под комбинованим утицајем тзв. **TEAM** фактора, (*Temperature, Electrical, Ambient, Mechanical*) примењени материјали електричног изолационог система (ЕИС) непобитно старе те се њихова изолациона својства погоршавају.

Према појединим статистичким истраживањима, испади због проблема у ЕИС статора могу проузроковати и преко 50% испада, пре свега при експлоатацији хидрогенератора који раде у честим интермитентним режимима [5]. У литератури се истовремено могу пронаћи статистички подаци који указују да око 20% од укупног броја испада турбоагрегата настаје због проблема са статором [6], односно, у појединим случајевима и до 80% укупних кварова на обртним машинама [7].



**Слика 1** Статистика кварова синхроних машина: а) Сигре истраживање о кваровима на хидрогенераторима [5], б) статистика кварова турбогенератора [6], в) статистика кварова великих синхроних машина од стране осигуравајућег друштва[7]

Планирање активности везаних за заустављање синхроних генератора у сврхе ремонта, сервиса и сличних радњи доноси бројне позитивне ефекте на укупну поузданост система и техноекономску исплативост експлоатације синхроних генератора [8, 9]. Како би се благовремено планирале сервисне активности које могу предупредити дуготрајне и скупоцене кварове од изузетне је важности познавати стање електричног изолационог система с обзиром да проблеми у ЕИС представљају велики удео у укупним узроцима кварова синхроних генератора.

## 1.2 Дефинисање проблема

Процена стања изолационог система може се извршити на основу развијених метода испитивања ЕИС, као што су мерење фактора диелектричних губитака, електричног отпора изолације, интезитета парцијалних пражњења итд [10-13].

Међународни стандарди намењени ротационим машинама нису имплементирали граничне вредности за већину примењених испитних метода у стандардној инжењерској пракси у Србији али и свету [14], те се процена стања често своди на одређени степен субјективне процене испитивача, одговорних инжењера одржавања или интерне препоруке одређених индустријских или електропривредних предузећа и анализу промене измерених вредности у времену. Чак и приликом оваквих тумачења, прилично је лако дефинисати налаз о резултатима једне испитне методе. Међутим кад се анализира више примењених испитних метода, изузетно је тешко објединити сва сазнања у једну потпуно објективну оцену.

Истовремено, чести интермитентни погони у значајној мери погоршавају радне околности ЕИС-а због честих термичких циклуса [11]. Узимајући у обзир и еквивалентну старост генератора, која узима у обзир и број покретања генератора, могуће је потпуније сагледати стање ЕИС синхроног генератора те објективније планирати одређене сервисне активности, међутим овај податак често није доступан нити систематизован у постојећим базама података.

На основу квалитетне дијагностике стања могу се потом, донети благовремене одлуке о сервисирању, ревитализацији или замени појединих делова синхроних генератора. У циљу практичнијег распореда углавном ограничених финансијских ресурса, неопходно је изузетно

пажљиво планирати неопходна улагања, имајући у виду приоритетне. Овакво доношење одлука се заснива на тренутном стању ЕИС генератора (*CBM - Condition Based Maintenance*), али и на основу битности генератора у систему и његових економских импликација.

Метода која сагледава оба фактора за доношење одлуке са приоритетима се назива одржавања према ризику (*RBM - Risk Based Maintenance*) [11-17].

### **1.3 Образложење предложеног решења**

Истраживања у оквиру докторске дисертације обухвата преглед и анализу метода за испитивање и дијагностику стања ЕИС синхроних генератора са акцентом на примени вештачке интелигенције са циљем аутоматизације процеса анализе резултата и објективне процене стања ЕИС. Овако креиран експертски систем би имао функцију софтверског асистента, и омогућавао би брзу анализу великог броја података на поновљив начин.

У раду се не настоји бавити проблематиком самог начина функционисања појединих алгоритама машинског учења и софтверских детаља, премда ће укратко сваки од система бити објашњен, већ је акценат на њиховој практичној примени и употребној вредности.

Основни циљ је да се применом вештачке интелигенције развије један или више софтверских експертских система за поуздану и објективну процену стања ЕИС. Развијени софтверски експертски системи ће бити тестирани на скупу реалних података из редовних електричних испитивања синхроних генератора као и на моделованој, вештачки креираној бази података. Базе података ће претходно бити прилагођене тако да одговарају улазним подацима појединих експертских система. База реалних података ће бити коришћена за обуку, тренирање појединих система машинског учења.

### **1.4 Концепција докторског рада**

Рад је конципиран кроз 11 поглавља и 9 прилога. Поред уводног, у другом поглављу представљене су основне конструкције изолационих система статора и ротора синхроних генератора. Дат је преглед основних фактора старења изолационих система као и увид у механизме њиховог деловања. Кроз преглед метода испитивања у поглављу 3 направљен је осврт на стандарде, критеријуме и начине тумачења резултата што читаоца уводи у проблем који се настоји решити применом модерних алгоритама вештачке интелигенције. Такође, кроз једно потпоглавље дат је приказ еволуције општих модела одржавања система у електроенергетици.

У четвртном поглављу су приказани основни појмови вештачке интелигенције који ће бити коришћени у раду. Потпоглавља укратко дају приказ сваке од употребљених алгоритама машинског учења са циљем да се јасно укаже на начине креирања сваког од модела.

У наредних 5 поглавља објашњени су кључни кораци приликом израде сваког од експертских система: Припрема и обрада базе података, креирање и евалуација модела и предикција стања на основу модела. Предикција стања се врши на истом скупу података за све експертске системе како би се након тога у поглављу 10 извршило поређење креираних модела.

У десетом поглављу биће приказан и концепт начина употребе добијених резултата кроз мапе ризика у циљу реализације и визуелног представљања резултата RBM.

Поглавље 11 представља закључак аутора изведен током рада на наведеним моделима и пружа предлог будућег развоја и имплементације сазнања стечених у раду на проблематици коју теза обрађује.

## 2. Изолациони системи синхроних генератора и фактори старења

---

### 2.1 Изолациони системи статорских намотаја

Технологија израде статорских намотаја је увелико унапредовала развојем савремених производних система и материјала. Највећи искорак је учињен у погледу аутоматизације процеса који су у зачетку вршени ручно, али и развојем и применом нових изолационих материјала [11, 18-21]. У самом повоју технологије израде ЕИС статора коришћени су материјали који су у том тренутку развоја били доступни, као што су папир, гума и сл. Убрзо се као изузетно погодан истакао лискун (тињац, мика) који представља основу и свих савремених ЕИС, како униформних (профилисаних) тако и Ребел намотаја.

Лискун је природни материјал на бази силицијума са изузетним изолационим карактеристикама односно способношћу да подноси напонска напрезања. Основа изолације од лискуна се у технолошком процесу удружује са различитим испунама - носачима чиме се добијају изолациони полупроизводи у виду мика-трака, мика-фолија различитих димензија и карактеристика. Намотавањем ових изолационих трака у више слојева на бакарне проводнике формира се главна изолације која се затим термички третира различитим везивним материјалима, у условима високог вакуума, у циљу боље импрегнације и максималног уклањања заосталих шупљина [11, 19, 20].

Шупљине заостале у процесу производње представљају специфична „слаба места“, односно места у којима се појављују парцијална пражњења. Парцијална пражњења проузрокују даљу деградацију изолације и на послетку могу довести до потпуног пробоја.

Као везивни материјал у почетку су се користили материјали на бази битумена, међутим развојем технике производње полиестерских, а потом и епоксидних смола, битумен је у потпуности потиснут. Применом епоксидних смола добија се изолациони систем који, поред својих одличних и постојаних изолационих карактеристика, има компактност и довољну чврстину да подноси сва механичка напрезања током погона.

Осим тога, ЕИС намотаја синхроних машина мора поседовати и добру топлотну проводљивост која омогућава ефикасан пренос топлоте и тиме хлађење бакарних проводника. Лискун се одржао као основа електроизолационих система синхроних генератора на основу својих веома добрих физичких карактеристика:

- веома велика диелектрична чврстоћа,
- мали диелектрични губици,
- велике површинске и запреминске отпорности,
- одлична термичка стабилност и до  $(650-870)^{\circ}\text{C}$ ,
- добар отпор оксидисању услед електричних пражњења,
- флексибилност и еластичност у танким слојевима,
- способност да издржи нагле и широке промене температуре, а да при томе не изгуби знатно своја физичка и електрична својстава,
- мали термички коефицијент,
- незапаљивост,
- потпуна инертност према води, киселинама, базама и растварачима и
- велика отпорност на радиоактивно зрачење.

## 2.2 Врсте статорских намотаја према конструкцији ЕИС

У зависности од снаге, димензија и напонског нивоа, статорски намотаји се према начину израде могу поделити у следеће врсте:


- неуниформни (расути, непрофилисани) намотаји,
- униформни (профилисани) намотаји и
- Ребел (*Roebel*) намотај.

Неуниформни (расути, непрофилисани) намотаји израђују се готово искључиво од тзв. лак-жице и формирају од готових секција (Слика 2а). С обзиром да се при намотавању ових намотаја не води рачуна о диспозицији навојака, посматрано са становишта расподеле електричног напрезања, навојак који представља извод и који је у раду на фазном напону, може се наћи непосредно поред навојка који је у раду на јако малом потенцијалу, чиме се максимално напреже изолација. На овај начин се обично израђују намотаји за електричне обртне машине мањих снага и напонских нивоа испод 1000 V.

Униформни (профилисани) намотаји израђују се за машине назначених напона изнад 1000 V. Начињени су од припремљених снопова изолованих елементарних проводника формираних у секције које су изоловане, пресоване, термички обрађене и обликоване према геометрији статорског језгра (слика 2б). Пажљивим дизајнирањем обезбеђује се да се суседни навојци минимално напонски напрежу, односно да напон између два суседна навојка буде

што је могуће мањи. На овај начин, могуће је употребити тању изолацију између навојака, односно могуће је постићи већи однос снаге машине у односу на њене димензије и масу.

Ребел (*Roebel*) намотај – уобичајено се назива по имену немачког инжењера и проналазача Лудвига Ребела (*Ludwig Röebel*) и представља специфичну подврсту униформног намотаја. Наиме, машине већих снага захтевају веће попречне пресеке проводника и већу крутост намотаја. Истовремено веће снаге машине подразумевају и увећање у погледу физичких димензија. Из тог разлога би процес уметања обе стране секција као на слици 2б било тешко изводљиво.




а)



б)

**Слика 2 Примери а) неуниформног и б) једне секције униформног намотаја**

При томе, ризикује се оштећење изолације приликом уметања тако великих секција. Стога се намотаји машина већих снага израђују од Ребел полунавојака – статорских штапова (слика 3). Ребел полунавојци се израђују од појединачно изолованих елементарних бакарних проводника који се приликом формирања (израде) преплићу-транспонују у циљу минимизирања губитака услед паразитних струја и скин ефекта. На овај начин се по један полунавојак умеће у жлеб, што поједностављује израду, нарочито великих и снажнијих генератора.



а



б



в

**Слика 3 Приказ Ребел (Röebel) статорског штапа: а) приказ елементарних проводника Ребел штапа пре облагања основном изолацијом, б) готови статорски штапови, в) попречни пресек статорског штапа са шупљим проводницима за проток расхладне воде**




Предмет овог рада су снажни синхрони генератори називних напона 6kV и више, чији се статорски намотаји готово искључиво израђују као Ребел или профилисани намотаји те ће стога све напред написано бити искључиво везано за ова два типа ЕИС статорских намотаја.

### 2.3 Изолациони системи роторских намотаја

Електрични изолациони системи роторских намотаја подразумевају у суштини два основна елемента ЕИС [11, 18]: изолацију између навојака ротора и изолацију према телу ротора. Конструкционо, разликују се ротори и самим тим елементи ЕИС ротора са истакнутим половима типичним за хидрогенераторе (Слика 4а), и ротори цилиндричног облика уобичајни за турбогенераторе (Слика 4б).

Роторски намотаји су димензионисани за значајно ниже напонске нивое, у поређењу са напонима статорских намотаја. Чак и за снажније синхроне генераторе, ова вредност не премашује 600-700Vdc, те се стога велика пажња при дизајнирању поклања управо факторима који највише утиче на деградацију ЕИС роторских намотаја: механичко и температурно напрезање. Роторски намотаји у погону су изложени константном механичком напрезању проузрокованом центрифугалним силама услед вртње ротора. Истовремено, побудна струја ротора проузрокује значајне Џулове губитке и загревање ротора. Ови фактори најчешће доводе до међузавојних кратких спојева и земљоспојева.



Слика 4 Приказ различитих конструкција ротора синхронних машина: а) цилиндрични, б) са истакнутим половима

Ротор може несметано наставити погон у случају једног земљоспоја. Међутим у случају појаве и другог земљоспоја стварају се услови за формирање струјне контуре са великим струјама које протичу кроз тело ротора. Услед тога могу се изазвати локална прегревања па чак и локализовано топљење роторског тела. Модерни системи електричних заштита ротора се формирају често у виду аларма који детектује први земљоспој ротора али дозвољава наставак погона генератора. Међутим, друга заштита аутоматски искључује генератор уколико детектује други земљоспој.

Међузавојни кратки спојеви такође не условљавају хитан прекид рада генератора. С обзиром да је ротор напајан једносмерним напоном при краткоспојеним завојцима не долази до ефекта трансформатора као код наизменичних напона, те кроз краткоспојене завојке неће протичати значајно већа струја и изазвати прегревање. Али, скраћен намотај ротора може проузроковати асиметрично магнетно поље ротора те изазвати повећане вибрације.

Истовремено, увећане вибрације се могу појавити услед неравномерног загревања ротора у случају појаве међузавојног кратког споја, с обзиром да ће у жљебовима ротора у којима није настао кратак спој јачина електричне струје бити већа.

Из описаног се лако може закључити да се дефекти на ротору могу толерисати извесно време, и да је од изузетне важности утврдити њихово постојање али да генератор може наставити погон док се не стекну адекватни услови за поправку.

## 2.4 Фактори старења ЕИС намотаја

Електрични изолациони систем генератора, током рада суочава се са неповратним процесима деградације изолационих карактеристика ЕИС-а што може довести до изненадних и непредвидивих кварова, а самим тим и до смањења поузданости рада обртних машина [22-27]. Деценијама су произвођачи, услед недостатка искуства, често правили предимензионисане машине. Тако су се на пример, намотаји правили од бакарних проводника значајно већег попречног пресека од пројектованог, како би се умањила могућност њиховог прегревања. Истовремено, основна изолација израђивана је са великим фактором сигурности у односу на прорачунску вредност у сврху спречавања електричних пробоја. Такав приступ водио је ка прекомерним трошковима израде што је у модерним условима пословања недопустиво.

ЕИС обртних машина током редовног погона је изложен деловању углавном више различитих фактора деградације, као што су температурно и напонско напрезање, механичко напрезање као последица вибрације услед електродинамичких сила, као и различитих амбијенталних утицаја, присуства нечистоћа, те хемијски агресивних материја и сл. Процес старења ЕИС најчешће се у литератури објашњава се садејством више обједињених фактора тзв. ТЕАМ фактора [12,13, 19-27].

### 2.4.1 Термичка напрезања

Овај вид напрезања представља вероватно најчешћи узрок постепеног погоршања стања изолације као и њеног потпуног оштећења, па је према томе изолациони систем намотаја статора класификован према способности да издржи одговарајућа термичка напрезања [11-13, 22, 23, 26]. Радна температура изолације је одређена џуловим губицима услед оптерећења, вихорним струјама и додатним губицима у бакарним проводницима, као и температурним оптерећењем услед загревања магнетног кола. Повишена радна температура, која се може јавити услед свих наведених разлога, узрокује хемијску реакцију при чему изолација постаје кртија, а такође изазива раслојавање основне изолације у профилисаним намотајима.

Промена оптерећења машине узроковаће промену температуре намотаја. Варијације термичког напрезања заправо представљају термо-механичко напрезање. Ако температура намотаја брзо порасте од собне до радне, бакарни проводници ће се проширити аксијално. Имајући у виду да савремени изолациони материјали имају мањи коефицијент термичког ширења, они се мање загревају након промена оптерећења машине, а као резултат тога долази до појаве смицања између бакарних проводника и основне изолације. Код статорских

намотаја, након много термичких циклуса изазваних променом оптерећења машине, долази до слабљења веза између бакарних проводника и изолације.

Брзина и степен деградације појединог материјала зависиће од његових термичких карактеристика - подносиве температуре и радне температуре којој је изложен током погона. Уколико је материјал изабран у складу са очекиваним радним температурама, брзина његовог термичког старења биће очекивана и у складу са пројектованим радним (животним) веком.

## 2.4.2 Електрична напрезања

Димензије (дебљина) изолације статорских намотаја нижег назначеног напона првенствено је одређена разматрањима њених механичких напрезања који се очекују током погона. Према томе, изолација мора имати задовољавајућу дебљину тако да издржи сва електрична и механичка напрезања која се јављају у погону машине. Наизменични напон може додатно да доприноси старењу изолације услед парцијалних пражњења.

Као и у случају термичког напрезања постоји праг електричног напрезања (минимална јачина електричног поља) испод ког не постоји ефективно старење изолације, при чему је тај праг заправо напон гашења ПП (*Discharge Extinction Voltage - DEV*), а електрично напрезање количник *DEV* и дебљине изолације.

Електрично старење настаје као последица деловања напонских напрезања на изолациони систем. Иако једносмерна (*DC*), односно транзијентна компонента доприносе процесу старења изолације, погонска наизменична напонска напрезања су доминантан чинилац. Електрично старења делује како на изолациони систем намотаја статора и ротора, тако и на изолациони систем магнетног кола.

По дефиницији, квар на намотајима дешава се у тренутку када диелектрична чврстоћа изолационог система падне на вредност која је мања од нивоа напонских напрезања и/или транзијентних пренапона која прате редовни погон. Треба напоменути да квар (пробој) изолације као последица опадања диелектричне чврстоће не мора нужно да буде последица деловања електричних напрезања, већ може да се деси и као последица термичког и/или механичког механизма старења.

Основу механизма електричног старења изолационог система представљају електрична пражњења која настају у машини, односно у њеном изолационом систему преваходно намотаја статора, односно ротора, али и на изолацији магнетног кола.

Када говоримо о електричним пражњењима на изолацији намотаја статора мисли се на парцијална пражњења (ПП), некада означаваним и као корона. ПП чине струјни импулси, који резултују прерасподелом наелектрисања.

Генерално, ПП настају у изолацији намотаја назначеног напона реда 5 kV и више. ПП се карактеришу напоном појаве, односно гашења (прекидања), који је диктиран локалном концентрацијом електричног поља у гасној шупљини или на некој површини. То су минимални напони при којима се јављају и ишчезавају ПП на посматраном месту дефекта. Тако је код статорских намотаја ваздухом хлађених генератора већа вероватноћа настанка ПП, јер је напон појаве нижи у ваздуху (на атмосферском притиску) него код водоником хлађених машина.

ПП на структуру изолације делују као "убоди игле" који појединачно могу да буду "мање болни", чак наизглед "безазлени" за изолацију. Међутим, њиховим дуготрајним, вишеструким и све интензивнијим појавама и деловањем врши се значајна деградација ЕИС.

### 2.4.3 Амбијентална напрезања

Под овим видом напрезања подразумева се скуп више фактора који се јављају у амбијенталном окружењу генератора, а могу довести до квара машине. Неки од њих су:

1. висока влажност, односно влага кондензована на намотајима,
2. уље или кондензоване уљне паре из лежајева или заптивних система у водоником хлађеним машинама,
3. графитна и азбестна прашина као последица трошења угљених четкица односно кочионих плочица,
4. разне врсте хемикалија и агресивних материја,
5. присуство озона као последица површинских ПП,
6. присуство абразивних честица у машина хлађеним ваздухом или водоником,
7. прљавштина и друге нечистоће доведене у машину из околне средине, пепео, угљена прашина, разни хемијски остаци итд и
8. радиоактивно зрачење (у нуклеарним електранама).

Сваки од наведених фактора утиче на изолацију намотаја обртних машина на различит начин, при чему у комбинацији са неком другом врстом напрезања може значајно допринети убрзаном старењу изолације.

Тако на пример, влага или уље у комбинацији са нечистоћама могу довести до формирања слабопроводног слоја преко изолације, односно увећаних површинских струја, а самим тим повећања могућности за прескок.

Такође, мешавина влаге, уља, прљавштине може да блокира - зачепи вентилационе путеве за хлађење између навојака у главама намотаја, где услед неадекватног хлађења може доћи до ризика од термичког оштећења. Уље које продре унутар жлебова може у својству мазива да битно смањи трење и олакша померање/вибрације полунавојака - штапова унутар жлебова, што може поспешити вибрације и хабање изолације.

Разне хемикалије, киселине, озон могу довести до распадања изолације смањујући њену механичку чврстоћу. Сви поменути фактори могу бити присутни при тестовима убрзаног старења, али се не може са сигурношћу знати у којој мери директно утичу на степен оштећења изолације.

Са друге стране радиоактивно зрачење се мало разликује од осталих фактора јер оно може довести до раскидања хемијских веза унутар изолације, па чак и до пуцања саме изолације. Већи ниво радиоактивног зрачења убрзава старење изолације. Сам процес радиоактивног зрачења више је приближан термичком погоршању стања изолације, уз изузетак да знатно више утиче на површинско старење изолације за разлику од термичког напрезања где је више напрегнут унутрашњи део изолације.

#### 2.4.4 Механичка напрезања

Постоји неколико извора механичких напрезања. Изолациони систем роторских намотаја је изложен великој центрифугалној сили која је неосцилујућа сила и тежи да смрска изолацију. Различитим краткотрајним механичким тестовима може да се оцени да ли је у већини случајева изолација способна да издржи те силе или не.

Код статорских намотаја основни узрок механичког напрезања је сама радна наизменична струја која изазива електромагнетне силе које делују између проводника. До вибрација намотаја у жлебовима ће доћи услед деловања магнетних сила ако учвршћење (заклињеност) полунавојака - штапова временом ослаби, а последица свега тога је повећана абразија/хабање основне изолације. Сличне силе се јављају и у главама намотаја где, такође услед олабављености бочних веза - глава, долази до вибрација између самих навојака или између навојака и бандажних прстенова што опет доводи до абразије изолације.

Трећи, веома важан, извор механичких напрезања су транзијентни (прелазни) режими (укључивање/искључивање машине из погона, синхронизација машине на мрежу) у којима се јављају огромне транзијентне струје које су пет и више пута веће од струја статора током нормалног погона. Као резултат тих струја јављају се електродинамичке силе 25 и више пута веће од оних током нормалног погона. Једносмерна компонента тих електродинамичких сила има тенденцију да савија полунавојке - штапове у главама намотаја статора, при чему долази до њиховог пуцања, ако не могу да издрже напрезање при деловању тих сила. Ако су транзијентни периоди учестали (машина се много пута стартује и зауставља), временом може доћи до губитка учвршћења и међусобног кретања полунавојака - штапова у главама намотаја што даље води до хабања изолације намотаја чак и у нормалним условима рада машине.

Механизам механичког старења доминантно је узрокован механичким напрезањима којима је директно или индиректно изложен изолациони систем магнетног кола, односно намотаја. Напрезања која су фактор механичког старења настају деловањем електромагнетних сила и настале резонансе услед губитка заклињености намотаја у жлебном делу или учвршћења у потпорама и бандажним прстеновима глава намотаја у зони бочних веза - глава намотаја, деформација и промена облика, абразије (трошења/хабања), као и деловањем разних амбијенталних фактора који нарушавају механичке карактеристике изолације.

Током погона може да дође до појаве вибрација у магнетном колу као последица губитка/пуцања учвршћења магнетног кола за конструктивне елементе кућишта статора, губитак учвршћења глава намотаја за потпоре и бандажне прстенове које своје вибрације преносе на магнетно коло, али и несиметричног фазног оптерећења. И без наведених додатних напрезања, сам редован погон генерише одређен "нормалан" (пројектован) ниво вибрација магнетног кола услед електромагнетних сила учестаности 100 Hz. Лабаво магнетно коло осцилује, помера се у ритму сила учестаности 100 Hz што може да произведе релативно кретање у односу на намотаје и постепено трење (абразију), за почетак површине а временом и унутрашњост главне изолације водећи ка пробоју.

## 2.4.5 Вишеструка напрезања

Чињеница је да многи кварови и оштећења изолације намотаја обртних машина нису последица само једног од описаних, већ је најчешће последица интеракција најмање две врсте напрезања које би довеле до погоршања стања изолације намотаја. Неки од примера који се између осталог могу додати су:

Термичко напрезање код профилисаних статорских намотаја утиче на раслојавање изолације омогућавајући парцијалним пражњењима да својим активностима даље погоршају већ нарушено стање изолације.

Пуцање бакарних проводника код водом хлађених машина узроковано замором услед вибрација у главама намотаја, у комбинацији са водом која цури, води ка деламинацији изолације допуштајући тако даљи развој парцијалних пражњења, при чему у зависности од степена оштећења изолације може доћи до земљоспоја.

Оштећења полупроводног премаза полунавојака - штапова код профилисаних намотаја услед лоше израде током производње истих или високе радне температуре доводе до појаве парцијалних пражњења стварајући озон који, како је већ речено, лоше утиче на изолацију намотаја.

Кључна одлика је узајамно деловање минимум две врсте напрезања да би дошло до било каквог оштећења или квара, тј. много брже долази до нарушавања стања изолације, него у случају дејства само једног од фактора напрезања.

Дакле, модели старења изолације који омогућавају произвођачима машина да предвиде способност изолације да издржи одређена напрезања у разним ситуацијама веома су сложени и донекле непрактични.

### 3. Методе испитивања изолационих система синхроних генератора

---

Током претходних неколико деценија развијене су бројне електричне методе испитивања превентивне контроле ЕИС статорских и роторских намотаја. Иако се велики број тих метода може сматрати уобичајним и традиционалним, критеријумске вредности за неке од њих нису једнозначно дефинисани или уопште нису стандардизовани за одређене случајеве из праксе [8,9, 11-14, 19-33]. Методе које се најчешће користе у уобичајној дијагностичкој пракси испитивања синхроних генератора и које ће бити уврштене у експертским системима креираним у овом раду су:

- мерење електричног отпора изолације ЕИС намотаја статора,
- мерење електричног отпора изолације ЕИС намотаја ротора,
- мерење фактора диелектричних губитака и капацитета ЕИС намотаја статора,
- мерење интезитета парцијалних пражњења ЕИС намотаја статора и
- контрола међузавојне изолације ротора.

Превентивно, врше се и друга испитивања, којима се стиче одређена погонска сигурност у експлоатацији машине али ове методе углавном не пружају много дијагностичких информација које су од значаја у превентивној контроли или је изузетно тешко поставити једнозначне критеријумске вредности за поједина мерења за која се оцена резултата врши искуствено. За одређени део тих испитивања на просторима електроенергетског система Србије још увек не постоје значајна искуства, с обзиром на то да се превентивна контрола електричних машина у пуном опсегу убрзано развија тек неких 15-ак година.

На пример, у ова испитивања спадају и испитивање ЕИС статорског и роторског намотаја повишеним доведеним једносмерним или наизменичним напоном. Резултат овог

испитивања је прост резултат прошао/није прошао. Такође, при мерењу једносмерних струја одвода кроз ЕИС равномерним подизањем испитног напона – *Ramp test* –врши се поређење измерених карактеристика и тумачење њиховог облика, али је помак у примени ове методе у електроенергетским постројењима у Србији направљен тек пре неколико година, те не постоје довољна искуства у погледу ефикасности и дијагностичког значај методе [20].

### 3.1 Мерење електричног отпора изолација намотаја статора и ротора

Електрични отпор изолационог система је вредност директно сразмерна дебљини и квалитету примењеног изолационог материјала и обрнуто пропорционална додирној површини са проводником [11-13, 19, 32, 34]. Истовремено, може се употребити као индикатор овлажености, задржаности или остарелости, похабаности ЕИС намотаја. Мерење се у пракси врши готово искључиво комерцијалним наменским уређајем директном применом Омовог закона као однос примењеног једносмерног испитног напона и измерене струје кроз ЕИС. Ова величина се мери у 15-тој ( $R_{15}$ ) и 60-тој секунди ( $R_{60}$  тј.  $R_1$ ). У појединим случајевима мери се и 10 минута након успостављања стабилне вредности испитног напона ( $R_{10}$ ). Из односа измерених отпора срачунавају се индекс апсорпције:

$$K_a = \frac{R_{60''}}{R_{15''}} \quad (1)$$

и индекс поларизације

$$IP = \frac{R_{10'}}{R_{60''}} \quad (2)$$

који дају информацију о овлажености ЕИС намотаја.

Мерни спојеви у којима се врши мерење изолационих отпора, као и свих осталих даље наведених *Off-line* електричних метода, је између намотаја једне фазе и друга два намотаја који су уземљени осим у случају неразвезивог звездишта машине када се мери изолациони отпор између све три фазе заједно и уземљених делова машине.

Мерење на роторском намотају се врши између извода роторског намотаја и уземљеног тела ротора – вратила.

Вредност испитног напона при коме се врши мерење одређује се према назначеном напону објекта који се испитује. Сврставање у групе квалитета се врши према вредностима изолационог отпора и поларизационог индекса, за статорске намотаје према табели 1 и за роторске намотаје према табели 2 [13].

**Табела 1 Препоручене граничне вредности изолационог отпора  $R_{60}$  статорског намотаја [13]**

ЕИС	Оцена	$R_{60}(M\Omega)$	$K_a = \frac{R_{60}}{R_{15}}$	$IP = R_{10}/R_1$
	добро	$\geq 50U_n(kV)$	$\geq 2$	$\geq 4$
	сумњиво	$\geq 10U_n(kV)$	$\geq 1,3$	$\geq 2$
	лоше	$< 10U_n(kV)$	$< 1,3$	$< 2$



Табела 1 се односи на машине које се не хладе директно водом, при чему је  $U_p$  назначени напон статорског намотаја. За машине чији се намотаји директно хладе водом изолациони отпор зависи од карактеристика воде и  $R_{60}$  мора да буде веће од реда  $1\text{ M}\Omega$  осим ако произвођач машине не гарантује сигуран погон са мањом вредности изолационог отпора. Карактеристична величина при извођењу овог испитивања на водом хлађеним машинама је коефицијент апсорпције који у овом случају износи 1, тачније вредност електричног отпора изолације се практично не мења у времену. Ова појава се директно повезује са поларизационим својствима расхладне воде.

**Табела 2 Препоручене граничне вредности изолационог отпора  $R_{60}$  и коефицијента апсорпције  $K_a$  роторског намотаја [13]**

Група квалитета ЕИС	$R_{60}(\text{M}\Omega)$	$K_a = R_{60}/R_{15}$
I група	$\geq 10U_p(\text{kV})$	$\geq 2$
II група	$< 10U_p(\text{kV})$	$\geq 1,3$
III група	$< 1$	$< 1,3$

У табели 2 критеријумске вредности се рачунају на основу назначеног побудног напона намотаја ротора  $U_p$ .

У циљу што поузданије дијагностике, препоручује се да температура ЕИС намотаја у току испитивања буде од  $10\text{ }^\circ\text{C}$  до  $40\text{ }^\circ\text{C}$ , како би се избегло прерачунавање измерене вредности на референтну вредност температуре. Тренутно не постоје универзални коефицијенти којима би овај поступак могао бити урађен са великом поузданошћу.

### 3.2 Мерење фактора диелектричних губитака

Фактор диелектричних губитака -  $\text{tg}\delta$  је однос активне  $I_r$  и капацитивне  $I_c$  компоненте укупне струје  $I$  кроз ЕИС тј. однос активне и реактивне снаге, изражен у процентима према релацији [13, 31].

$$\text{tg}\delta = \frac{I_r}{I_c} \cdot 100\% \quad (3)$$

Мерење се врши мерним мостовима (Шерингов, Винов, Глинов) или савременим специјалним мерним уређајима са могућношћу мерења снага високе тачности и при малим вредностима фактора снаге  $\cos\varphi$  и то на статорским намотајима синхроних генератора. Примена ове методе на нисконапонским намотајима попут намотаја ротора или намотаја статора нисконапонских мотора није уобичајна.

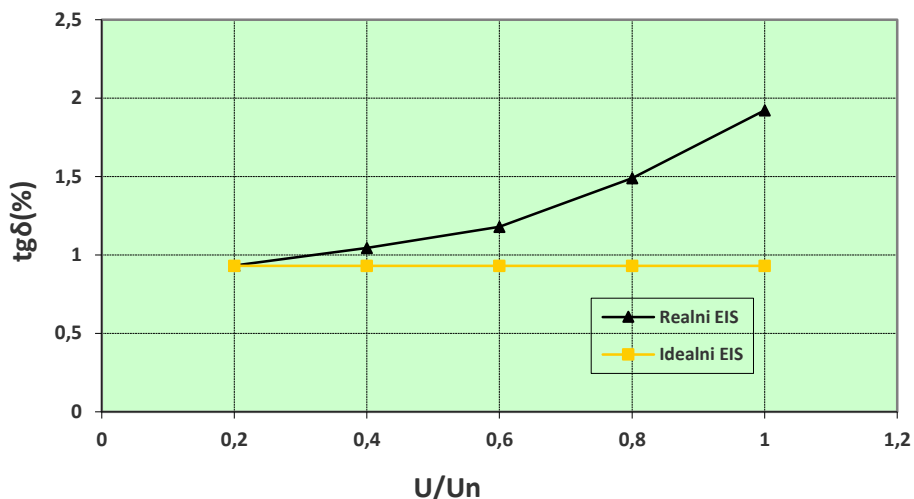
Напојна опрема за ово испитивање, а уједно за сва високонапонска испитивања наизменичним напоном од 50 Hz, мора да има регулацију напона до максималне вредности испитног напона  $U_{isp}$  и довољну привидну снагу капацитивне природе која се може одредити према једначини:

$$S \approx Q = \omega C U_{test}^2 \quad (4)$$

при чему је:

- $Q$  - реактивна снага,
- $C$  - капацитет испитиваног објекта
- а  $\omega=2\pi f$  - кружна учестаност.

Могуће је користити пригушнице за компензацију ове капацитивне снаге чиме би се снизила снага напојне опреме. Уз напојну опрему корисно је користити варничар као заштиту за случај појаве пренапона у току испитивања. Испитни напон се у корацима по  $0,2U_n$  подиже до назначеног напона машине. Вредности које су од значаја за процену стања ЕИС су почетна вредност  $\text{tg}\delta_{0,2}$  ( $\text{tg}\delta$  при  $0,2U_n$ ) и максимални прираштаји  $\text{tg}\delta$  при подизању напона. Прираштаји, односно инкременти вредности фактора диелектричних губитака са порастом испитног напона су директна последица јонизације шупљина унутар ЕИС, и представљају својеврсну меру несавршености ЕИС статорских намотаја (Слика 5).



Слика 5 Пример зависности фактора диелектричних губитака савршеног и реалног ЕИС

Резултати мерења пружају процену општег стања ЕИС намотаја и очуваност квалитета примењених материјала при изради ЕИС. Тако, вредност  $tg\delta$  при малим вредностима испитног напона дају увид у глобални квалитет ЕИС статорског намотаја, док пораст  $tg\delta$  са испитним напоном указују на велики број деламинација и шупљина у запремини ЕИС.

Препоручене критеријумске вредности се могу пронаћи у одговарајућим стандардима, међутим не дефинишу се за цео статорски намотај већ за појединачне штапове [13, 14, 31, 35]. У табели 3 су приказане оријентационе вредности које се употребљавају у при анализи резултата испитивања ЕИС статорских намотаја према [13].

Табела 3 Препоручене граничне вредности фактора диелектричних губитака  $tg\delta$  статорског намотаја на  $20^{\circ}\text{C}$  према групама квалитета за обртне машине (ТП-32)

Оцена ЕИС	$tg\delta$ 0,2(%)	$\Delta tg\delta_{\text{max}} / 0,2U_n$	
		(0,2 - 0,6) $U_n$	(0,6 - 1,0) $U_n$
Добро	$\leq 30 \times 10^{-3}$	$\leq 6 \times 10^{-3}$	$\leq 8 \times 10^{-3}$
Сумњиво	$\leq 40 \times 10^{-3}$	$\leq 12 \times 10^{-3}$	$\leq 16 \times 10^{-3}$
Лоше	$> 40 \times 10^{-3}$	$> 12 \times 10^{-3}$	$> 16 \times 10^{-3}$

### 3.3 Мерење интензитета парцијалних пражњења

Мерење интензитета парцијалних пражњења – ПП представља методу којом се мери привидно наелектрисање унутар ЕИС намотаја [13, 29, 30]. Парцијална пражњења у ЕИС намотаја значајно доприносе његовом оштећењу и убрзаном старењу због чега се повећава важност мерења ПП. Модерни аквизициони уређаји омогућавају снимање образаца парцијалних пражњења, тј. зависности интензитета и броја понављања импулса ПП од фазе испитног напона.

Испитни напон се у корацима од  $0,2U_n$  подиже до назначеног напона машине и на исти начин спушта при чему се врши мерење парцијалних пражњења за сваку вредност напона. У међународним и националним стандардима не постоје важећи критеријуми за тумачење измерених вредности. Оријентационе вредности које се користе при анализи резултата датих у [13] приказане су у табели 4. При тумачењу резултата дијагностички значај се примарно пружа измереним вредностима при испитном напону од  $0,6U_n$ , с обзиром да је намотај у погону изложен управо овом напону. Интензитет ПП при номиналном напону се бележи информативно.


**Табела 4 Оријентационе вредности интензитета привидног наелектрисања PD према групама квалитета за обртне машине**

Оцена ЕИС	$PD_{0,6U_n}(nC)$	$PD_{1,0U_n}(nC)$
Добро	$\leq 5$	$\leq 10$
Сумњиво	$\leq 10$	$\leq 20$
Лоше	$> 10$	$> 20$

### 3.4 Контрола међузавојне изолације намотаја ротора

Међузавојни кратки спојеви роторског намотаја су релативно чест проблем који се јавља услед оштећења међузавојне изолације. Ова врста квара не представља препреку за наставак погона генератора уз надгледање осталих параметара који могу да укажу на погоршање стања као што су подаци о релативним вибрацијама ротора [13, 36].

У редовној пракси испитивања електричних машина се различитим методама третирају поједине врсте ротора. Ротори турбогенератора су цилиндрични, са симетрично постављена два или четири пола. У 50Hz електроенергетским системима уобичајно су у употреби двополни синхрони турбогенератори. Чињеница да је намотај ротора турбогенератора симетричан, посматран са једног клизног прстена према другом искоришћена је при развоју ове методе. Напонски импулс доведен на један клизни прстен креће се кроз намотај ка другом прстену. Уколико је други клизни прстен отворен, импулс се у потпуности рефлектује и суперпонира са побудним импулсом на првом прстену. Снимљени одзив на једном прстену, имајући у виду симетричност намотаја, у потпуности је идентичан на исти начин снимљеном одзиву са другог прстена. Уколико се уочи разлика између ова два одзива, са великом вероватноћом се може тврдити да је дошло до међузавојног кратког споја у намотају ротора (Слика 5). Ова метода није осетљива само за симетричне кварова. С обзиром да су такви кварови мало вероватни ова метода се сматра веома поузданом у откривању несиметрија, међузавојних кратких спојева у намотају ротора.



Слика 6 Одзиви роторског намотаја присутним међузавојним кратким спојевима на импулсну побуду снимљена на оба клизна прстена и разлика ова два сигнала

Ова метода се сматра недовољно осетљивом при испитивању намотаја великих хидрогенератора који су сачињени и од неколико десетина полова. Уобичајно се постојање међузавојних кратких спојева у половима хидрогенератора врши мерењем падова наизменичног напона по половима. Значајно нижи напон на неком од полова при константној струји указује на постојање кратког споја између навојака тог пола.

### 3.5 Методе одржавања електроенергетске опреме

Под појмом одржавања електроенергетске опреме подразумева се низ узајамно повезаних извршилаца, техничких средстава и операција које су неопходне за одржавање и поновно враћање у погонску спремност свих елемената техничких система у процесу експлоатације. У литератури се под дефиницијом одржавања може наћи и тумачење да одржавање представља „спровођење свих мера нужних да би једна машина, постројење или цео објекат функционисао на прописан начин развијајући перформансе у прописаним границама, односно са номиналним захтеваним учинцима, без отказа, уз прописано обезбеђење животне околине, а под претпоставком добре обезбеђености свих услова, односно уз потребну подршку“ [8, 9, 15-17, 37-39].

Тржиште и развој електрификације и испитних метода је условило и еволутивни развој различитих приступа одржавању електроенергетске опреме (Слика 7). Даљим развојем тржишта електричне енергије показало се да трошкови изненадних застоја и неиспоручене електричне енергије могу вишеструко премашити финансијска средства која би се уложила у одржавање. Истовремено импликације на стабилност целог електроенергетског иситема могу бити велике када се посматрају велики турбогенератори којима се најчешће формира базна снага електроенергетског система.

Негативне финансијске последице су утолико веће, што је снага машине већа. Наиме, синхроне машине за мање хидроелектране се израђују са номиналним снагама и до свега пар мегавата, док се машине у снажним блоковима термо и термонуклеарним производним погонима се израђују за номиналним снагама и до 2 гигавата. Импликације изненадних испада ових снажних машина на поузаност и стабилност ЕЕС-а је изузетно велика у поређењу са малим хидрогенераторима.

У зачетку развоја електроенергетике одржавање опреме је подразумевало искључиво вршење поправке на опреми након настанка квара са циљем враћања у погон, тј. корективно или реактивно одржавање. Временом, показало се да трошкови који настају изненадним кваровима и услед неиспоручене електричне енергије могу вишеструко премашити трошкове одржавања. Концепт је мењан ка превентивном одржавању са циљем да до квара не дође, односно, да се средње време између кварова увећа максимално.



Слика 7 Еволуција стратегија одржавања

Превентивно одржавање у фиксним временским интервалима подразумева вршење унапред дефинисаних сервисних активности у тачно предвиђеним временским интервалима неовисно од стварног стања опреме и без узимања у обзир да ли је овај захват уопште неопходан.

Убрзо је за велики део области електроенергетике овај приступ био техноекономски непрактичан, имајући у виду могућности и технике мерења и испитивања, које су у међувремену развијене, да укажу на стварно стање. Тако се извршио прелаз на одржавање према стању, при чему су се са одређеном периодиком вршила одређена електрична испитивања и тестови како би се донео закључак о стању опреме и у зависности од изнетих налаза благовремено планирале сервисне активности у најповољнијем тренутку. Одржавање према степену ризика представља још један еволутивни корак напред у погледу оптимизације трошкова одржавања и трошкова насталих застојем у експлоатацији машине. Овај тип одржавања представља потпуно пробабилистички приступ и захтева изузетно квалитетне улазне податке како би статистички алат могао бити употребљив.

Изненадни прекиди у раду најчешће захтевају дуже застоје, с обзиром да припрема радова на санацији појединих кварова може заузети значајне временске ресурсе. Стога, од изузетне важности су прецизна статистика о кваровима као и о активностима и трајању сервисних активности када је до појединих кварова дошло. На основу ових података и података о редовним профилатичким испитивањима изводи се статистички податак о вероватноћи отказа који указује на поједине елементе који ће највероватније отказати. У складу са овим налазом планирају се сервисне радње у најповољнијем могућем тренутку. На овај начин, могуће је припремити електроенергетски систем на привременом застоју одређених машина, тако што се благовремено планира покретање другог производног блока или увоз електричне енергије по повољнијим ценама. Истовремено, могуће је правовремено извршити све припремне радње са циљем што брже реализације сервисних радњи.

У примени се могу наћи и многи деривати ових модела одржавања који на различите начине процењују редослед „кандидата“ за одржавање. Резултати стратегија одржавања представљају улазне податке при планирању финансијских средстава за одржавање опреме, од чега зависи поузданост целог постројења.

У претходних 15-ак година створен је нови термин „Управљање ресурсима“ или „*Asset Management*“ који је општеприхваћен због низа бенефита који се овим приступом остварују у готово свим областима науке, технологије, медицине...

Овај термин означава систематски приступ управљању и остваривању користи од ресурса који се имају под надлежношћу. Представља комбинацију стручних приступа управљању, финансијама, економији и инжињерству како би се обезбедила највећа могућа корист за уложена средства.

У пракси, као један од улазних параметара управљања ресурсима у ЕЕС-у је свакако стање сваког од објеката над којим се врши управљање. При томе, у сврху планирања и управљања ресурсима пожељно је да та улазна величина буде једноставна за перцепцију и поређење, а пре свега неопходно је да буде објективна и поуздана.

У овом раду се управо жели презентовати могућност да се искористи вештачка интелигенција у сврху прорачуна својеврсног индекса здравља синхроне машине, који би могао аутоматизовати класификацију машина на којима није потребно вршити било какве сервисне радње и истаћи машине на којима је нужно планирати интервенцију.

На овај начин се на популацији синхроних машина над којом се врши управљање ресурсима може вршити правовремено планирање техничких и финансијских ресурса како би се стање одређених генератора довело у задовољавајуће.



## 4. Методе вештачке интелигенције

---

Под појмом интелигенције уобичајно се подразумева способност усвајања, памћења и обраде одређених знања [40 - 51]. Вештачка интелигенција као појам први пут се помиње још 1956. године од стране америчког научника у области информатике, Џона Макартија. Његовом формулацијом овог појма отвара се потпуно ново поглавље у области информатике које представља замајац и у областима аутоматизације обраде података и машинског учења.

Развој вештачке интелигенције омогућен је пре свега развојем моћних рачунарских система и алгоритама вештачке интелигенције који су довољно унапредовали да је њихова примена изузетно погодна и олакшава аутоматизацију обраде велике количине података. У самом зачетку вештачке интелигенције као гране информатике очекивања су била изузетно висока. Осамдесетих година преовладава мишљење да очекивања у погледу развоја вештачке интелигенције нису била реална, те се улагања у развој и истраживање драматично смањују у наредним годинама, све до краја деведесетих година 20-ог века, када истраживања у овој сфери поново узимају маха. Наравно, пре свега, захваљујући еволуцији рачунара који су сада били у стању извршавати много комплексније задатке.

Истовремено, развој технологије омогућио је складиштење велике количине података што је довело до тога да количина упамћених података глобално расте по експоненцијалној функцији. Овај експоненцијални глобални раст складиштене количине података је условио додатне инвестиције у област аутоматизације обраде података и развој вештачке интелигенције као алата за аутоматизацију обраде података са могућношћу учења, памћења и доношења одлука у будућности уз константно унапређивање. Поједини модели вештачке интелигенције се већ увелико користе у разним онлајн сервисима, попут *Amazon-а*, *Facebook-а*, *Instagram-а* и сл. Њиховом комерцијализацијом значајно су унапређени и софтверски алати којима се изузетно упрошћава примена алгоритама машинског учења. Ови алати нису више резервисани само за експерте у области софтверског инжињерства већ постају доступни широј стручној јавности. Популаризацијом алгоритама машинског учења, проналази се њихова

примена у готово свим аспектима развоја и модернизације процеса у модерној индустрији, здравству, друштвеним и техничким наукама. Док се развој механизације и употреба парне машине сматрао првом индустријском револуцијом, електрификација и употреба информационих технологија се сматрају у историји другом, односно трећом индустријском револуцијом и великим помацама у развоју човечанства. У модерном времену, системи и модели вештачке интелигенције, *data mining* и IIoT у литератури и науци се сматрају четвртом индустријском револуцијом која се управо дешава и којој сведочимо (Слика 8).



Слика 8 Индустријске револуције кроз историју

Основни допринос овог истраживања јесте управо развој експертских система за процену стања електричних изолационих система синхроних генератора базираних на машинском учењу. Овако креирани експертски системи би на поновљив начин, објективно могли аутоматизовати обраду података о испитивању синхроних генератора и извести закључке о њиховом стању.

Анализа резултата електричних испитивања биће извршена креираним експертским системима на бази неколико различитих поступака машинског учења, уз процену тачности сваког од експертских система. Процена тачности биће извршена поређењем са оценама експерата.

Сам појам машинског учења је свакако прерастао у посебну научну дисциплину и обухвата бројне методе и варијације метода које су развијене у претходном периоду и константно се развијају и унапређују. Стога, у овом поглављу укратко ће бити описани само алгоритми машинског учења који ће бити предмет овог рада:

1. Фази логички експертски системи,
2. Вештачке неуралне мреже,
3. Аутоенкодерске неуралне мреже,
4. *ANFIS* – Адаптивни неуро-фази инферентни системи,
5. Стабло одлучивања – *Decission tree*.

Модели креирани у овом раду су одабрани на основу процене аутора о њиховој подобности и потенцијала које поједини алгоритми нуде у погледу класификације података као и доступних информатичких и рачунарских ресурса. Машинско учење представља грану информатике која је у експоненцијалном расту те се готово свакодневно се развијају нови модели и алгоритми машинског учења који представљају усавршене и/или потпуно нове верзије постојећих и проналазе се нова решења за имплементацију машинског учења у решавању свакодневних инжењерских проблема.

#### 4.1 Врсте вештачке интелигенције

Развојем вештачке интелигенције у литератури се обично препознају следећи еволутивни кораци у развоју вештачке интелигенције [41]:

- Уска вештачка интелигенција
- Општа вештачка интелигенција
- Вештачка супер интелигенција

Уопштено, развој вештачке интелигенције је до сада углавном био заснован на креирању система који за задатак имају решавање једног или низа предефинисаних задатака. Овако развијена вештачка интелигенција назива се уском вештачком интелигенцијом (*Narrow Artificial Intelligence*). Често се овај вид вештачке интелигенције назива и слаба вештачка интелигенција, с обзиром да је за развој ових система углавном неопходна асистенција у виду пружања података или предефинисање правила понашања система. Већина система који користе алгоритме вештачке интелигенције данас заснивају се управо на уској вештачкој интелигенцији.

Општа вештачка интелигенција (*Artificial General Intelligence*) подразумева могућност машина да обављају све задатке и да имају потпуну перцепцију дешавања у њиховој околини налик људској. Тренутно, овај вид вештачке интелигенције представља предвиђање могућег тока развоја машинске интелигенције.

Истовремено, предвиђања појединих стручњака из области вештачке интелигенције указују да, уколико се дође у стадијум опште вештачке интелигенције, може се очекивати да релативно спори еволутивни раст људских умних и физичких способности може бити превазиђен суперинтелигентним машинама, чије ће могућности учења и закључивања бити у толикој мери развијене да ће бити способне саме да уче, расуђују и одлучују – вештачка супер интелигенција (*Artificial Super Intelligence*).

За сада, појам вештачке интелигенције је широко развијен само у домену уске или слабе вештачке интелигенције за коју је неопходно предефинисати задатке које ће систем извршити односно извршити програмирање/тренирање модела.

Машинско учење се може посматрати као својеврсни подскуп појма вештачке интелигенције који представља (Слика 8):

1. технике анализе података,
2. учења на основу анализе података и
3. доношење одлука на основу наученог.

У том смислу могуће је раздвојити поједине типове алгоритама машинског учења на основу начина на који се учење система врши. То су:

1. Надгледано машинско учење – *Supervised learning*,
2. Ненадгледано машинско учење - *Unsupervised learning*,
3. Учење уз подршку - *Reinforcement learning*.



Слика 9 Релације између појединих појмова вештачке интелигенције

Надгледано учење представља начин машинског учења у коме је програму обезбеђен скуп улазних података и скуп тачних излазних вредности. Модел машинског надгледаног учења има задатак да на основу овог скупа улазних и излазних вредности „научи“ како да на неозначеном сету улазних података израчуна/додели излазну вредност која је што је могуће више приближна тачној вредности.

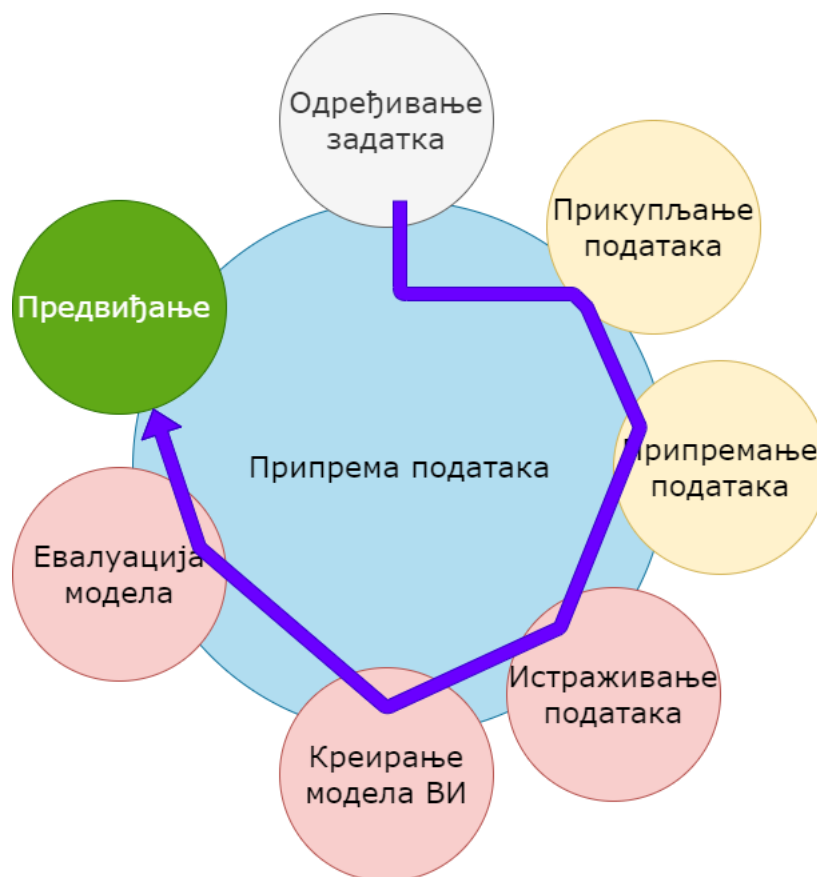
Ненадгледано машинско учење подразумева да је програму на располагању само скуп улазних података. Задатак програма је да сам препозна законитости у структури улазних података и формира излазне вредности на основу успостављених релација.

Учење уз подршку, подстицаје, подразумева да програм делује на окружење извршавањем низа акција. Ове акције програма утичу на програм пружајући му повратне информације у виду „награде“ или „казне“, тј. „добро“ и „лоше“. Програм има задатак да научи како да делује на окружење, тако да након неког времена буде минимално кажњаван, тј. да има минимално лоших оцена окружења за своје акције.

У овом раду користиће се системи надгледаног учења, у виду фази логичких експертских система, вештачких неуралних мрежа и стабла одлучивања пре свега због комплексности релација улазних и излазних података, са циљем да се постојећа експертска сазнања пресликају у софтверске експертске системе креиране машинским учењем. Под методу надгледаног машинског учења потпада и *ANFIS* с обзиром да је за имплементацију неопходно извршити припрему улазних и излазних података. Као модел ненадгледаног машинског учења креиран је систем аутоенкодерске неуралне мреже који се у овом раду користи у функцији надгледаног учења.

Уопштени алгоритам машинског учења може се представити кроз низ активности, као на слици 9. Препознавање задатка који би систем требао да реши представља први корак ка формирању система вештачке интелигенције. Прикупљање и припремање података су свакако најобимнији и најзахтевнији кораци у овом алгоритму. Припремање података подразумева преглед базе са подацима и уочавање недостатака и евентуалне корекције и

допуне. Истраживање базе података подразумева уочавање кључних параметара којима се може описати жељени систем. На овај начин се минимизује скуп улазних параметара чиме се може значајно упростити модел вештачке интелигенције. На овај начин се могу креирати поузданији и тачнији системи уз минималне неопходне рачунарске ресурсе.



Слика 10 Приказ основног алгоритма поступка креирања система вештачке интелигенције

## 4.2 Фази експертски системи

Фази логички системи представљају изузетно популарне логичке алгоритме у подручју контроле и управљања процесима и системима [13, 52 – 66]. Формулација појма фази логике потекла је 1965. године од стране професора Лотфија Задеха. Овим појмом означени су скупови чији елементи припадају том скупу са одређеном вероватноћом, односно степеном припадности, за разлику од класичне теорије скупова код које елемент или припада или не припада скупу. Оваква дефиниција може се сматрати генерализацијом теорије скупова.

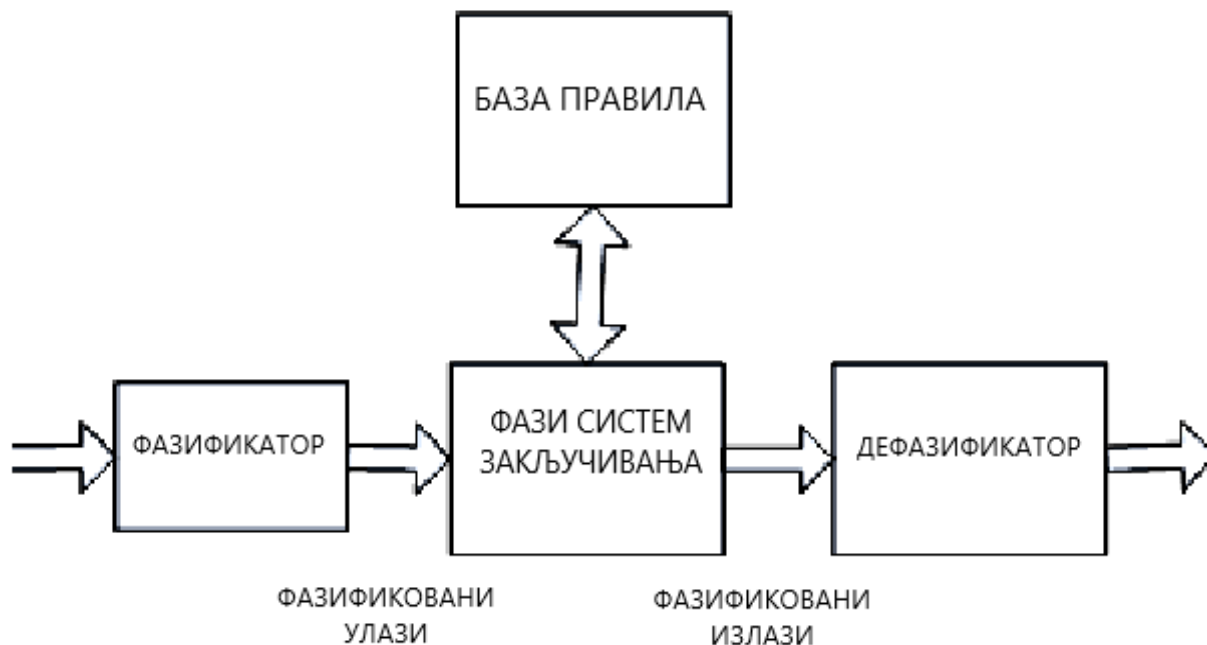
Године 1970. дизајниран је први фази логички контролер за потребе управљања парном машином, а потом и контролер за управљање семафорском сигнализацијом. Након тога, употреба фази логичких система у системима управљања и контроле експоненцијално расте.

Задех је 1975. представио уопштеније облике фази скупова у којима се степени припадности такође представљају као фази вредности. Два најприменљивија облика су тип-1 фази логика и тип-2 фази логика. Тип-1 фази логички системи су засновани на степенима припадности који представљају целобројне вредности док је код тип 2 фази логичких система степен припадности такође фази број. Овако дефинисана тип-2 фази логика у стању је да робусније одговори на несигурности и непознанице у систему. Међутим, математички је репрезентација тип 2 фази логичких система изузетно компликована те је њихова примена још увек у повоју.

Лингвистичке променљиве, појам којим се називају улазне и излазне величине фази логичких контролера, представљају основу фази логичких система. Управо овакав начин представљања променљивих условио је велики успех фази логике у инжењерској примени с обзиром да се на овај начин интуитивно представљају реални проблеми на које се наилази у редовној пракси.

Фази логички систем у уобичајној конфигурацији подразумева (слика 10) [55, 66]:

1. Фазификатор – за фазификацију улазних величина,
2. Базу експертског знања,
3. Машину за фази одлучивање,
4. Базу правила и
5. Дефазификатор – за израчунавање излаза.



Слика 11 Блок шема уобичајног фази логичког контролера

Поседовање експертских знања или базе експертских знања предуслов је за правилно креирање фазификатора, односно за одговарајућу фазификацију улазних величина. Како би се овај корак на исправан начин дизајнирао, морају се познавати улазне величине и њихова природа, како би се исправно одабрале и подесиле функције припадности. Функцијама припадности одређује се степен припадности са којим се свака нумеричка улазна вредност придружује одређеној лингвистичкој вредности. Фазификатор, запрево, пресликава јасне, прецизне вредности улазних величина у фази вредности, како би биле компатибилне са фази улазним вредностима базе правила.

У бази правила се дефинишу релације између улазних и излазних лингвистичких величина. Релације су дефинисане кроз низ тзв. *IF-THEN*, тј. АКО-ОНДА правила. Машина за закључивање користи све доступне информације из базе знања и правила да генерише тачне излазе. Међу данас развијеним различитим типовима закључивања, најзаступљенија су два основна типа: *Mamdani* и *Sugeno*. Код оба типа, улазне вредности пролазе кроз цео низ унапред дефинисаних правила и процњује се удео истинитости у свакој појединачној тврдњи. Разликују се у поступку дефазификације.

Дефазификација је појам супротан фазификацији и представља поступак превођења израчунате фази излазне величине у употребљиву вредност, корисни сигнал, величину или број. Два наведена метода фази логичког закључивања базирају процес дефазификације на различите начине.

*Mamdani* систем израчунава излазе на неколико начина: методом тежишне тачке, најмањег максимума, средњег максимума, највећег максимума, метода једнаких површина. У највећем броју примена, употребљавају се метода средњих максимума (*MOM - mean of maximum*) или метода тежишне тачке (*COG - center of gravity*).

*Sugeno* систем након прорачуна у машини за одлучивање као излазну величину нема фази број, већ је излазна величина представљена у функцији улазних. Дакле, није потребан



дефазтификатор излазне величине, већ се излаз прорачунава методом тежинског усредњавања (*weighted average*).


За потребе софтверске имплементације експертских знања *Mamdani* систем се сматра увелико подобнијим и биће имплементиран и у овом раду.

У току израде рада велика предност фази логичких експертских система је у чињеници да не захтевају обимне базе података. Довољно је поседовати базу експертских знања и релација између појединих улазних величина и излаза како би се правилно формирала база правила. На својеврсни начин, фази логичким системима се унапред дефинишу односи и релације улазних и излазних величина.

### 4.3 Неуралне мреже

Базични градивни елементи људског мозга су неурони. Проучавање неурона, њиховог начина функционисања и улоге у обради информација је веома важна грана истраживања у области модерних биолошких наука [40, 41, 67 - 80].

Вештачке неуралне мреже представљају софтверско решење, модел, које је базирано на симплификацији стварног функционисања људског мозга и досадашњим сазнањима о његовој способности закључивања и доношења одлука. Посматрано историјски, вештачке неуронске мреже су производ настојања да се креира софтверски модел способан за софистицирано, па чак и интелигентно израчунавање и доношење одлука на начин сличан спонтаним функцијама људског мозга. Начин функционисања биолошког неурона (Слика 11) је врло комплексан и немогуће је у адекватно и у потпуности математички га моделовати [66].



Слика 12 Приказ биолошког неурона

Укратко, дендрити представљају проводне канале за улазне информације у неурон. Синапсе су контактне површине које прикупљају информације и прослеђују их дендритима. Аксони су одговорни за прослеђивање обрађене информације другим неуронима. У ћелији се врши процесуирање улазне информације у зависности од бројних електрохемијских реакција и процеса. Синапсе имају могућност да одреде смер протока информација.

Вештачки неурони функционишу на сличним принципима, иако представљају веома упрошћен модел функционисања биолошког неурона. Вештачки неурон се састоји од улазних и излазних канала и тела ћелије. Синапсе су заправо тачке додира између тела ћелије и улазних или излазних величина са њима припадајућим тежинским факторима.

Основна три појма који дефинишу неуралну мрежу су:

1. Модел неурона, односно елемента за процесирање,
2. Структура везе између неурона и
3. Правило којим се обучава мрежа односно подешавају тежине појединих веза.

Модел неурона (чвора) дефинишу две функције. Прва функција представља функцију којим се обједињавају сви улази у чвор и често се назива агрегациона функција. Ове интеграционе, агрегационе, функције могу бити линеарне функције, нелинеарне, квадратне, полиномијалне, сферичне и тд... Друга функција се често назива активационом или функцијом преноса и има задатак да унутар једног чвора на основу прве вредности добијене агрегационом функцијом израчуна излаз чвора, који је одговарајући репрезент свих улазних величина. Ове функције се најчешће формирају као степ функције, рампа функције, али и различите варијанте сигмоидалне и Гаусове функције.

Вештачке неуралне мреже се обично састоје од великог броја неурона. Топологија или геометрија веза између неурона у мрежи се може описати кроз неколико уобичајних типова мрежа [69 - 73]:

1. Једнослојне *feed forward* мреже
2. Вишеслојне *feed forward* мреже
3. Једнослојна рекурентна мрежа
4. Вишеслојна рекурентна мрежа

Конфигурације типа *feed forward* се у литератури називају још и ацикличне конфигурације с обзиром да не садрже циклусе у графу неуралне мреже попут рекурентних мрежа.

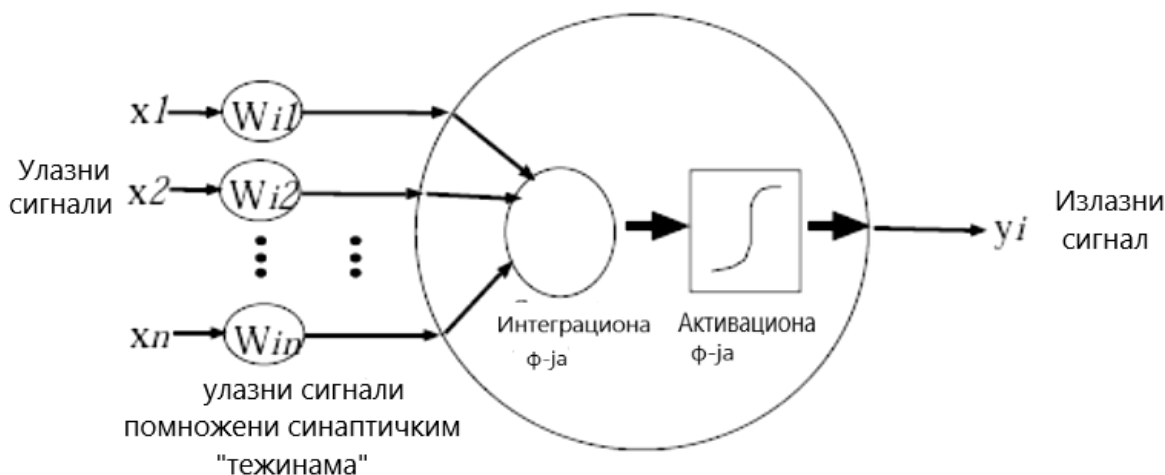
На који начин ће неурон процесуирати улазне податке зависи од тежинских фактора.

Процес учења, односно тренирања неуралне мреже је заправо процес проналажења одговарајућих тежинских фактора који ће најтачније репродуковати жељену функцију или базу експертских знања, тј. одредити колико ће тачно извршавати задате операције. Ове вредности је могуће предефинисати, али је такав приступ изузетно непрактичан, с обзиром да чак и за једноставније проблеме, није могуће адекватно проценти најпогодније вредности. Из тог разлога се обично прибегава тренирању мреже на предходно припремљеном сету улазних и излазних података.


Алгоритми тренирања мреже су адаптирани у софтверска решења попут Матлаб-а, и у стању су аутоматски извршити тренирање креиране вештачке неуралне мреже уз процену грешке система. Мрежа се тренира у више итерација, док грешка система не постане минимална. Уколико је грешка модела и даље велика, неопходно је применити неку од следећих модификација:

1. Изменити конструкцију мреже,
2. проширити базу података и/или
3. покушати са редукацијом броја улазних величина.

Измена конструкције мреже углавном подразумева измену броја неурона у скривеном слоју неуралне мреже, или, пак, измену агрегационих или активационих функција. Базе доступних података често може бити изузетно тешко проширити, с обзиром да то захтева временски захтеван задатак прикупљања неопходних података. Такође, у појединим проблемима неки улази могу бити сувишни, те изазивати додатне проблеме при прорачунима и беспотребно окупирати рачунарске ресурсе.



Слика 13 Приказ вештачког неурона



Слика 14 Приказ *feed forward* потпуно повезане неуралне мреже са једним улазним и једним излазним слојем и једним сакривеним слојем

С обзиром на начин на који се обучавају, неуралне мреже изискују процесирање улазних података и припрему података на начин на који је мрежа у стању те податке да прихвати и изврши обучавање на њима.

Неуралне мреже могу решавати низ различитих проблема попут проблема класификације, препознавања образаца у подацима и слично. Од природе проблема и скупа доступних података највише зависи који ће се приступ користити. Припрема података је најчешће најобимнији и најтежи део посла при тренирању вештачких неуралних мрежа. Након адекватне припреме података, издвајају се подаци на којима ће се вршити тренирање мреже и подаци на којима ће се мрежа тестирати. Уобичајан однос је око 75% за тренирање, 25% за тестирање.

Након постизања минималне и задовољавајуће грешке креираног система, могуће је вршити предикцију излаза на основу било ког скупа улазних података, имајући у виду са којом вероватноћом систем може да погрешити.


Као алат за процену грешке система могу се користити разни математички алати. Врло често се у ове сврхе прорачунава средње квадратно одступање тачне вредности из базе података и вредности прорачунате неуралном мрежом (*Mean Squared Error- MSE - Прилог 7*).

Алгоритми нису у стању подесити све аспекте неуралних мрежа. Углавном, подешавају се тежински фактори док је конфигурацију мреже неопходно унапред дефинисати. Дакле, не постоје алгоритми који ће унапред дефинисати број скривених слојева, број неурона у сваком скривеном слоју или активационе функције. Ово је заправо скуп тзв. хиперпараметара који морају бити предефинисани пре самог тренирања мреже. Валидација одабраних хиперпараметара се врши одвајањем посебног скупа података – валидацијског скупа у сврху евалуације различитих комбинација параметара.

Све неуралне мреже које се састоје од 2 и више скривених слојева се називају дубоким неуралним мрежама. Уколико је грешка система превелика, неопходно је променити хиперпараметре и поново започети тренирање мреже. При сваком отпочињању процеса тренирања, модел усваја произвољне почетне вредности тежинских фактора. У зависности од ових вредности, прорачуната грешка може варирати за потпуно идентичну конфигурацију мреже. У овом случају, број итерација, епоха, при тренирању мреже може се увећати, тако да ова одступања буду занемарљива.

#### 4.4 Аутоенкодерске неуралне мреже

Аутоенкодерске неуралне мреже представљају својеврсну подврсту вештачких неуралних мрежа [69, 81-90]. Аутоенкодер је заправо ненадгледана неурална мрежа која на основу неозначеног скупа података тренира ефикасан начин компримовања и кодирања улазних података. Након тога обучава се са циљем реконструкције идентичног скупа података (слика 14).



Слика 15 Приказ аутоенкодерске неуралне мреже

Аутоенкодер се састоји од два основна елемента: енкодера и декодера. Енкодер је део у коме модел учи како да компримује, смањи димензије улазних података и представи их енкодирано информацијом. Декодер је део у коме модел учи како да реконструише податке из компримованог записа што је могуће приближније оригиналним улазним подацима. Део који садржи компримоване податке се често у литератури назива „*bottleneck*”. Након реконструкције улаза, следи прорачун грешке реконструисања. Као алат за процену грешке могу се користити разне математичке функције. Као и при тренирању и валидацији вештачких неуралних мрежа најчешће је у употреби прорачун средњих квадрата одступања – *Mean Squared Error- MSE* (Прилог 7).

Перформансе ситема директно утичу на оригиналност репродукованих података. Уколико се ова грешка сведе на јако мали проценат, репродукцијом излаза се добијају готово идентични подаци као и при обучавању мреже. Међутим, уколико се за научен аутоенкодер, накнадном обрадом новог скупа података уочи већа грешка, овај податак може индиковати поремећаје у улазном скупу података, односно може указати да је дошло до значајне промене неког од улазних параметара. С обзиром да не захтева означену базу података за обучавање мреже, може се тренирати и на моделованој бази података. Уколико се аутоенкодер жели применити на потпуно новом скупу улазних података, није од интереса научити га да потпуно савршено пресликава улазне вредности у излазне на скупу за тренирање, с обзиром да у том случају се не би могао употребити.

Неке од примена аутоенкодера подразумевају [69]:

- Уочавање аномалија на скупу података (бројчане вредности, слова, фотографије...),
- Смањење димензија података,
- Умањење нежељеног сигнала, филтрирање шума,
- Обрада дигиталних фотографија и
- Машинско превођење текста.

## 4.5 ANFIS – Adaptive Neural – Fuzzy Inference system

ANFIS или *Adaptive Neuro-Fuzzy Inference System* представља вештачку неуралну мрежу базирану на Такаги – Сужено фази системима закључивања [55, 58, 60, 91 - 107]. Метода је развијена почетком 1990-тих. Представља својеврсну синергију неуралних мрежа и принципа фази логичког закључивања што јој даје могућност да од обе методе синтетизује најбоље ефекте у једну машинског учења. Систем закључивања АНФИС система се састоји од скупа фази *IF-THEN* правила која имају способност да апроксимирају нелинеарне функције. Параметри функција припадности се не подешавају унапред. У неким случајевима једноставно је изузетно тешко одредити релације између појединих улазних величина и дефинисати одговарајуће функције припадности. Уколико у овом случају постоје дефинисани излази за скуп улазних података, овај систем ће сам истренирати параметре и подешавања функција припадности која дају најоптималније решење. Подешавање функција припадности и тежинских фактора појединих правила врши се на сличан начин као при тренирању неуралних мрежа. Овим је омогућено превазилажење једног од највећих недостатака фази логичких експертских система, а то је дуготрајно и непредвидиво итеративно подешавање функција припадности и скупа релација (правила).

## 4.6 Стабло класификације–Classification tree

Стабла одлуке и класификације представљају посебне алате вештачке интелигенције и *data mining*-а у пољима класификације и доношења одређених одлука на основу улазних података [60, 75, 103-109]. Њихово разумевање је најчешће веома лако и прилично интуитивно за људски мозак. Користе се алгоритмима у облику стабла како би на основу одређених података о објекту анализе произвели тачну одлуку о циљаној вредности тог објекта. Два уобичајна типа стабла одлучивања су:

- ❖ Стабло класификације
- ❖ Стабло регресије

Пример стабла класификације је приказан на слици 16.

Класификациона стабла за примарни циљ имају одређивање припадности објекта дискретној вредности односно скупу закључака. Нпр, да ли улазни скуп података приказује да ли купити некретнину или не, као у примеру на слици 16. Регресионо стабло одлучивања као излазну величину предвиђа реалан број, нпр. цену аутомобила на основу улазних података.





Слика 16 Пример стабла одлуке о куповини некретнине

Свако стабло одлучивања састоји се од следећих елемената:

- Чворова (енг. *Nodes*) - који представљају места на којима се врши гранање стабла на основу вредности неког од улазних података,
- Ивица или Грана (енг. *Edges/branches*) – које усмеравају потенцијалне резултате сваког чвора,
- Корена (енг. *Root*) – места где се врши прво гранање стабла одлуке и
- Листова (енг. *Leaves*) – завршни чворови који предвиђају излаз стабла одлучивања.

У основи, алгоритам тренирања стабла одлучивања се заснива на следећем редоследу активности:

1. Одабир улазних података који су од највећег утицаја/значаја,
2. Начинити чвор за тај податак и поделити улазне податке у мање подскупове,
3. Понављати овај процес рекурзивно за сваку грану, користећи се само подацима/вредностима који долазе до гране и затим,
4. Зауставити поступак уколико су сви подаци у грани класификовани у исту класу.

Програмски пакет Матлаб садржи алате за обучавање стабла одлучивања на основу већ припремљеног скупа података. Након тога, могуће је извршити класификацију неозначеног скупа података. Процена квалитета креираног модела се врши уобичајним алатима попут ROC-а и матрица конфузије (Прилог 7).

Стабла одлучивања су у поређењу са другим моделима вештачке интелигенције за класификацију података [108]:

- Незахтевна у погледу неопходних рачунарских ресурса,
- Функционишу на принципима на којима расуђује и људски мозак,
- Врше брзу класификацију непознатог скупа података,
- Лака су за разумевање,
- Уобичајно дају већу тачност и
- Могуће је искључити непотребне улазе.

Одређене неповољности овог модела обично се огледају у :

- Могућности за лако преобучавање модела (*overfitting*),
- Мале промене у подацима могу значајно изменити логику закључивања и
- Велика стабла су прилично тешка за разумевање и интерпретацију.

#### 4.7 Анализа доступних података

Пре отпочињања детаљније анализе доступних података неопходних за креирање наведених модела експертских модела извршен је преглед доступне базе података о испитивању ЕИС генератора у ЈП ЕПС као и важећих међународних и националних стандарда који обрађују ову тему. Систематизација и дигитализација података измерених при електричним испитивањима ЕИС генератора је релативно млада дисциплина. Развојем модерних рачунара и меморијских уређаја, реализација овог задатка постала је доступна већини модерних предузећа.


База података се састоји од систематичних вредности електричних величина измерених при редовним профилактичким испитивањима генератора на месту уградње у електранама. База је формирана тако да по датуму испитивања складишти све измерене вредности у посебним табелама. Тако, нпр, постоје форме за унос мерења електричног отпора изолације, фактора диелектричних губитака, парцијалних пражњења, електричног отпора изолације ротора, уноса вредности која указује о постојању међузавојних кратких спојева на ротору итд. За потребе квалитативне процене ЕИС генератора биће коришћене само величине које указују на евентуалне деградације изолације статора и ротора. Такође, примена неких испитних метода је ограничена на поједине типове изолације, те је број доступних података ових мерења ограничен. Стога, у циљу формирања базе података која би могла бити коришћена за обучавање модела машинског учења, доступна база података је обрађена. За обраду и екстракцију жељених података и уопште за рад са доступном базом података употребљен је релациони програмски језик SQL.

Након обраде формирана су укупно 538 комплетна резултата испитивања на укупно 76 синхроних генератора. Резултати који су коришћени представљају одабране кључне параметре за процену стања ЕИС дефинисане у поглављу 3. Тако, на пример, употребљене су вредности за фактор диелектричних губитака као што су дефинисани у појединим моделима, а не свако појединачно мерење.

Као посебан параметар, изведена је апсолутна старост машине у тренутку извођења електричног испитивања. Пример употребљене базе података приказан је у прилогу 1.

База експертских знања неопходна за креирање фази логичких експертских система састоји се од експертског знања и искуства стеченог приликом редовних испитивања синхроних генератора, као и важећих интернационалних и националних стандарда и техничких препорука. Такође, од велике важности су искуства презентована од стране међународних стручних организација попут резултата презентованих на слици 1. Свеобухватна искуства и добро познавање националног електроенергетског система и доступних ресурса обухваћено је кроз завршну оцену о стању ЕИС генератора, којом експерти задужени за формирање извештаја о испитивању формирају закључке о спремности за неометан наставак нормалног погона машине, тј свеукупно стање ЕИС-а. Овај параметар који се приказује у форми оцене стања узма дискретне вредности на скали од 1 до 3, при чему оцена 3 указује на задовољавајуће стање ЕИС, који несметано може наставити погон. Насупрот томе, оцена 1 указује на лоше стање ЕИС које изискује хитну интервенцију у циљу превенције значајног оштећења генератора услед потенцијалних електричних пробоја у погону. Оцена 2 означава приметну деградацију ЕИС уз вредности карактеристичних параметара још увек у задовољавајућем опсегу за наставак погона, уз благовремено планирање сервисних активности и скраћивању периода између два електрична испитивања ЕИС генератора. Употреба наведене базе података захтевала је пре свега проверу свих података, преглед

одређених специфичних случајева чије вредности значајно одступају те провера постојања грешке при уносу података. На доступном скупу података расподела скупова добрих, сумњивих и лоших вредности, приказаних на слици 17, је прилично неуједначена, што ће представљати велики изазов за поједине моделе при њиховом тренирању.



Слика 17 Процентуални удео појединих оцена у укупном скупу података

## 5. Фази логички експертски систем

---

### 5.1 Припрема података

Формирање и прилагођавање базе података за израду фази логичког експертског система није потребно. Неопходно је поседовање одговарајућих експертских сазнања и познавање релација између физичких појава улазних величина.

У поглављу 3 приказана су уобичајне испитне методе које су у пуном обиму у употреби приликом редовних профилактских испитивања синхроних генератора. Резултати ових испитних метода које се користе и приликом дијагностике стања ЕИС од стране експерта су приказани у прилогу 1.

Излаз је дефинисан као оцена, закључак експерта. Прегледом базе података није могуће уочити било какву законитост и понављања која би утицала на редукцију улазних података и смањење неопходних рачунарских ресурса. Ово је проузроковано делимично и недостацима података, с обзиром да за неке активности које могу имати утицај на продужење животног века машине нису јасно дефинисане у бази података као нпр. премотавање изолације ЕИС статора, замена корсета и сл.

Стога је као поуздан одабран аспект са кога експерт који се бави дијагностиком стања посматра резултате и евалуира их оценама 1-3, при чему је 3 означава задовољавајуће стање, 2-сумњиво, а 1 указује на лоше стање ЕИС као што је већ наглашено у поглављу 4.7.

Ове вредности које је експерт из ове области додељивао резултатима након обраде података и формирања закључака о испитивању, коришћене су како за креирање тако и за евалуацију креираних система фази логичких експертских система.

Подешавање функција припадности је изведено комбиновањем различитих стандардизованих и усвојених критеријума како би експертски систем могао што тачније проценити стање различитих типова синхроних генератора. Дакле, у дијагностици стања синхроних генератора, ко што је раније назначено, није се могуће ослонити на међународне стандарде који најчешће нису обухватили критеријумске вредности, већ само обрађују проблематику извођења испитивања и исправне поставке теста.

## 5.2 Креирање модела

Дизајнирање фази логичких експертских система је прилично обиман задатак, у поређењу са другим моделима обрађеним у овом раду. Неопходно је проћи кроз неколико корака и извршити подешавање кроз итеративни поступак, све до постизања задовољавајуће тачних резултата. Фази логички експертски системи су креирани сходно алгоритму на слици 18.

Неколико различитих приступа је могуће дефинисати при одабиру могућих архитектура фази логичких експертских система у функцији процене стања ЕИС генератора. Као што је већ објашњено, под појмом ЕИС генератора се доминантно подразумева ЕИС намотаја статора као електрично најоптерећенијег и најутицајнијег на оцену глобалног стања генератора. Потом се разматра и ЕИС намотаја ротора који је механички оптерећенији, али не и електрично с обзиром да су номинални напони ротора углавном испод 1000V.

Сходно претходно наведеним разматрањима, развој фази логичког експертског система за процену стања ЕИС синхроних генератора извршен је на више различитих начина:

1. ФЛС са два одвојена подсистема за процену стања статора и ротора у коме се укупна оцена израчунавала као збир оцене статора и оцене ротора са тежинским уделима 0,75 и 0,25 респективно.
2. Један ФЛС који као улазне величине користи резултате испитивања статора и ротора
3. Посебне ФЛС за дијагностику стања сувих синхроних генератора и генератора хлађених водом.
4. ФЛС који се базира на редукованом скупу резултата испитивања статора

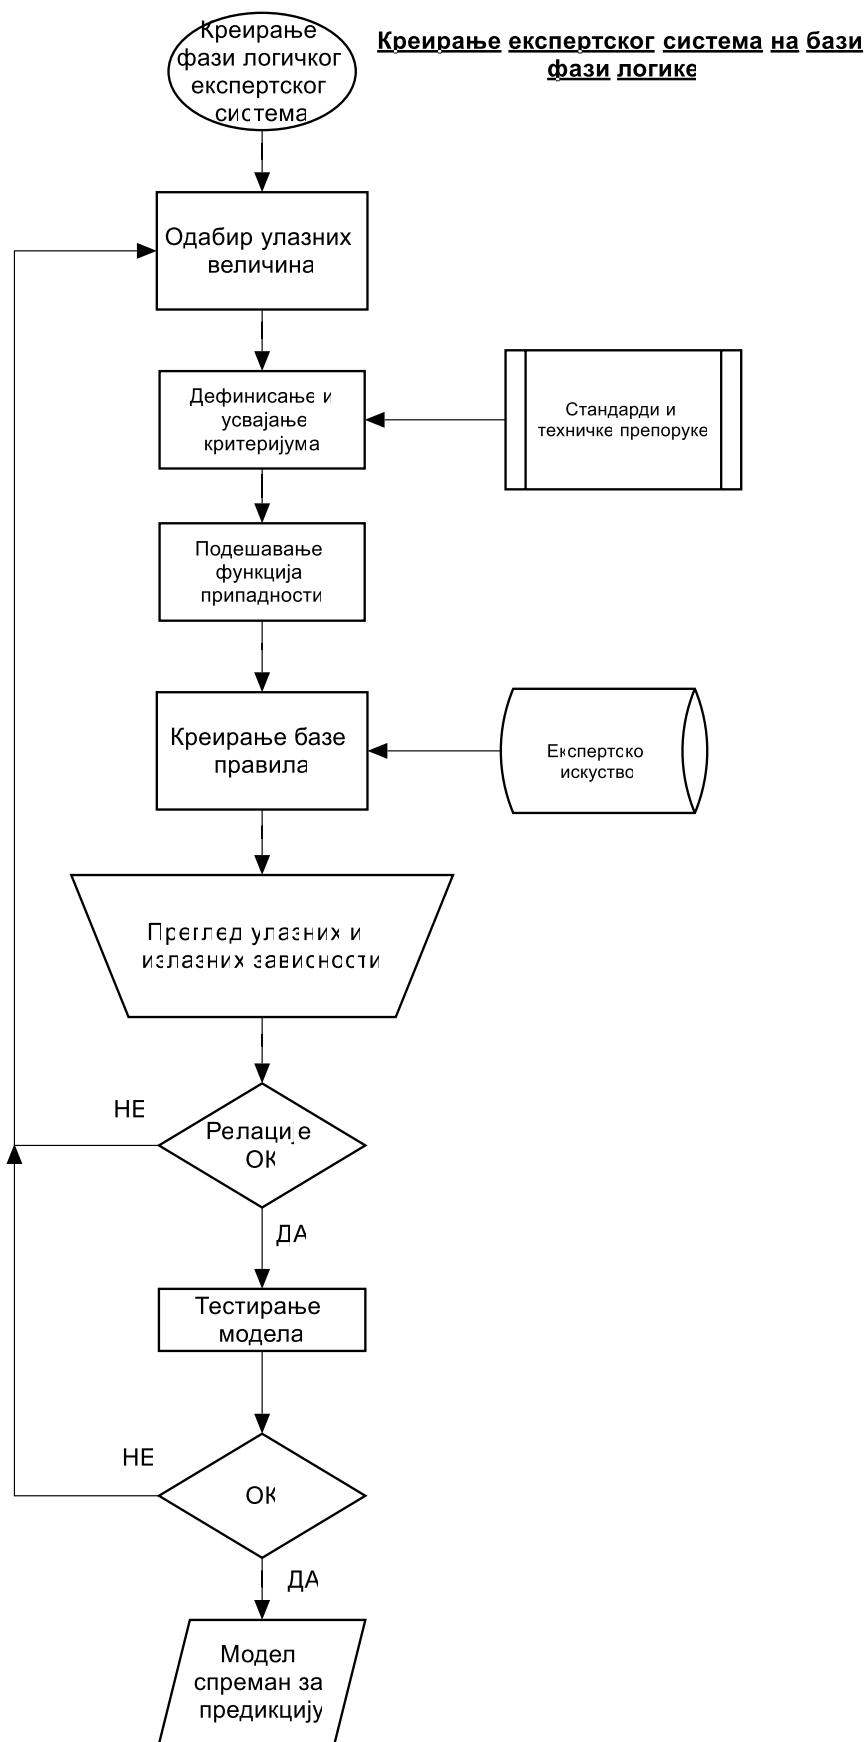
Након одређеног броја итерација и упоређивања добијених резултата и подешавања ФЛС сходно алгоритму на слици 18, као најоптималнији одабран је систем који користи један фази логички систем и следеће улазне величине:

1. Максимални почетни фактор диелектричних губитака при  $0.2U_n$  посматрајући све три фазе,
2. Максимални међуфазни прираштај фактора диелектричних губитака при подизању испитног напона у корацима  $0.2U_n$  до  $U_n$ ,
3. Максимална вредност интезитета парцијалних пражњења при испитном напону од  $0.6U_n$ ,
4. Електрични отпор изолационог система статора,
5. Индекс апсорпције и
6. Апсолутна старост синхроног генератора.

Модел је одабран упоређивањем оцењених резултата и оцена које модел које производи на скупу од 20 резултата намењених тестирању (Прилог 3). Резултати појединих модела приказани су на графикону на слици 19. Фази експертски системи су током развоја означавани са „FLSX” где X представља редни број модела. Разлике између појединих модела огледају се у скупу дефинисаних правила, као и у другачије подешеним функцијама припадности. Финални модел усвојен у овом раду је настао након претходно креираних и тестираних 26 модела.


При креирању и селекцији модела, неопходно је имати у виду да фази логички системи нису погодни за класификацију података. У те сврхе су развијани много успешнији алгоритми машинског учења. У овом случају, фази логички експертски систем је у функцији процене стања, израчунавањем броја који се може тумачити као својеврсни „индекс здравља“ генератора. На тај начин, са адекватним подешавањем функција припадности и базе правила, могуће је извршити „рангирање“ генератора према њиховом стању и омогућити издвајање приоритета за одржавање и инвестирање.

Дакле, фази логички експертски системи захтевају претходно подешавање функција припадности у складу са усвојеним критеријумима и природом физичке величине. Затим, неопходно је дефинисати скуп IF-THEN правила којим се дефинишу релације између улазних и излазне/излазних величина. Скуп правила у овом раду је дефинисан у складу са искуством у погледу најчешће детектованих процеса деградације ЕИС. Тренутно, не постоји конвергентно мишљење међу истраживачима о неопходном минималном броју правила. Број могућих комбинација је изузетно велики, чак и за свега неколико улазних величине. У овом раду биће генерисана правила која приказују већину потенцијалних сценарија деградације ЕИС статорских намотаја. Након тога, могуће је посматрати зависности излазне величине од улаза, те вршити адаптацију функција припадности или релација у бази правила како би се моделовали одговарајуће зависности. База правила приказана је у прилогу 2.



Слика 18 Алгоритам развоја фази логичког експертског система



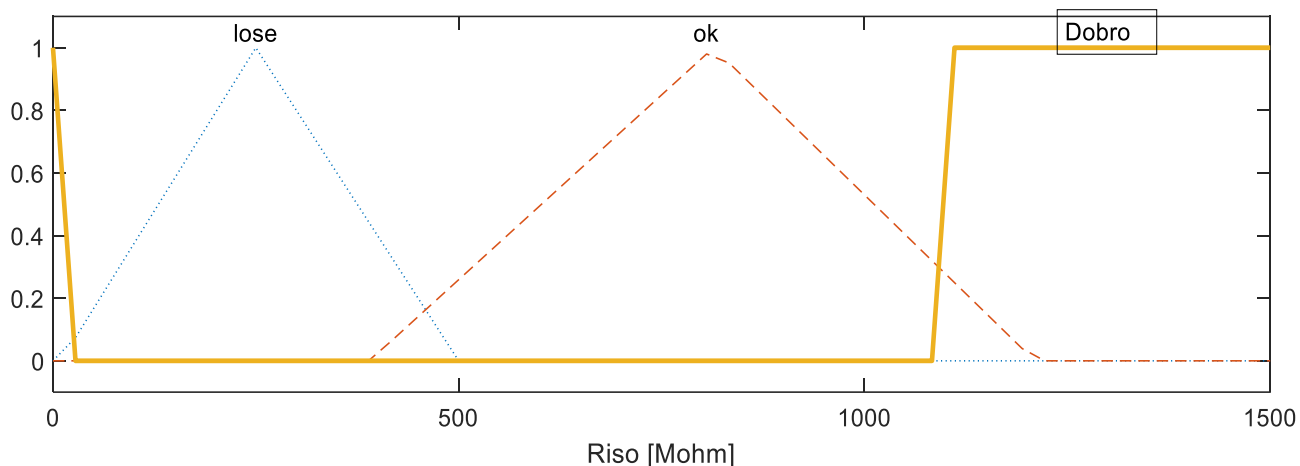


Слика 19 Упоредни приказ грешака показивања за завршна три модела

Истовремено, уколико се жели као улазни податак користити резултат мерење електричног отпора изолације, што је свакако базично, рутинско дијагностичко испитивање, морају се дефинисати начини третирања статорских намотаја који се хладе водом.

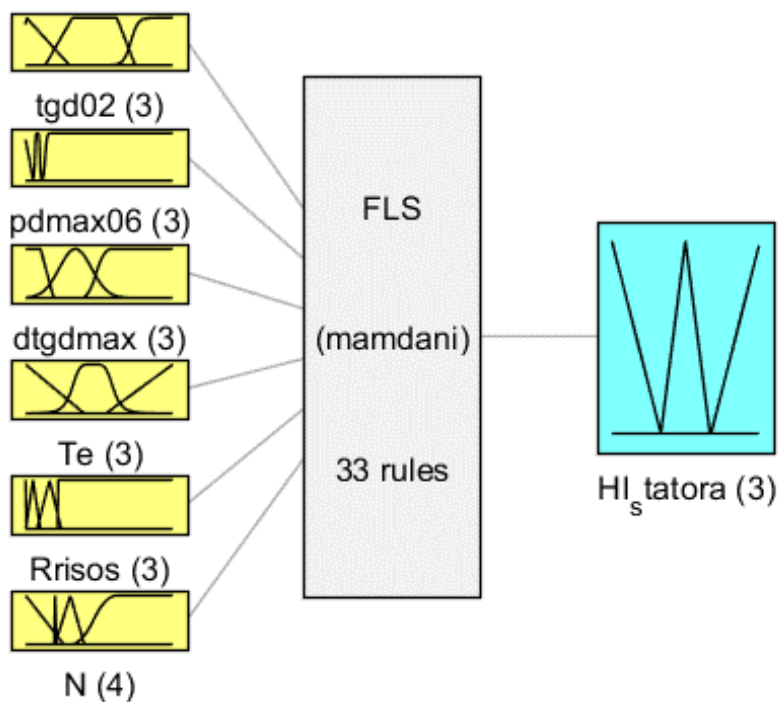
Наиме, водом хлађене машине се углавном испитују са расхладном водом у циркулацији, те ово испитивање као резултат доминантно приказује квалитет воде, директно пропорционалан специфичној отпорности расхладног флуида. Овај резултат је углавном изузетно низак и створио би много погрешних закључака када би се гледао кроз савремене дијагностичке оквире и критеријуме. Такође, резултати нису од великог дијагностичког значаја када се посматра цео ЕИС статора али се као неопходно наметнула потреба за могућношћу исправног третирања ових резултата, како имплементација овог експертског система не би захтевала претходно прилагођавање дела улазних података.

Стога је, у сврху моделовања оваквих закључака по питању третирања вредности електричног отпора изолације, креирана посебна прилагођена функција припадности за вредности које се третирају као добре (Слика 20). Код којим је креирана наведена функција припадности приказан је у прилогу 9.



**Слика 20** Прилагођена импортована функција припадности за вредности електричног отпора изоације означена наранџастом бојом

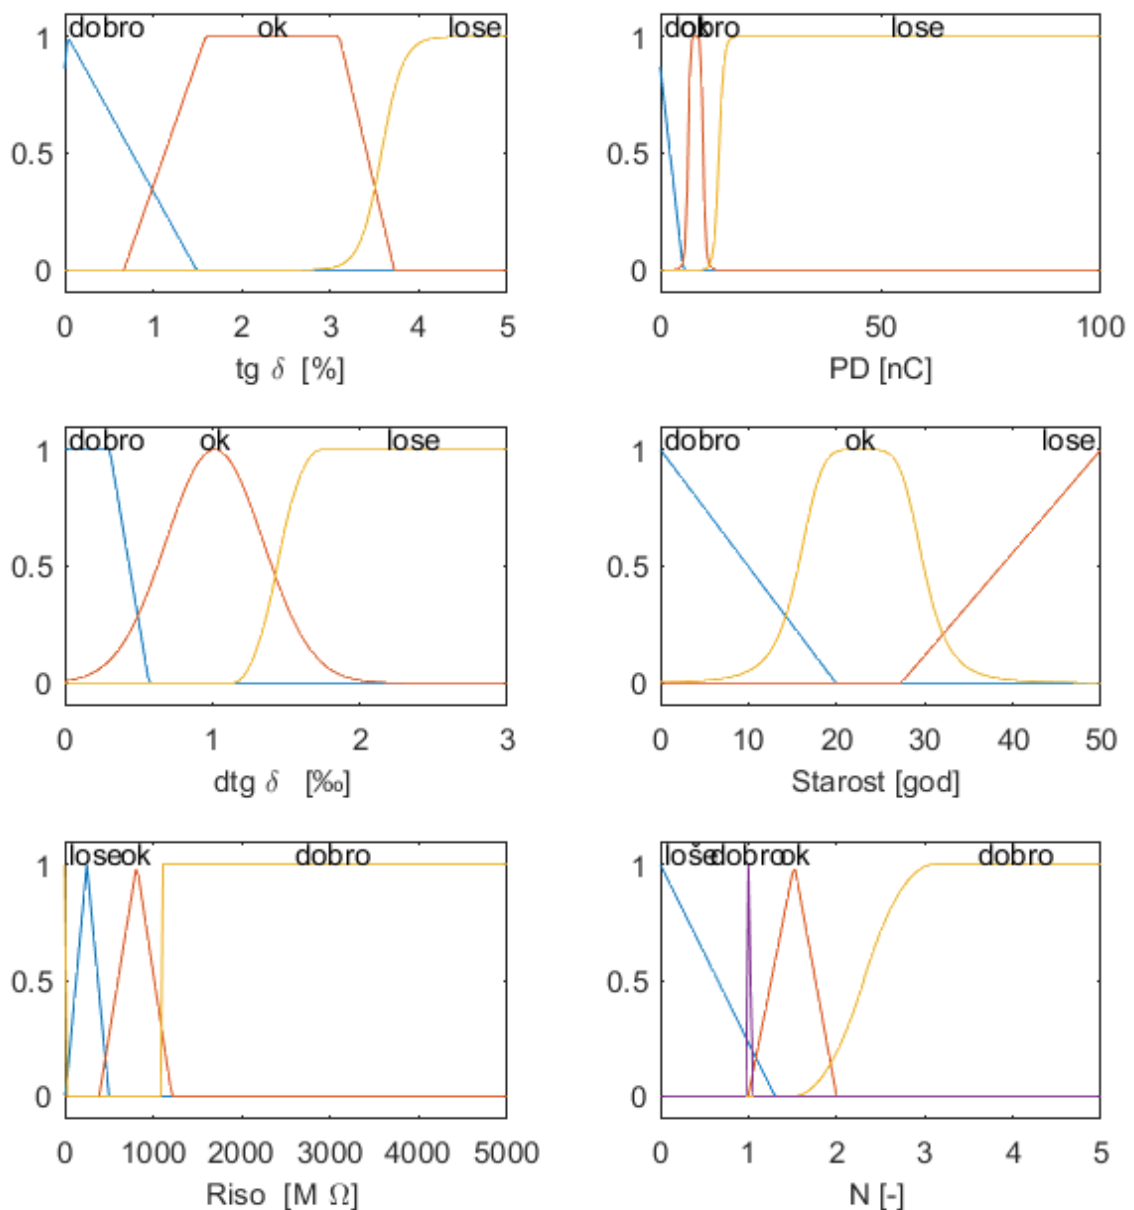
Експертски системи на бази фази логичког резонувања креирани су програмским алатима у оквиру програмског пакета *Matlab*. Коначна верзија приказана је на слици 21.



System FLS: 6 inputs, 1 outputs, 33 rules

**Слика 21** Фази логички експертски систем на бази Мамдани система закључивања са 6 улазних величина и једним излазом

Функције припадности су подешене тако да покушавају да репродукују граничне вредности приказане у поглављу 3. Фазификација улазних величина је најпре изведена са већ предефинисаним троугаоним функцијама припадности, а потом је вршено подешавање како би се генерисале одговарајуће зависности и минимизовала грешка при одлучивању. Напоследку, усвојене су функције припадности као на слици 22.



Слика 22 Функције припадности за 6 улазних величина фази логичког експертског система


При формирању функција припадности усвојене су следеће критеријумске вредности:

- Вредности електричног отпора изолације преко 1000 мегаома ће се сматрати добрим вредностима. Такође, вредности од 300 k $\Omega$  до 5M $\Omega$  ће се такође сматрати добрим вредностима. Ово се уобичајне вредности при мерењу на водом хлађеним машинама. Уколико се ове вредности не узму у обзир, могу проузроковати значајан број лажно лоших


или сумњивих резултата. Вредности од  $5M\Omega$  до  $500M\Omega$  биће третиране као лоше вредности. Вредности од  $500M\Omega$  до  $1000M\Omega$  бити сматране сумњивим. Слично томе, индекс поларизације ће бити сматран добрим уколико износи тачно 1.0, или уколико је већи од 2. Задовољавајуће вредности су између 1.3 и 2, док су вредности испод 1 незадовољавајуће.

- Фактор диелектричних губитака  $tg\delta$  испод 1.5% је оцењен као добар. Задовољавајућим се сматрају вредности између 1.5% и 3%, док ће вредности преко 3.5% бити сматране лошим вредностима. За исте категорије прираштаја фактора диелектричних губитака усвојене су границе од 0.5‰, 1.5‰ и 2‰.
- Све вредности интензитета парцијалних пражњења при испитном напону од  $0.6U_n$  испод  $5nC$  ће бити третиране као добре вредности. Интервал од  $5nC$  до  $10nC$  ће за фази логички експертски систем бити задовољавајућа вредност, док ће сви интензитети ПП изнад  $10nC$  бити сматрани лошим вредностима.
- Старост синхроног генератора је прорачуната од године производње машине. Старост испод 20 година сматраће се добром вредношћу, 20 до 30 година сумњивом, док ће све машине старије од 30 година имати за старост оцену „лоше“.


Након финог подешавања функција припадности извршена је и допуна базе релација односно правила. Функција припадности излазне величине приказана је на слици 23. Зависности појединих улаза и њихов комбиновани утицај на излазну величину може се посматрати кроз тродимензионе графиконе на сликама 24-27.



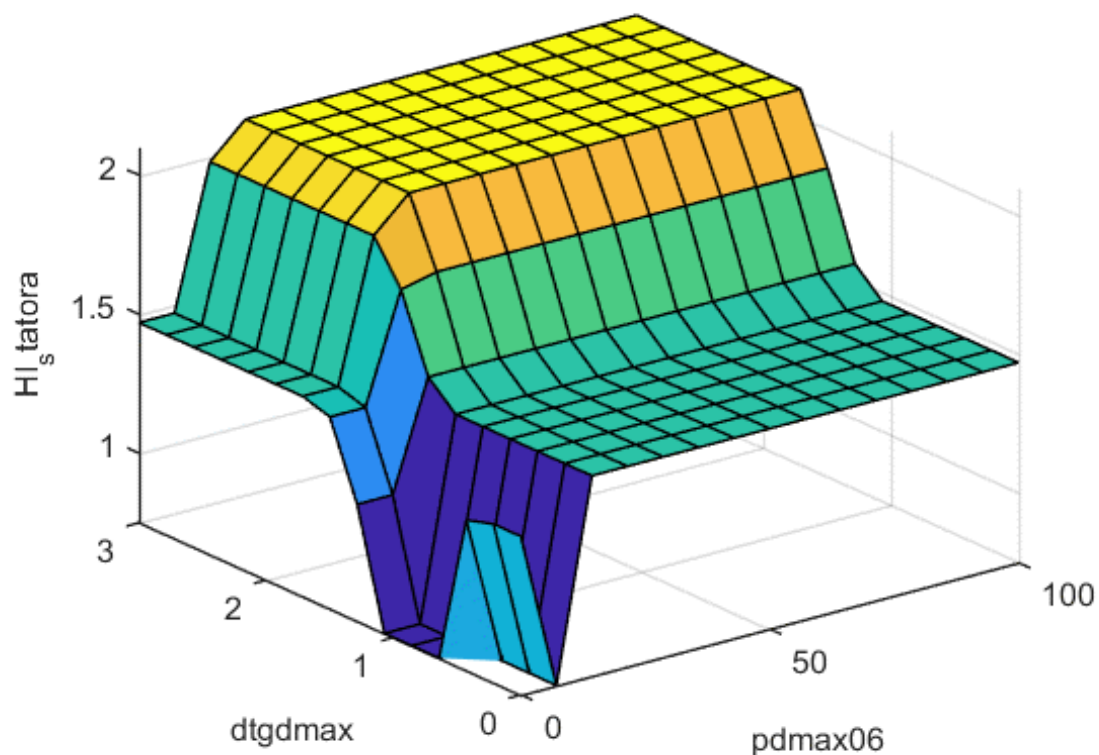
Слика 23 Приказ функције припадности излазне вредности - индекса стања генератора




Слика 24 Вредности излазне величине фази логичког експертског система у функцији почетне вредности  $tgd$  и старости машине



Слика 25 Вредности излазне величине фази логичког експертског система у функцији почетне вредности  $tgd$  и парцијалних пражњења



Слика 26 Вредности излазне величине фази логичког експертског система у функцији максималне вредности прираштаја  $tgd$  парцијалних пражњења



Слика 27 Вредности излазне величине фази логичког експертског система у функцији електричног отпора изолације намотаја статора и индекса апсорпције

### 5.3 Предикција стања на основу модела

Као што је већ напоменуто, овај тип експертског система није нарочито погодан за класификацију података. Овај налаз је потврђен израдом матрице конфузије система за скуп од 538 реалних скупова резултата (Слика 28) из које се може закључити да је само 21,6% података класификовано на исти начин као што је то урадио експерт. Разлог за ово је у чињеници да овај систем даје оцену улазног скупа података на скали од 0 до 3, те простим заокруживањем ових вредности није могуће извршити употребљиву класификацију у три скупа.

**Confusion Matrix**

Output Class	1	5 0.9%	0 0.0%	1 0.2%	83.3% 16.7%
	2	81 15.1%	16 3.0%	15 2.8%	14.3% 85.7%
	3	224 41.6%	101 18.8%	95 17.7%	22.6% 77.4%
		1.6% 98.4%	13.7% 86.3%	85.6% 14.4%	21.6% 78.4%
		1	2	3	
		Target Class			

Слика 28 Матрица збуњености фази логичког експертског система


Најважнија одлика овог система је да може „распознати“ нешто боље вредности од оних лошијих и на тај начин „рангирати“ резултате према израчунатој оцени. Пример излаза прорачунатих фази логичким експертским системом за неколико различитих улазних података приказан је у табели 5.

Табела 5 Пример израчунатих "индекса стања" генератора за различите улазне вредности

Генератор бр.	$\text{tg}\delta$ @0.2Un [%]	PD [nC]	$\Delta\text{tg}\delta_{\text{max}}$ [%]	Starost [god]	Riso [MΩ]	N [-]	Oцена
1	0.70	3.2	0.42	11.5	4730	3.56	0.57
2	0.80	15	1	20	900	1.12	1.68
3	3.6	50	1.5	40	585	1.44	2.68


Из табеле се може уочити да подаци за генератор 1 указују на задовољавајуће стање генератора те самим тим фази логички експертски систем је за овај сет података израчунао оцену 0.57, што представља добру вредност. Насупрот томе, резултати генератора 3 указују на деградиран изолациони систем са вероватно великим бројем шупљуна и деламинација унутар запремине диелектрика као последица интермитентног рада и остарелости машине. Стога, експертски систем му је доделио оцену 2.68, истичући тиме лоше стање машине.

Упоредни приказ резултата фази логичког експертског система и оцена експерта на моделованиј бази података 20 генератора дат је на слици 29, док је грешка модела приказана на слици 30. Са приложених графикана може се уочити велика подударност оцена експерта и оцена насталих као производ прорачуна модела.



Слика 29 Упоредни приказ резултата експертске анализе и прорачуна фази логичког модела на бази од 20 моделованих резултата





Слика 30 Грешка фази логичког експертског система на прорачуну за 20 моделованих резултата

## 6. Вештачка неурална мрежа

---

Неурална мрежа за процену резултата испитивања ЕИС намотаја ротора и статора је креирана у програмском пакету *Matlab*. Имплементиран је метод учења за препознавање образаца (*Pattern Recognition*) [75]. Мрежа је „обучена“, тј. „тренирана“ на скупу реалних података о испитивањима генератора којима је као излазни податак придодата оцена стања пружена од стране експерата у овој области као и апсолутна старост генератора.

### 6.1. Припрема података

Као основни скуп за тренирање неуралне мреже биће употребљен скуп улазних података из прилога 1. Као жељене излазне величине биће коришћене оцене стања дате анализом експерта, на основу важећих техничких препорука и искустава са дијагностиком електричних машина. Оцене експерта категоришу сваки ред података сачињених од следећих величина:

- Почетна вредност  $\text{tg}\delta$  на  $0,2U_n$  – максимална вредност одабрана између резултата све три фазе
- Максимална вредност пораста  $\text{tg}\delta$  на по кораку испитног напона од  $0,2U_n$
- Максимална вредност интезитета парцијалних пражњења при  $0,6U_n$
- Минималне једноминутне вредности електричног отпора излације фазних намотаја и индекса поларизације фазних намотаја статора
- Вредност електричног отпора изолације ЕИС намотаја ротора
- Апсолутна старост намотаја статора у годинама

Оцена експерта је формирана у последњој колони. Пример табеле је приказан у Прилогу 1. Оцене експерта су приказане у форми бројева који су еквиваленти лингвистичких закључака о стању ЕИС генератора као према [ТР32]:

- Број 3 је означавао највишу оцену која представља задовољавајуће стање генератора без процене било какве ометености за даљи нормалан погон генератора.


- Број 1 је, антагоно броју 3, представљао лоше стање генератора, које захтева озбиљан третман и процењује се да је даљи погон генератора ризичан с обзиром да су деградациони процеси у ЕИС сходно резултатима узнатредовали.
- Број 2 представља оцену „ Сумњиво“ и означава скуп резултата који још увек не угрожавају погон генератора, али су примећене назнаке деградационих процеса које би у будућности могле прерасти у већи проблем. Ово су ситуације у којима се уобичајно препоручује појачано праћење стања ЕИС генератора учесталијим испитивањима.

Оцене креиране у једној колони су при обради и припреми података раздвојени у 3 колоне, како би се подаци адекватно припремили за тренирање неуралне мреже која ће будуће улазне податке да препозна обрасце по којима су додељиване поједине оцене и скуп будућих улазних података успешно класификовати као добро, сумњиво или лоше. У овим колонама, које ће се при процесу тренирања сматрати циљаним вредностима, број 1 означава потпуну припадност одговарајућег реда том скупу. Број 0 означава потпуну неприпадност датом скупу тзв. *“one hot”* модел приказа категорисаних података. На тај начин су конвертоване оцене 1, 2 и 3 у колоне добро, сумњиво и лоше, тј. систему учења, тренирања, је на овај начин наложено да мрежу истренира тако да са што је могуће већом тачношћу класификује податке у три типа (класе, колоне).

## 6.2. Креирање и евалуација модела

Тренирање вештачке неуралне мреже и процена тачности модела је извршена у програмском пакету Матлаб. Употребљена је функција *nprtool* којом је могуће тренирати двослојне *feed forward* неуралне мреже. Процес тренирања се састоји од уноса два одвојена скупа улазних и излазних података, претходно припремљених као што је објашњено у 6.1.

Алгоритам за тренирање врши подешавање тежинских фактора почевши од насумичних вредности и посматрајући функцију за прорачун грешке те ажурирајући тежинске факторе тако да ова функција има опадајући градијент. Градијент је прорачунат пропацијом грешака на излазним чворовима ка улазним (*backpropagation*). Тренирање мреже је извршено на целом скупу од 538 узорака са њима додељеним оценама. Архитектура мреже је приказана на слици 31. Процес креирања вештачке неуралне мреже за процену стања синхроних генератора коришћен у овом раду приказан је алгоритмом на слици 32.



Слика 31 Конфигурација вештачке неуралне мреже за процену стања генератора

Креирана мрежа обрађује 7 улазних величина и 3 излазне, по једна колона за сваку категорију: добар, сумњив и лош ЕИС генератора.

Мрежа је конципирана као ациклична са 50 неурона у скривеном слоју и 3 излазна неурона. Број скривених неурона је подешаван како би се постигла најмања грешка система уз оптималан број неурона. Тако се, нпр. грешка модела занемарљиво умањила са даљим повећавањем неурона у скривеном слоју.

Однос података за тренирање, валидацију и тестирање је 70%, 15% и 15%, респективно.

Софтвер итеративно пролази кроз процес обучавања неуралне мреже сваки пут прорачунавајући грешку система. Циљ је обучити мрежу која ће класификацију вршити уз што је могуће мању вредност грешке система. Минимална грешка је постигнута у 54 итерацији (епохи), уз градијент од 0,0294.

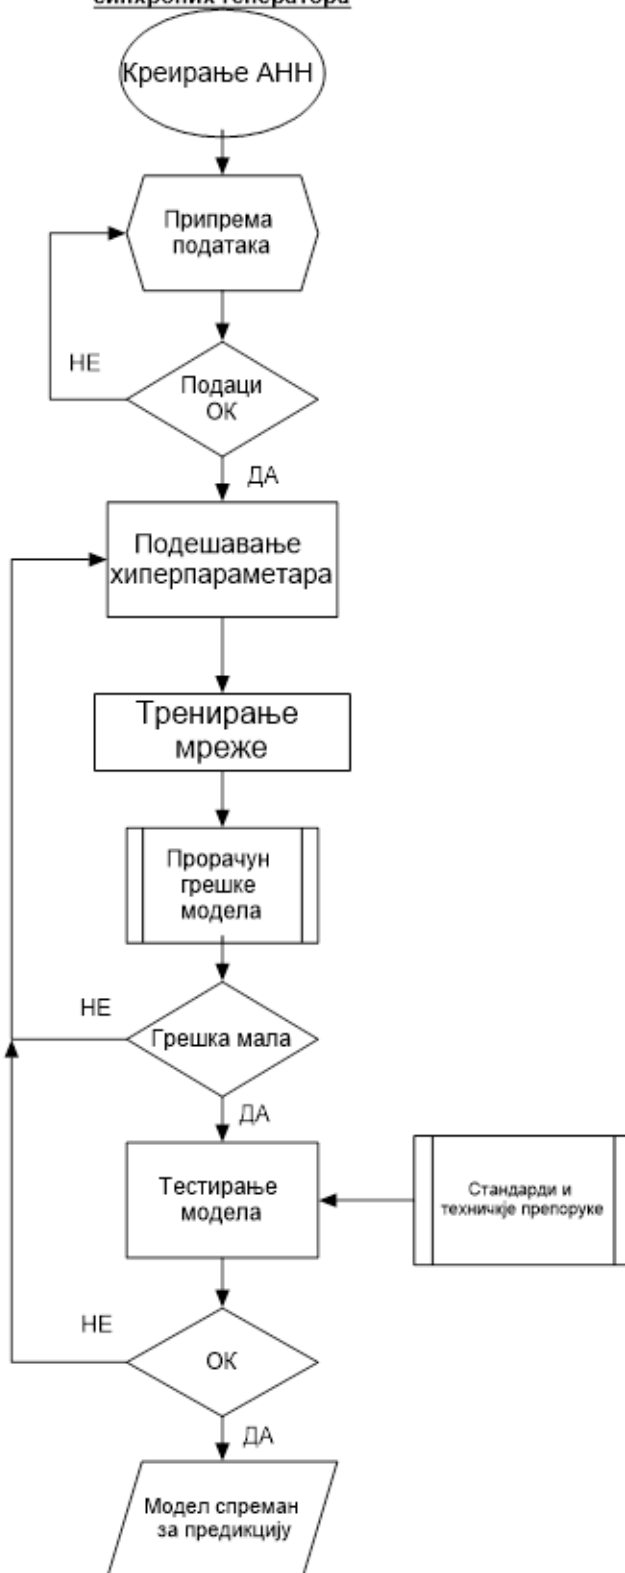
Приказ грешака је дат на слици 33 кроз матрице грешака или „збуњености“ неуралне мреже(прилог 7). Из дате матрице се поред осталих, могу извести следећи сумирајући закључци:

- На подскупу за тренирање 90,2% података је тачно категорисано, док је при категоризацији 9,8% података начињена грешка
- На подскупу за валидацију 95,1% података је тачно категорисано, док је при категоризацији 4,9% података начињена грешка
- На подскупу за тестирање 84% података је тачно категорисано, док је при категоризацији 16% података начињена грешка

- На целом скупу од 538 узорака 90,0% података је тачно категорисано, док је при категоризацији 10% података начињена грешка.

На графиконима на слици 34 приказана је *ROC (Receiver Operating Characteristic)* функција којом се може утврдити квалитет неуралне мреже за класификацију (Прилог 7). На приказаним графиконима уочава се да су функције за све три категорије у горњем левом делу, што указује на квалитетан систем за аутоматизовану класификацију. Исти налаз се може потврдити и из хистограма на слици 35, где је јасно приказано да је већина података у све три категорије приказана са минималном грешком, што такође указује на квалитетно формирану неуралну мрежу за класификацију улазних величина. Мана доступног скупа резултата електричних испитивања ЕИС генератора је заправо у уделу количине података у свакој од категорија, што свакако утиче на укупну тачност креираног експертског система. Наиме, идеално би било да се за тренирање користе подаци са приближно сличном количином података за све три категорије. У овом случају, већина података описује добро стање генератора, управо зато што је једино такав скуп података доступан. Углавном, такви резултати се могу очекивати у погону, с обзиром да се увек већина генератора налази у добром, оперативном стању.


Креирање вештачке неуралне мреже за процену стања ЕИС синхроних генератора



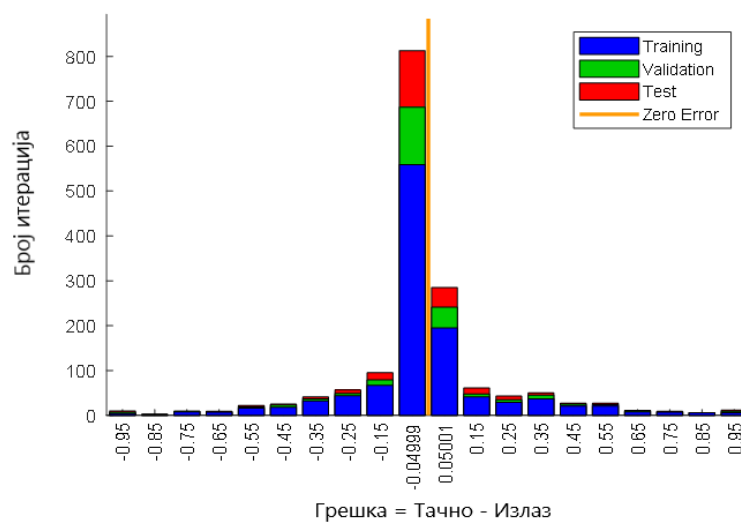
Слика 32 Процес креирања вештачке неуралне мреже за процену стања ЕИС синхроних генератора



Слика 33 Матрични приказ грешака мреже за сваки подскуп података –*Confusion matrix*



Слика 34 Приказ ROC функције (Receiver Operating Characteristics)



Слика 35 Хистограм грешке



### 6.3. Предикција стања на основу модела


Евалуација експертског система извршена је израчунавањем излазних вредности креираног модела на скупу од 20 моделованих података чије су вредности креиране и указују на неке типичне случајеве из праксе. Истовремено, израчунавање је извршено и за скуп од 538 резултата на којима је вршена обука неуралне мреже.

За предикцију стања довољно је позвати направљену функцију модела неуралне мреже и доделити јој скуп улазних података. Вредности добијене за скуп од 538 реалних приказане су у прилогу 1. Мрежа као излазну даје вредност од 0 до 1 у одговарајућим колонама које репрезентују стања добро, сумњиво и лоше. Формирање оцена 1, 2 и 3 из добијеног предикцијског скупа вредности вршена је као у примеру у табели 6.


**Табела 6 Пример формирања коначне оцене из прорачунатих вредности вештачке неуралне мреже**

Бројчана цена	Лингвистичка оцена	Припрема за "pattern recognition"			Резултати вештачке НМ			Предикција након обrade
		Добро=3	Сумњиво=	Лоше=1	Добро	Сумњиво	Лоше	
								Out= max(добро, сумњиво, лоше)
1	Лоше	1	0	1	0.011	0.082	0.908	Лоше
3	Добро	0	0	0	0.967	0.033	0.000	Добро
2	Сумњиво	0	1	0	0.163	0.836	0.001	Сумњиво

На слици 36 приказани су упоредно резултати настали као производ експертског система на бази неуралне мреже и оцена додељених од стране експерта на скупу за тестирање (Прилог3), док су на слици 37 приказана одступања закључака неуралне мреже и експерта.



Слика 36 Упоредни приказ резултата вештачке неуралне мреже и експерта



Слика 37 Грешка прорачуна оцене стања синхроних генератора на скупу за тестирање

## 7. Аутоенкодерска неурална мрежа

---

Основна идеја употребе аутоенкодера у сврхе дијагностике стања генератора на основу бројчаних резултата електричних испитивања ЕИС у овом раду заснива се на обучавању аутоенкодерске мреже да на основу великог скупа резултата који указују на добро стање генератора квалитетно репродукује улазни скуп података. Након тога, уколико се при репродукцији неког новог скупа улазних података уочи велико одступање, овај налаз може послужити као индикација да генератор више не припада класи ЕИС са задовољавајућим резултатима, односно, један или више критеријума премашује дозвољене граничне вредности. Дакле, премда је аутоенкодерска неурална мрежа оригинално ненадгледан модел машинског учења, обучавањем на означеном скупу података овде се практично користи у форми надгледаног машинског учења.

### 7.1 Припрема података

Подаци који ће бити употребљени за тренирање аутоенкодера су приказани у прилогу 7 и садрже вредности карактеристичне за добро стање ЕИС намотаја генератора. С обзиром да аутоенкодерске мреже заснивају свој принцип рада на реконструкцији улазног скупа података није могуће тренирати их тако да пружају један излаз, већ мрежа покушава репродуковати скуп података са улаза. Истовремено, за постизање задовољавајуће мале грешке система неопходно је имати велики узорак на коме би се систем научио са одговарајућом тачношћу. Стога је припремљена одговарајућа база вредности, вештачки креираних, моделованих резултата који указују на добро стање ЕИС генератора. Ова база је сачињена од 10000 резултата на којима се аутоенкодерска мрежа обучила да препозна добро стање ЕИС генератора. Као улазни подаци употребљене су следеће величине:

- Почетна вредност  $\text{tg}\delta$  на  $0,2U_n$  – аутоматски генерисан број са у интервалу од 0.3 до 3%. Прва вредност представља процењену најнижу очекивану стварну вредност, с обзиром да се не може очекивати да ова вредност буде 0 или много близу нулте вредности за овај тип ЕИС.
- Максимална вредност пораста  $\text{tg}\delta$  на по кораку испитног напона од  $0,2U_n$  - је аутоматски генерисан број у интервалу од 0.1 до 0.5%, што ће аутоенкодер посматрати као задовољавајуће вредности.
- Максимална вредност интензитета парцијалних пражњења при  $0,6U_n$  је такђе аутоматски генерисан број са задатим граничним вредностима од 0 до  $5nC$  [IS32].
- Једноминутне вредности електричног отпора излације и индекса поларизације намотаја статора у границама од 1000 до 100000  $M\Omega$
- Вредност електричног отпора изолације ЕИС намотаја ротора са границама од 100 до 10000  $M\Omega$
- Апсолутна старост намотаја статора у годинама од 0 до 30 година, с обзиром да углавном ова вредност представља пројектовани животни век генератора

Вредности испитивања међузавојне изолације намотаја ротора и индекс поларизације ЕИС намотаја ротора су изостављени при креирању овог алгорита с обзиром да су проузроковали веома велики пораст грешке тренирања, уз минимални дијагностички значај.


Пример креиране базе података је приказан у прилогу 4.

## 7.2 Креирање и евалуација модела

Кôд којим је извршено генерисање моделоване, вештачке, базе података „добрих“ резултата испитивања ЕИС генератора је приказан у прилогу 4. На овај начин се примена аутоенкодера трансформисала у делимично надгледани систем учења, с обзиром да је учење мреже извршено за обележен скуп података, који у основи није неопходан за тренирање аутоенкодера.

Тренирање аутоенкодера је извршено у програмском пакету Матлаб функцијом *trainAutoencoder*. Хиперпараметри аутоенкодерске мреже који су подешавани су број итерација (епоха), и број неурона у скривеном слоју аутоенкодера (Прилог 4).

Завршна верзија аутоенкодера је креирана са 75 неурона у скривеном слоју, уз 5000 итерација при тренирању (Слика 38). Алгоритам креирања експертског система на бази аутоенкодера приказан је на слици 39. На слици 40 приказана је грешка система у функцији броја епохе. Добијена грешка система од 0,0551 се сматра задовољавајућим резултатом. Са мањим бројем неурона у скривеном слоју, реда до 40 грешка система се кретала од вредности 3 до 25 у појединим случајевима. При томе, потребно је имати у виду да се грешка заправо мења сваким новим отпочињањем процеса тренирања услед различитих почетних услова који се сваки пут насумично аутоматски бирају.

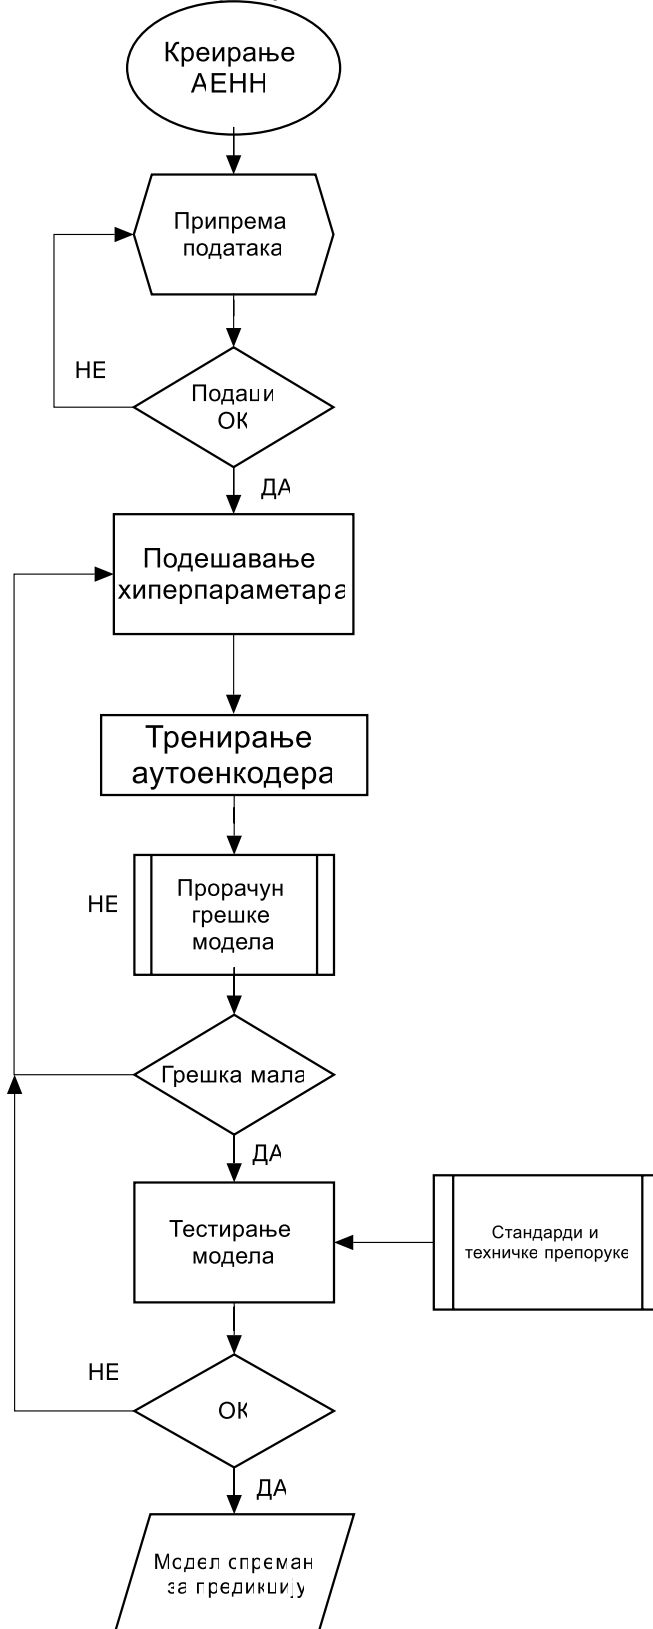


Слика 38 Приказ архитектуре креираног аутоенкодера


Тренирање аутоенкодера извршено је сходно алгоритму на слици 39 и окончано је са грешком модела:

$$\text{mseError} = 0,0551$$

**Креирање аутоенкодерске неуралне мреже за процену стања ЕИС синхроних генератора**



**Слика 39** Процес креирања аутоенкодера за процену стања ЕИС синхроних генератора



Слика 40 Приказ грешке у зависности од редног броја итерације

### 7.3 Предикција стања на основу модела

Прорачун стања синхроних генератора је извршен на скупу од 20 узорака приказаних у прилогу 6.

Идејно, овако креирана аутоенкодерска неурална мрежа није у стању пружити више информација осим процене да ли је скуп улазних података налик скупу добрих вредности или није. Уколико није стање генератора се проглашава упитним. Дакле, излазна вредност аутоенкодера је заправо грешка као индикатор поређења новог скупа резултата, са наученим „изгледом“ тог скупа. Тако, нпр. уколико вредности одабраних метода не улазе у опсег дефинисан као добре вредности, прорачуната грешка је очекивано велика.

Међутим, у овом случају, овај модел није био у стању довољно добро разликовати велики број добрих и „осталих“ вредности. Наиме, у примеру у табели 7, за скупове резултата који несумњиво указују на задовољавајуће стање генератора, овај алгоритам је приказао изузетно велике грешке, наводећи на закључак да је стање генератора прилично лоше.

Табела 7 Пример предикције стања аутоенкодера

Р. бр	Резултати испитивања									Оцена експерата	Резултат аутоенкодера
	$tg\delta_{0.2Un}$	$\Delta tg\delta$	PD06	Risos	N	Risor	Nr	M3И	Стар		
1	0.377	0.618	3.4	2630	3.55	356	1.4	0	37	3	62420.77
2	0.520	0.340	6000	3830	3.18	45	1.3	0	8	3	298256743.90
3	0.549	0.200	3800	6640	3.79	63.2	1.2	0	10	3	263417101.45
4	0.556	0.280	1300	1970	3.51	0.071	1.5	0	60	3	262855252.32

При тестирању аутоенкодера уочен је велики број ових нетачних налаза те се овако креиран експертски систем показао прилично нетачним и тешко употребљивим. У табели 8 су упоредо приказани резултати процене експерата и аутоенкодерске неуралне мрежена скупу од 20 генератора који су намењени тестирању модела.

Табела 8 Приказ резултата аутоенкодера

Експерт	1	3	2	2	2	2	3	2	2	2	2	3	1	2	3	2	1	2	2	3
АЕ	9.48.1	95.1E-3	1.6E+6	42.3E+3	31.2E-3	245.6E+3	15.7	9.3E+3	128.2E+3	66.8E+3	4.4E+3	1.3	3.3	13.0E-3	27.3E+3	1.3E+6	4.3	4.8E+3	612.3E+3	352.4E-3

Разлог за овакво „понашање“ модела креираног аутоенкодерском неуралном мрежом је тешко растумачити . Међутим, може се наслутити из основне дефиниције аутоенкодерске мреже која гласи:



„Аутоенкодери, у суштини, представљају метод ненадгледаног учења неуралне мреже у сврху рекреације скупа података коришћеног за учење.“

Претпоставка аутора је да аутоенкодер из тог разлога није у стању добро да функционише на потпуно новом, „непознатом“ скупу података, у случају вишедимензионих скупова, који не „личи“ на скуп података на коме је вршено учење. Нпр. аутоенкодер се у литератури одлично показао у обради скупова података, као нпр. монохроматских дигиталних фотографија.

Истовремено, експертско знање није могуће потпуно применити, с обзиром да није могуће утицати на тежинске факторе које алгоритам прорачунава. Тако нпр, експерт неће доделити велики значај старости машине уколико су сви резултати добри. Међутим уколико су резултати испитивања лоши, а при томе је и машина премашила свој пројектовани животни век, свакако ће у доношењу коначне оцене старост утицати са великом тежином.

С тим у вези, употреба аутоенкодерске неуралне мреже на овде дефинисан начин и потребу није била могућа у домену могућности подржаних у софтверском пакету *Matlab*.

Ово свакако не умањује њене могућности у погледу имплементације у домену мониторинга на нешто другачији начин. Наиме, индикативно је да је њена примена сасвим могућа и извесна у погледу надгледања мониторисаних величина, не само генератора, већ и целог блока или постројења. У овом случају, улазни скуп у нормалним околностима не би одступао значајно, те је претпоставка да би аутоенкодер могао поуздано регистровати промене мониторисаних вредности и аалрмирати са одређеном логиком. Ово ће свакако бити предмет даљих истраживања могућности овог модела.

## 8. ANFIS - Adaptive Neural Fuzzy Inference system

---

### 8.1 Припрема података

За тренирање АНФИС система употребљена је база реалних података о испитивањима ЕИС генератора са следећим вредностима (Прилог 1):

- Почетна вредност  $\text{tg}\delta$  на  $0,2U_n$  – максимална вредност одабрана између резултата све три фазе
- Максимална вредност пораста  $\text{tg}\delta$  на по кораку испитног напона од  $0,2U_n$
- Максимална вредност интезитета парцијалних пражњења при  $0,6U_n$
- Минималне једноминутне вредности електричног отпора излације фазних намотаја
- Индекс поларизације ЕИС фазних намотаја статора (минимална вредност)
- Вредност електричног отпора изолације ЕИС намотаја ротора
- Апсолутна старост намотаја статора у годинама
- Оцена експерта


Дакле, систем се састоји од 7 улазних величина и једне излазне величине у виду процене експерта о стању ЕИС генератора у виду бројева 1, 2 и 3 при чему број 3 представља најбоље стање ЕИС.

## 8.2 Креирање и евалуација модела

Систем је креиран функцијом *trainanfis* у програмском пакету Матлаб. Овом функцијом креира се Сугено фази логички систем са једним излазом и врши се аутоматизовано подешавање свих параметара.

Завршна верзија АНФИС модела са приказом релација дата је на слици 41. Кôд којим је извршено тренирање модела је приказан у прилогу 6, док је алгоритам који примењен при креирању и подешавању система приказан на слици 42. Тренирање система је извршено на скупу од 538 реалних података. Завршно тренирање система након низа доступних подешавања и понављања је завршено након 4 итерације уз израчунату грешку система од 0,0293. Након тренирања, алгоритам је дефинисао укупно 2187 правила фази система која дефинишу релације између 7 улазних и излазне вредности.

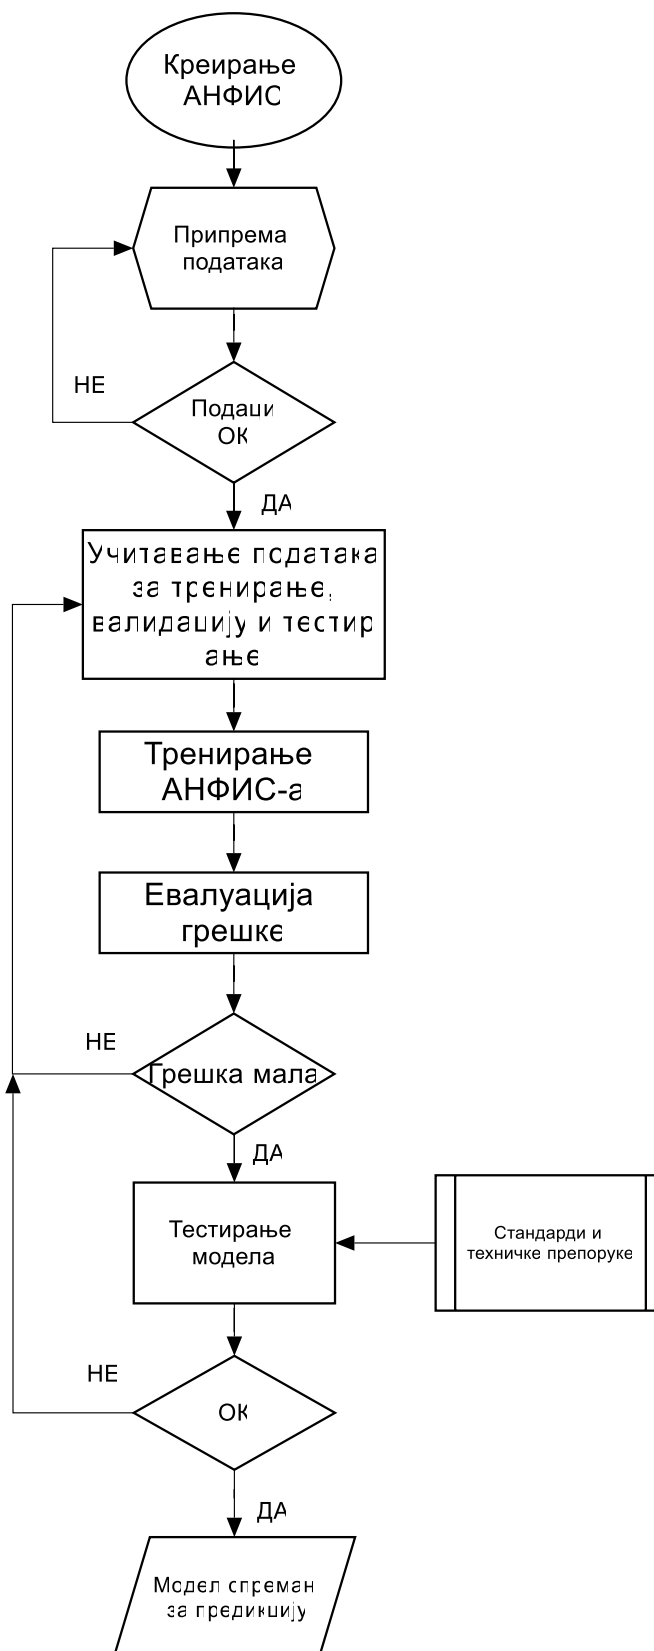
Јасно је да овај број правила није могуће једноставно графички приказати, те се на слици 41 само указује на комплексоност креираног система. Јасно је да мануелним уносом базе правила није једноставно правилно дефинисати велики број смислених правила, а нарочито не за велики број улаза. Овај корак је при дизајнирању фази логичких експертских система један од најзахтевнијих и најважнијих, али истовремено и временски најзахтевнији и најподложнији грешкама. Овом симбиозом фази логике и неуралних мрежа, овај корак је прилично симплификован уз очување задовољавајуће, па чак и боље тачности и поузданости целог система.



Слика 41 Анфис експертски систем за процену стања ЕИС синхроних генератора


С обзиром да је овај систем сличан фази логичком систему, такође није подесан за грубу класификацију, с обзиром да је у могућности да додели оцену са много већом резолуцијом од 1,2 и 3. Стога је такође веома употребљив за рангирање, у овом случају генератора према стању.

**Креирање АНФИС модела за процену стања ЕИС синхронних генератора**



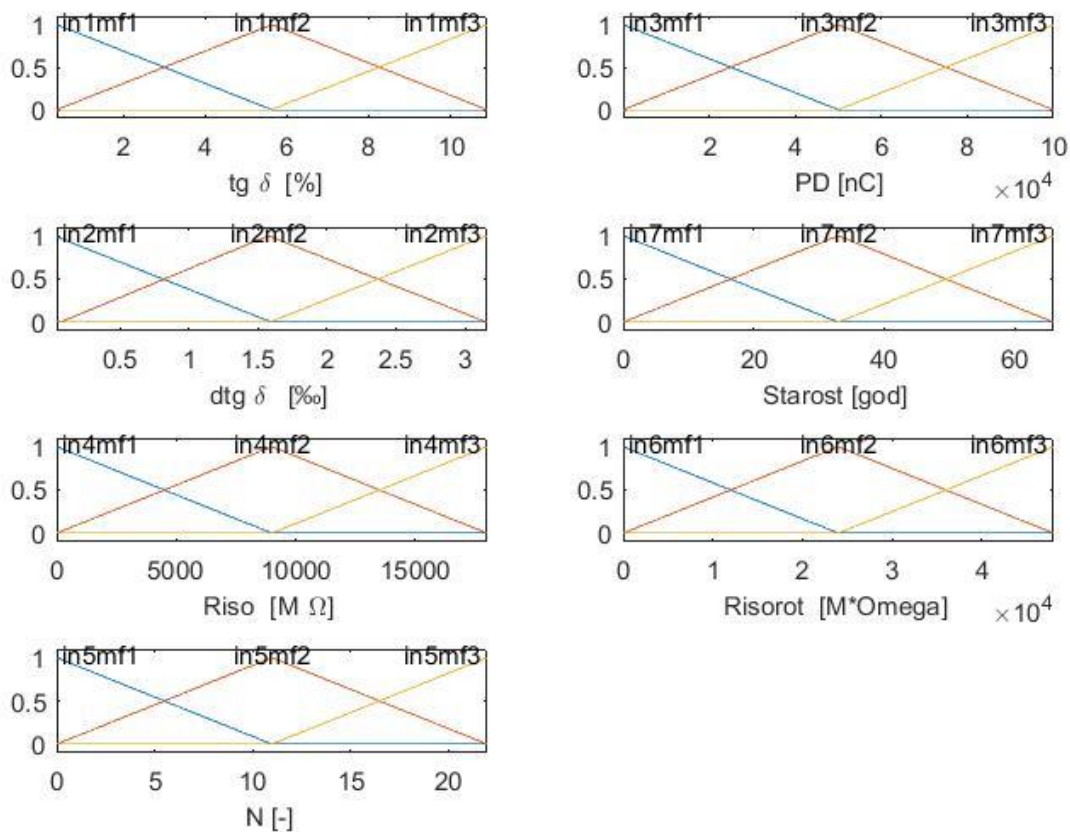
**Слика 42** Процес креирања АНФИС експертског система

Након низа тестирања и подешавања модела, креиран је фази логички експертски систем као на слици 43. При тренирању АНФИС-а, најмања грешка остварена је троугаоним функцијама припадности, као на слици 44. Зависност излазне величине од појединих улаза приказана је на сликама 45 до 48, у форми тродимензионалног графикона (*Surface view*).




System FLS: 7 inputs, 1 outputs, 2187 rules


Слика 43 Креирани АНФИС експертски систем за процену стања генератора




Слика 44 Функције припадности за поједине улазне величине дефинисане алгоритмом АНФИС-а




**Слика 45** Вредности излазне величине фази логичког експертског система у функцији почетног фактора диелектричних губитака и старости машине



**Слика 46** Вредности излазне величине фази логичког експертског система у функцији почетног фактора диелектричних губитака и максималног прираштаја фактора диелектричних губитака



Слика 47 Вредности излазне величине фази логичког експертског система у функцији електричног отпора изолације и интензитета парцијалних пражњења



Слика 48 Вредности излазне величине фази логичког експертског система у функцији почетног фактора диелектричних губитака и индекса апсорпције ЕИС




### 8.3 Предикција стања на основу модела

Прорачун оцене стања синхроних генератора извршен је у програмском пакету *Matlab* функцијом *evalfis()*. Пример израчунатих вредности за скуп од 10 резултата редовних испитивања из праксе дат је у табели 9. Подаци су преузети из табеле реалних резултата из прилога 1. За овај скуп података на слици 49 упоредно су приказани резултати АНФИС експертског система и оцена датих од стране експерта из области дијагностике стања ЕИС синхроних генератора.


Табела 9 Пример резултата предикције ANFIS система

Редни бр.	$Tg\delta_{0.2U_n}$ [%]	$\Delta tg\delta_{max}$ [‰]	PD [pC]	Riso [MΩ]	N [-]	Risor [MΩ]	Старост [год]	Оцена експерта	Оцена –ANFIS
1	0.640	0.230	100.0	0.163	1.00	0.041	29	3	3.24
2	0.640	0.890	54.0	210.000	2.30	0.250	30	2	2.75
3	0.669	1.000	46.0	280.000	2.15	13.000	30	2	2.77
4	0.671	0.130	6.2	2400.000	4.08	0.043	41	3	3.08
5	0.700	0.420	1300.0	1700.000	2.96	2120.000	14	3	3.00
6	0.700	0.940	51.0	320.000	2.38	0.150	30	2	2.78
7	0.710	1.220	20000.0	466.000	2.35	1.510	37	1	0.91
8	0.720	0.100	4400.0	0.060	1.00	0.020	20	3	2.85
9	0.723	0.096	2300.0	2510.000	2.70	16.570	64	3	2.62
10	0.740	0.627	10000.0	391.000	2.46	1870.000	53	2	1.98

Из графика на слици 49 се може једноставно увидети да је степен корелације између резултата процене стања синхроних генератора предикцијом изученог АНФИС експертског система и оцена датих од стране висококвалификованих експерата изузетно висок, те да овако креиран систем пружа логичне и очекиване резултате који се могу користити за рангирање генератора према стању и на тај начин издвајање приоритета за одржавање. Грешка у прорачуну оцене стања у поређењу са проценом експерта приказана је на слици 50.



Слика 49 Упоредни резултати експерта и резултати ANFIS експертског система




Слика 50 Грешка процене ANFIS експертског система на примеру од 10 генератора

Пример резултата произведених на скупу од 20 моделованих података за тестирање дати су у табели 10, а графички приказ на слици 51. Могуће је извести закључак да се посматрањем графикана на слици 51 свакако може запазити корелација оцена додељених од стране експерта и оцена прорачунатих анфис системом.

**Табела 10** Пример резултата АНФИС експертског система на скупу од 20 моделованих података о стању генератора

<b>Р.бр.</b>	<b>Експерт</b>	<b>АНФИС</b>
1	1	0,64
2	3	3,37
3	2	3,81
4	2	2,09
5	2	3,11
6	2	2,96
7	3	4,12
8	2	3,21
9	2	2,86
10	2	3,35
11	2	3,54
12	3	4,45
13	1	1,82
14	2	3,24
15	3	2,59
16	2	4,98
17	1	1,65
18	2	3,03
19	2	3,56
20	3	2,88



Слика 51 Упоредни приказ резултата АНФИС експертског система и оцена експерта на скупу од 20 моделованих података

## 9. Стабло одлучивања - *Decision tree*

---

### 9.1 Припрема података

Подаци употребљени за тренирање стабла су идентични скупу података употребљеном за тренирање вештачке неуралне мреже у делу 6.1 и АНФИС система у делу 8.1. Дакле, као релевантни улазни подаци користе се првих 7 колона базе од 538 података, док је последња колона оцена експерта дата на основу резултата. С обзиром да су иницијална истраживања и тестирања показала да је овај модел надгледаног учења прилично добро може репродуковати и већи број улаза, за тренирање стабла одлучивања коришћени су сви одабрани и доступни подаци, укључујући и мерења на ротору.

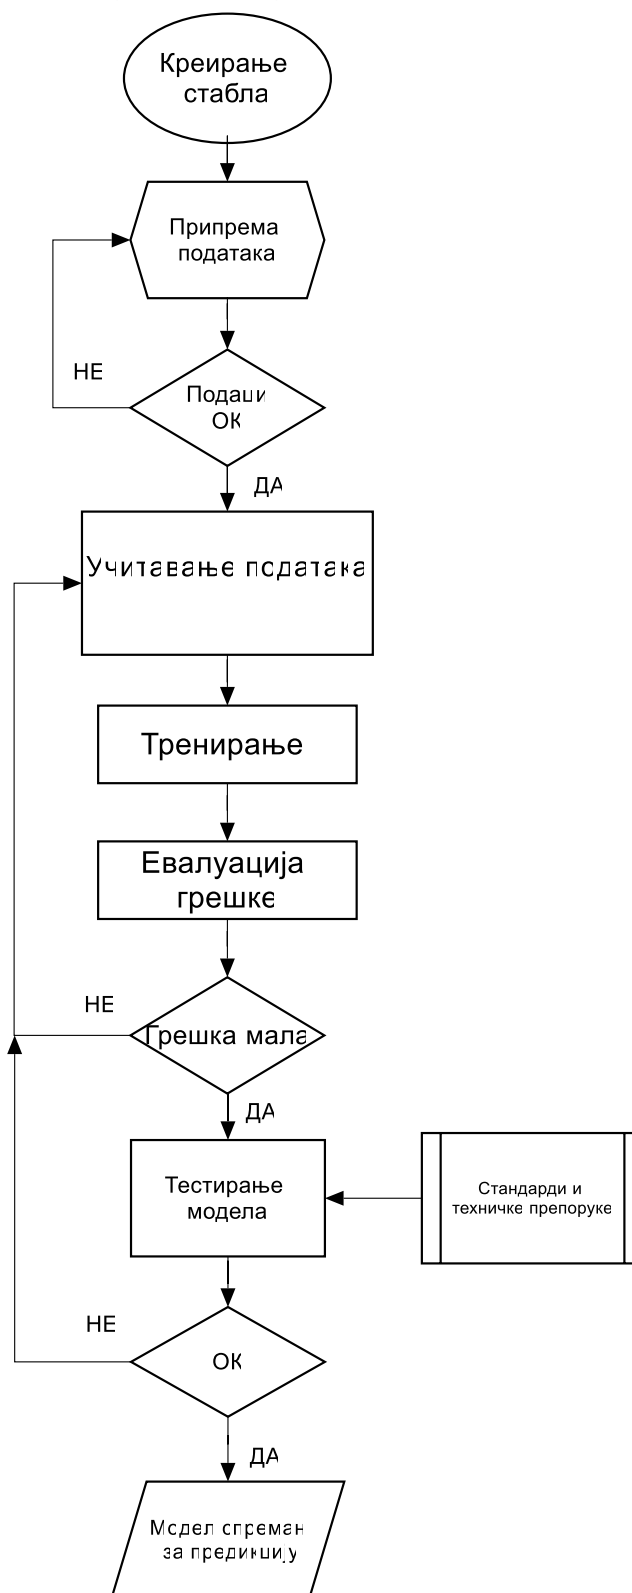
## 9.2 Креирање и евалуација модела

На бази припремљених података као у 9.1 софтверски алати у програмском пакету Матлаб ће извршити креирање класификационог стабла које ће бити тренирано тако да улазни скуп података класификује тј. оцени са 1, 2 или 3, налик скупу на коме је вршена обука стабла. За тренирање стабла коришћена је функција *fitctree* којом се тренира бинарно класификационо стабло на припремљеном скупу података. Алгоритам коришћен при креирању и процени стабла као експертског система приказан је на слици 52. Приказ класификационог стабла одлуке дат је на слици 53.

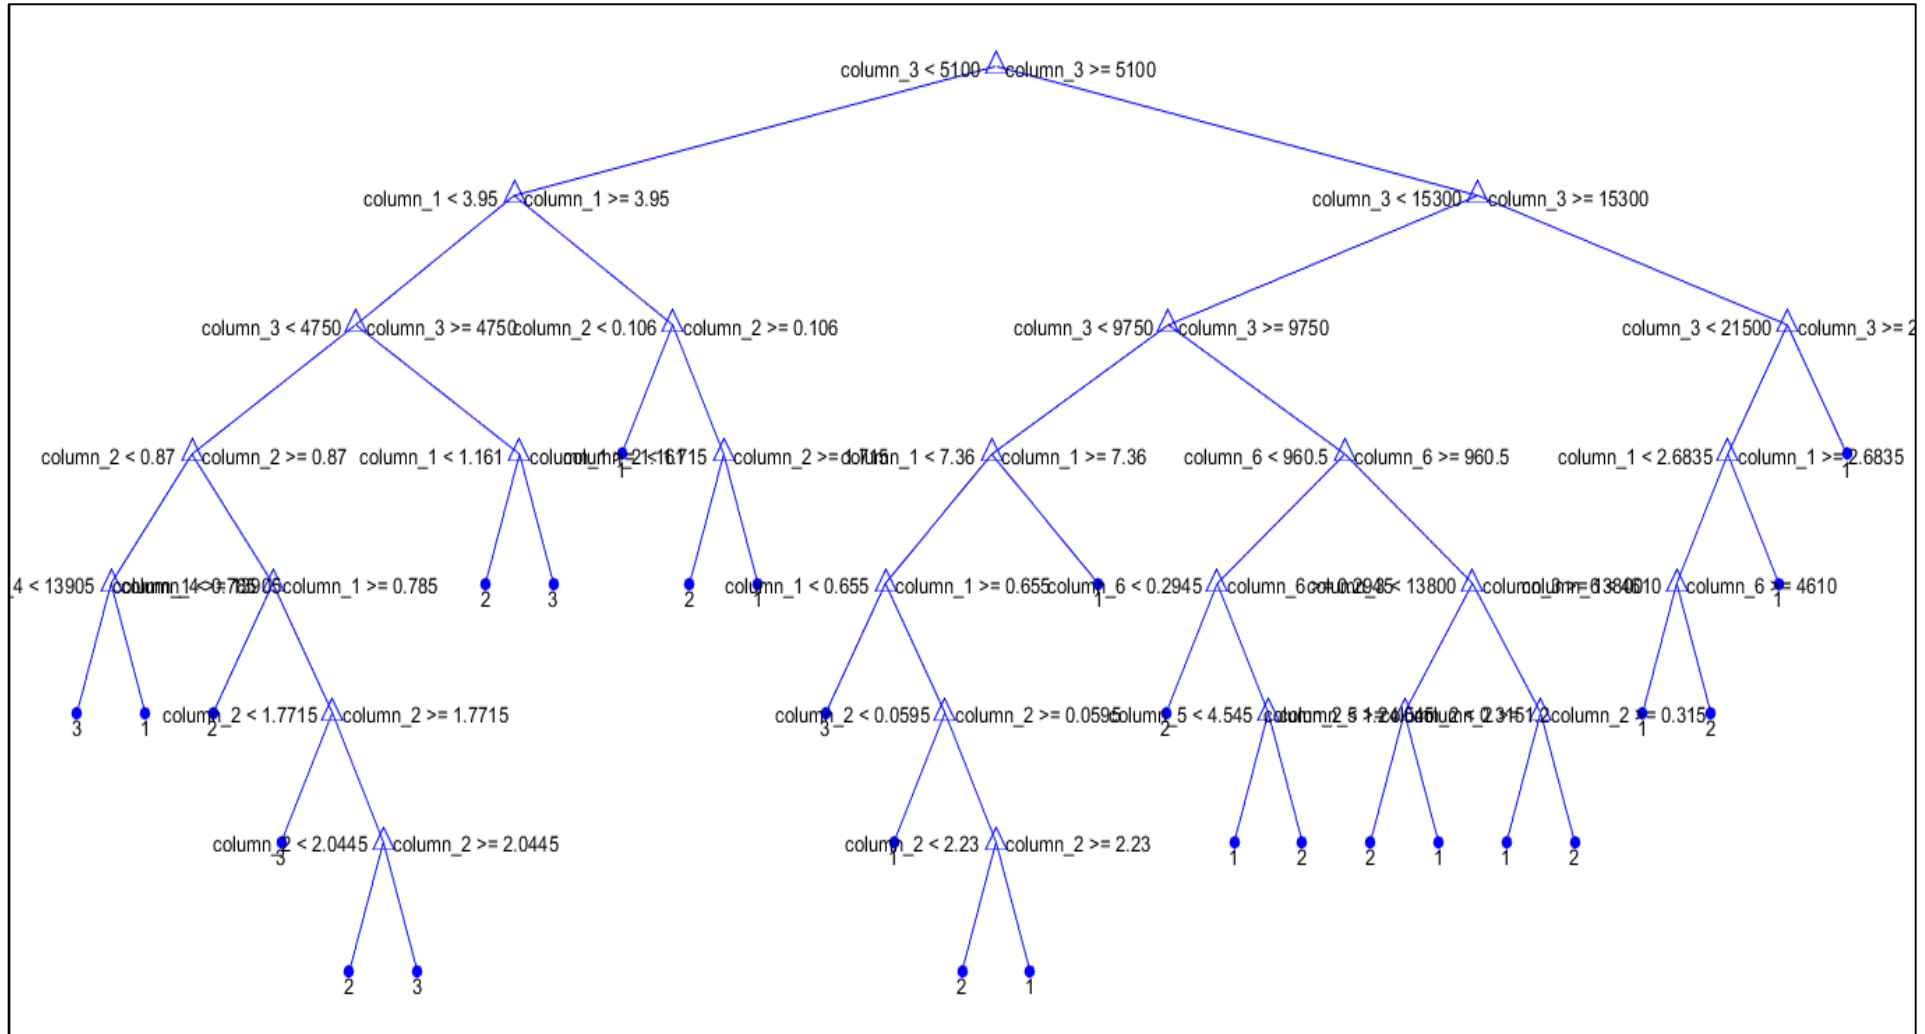
Процена квалитета класификационог стабла извршена је прорачуном матрице конфузије модела (слика 54) и ROC-а (Слика 55). Кратка појашњења наведених евалуационох алата дата су у Прилогу 8.

На основу приказа матрице конфузије и коефицијената TPR/FNR (True Positive Rate/ False Negative Rate) може се закључити да је тачност овако креираног стабла у класификацији улазних вредности у скуп „добрих“ вредности износи чак 97,7%, скуп „сумњивих“ односно вредност „2“ 65%, док је тачност класификације у скуп „лоших“ ЕИС једнака 77,5%. Очекивано је тачност највећа за класификацију у скупу добрих вредности с обзиром да је ових у скупу за тренирање стабла највише, око 3/5.

Креирање модела стабла одлуке за процену стања ЕИС синхроних генератора

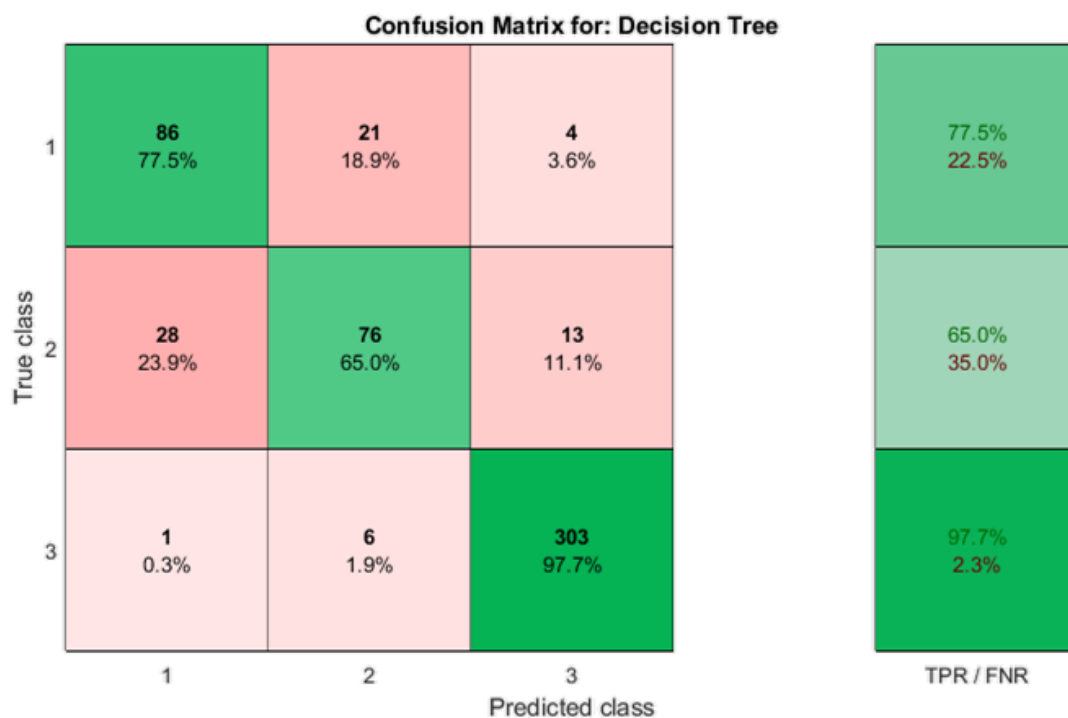


**Слика 52** Алгоритам коришћен при креирању стабла одлуке као експертског система за процену стања генератора




Слика 53 Класификационо стабло за процену стања ЕИС генератора





**Слика 54** Матрица конфузије класификационог стабла за предикцију стања ЕИС синхроних генератора



**Слика 55** Приказ ROC карактеристика за категорију добрих, сумњивих и лоших резултата

### 9.3 Предикција стања на основу модела

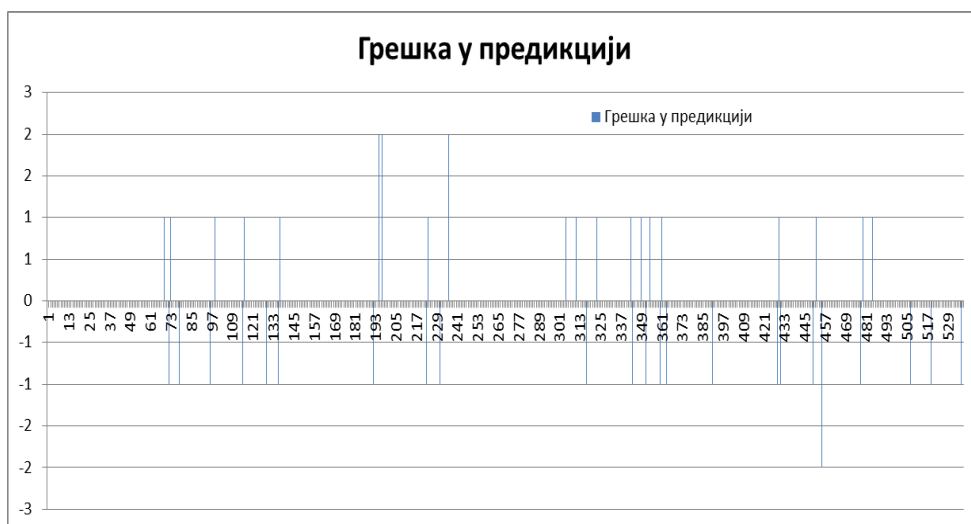
Овај експертски систем се показао као најтачнији, што показују и резултати тренирања презентовани у 9.2. Поређењем резултата изведени су следећи закључци:

- На скупу за тестирање од 20 генератора, класификатор је успешно класификовао све лоше резултате, што га чини изузетно добрим индикатором потребе за неким сервисном активностима. Од три резултата оцењена као „добро“ класификатор је направио грешку на једном улазном скупу сместивши га у категорију 2, с обзиром да је вредност интезитета парцијалних пражњења износила 13nС, тако да се ово може протумачити и као грешка у процени експерта, премда постоји могућност да је експерт имао као алат при доношењу одлуке и образац парцијалних пражњења који је вероватно указивао на задовољавајуће стање ЕИС и поред интезитета ПП од 13nС.
- Највише проблема класификатор је имао у класификацији улазних вредности које су оцењене као „сумњиве“ односно оценом 2. Чак и у редовној инжењерској пракси је овај подскуп увек најтеже разграничити. Модел је у највећем броју случајева подскуп класификован од стране експерта као „сумњив“ погрешно категорисао као „добар“.
- На скупу од 538 реалних резултата постигнута је корелација између оцена експерата и оцена добијених стаблом од 92%, што представља очекивано добар резултат с обзиром да се обучавање стабла вршило управо на овом скупу. Дакле, на овом скупу 8% улазних података је погрешно класификовано овако креираним стаблом.


Приказ грешке при класификацији на скупу од 538 узорака приказан је на слици 56. Упоредни приказ резултата оценом експерта и резултата модела дати су у табели 11 док је графички приказ дат на слици 57. На слици 58 приказана је грешка прорачуна на овом скупу. Са слике 58 се може закључити да модел погрешно класификује резултате у суседну категорију али се не дешава да је погрешно класификовао нпр. добро стање као лоше и обратно.

**Табела 11 Упоредни приказ резултата експерта и стабла одлуке**


Експерт	1	3	2	2	2	2	3	2	2	2	2	3	1	2	3	2	1	2	2	3
Стабло одлуке	1	3	2	3	3	3	3	3	3	3	3	2	1	3	3	3	1	3	3	3



Слика 56 Приказ грешака при предикцији на скупу од 538 узорака



Слика 57 Упоредни приказ оцена експерта и модела на бази стабла одлуке на скупу од 20 моделованих резултата испитивања генератора



Слика 58 Грешка модела заснованог на стаблу одлуке на бази од 20 моделованих података

## 10. Анализа модела и могућности примене

---

Могућности примене експертских система заснованих на вештачкој интелигенцији презентованих у овом раду су изузетне. Често је експертско знање и искуство веома скупо, компликовано за имплементацију у доношењу одлука, може бити субјективно и, можда најважније, веома често је у пракси изузетно тешко доступно. На овај начин се могу у великој мери превазићи сви наведени проблеми, нарочито у погледу оптимизације планова улагања и инвестиција.

У циљу верификације, подешавања и тестирања експертских система заснованих на вештачкој интелигенцији довољно је краткотрајно учешће експерата из појединих области. Након постизања задовољавајућих резултата, даља анализа и употреба произведених резултата могла би бити потпуно независна од њиховог присуства. На тај начин би се омогућила синтеза свих извршених мерења у једну величину, закључак или број, на основу којег би се на популацији машина могле вршити одговарајуће статистичке анализе, процене и производити планови. Овако креирани системи су веома прилагодљиви, поседују могућност даљег унапређивања и проширењима и на друга поља експертизе која су уско везана са проблемима у електротехници, као нпр. машинство.

## 10.1 Упоредна анализа креираних експертских система на бази вештачке интелигенције

У табели 12 дата је анализа и приказани закључци о предностима и манама појединих модела вештачке интелигенције креираним у овом раду. Закључци се односе на налазе аутора настале приликом израде сваког од модела и у сврху креирања експертских система у домену наслова ове тезе. На слици 58 дат је графички приказ упоредних резултата предикције свих креираних модела и оцена које су додељене од стране експерта.

**Табела 12 Упоредни приказ предности и мана сваког од коришћених модела**


Метод машинског учења	База означених података потребна ДА/НЕ	Претпроцесирање података неопходно ДА /НЕ	Експертско искуство неопходно за креирање модела ДА/НЕ	Једноставно креирање модела ДА/НЕ	Прецизност методе задовољавајућа
Фази експертски систем	НЕ	НЕ	ДА	НЕ	ДА
Неуралне мреже	ДА	ДА	НЕ	ДА	ДА
АНФИС	ДА	ДА	НЕ	ДА/НЕ	ДА
Аутоенкодерска неурална мрежа	ДА	ДА	НЕ	ДА/НЕ	НЕ
Стабло одлуке	ДА	ДА	НЕ	ДА	ДА

У табели 13 приказане су предикције оцена стања за све обрађене моделе машинског учења на скупу од 20 моделованих података о испитивању генератора. У првој колони су дате оцене експерта које се сматрају референтним, тачним вредностима. На слици 59 дат је упоредни графички приказ свих резултата прорачунатих моделима који су показали задовољавајућу тачност. Резултати аутоенкодерске неуралне мреже су изостављени.

Како би се грубо утврдиле прецизности свих креираних система, прорачунат је фактор корелације резултата предикције сваког од модела са оценама експерта које су сматране тачним вредностима (Слика 59). Са графикона на слици 59 јасно се издвајају системи креирани на бази стабла одлуке, а потом вештачке неуралне мреже, те АНФИС експертски систем. Ово су уједно и модели који су се при тренирању показали као најтачнији.

**Табела 13 Приказ резултата предикција свих креираних модела на скупу за тестирање од 20 моделованих резултата**


Оцена експерта	ФЛС	АНФИС	ВНМ	Стабло	Аутоенкодер
1	1.37	0.64	2	1	948.1110328
1	1.46	1.82	2	1	3.269734393
1	2.52	1.65	2	1	4.296931901
2	1.32	3.81	2	2	1643003.876
2	1.36	2.09	3	3	42344.95023
2	2.96	3.11	3	3	0.031159566
2	1.79	2.96	3	3	245627.9034
2	1.50	3.21	3	3	9265.14406
2	1.33	2.86	3	3	128165.4437
2	1.81	3.35	3	3	66795.17803
2	2.04	3.54	3	3	4419.576427
2	2.98	3.24	3	3	0.013044306
2	1.32	4.98	3	3	1340596.101
2	2.73	3.03	3	3	4813.422916
2	1.98	3.56	3	3	612300.9511
3	2.96	3.37	3	3	0.095119943
3	3.03	4.12	3	3	15.68256511
3	2.60	4.45	3	2	1.323507789
3	1.88	2.59	3	3	27297.6474
3	2.99	2.88	3	3	0.352350465
Фактор корелације	47,81	59,56	68,05	69,45	6,83



**Слика 59 Упоредни приказ резултата креираних модела на моделованој бази података**

Сви експертски системи су највише грешили у погледу предикције стања које су експерти оценили као сумњиво. Овај налаз се може значајно побољшати уколико се у будућности прикупи значајнија количина података везаних за ову оцену.

Експертски систем базиран на стаблу одлуке је са великом тачношћу уочио резултате који су оцењени као лоши, што представља својеврсну предност овако креираних система.



Слика 60 Фактор корелације низа вредности прорачунатих моделима машинског учења и оцена додељених од стране експерта



## 10.2 Одржавање према стању и одржавање према ризику

Прорачун индекса стања или „здравља“ генератора приказан у претходним поглављима веома често није оправдано користити самостално при планирању одржавања популације од неколико десетина генератора. Уколико се модел одржавања синхроних генератора заснива на стању машине (енг. *CBM – Condition Based Maintenance*), овај индекс је веома користан. Тим пре што омогућава синтезу свих измерених резултата у само један број.

Са становишта одржавања базираног на процени ризика од отказа није могуће подједнако третирати генераторе који су изузетно снажни, и оне који су малих снага. Утицај на стабилност и поузданост електроенергетског система услед испада великих, базних јединица је изузетно велика, док испади малих генератора од свега пар мегавата електроенергетски систем може превазићи без значајних потешкоћа. Стога се могу пронаћи разни модели којима се прорачунати индекс стања или „здравља“ генератора може употпунити као податак погодан за одржавање базирано на анализи ризика (енг. *RBM - Risk Based Maintenance*). Најједноставнији линеарни модел предложен у овом раду као податак користи производ прорачунате оцене стања и номиналне снаге машине. Увођењем новог коефицијента  $HI_{RBM}$  прорачунатог према следећој релацији:

$$HI_{RBM} = HI * S_n \quad (5)$$

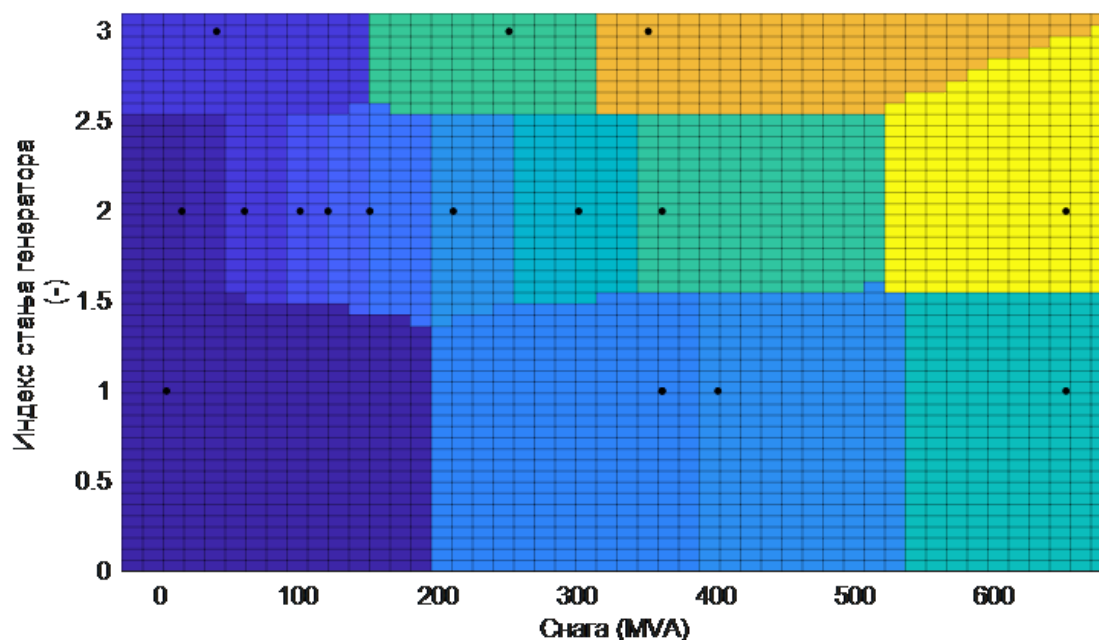
При томе, више оцене подразумевају лошије стање. На тај начин, машина од нпр. 350 MVA са оценом 2 производи RBM индекс 700. Слично, машина веће снаге, нпр 650 MVA са такође оценом 2 производи индекс RBM од 1300, те се јасно истиче да је неопходно пре свега пажњу посветити овој машини.

На скупу од 20 моделованих резултата извршен је прорачуната листа приоритета за превентивно одржавање базирано на стању као и према ризику прорачунатом према релацији 5. Резултати су приказани у табели 14. Предикцијске оцене стања су формиране тако да оцена 3 означава најлошије стање генератора, оцена 1 најбоље. Може се једноставно закључити да је примарно неопходно извршити корективне радње на генераторима под редним бројем 15, затим на генератору под редним бројем 3 итд.

Истовремено, резултати се могу приказати и у виду својеврсне „мапе ризика“ експлоатације (Слика б1). На приказаној слици испад генератора који се налазе ближе горњем десном углу графикона налазе се у већем ризику и са већим последицама од испада, те су стога интервенције на овим машинама су већег приоритета у односу на остале машине.

Табела 14 Приказ прорачунатих индекса стања за CBM и RBM модел одржавања

Редни број	Номинална снага (MVA)	Индекс стања (стабло одлуке)	Индекс RBM	Редослед одржавања према RBM
1	40	3	120	16
2	250	3	750	3
3	350	3	1050	2
4	4	2	8	19
5	8	2	16	18
6	15	2	30	17
7	60	2	120	15
8	100	2	200	14
9	120	2	240	13
10	150	2	300	12
11	210	2	420	8
12	290	2	580	7
13	300	2	600	6
14	360	2	720	4
15	650	2	1300	1
16	4	1	4	20
17	360	1	360	10
18	360	1	360	11
19	400	1	400	9
20	650	1	650	5



Слика 61 Мапа ризика експлоатације, односно мапа приоритета за одржавање

Примена ових образаца одржавања након усвајања одговарајућег модела вештачке интелигенције значајно може олакшати планирање оптималних средстава које је неопходно издвојити за поједине машине у циљу очувања максималне могуће поузданости. Рачунарски модели и резултати произведени на овај начин обезбеђују употребу мноштва статистичких алата те се закључци могу анализирати једноставно.

## **11. Закључак и будући рад**

---

У овом поглављу су сумирани утисци аутора стечени при раду, учењу и развоју свих модела и концепата приказаних у овом раду. Такође, презентовано је и виђење аутора о будућем раду и развоју из области примене науке о подацима и машинског учења у области планирања одржавања синхроних генератора али и електроенергетских објеката уопште.

## 11.1 Закључак

Развојем модерних информатичких система, могућности аквизиције, обраде и складиштења података из области електроенергетике уопште, постале су огромне. Екстракција корисних информација из велике количине података постаје, последично, дисциплина од великог значаја. У области индустрије и, уже, електроенергетике, могућности су веома велике. Развојем појединих модела приказаних у овом раду, дат је увид у могућности модерних алгоритама машинског учења и њихове примене у предикцији и аутоматизацији процене стања електроенергетске опреме, у конкретном случају, синхроних генератора.

Иницијални проблем у пракси дијагностике стања синхроних генератора, који је произвео идеју употребе вештачке интелигенције на начин презентован у овом раду, представљају нестандартизовани критеријумске вредности којима би се могли проценити резултати појединих тестова. У важећим међународним стандардима најчешће се дефинишу начини исправног извршења појединих мерења, али су изостављени критеријуми.

Затим, и у случају постојања интерних стандарда и критеријума, често је веома тешко сумирати резултате свих испитивања у коначну оцену, један број или описну процену.

Потом, у сврхе планирања одржавања и ресурса неопходних за одржавање, веома је тешко дефинисати листу приоритета, тј. извршити рангирање стања према процени стања и на тај начин издвојити приоритете.

Основни концепт тезе којом се настоје превазићи претходно наведени проблеми подразумевао је креирање експертског система на бази вештачке интелигенције који ће поуздано, тачно, логично и објективно репродуковати закључке експерта, односно тима експерата из области дијагностике стања синхроних генератора. На тај начин експертско знање постаје значајно доступније и присутније у области планирања одржавања синхроних машина.

У циљу проналажења адекватног решења, задатак је дефинисан као проблем класификације стања синхроних генератора као добро, сумњиво или лоше. Анализирани су модели базирани на неколико алгоритама машинског учења: фази експертски системи, АНФИС, неуралне мреже, аутоенкодерске неуралне мреже и стабла одлуке. Резултати креирања, односно тренирања, и предикције сваког од система су дате у одговарајућим поглављима. Аутор је извео закључак о укупној тачности свих система прорачуном индекса стања над моделованим скупом података који није коришћен при креирању и тестирању модела. На основу тога се као неповољан јасно истакао систем базиран на аутоенкодерској неуралној мрежи, која је на скупу за тестирање показала највећу грешку. Остали системи су се показали свакако употребљивим уз одређене разлике. Систем базиран на стаблу одлуке је и на скупу за тренирање и на скупу за тестирање јасно, и без много грешака истакао генераторе које су и експерти оценили као лоше. Из тог разлога је одабран за даљу анализу и пример могуће примене у моделима одржавања према стању и према ризику. Напослетку, приказани су могући модели прорачуна индекса стања или „здравља“ генератора на основу којих је могуће доносити даље одлуке о хитности одржавања, издвајати приоритете и вршити рангирање. Основни мотив се огледа у опште прихваћеној чињеници да унапређењем модела одржавања електроенергетске опреме, могуће је остварити значајну добит која се може употребити за даљи развој и унапређење пословања.

## 11.2 Перспектива примене и даљи развој

С обзиром на тренутна достигнућа информационих технологија у погледу примене вештачке интелигенције, а имајући у виду и тренутну перспективу овог поља науке, методе машинског учења су свакако један логичан корак којим се може управљати и користити подацима који су већ доступни.

Недостатак модела система надгледања стања стања електроенергетске опреме на овај начин је свакако подржан недостатком стандардизације ове области, што је, даље, утицало на неуниформност доступних података као још један отежавајући фактор. Стога из ове тезе јасно проистиче препорука за даљим усавршавањем и широм имплементацијом како *off-line* тако и *on-line* решења за мониторинг стања електроенергетске опреме, а нарочито опреме од великог значаја за укупну поузданост електроенергетског система попут синхроних генератора и енергетских трансформатора. Даље, неопходно је, по мишљењу аутора, усмерити будућа истраживања у правцу стандардизације мониторинг опција, како би се извршила одређена униформисаност минимум производних блокова и, посредно, задовољавајућа хигијена података неопходних за даљу анализу. Самим тим, модели вештачке интелигенције би могли постати још тачнији, а самим тим и увећана њихова корисност и техноекономска добит коју остварују. Додатно, имплементација и даља употреба система експертске подршке на бази вештачке интелигенције могла би значајно унапредити адекватно планирање средстава за одржавање, упрошћавајући разумевање стварног стања машине сведеног на један број, којим се лако може даље вршити рангирање и издвајање приоритета за одржавање.

## Литература

- [1] Liu Nian, Teng Fusheng, "The new intelligent monitoring method for operating states of large generator units", IEEE Power Engineering Society Winter Meeting. Conference Proceedings - Singapore 23-27 Jan. 2000, 223–227. doi:10.1109/pesw.2000.849959
- [2] Peter Tavner, Li Ran, Jim Penman, Howard Sedding, "Condition Monitoring of Rotating Electrical Machines" IET, 2008, eISBN: 978-0-86341-991-1
- [3] Zenios, Stavros & Ziemba, William, "Handbook of Asset and Liability Management Volume 2: Applications and Case Studies", North-Holland, (2007), ISBN: 978-0-444-52802-5
- [4] Hrvoje POŽAR, "Snaga i energija u elektromagnetskim sistemima", Zagreb -Informator 1983 -1985.
- [5] Cigre WG A1.10. "Survey of Hydrogenerator Failures", Cigre Report 392, CIGRE Paris, France, 2009.
- [6] Babin, Alexander & Polyakov, Roman & Savin, Leonid & Tyurin, Valentin "Statistical analysis of turbo generator sets failure causes", Vibroengineering PROCEDIA. 31. 129-133. (2020). DOI:10.21595/vp.2020.21331.
- [7] H. O. Seinsch, "Monitoring und Diagnose elektrischer maschinen und Antriebe", Stand der Forschung, Entwicklungstendenzen, Frankfurt am Main, VDE-Haus, 28 June 2001
- [8] Gill, Paul, "Electrical Power Equipment Maintenance and Testing", CRC Press, (2016). DOI:10.1201/9781420017557.
- [9] C. V. Maughan and J. E. Timperley, "Remote Technical Support of Generator Maintenance," 2021 IEEE Electrical Insulation Conference (EIC), 2021, pp. 5-7, doi: 10.1109/EIC49891.2021.9612349.
- [10] Милета Жарковић, „Мониторинг и дијагностика разводног постројења на бази фази модела стања високонапонске опреме“, докторска дисертација, Универзитет у Београду, Електротехнички факултет, 2017.
- [11] Stone, Greg & Culbert, Ian & Boulter, Edward & Dhirani, Hussein, "Electrical Insulation for Rotating Machines: Design, Evaluation, Aging, Testing, and Repair", Wiley-IEEE Press (2014). DOI:10.1002/9781118886663.
- [12] Ilić, D., Žarković, M. & Stojković, "Z. Artificial intelligence system for stator condition diagnostic" Electrical Engineering 104, 1503–1513 (2022). <https://doi.org/10.1007/s00202-021-01402-6>
- [13] ЈП ЕПС, „Интерни стандард ИС 32“ – У поступки хармонизације – Прво издање, Октобар 2015.
- [14] Илија Класнић, Денис Илић, Ђорђе Јовановић, Зоран Ђирић, Душан Кулић, Иван Шука, „Фабричка испитивања турбогенератора“, 35. Саветовање CIGRE Србија, 03. – 08. Октобар, 2021. Златибор

- [15] Aelst, Jos. „A field proven vision on Asset Management in an industrial environment“, Conference: Asset Management Conference 2011, IET and IAM (2011), p.p. 1-5. DOI:10.1049/cp.2011.0560.
- [16] Katičić, Ljiljana & Lovrinčević, Zeljko, “Corporate asset management and survey in Croatian companies” p.p. 1-5, (2012). DOI:10.1049/cp.2012.1933.
- [17] Mottershead, Glenn & Bomben, Stefano & Kerszenbaum, Isidor & Klempner, Geoff, “Handbook of Large Hydro Generators: Operation and Maintenance”, IEEE Press (2020). DOI:10.1002/9781119524205.
- [18] Boulter, E.A. & Stone, G.C. “Historical development of rotor and stator winding insulation materials and systems” Electrical Insulation Magazine, IEEE.20. p.p.25 – 39, (2004). DOI:10.1109/MEI.2004.1307083.
- [19] ЈП ЕПС, Студија: „УНАПРЕЂИВАЊЕ МЕТОДА ПРЕВЕНТИВНЕ КОНТРОЛЕ ИЗОЛАЦИЈЕ СТАТОРА РОТАЦИОНИХ МАШИНА У СИСТЕМУ ЕПС УВОЂЕЊЕМ ЕДА ТЕСТА (EDA - Electronic Dielectric Analyzer)“, мај 2017.
- [20] ЈП ЕПС, Студија: „УВОЂЕЊЕ НОВЕ МЕТОДЕ ЗА ИСПИТИВАЊЕ ИЗОЛАЦИОНИХ СИСТЕМА ВН ОБРТНИХ МАШИНА – РАМП ТЕСТА У ПРАКСУ ЕПС“, април 2018.
- [21] ЈП ЕПС, Студија: „Увођење и примена нове методологије за утврђивање стања и преосталог радног века на генераторима Лимских ХЕ ЈП ЕПС“ октобар 2015.
- [22] IEC 60505:2011 - Evaluation and qualification of electrical insulation systems
- [23] N. Phloymuk and N. Pattanadech, "The Aging of the Insulation System of Large Rotating Machines in Frequency Domains," 2019 5th International Conference on Engineering, Applied Sciences and Technology (ICEAST), Luang Prabang, Laos, 2019, pp. 1-4, DOI: 10.1109/ICEAST.2019.8802581.
- [24] R. Kuppuswamy and S. Rainey, "Facilitating Proactive Stator Winding Maintenance Using Partial Discharge Patterns," 2018 IEEE Electrical Insulation Conference (EIC), San Antonio, TX, USA, 2018, pp. 566-571, DOI: 10.1109/EIC.2018.8480895.
- [25] C. V. Maughan, "Generator reliability as influenced by engineering design parameters," Proceedings: Electrical Insulation Conference and Electrical Manufacturing and Coil Winding Conference (Cat. No.01CH37264), Cincinnati, OH, USA, 2001, pp. 159-179, DOI: 10.1109/EEIC.2001.965605.
- [26] Rao, Burjupati, “Assessment of Stator winding Insulation, PART 1 - Review of deterioration mechanisms and condition monitoring techniques”, The Journal of CPRI, . (2010). ISSN 0973 -0388.
- [27] Electrical Power Research Institute, Palo Alto, USA, “Hydropower plant modernization guide: Volume 1”, Hydroplant modernization, Final report, United States, 1989. Web.



- [28] Choudhary, Maninder & Shafiq, Muhammad & Kiitam, Ivar & Hussain, Ghulam & Palu, Ivo & Taklaja, Paul, "A Review of Aging Models for Electrical Insulation in Power Cables", *Energies*-15, (2022). DOI:10.3390/en15093408.
- [29] IEC60034 -27 -1:2017 - Rotating electrical machines - Part 27-1: Off-line partial discharge measurements on the winding insulation
- [30] IEC60034 -27 -2: 2012 - Rotating electrical machines - Part 27-2: On-line partial discharge measurements on the stator winding insulation of rotating electrical machines
- [31] IEC60034 -27 -3:2015 - Rotating electrical machines - Part 27-3: Dielectric dissipation factor measurement on stator winding insulation of rotating electrical machines
- [32] IEC60034 -27 -4: 2018 - Rotating electrical machines - Part 27-4: Measurement of insulation resistance and polarization index of winding insulation of rotating electrical machines
- [33] IEC60034 -27 -5:2021 - Rotating electrical machines - Part 27-5: Off-line measurement of partial discharge inception voltage on winding insulation under repetitive impulse voltage
- [34] IEEE std 43-2013 - IEEE Recommended Practice for Testing Insulation Resistance of Electric Machinery
- [35] SPRS EN 50209:2009 – Испитивање изолације полунавоја и навоја високонапонских машина
- [36] "IEEE Guide for Operation and Maintenance of Turbine Generators," in IEEE Std 67-2005 (Revision of IEEE Std 67-1990) , pp.1-72, 8 May 2006, DOI: 10.1109/IEEESTD.2006.224402.
- [37] Tse, Peter & Mathew, Joseph & Wong, King & Lam, Rocky & Ko, C.N. "Engineering Asset Management - Systems, Professional Practices and Certification", *Proceedings of the 8th World Congress on Engineering Asset Management (WCEAM 2013) & the 3rd International Conference on Utility Management & Safety (ICUMAS)*, (2015), DOI:10.1007/978-3-319-09507-3.
- [38] EPRI – Technical report: Optimized Maintenance of Generator Rotors, November 2004.
- [39] Predrag Janičić, Mladen Nikolić, „Veštačka inteligencija“, Univerzitet u Beogradu, Matematički fakultet, Beograd 2021.
- [40] Russell, Stuart & Norvig, Peter, "Artificial Intelligence: A Modern Approach", Third Edition, Pearson Education, 2010.
- [41] Eisenecker, Ulrich, "AI: The Tumultuous History of the Search for Artificial Intelligence", *AI Communications*, (1995), DOI: 10.3233/AIC-1995-8108.
- [42] Amit, Konar, "Artificial Intelligence and Soft Computing: Behavioral and Cognitive Modeling of the Human Brain", (2018) DOI: 10.1201/9781315219738.
- [43] Partridge, Derek, "Artificial Intelligence and Software Engineering – Understanding the Promise of the Future", *American Management Association*, New York, (2013) DOI: 10.4324/9780203058572.

- [44] Deyi Li, Yi Du, „Artificial Intelligence with Uncertainty“, Chapman and Hall/CRC, Tsinghua University, Beijing, China, 2008.
- [45] George F. Luger, William A. Stubblefield, „Artificial Intelligence\_ Structures And Strategies For Complex Problem Solving“ Third Edition, Addison Wesley Publishing Company (1997)
- [46] Goertzel, Ben & Pennachin, Cassio., „Artificial General Intelligence“ Springer-Verlag Berlin Heidelberg – Cognitive Technologies (2007), DOI: 10.1007/978-3-540-68677-4.
- [47] Fulcher, J. „Advances in Applied Artificial Intelligence“, Idea Group Publishing, Computational Intelligence and Its Application Series (2006). 10.4018/978-1-59140-827-7.
- [48] Michie, D. & Spiegelhalter, D. & Taylor, Charles, “Machine Learning, Neural and Statistical Classification”, Technometrics. Vol. 37, 1995. DOI: 10.2307/1269742.
- [49] Ishwar K. Sethi – „Artificial neural networks and statistical pattern recognition: old and new connections“ – Machine Learning and Pattern Recognition, Vol.11, Amsterdam: North-Holland, 1991
- [50] Krishnamoorthy, C.S. & Rajeev, S. „Artificial Intelligence and Expert Systems for Engineers“, CRC Press LLC, ISBN: 0849391253, 1996.
- [51] Klement, Erich Peter & Slany, Wolfgang, „Fuzzy Logic in Artificial Intelligence“, Encyclopedia of Computer Science and Technology Chapter, Vol. 34, (1997)
- [52] Piero P. Bonissone, “Fuzzy Logic and Soft Computing: Technology Development and Applications”, General Electric CRD, Schenectady NY 12309, USA, 1997.
- [53] Earl Cox, “The fuzzy systems handbook: a practitioner’s guide to building, using, and maintaining fuzzy systems”, Academic Press, Inc., The Metus System Group, New York, (1999) ISBN9780121944551
- [54] Cirstea, M. A. Dinu, J.G. Khor, M. McCornick, „Neural and Fuzzy Logic Control of Drives and Power Systems“, Newness, (2022). ISBN: 0750655585
- [55] F. Martin McNeill, Ellen Thro, „Fuzzy logic: A practical approach“, AP Professional, Academic Press, 1994.
- [56] Jager R. „Fuzzy Logic in Control“, Doctoral Thesis, TU Delft, School of [Electrical Engineering, Mathematics and Computer Science](#), (1995), ISBN 90-9008318-9
- [57] Jyh-Shing, Roger Jang, Chuen-Tsai Sun, Eiji Mizutani, „Neuro-fuzzy and soft computing - a computational approach to learning and machine intelligence“, Prentice Hall (1997), ISBN: 0132610663
- [58] Moller B., Beer M., Liedscher M. „Fuzzy analysis as alternative to stochastic methods -- theoretical aspects“, 4th German LS DYNA Forum, 20. – 21. October, Bamberg (2005)
- [59] MATLAB User Guide: Fuzzy Logic Toolbox, Version 2, [www.matlab.com](http://www.matlab.com)

- [60] Nina Radojičić, „Primena fazi logike za rešavanje NP-teških problema rutiranja vozila i lokacije resursa metodama računarske inteligencije“, Doktorska teza, Univerzitet u Beogradu, Matematički fakultet, Beograd 2018.
- [61] Toshiro Terano, Kiyoji Asai, Michio Sugeno, „Fuzzy systems theory and its applications“, Academic Press (1992) ISBN 9780126852455
- [62] C. Von Altrock, "Fuzzy logic technologies in automotive engineering," Proceedings of WESCON '94, 1994, pp. 110-117, DOI: 10.1109/WESCON.1994.403618.
- [63] Wolkenhauer, Olaf. „Data Engineering: Fuzzy Mathematics in Systems Theory and Data Analysis“, Wiley Publishing (2001) DOI: 10.1002/0471224340.ch11, ISBN: 978-0-471-41656-2
- [64] Castelltort, A., Laurent, A., „Extracting Fuzzy Summaries from NoSQL Graph Databases“ Flexible Query Answering Systems 2015 - Advances in Intelligent Systems and Computing, vol 400. Springer, DOI:10.1007/978-3-319-26154-6\_15
- [65] Бочарников В.П., „Fuzzy-технология: Математические основы. Практика моделирования в экономике“, Санкт Петербург, Алетейя, 1995.
- [66] Zoran Miljković, Dragan Aleksandrić „Veštačke neuronske mreže- zbirka rešenih zadataka sa izvodima iz teorije“, Univerzitet u Beogradu, Mašinski fakultet, Beograd, 2018.
- [67] Ethem Alpaydin, „Machine Learning: The New AI“, MIT Press, 2016. ISBN:9780262337595
- [68] Heaton, J. Ian Goodfellow, Yoshua Bengio, and Aaron Courville, „Deep learning“, Genet Program Evolvable Mach 19, 305–307 (2018). [DOI:10.1007/s10710-017-9314-z](https://doi.org/10.1007/s10710-017-9314-z)
- [69] Tencent Research Institute, CAICT, Tencent AI Lab., „An Overview of the Artificial Intelligence Industry“, Artificial Intelligence, Springer Singapore, (2021). [DOI:10.1007/978-981-15-6548-9\\_4](https://doi.org/10.1007/978-981-15-6548-9_4)
- [70] Stahl, B.C. „Perspectives on Artificial Intelligence“, Artificial Intelligence for a Better Future. SpringerBriefs in Research and Innovation Governance. Springer, (2021). [DOI:10.1007/978-3-030-69978-9\\_2](https://doi.org/10.1007/978-3-030-69978-9_2)
- [71] Miloš Manić, „Smanjenje dimenzionalnosti prostornih podataka pomoću veštačkih neuronskih mreža“, Master rad, Univerzitet u Beogradu, Matematički fakultet, Beograd 2018.
- [72] Djukova, E.V., Masliakov, G.O., Prokofyev, P.A. „Logical Classification of Partially Ordered Data“, Artificial Intelligence. RCAI 2019. Communications in Computer and Information Science, vol 1093. Springer, (2019), [DOI:10.1007/978-3-030-30763-9\\_10](https://doi.org/10.1007/978-3-030-30763-9_10)
- [73] Zsolt Nagy, „Osnove veštačke inteligencije i mašinskog učenja“, Kompjuter biblioteka, Beograd, 2019. ISSN 978-1-78980-165-1
- [74] Matlab User Guide – Statistics and Machine Learning Toolbox, Ver. 12.3, [www.mathworks.com](http://www.mathworks.com)

- [75] Komyakov, M. M. Nikiforov, V. V. Erbes, V. T. Cheremisin and V. I. Ivanchenko, "Construction of electricity consumption mathematical models on railway transport used artificial neural network and fuzzy neural network," 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016, pp. 1-4, DOI: 10.1109/EEEIC.2016.7555450.
- [76] Z. Hong, "A preliminary study on artificial neural network," 2011 6th IEEE Joint International Information Technology and Artificial Intelligence Conference, 2011, pp. 336-338, DOI:10.1109/ITAIC.2011.6030344.
- [77] Cong, S. "Toolbox for MATLAB neural network theory and application." (1998).
- [78] Karampelas, Panagiotis; Vita, Vassiliki; Pavlatos, Christos; Mladenov, Valeri; Ekonomou, Lambros, „Design of artificial neural network models for the prediction of the Hellenic energy consumption“, IEEE 2010 10th Symposium on Neural Network Applications in Electrical Engineering (NEUREL 2010) - Belgrade, Serbia (2010.09.23-2010.09.25), 41–44. DOI:10.1109/neurel.2010.5644049
- [79] Beckenkamp, Fábio, „A component architecture for artificial neural network systems“ , Doctoral thesiss, University of Konstanz, Computer and Information Science Dpt. 2002.
- [80] Han, Yaning; Ma, Yunyun; Wang, Jinbo; Wang, Jianmin, „Research on ensemble model of anomaly detection based on autoencoder“, IEEE 20th International Conference on Software Quality, Reliability and Security (QRS) - Macau (2020.12.11-2020.12.14), (2020). 414–417. DOI:10.1109/qrs51102.2020.00060
- [81] Hanxuan Wang, Na Lu, „Deep Embedded Clustering with Asymmetric Residual Autoencoder“, 2020 Chinese Automation Congress (CAC), (2020.) DOI:10.1109/cac51589.2020.9326728
- [82] Rami Al-Hmouz, Witold Pedrycz, Abdullah Balamash, Ali Morfeq, „Logic-Oriented Autoencoders and Granular Logic Autoencoders: Developing Interpretable Data Representation“, IEEE Transactions on Fuzzy Systems, (2022). DOI:10.1109/tfuzz.2020.3043659
- [83] Xu, Qingyang, Wu, Zhe, Yang, Yiqin, Zhang, Li, „The difference learning of hidden layer between autoencoder and variational autoencoder“, 29th Chinese Control And Decision Conference (CCDC) - (2017), 4801–4804. DOI:10.1109/ccdc.2017.7979344
- [84] Hanxuan Wang, Na Lu, „Deep Embedded Clustering with Asymmetric Residual Autoencoder“, 2020 Chinese Automation Congress (CAC), (2020). DOI:10.1109/cac51589.2020.9326728
- [85] Yun Wu, Zhixiong Zhang, „A Performance Prediction Model Based on Combined Autoencoder“, 2020 IEEE 11th International Conference on Software Engineering and Service Science (ICSESS), (2020). DOI:10.1109/icsess49938.2020.9237748
- [86] D. L. Aguilar, M. A. M. Perez, O. Loyola-Gonzalez, K. -K. R. Choo and E. Bucheli-Susarrey, "Towards an interpretable autoencoder: A decision tree-based autoencoder and its application in anomaly detection," in IEEE Transactions on Dependable and Secure Computing, (2022), DOI:10.1109/TDSC.2022.3148331.

- [87] Chen, Zhaomin, Yeo, Chai Kiat, Lee, Bu Sung, Lau, Chiew Tong, „Autoencoder-based network anomaly detection“, Wireless Telecommunications Symposium (WTS) - (2018), 1–5. DOI:10.1109/WTS.2018.8363930
- [88] G. E. Hinton and R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks", Science, vol. 313, pp. 504-507, 2006.
- [89] C. C. Tan and C. Eswaran, "Performance Comparison of Three Types of Autoencoder Neural Networks," 2008 Second Asia International Conference on Modelling & Simulation (AMS), 2008, pp. 213-218, DOI: 10.1109/AMS.2008.105.
- [90] K. Kalyani and S. Kanagalakshmi, "Control of Trms using Adaptive Neuro Fuzzy Inference System (ANFIS)," 2020 International Conference on System, Computation, Automation and Networking (ICSCAN), 2020, pp. 1-5, DOI: 10.1109/ICSCAN49426.2020.9262417.
- [91] T. İnan and A. F. BABA, "Prediction of Wind Speed Using Artificial Neural Networks and ANFIS Methods (Observation Buoy Example)," 2020 Innovations in Intelligent Systems and Applications Conference (ASYU), 2020, pp. 1-5, DOI: 10.1109/ASYU50717.2020.9259894.
- [92] Tushar, Abhinav and G. N. Pillai, "Extreme Learning ANFIS for classification problems," 1st International Conference on Next Generation Computing Technologies (NGCT), 2015, pp. 784-787, DOI: 10.1109/NGCT.2015.7375227.
- [93] M. Ginarsa, A. Soeprijanto and M. H. Purnomo, "Controlling chaos using ANFIS-based Composite Controller (ANFIS-CC) in power systems," International Conference on Instrumentation, Communication, Information Technology, and Biomedical Engineering 2009, 2009, pp. 1-5, doi: 10.1109/ICICI-BME.2009.5417262.
- [94] K. Amara et al., "Improved Performance of a PV Solar Panel with Adaptive Neuro Fuzzy Inference System ANFIS based MPPT," 2018 7th International Conference on Renewable Energy Research and Applications (ICRERA), 2018, pp. 1098-1101, DOI: 10.1109/ICRERA.2018.8566818.
- [95] P. Jagtap and G. N. Pillai, "Comparison of extreme-ANFIS and ANFIS networks for regression problems," 2014 IEEE International Advance Computing Conference (IACC), 2014, pp. 1190-1194, DOI: 10.1109/IAdCC.2014.6779496.
- [96] Jang, J.-S.R. (1993). "ANFIS: adaptive-network-based fuzzy inference system". IEEE Transactions on Systems, Man and Cybernetics. 23 (3): 665–685. DOI:10.1109/21.256541. S2CID 14345934.
- [97] Abraham, A. (2005), "Adaptation of Fuzzy Inference System Using Neural Learning", in Nedjah, Nadia; de Macedo Mourelle, Luiza (eds.), Fuzzy Systems Engineering: Theory and Practice, Studies in Fuzziness and Soft Computing, vol. 181, Germany: Springer Verlag, pp. 53–83, DOI:10.1007/11339366\_3, ISBN 978-3-540-25322-8
- [98] Jang, Sun, Mizutani, „Neuro-Fuzzy and Soft Computing“, Prentice Hall, pp 335–368, (1997) ISBN:0-13-261066-3

- [99] Tahmasebi, P. "A hybrid neural networks-fuzzy logic-genetic algorithm for grade estimation". Computers & Geosciences. Vol. 42: 18–27. (2012). DOI:10.1016/j.cageo.2012.02.004.
- [100] Karaboga, Dervis; Kaya, Ebubekir, "Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey", Artificial Intelligence Review, pp. 2263–2293. (2018). DOI:10.1007/s10462-017-9610-2.
- [101] Breiman, L., J. Friedman, R. Olshen, and C. Stone. „Classification and Regression Trees“, Boca Raton, FL: CRC Press, (1984).
- [102] Coppersmith, D., S. J. Hong, and J. R. M. Hosking. “Partitioning Nominal Attributes in Decision Trees.” Data Mining and Knowledge Discovery, Vol. 3, (1999), pp. 197–217.
- [103] Loh, W.Y. “Regression Trees with Unbiased Variable Selection and Interaction Detection.” Statistica Sinica, Vol. 12, (2002), pp. 361–386.
- [104] Loh, W.Y. and Y.S. Shih. “Split Selection Methods for Classification Trees.” Statistica Sinica, Vol. 7, (1997), pp. 815–840.
- [105] K. Okuda and H. Takeyama, "Decision tree generation for decoding irregular instructions," 2016 Design, Automation & Test in Europe Conference & Exhibition (DATE), 2016, pp. 1592-1597.
- [106] <https://scikit-learn.org/stable/modules/tree.html>
- [107] Prof. Dr Milan Nikolić, „Metode odlučivanja“, Biblioteka Udžbenici, Univerzitet u Novom Sadu, Tehnički fakultet „Mihajlo Pupin“, Zrenjanin, (2012).

## Прилог 1 – База реалних података коришћена у раду

Резултати испитивања									Оцена експерта	Припрема података "1Hot"			Резултати ANN		
tgδ0.2Unmax	dtgdmax	PD06	MINRisos	MinN1	Risorotor	Nrot	Mzi	Starost	Оцена	Добро	Сумњив	Лоше	Добро	Сумњив	Лоше
0.377	0.618	3.40	2630.00	3.55	356.00	1.40	0	37	3	1	0	0	0.011	0.908	0.082
0.520	0.340	6000.00	3830.00	3.18	45.00	1.30	0	8	3	1	0	0	0.613	0.383	0.004
0.549	0.200	3800.00	6640.00	3.79	63.20	1.20	0	10	3	1	0	0	0.693	0.303	0.004
0.556	0.280	1300.00	1970.00	3.51	0.07	1.54	0	60	3	1	0	0	0.967	0.033	0.000
0.560	0.173	31.90	2750.00	3.93	340.00	1.20	0	25	3	1	0	0	0.836	0.163	0.001
0.582	0.210	42.00	2300.00	6.22	0.04	1.54	0	28	3	1	0	0	0.916	0.083	0.001
0.588	0.250	20.00	857.00	3.00	0.04	1.08	0	25	3	1	0	0	0.885	0.114	0.001
0.623	0.240	57.00	2300.00	6.39	0.38	1.21	0	28	3	1	0	0	0.916	0.083	0.001
0.626	0.208	20.30	2250.00	3.21	20.00	1.00	0	30	3	1	0	0	0.807	0.193	0.000
0.640	0.230	100.00	0.16	1.00	0.04	1.00	0	29	3	1	0	0	0.946	0.054	0.000
0.640	0.890	54.00	210.00	2.30	0.25	1.00	0	30	2	1	0	0	0.576	0.422	0.002

....

1.114	0.080	80.00	0.03	1.00	0.02	1.54	0	24	3	1	0	0	0.000	0.095	0.905
1.114	0.269	250.00	4050.00	3.59	0.06	1.00	0	34	3	1	0	0	0.000	0.036	0.964
1.120	0.510	750.00	425.00	1.30	3660.00	1.21	0	16	3	1	0	0	0.001	0.117	0.882
1.120	0.150	4000.00	0.23	1.00	10.51	4.15	0	45	3	1	0	0	0.003	0.950	0.047

Денис Илић – докторска дисертација

1.120	0.090	14000.00	1.06	1.00	1610.00	1.54	0	25	1	1	0	0	0.940	0.057	0.003
1.130	0.520	2000.00	5670.00	3.62	1544.00	2.00	0	18	3	1	0	0	0.932	0.029	0.039
1.130	1.730	19.90	153.00	1.61	60.80	1.00	0	45	3	1	0	0	0.842	0.144	0.015
1.354	1.850	14000.00	498.00	2.15	1240.00	1.08	1	47	2	1	0	0	0.000	0.962	0.038
1.360	0.365	8000.00	6.11	1.00	#####	1.21	0	34	2	1	0	0	0.000	0.037	0.963
1.361	0.260	1500.00	1990.00	3.31	0.06	1.54	0	60	3	1	0	0	0.020	0.891	0.089
1.361	1.330	52000.00	3930.00	3.07	673.00	1.54	0	55	1	1	0	0	0.090	0.875	0.035
1.366	0.070	17000.00	2220.00	2.71	0.83	1.00	0	63	1	1	0	0	0.000	0.742	0.258
1.370	0.150	1500.00	1730.00	3.19	54.60	1.08	0	59	3	1	0	0	0.000	0.004	0.996
1.370	0.350	26000.00	266.00	3.45	376.00	1.00	0	38	1	1	0	0	0.000	0.869	0.131
1.376	1.330	35000.00	4290.00	3.24	648.00	1.00	0	51	1	1	0	0	0.000	0.140	0.860
1.377	0.460	30000.00	4540.00	3.25	723.00	1.21	0	54	1	1	0	0	0.021	0.588	0.391

...

3.580	0.440	580.00	564.00	4.06	4340.00	4.15	0	2	3	0	1	0	0.775	0.203	0.022
3.641	2.370	55000.00	1460.00	2.72	41.80	1.00	0	41	3	0	1	0	0.027	0.692	0.281
3.650	0.300	40000.00	2000.00	2.20	0.00	1.00	0	37	1	0	1	0	0.004	0.996	0.000
3.750	0.351	4.00	5000.00	5.00	83.30	1.00	0	38	3	0	1	0	0.734	0.266	0.000

...

9.280	0.430	35.80	6100.00	2.71	7.34	1.54	0	27	2	0	1	0	0.883	0.081	0.037
9.440	0.430	11.70	5000.00	6.67	#####	1.54	0	26	2	0	1	0	0.934	0.023	0.043
9.700	1.790	4000.00	1580.00	3.15	#####	1.00	0	49	1	0	1	0	0.953	0.014	0.033
9.900	0.130	450.00	0.04	1.00	0.02	1.00	0	19	2	0	1	0	0.956	0.015	0.029



Денис Илић – докторска дисертација

9.970	0.250	65000.00	7142.00	2.46	#####	1.08	0	23	1	0	1	0	0.919	0.014	0.066
10.410	0.340	5500.00	6150.00	3.38	0.19	1.00	0	36	2	0	1	0	0.998	0.002	0.000
10.890	0.340	15000.00	2740.00	4.06	14.90	1.21	0	38	1	0	1	0	0.995	0.005	0.000

## Прилог 2 База дефинисаних правила фази експертског система

1. If (tgd02 is ok) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is dobro) and (N is dobro) then (HI\_statora is good) (1)
2. If (tgd02 is dobro) and (pdmax06 is ok) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is dobro) and (N is dobro) then (HI\_statora is good) (1)
3. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is ok) and (Te is dobro) and (Rrisos is dobro) and (N is dobro) then (HI\_statora is good) (1)
4. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is ok) and (Rrisos is dobro) then (HI\_statora is good) (1)
5. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is lose) and (Rrisos is dobro) then (HI\_statora is good) (1)
6. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is dobro) then (HI\_statora is good) (1)
7. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is dobro) and (N is dobro) then (HI\_statora is good) (1)
8. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is ok) and (N is dobro) then (HI\_statora is good) (1)
9. If (tgd02 is lose) or (pdmax06 is lose) or (dtgdmax is lose) or (Te is lose) or (Rrisos is lose) or (N is loše) then (HI\_statora is bad) (1)
10. If (tgd02 is lose) and (pdmax06 is lose) and (dtgdmax is lose) and (Te is lose) and (Rrisos is lose) and (N is dobro) then (HI\_statora is normal) (1)
11. If (tgd02 is lose) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is lose) and (Rrisos is lose) and (N is loše) then (HI\_statora is bad) (1)
12. If (pdmax06 is lose) and (dtgdmax is lose) and (Te is lose) then (HI\_statora is bad) (1)
13. If (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is ok) then (HI\_statora is normal) (1)
14. If (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is dobro) then (HI\_statora is normal) (1)
15. If (tgd02 is dobro) or (dtgdmax is dobro) or (Te is dobro) or (Rrisos is dobro) then (HI\_statora is good) (1)
16. If (Te is lose) then (HI\_statora is good) (1)

17. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is ok) and (Te is dobro) and (Rrisos is dobro) and (N is ok) then (HI\_statora is good) (1)
18. If (tgd02 is lose) and (dtgdmax is lose) then (HI\_statora is bad) (1)
19. If (Rrisos is lose) and (N is loše) then (HI\_statora is bad) (1)
20. If (Rrisos is dobro) and (N is dobro) then (HI\_statora is normal) (1)
21. If (tgd02 is dobro) and (dtgdmax is dobro) then (HI\_statora is good) (1)
22. If (pdmax06 is lose) and (dtgdmax is lose) then (HI\_statora is bad) (1)
23. If (Te is lose) then (HI\_statora is bad) (1)
24. If (tgd02 is ok) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is dobro) and (N is dobro) then (HI\_statora is good) (1)
25. If (tgd02 is dobro) and (pdmax06 is ok) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is dobro) and (N is dobro) then (HI\_statora is good) (1)
26. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is ok) and (Te is dobro) and (Rrisos is dobro) and (N is dobro) then (HI\_statora is good) (1)
27. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is dobro) and (N is dobro) then (HI\_statora is good) (1)
28. If (tgd02 is dobro) and (pdmax06 is dobro) and (dtgdmax is dobro) and (Te is dobro) and (Rrisos is ok) and (N is dobro) then (HI\_statora is good) (1)
29. If (tgd02 is lose) and (pdmax06 is lose) and (dtgdmax is lose) and (Te is lose) and (Rrisos is lose) and (N is dobro) then (HI\_statora is normal) (1)
30. If (Rrisos is dobro) and (N is dobro) then (HI\_statora is normal) (1)
31. If (N is loše) then (HI\_statora is bad) (1)
32. If (Rrisos is lose) then (HI\_statora is bad) (1)
33. If (Rrisos is ok) then (HI\_statora is normal) (1)

### Прилог 3 Програмски код вештачке неуралне мреже

```
function [Y,Xf,Af] = net90(X,~,~)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Generated by Neural Network Toolbox function genFunction, 15-Mar-2022 10:49:06.
%
% [Y] = myNeuralNetworkFunction(X,~,~) takes these arguments:
%
% X = 1xTS cell, 1 inputs over TS timesteps
% Each X{1,ts} = Qx7 matrix, input #1 at timestep ts.
%
% and returns:
% Y = 1xTS cell of 1 outputs over TS timesteps.
% Each Y{1,ts} = Qx3 matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMTO>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0.377;0.0410000000000001;1.6;0;0;0;0];
x1_step1.gain = [0.190240654427851;0.641231163834562;2.00003200051201e-
05;0.000111111111111111;0.0909090909090909;4.16666666666667e-05;0.0303030303030303];
x1_step1.ymin = -1;
```

% Layer 1

b1 = [-2.703687565998723;2.7286465363839545;-2.1065671371646242;2.3815480348899682;-2.6571468999125378;  
-2.3538824639357503;-2.4030066956527696;-2.2088308890654424;-.2532085447080834;2.1875231244540729;2.1946746523203515;  
1.9822261342837917;-2.1448022899137618;-1.9922102043839189;1.9786318592326595;2.0148152029928696;  
1.8337712023959762;1.6593829551702151;-1.7486011269352484;1.6884316684875851;1.5760088037983402;-1.5368986398709845;-  
1.5846274819167923;-1.4017159110674975;1.482157251114788;-0.87911403966243695;-  
1.3243694369953263;1.203766672406362;1.1669115151849967;1.180497205861224;1.1023912808670977;1.0405023061774363;0.69  
516830938351404;-0.7642777730480248;1.0070837984446981;-0.85632753334424749;0.7715218357440955;0.61657976672579728;  
0.42760069080622726;0.70600257856789239;-0.41375298255690529; -0.64991678065792535; 0.71729560811136106;  
0.36008710000275979; 0.41056377494467811; 0.072560977985378888; -0.51067628534442056;-0.14229766626164622;  
0.22047788527326478; 0.037503303488615594; -0.32227764166657957; 0.38056348825367259;  
0.13983202092479585;0.17170169950594621;0.37422709779010571;-0.35432297776956512;-0.50480128142748026;  
0.36844736961134505;-0.45105044653560522;-0.49203419254477154;-0.46449876875292523;-  
0.76262816027956515;0.86533178636948138;0.77332610522990985;-0.8822236380659999;-  
1.4590498809420305;0.81922592404102235;0.96502627362339377;-0.76305083554261732;1.7332335539206727;-  
1.0859180092640153;1.1146833191696102;-1.1945718089944335;1.0282633751215398;2.1124656121435801;-  
1.2821190468776975;1.3234839015381523;1.5285103873154666;-1.502869192260829;-1.6020173115416179;1.7068868806097672;-  
1.6294467548456166;-2.6344581081112795;-2.2358921548852773;-1.6832595881788133;-1.8108389185383065;-  
2.1512035372679565;2.2097612544427059;2.1044791075337685;-2.6366235484160496;-2.3801995021146802;-  
1.7841371197805256;-2.4038742987364752;2.2012988309201047;-2.5735045943059922;-2.4897716098940164;-  
2.5335088150512002;-2.8933331350788003;3.022204092211595;-2.9051908138310774];

IW1\_1 = [0.26533253634132897 0.031820675597326237 1.6186690406826421 1.715244796301149 -0.070517068758214368  
1.1620490228783891 0.563962353370147;-1.3671343365222361 0.16500338049820401 0.60865539019786108  
0.047510729331221573 -0.40707250983448495 -1.5128981704223945 1.4767834922184138;1.9004030593832877 -  
1.667108029746438 0.70168329197794965 -1.1285441883972027 -1.0994445771212524 -0.65890755381436061  
0.27659160271945993;-0.78231664144120805 -1.5027847174812707 0.28824666502595431 1.3894496421005471  
0.33911835590358219 1.5766840410234506 0.82673598087318534;0.80056316771015457 -0.23724280655729071 -  
1.1084383818554722 1.254613630161904 0.74048340034215054 -1.449364145654481 0.50506349662678718;2.0446652574928437 -

0.078580408598743101 -1.0524386685055744 -1.0214335470805402 -1.1001627774936105 0.56640660942260401 -  
1.2825635247336455;1.2056746484276701 -0.32257667353552161 1.2087613269675739 -0.70996295195387449  
0.95020282781868637 -1.3042823353966428 -1.0566432256320044;0.74548545141305145 1.407120996200957 -1.256872771186071  
-0.89989565191399878 -1.4693488838059861 -0.084619519845573671 -0.87175340343276875;0.42780875494797188  
0.51449280739702397 1.3669060808906137 -0.12086844553253015 -0.78254834409675222 1.3635294634340593  
1.5820691538052873;-0.94224011758544934 -0.28012172514218298 1.1924599479342644 -1.5660335597238431  
0.615485956178632 -1.4298143518798707 0.4198960598410742;-0.30321709614705983 0.15256671375697389 1.5535613666881452  
0.52257427064182127 -0.85997631327818136 -0.83980540225286271 1.8059687893710126;-0.24968837856741327  
1.4124340997054832 0.95517619237401741 1.5588574606861216 0.22992936617620471 1.1408116114298252  
0.91521371429985732;1.5545835730128508 -0.82460473789792044 -0.82150013548489664 -0.69903194296326365  
1.3919220725698056 0.97599891906915748 0.016697545668196593;1.087014921736948 0.43524755988165936  
0.75973972538282353 1.4533469356102944 1.3894781040749875 -0.46529962585377121 1.0466898354820324;-  
0.83256526442616463 1.3487640006508621 1.9289217424480121 -0.36651613184408888 1.2106090816102435 -  
1.0380315931800583 0.34740633929053022;-0.56268218159631056 1.5833289705675084 0.71206391134715596 -  
1.2149044263326776 0.98098030205307329 -1.0368812234189664 -0.19729730482002295;-0.90023291206008516 -  
0.66330580731327149 1.5331915993136589 0.7803596355341198 -1.5945398826324093 -0.73040260160577486 -  
0.15725767347668446;-1.2339880938837693 -0.86425010064828178 -0.94721444413993727 1.096089060302575 -  
1.0724788623376575 1.0747669148121308 -1.0239110705336243;2.0131467091286663 -0.86401404632676837 -  
0.99598669904416715 -0.055024791885034736 0.37573871100624606 -0.091635245245146435 1.0415360308526975;-  
2.1403743086495877 1.3521750740843035 -0.23458746830122937 0.19994165387889717 0.17076380401230809  
1.1302719283569864 0.191707854563929;-0.24451951507739247 -1.1231415596095891 0.40337872257769414 -  
0.9732225941628434 -0.52049095996244099 -1.5844819158311043 1.4968826699706812;1.699296851368526 -1.3622930804615418  
-0.19066598044446487 -0.43947530422645964 -1.2571874922792627 -0.93241190391010076  
0.21846368508343911;0.23325700853932521 -0.078651326100083921 1.4805917880390564 0.81027259774694671 -  
1.249424730926997 -0.62919487700357069 1.576398000581944;0.75986330320840301 1.5477875806774706 -1.3345281190143101  
0.21917242388930167 0.84241518067169241 1.3367009627875013 0.18127867026878197;-0.84844159734078783 -  
1.3888714542928944 0.60467557674684602 0.034587015024626633 -0.37408467493281999 1.6604618486467653 -  
1.3363414132858158;0.26757107163306715 -0.3816799780494492 -1.7583852187894433 -2.0526017087439858  
0.26785011203839965 -0.72618091957402631 0.62374065787632971;0.56549354143041219 -1.1239858324719199

0.56415936939082501 1.1236264787422268 1.2493178836336629 -1.0891235951552396 1.1101279092199874;-1.1611353307603913  
1.3381903356102456 1.0457179555840646 -1.1514994660102433 -0.84529753470420943 -0.64497799368297082  
0.76345540626911923;-1.6228371920474598 -0.61684397315231343 -0.27414533274157504 -0.28661201232808564  
0.4444215488143225 -1.371594628305834 -1.4395752235945485;-0.40475360178535841 0.10751505061748062 -  
1.1141245780496547 1.9473588631371244 -1.1410994195840518 -0.87104154221491081 0.36304545112451519;-  
0.24779961982645754 -1.2528077121746417 -1.6759999170310951 1.4815271530139624 -0.91266159169144212  
0.51328330346792761 0.30058357090497734;-0.050141310166689483 0.22471654555094722 -2.0321428132346089  
1.0338954712174149 0.65569965228844063 -1.2922209512991978 0.12986731305351493;-0.4883727245617468 -  
0.7867521509047406 1.3662312349931935 1.4977494999932233 1.0384945719863514 0.75372471296143118  
1.0499593562072806;0.27412584765335118 -1.2006943094770108 1.036400928776783 1.7220166554045648 0.76447571900685607  
1.0699518013139695 0.056469826922376377;-1.0085826041409109 0.83093721373909135 0.51359884641124987  
0.80510151699069399 -1.6588474672766937 1.5278246152534152 0.16295697521133132;0.78878053289302508  
0.9267241793959714 -0.49376133365894576 -1.3173647490356559 1.2088816357230199 1.5435667340996497  
0.072956561420395055;-0.31755330092077672 -0.41783553690427433 -0.77589049776430552 0.88275379853015978 -  
1.1442242294411644 0.86517680412890718 -1.9064048439868473;-0.39903730648025831 1.0324928065900703 -  
1.0506510610839612 -1.0707514439896855 -0.59924124766100928 -1.8789368603422785 -0.4112617231623818;-  
0.15952132710166655 1.389483210040968 -0.51807126895794653 1.6689590504297616 -1.2277289158162805 1.1956490285367296  
0.27439805855615335;-0.81680442956783017 0.64209417906852817 -1.4351916904594595 -0.561322848170838 -  
1.3334767889690018 0.74902542498648739 1.3013309790401451;0.42769443841512084 -0.52475947996391237 -  
0.16559364160581205 1.4255598796937787 -0.4493561218289352 -2.3438409094470085  
0.082455371083543672;0.83027126626846692 -1.4550782113386411 -1.9946581857773087 0.53417082048459574 -  
0.058069969735520401 1.1295393841553101 -0.022548312328488772;-1.264933349301673 -0.1148999340926401 -  
0.99709534515121334 1.3275536380922675 0.59901142240427152 -1.3089320998829266 -1.0996067131291556;-  
1.4222973475272214 0.74234135484503216 0.50391199776072515 0.43145472984190375 1.3254487384281664 1.2883953316302987  
0.78976234298539039;-1.8445465980883351 1.7232489454117867 -1.5716287036178538 0.63862172043143273  
0.21499677065126829 -0.0021129044784800582 1.0072198670999948;-1.0205380518142599 0.28295720547547881  
1.2930859883181656 1.2247554433131267 1.1026948767831972 -0.70912871936037891 1.110668172228952;1.1991162438817842  
0.21950124451295094 0.40253222601358785 0.3270267766719176 1.1393968411772459 -1.929023555335069  
0.78596222071033073;1.2968091263831338 0.9628330809776563 -1.3773708064965779 1.3418309786148275 1.0003111153223683 -

0.30246367649994971 0.55810188948457373;0.28437848128587156 0.30386568502257177 0.88375773456156725 -  
1.5710876512853411 0.99217200633270863 -0.029320980687053896 1.3769363665971266;-1.1759346633028576  
0.24715263096260334 -0.8432347674637154 -1.0310148976220159 -1.4037883870429271 -1.3750360753416324  
0.39068486840957273;-0.66322691733261618 -1.4028973798952744 -0.85468615529288927 -1.0073752536298932 -  
1.1951428677446985 1.172517898210389 -0.3275696887380749;-0.075940338184919076 -2.1661080406154651 -  
0.63688799112087524 -1.0793593162648185 0.45633405903409635 0.9621652898645372  
0.30074385315960334;0.61373991745954559 0.76894391102672088 -0.63613959139678966 -1.4244779061532533 -  
1.8375825527996781 0.79784177806812884 0.15366596757141704;1.0468512510283059 1.1463646472917433 -  
0.71466901711290853 1.3453360894889161 -0.10401885024359972 1.520055282897069 -  
0.56526720871580982;0.21994922639561895 1.3364676582929633 -0.40260218532950365 1.6578483117470775 -  
0.45554797124633672 0.47740697368828772 1.7951134838905141;0.017865307692210113 1.6612913193536907  
0.36136424684601132 1.2604100385287023 1.2748796959689022 0.15904866558354822 -1.1453438955603958;-  
1.2933771865553678 1.2447972221002446 -0.54876830150988198 0.052819335209849924 -0.95283434391733624  
1.3860004471331011 -1.5742809434252711;0.057813223338150165 -0.59519379732418387 -1.2065423976338772  
1.7205051138364011 1.6213542449962566 0.2344100382198277 0.40348509054398274;-1.0128692332678424 -  
0.80100051592487864 0.31734417869999126 -0.78068794668576291 1.0718463294757772 1.5827663299316963  
1.246303021868544;-1.1896008290628364 -0.21640130088782586 0.37147694364849421 0.81302938384211731 -  
0.31453497901982774 1.5834307774668859 1.5257631545876567;-0.48851245948645211 -0.55616235024609162  
0.30896723180078367 1.5310254730665651 -1.2333814597043347 -1.4787022003945829 1.162856835132271;-1.5024623719195729  
-0.87842722781049909 0.0038934520591505577 -0.87627487152899664 -0.99201467571846136 -1.3659806190148072  
0.21751764157102904;0.43719996793535948 1.5956129621898762 -1.6888574851371769 1.0252310368206314  
0.51004309223075817 -0.15877956786313552 0.18351125224614145;-0.012124578997471195 -0.97402762311695612 -  
1.3582782216640266 0.44962236896620134 0.59397408180380851 1.4174239469577461 -1.5677421086851357;-  
0.69750099756481176 -1.5418274484694614 0.18752777731366055 -1.5556224334570714 1.0907873302958675  
0.3538825786526506 0.79605187180122727;-0.7302908165020725 -0.3078409647165754 -1.2268825670537529  
1.3033322302532584 -0.64176718638620744 -0.2953438822171956 1.5430186881860739;-0.030224269584778189  
0.33074454348029036 0.19497831939639393 1.6681246218815158 -1.1092639944995719 -0.94839667503745229  
1.4012572400593972;0.90049138319659483 1.2784549265480645 1.1369833184548426 0.50666370494500601 1.0957517650913013  
1.3935835767223081 -0.1206764789539632;-1.286554471666838 -1.3299436265357698 -1.4217119344851366 1.1140160909949131 -



0.044060636509491206 -0.9252574123863454 0.9821855435839415;0.88958442356305056 0.53269143115952355  
1.5815362404778102 1.263766239431142 -0.89209059608145047 -0.44220050114882248 1.0750951914258753;-  
1.6831490377050469 -0.7030854490304731 1.3002038293507214 1.4174141817106984 0.66093711943354561 -  
0.27523402998029084 -0.061698625374466749;1.635636578840256 -0.60893249280724437 0.37054417957156727  
0.44379988192989656 0.14701537285293079 -1.7106234187366451 1.0324366284108204;-1.1878517414434318  
0.5399746251222346 0.71978982702522398 -1.0651288280542837 1.5549778105961218 -0.46412234084337678 -  
1.6042378470013947;1.0983062452044243 1.4653352206675669 -1.558753308873065 1.0955727555707089 -0.89237964016879057  
0.60331260979487766 0.99617415175700796;-0.059126220065449278 1.0443899674238339 1.3926121283426149  
0.83955870285942047 -0.16243496036522659 -0.60176414476396267 -1.2835483650301767;-0.66364110280936384  
0.61962691627072541 0.44696334153074063 1.0715025232188451 -1.0070725519573254 -1.4885148855733816  
1.3704551096829851;0.52148740791149373 -0.93563107361392617 0.006606316399283111 -0.71159591434499525  
0.99124330925469362 -1.1981714587597179 1.8751749630481966;1.8390698275889878 0.26545571864679285 -  
2.0321800703277391 -0.14369060876575362 0.60820803532556023 1.17727677823192 -0.15131037911340955;-  
1.2127328379387805 -1.2139601477461599 -0.4151479606403729 -0.56632455701712825 -0.70964195437115696  
1.1741389774116933 -1.451601067492706;-0.99788424914199991 0.23667436614599488 0.11543218394098759 -  
1.6076045613821284 -1.4215958623663461 -0.42555734792920835 -1.3119789282615637;2.0251084622719371  
0.18508814532260856 0.80518631106762606 -0.057331186802479533 -1.3077534205939032 0.55821448022461351  
0.89484450855871855;-0.54325846625975227 -0.46328773592813083 -0.21302512594399156 -0.55700177852073451  
1.3891911449828975 -1.3838530288205304 -1.894413270109411;-0.10025554906529964 -0.40991430974281862 -  
3.0023660373662597 1.0790709739427704 -0.60594522025150466 0.23587716431017636 -0.28067483031045526;-  
0.79361954256765976 1.4910410347789087 1.0168373303921345 -0.77404518841067582 0.14167774642428915 -  
0.78593938158131738 0.81400718279391504;-0.7417897904909635 -1.3248689236827944 -0.48383068467370938 -  
0.024649018125278643 1.0393131184543067 1.2478934427201238 -1.7163254646002923;-1.0879956886019002 -  
1.6393465739857824 1.6219903622896654 0.82587101014867303 -1.1209274992112115 -0.60988544827239977  
0.52203782589251935;-0.7951347686121587 0.84164464361519298 1.2826492885269529 -1.2460576159479768 -  
0.59792124892465592 -0.61935082068145042 -1.6252466704769786;1.2055560726785159 0.32767272032841827 -  
1.0508600546088134 0.51246633964814514 -1.4823902911845264 0.080230820071056155  
1.3021559187137015;0.93620850649536125 1.2059984477110084 -0.87574153689075707 1.167010038658435 -1.6668221266407288  
-0.22376061911675307 0.22063870008533285;-0.25110050484237451 -0.55617588907461291 -1.4848094602502722

0.97465591735489232 -0.66707043263332089 -1.2414892963713213 -0.91425871294675809;-1.3737948296018416 -  
0.87443509012329346 0.26899683812362529 1.3256732554699573 0.51445576039373153 -1.1909476268090571 -  
0.14631225561246103;-0.69386275139138898 0.97515346607275366 -1.5203583925313395 -2.4299151468889142 -  
0.072584536274313952 0.49576133629020941 0.4230811402790432;-0.26510588218795839 -0.27671401657060429 -  
1.5211286529884924 -1.4960386111503943 -1.3752894654460588 0.15062671946237946 -0.90801502401251766;  
1.4687546643075258 1.3969085607448692 -1.3765521713378077 0.47716388000569376 -0.95611040946589931  
0.001235993544821362 0.81102224275694768;-1.0490628520673755 1.380104841720555 0.71538096559599373 -  
0.76797625385910917 1.134202923971664 -1.0172436785793126 -0.021051512543982465;-1.1958985916910032  
0.51713538790319669 -0.11468402100353066 -0.62200285368407016 1.0994882864931572 1.2775479507595859 -  
1.50791526249375;-0.34038599130134178 0.80826342146026897 -0.9324211321488225 1.3139109519192447 0.86337703886725592  
1.38938559643215 -1.1351380787582783;-0.48022980765904444 0.87790068666127707 -0.43240807953310934 -  
0.88774047433786873 -1.4225705582199304 -0.80807063428277259 0.79151004311978412;0.88072309974189511  
0.63795824146002411 2.3516180570286274 0.14208456101076006 1.0969774220877169 -1.2205533276128708 -  
0.098455189125584847;-0.72326123720412216 0.20165637333439559 -0.19631507967228065 -0.34343134051049362 -  
0.12429092303345812 -2.1375255261130932 -1.3742461359654055];

## % Layer 2

b2 = [0.00098921561164540218;-0.79596366897510518;1.1005936964614667];  
LW2\_1 = [-0.43911621765177616 0.81271184645412298 -1.0449698471991724 0.011305268233510763 -0.20142551468983047 -  
1.3175230010911849 -0.46804545272891318 0.70243041937138206 0.026506448634820247 0.71061771684073938 -  
1.1083471839632539 0.51844568165688854 0.079318756308271954 0.23984346314875635 -1.7027295389762123 -  
0.077419441943690104 -0.71101421159507971 -0.91760497002225128 -0.84998301350995298 0.63559473103521613 -  
0.26453552156208693 -0.024974578598297895 0.4438279112308971 -0.40312422139353554 -1.3208820926626292  
0.70071748450661997 -0.80861398963976461 -0.1041656915413235 0.79237908840865023 -0.79462800219390961 -  
0.38069612749931675 0.42240015484816396 0.11332627184818576 -0.52231805193738734 -0.90645638166998999 -  
0.51220338107777896 -0.66722633369963125 0.03396610492065108 0.49910842197592503 -0.38439308687171569 -  
0.68101008635009475 0.54852469797485426 -0.142822274242493 -0.84258053464174543 1.4497932153458142  
0.42772863477643153 -0.2108724161793516 0.038496970022334744 -0.5721363761632553 0.079283590161892722 -  
1.0609897634213603 -1.1512724815930795 -0.1124148758316585 0.84648065951248408 -0.21961026534663466

0.1541629892147941 -0.28608600164528541 -0.046125519755487933 -0.32849315140780533 -0.26568597523990078  
0.085041105207564499 0.3855675351758403 0.72441123602043356 0.56780937312865709 0.18771991192159129  
0.84982532549584056 0.56346100543882793 0.86492863579437784 -0.5030772027883732 -0.407422744812722 -  
0.4863168827844323 -0.72461346305427532 1.3777661373921173 0.88594078825783718 -1.1430042563885727 -  
0.16650272792595597 -0.53473839306689908 0.31231339025917831 -0.5800405957553324 -0.68387636662514062 -  
1.2520447097446616 -0.11457001765702958 2.31088034435431 0.44306595426564432 0.012706789758708282 -  
1.4152769311748241 1.015552540368714 0.77741399703960157 0.063734186631213191 1.0988285972504908 0.67557331395624609  
1.690686020408674 -0.68650570777855802 0.98457133075262393 -0.10091541217946993 0.52713821065702582 -  
0.66780751137057415 0.70939144553184197 -2.1764537524064842 0.59292939301908587;-0.92137466723255468  
0.8299008680890978 0.36743958427346762 -0.67422105510743313 -0.10215364916115914 -0.25033159536140126 -  
0.88973367641207601 1.1256477689624544 -0.92184806374124206 -0.17943717558297842 -0.73639328379107838  
0.32572894270502156 -0.23494553899825571 -0.57870546411273005 0.15424403856507449 -0.45553742505694234 -  
1.0161849848265685 -0.23362276424846742 0.7457760855191562 -1.4636217131317082 -0.83729165642067316 -  
0.89125800750715145 0.2088895240105261 0.88686714708513403 0.8933036978660216 -0.04116377508837165 -  
0.32637129050178953 -0.57939220109803713 -0.80528451219190655 0.19084468930867843 0.40723554514297672  
0.32776802245796244 0.26337016858002238 -0.24602808308698579 0.75367174566350414 -0.22210033452324424 -  
0.038901375911734787 -1.1328879870208368 -0.3421481275227366 0.65936310032666734 -0.96630850235627419 -  
0.95728702271194321 0.79629680093665889 0.44871154053275369 -0.06284078190906206 0.50876523079964131  
0.19520249667614623 0.89206132737159782 0.32040164155762518 0.11543221569539568 0.69039240975997551 -  
0.063920772390239813 -0.038013424899811209 1.126681124481655 -1.2112401425255359 0.31308556404861859  
1.1976988277834388 -1.1012196818232198 0.3887796015244326 1.0562544534770462 1.0324409400891594 -  
0.29439372650754975 0.23821067638575549 0.66517024724712392 -0.74191048217616196 -0.60293356586768243  
0.39574023493037247 -0.52049711537347332 0.74566860938905377 -0.98423532142289083 -0.51806429036800072 -  
0.70073739530979318 -0.2096424919765231 -0.32607608228357204 0.27740819392094279 0.51530276158134947  
0.031805026872148104 -1.4725026089162059 -0.78694724340148037 -0.13571125123210592 -0.25247037104163889 -  
1.2965586380474285 -0.2302257148907535 -0.72680523246202722 -0.85574559277936391 0.37854693035688086 -  
0.41929585145084597 0.1454150067996377 0.47944714149925233 0.98897648471001243 0.72746804591471093 -  
0.60525956030946748 0.94220882639557835 0.50032332086311193 0.015375779070326145 0.26819119246490503 -  
0.49390302896260779 -0.84426331425475931 0.63522584494045098 -1.1433046884064484;-1.0821756633365007 -

0.056110489106849848 0.63520452377900982 0.37393503316383692 0.28374627869199326 0.70961004531971372 -  
0.38968170722479034 0.65287296121024774 0.20820247686931437 -0.80751175902086481 -0.051169494957779164  
0.24277990248903641 -0.76433985064479582 0.41021179580085682 -0.53431540229696328 -0.23410753523094008 -  
0.11817022196714022 -0.067447123239735687 -0.37556801328363365 0.32032114294580805 -0.65758208878777957 -  
0.011579913135569931 -0.52380017466438278 0.84491832094949892 0.16009685117355013 0.39829480078873236  
0.59368564041902405 -0.4247275150619863 -0.8454979764961259 0.6459984301386974 1.1545370470766092  
0.99531047010871398 0.39881897208661815 0.69440433306106952 0.39549256745588518 -0.97856159101318207 -  
0.4799781931691825 -0.17276052902010078 0.90758908701007568 0.34432171306103732 0.6311189461822162 -  
0.66458554828804439 -0.48855334241864745 -0.48050171467067482 -1.3749132621436218 0.024272684690187056 -  
0.87136604775009607 0.74896040274843134 -0.50452384589873578 -0.3872261628839026 -0.70927288106487829 -  
0.59702291669795426 -0.71218034539199959 0.8371370425852851 1.208915233845796 -0.83627816913956832 -  
0.99871737912720226 -0.50927101387211471 0.53896753398237651 -0.49284968996731077 0.26664726448181952 -  
0.82506616774746 0.36019974725454734 -1.1147918102764189 -0.26218456041247151 -0.92463889361648144  
0.093733349496884819 0.17270577790516753 0.33057355608612854 1.2574318628767687 0.42123226989631263 -  
0.16142338600884257 0.043228798679582146 -1.1636618121280646 1.2106169578227683 0.04075431695503734  
0.49659030968519691 -0.89559294935128964 -0.080033421875062766 -0.71563786046154987 -0.30206272495776298  
0.15355291588810469 -1.8054793486443044 -0.81885108246134564 -0.95988829534821574 1.3226179150340258 -  
0.096556182178010402 0.99514973892222847 0.22352153923329504 -0.7303218428509769 -0.01748296275569235 -  
0.57819779621890399 -0.4363683181223218 -0.15227842136346825 0.26611207069444687 0.097653546996776086  
0.0010990109497008387 -0.093984944697469014 0.0013416949906557077 -0.25701671064117132];

% ===== SIMULATION =====

% Format Input Arguments

isCellX = iscell(X);

if ~isCellX

    X = {X};

end

```
% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
    Q = size(X{1},1); % samples/series
else
    Q = 0;
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Input 1
    X{1,ts} = X{1,ts}';
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);

    % Layer 1
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);

    % Layer 2
    a2 = softmax_apply(repmat(b2,1,Q) + LW2_1*a1);

    % Output 1
    Y{1,ts} = a2;
    Y{1,ts} = Y{1,ts}';
end
```

```
% Final Delay States
```

```
Xf = cell(1,0);
```

```
Af = cell(2,0);
```

```
% Format Output Arguments
```

```
if ~isCellX
```

```
    Y = cell2mat(Y);
```

```
end
```

```
end
```

```
% ===== MODULE FUNCTIONS =====
```

```
% Map Minimum and Maximum Input Processing Function
```

```
function y = mapminmax_apply(x,settings)
```

```
y = bsxfun(@minus,x,settings.xoffset);
```

```
y = bsxfun(@times,y,settings.gain);
```

```
y = bsxfun(@plus,y,settings.ymin);
```

```
end
```

```
% Competitive Soft Transfer Function
```

```
function a = softmax_apply(n,~)
```

```
if isa(n,'gpuArray')
```

```
    a = iSoftmaxApplyGPU(n);
```

```
else
```

```
    a = iSoftmaxApplyCPU(n);
```

```
end
```

```
end
```

```
function a = iSoftmaxApplyCPU(n)
```

```
nmax = max(n,[],1);
```

```
n = bsxfun(@minus,n,nmax);
numerator = exp(n);
denominator = sum(numerator,1);
denominator(denominator == 0) = 1;
a = bsxfun(@rdivide,numerator,denominator);
end
function a = iSoftmaxApplyGPU(n)
nmax = max(n,[],1);
numerator = arrayfun(@iSoftmaxApplyGPUHelper1,n,nmax);
denominator = sum(numerator,1);
a = arrayfun(@iSoftmaxApplyGPUHelper2,numerator,denominator);
end
function numerator = iSoftmaxApplyGPUHelper1(n,nmax)
numerator = exp(n - nmax);
end
function a = iSoftmaxApplyGPUHelper2(numerator,denominator)
if (denominator == 0)
    a = numerator;
else
    a = numerator ./ denominator;
end
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end
```

## Прилог 4 Приказ дела базе података употребљених за тренирање аутоенкодера

Параметар →	1	2	3	4	5	6	7
Узорак ↓	tg 02	delta tg delta	pd 06	Te	Riso statora	N	Riso rotora
1	1.6284	0.348	1.8273	19.9321	3.06E+03	5.8856	5.56E+03
2	1.3261	0.3587	2.5666	19.5751	3.85E+03	2.8989	1.98E+03
3	1.572	0.3089	0.1744	0.0423	8.40E+03	5.8781	5.90E+03
4	0.7928	0.3855	2.7771	12.0041	5.18E+03	9.1156	1.31E+03
5	1.9742	0.4749	0.7585	19.9791	2.66E+03	8.6141	7.44E+03
6	1.4064	0.2933	3.9171	15.2022	9.25E+03	7.1344	3.28E+03
7	1.4137	0.3034	0.3683	4.9495	6.65E+03	6.4039	3.18E+03
8	1.0477	0.3267	2.2916	10.201	2.96E+03	2.8516	1.31E+03
9	1.2757	0.046	3.0705	29.2779	2.20E+03	9.8611	9.30E+03
10	1.6733	0.1573	4.6493	27.0651	6.70E+03	6.7949	7.38E+03
11	0.2984	0.3486	3.1089	28.8856	3.81E+03	4.5555	6.86E+03
12	0.1139	0.0625	0.7935	15.8048	6.92E+03	5.97	3.50E+03
13	1.4784	0.0059	0.9528	5.206	3.91E+03	8.9813	4.96E+03
14	0.7011	0.2281	4.1813	27.6706	5.90E+03	3.977	4.76E+03
15	0.5848	0.225	0.9409	1.1567	5.34E+03	7.5593	1.71E+03
16	1.8137	0.3302	0.8417	3.9646	8.31E+03	8.2282	7.26E+03
17	1.7298	0.4926	4.8999	21.4353	5.81E+03	8.258	9.53E+03
18	1.1997	0.0109	0.0801	8.4343	3.06E+03	5.1845	1.04E+03
19	1.2461	0.0249	2.8651	24.2284	7.44E+03	5.8754	9.49E+03



## Прилог 5 Код за тренирање аутоенкодера у програмском пакету Матлаб

```
% 1. Korak – kreiranje baze podataka 10000 zadovoljavajućih rezultata
n=10000;
%tgd02
a=0;b=2;
u1=(b-a).*rand(n,1)+a;
%dtgdmax
a=0;b=0.5;
u2=(b-a).*rand(n,1)+a;
%pdmax06
a=0;b=5;
u3=(b-a).*rand(n,1)+a;
% Te
a=0;b=30;
u4=(b-a).*rand(n,1)+a;
%Riso statora
a=1000;b=10000;
u5=(b-a).*rand(n,1)+a;
%N statora
a=2;b=10;
u6=(b-a).*rand(n,1)+a;
%Riso rotora
a=100;b=10000;
u7=(b-a).*rand(n,1)+a;
baza=[u1 u2 u3 u4 u5 u6 u7];

% 2. Korak – Treniranje autoenkodera
X=baza';
enc1= trainAutoencoder(X,75, 'maxepochs', 5000, ...
    'EncoderTransferFunction','satlin',...
    'DecoderTransferFunction','purelin',...
    'L2WeightRegularization',0.01,...
    'SparsityRegularization',4,...
    'SparsityProportion',0.4);

% 3. Korak – evaluacija modela na osnovu proračuna MSE
XReconstructed= predict(enc1,X);
mseError = mse(X-XReconstructed)

% 5. Korak – prikaz autoenkoderske mreže
view (enc);

% 6. Proračun na veštačkoj bazi od 20 uzoraka
for i=1:21{X(:)=[tgdelta(i);deltatgdelta(i);pd06(i);starost(i);Risostator(i); N(i);
Risorotor(i);]
```

*Денис Илић – докторска дисертација*

```
procena = predict(enc1, X);  
mseError(i) = mse(X(i) - procena(i))  
end
```

## Прилог 6 Приказ вештачке базе употребљене за тестирање система и резултата појединих експертских система

Ред. број	tgδ	Δtgδ	PD <sub>06</sub>	R <sub>isos</sub>	N	R <sub>isor</sub>	Стар	ФЛС	АНН	MSE АЕ	Tree	Анфис
1	4.06	0.57	7	728	0.75	1140	2	2.63	2	948.111	1	0.64
2	0.23	0.01	4	1500	1.00	5039	5	1.04	3	0.095	3	3.37
3	5.26	0.20	37	1222	6.29	114	4	2.68	2	164300 3.876	2	3.81
4	2.74	0.10	13	3106	13.9	2215	26	2.64	3	42344.9 50	3	2.09
5	1.33	0.05	4	954	1.53	1125	18	1.04	3	0.031	3	3.11
6	2.10	0.37	31	5978	1.48	2015	26	2.21	3	245627. 903	3	2.96
7	0.28	0.20	1	1869	0.33	1481	1	0.97	3	15.683	3	4.12
8	0.18	0.12	10	641	3.03	1143	26	2.51	3	9265.14 4	3	3.21
9	3.34	0.14	14	560	3.13	3822	46	2.67	3	128165. 444	3	2.86
10	0.53	0.11	29	3617	0.64	2838	14	2.19	3	66795.1 78	3	3.35
11	0.66	0.05	13	1910	3.30	1606	1	1.96	3	4419.57 6	3	3.54
12	4.05	0.22	0	1044	5.59	6505	15	1.40	3	1.324	2	4.45
13	5.79	0.09	6	584	3.05	271	6	2.54	2	3.270	1	1.82
14	0.98	0.02	1	571	1.80	2574	12	1.02	3	0.013	3	3.24
15	1.81	0.31	14	6051	7.36	809	17	2.12	3	27297.6 47	3	2.59
16	3.68	0.12	35	1318	8.77	177	0	2.68	3	134059 6.101	3	4.98
17	4.42	0.01	1	241	1.39	3334	3	1.48	2	4.297	1	1.65
18	0.99	0.17	2	425	11.9	2007	42	1.27	3	4813.42 3	3	3.03
19	0.24	0.18	21	241	4.53	496	5	2.02	3	612300. 951	3	3.56
20	2.57	0.14	1	2474	2.37	3511	13	1.01	3	0.352	3	2.88

## Прилог 7 Кôд којим је креиран АНФИС експертски систем

```
load ('DATAFINAL.xml')  
anfissistem=anfis(DATAFINAL);
```

output:

struct with fields:

```
name: 'ANFIS'  
type: 'sugeno'  
andMethod: 'prod'  
orMethod: 'probor'  
defuzzMethod: 'wtaver'  
impMethod: 'prod'  
aggMethod: 'sum'  
input: [1×7 struct]  
output: [1×1 struct]  
rule: [1×2187 struct]
```

## Прилог 8 – Алати за процену квалитета примењених система и грешке при тренирању система

У овом прилогу су објашњени основни математички алати који су употребљавани за процену квалитета тренирања и креираних модела вештачке интелигенције. Развојем информатичких технологија и алгоритама машинског учења поједине методе машинског учења су се показале погодним за решавање одређеног типа проблема. За процену квалитета и прецизности појединих модела вештачке интелигенције у овом раду се користи неколико математичких алата интегрисаних у програмски пакет Матлаб. Опис ових алата приказан је у наставку.

### I - Средње квадратно одступање

Средње квадратно одступање или варијанса се израчунава као просек квадрата одступања вредности сваког податка у скупу од средње вредности.

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} = \frac{\sum_{i=1}^n x_i^2}{n} - \bar{x}^2$$

#### ○ Gде је

- $x_i$  вредност obeležja,
- $\bar{x}$  аритметичка средина
- $n$  број података

### II - Матрице конфузије (Confusion Matrix) система

У области машинског учења а нарочито у подобласти класификације података матрице конфузије или матрице грешке, како се често називају, представљају изузетно користан алат за оцену перформанси креираног модела. Представљају, заправо, табеларни приказ перформанси модела надгледаног вештачког учења. У колонама су приказане категорије које су у скупу тачних вредности нпр. на основу којих је вршено учење модела. У редовима су категорије које су предвиђене употребом модела. У дијагоналним ћелијама табеле су приказани бројеви тачно категорисаних података. Крајња десна колона приказује проценат тачно и погрешно категорисаних предикција. Крајњи доњи ред приказује процентуални удео свих узорака који су тачно и погрешно категорисани. Ћелија у доњем десном углу представља укупну тачност модела.

Тако се са примера на слици 25 (пример креиране вештачке неуралне мреже у тачки 6.1) могу извести следећи закључци:

- Од укупног броја од 538 узорака модел је тачно категорисао 308 узорака као „добре“ вредности, 17 узорака који су заправо сумњиви и 4 узорака оцењена као лоша су грешком категорисани као добри
- Од укупног броја од 538 узорака модел је тачно категорисао 86 узорака као „сумњиве“ вредности, 1 узорак који су заправо добар и 17 узорака оцењена као лоша су грешком категорисани као сумњиви

- Од укупног броја од 538 узорака модел је тачно категорисао 90 узорака као „лоше“ вредности, 1 узорак који су заправо добар и 14 узорака оцењена као симњиво су грешком категорисани као лоши.
- Укупна тачност модела износи 90%, тј 90 узорака је тачно категорисано, док је 10% погрешно категорисано. Креирани модел је у стању да прилично добро „препозна“ добре вредности, док је нешто мање успешан у разграничењу сумњивих и лоших вредности. Такође, од свих узорака мали проценат узорака је погрешно категорисан као лош а да је заправо оцењен као добар и обрнуто.

**All Confusion Matrix**

<b>Output Class</b>	1	308 57.2%	17 3.2%	4 0.7%	93.6% 6.4%
	2	1 0.2%	86 16.0%	17 3.2%	82.7% 17.3%
	3	1 0.2%	14 2.6%	90 16.7%	85.7% 14.3%
		99.4% 0.6%	73.5% 26.5%	81.1% 18.9%	90.0% 10.0%
	1	2	3	<b>Target Class</b>	

Слика 62 Пример матрице конфузије модела


III - ROC- Receiver Operating Characteristic у процени квалитета система у машинском учењу

ROC графикони су веома често коришћени у сврху визуелизације перформанси класификатора. Оригинално су развијени током Другог светског рата у сврхе процене квалитет система за раздвајање корисног сигнала радара од шума. Ови графикони су коришћени и као медицински алати за доношење одлука, да би потом њихова примена нагло порасла у областима машинског учења и *data mininga*. Пример графикона са 5 класификатора приказан је на слици 26.[ref roc] На осама овог графикона налазе се величине:

- Процент тачних предвиђања
- Процент погрешних предвиђања

У примеру са слике 26, тачка D представља идеалан класификатор. Дијагонална линија на графикону представља класификатор који случајно врши класификацију. Нпр, тачка С на

графикону указује на класификатор који у 70% случајева класификује узорак као „позитиван“, немајући при томе у виду да ли је то тачно или не. У принципу, класификаторски модели су бољи што им је ROC карактеристика више у горњем левом углу. Класификатор Е на графикону из примера је најлошији. Може се сматрати да овај класификатор садржи информацију о класификацији, за разлику од тачке С, али је интерпретира погрешно.



Слика 26 Пример ROC графикона

Постоје бројне математичке анализе ових графикона којима се могу извести многе додатне информације о моделу, попут прорачуна површине испод графикона (AUC – Area Under Curve). У овом раду ће се првенствено поредити графикони при креирању, тестирању и подешавању модела како би се изабрао најтачнији модел. Подешавање хиперпараметара ће бити извршавано док се не постигне максимална вредност AUC параметра.

## Прилог 9 – Код функције којим је креирана прилагођена функција припадности

```
function out = riso(x, params)
for i = 1:length(x)
    if x(i) < params(1)
        y(i) = 10;
    elseif x(i) > params(2)
        y(i) = 10;
    else
        y(i) = 0;
    end
end
end

out = 0.1*y'
```



## Биографски подаци о аутору дисертације

Денис Илић рођен је 03.08.1989. године у Тузли, Босна и Херцеговина. Основну школу завршио је у Баричу. Потом је похађао средњу Електротехничку школу Никола Тесла у Београду. Након завршене средње школе, 2008. године уписује Електротехнички факултет Универзитета у Београду. На Електротехничком факултету изабрао је Одсек за енергетику, а затим и Смер за електроенергетске системе. Дана 04.09.2012. године завршио је основне академске студије на студијском програму Основне академске студије Електротехника и рачунарство, модул Енергетика – Смер електроенергетски системи, у трајању од четири године, обима 240 ЕСПБ бодова, са просечном оценом 7,62. Дипломски рад „Оптимално планирање линијских одводника пренапона“ одбранио је са оценом 10, уз менторство проф. др Милана Савића.

Мастер студије на Електротехничком факултету, Смер за електроенергетске системе, уписао је 2012. године. У току мастер студија остварио је просечну оцену 9,00. Мастер академске студије на студијском програму Електротехника и рачунарство, модул Електроенергетски системи завршио је 11.09.2013. године, са оценом 10 на одбрани мастер рада на тему „Методе за испитивање мониторинг и дијагностику енергетских и мерних трансформатора“. Ментор на изради мастер рада је био проф. др Златан Стојковић.

Докторске студије на Електротехничком факултету у Београду уписао је школске 2014/2015. године на модулу Електроенергетске мреже и системи, где је све испите положио са просечном оценом 9,50.

Од марта 2013. године запослен је у Електротехничком институту Никола Тесла Београд, у Центру за електромерење и Специјализованој лабораторији за испитивање изолационих система. Тренутно распоређен на послове самосталног сарадника при испитивању електроизолационих система синхроних генератора, енергетских и мерних трансформатора. Током рада учествовао је у изради више стручних студија за потребе ЈП ЕПС, углавном на тему унапређења у процене стања изолационих система ЕЕО у постројењима ЈП ЕПС као и увођења нових испитних метода у праксу дијагностике у енергетским и индустријским погонима у Србији. Учествовао је у пружању консултантских услуга при пројектовању, фабричким и пријемним испитивањима капиталне ЕЕО у ЈП ЕПС.

Аутор/коаутор је на укупно 26 објављених радова. Аутор је рада у научном часопису међународног значаја са SCI листе, категорије М23. Такође, аутор је два научна рада у часопису националног значаја категорије М53. Аутор је једног рада у зборнику регионалних научних скупова, као и четири рада у зборницима скупова националног значаја.

Активно се служи енглеским језиком, познаје основе немачког и француског језика.

## Изјава о ауторству

Потписани: Денис Илић

Број уписа: 5015/2014

### Изјављујем

да је докторска дисертација под насловом:

„Дијагностика стања електроизолационих система синхроних генератора заснована на вештачкој интелигенцији“

- резултат сопственог истраживачког рада,
- да приложена дисертација у целини, ни у деловима није била предложена за добијање било које дипломе према студијским програмима других високошколских установа,
- да су резултати коректно наведени и
- да нисам кршио ауторска права и користио интелектуалну својину других лица.

У Београду, 15.08.2022. године

Потпис аутора



## Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора: Денис Илић

Број индекса: 5015/2014

Студијски програм: Електроенергетске мреже и системи

Наслов рада: Дијагностика стања електроизолационих система синхроних генератора заснована на вештачкој интелигенцији

Ментор: доц. др Милета Жарковић

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла ради похрањивања у Дигиталном репозиторијуму Универзитета у Београду. Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

У Београду, 15.08.2022. године

Потпис аутора



## Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Дијагностика стања електроизолационих система синхроних генератора заснована на вештачкој интелигенцији

која је моје ауторско дело.

Дисертацију са свим прилозима предао сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио/ла.

1. Ауторство (CC BY)
2. Ауторство – некомерцијално (CC BY-NC)
3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)
4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)
5. Ауторство – без прерада (CC BY-ND)
6. Ауторство – делити под истим условима (CC BY-SA)

У Београду, 15.08.2022. године

Потпис аутора



**1. Ауторство.** Дозвољава се умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.

**2. Ауторство – некомерцијално.** Дозвољава се умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.

**3. Ауторство – некомерцијално – без прерада.** Дозвољава се умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.

**4. Ауторство – некомерцијално – делити под истим условима.** Дозвољава се умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.

**5. Ауторство – без прерада.** Дозвољава се умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.

**6. Ауторство – делити под истим условима.** Дозвољава се умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода