

Соња С. Кнежевић

Предиктивно управљање ресурсима у
микромрежи

-докторска дисертација-

Београд, 2026.

Sonja S. Knezevic

Predictive Control of Resources in Microgrid
Systems

-doctoral dissertation-

Belgrade, 2026.

ПОДАЦИ О МЕНТОРУ И ЧЛАНОВИМА КОМИСИЈЕ

Ментор:

Др Милета Жарковић, ванредни професор
Универзитет у Београду, Електротехнички факултет

Чланови комисије:

Др Горан Добрић, ванредни професор
Универзитет у Београду, Електротехнички факултет
Др Александар Милићевић, виши научни сарадник
Универзитет у Београду, Институт за нуклеарне науке „Винча”
Др Горан Квашчев, редовни професор
Универзитет у Београду, Електротехнички факултет

Датум одбране:

Захвалница

Ова дисертација је резултат вишегодишњег рада, истраживања и посвећености током докторских студија на Електротехничком факултету Универзитета у Београду.

Посебну захвалност дугујем свом ментору, проф. др Милети Жарковићу, на стручној помоћи, корисним сугестијама и способности да моја размишљања квалитетно усмери. Хвала му и на подршци, поверењу и начину на који је умео да ме покрене у тренуцима застоја.

Захваљујем се и проф. др Златану Стојковићу, који је био мој први изабрани ментор током докторских студија и усмерио ме ка проф. др Милети Жарковићу. Искрену захвалност упућујем и проф. др Дарку Шошићу, који уме да говори и о техници и о књигама и тиме подсети да знање има шири смисао.

Проф. др Горану Добрићу захваљујем на критичким запажањима, снажној стручној подршци и бројним дискусијама током израде рада, које су значајно допринеле квалитету и обликовању ове докторске дисертације. Захваљујем се и др Александру Милићевићу др Горану Квашћеву на разумевању, корисним саветима и времену посвећеном детаљном прегледу ове тезе. Хвала му на преданом читању, ред по ред.

Хвала тати за „јуначе“ после сваког написаног поглавља. Хвала мами, која ме је научила да мислим и трајем.

Предиктивно управљање ресурсима у микромрежи

Резиме

Савремени електроенергетски системи пролазе кроз интензивну трансформацију услед значајно повећаних удела обновљивих извора, тежења ка децентрализацији производње, развијањем нових технологија које не потпомажу систему рада традиционалних система. Ове промене значајно повећавају комплексност планирања и управљања системима где традиционални приступ показује своја ограничења.

У овој дисертацији развијене су методе за предиктивно управљање ресурсима електроенергетског система Србије (ЕЕС) применом метода вештачке интелигенције. Предложена методологија комбинује вештачке неуралне мреже и адаптивне неуро фази системе у циљу прецизније предикције потрошње и производње електричне енергије, као и емисије CO₂. ANN (*Artificial Neural Networks – ANN*) модел користи се за краткорочну и дугорочну предикцију потрошње електричне енергије, као и токова снага у електроенергетској мрежи. ANFIS (*Adaptive Neuro-Fuzzy Inference System - ANFIS*) модели се, уз резултате добијене применом ANN модела и експертска знања и искуства диспечера, користе за предвиђање производње електричне енергије из различитих извора и емисија CO₂. ARIMA (*Autoregressive Integrated Moving Average – ARIMA*) модел служи као референтна статистичка метода са којом се пореде предвиђања добијена моделима базираним на вештачкој интелигенцији.

Модели су обучени и тестирани на реалним мерним вредностима ЕЕС-а Србије на сатном нивоу. Укључују реалне податке о потрошњи и производњи из различитих извора енергије, као и релевантне амбијенталне услове, чији је утицај на рад ЕЕС-а узет у обзир кроз прорачуне. Тачност развијених модела је приказана кроз више метрика грешака (*Mean Absolute Error – MAE*, *MSE – Mean Squared Error*, *RMSE – Root Mean Square Error*, *MAPE – Mean Absolute Percentage Error*), које су показале да су развијени модели са високом прецизношћу. Посебно је приказано да спајање ANN и ANFIS метода значајно смањује укупну грешку предикције, која за предвиђање потрошње износи мање од 6%, док за предикцију емисије CO₂ износи 1,3%.

Резултати истраживања показују да предложени приступ омогућава поуздано планирање рада ЕЕС-а, пружа значајну подршку експертима и смањује потенцијалне људске грешке. Представљен је допринос предиктивном управљању, како постојећим системима, тако и микромрежама и системима са значајним уделом обновљивих извора енергије и нових технологија.

Кључне речи: Предиктивно управљање ресурсима ЕЕС-а; Вештачке неуралне мреже; ANFIS; Предикција потрошње, Предикције производње; Велики скупови података; Микромрежа; Интеграција микромреже у ЕЕС.

Научна област: Техничке науке – Електротехника

Ужа научна област: Електроенергетски системи

УДК:621.3

Predictive Control of Resources in Microgrid Systems

Abstract

Modern electric power systems are undergoing an intensive transformation due to the rapidly increased penetration of renewable sources, the tendency toward decentralization of generation, and the development of new technologies that do not support the operating principles of traditional systems. These changes significantly increase the complexity of planning and managing the systems themselves, where the traditional approach shows its limitations.

In this dissertation, methods for predictive management of EPS resources using artificial intelligence methods have been developed. The proposed methodology combines artificial neural networks and adaptive neuro–fuzzy systems with the aim of more precise prediction of electricity consumption and energy production, as well as CO₂ emissions. The ANN model is used for short–term and long–term prediction of electricity consumption, as well as power flows in the electric power network. ANFIS models, together with the results obtained from ANN models and the expert knowledge and experience of dispatchers, are used to predict electricity generation from various sources and CO₂ emissions. The ARIMA model serves as a reference statistical method with which predictions from models based on artificial intelligence are compared.

The models were trained and tested on real, measured values of the Serbian EPS at an hourly level. They include actual data on consumption, generation from different energy sources, as well as relevant ambient conditions whose influence on EPS operation is taken into account through calculations. The accuracy of the developed models is presented through several types of errors (MAE, MSE, RMSE, MAPE), which have shown that a high–precision model has been achieved. It is particularly shown that the combination of ANN and ANFIS methods significantly reduces the overall prediction error, which for consumption forecasting is below 6%, while for CO₂ emission prediction it amounts to 1.3%.

The research results show that the proposed approach enables reliable planning of EPS operation with significant assistance to experts and a reduction of potential human errors. A contribution to predictive system management is presented, both for existing systems and for microgrids and systems with a significant share of renewable energy sources and new technologies.

Keywords: Predictive resource management in power systems; Artificial Neural Networks (ANN); Adaptive Neuro–Fuzzy Inference System (ANFIS); Load forecasting; Generation forecasting; Big data analytics; Microgrid; Microgrid integration into the power system

Scientific field: Technical science – Electrical engineering

Specific scientific field: Power systems

UDK:621.3

САДРЖАЈ

<u>ЛИСТА СЛИКА</u>	<u>VIII</u>
<u>ЛИСТА ТАБЕЛА</u>	<u>XI</u>
<u>1. УВОД.....</u>	<u>1</u>
<u>2. ЕЛЕКТРОЕНЕРГЕТСКИ СИСТЕМ СА НОВИМ ТЕХНОЛОГИЈАМА И ИЗАЗОВИМА</u>	<u>4</u>
2.1. Од ЛИНЕАРНОГ КА КОМПЛЕКСНОМ, БИ–ДИРЕКЦИОНОМ СИСТЕМУ.....	5
2.2. ИНТЕРМИТЕНТНОСТ ОБНОВЉИВИХ ИЗВОРА ЕНЕРГИЈЕ	6
2.3. СКЛАДИШТА ЕЛЕКТРИЧНЕ ЕНЕРГИЈЕ.....	8
2.4. ПОРАСТ БРОЈА КУПАЦА–ПРОИЗВОЂАЧА.....	9
2.5. МИКРОМРЕЖЕ И ЛОКАЛНА ФЛЕКСИБИЛНОСТ.....	10
2.6. АНАЛИЗА СИСТЕМА	10
<u>3. МАШИНСКО УЧЕЊЕ</u>	<u>12</u>
3.1. ТИПОВИ МАШИНСКОГ УЧЕЊА.....	13
3.1.1. НАДГЛЕДАНО МАШИНСКО УЧЕЊЕ	14
3.1.2. НЕНАДГЛЕДАНО МАШИНСКО УЧЕЊЕ	15
3.1.3. ПОДСТАКНУТО МАШИНСКО УЧЕЊЕ	15
3.1.4. САМОНАДГЛЕДАНО МАШИНСКО УЧЕЊЕ.....	17
3.1.5. ХИБРИДНО МАШИНСКО УЧЕЊЕ.....	17
<u>4. ВЕШТАЧКЕ НЕУРАЛНЕ МРЕЖЕ</u>	<u>18</u>
4.1. АРХИТЕКТУРА ANN-А	19
4.2. ОБУЧАВАЊЕ ANN-А	24
4.3. АНАЛИЗА ПЕРФОРМАНСИ ANN МОДЕЛА.....	27
4.4. ПРАКТИЧНЕ ПРИМЕНЕ У ЕЕС–У	28
<u>5. ANFIS.....</u>	<u>30</u>
5.1. СТРУКТУРА ANFIS МОДЕЛА.....	31
5.2. ПРЕДНОСТИ ANFIS МОДЕЛА	34
5.3. ПРИМЕНА ANFIS МОДЕЛА	36
<u>6. ARIMA</u>	<u>38</u>

6.1. Увод у ARIMA МОДЕЛЕ	38
6.2. МАТЕМАТИЧКИ МОДЕЛ ARIMA.....	40
6.3. ПРОЦЕС ФОРМИРАЊА ARIMA МОДЕЛА.....	41
6.4. ОГРАНИЧЕЊА ARIMA МОДЕЛА	45
6.5. ПРИМЕНЕ ARIMA МОДЕЛА У ЕНЕРГЕТИЦИ.....	47
<u>7. УПОТРЕБА ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ ЗА ПЛАНИРАЊЕ РАДА ЕЛЕКТРОЕНЕРГЕТСКОГ СИСТЕМА</u>	48
7.1. ФОРМИРАЊЕ ANN МОДЕЛА.....	49
7.2. РЕЗУЛТАТИ ПРЕДВИЂАЊА ПОТРОШЊЕ	55
7.3. ПОРЕЂЕЊЕ ANN И ARIMA ПРЕДВИЂАЊА ПОТРОШЊЕ	57
7.4. ТРОДИМЕНЗИОНАЛНА ЗАВИСНОСТ ПРОИЗВОДЊЕ ЕЛЕКТРИЧНЕ ЕНЕРГИЈЕ ОД АМБИЈЕНТАЛНИХ УСЛОВА.....	57
7.5. ПРЕДИКЦИЈА ПРОИЗВОДЊЕ ИЗ ТЕРМОЕЛЕКТРАНА И ХИДРОЕЛЕКТРАНА ПОМОЋУ ANFIS–А	59
7.6. РЕЗУЛТАТИ ПРЕДИКЦИЈЕ ПРОИЗВОДЊЕ ПОМОЋУ ANFIS МОДЕЛА	60
7.7. РЕЗУЛТАТИ ПРЕДИКЦИЈЕ ЕМИСИЈЕ CO ₂	62
<u>8. ПРЕДИКТИВНО МОДЕЛОВАЊЕ ЗА ПРОЦЕНУ СТАЊА ЕЕС–А</u>	68
8.1. РАЗВИЈЕНИ АЛГОРИТАМ	69
8.2. МОДЕЛОВАЊЕ СИСТЕМА	73
8.2.1. ТЕРМИЧКИ ЗАВИСТАН МОДЕЛ НАДЗЕМНОГ ВОДА	73
8.2.2. МОДЕЛОВАЊЕ ПРОИЗВОДЊЕ И ПОТРОШЊЕ	75
8.2.3. ПОСМАТРАНА МРЕЖА	77
8.3. РЕЗУЛТАТИ ПРОРАЧУНА	78
<u>9. ИЗОЛОВАНИ РАД МИКРОМРЕЖЕ СА ВИШЕСТРУКИМ СКЛАДИШТИМА ЕНЕРГИЈЕ</u>	84
9.1. СКЛАДИШТА ЕНЕРГИЈЕ У МОДЕЛУ СИСТЕМА	85
9.2. ТЕХНОЛОГИЈА РАДА ЕЛЕКТРОЛИЗЕРА У МОДЕЛУ СИСТЕМА	87
9.3. ПРИНЦИП РАДА СИСТЕМА.....	88
9.4. МОДЕЛОВАЊЕ ЕЛЕМЕНАТА СИСТЕМА	90
9.4.1. ЕЛЕКТРОЛИЗЕР И СПУШТАЧ НАПОНА	90
9.4.2. БАТЕРИЈЕ И ЕВ.....	92
9.4.3. ГОРИВЕ ЋЕЛИЈЕ И ПОДИЗАЧ НАПОНА	92
9.4.4. СКЛАДИШТЕ ВОДНИКА	93
9.4.5. КОНТРОЛА СИСТЕМА	93
9.5. РЕЗУЛТАТИПРОРАЧУНА.....	95
9.5.1. ТОК СНАГА И АКТИВАЦИЈА СКЛАДИШТА	95
<u>10. ПРОРАЧУН СТАЊА ЕЕС-А УЗ АНГАЖОВАЊЕ МИКРОМРЕЖЕ.....</u>	99

10.1. РАЗВИЈЕНИ АЛГОРИТАМ	100
10.2. ПОДАЦИ ПРОРАЧУНА	103
10.3. РЕЗУЛТАТИ ПРОРАЧУНА	105
10.3.1. НИВЕЛИСАЊЕ НАПОНСКОГ НИВОА.....	106
10.3.2. СМАЊИВАЊЕ ГУБИТАКА СНАГЕ	109
<u>11. ЗАКЉУЧАК.....</u>	<u>114</u>
<u>ЛИТЕРАТУРА.....</u>	<u>116</u>
<u>ПРИЛОЗИ</u>	<u>123</u>
Прилог 1 – Нумеричке вредности уз поглавље 10.....	123
Нивелисање напонских нивоа	123
Смањење губитака снаге	123

Листа слика

Сл.1 – Традиционални електроенергетски систем	5
Сл.2 – Модерни електроенергетски систем.....	6
Сл. 3 – Промене а) Брзина ветра; б) Соларна ирадијација.....	8
Сл.4 – Принцип функционисања анализираног система	11
Сл.5 – Модел преносне мреже Србије	11
Сл.6 – Архитектура дубоког учења	12
Сл.7 – Класификација метода машинског учења	14
Сл.8 – Надгледано машинско учење.....	14
Сл.9 – Ненадгледано машинско учење.....	15
Сл.10 – Типови поткрепљеног машинског учења	16
Сл.11–Структура перцептрона.....	19
Сл.12– Тежња утицаја тежине/bias-а на излаз.....	20
Сл.13 – Поређење степ (а) и сигмоидне (б) функције	21
Сл.14 – Пример ANN-а са 2 скривена слоја	22
Сл.15 – Архитектура конволуционе неруалне мреже.....	22
Сл.16 – Процес обучавања ANN модела	24
Сл.17 – Алгоритам обучавања ANN-а	25
Сл.18 – ANFIS модел: спој ANN-а и фази логике	30
Сл.19 – Архитектура ANFIS-а	31
Сл.20 – Криве функција припадности.....	32
Сл.21 – Предности примене ANFISмодела.....	35
Сл.22 – ARIMA алгоритам	42
Сл.23 – Ограниченја ARIMA модела.....	46
Сл.24 – Математички модел ANN-а за предвиђање потрошње	49
Сл.25 – Алгоритам учења ANN модела.	51
Сл.26 – Промена средње квадратне грешке током тренирања ANN модела	52
Сл.27 – Промена градијента, параметра μ и броја неуспешних валидација током тренирања ANN модела.....	53
Сл.28 – Регресиона анализа ANN модела на тренинг, валидационом, тест и целокупном скупу података	54
Сл.29 – Годишња предикција потрошње из ANN модела	55
Сл.30 – Предикција дневне потрошње.....	56
Сл.31 – Тродимензионална зависност производње из термоелектрана од потрошње и (а) – температуре; (б) – ветра.....	58
Сл.32 – Тродимензионална зависност производње из хидроелектране од потрошње и (а) – температуре; (б) – ветра.....	58
Сл.33 – Структура ANFIS модела	60
Сл.34 – Предикција производње термоелектрана за а) Зиму; б) Пролеће; в) Лето; г) Јесен	61

Сл.35 – Предикција производње хидроелектрана за а) Зиму; б) Пролеће; в) Лето; г) Јесен	61
Сл.36 – Емисија CO ₂ по изворима у Србији	62
Сл.37 – Годишња предикција емисије CO ₂	63
Сл.38 – Промена средње квадратне грешке током тренирања ANN модела	63
Сл.39 – Промена градијента, параметра μ и броја неуспешних валидација током тренирања ANN модела.....	64
Сл.40 – Регресиона анализа ANN модела на тренинг, валидационом, тест и укупном скупу података.....	65
Сл.41 – Алгоритам прорачуна и предикције ANN моделом	71
Сл.42 – Математички модел ANN мреже у прорачуну.....	72
Сл.43 – Модел надземног вода.....	73
Сл.44 – Одступање реактансе услед амбијенталних услова.....	75
Сл.45 – Одступање резистансе услед амбијенталних услова	75
Сл.46 – Варирање сунчевог зрачења током месеца	76
Сл.47 – Производња енергијесоларних панела током недеље.....	76
Сл.48 – Потрошња домаћинства током недеље.....	77
Сл.49 – Анализирана дистрибутивна мрежа у Банату.....	78
Сл.50 – Губици активне снаге у мрежи за различите условеза један сат	79
Сл.51 – Предвиђање амплитуде напона	80
Сл.52 – Предвиђање фазног става напона	81
Сл.53 – Предвиђање губитака активне снаге за месец дана	81
Сл.54 – Предвиђање губитака активне снаге за један дан	82
Сл.55 – Промена а) Брзине ветра; б) Соларне ирадијације.....	86
Сл.56 – За недељу дана: а) Производња из обновљивих извора; б) Потрошња домаћинства	86
Сл.57 – Принцип ПЕМ електролизе.....	88
Сл.58 – Модел система	89
Сл.59 – Стање система у току недеље.....	96
Сл.60 – Активација различитих врста складиштења у току недеље.....	96
Сл.61 – Снага за недељу дана	97
Сл.62 – SOC батерија и ЕВ.....	97
Сл.63 – Преносна мрежа Републике Србије	100
Сл.64 – Развијени алгоритам проачуна.....	101
Сл.65 – Амбијенталне зоне Србије.....	104
Сл.66 – Промена губитака снаге услед амбијенталних услова.....	105
Сл.67 – Напонски нивои преносне мреже пре и после активације микромреже.....	106
Сл.68 – Распоред активирања складишта	107
Сл.69 – Активација складишта и размена енергије	107
Сл.70 – Реактивна снага унутар микромреже	108
Сл.71 – Ток активне и реактивне снаге	108
Сл.72 – Размењена енергије у систему	109
Сл.73 – Губици активне снаге пре и после активације микромреже	110
Сл.74 – Напони преносне мреже при смањењу губитака снаге	110

Сл.75 – Губици реактивне снаге пре и после активације микромреже.....	111
Сл.76 – Распоред активирања складишта.....	111
Сл.77 – Активација складишта и размена енергије.....	112
Сл.78 – Реактивна снага унутар микромреже.....	112
Сл.79 – Ток активне и реактивне снаге.....	113
Сл.80 – Укупна размењена енергија.....	113

Листа табела

Таб. 1 – Преглед технологија складиштења енергије	9
Таб. 2 – Поређење терминологије ANN и биолошких неуралним мрежама	18
Таб. 3 – Вредности прорачунатих грешака	28
Таб. 4 – Поређење фаза обучавања ANFIS модела и примењених метода оптимизације	34
Таб. 5 – Основна правила за избор ARIMA модела:	44
Таб. 6 – Параметри тренираног ANN модела	54
Таб. 7 – Грешке предикције ANN модела	55
Таб. 8 – Предикције ANN модела за један дан у зимској сезони.....	56
Таб. 9 – Поређење грешака предикције за ANN и ARIMA моделе.....	57
Таб. 10 – Улазни и излазни подаци ANFIS модела.....	59
Таб. 11 – Сезонске вредности MAPE за производњу из хидро- и термоелектрана	60
Таб. 12 – Параметри тренираног ANN модела	65
Таб. 13 – Грешка MAPE за годишњу предикцију емисије CO ₂ употребом различитих база података.....	66
Таб. 14 – Улазни подаци за анализу.....	77
Таб. 15 – Параметри тренираног ANN модела	79
Таб. 16 – Вредности MAPE за анализиране сценарије.....	79
Таб. 17 – Грешке предвиђања за анализиране параметре	80
Таб. 18 – Нумеричке вредности предвиђања за 24 сата	82
Таб. 19 – Преглед технологија различитих врста електролизе	87
Таб. 20 – Стање система током недеље	95
Таб. 21 – Чворови преносне мреже	103
Таб. 22 – Чворови преносне мреже груписани по зонама амбијенталних услова	104

1. Увод

Савремени електроенергетски системи (ЕЕС) пролазе кроз значајне трансформације услед све веће интеграције обновљивих извора, купаца–произвођача, као и система за складиштење енергије. Њихова комплексност расте и полако прелазе са стандардног централизованог функционисања на децентрализован. Као последица растуће комплексности модерних електроенергетских мрежа, значајно је закомпликована организација и планирање система. Предикција стања електроенергетског система је на комплекснијем нивоу. Овај процес, иако доноси бројне еколошке и енергетске користи, истовремено повећава комплексност система и захтева развој напредних метода за анализу, управљање и планирање рада ресурса.

Класична предикција стања електроенергетског система се ради већ годинама како би систем функционисао ефикасно и поуздано. Постоји константна потреба да се балансира потрошња и производња електричне енергије и овај процес захтева константо решавање математички захтевних, нелинеарних оптимизационих проблема на дневном, сатном, чак и минутном нивоу [1]. Планирање рада електроенергетског система се традиционално састоји од предвиђања потрошње, производње, и ефикасног и сигурног преноса и дистрибуције електричне енергије. Резултати индивидуалних фаза планирања морају да буду координисани тако да обезбеде сигурну и ефикасну дистрибуцију енергије [2].

Са растућим трошковима фосилних горива и еколошким проблемима повезаним са традиционалним изворима енергије, интеграција обновљивих извора енергије појавила се као одрживо решење за задовољавање потражње за електричном енергијом, уз истовремено побољшање еколошке ситуације. Међутим, укључивање обновљивих извора у ЕЕС уноси одређене изазове. Једна од карактеристика обновљивих извора је њихова интермитентна производња. Количина енергије коју генеришу ветроелектране зависи од услова околине и брзине ветра, који су по својој природи непредвидиви. Слично томе, енергија коју производе соларни панели зависи од доступности употребљивих светлосних зрака, на које утичу фактори као што су доба дана, облачност и положај панела. Пошто се ова врста производње не може лако предвидети или јој се приступити по потреби, балансирање таквог електроенергетског система постаје сложено. Традиционално, ЕЕС је балансиран на основу принципа да ће се производња ускладити са захтевима потрошње. Међутим, овај приступ је теже одржати када извор енергије не може да обезбеди енергију по потреби.

У класичним системима, стање система је предвиђано у једноставнијим околностима јер је централизована производња допремала енергију захтевану од стране потрошача. Уз развој система и технологије, последњих година је организација ЕЕС–а значајно закомпликована. Влада често подстиче имплементацију обновљивих извора енергије како би се постигао циљ нето нулте стопе емисије гасова стаклене башта до 2050. [3], [4]. Обновљиви извори енергије су у значајној експанзији приказујући раст од 17% у периоду од 2021. године, док су се енергија ветра и солара удвостручиле између 2019. и 2024. године [5]. У процесу интеграције обновљивих извора у постојеће традиционалне системе постоје одређени изазови. Често су они разлог ремећења баланса између потрошње и производње који је неопходан за стабилно функционисање система услед интермитентности самих извора из којих се добија обновљива енергије [6]. Купци–произвођачи, индивидуално анализирани у многим радовима [7], [8] имају двоструку улогу у систему, али имају ограничену применљивост у планирању система услед тешке предвидивости њихових карактеристика. Додатно повећање комплексности узрокују системи за складиштење електричне енергије различитих капацитета [9], [10]. Иако су ови

елементи кључни за адекватно функционисање модерних електроенергетских система, значајно компликују његов рад тиме отежавајући планирање рада система експертима који се њима баве.

Са развојем нових елемената у електроенергетским системима паралелно се развијају и методе рачунарске технике. Ове методе су засноване на обради великих количина података, што омогућава све прецизнију анализу и управљање сложеним системима. У енергетици је доступна значајна количина реалних података добијених из мерења и оперативног надзора, па се њиховом обрадом могу добити модели који у великој мери олакшавају рад стручњацима у електроенергетским системима. Управо из тог разлога, применом савремених метода вештачке интелигенције могуће је развити предиктивне моделе који доприносе ефикаснијем планирању и управљању енергетским ресурсима.

Електроенергетски системи постоје довољно дуго да организације које се баве њиховим надзором имају податке мерења потрошње, производње и услова који на њих утичу. Употребом ових података предиктивни модели базирани на вештачкој интелигенцији могу предвидети будућу потрошњу и производњу енергије на основу претходних искустава. Машинско учење (МУ) се неретко користи како би се овакве информације искористиле у решавању проблема растуће комплексности ЕЕС–а услед учешћа интермитентних обновљивих извора енергије [11]–[13]. У прорачунима где доношење оптималне одлуке зависи од захтева потрошача у непредвидивим временским условима, МУ је корисна метода [14].

Ако се користе претходна искуства стручњака, историја рада електроенергетског система и велики број доступних мерења из прошлости, МУ и вештачка интелигенција (ВИ) су одличне методе за њихово максимално искоришћавање. Из њих би се могла направити будућа предвиђања која би омогућила инжењерима и оператерима електроенергетског система да доносе одлуке засноване на подацима одлуке и оптимизују перформансе система.

До сада је одлука о томе који ће извори енергије бити активни у одређеним временским периодима, ради безбедне и поуздане испоруке електричне енергије потрошачима, била у потпуности у надлежности људског фактора. Искусно диспечерско особље је, на основу стеченог знања и праксе, доносило кључне одлуке у управљању и организацији електроенергетског система.

Како ЕЕС постоје већ деценијама, доступни су обимни скупови података који документују њихов рад и динамику функционисања. Ти подаци представљају резултат различитих оперативних ситуација које су обликовале искуство диспечера.

У оквиру овог рада, управо су ти историјски подаци искоришћени за развој модела који преузимају улогу у процесу доношења одлука одређујући који ће се извори енергије користити у појединим временским интервалима. Даљим унапређењем ових модела, кроз континуално увођење савремених и актуелних података, могуће је значајно смањити грешке у предвиђању и повећати поузданост система.

Постоје различите врсте метода вештачке интелигенције које се примењују у зависности од природе проблема. За одређене задатке, као што су предвиђање потрошње, производње или стања система, постоје преференсе по питању адекватности одређених техника наспрам других. Због тога је у овом раду анализирано више различитих метода ВИ на различитим типовима проблема како би се утврдило које од њих најбоље одговарају специфичним условима и потребама појединих проблема електроенергетских система.

У поглављу 2 приказане су основне карактеристике електроенергетских система и изазови који настају услед интеграције обновљивих извора енергије. У поглављу 3 разматрана је примена метода машинског учења у анализи и предикцији рада електроенергетских система. У поглављу 4 дат је приказ примене вештачких неуралних мрежа (*Artificial Neural Networks – ANN*) за предикцију потрошње и стања система. У поглављу 5 анализирана је примена ANFIS (*Adaptive Neuro-Fuzzy Inference System - ANFIS*) методологије за предикцију производње и емисије CO₂. У поглављу **Error! Reference source not found.** приказана је примена ARIMA (*Autoregressive Integrated Moving Average – ARIMA*) модела као референтне статистичке методе за поређење са методама вештачке интелигенције.

У поглављу 7 развијен је модел предикције употребом ANN методологије који је трениран на мерним подацима из електроенергетског система Србије. Узети су у обзир утицаји амбијенталних и временских услова који би се у класичном приступу занемаривали ради поједностављења прорачуна и његовог убрзавања. Овај модел упоређен је са ANFIS методологијом и класичном предиктивном методом ARIMA. Установиле су се значаје предности ANN методологије и у даљем раду је фокус на овом сегменту вештачке интелигенције. Из тог разлога се даље приступило употреби ANN методологије у развоју алгорита који дефинише стање система уз уважавање параметара који се у класичном прорачуну токова снага занемарују. Овај алгоритам је приказан у поглављу 8 где се, на делу дистрибутивне мреже у Банату, где је алгоритам тестиран на мерним подацима са посматране територије. Овде су уважени утицаји амбијенталних и временских услова на сегменте мреже као што су утицај на сам надземни вод, производњу и потрошњу у систему.

Један од главних циљева овог истраживања је развој методологија применљивих у новим технологијама које постају све заступљеније у оквиру класичних електроенергетских система. У поглављу 9 анализирана је изолована микромрежа која се састоји искључиво од обновљивих извора енергије, купаца-произвођача и различитих типова складишта енергије. На овом примеру изолованог система развијен је принцип управљања који омогућава самоодржив рад система, уз укључивање складишта енергије и купаца-произвођача у одговарајућим временским периодима ради балансирања система.

У поглављу 10 приказано је сједињавање анализираних методологија. Анализирано је понашање система који као свој сегмент има дефинисану микромрежу са својом развијеном контролом. Ова мрежа је повезана на преносну мрежу Републике Србије. При анализи уважила се промена стања система и елемената система са амбијенталним и временским условима. Исход овог прорачуна је оптимална активација складишта унутар микромреже како би се смањили губици снаге или побољшали напонски нивои унутар преносне мреже.

2. Електроенергетски систем са новим технологијама и изазовима

У последњих неколико деценија ЕЕС пролази кроз значајну трансформацију своје целокупне структуре. Уводе се нови елементи, а дугогодишња пракса на коју су и корисници и оператори навикли постепено еволуира. Традиционални систем је био централизован. Био је заснован на великим производним јединицама које једносмерно снабдевају потрошаче. Циљ је био колико праволинијски и једноставан за разумевање, толико екстремно захтеван за извршење. Циљ је обезбеђивање поузданог и ефикасног снабдевања електричном енергијом у складу са потражњом [15].

Како време пролази, овај систем се мења. Централизовани систем постаје децентрализован, добија одређени степен динамичности и токови енергије постају вишесмерни. У систем се уноси комплексност и варијабилност која до пре неколико година није постојала. Појављују се мањи произвођаји, складишта електричне енергије, електрична возила, долази до формирање микромрежа.

Велики утицај на промене које у систему настају има политика декарбонизације. На глобалном нивоу се тежи очувању климатске стабилности и смањењу емисије штетних гасова. Ово су разлози због којих долази до експанзије обновљивих извора. Њих прати потреба за складиштима електричне енергије и напредних система управљања. Систем је преплављен елементима новонасталих технологија, од извора енергије до складишта, која треба да одрже баланс рада апсорпцијом вишкова произведене енергије и снабдевањем у тренуцима њеног недостатка. [6]

Формирају се нове категорије учесника у систему, попут купаца–произвођача (*prosumers*), а у дистрибутивним мрежама почињу да се јављају микромреже које могу да раде полу–аутономно или потпуно самостално. Ово уноси нову димензију у планирање и управљање, посебно зато што многи од ових извора раде стохастички.

Систем више не функционише по принципу да потрошач једноставно затражи енергију, а велике електране се укључују да би задовољиле потребе. Обновљиви извори не могу да се активирају на захтев. Њихова производња зависи од доступности сунца, ветра и других ресурса, што значи да се енергија производи онда када одговара условима у природи, а не у тренуцима када постоји потражња за енергијом [11].

Када обновљиви извори имају вишак производње, та енергија мора негде да се складишти. Циљ је да се употреби у каснијим моментима пораста потрошње. Стога улогу балансирања рада система пружају новонастале различите врсте складишта електричне енергије.

Потрошачи више нису само пасивни корисници. Многи од њих постају активни учесници, производе сопствену енергију кроз соларне панеле и продају вишкове назад у мрежу. Ово у великој мери мења токове енергије што чини мрежу много сложенијом за управљање. [7]

Као последица ових промена, појављују се делови система који могу да функционишу потпуно независно од државног електроенергетског система. То су изоловане или полу–изоловане микромреже са сопственом производњом, сопственом потрошњом и складиштима. Оне могу да буду интегрисане у велики систем или да раде одвојено, у зависности од потреба и инфраструктуре.

Уколико је микромрежа повезана на већи систем, она мора да испуњава све техничке услове за стабилан напон, фреквенцију и квалитет напајања. Уколико је независна, та обавеза не постоји. Онда целокупна одговорност за поузданост и сигурност напајања остаје на унутрашњим ресурсима саме микромреже [16].

Сам принцип функционисања традиционалних ЕЕС–а подразумева да су они изузетно спори при потреби за променом стања и релативно предвидиви у нормалним радним режимима. Насупрот њима, померањем од традиционалног функционисања долази до пораста варијабилности, потребе за аутоматизацијом и интермитентношћу енергетских извора. Са овим карактеристикама долази до израженијих осцилација и већих захтева за секундарним и терцијарним резервама снаге.

2.1. Од линеарног ка комплексном, би–дирекционом систему

Традиционални енергетски систем има праволинијски и јасан ланац функционисања. Енергију производе велике електране. Преносном и дистрибутивном мрежом она иде ка потрошачима, као што је приказано на Сл.1.



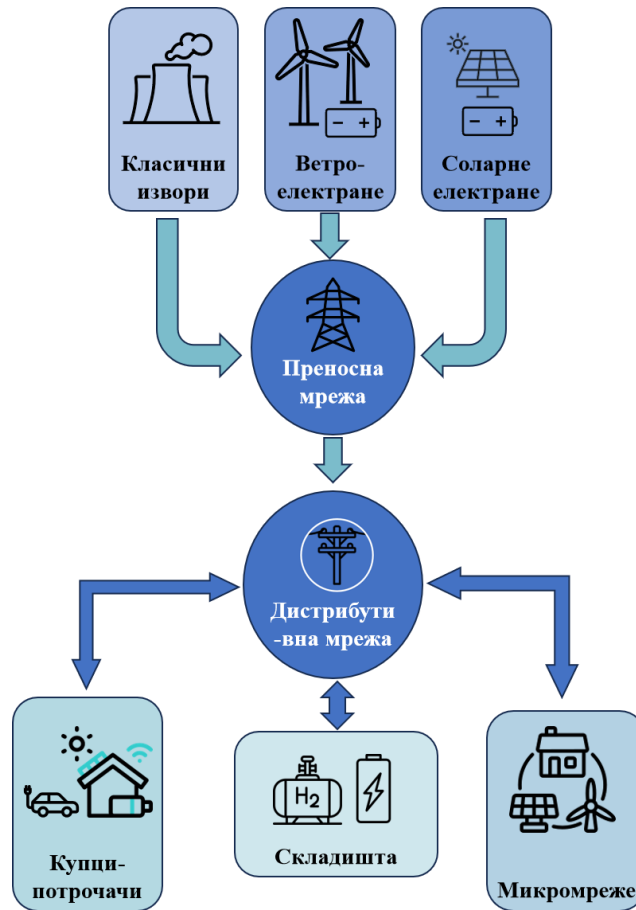
Сл.1 – Традиционални електроенергетски систем

Модерни системи функционишу на далеко комплекснији начин. За разлику од традиционалних система, одликују се следећим додатним особинама:

- вишеслојношћу,
- зависношћу од климатских услова,
- минутном и сатном варијабилношћу,
- великим бројем непредвидивих малих извора енергије.

Услед ових особина системи губе на предвидивости, стабилности и могућности примене класичних метода планирања и управљања. Више није могуће одржавати баланс система применом класичних приступа јер систем више није класичан. Ови приступи претпостављају релативно споре динамичке промене и добру предвидивост оптерећења. Модерни системи имају сложена нелинеарна понашања, високу стохастичност и честе промене смера токова снаге услед

рада дистрибуираних извора енергије, микромрежа и купаца–произвођача. Управо зато новија истраживања указују да је неопходно усвајање напредних метода МУ и физички информисаних модела који могу да обраде велике количине података и ефикасно моделују комплексну динамику савремених дистрибутивних мрежа [3]. Приказ структуре савременог електроенергетског система дат је на Сл.2.



Сл.2 – Модерни електроенергетски систем

2.2. Интермитентност обновљивих извора енергије


Са све већим трошковима фосилних горива и еколошким проблемима [17] повезаним са традиционалним изворима енергије, многе земље су се окренуле ка производњи обновљиве енергије. Владе често подстичу коришћење обновљивих извора енергије како би се постигли циљеви нето–нулте емисије до 2050. године [3], [15]. Међутим, укључивање обновљивих извора у ЕЕС доноси одређене изазове. Услед интермитентности и неизвесности обновљивих извора енергије долази до дисбаланса између производње и потрошње[6]. Количина енергије коју производе ветропаркови директно зависи од амбијенталних услова и брзине ветра, који су по својој природи непредвидиви. Слично томе, енергија коју производе соларни панели зависи од доступности употребљивих светлосних зрака, на које утичу фактори као што су доба дана, облачност и положај панела. Како се ова врста производње не може лако предвидети или користити на захтев, балансирање таквог електроенергетског система постаје сложено.

Традиционално, ЕЕС је био балансиран на основу принципа да производња прати потрошачке потребе. Међутим, овај приступ је теже одржати када извор енергије не може да обезбеди енергију на захтев.


Због еколошких изазова и све већих цена фосилних горива, обновљиви извори представљају адекватно решење за енергетску кризу. Поред тога, последњих година постали су економски исплативији, а многе земље пружају финансијске подстицаје за њихов развој како би се суочиле са глобалним еколошким проблемима.

Међутим, интермитентна природа производње обновљиве енергије представља велики изазов за постојеће енергетске системе. Потрошачи можда неће добити енергију онда када им је потребна, јер она зависи од примарних извора као што су ветар и сунчева радијација.

Сл. 3 приказује промене брзине ветра и сунчевог зрачења измерене на подручју Србије, које директно утичу на количину енергије коју производе ветротурбине и соларни панели. Ове мерне вредности су коришћене у прорачуну у поглављу 9. На Сл. 3 приказује се варијације у производњи обновљиве енергије из соларних и ветроелектрана, као и потрошњи током недеље. Како се ова енергија производи у неконтролисаним тренуцима, често је није могуће одмах искористити или испоручити потрошачима.




a)




б)

Сл. 3 – Промене а) Брзина ветра; б) Соларна ирадијација



a)



б)

Сл. 4 – За недељу дана: а) Производња из соларних и ветроелектрана б) Потрошња домаћинства

2.3. Складишта електричне енергије

Складиштење енергије представља могуће решење проблема који настају усред одступања између произведене и захтеване енергије у одређеним временским периодима. Они омогућавају да се вишак енергије у мрежи акумулира и искористи у моментима када долази до недостатка. Истраживања показују да складишта електричне енергије постају неизоставни елемент модерних електроенергетских система [18][10].

У циљу складиштења електричне енергије, развијене су различите врсте технологија. Свака од њих имају одређене мане и предности везане за своје функционисање. Преглед ових складишта енергија и њихових особина је дат у Таб.1. На пример, системи складиштења енергије у замајцима (*Flywheel Energy Storage – FES*) и суперпроводним магнетним системима (*Superconducting magnetic energy storage – SMES*) имају изузетно брзо време одзива у опсегу од неколико милсекунди и дуг животни век са великим бројем циклуса пуњења и прањења. Међутим, њихова цена по јединици складиштене енергије је висока, због чега су најисплативији за мање количине енергије [19][20].

2.5. Микромреже и локална флексибилност

Микромрежа је децентрализован и груписан енергетски систем који интегрише дистрибуиране изворе енергије (*Distributed Energy Sources – DER*), потрошаче и складишта на локалном нивоу, контролисан као јединствена целина [22]. То је ЕЕС са јасно дефинисаним границама, који садржи дистрибуиране ресурсе, производњу, складишта и контролисане потрошаче и који може да ради повезан на електроенергетску мрежу или у изолованом режиму [23][24].

Микромреже омогућавају:

- Локалну оптимизацију рада
- Енергетску аутономију
- Бољу отпорност на ванредна стања
- Лакше управљање обновљивим изворима

2.6. Анализа система

У поглављу 7 врши се предикција ангажованих енергетских извора на ЕЕС–у Србије. Употребом развијеног ANN модела долази се до сатне предикције производње из различитих врста извора који треба да буду ангажовани, као и потрошње. Ради се предикција функционисања једног државног система. На Сл.4. приказан је модеран електроенергетски систем подељен на нивое који одговарају различитим фазама прорачуна. На овом нивоу приказани су улазни подаци за модел, односно снаге производње из хидро и термо извора ($P_{\text{хидро}}$ и $P_{\text{термо}}$), као и потрошња електричне енергије ($P_{\text{потрошња}}$).


Сл.5 приказује преносни систем Републике Србије који ће бити анализиран у финалном прорачуну овог рада. На основу извршене предикције у поглављу 7 распоређује се ангажовање производње активацијама појединих електрана анализираних мреже преносног система Србије приказаних на Сл.5. Ови подаци се враћају и у преносној мрежи се распоређују вредности производње на чворове 1, 2, 3, 5, 6 и 28.

У поглављу 8 обрађен је прорачун токова снага уз уважавање зависности мреже од амбијенталних услова. Алгоритам који се развио у овом поглављу примењује се на прорачуну за приказану преносну мрежу са условима потрошње и производње дефинисаним из прорачуна у поглављу 7. Овај алгоритам је обележен на Сл.4 као ниво 2. Излаз нивоа 2 су губици активне и реактивне снаге као и напонски нивои чворова.


На основу прорачунатих снага се дефинише дисбаланс између потрошње и производње. Уколико је у систему збир губитака у мрежи и потрошње већи од произведене енергије, неопходно је ињектирати додатну енергију у систем. Уколико је збир мањи, постоји вишак произведене енергије и она би требала негде да се складиши.

Идеја је да овај дисбаланс нивелише микромрежа развијена у поглављу 9. Алгоритам који прорачунава стање у ЕЕС–у Србије такође као излаз предлаже најподобније место за прикључење микромреже како би се дошло до побољшаног стања читавог система. До микромреже која је повезана на преносни систем долази информација о томе колика је захтевана снага која треба од ње да се добије или у њој да се складишти, ниво 3. Сходно томе се у микромрежи активирају складишта енергије како би испунили овај захтев. Крајњи резултат

прорачуна је двадесетчасовна активација рада микромреже на сатном нивоу, као и вредности напона и губитака у приказаном систему.



Сл.4 – Принцип функционисања анализираниог система



Сл.5 – Модел преносне мреже Србије

3. Машинско учење

Машинско учење (*Machine Learning – ML*) представља дисциплину у оквиру вештачке интелигенције која се бави развојем алгоритама и модела способних да из података уче, препознају обрасце и доносе одлуке без експлицитног програмирања, Сл.6. Основна идеја је да се кроз анализу историјских података развије модел који је у стању да генерализује научено за нове, невиђене примере. Овим се омогућава адаптивно и интелигентно понашање рачунарских система у реалним окружењима.



Сл.6 – Архитектура дубоког учења

Суштина МУ је способност препознавања шаблона, доношења предикција, и скупљању информација из велике количине података. Употребљава статистичке технике и снагу модерних компјутера како би нашао корелације које за људско око нису једноставно уочљиве. МУ постаје интегрисано у енергетику јер га дефинишу способност схватања комплексних система и великог броја мерних података који су одраз електроенергетских система. Како се у традиционалним мрежама имплементирају обновљиви извори енергије, долази до честих флукуација у потражњи, при чему расте и сложеност обраде података и надгледања система. МУ у овом случају нуди своје предности које се свде на напредне аналитичке способности које могу оптимизовати рад оператора система, предикције потенцијалних кварова чиме би се повећала ефикасност рада.

Постоји више разлога услед којих су методе вештачке интелигенције примењиве за електроенергетске системе [25]:

1. Доступност података – модерни ЕЕС генерише велике количине података. Уз пораст дигитализације и повећан број мерених вредности (ПМУ мерења), као и управљачки уређаји, долази се до веће количине података који показују стање мреже. У комбинацији са лакшим складиштењем ових података доводи до веће доступности истих.
2. Рачунарска снага – јаки процесори и могућност да се удаљене машине међусобно конектују ради брзе размене података. Све мањи трошкови рачунарске снаге доприносе

широкој доступности инфраструктуре потребне за тренирање алгоритама, развој нових модела ВИ као и обраду комплексних задатака.

3. Иновације у алгоритмима – нове технике МУ, као што је дубоко учење које је примењено у вештачким неуралним мрежама са више слојева. Ове технике су постале основа многих савремених приступа у различитим областима енергетике (планирање система, анализа стања, оптимизација токова снага).

3.1. Типови машинског учења

Дубоко структурирно/хијерархиско учење (*Deep Learning – DL*) представља подкуп МУ који се ослања на вишеслојне неуралне мреже у циљу моделовања сложених и високо нелинеарних односа у подацима. Оно омогућава аутоматско издвајање карактеристика из великих количина сирових података, без потребе за ручним дефинисањем карактеристика. Дубоке мреже, попут конволутивних и рекурентних, показале су изузетну ефикасност у задацима као што су препознавање слике, разумевање природног језика, синтеза говора и предвиђање временских серија. Захваљујући својој способности да уче хијерархијски, дубоко учење је постало основа модерних система ВИ [26].

Различите технике МУ омогућавају решавање широког спектра проблема: класификације и регресије, препознавања објеката, разумевања природног језика и доношења одлука у реалном времену. Методе МУ се генерално класификују у неколико основних скупова, зависно од природе података и начина учења, Сл.7. [27]

Основни типови МУ:


- 1) Надгледано МУ (*Supervised Machine Learning*)
- 2) Ненадгледано МУ (*Unsupervised Machine Learning*)
- 3) Подстакнуто (појачано) МУ (*Reinforcement Machine Learning*)
- 4) Самонадгледано МУ (*Self-Supervised Machine Learning*)
- 5) Хибридни приступи (*Hybrid Machine Learning*).



Сл.7 – Класификација метода машинског учења

3.1.1. Надгледано машинско учење

У надгледаном машинском учењу модел добија скуп улазно–излазних парова података, где сваки улаз има ознаку или тачно дефинисану вредност, Сл.8. Циљ модела је да научи функцију која што прецизније повезује улазне и излазне податке. Циљ је да за нове, невиђене улазе може да предвиди исправан излаз. Обука се врши кроз процес минимизације функције губитка која мери разлику између предвиђеног и стварног излаза.



Сл.8 – Надгледано машинско учење

Надгледано учење се примењује у великом броју задатака, као што су:


- Класификација: препознавање категорија (нпр. класификација електричне опреме по стању – исправна/оштећена),
- Регресија: континуална прогноза (нпр. предвиђање оптерећења електроенергетске мреже на основу временских услова).

Алгоритми који се користе укључују логистичку регресију, подржавајуће векторске машине (*SVM*), вештачке неуралне мреже и ансамбл методе (нпр. *Random Forest*).

3.1.2. Ненадгледано машинско учење

Ненадгледано машинско учење подразумева рад са подацима који нису означени, односно немају сопствене излазне вредности, Сл.9. Алгоритам анализира структуру и расподелу улазних података како би открио латентне обрасце, групе, корелације или унутрашње структуре.

Ненадгледано учење



Сл.9 – Ненадгледано машинско учење

Најчешће технике укључују:

- Кластеровање: груписање сличних примера без претходне категоризације (нпр. идентификација типова потрошача у енергетској мрежи),
- Редукцију димензионалности: смањење броја улазних промењивих уз очување битних информација.

Овај приступ је користан у ситуацијама где је сврставање података скупо или непрактично, а такође служи и као припремна фаза за надгледано учење или визуелизацију вишедимензионих података.

3.1.3. Подстакнуто машинско учење

У подстакнутом машинском учењу, Сл.10, модел делује у неком окружењу и учи путем повратних информација у облику награда или казни. За разлику од надгледаног учења, овде не постоји експлицитна ознака за сваки улаз. Модел доноси одлуке (акције), прима повратну информацију и на основу ње ажурира свој принцип одлучивања у циљу максимизовања укупног квалитета предикције током времена.



Сл.10 – Типови поткрепљеног машинског учења

Принципи подстакнутог учења:

1. Награда – представља основни механизам за усмеравање понашања модела. Она служи као повратна информација која указује на пожељност извршене акције. Награде су скаларне вредности које могу бити позитивне, негативне или неутралне. Основни циљ модела је да максимизује збир свих награда кроз време, односно да усвоји стратегију деловања која доноси највећи укупан добитак.
2. Казна – користи се у ситуацијама када модел изврши непожељне радње. Улога казне је да одврати модел од неадекватног понашања. У методологији подстакнутог учења, казне служе за обликовање понашања, коригујући лоше одлуке и усмеравајући модел ка бољим изборима у будућности.
3. Кумулативна награда – представља укупну суму свих награда које модел добија током једне или више епизода учења. Позната је и под називом „поврат“ (*return*) и служи као основни критеријум за евалуацију стратегије коју модел усваја. Алгоритми подстакнутог учења теже принципу који ће максимизовати ову вредност, узимајући у обзир и тренутне и дугорочне ефекте одлука.
4. Непосредна награда – она која се добија одмах након извршења одређене радње. Обезбеђује брзу и јасну повратну информацију. Ово моделу омогућава ефикасније усмеравање у процесу доношења одлука. Ова врста награде је посебно корисна у ситуацијама где постоји директна и очигледна повезаност између акције и резултата.
5. Одгођена награда – јавља се тек након више узастопних акција или у каснијим фазама учења. У таквим ситуацијама, модел мора да научи да повезује радње које су претходиле са касније добијеном наградом. Ово представља један од кључних изазова у подстакнутом учењу, јер захтева дугорочно планирање и способност моделовања узрочнопоследичних односа.
6. Ретка награда – настаје у окружењима у којима се повратне информације пружају само у специфичним или ограниченим ситуацијама, као што је достигнуће одређеног циља.

Овакви услови отежавају процес учења јер модел мора да истражи велики број стања пре него што добије било какву награду, што чини оптимизацију политике изузетно комплексном.

7. Обликујућа награда – представља додатне, често вештачки конструисане награде које се користе ради убрзавања процеса учења. Њихова сврха је да моделу обезбеде интермедијарну повратну информацију током постизања коначног циља, чиме се стимулише жељено понашање и скраћује време потребно за конвергенцију стратегије.

Алгоритми као што су *Q-learning*, *Deep Q Networks (DQN)* и *Policy Gradient* користе се за решавање проблема оптималне одлуке у стохастичким окружењима.

3.1.4. Самонадгледано машинско учење

Самонадгледано машинско учење представља хибридни приступ у којем модел учи из необележених података стварањем интерних задатака који симулирају надгледано учење. На тај начин модел може учити из великих количина података без ручне класификације.

Овај приступ је постао кључан у изградњи великих језичких модела (нпр. *GPT*, *BERT*), визуелних репрезентација, као и у применама где је означене податке тешко или скупо добити. Самонадгледано учење доприноси бољој генерализацији и ефикаснијој употреби ресурса.

3.1.5. Хибридно машинско учење

Хибридно учење комбинује више типова учења у јединствену архитектуру или процес обуке, како би се искористиле предности сваког појединачног приступа. На пример, могуће је применити ненадгледано учење за иницијалну екстракцију особина из података, затим применити надгледано учење за класификацију, а подстакнуто учење за адаптацију на промењиво окружење.

Хибридни модели се користе у комплексним системима као што су:

- Аутономна возила (обрада слике + доношење одлука),
- Интелигентне енергетске мреже (кластеровање потрошача + оптимизација рада),
- Дијагностика и медицински системи.

Постоји више разлога услед којих су методе вештачке интелигенције примењиве за електроенергетске системе [25].

Модерни ЕЕС генерише велике количине података. Уз пораст дигитализације и повећан број мерених вредности (ПМУ мерења), као и управљачки ИЕД уређаји долази се до веће количине података који показују стање мреже. У комбинацији са лакшим складиштењем ових података доводи до веће доступности истих.

Јаки процесори и могућност да се удаљене машине међусобно конектују ради брзе размене података. Све мањи трошкови рачунарске снаге доприносе широкој доступности инфраструктуре потребне за тренирање алгоритама, развој нових модела ВИ као и обраду комплексних задатака.

Нове технике МУ, као што је дубоко учење које је примењено у вештачким неуралним мрежама са више слојева су постале основа многих савремених приступа у различитим областима енергетике (планирање система, анализа стања, оптимизација токова снага).

4. Вештачке неуралне мреже

Вештачке неуралне мреже (*Artificial Neural Networks – ANN*) представљају напредну класу алгоритама машинског учења, инспирисану архитектуром и механизмима функционисања људског мозга. Развијене су са циљем да имитирају процесе обраде информација карактеристичне за биолошке нервне системе, Таб.2. ANN су дизајниране да самостално уче на основу података, препознају обрасце и доносе закључке у ситуацијама где експлицитно дефинисање правила није практично или могуће.

Први концепти вештачких неурона настали су током педесетих година двадесетог века, али је значајан напредак у овој области омогућен тек са развијањем рачунарских ресурса и модерних алгоритама за оптимизацију процеса учења. Основни елемент ANN-а је вештачки неурон, који функционално опонаша биолошки неурон: улазне вредности (сигнали) пролазе кроз везе (синапсе) различите јачине (тежине), интегришу се и активирају излаз према дефинисаној функцији преноса.

Таб.2 – Поређење терминологије ANN-а и биолошких неуралним мрежама

Биолошки неурон	Вештачки неурон (ANN)
Неурон	Неурон
Синапса	Веза
Неуротрансмисија	Тежина везе (јачина конекције)
Фреквенција нервних импулса	Излаз неурона
Дендрити	Улазни подаци
Аксон	Излазни сигнал
Мембрански потенцијал	Активирана вредност
Потенцијал дејства	Активациона функција
Интеграција сигнала	Сабирач (агрегација улаза)
Синаптичка пластичност	Ажурирање тежина (тренинг)

Кључна предност ANN-а је њихова способност да моделују сложене нелинеарне односе у подацима без потребе за експлицитним програмирањем правила понашања. Ова особина је нарочито значајна у применама као што су препознавање образаца, класификација, регресија, као и предвиђање временских серија. У области енергетике, ANN налазе широку примену у предвиђању потрошње електричне енергије, дијагностици и предиктивном одржавању трансформатора и турбина, оптимизацији производње енергије из обновљивих извора, као и у системима управљања паметним мрежама (*smart grids*).

Ипак, примена ANN-а није без ограничења. Ефикасност њиховог учења зависи од доступности великих и репрезентативних скупова података, што у неким апликацијама може представљати значајан изазов. Скуп података треба да пружа корисне информације, а да су из њега елиминисане грешке, понављања и било које вредности које би могле збунити ANN. Поред тога, због природе њихове интерне обраде података, ANN се често карактеришу као црне кутије, модели чије је унутрашње функционисање тешко интуитивно разумети и објаснити. Ово, као њихова главна предност где не захтевају експлицитна упутства, може бити и мана јер оне не могу експлицитно ни показати до којих правила закључивања се дошло обрадом базе података, већ само дају излазне вредности, такође у форми скупа података. Ово потенцијално ограничава њихову примену у областима где је објашњивост модела критична.


Са развојем техника дубоког учења и интеграцијом ANN-а са другим интелигентним системима као што су фази логика и генетски алгоритми, дошло је до еволуције хибридних модела који додатно проширују њихове могућности. У контексту енергетике, ови хибридни приступи омогућавају прецизније прогнозе производње енергије из соларних и ветропаркова, као и флексибилније управљање оптерећењем у дистрибутивним мрежама.

Будућност развоја вештачких неуралних мрежа усмерена је на побољшање ефикасности процеса учења, обликовање адекватних база података, као и развој објашњивих модела који ће омогућити дубље разумевање механизма доношења одлука. У енергетском сектору, овакав развој ће играти кључну улогу у изградњи одрживијих, поузданијих и интелигентнијих енергетских система.

4.1. Архитектура ANN-а

Архитектура вештачке неуралне мреже дефинише начин на који су неурони повезани, као и начин на који се информације преносе и обрађују кроз мрежу. Од избора архитектуре зависи способност мреже да решава различите типове проблема, њена способност генерализације, као и ефикасност процеса учења.

Перцептрон, Сл.11, представља најранији модел вештачког неурона, развијен од стране Френка Розенבלата 1958. године. Једноструки перцептрон је мрежа која се састоји од улазног слоја и излазног неурона, способног да класификује улазне податке који су линеарно раздвојиви.




Сл.11–Структура перцептрона

Основна ограничења перцептронских модела односе се на њихову применљивост само на линеарно сепарабилне проблеме и употребу дискретне функције активације. Перцептрон користи дискретну функцију активације при чему је излаз дискретан. Може бити 0 или 1, или -1 или 1, у зависности од дефиниције. Пример уколико је излаз 0 или 1 је дат једначином 1.

$$\text{излаз} = \begin{cases} 0 & \text{ако } \sum_j \omega_j x_j \leq \text{граница} \\ 1 & \text{ако } \sum_j \omega_j x_j \geq \text{граница} \end{cases} \quad 1$$

Због дисконтинуалности ове функције, није могуће применити градијентне методе оптимизације, што значајно ограничава примену перцептрона у тренирању вишеслојних неуралних мрежа. Мале промене параметара не доводе нужно до постепених промена излаза, већ могу изазвати нагле промене, што додатно отежава процес оптимизације.

Суштински је потребан принцип где мала промена у параметрима мреже узрокује и мале промене у излазима као што је приказано на Сл.12.



Сл.12– Тежња утицаја тежине/bias-a на излаз

Како би се постигао жељени принцип, уведени су сигмоидни неурони. Они, за функцију активације, уместо одскочне функције користе глатке и континуалне функције попут сигмоидне функције, приказане једначином 2, или хиперболичке тангенсе функције.

$$\sigma(z) \equiv \frac{1}{1 + e^{-z}} \quad 2$$


Излаз сигмоидне функције је, преко улаза, тежина и *bias*, представљен у једначини 3.

$$\text{излаз} \equiv \frac{1}{1 + \exp(-\sum_j \omega_j x_j - b)} \quad 3$$


где су:

x_j – улазне вредности функције,
 ω_j – тежине одређених улазних вредности,
 b – *bias*.

За анализу је значајнији облик функције као глатке апроксимације одскочне функције, него њен тачан аналитички облик. Поређење одскочне функције и сигмоидне функције дато је на Сл.13.



а)



б)

Сл.13 – Поређење степ (а) и сигмоидне (б) функције

Када би уместо сигмоидне функције била степ функција, онда би излазне вредности биле 1 или 0, као код перцептрона. Ово значи да сигмоидни неурон употребом степ функције поприма понашање перцептрона.

Оваква функција омогућава да мале промене тежине параметра мреже, изазивају малу промену у излазу, једначина 4. Услед овога је омогућена примена алгоритама оптимизације базираних на градијентном спусту. На овај начин постаје могуће ефикасно и стабилно тренирање дубоких неуралних мрежа, уз прецизно праћење промене грешке у односу на промене у параметрима мреже.

$$\Delta \text{ излаз} \approx \sum_i \frac{\delta \text{ излаз}}{\delta \omega_i} \Delta \omega_i + \frac{\delta \text{ излаз}}{\delta b} \Delta b \quad 4$$

Иако је овај модел перцептрона био револуционаран за своје време, његова ограничења као што је немогућност решавања нелинеарно раздвојивих проблема, указала су на потребу за сложенијим архитектурама.

1. Мреже са једним скривеним слојем

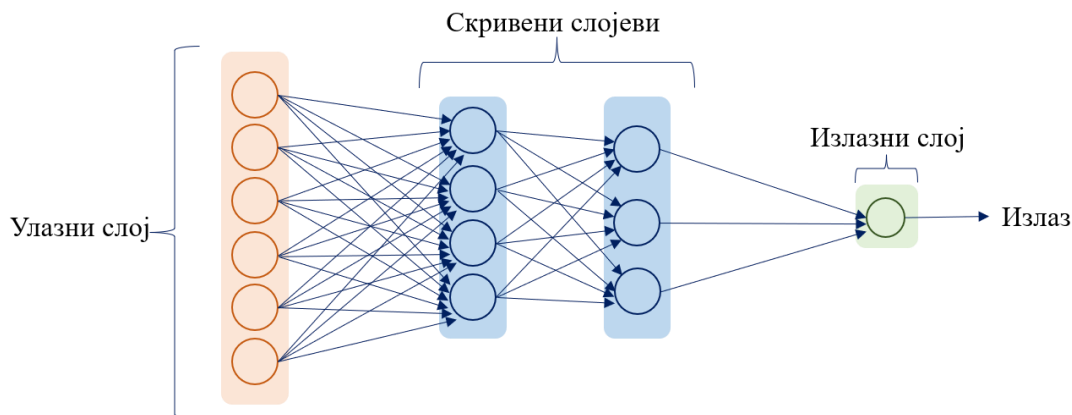
Мрежа са једним скривеним слојем је погодна за једноставније задатке као што су основна класификација и регресија. Међутим, за комплексније проблеме као што су препознавање образаца у временским серијама, обрада слике или предвиђање динамичких система у енергетици, један слој обично није довољан.

2. Вишеслојне неуралне мреже

Вишеслојне неуралне мреже, Сл.14, уводе најмање један скривени слој између улазног и излазног слоја, чиме се омогућава моделовање сложенијих нелинеарних функција. Скривени слојеви обрађују податке применом нелинеарних функција активације као што су ReLU (*Rectified Linear Unit*), сигмоидна или хиперболичка тангенс функција. Тренинг вишеслојних неуралних мрежа се врши методом пропације грешке уназад (*backpropagation*), у комбинацији са методама за израчунавање градијента као што је стохастички градијентни спуст (*SGD*).

Лево постављени слој у овој мрежи назива се улазни слој, а неурони у том слоју су улазни неурони. Излазни слој, десно, садржи излазне неуроне, у овом случају, један излазни неурон. Средишњи слој назива се скривени слој. Неурони у овом слоју нису ни улазни ни излазни. Скривени слој заправо значи једноставно да није улазни ни излазни. Постоје мреже са више скривених слојева. У пракси, избор броја скривених слојева зависи од неколико фактора:

сложености задатка, количине и природе доступних података, ризика од преобучавања (*overfitting*), као и софтверских ресурса. Превише слојева без довољно података може довести до слабе генерализације, док премало слојева може бити недовољно да мреже детектују везе и шаблоне међу подацима. Често се због тога, у реалној примени обично приступа експерименталном пројектовању архитектуре.




Сл.14 – Пример ANN-а са 2 скривена слоја

Број скривених слојева у ANN-у игра кључну улогу у способности мреже да моделује комплексне односе између улазних и излазних података. Са теоријског становишта, већ један скривени слој са довољним бројем неурона може апроксимирати било коју континуалну функцију (тзв. *Universal Approximation Theorem*), али у пракси се често користи више скривених слојева како би се побољшала ефикасност и тачност модела.

3. Конволуционе неуралне мреже

Конволуционе неуралне мреже (*Convolutional Neural Networks – CNN*) представљају врсту типа дубоког учења која је посебно ефикасна у анализи података са просторном или временском структуром (нпр. временске серије, сигнални подаци,...). За разлику од класичних мрежа, КНН користи конволуционе слојеве који примењују филтере над улазом како би аутоматски издвојили релевантне особине без потребе за ручним дефинисањем карактеристика, приказано на Сл.15.



Сл.15 – Архитектура конволуционе неуралне мреже

Основне компоненте архитектуре конволуционих неуралних мрежа укључују:

- конволуционе слојеве;
- слојеве за сабијање (pooling);
- излазни слој.

Захваљујући способности да гради хијерархију карактеристика CNN су изузетно успешне у задацима попут препознавања објеката и анализе слика. Такође су корисне у енергетским апликацијама као што су дијагностика термалних аномалија, класификација стања опреме и предвиђање оптерећења на основу временских и сензорских података.

4. Рекурентне неуралне мреже

Рекурентне неуралне мреже (*Recurrent Neural Networks* – RNN) представљају класу неуралних мрежа која се разликује од традиционалних *feedforward* архитектура по томе што дозвољавају проток информација у оба смера, укључујући и повратне спреге. Захваљујући тим повратним спрегама, RNN имају способност да задрже информације о претходним стањима, што им омогућава моделовање секвенцијалних података и временских зависности.

Ова архитектура омогућава да излаз из једног временског корака утиче на обраду у наредном кораку, што значи да мрежа памти контекст и динамику током времена. Управо та способност чини RNN изузетно погодним за задатке где је временска структура података кључна, као што су:

- предвиђање потрошње електричне енергије;
- анализа флукуација цена на енергетском тржишту;
- прогноза производње из обновљивих извора енергије.

Основна идеја рекурентних модела је у томе да неурони могу бити активирани током ограниченог временског периода, након чега прелазе у мирно стање. Та активација може подстаћи активацију других неурона са одложеним ефектом, чиме се креира динамичан ланац међусобно повезаних активација током времена. Повратне петље у оваквим мрежама не представљају проблем, јер се повратне информације примењују са временским одлагањем, а не моментално.

Иако су RNN у досадашњој пракси имале мањи утицај у односу на *feedforward* мреже, делимично због сложенијих и мање ефикасних алгоритама учења, оне и даље представљају веома важан и актуелан правац у области дубоког учења. RNN боље одражавају начела функционисања биолошког мозга и имају потенцијал да решавају сложене задатке које класичне мреже могу обрадити само уз знатно већи напор и ресурсе.

4.2. Обучавање ANN-а

Обучавање ANN-а представља централни део процеса МУ, у којем модел стиче способност да препознаје шаблоне, обрађује информације и доноси одлуке на основу улазних података. За квалитетно обучавање модела неопходно је адекватно припремити и поделити податке на скупове за обуку, валидацију и тестирање, одабрати архитектуру мреже и проценити перформансе модела. Циљ овог поглавља је да прикаже кораке процеса обучавања ANN-а, од обраде података до примене на нове, непознате улазе.

Процес обучавања почиње формирањем базе података, која мора бити довољно обимна и репрезентативна. Припрема података укључује: чишћење (елиминацију неконзистентности и празних вредности), нормализацију, класификовање променљивих и евентуално смањење димензионалности. Након тога, подаци се деле на три различита скупа, приказано на Сл.16.

1. Тренирајући скуп – обухвата приближно 60–80% података, користи се за прилагођавање параметара мреже, односно синаптичких тежина, кроз итеративни процес учења.
2. Валидациони скуп – чини 10–20% података, служи за фино подешавање модела, праћење његове способности уопштавања и превенцију преобучавања (*overfitting*), при чему се модел не ажурира на основу ових података, већ се њихова анализа користи за избор оптималне архитектуре или хиперпараметара.
3. Тестирајући скуп – у распону од 10–20%, користи се искључиво за финалну евалуацију модела, односно за процену тачности модела.



Сл.16 – Процес обучавања ANN модела

Алгоритам обучавања ANN-а приказан је на Сл.17. Показано је како модел постепено прилагођава своје унутрашње параметре (тежине и bias-e) како би минимизовао грешку у предвиђању. Циљ је да се мрежа обучи тако да за произвољан улаз буде у стању да произведе што тачнији излаз, односно да научи функционалну зависност између улаза и излаза. Обучавање се најчешће реализује применом метода глобалне оптимизације, као што је алгоритам уназадне пропагације грешке (*backpropagation*) у комбинацији са градијентним спустом (*gradient descent*) или неком од његових варијанти.



Сл.17 – Алгоритам обучавања ANN-a

Алгоритам обухвата следеће кораке:

1. Иницијализација мреже – На почетку процеса, мрежа се иницијализује насумичним вредностима тежина и *bias*-а. Важно је да иницијализација буде таква да не доведе до симетричног учења или ишчезавајућих сигнала (тзв. *vanishing/exploding gradients*), што се решава одговарајућим техникама иницијализације (нпр. Xavier, He).
2. Пропагација унапред (*Forward Propagation*) – За сваки улазни вектор из тренирајућег скупа, вредности се прослеђују кроз мрежу, слој по слој, уз примену тежинских коефицијената и функција активације (нпр. ReLU, сигмоидна, тангенс хиперболичка), све до добијања излазне вредности модела. Ова вредност се затим пореди са стварном вредношћу.
3. Израчунавање грешке – Функција грешке (или функција губитка, *loss function*) израчунава разлику између предвиђене вредности и реалног излаза. У зависности од задатка, користе се различите функције губитка, као што су:
 - Средња квадратна грешка (*Mean Squared Error* – MSE) за регресионе проблеме,
 - Средња апсолутна процентуална грешка (*Mean absolute percentage error* – MAPE),
 - Крос–ентропија (*cross–entropy*) за класификацију.
4. Минимизација функције губитака и градијентни спуст

Циљ процеса обучавања ANN-a је да се за сваки улазни податак x предвиди излаз $a(x)$ који је што ближи стварном излазу $y(x)$. Да бисмо мерили колико је модел успешан у овом задатку,

уводи се функција губитака (енгл. *cost function*), која представља квантификацију укупне грешке модела на датом скупу података.

Један од најчешће коришћених облика функције губитака је стандардна грешка средње вредности, једначина 5.

$$C(\omega, b) = \frac{1}{2n} \sum_x \|y(x) - a\|^2 \quad 5$$

где је:

ω – вектор тежине;

b – вектор *bias*-а;

n – укупан број примера у тренирајућем скупу;

a – излаз мреже за дати улаз x ;

$y(x)$ – жељени излаз за дати улаз x .

Што је вредност функције губитака $C(\omega, b)$ мања, то је мрежа прецизнија. Идеалан случај је када $C(\omega, b) = 0$, што значи да је модел у потпуности предвидео све излазе.

У циљу минимизације функције губитака користи се градијентни спуст. То је итеративна метода оптимизације која симулира кретање низ површину функције губитака ка њеном минимуму. Формално правило ажурирања параметара приказано је у једначини 6.

$$\omega' = \omega - \eta \nabla C \quad 6$$

где је:

ω – тренутна вредност параметра (нпр. тежине),

η – константа обучавања (*learning rate*), која дефинише величину корака,

∇C – градијент функције губитака, односно вектор парцијалних извода.

Градијент увек показује смер најбржег раста функције губитака, па се ажурирање параметара врши у супротном смеру, што осигурава смањење вредности функције губитака. Класичан градијентни спуст захтева израчунавање градијента над целом базом података. Ово је софтверски захтеван процес кад се одвија над великим скупом података, али у пракси се користе ефикасније варијанте. Практичне варијанте принципа градијентног спуста су стохастички и градијентни спуст са мини групама:

- Стохастички градијентни спуст (*SGD*) – ажурирање параметара се врши након сваког појединачног примера;
- Mini-Batch градијентни спуст – ажурирање се врши након сваке мини-групе, што омогућава бољу стабилност и убрзава обраду.
- Градијентни спуст (*GD*) – ажурирање параметара се врши након обраде целог скупа података.

Ове методе обезбеђују усклађеност између тачности и ефикасности, што их чини применљивим за обуку дубоких неуралних мрежа са великим бројем параметара.

5. Уназадна пропација (*Backpropagation*) – Грешка се затим враћа уназад, примењујући правило ланца деривација, ради израчунавања градијената функције губитка у односу на све

параметре у мрежи. На овај начин се утврђује како промена сваке појединачне тежине утиче на укупну грешку.

6. Ажурирање параметара – На основу израчунатих градијената, тежине и bias-и се ажурирају у смеру супротном од градијента (ка смеру највећег смањења грешке), уз одређену брзину учења (*learning rate*). Ажурирање се може вршити појединачно по примеру (стохастички градијентни спуст), по мини–групама (*mini-batch*) или над целим скупом.
7. Валидација модела – По завршетку сваке епохе, модел се тестира на валидационом скупу, како би се проценила његова способност да генерализује. Преобучавање (*overfitting*) се идентификује у ситуацији када грешка на тренирајућем скупу наставља да опада, док грешка на валидационом скупу почиње да расте. Ова појава указује на то да је модел превише прилагођен тренинг подацима, укључујући и шум и случајне варијације у подацима, услед чега губи способност генерализације на нове, невиђене податке. У том случају се примењују технике као што су: регуларизација, рано заустављање (*early stopping*) или смањење комплексности архитектуре.
8. Евалуација и итерација – Ако је грешка у фази тестирања прихватљива, модел се сматра обученим и спремним за предикцију. У супротном, поступак се враћа у фазу поновног тренирања. Често се ту прилагођавају хиперпараметари као што су број слојева, број неурона, функције активације, и слично. Овај процес се понавља до испуњења задатих критеријума за заустављање, као што су: достизање задовољавајуће тачности на валидационом скупу, максималан број епоха или итерација, као и појава преобучавања.

4.3. Анализа перформанси ANN модела

Тачна и поуздана процена перформанси вештачких неуралних мрежа од кључног је значаја за њихову примену у енергетским системима. Избор одговарајућих метрика евалуације зависи од природе проблема: да ли се ради о регресији (предвиђање континуални хвредности) или класификацији (одлучивање између дискретних категорија).

1. Метрике у задацима регресије

У случајевима као што су предвиђање потрошње електричне енергије, производње из обновљивих извора или вредности напона у неком моменту, користе се следеће метрике:

- RMSE (*Root Mean Squared Error*) – корен средње квадратне грешке; наглашава велике грешке;
- MAE (*Mean Absolute Error*) – средња апсолутна грешка; мање је осетљива на погрешна мерења попут *outlier*-а од RMSE–а;
- MAPE (*Mean Absolute Percentage Error*) – средња апсолутна процентуална грешка; погодна за поређење на различитим скалама.

2. Метрике у задацима класификације

Када се ANN користи за класификацију стања система (нпр. исправно/неисправно, стабилно/нестабилно), примењују се:

- Тачност – однос тачно класификованих узорака и укупног броја;
- F1–score – хармонијска средина прецизности и одзива; корисна у неуравнотеженим скуповима;

- Конфузиона матрица – матрица која приказује поређење стварних класа и класа које предвиђа модел, односно број истинито позитивних, лажно позитивних, истинито негативних и лажно негативних класификација;
- *ROC AUC* крива (енгл. *Area Under the Receiver Operating Characteristic curve*) – мера дискриминационе способности класификатора.

Избор метрике мора бити усклађен са конкретним захтевима апликације. У задацима предвиђања, већи значај се често даје RMSE–у јер осетљивије реагује на велике одступања, која у енергетици могу указивати на критичне догађаје.

Тачност ANN модела анализира се на основу вредности прорачунатих грешака: MAPE (*Mean Absolute Percentage Error*), MAE (*Mean Absolute Error*), MSE (*Mean Square Error*) и RMSE (*Root Mean Square Error*), према једначинама приказаним у Таб.3 при чему је N број узорака у бази података, y_i је предикциона вредност, а y стварна вредност.

Према Yadav и Chandel [28], модел се сматра високе прецизности ако је $MAPE < 10\%$, добар ако је $10\% < MAPE < 20\%$, задовољавајући ако је $20\% < MAPE < 50\%$, док се за $MAPE > 50\%$ сматра нетачним.

Таб.3 – Вредности прорачунатих грешака

$MAPE = \frac{\sum_{i=1}^N \frac{ y - y_i }{y}}{N} \cdot 100\%$	$MAE = \frac{\sum_{i=1}^N y_i - y }{N}$
$MSE = \frac{\sum_{i=1}^N (y - y_i)^2}{N}$	$RMSE = \sqrt{\frac{\sum_{i=1}^N (y - y_i)^2}{N}}$

4.4. Практичне примене у ЕЕС–у

Иако ANN показују велики потенцијал у моделовању, предикцији и оптимизацији у енергетском сектору, њихова практична примена у реалним системима праћена је бројним изазовима.

У многим случајевима, посебно у традиционалним енергетским системима или локалним дистрибутивним мрежама, не постоји довољно велики број података потребних за квалитетно обучавање модела. Без репрезентативних скупова података, мрежа ризикује да генерализује лоше и доведе до погрешних закључака или да буде подложна преобучавању (*overfitting*).

ЕЕС често захтевају доношење одлука у реалном времену. ANN модели могу бити рачунски захтевни и временски осетљиви, што отежава њихову примену у системима који не толеришу кашњење или нестабилност предвиђања.

У области енергетике често не постоји довољно стандардизованих, јавних скупова података који би омогућили поређење ANN модела у различитим сценаријима. Ово отежава репродуктивност резултата и верификацију модела. Потреба за заштитом података и безбедносним ограничењима додатно успорава развој решења у овој области.

Предности ANN–а и машинског учења у погледу времена прорачуна демонстриране су у многим радовима [30]–[32]. ANN су коришћене за предвиђање потрошње енергије [33], чак и за периоде од више година [34]. Предвиђања потрошње ANN била су довољно задовољавајућа да се користе за економско прогнозирање [35]. Различите методе анализе великих података за иновативна предвиђања у паметним мрежама приказане су у [36], док се предвиђање оптерећења врши и помоћу машинског учења у паметним мрежама [37].

Упркос значајним предностима које ANN поседују и добром предвиђању потрошње, они имају и одређене недостатке. Недостаје им одређени ниво интерпретабилности у моментима када је неопходно на који начин је одређени проблем решен [38]. Ове методе обезбеђују коначно решење, али не пружају транспарентан увид у механизам повезивања улазних података и излазних резултата.

Различити алгоритми се развијају како би решили проблем прорачуна токова снага и примењују нове методе које су прилагодљиве конкретним проблемима. Граф неуралне мреже (*GNN– Graph Neural Networks*) су предложене као решење за прорачун токова снага у дистрибутивном систему где је неопходно нагласити велики број ограничења [11]. Физички информисане неуралне мреже (*Physics–informed Neural Networks*) се развијају како би се примениле за решавање једначина *ACPF (Alternating Current Power Flow)* уз уважавање утицаја амбијенталних услова у којима се електроенергетски налази на рад читавог система [12]. Овде је представљен је и динамички метод заснован на графовима за примену проблема планирања који се базира на класичном методу решавања токова снаге. Поред наведених приступа, у литератури се често користе и динамичке неуралне мреже, као што су RNN и LSTM мреже, које су посебно погодне за моделовање временске зависности и предикцију у електроенергетским системима.

5. ANFIS

Адаптивни Неуро Фази Системи (*Adaptive Neuro-Fuzzy Inference System – ANFIS*) представљају методологију која комбинује принципе рада ANN-а и фази логике, Сл.18. Овакав склоп особина из два различита приступа омогућава да се искористе предности оба принципа. Као предност ANN-а користи се њихова адаптивност и способност учења, а из фази логике се узима способност закључивања у условима неизвесности.



Сл.18 – ANFIS модел: спој ANN-а и фази логике

ANFIS модел функционише као неурална мрежа у чијем се језгру налази фази систем заснован на Такаги–Сугено–Канг (*Takagi-Sugeno-Kangtype*) логичким принципима. Његова архитектура се састоји од више слојева, при чему сваки слој има конкретну улогу у обради података. Слојеви почињу од фазификације улазних података, евалуације фази правила и нормализације, па све до дефазификације и одређивања крајњег излаза. Овај систем користи *if-then* правила и функције припадности да би представио релације између улаза и излаза [39].

ANFIS обрађује улазне податке тако што их прво преводи у фази облик одређујући степене припадности сваког улаза одређеним фази категоријама. Ови степени припадности се затим комбинују кроз дефинисана правила, која воде до излаза кроз процес дефазификације.


Како би ANFIS модел могао да се прилагођава новим подацима, а истовремено сачува разумљивост правила, обучава се комбиновањем два алгоритма учења. Ова два алгоритма учења су:

1. Метода најмањих квадрата – за иницијалну процену параметара функција припадности;
2. Градијентни спуст – за фино подешавање параметара како би се минимизовала грешка.

Захваљујући способности обраде нејасних, нелинеарних и шумовитих података, ANFIS је ефикасан у моделовању сложених система. Посебно је значајан у областима као што су управљање енергијом, предикција потрошње и откривање неправилности, као и у класификацији и регресији у индустријским и техничким системима.

5.1. Структура ANFIS модела

ANFIS је сложен од пет слојева приказаних на слици Сл.19. Сваки слој у овој архитектури има специфичну улогу у обради података. Овде слој 0 приказује улазне вредности у ANFIS модел [40].



Сл.19 – Архитектура ANFIS-a

1. Слој 1 – Фазификациони слој (улазни слој)

Циљ: Улазни подаци овог слоја су бројчане вредности. Оне се кроз овај слој, помоћу функција припадности, трансформишу у фази вредности ради примене метода фази логике.

Пример: Нека је улаз промењива x . За дати улаз могу се дефинисати фази скупови као што су *ниско*, *средње* и *високо*. Функција припадности служи како би се проценило у којој мери улазна вредност x припада појединим, дефинисаним скуповима.

Најчешће функције припадности које омогућавају флексибилну фазификацију података и дефинисање нејасних појмова су приказане једначинама 7-9 и графички на слици Сл.20.

- Гаусова функција:


$$\mu(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad 7$$

- Троугаона функција


$$\mu(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ \frac{c-x}{c-b}, & b < x \leq c \\ 0, & x > d \end{cases} \quad 8$$

- Трапезна функција


$$\mu(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ 1, & b < x \leq c \\ \frac{d-x}{d-c}, & c < x \leq d \\ 0, & x > d \end{cases} \quad 9$$



а) Гаусова



б) Троугаона



в) Трапезна

Сл.20 – Криве функција припадности

2. Слој 2 – Слој правила (евалуација фази правила)

Циљ: Улазни подаци овог слоја су фазификоване улазне вредности ANFIS модела. Сваки чвор у овом слоју представља једно фази правило и израчунава његову јачину активирања.

Обрада: Јачина активирања W_i је производ вредности припадности за све улазне променљиве, према једначини 10:

$$W_i = \pi_A(x) \cdot \pi_B(x) \quad 10$$

где су A и B фази скупови за променљиве x и y .

3. Слој 3 – Слој нормализације

Циљ: Потребно је нормализовати тежину правила како различите врсте правила не би биле теже поредиве. Уколико су у различитим степенима величина на основу типа података који обрађују, то не сме имати утицај на важност правила која из те врсте података долазе. Потребно је да се добијене вредности третирају као релативне важности појединачних параметара. У ову сврху се нормализују јачине активирања правила тако да њихов збир буде једнак 1, према једначини 11.

$$\bar{W}_i = \frac{W_i}{\sum_j W_j} \quad 11$$

4. Слој 4 – Дефазификациони слој (излаз из правила)

Циљ: Улаз овог слоја су нормализоване вредности правила и фазификовани подаци, а излази су дефинисани на основу пондерисаних вредности правила. Израчунава се излаз сваког правила као линеарне функције улаза, пондерисане нормализованом јачином активирања, према једначини 12, у оквиру фазе фази закључивања.

$$\text{излаз} = \bar{W}_i \cdot (a_i x + b_i y + c_i) \quad 12$$

5. Слој 5 – Излазни слој

Циљ: Коначни излаз модела добија се као збир свих пондерисаних излаза из претходног слоја, једначина 13.

$$\text{излаз} = \sum_{i=1}^n \bar{W}_i \cdot f_i(x, y) \quad 13$$

Ова структура омогућава ANFIS систему да учи параметре функција припадности и правила користећи методе оптимизације и регресије.

Обучавање ANFIS–а представља кључни корак у осигуравању његове тачности, прилагодљивости и применљивости у решавању практичних проблема [39]. ANFIS модел садржи два скупа параметара који морају бити оптимизовани током процеса учења:

1. параметре функција припадности,
2. параметре у коњункцији фази правила.

Стандардни приступ тренирању ANFIS–а ослања се на хибридни алгоритам учења који комбинује:

- Метод најмањих квадрата (*Least Square Error*, LSE) – оптимизацију параметара у последњем слоју,
- Градијентни спуст (*Batch Gradient Descent*, BP) – ажурирање параметара функција припадности у улазном слоју.

Тренинг се одвија у две фазе приказане у Таб.4:

- Прослеђивање унапред (*Forward pass*): Улазни подаци пролазе кроз мрежу и израчунава се излаз користећи тренутне вредности параметара. У овој фази се примењује LSE за подешавање параметара последњег слоја,

- Повратна корекција (*Backward pass*): Грешка између добијеног и стварног излаза се уназад прослеђује кроз мрежу. Примењује се алгоритам градијентског спуста ради прилагођавања функција припадности.

Таб.4 – Поређење фаза обучавања ANFIS модела и примењених метода оптимизације

Фаза	Параметри премисе	Параметри коњеквенције	Метод
Унапред	Фиксни	Најмањи квадрати	Прослеђивање унапред
Уназад	Градијентни спуст	Фиксни	Повратна корекција

Овој методи је предност то што је једноставан и ефективан за мање комплексне ANFIS моделе. Али има значајна ограничења по питању конвергенције и ризика од заглављивања у локалним минимумима.

Упркос значајним предностима, примена овог приступа праћена је одређеним ограничењима и изазовима. Повећањем броја улазних променљивих и функција припадности, експоненцијално расте број правила. Већи број правила отежава тумачење и примењује веће трошкове обраде. Већина студија се фокусира само на параметре, а мање на саму базу правила.

Истраживања указују да је неопходно истовремено максимизирати тачност и минимизирати комплексност система, кроз увођење адаптивних механизма за редукацију правила и ефикаснију селекцију функција припадности.

5.2. Предности ANFIS модела

ANFIS, као хибридни модел који комбинује предности ANN-а и фази логике, у односу на класичне статистичке приступе нуди значајне предности. Фази логика му доноси објашњивост, док се задржавају предности резоновања ANN-а. У овом поглављу су приказане појединачне предности којима он доприноси [30], што је илустровано на Сл.21.



Сл.21 – Предности примене ANFISмодела

Рачунајући заједнички рад ANN–а и фази логике, ANFIS модели могу са великом комплексношћу да симулирају комплексне, нелинеарне и вишедимензионе функције. Применом *if-then* правила могу се моделовати појаве које немају јасно дефинисану математичку структуру, већ се описују језиком логике. Ово има значајну предност при класификацији и прогнозирању у поређењу са класичним приступима попут ARIMA-е или линеарне регресије.

Једна од кључних предности ANFIS–а је његова способност да се аутоматски прилагођава новим улазним подацима. Његова значајна предност је комбиновано учење. Употреба и методе најмањих квадрата и градијентног спуста у исто време доприноси динамичном ажурирању функција припадности и фази правила. Како се обрасци података мењају у току времена у реалним ситуацијама, робусност коју ова особина даје је од велике користи.

Оно што може недостајати у моделима попут ANN–а за употребу где жели да се сазна правило закључивања на основу података која су део модела је интерпретабилност. Захваљујући фази логици, ANFIS модел ову особину поседује. Фази правила су изражена у облику блиском људској логици. Овим може тачно да се изрази шта корисник жели што омогућава боље разумевање и валидира доношење одлука система.

Модел може ефикасно научити било коју функцију дефинисану на основу скупа улазно–излазних података, што га чини идеалним за проблеме без експлицитне формуле.

Упркос својој унутрашњој сложености, ANFIS демонстрира високу рачунарску ефикасност, нарочито када се користе оптимизовани алгоритми за ажурирање параметара. У поређењу са дубоким моделима, који често захтевају велике количине података и ресурса, ANFIS може да

пружи конкурентне резултате уз мању рачунарску сложеност, што га чини погодним за апликацију у реалном времену.

ANFIS се лако интегрише у друге интелигентне системе, укључујући моделе засноване на ANN–у, генетским алгоритмима или системима заснованим на правилима. Такав модулари приступ омогућава проширење функционалности постојећих система и њихову адаптацију специфичним задацима уз минимално прилагођавање.

5.3. Примена ANFIS модела

ANFIS је нашао широку примену у разноврсним областима захваљујући својој способности да моделује нелинеарне, неодређене и вишедимензионалне односе. Комбинујући учење из података и лингвистичко расуђивање, ANFIS се издваја као алат који обезбеђује високу прецизност, стабилност у раду и интерпретабилност модела, што је посебно значајно у техничким системима где се тражи и адаптивност и разумљивост резултата.

Захваљујући фази логичкој компоненти, ANFIS показује отпорност на несавршене, непотпуне или зашумљене податке. То га чини изузетно применљивим у сценаријима где су мерења оптерећена грешком, подаци нису уједначени или се појављују неодређени улазни услови. Ова робусност утиче на већу поузданост предвиђања у реалном свету.

Флексибилна архитектура ANFIS модела омогућава примену у широком спектру области:

- техничке науке (контрола система, мехатроника, роботика),
- финансије (анализе ризика, прогноза тржишта),
- здравство (дијагностичке класификације, препознавање образаца у медицинским подацима),
- енергетика (предвиђање оптерећења, интеграција обновљивих извора).

ANFIS се често користи у пројектовању интелигентних регулатора за динамичке и комплексне системе. Посебно је ефикасан у апликацијама где је потребна прецизна контрола у реалном времену, као што су аутоматско управљање возилима (аутономна вожња, адаптивни темпомат), управљање индустријским процесима са нелинеарним понашањем, роботика (ANFIS омогућава роботу да адаптивно реагује на промене у окружењу). У овим системима, ANFIS делује као замена или допуна PID регулаторима, нарочито у условима где је класична контрола недовољна због нелинеарности, хистерезе или кашњења.

У односу на класичне статистичке моделе (ARIMA, регресија), ANFIS често постиже боље резултате у присуству шума, нелинеарности и у недостатку експлицитног математичког модела.

ANFIS се ефикасно користи у задацима класификације и препознавања облика.

Његова способност да уједини лингвистичка правила са процесом учења омогућава флексибилнију анализу и бољу толеранцију на неодређене или непотпуне податке.

ANFIS модели све више добијају на значају у електроенергетици, посебно у областима:

- предвиђања оптерећења и потрошње енергије, што је кључно за планирање производње и дистрибуције,

- оптимизације рада микромрежа, укључујући баланс обновљивих извора (соларни, ветар) и складишта енергије,
- откривања и дијагностике кварова на преносној и дистрибутивној мрежи,
- планирања рада електроенергетских система у реалном времену, укључујући и паметне мреже (*smart grid*).

У овом контексту, ANFIS омогућава интелигентну анализу историјских података у условима високих флукуација и несигурности, чиме доприноси стабилности и ефикасности система.

Предиктивни модел који има већи ниво транспарентности у систему свог доношења одлука је ANFIS. ANFIS је резултат изузетно успешне интеграције фази система и ANN-а [39] који поседује предности обе методологије. ANN и фази системи су слични по својој способности рада са нелинеарним, динамичким системима за које не постоји тачно дефинисан математички модел. Фази системи имају комплетну транспарентност кроз низ конкретизованих лингвистичких правила, али им недостају адекватни алгоритми који би могли да обрађују велику базу улазних података.

ANFIS може да се користи као база за развој модела где се њихови параметри могу подесити и користити за краткорочна превиђања [42]. Ово је главна предност због које се ANFIS користи при многим моделима предвиђања [43], као и у развоју методе за контролу статуса повезаности електричних возила [44].

6. ARIMA

6.1. Увод у ARIMA моделе

ARIMA модели (*Auto Regressive Integrated Moving Average*– ARIMA) представљају класу статистичких модела који се користе за анализу, моделовање и предвиђање временских серија. У науци и пракси, ARIMA се сматра једним од најмоћнијих и најфлексибилнијих алата за рад са подацима који су временски зависни, нарочито у доменима у којима је очување интерпретабилности модела од посебне важности. Развијен од стране Џорџа Бокса и Гвиндолина Џенкинса, овај модел је познат и као *Box–Jenkins* модел и подразумева формалан поступак идентификације, естимације и валидације модела временске серије [45].

ARIMA модели се базирају на анализи временских серија које садрже аутокорелацију, сезоналност, трендове и шумове. Главни циљ је да се идентификују параметри модела који могу најбоље објаснити понашање серије и предвидети будуће вредности. ARIMA модели се често користе у економији, финансијама, метеорологији, инжењерству и многим другим областима.

ARIMA представља један од најважнијих и најраспрострањенијих алгоритама за моделовање и предвиђање временских серија. Дизајнирана је да идентификује обрасце и структуре у подацима који су временски зависни, као што су трендови, сезоналности и међузависности између прошлих и садашњих вредности циљне променљиве. Кроз процес анализирања прошлих вредности временске серије, ARIMA омогућава формулацију предикција будућих вредности на основу откривених закономерности.

Модел који се разматра у овом раду представља униваријантни приступ, односно бави се моделовањем једне временске серије независно од других потенцијалних улазних променљивих. Предвиђање се заснива искључиво на информацијама садржаним у претходним вредностима циљне променљиве, што га чини посебно корисним у ситуацијама када додатне помоћне променљиве нису доступне.

ARIMA модел се састоји од три кључне компоненте:

- Ауторегресија (AR) – модел ауторегресије уводи претпоставку да се садашње вредности серије могу објаснити претходним вредностима саме серије. То значи да постоји статистички значајна временска корелација унутар серије. На пример, дневна потрошња електричне енергије може зависити од вредности из претходних дана,
- Интеграција (I) – пошто многе реалне временске серије показују трендове или сезонске компоненте, потребно их је трансформисати у стационарне серије пре примене моделовања. Ово се постиже диференцирањем серије – одузимањем претходне вредности од тренутне, како би се елиминисала нестабилност у средњој вредности,
- Покретни просек (MA) – моделује утицај случајних сметњи и грешака из прошлости. Она помаже да се ублаже ненадане флукуације у подацима које нису директно повезане са структуром саме временске серије.

Стационарност представља један од основних услова за примену ARIMA модела. Временска серија је стационарна ако има константну средњу вредност, варијансу и коваријансу током времена. Ако серија није стационарна, примена модела може довести до нетачних закључака. Зато је неопходно пре моделовања извршити диференцирање серије и проверити стационарност

формалним тестовима (*ADF*, *KPSS*). Тек након потврде стационарности може се приступити избору *AR* и *MA* параметара.

ARIMA модел се означава као *ARIMA* (p, d, q), где су:

- p – ред ауторегресивног дела,
- d – степен диференцирања серије,
- q – ред покретног просека.

У контексту енергетике, *ARIMA* модели налазе широку примену у задацима као што су: предвиђање електричног оптерећења, моделовање цене електричне енергије на тржишту, планирање производње у систему са обновљивим изворима енергије и управљање дистрибутивним мрежама. Њихова предност у овим применама је могућност креирања тачних и стабилних краткорочних прогноза у условима када су подаци високофреквентни и релативно уједначени.

Ипак, за разлику од модела дубоког учења и вештачких неуралних мрежа, *ARIMA* модели су мање ефикасни у ситуацијама када су подаци високо нестационарни, нелинеарни или недовољно обилни. Упркос томе, због своје једноставности, транспарентности и малог броја параметара, и даље остају основа у статистичкој анализи временских серија [46].

У наставку рада биће детаљно представљен процес идентификације *ARIMA* модела, методологија тренинга и валидације, као и примери њихове конкретне примене у енергетским системима.

6.2. Математички модел ARIMA

Када комбинујемо све три компоненте (AR, I и MA), добијамо ARIMA (p, d, q) модел, који се формулише према једначини 14.

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1 - L)^d Y_t = \left(1 + \sum_{j=1}^q \theta_j L^j\right) \varepsilon_t \quad 14$$

где су:

L – оператор кашњења, тако да важи $LY_t = Y_{t-1}$;

d – број диференцијација потребних да серија постане стационарна;

ϕ_1, \dots, ϕ_p – AR–параметри;

$\theta_1, \dots, \theta_q$ – MA–параметри;

ε_t – бели шум (независи од прошлих вредности).

У овом запису:

1. $(1 - L)^d$ означава да је серија Y_t диференцирана d пута до добијања стационарног облика,
2. AR–оператор $(1 - \sum_{i=1}^p \phi_i L^i)$ уводи утицај претходних p кашњења – линеарна аутокорељација,
3. MA–оператор $(1 + \sum_{j=1}^q \theta_j L^j)$ укључује ефекте претходних q грешака.

Оваква формулација омогућава да се у једној једначини обухвате тренд, сезоналност (кроз диференцирање) и утицај претходних грешака, чиме ARIMA модел постаје један од снажнијих алата за анализу и краткорочно предвиђање временских серија у енергетици и другим доменима.

ARIMA модел представља комбинацију три основне компоненте: ауторегресије (AR), покретног просека (MA) и диференцирања (I), које заједно омогућавају моделовање различитих карактеристика временских серија. У наставку су приказане појединачне компоненте овог модела, њихова улога и математичка формулација

1. Ауторегресија (AR)

Ауторегресивна компонента AR модела подразумева да се тренутна вредност временске серије може предвидети на основу претходних вредности исте серије. Математички модел приказан је једначином 15.

$$Y_t = (\varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p}) + \varepsilon_t \quad 15$$

где су:

Y_t – текућа вредност серије,

$\varphi_1, \dots, \varphi_p$ – параметри модела,

ε_t – бели шум, односно насумична грешка.

Ова компонента моделује унутрашњу структуру временске серије, одражавајући степен утицаја претходних вредности на тренутну. На пример, дневна потрошња електричне енергије може бити корелирана са потрошњом из претходних дана.

2. Покретни просек (МА)

Компонента покретног просека користи информације о претходним грешкама у моделовању серије. МА модел се може записати једначином 16.

$$Y_t = \mu + \varepsilon_t + (\theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}) \quad 16$$

где су:

μ – средња вредност серије;

$\theta_1, \dots, \theta_q$ – параметри МА дела модела;

ε_t – тренутна грешка (бели шум).

МА модел представља механизам за уравнотежење случајних варијација у подацима, побољшавајући стабилност прогнозе. Овим начином МА–компонента коригује серију на основу прошлих одступања од предвиђања, чиме се смањују ненадане и нелинеарне флукуације.

3. Интеграција (I)

Ако временска серија није стационарна (има тренд или променљиву варијансу), потребно ју је претворити у стационарни облик пре примене AR и МА компонената. То се постиже диференцирањем приказаним у једначини 17.

$$\nabla^d Y_t = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) - \dots - (Y_{t-(d-1)} - Y_{t-d}) \quad 17$$

Уколико је, након једне диференције, серија још увек нестабилна, ради се друга (или виша) диференција. Након што серија постане стационарна, AR и МА модели могу да се примене на разлику серија.


За стабилно понашање модела, AR компонента мора задовољити услове стационарности, односно да корени карактеристичног полинома буду изван јединичног круга у комплексној равни. Слично, МА компонента мора бити инвертибилна како би модели били јединствени и интерпретабилни.

6.3. Процес формирања ARIMA модела

Изградња ARIMA модела захтева систематичан приступ који обухвата неколико узастопних корака. Основна идеја је идентификовати структуру временске серије, трансформисати је у стационарну форму, проценити параметре модела и извршити валидацију на основу предвиђајућих способности.

У наставку је дат алгоритамски приказ процеса изградње ARIMA модела према Box–Jenkins методологији, приказан на Сл.22. Дијаграм обухвата кључне кораке: проверу стационарности, избор параметара, фитовање модела и евалуацију тачности предвиђања.

Овако структуриран процес моделовања обезбеђује да ARIMA модел буде не само статистички ваљан, већ и применљив у реалним условима, посебно у предвиђању енергетских параметара као што су потрошња, оптерећење, производња и цене енергије.



Сл.22 – ARIMA алгоритам

Ако серија није стационарна, примењује се диференцирање ради отклањања трендова и сезонских компоненти. Потреба за применом диференцирања одређује се на основу анализе стационарности временске серије, која се спроводи применом следећих метода:

- Визуелна анализа: графикон серије може указати на тренд или сезоналност,
- ACF/PACF графици: аутокорељациона (ACF) и парцијална аутокорељациона функција (PACF) користе се за одређивање редова AR и MA делова модела,
- Тестови стационарности: *Dickey–Fuller* или *KPSS* тест се користе ради формалне провере стационарности.

Након што су редови p , d и q идентификовани, следи естимација параметара модела. Најчешће се примењују методе максималне вероватноће или најмањих квадрата. У овом кораку одређују се тежински коефицијенти AR и MA компонената који најбоље описују зависности унутар серије.

1) Одређивање реда диференцирања (d)

Први корак у ARIMA моделовању је утврђивање да ли је временска серија стационарна. Уколико није, неопходно је применити диференцирање како би се уклонили трендови или сезоналне компоненте.

Стационарност подразумева да статистичке карактеристике серије (средња вредност, варијанса, аутокорељација) остају константне током времена. Ако серија показује тренд (нпр. континуирани раст или пад) или сезоналност, највероватније није стационарна.

Методе за тестирање стационарности:

- ADF тест (*Augmented Dickey–Fuller*): Нулта хипотеза (H_0) је да серија има јединствени корен (да није стационарна). Ако је $p < 0,05$, одбацујемо H_0 . То значи да је серија стационарна,
- KPSS тест (*Kwiatkowski–Phillips–Schmidt–Shin*): Овде је нулта хипотеза да је серија стационарна. Ако је $p < 0,05$, одбацујемо H_0 . Ово значи да серија није стационарна.

Практичан поступак:

- Ако серија није стационарна, примењује се први степен диференцирања, приказан у једначини 18.

$$\nabla X_t = X_t - X_{t-1} \quad 18$$

- Уколико ни након тога серија није стационарна, диференцира се поново према једначини 19.

$$\nabla^2 X_t = \nabla X_t - \nabla X_{t-1} \quad 19$$

Процес се понавља све док серија не постане стационарна. Типично, вредност параметра d износи 0, 1 или максимум 2. Виши степен диференцирања може довести до прекомпликованог модела и губитка важних информација.

2) Одређивање реда ауторегресије (p) и покретног просека (q)

Када је серија трансформисана у стационарну, следи идентификација параметара p и q .

Овај корак се обично спроводи, тумачењем графика серије података и коришћењем:

- Аутокорелационе функције (*ACF*) – приказује укупне корелације серије са њеним закашњелим вредностима (лаговима),
- Парцијалне аутокорелационе функције (*PACF*) –показује чисте корелације сваког појединачног лага, елиминишући утицај интермедијарних вредности.

На основу анализе *ACF* и *PACF* функција могу се формулисати правила за избор одговарајућег *ARIMA* модела, која су приказана у Таб.5.

Таб.5 – Основна правила за избор *ARIMA* модела:

Образац	Сугестија за модел
<i>PACF</i> нагло пада након лага p , <i>ACF</i> опада постепено	<i>AR</i> (p) модел
<i>ACF</i> нагло пада након лага q , <i>PACF</i> опада постепено	<i>MA</i> (q) модел
И <i>ACF</i> и <i>PACF</i> опадају постепено	<i>ARMA</i> (p, q) модел

Визуелном анализом се долази до:

- Број значајних лагова на *ACF* графикону даје предлог за q
- Број значајних лагова на *PACF* графикону даје предлог за p

3) Одређивање реда ауторегресије (p) и покретног просека (q)

Након што се идентификују потенцијалне комбинације параметара (p, d, q), бира се најбољи модел користећи квантитативне критеријуме као што су:

- Акаикеов информациони критеријум (*AIC*):

Акаикеов информациони критеријум кажњава моделе са већим бројем параметара. Што је нижа вредност *AIC*, то је модел бољи. Формула за овај критеријум приказана је кроз једначину 20.

$$AIC = 2k - 2 \ln(L) \quad 20$$

где су:

k – број процењених параметара,

L – максимална вредност лог–вероватноће модела,

У пракси се тестира више комбинација (p, d, q) и бира се модел са најнижом *AIC* (или *BIC*) вредношћу.

- Бајесов информациони критеријум (*BIC*)

Још строже кажњава комплексност модела у односу на *AIC*. Нижа вредност *BIC* значи бољи модел [47].

У модерним софтверским окружењима, као што је Python (библиотеке *statsmodels*, *pmdARIMA*) естимација се извршава аутоматски, али избор доброг модела увек захтева аналитичко размишљање и проверу статистичке оправданости.

Након естимације параметара врши се валидација модела. Потребно је проверити да ли модел добро описује податке. У овој фази испитује се да ли су резидуали модела (разлике између

предвиђених и стварних вредности) ненасумични, без аутокорелације и нормалне расподеле. Валидација модела обухвата примену више комплементарних метода за анализу резидуала и процену тачности, које су приказане у наставку:

- Тестови резидуала – Љунг-Бокс тест и ACF анализа резидуала откривају постојање преостале аутокорелације.
- Графичка анализа – Q-Q графикон и графикон резидуала помажу у процени нормалности.
- Евалуационе метрике – RMSE (*Root Mean Square Error*), MAE (*Mean Absolute Error*), MAPE (*Mean Absolute Percentage Error*) се користе за процену тачности на тест скупу.

Предвиђање је последњи корак за који се користи модел. Када модел задовољава све критеријуме, примењује се за краткорочно или дугорочно предвиђање будућих вредности. ARIMA модели су нарочито ефикасни у краткорочним прогнозама када је динамика серије релативно стабилна и без драстичних екстерних поремећаја.

Ако серија показује сезоналност, примењује се SARIMA модел (Seasonal ARIMA), који укључује додатне сезонске параметре (P, D, Q, s). Формула SARIMA модела приказан је једначином 21. За комплексније системе користе се:

- ARIMAX – који уводи егзогене променљиве у модел,
- VAR – за мултиваријантне серије,
- Хибридни модели – у комбинацији са ANN, фази логиком или другим техникама ради побољшања предиктивне снаге.

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) \left(1 - \sum_{k=1}^K \Phi_k L^{ks}\right) (1-L)^d (1-L^s)^D Y_t = \left(1 + \sum_{j=1}^q \theta_j L^j\right) \left(1 + \sum_{J=1}^Q \Theta_J L^{Jq}\right) \varepsilon_t, \quad 21$$

где је:

ϕ_i – несезонски AP параметар;

Φ_k – сезонски AP параметар;

θ_j – несезонски MA параметар;

Θ_J – сезонски MA параметар;


L – оператор кашњења, тако да важи $LY_t = Y_{t-1}$;

d, D – ред диференцирања и сезонског диференцирања.

6.4. Ограничења ARIMA модела

Иако ARIMA модели представљају снажан статистички алат за анализу и предвиђање временских серија, њихова примена није без ограничења. Упркос великој флексибилности у обради линеарних и стационарних процеса, постоје ситуације у којима ови модели нису

довољно ефикасни или уопште нису применљиви. Ограничења ARIMA модела приказана су на Сл.23.



Сл.23 – Ограничења ARIMA модела

Основна претпоставка ARIMA модела је линеарност, односно да се тренутна вредност серије може изразити као линеарна комбинација прошлих вредности и прошлих грешака. Ово значи да модел не може адекватно да обухвати нелинеарне обрасце или сложене динамике које укључују промену у зависностима током времена. У системима где су појаве контекстуалне или условљене комплексним спољашњим факторима (нпр. динамика цена у условима кризе), ARIMA модел може бити недовољан.

ARIMA модели захтевају да серија буде стационарна, односно да има константну средњу вредност, варијансу и коваријансу у времену. Иако се овај услов може постићи трансформацијом или диференцирањем серије, постоје ситуације где серија остаје нестабилна или где се трендови и сезонности мењају у зависности од спољних околности. У таквим условима, ARIMA модели могу да изгубе способност да дају валидне прогнозе.

Класичан ARIMA модел је унваријантан, што значи да узима у обзир само једну временску серију и претпоставља да све релевантне информације за прогнозу постоје унутар те серије. Међутим, у пракси, посебно у енергетици, вредности променљивих често зависе од екзогених фактора (нпр. температура, индустријска активност, регулаторна интервенција), што ARIMA модел у основној верзији не подржава. За такав тип проблема неопходно је применити *ARIMAX* модел или прелазак на мултиваријантне технике као што су *VAR* модели.

У реалним системима, као што су енергетске мреже, тржишта електричне енергије или потрошачке навике, често долази до структурних прекида (*structural breaks*) или регулаторних измена. ARIMA модели нису погодни за идентификацију или адаптацију на такве промене без експлицитне модификације или поделе серије на подинтервале.

Иако је могуће применити ARIMA модел на сезонске серије, ова способност постаје ограничена без увођења додатних сезонских параметара. За такве случајеве развијен је SARIMA модел који омогућава обраду сезонских образаца, али то више не спада у основни ARIMA оквир.

6.5. Примене ARIMA модела у енергетици

ARIMA модели налазе широку примену у анализи и предвиђању података временских серија у различитим секторима, а посебно се истичу у енергетском сектору због способности да моделују сложене динамике потрошње, производње и цена енергије. У наставку су представљене најзначајније примене ARIMA модела у оквиру енергетике:

Једна од најчешћих примена ARIMA модела је краткорочно и средњерочно предвиђање потрошње електричне енергије. Прецизна прогноза оптерећења омогућава оператерима система да боље планирају производњу, оптимизују рад електрана и смање трошкове балансирања. ARIMA модели су посебно ефикасни у стабилним системима где се временске серије карактеришу јасним обрасцима без значајних спољашњих поремећаја [49].

У либерализованим енергетским тржиштима, ARIMA модели се користе за предвиђање кретања цена на дан унапред. Ови модели омогућавају трговцима и произвођачима да унапред реагују на ценовне флукуације, смање ризике и повећају профитабилност [50].

У случајевима производње енергије из соларних и ветроелектрана, ARIMA модели могу се применити за краткорочно предвиђање производње базиране на историјским подацима, посебно када нема доступних екстерних метеоролошких променљивих. Иако нису идеални за високо варијабилне изворе, могу послужити као део хибридних система [51].

Оператери дистрибутивних система користе ARIMA моделе за праћење и анализу потрошње по трансформаторским станицама, улицама или индустријским зонама, како би идентификовали абнормалности и потенцијалне губитке у мрежи [52].

7. Употреба вештачке интелигенције за планирање рада електроенергетског система

У овом поглављу приказана је примена ANN и ANFIS метода за предвиђање стања система. ANN модел се користи за предвиђање потрошње енергије у систему, док се ANFIS модел примењује за предикцију производње енергије из термо- и хидроелектрана, као и емисије CO₂.

Тачност ових модела заснива се на колективном искуству експерата који се баве планирањем ЕЕС-а, као и на бази података која обухвата једночасовна мерења стања система у Србији. Ови подаци садрже сатне вредности производње електричне енергије из различитих извора, потрошње енергије, и релевантних амбијенталних параметара, као што су температура, брзина ветра и соларна радијација.

Како би се проверила ефикасност предложеног ANN модела, његове предикције се пореде са предикцијама добијеним применом ARIMA методе. Развијени предиктивни модели се користе како би се предвидела годишња и дневна потрошња, сезонска варирања у хидро и термо производњи и годишња емисија CO₂. Зависност између потрошње и производње од амбијенталних услова је визуелно приказана у тродимензионом моделу.

Тачност предвиђања ANN модела је процењена графички и нумерички, користећи четири различита типа грешака. Употреба историјских података и увида експерата који су радили на планирању производње омогућава овим моделима да смање грешке будућих предвиђања. Овај приступ минимизује грешку која може доћи услед људског фактора, максимизује знање које долази из људског искуства и успоставља принципе планирања великих ЕЕС-а.

Циљ прорачуна представљеног у овом поглављу је успостављање свеобухватног оквира за организацију електроенергетских система који се може користити у планирању производње и потрошње. Поред тога, процењује се и имплементирају различите методе прогнозирања како би се искористиле јединствене предности сваког принципа. Стога је развијен ANN модел за предвиђања потрошње на основу доступних улазних података из прошлости. На основу ових предвиђања потрошње из ANN и историјских података, развијен је ANFIS модел који ће предвидети производњу термоелектрана и хидроелектрана, као и емисију CO₂. Предвиђања потрошње из ARIMA и ANN модела су укључена у два различита ANFIS модела за предвиђања емисије CO₂, како би се утврдило која предвиђања потрошње дају мању грешку.

Предложени модели су тренирани на бази података која се састоји из мерења потрошње, производње из различитих извора из ЕЕС-а Србије као и амбијенталних услова који утичу на њих (температура, брзина ветра, соларна радијација), доба године, период дана и сат.

Како би се минимизовала грешка предикције, неопходно је одабрати адекватне улазне податке који у себи носе неопходне информације. У овом процесу, подаци који нису били корисни или су били непотпуни или нетачни су елиминисани из базе података како не би имали негативан утицај на тачност предвиђања.

Да би се олакшало поређење са стандардним моделима прогнозирања и истакле предности предложених модела, предвиђања из ANN-а су упоређена са предвиђањима из ARIMA модела.

Резултати ових методологија предикције су приказани графички и нумерички преко грешака које дефинишу одступање стварних вредности од предвиђаних. Приказана је тродимензионална зависност потрошње и производње енергије од различитих амбијенталних услова.

Поглавље је организовано на следећи начин. У потпоглављу 7.1 описан је ANN модел и приказано предвиђање потрошње електричне енергије који се пореде са резултатима из ARIMA модела. Употребом резултата из поглавља 7.1 за предвиђање потрошње из ANN-а, у потпоглављу 7.2 развијен је ANFIS модел за предвиђање производње енергије из термоелектрана и хидроелектрана. Овде су такође приказане тродимензионалне зависности производње енергије из различитих извора и амбијенталних услова. У потпоглављу 7.3, годишња предикција емисије CO₂ је представљена и извршено је поређење резултата који се добијају применом ANN и ANFIS модела. У потпоглављу 7.4 је приказан закључак овог поглавља.

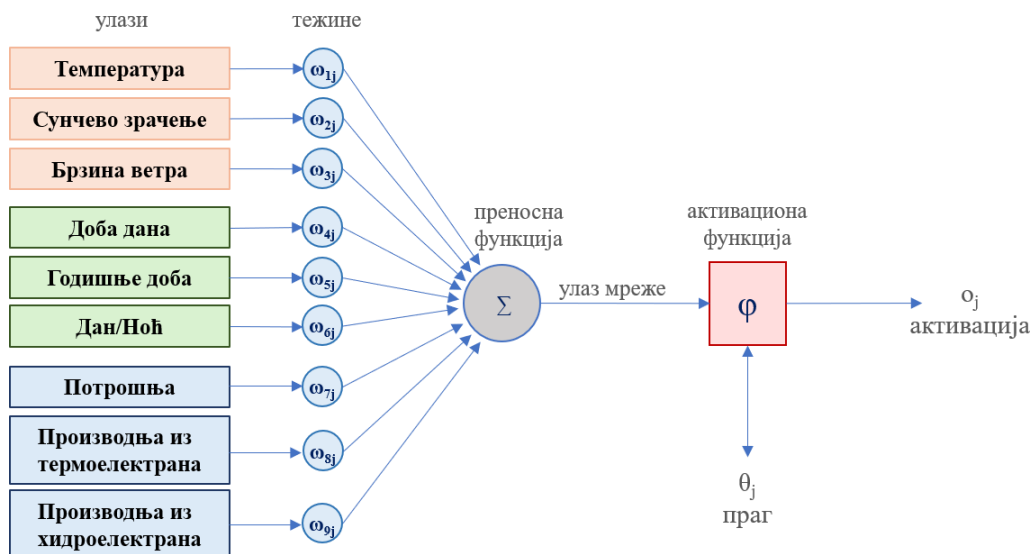
Примарна предност овакве методологије је комбиновање ANN и ANFIS модела. Оваква комбинација минимизује мане сваке методе појединачно и искоришћава њихове предности.

7.1. Формирање ANN модела

При прорачуну у овом поглављу било је неопходно применити метод који омогућава процену излазних величина на основу улазних података, без прецизно дефинисане преносне функције самог система [53].

Примењена је *Feed Forward* ANN за надгледано МУ где су улази x и излази y већ познати, а везе између њих успоставља модел. Како би се сам ANN модел формирао, учи се на великом броју мерних података. Што је већа количина података доступно, то ће тачније бити предикције [54].

На слици Сл.24 приказана је математичка представа ANN-а који је обучаван ради формирања предикција потрошње. На основу великог броја различитих типова улазних података, на слици обележени као *улази*, мрежа се тренира како би се постигла што тачније вредности *излаза*.



Сл.24 – Математички модел ANN-а за предвиђање потрошње

Улазни подаци коришћени при овом прорачуну обухватају производњу електричне енергије из различитих извора, као и потрошњу измерену у електроенергетском систему Србије.

Производња је груписана према типовима извора (термо, хидро и ветро), док су, поред ових параметара, у модел укључени и релевантни амбијентални и временски фактори, као што су температура, брзина ветра, соларна радијација, доба дана, сат и годишње доба. На основу реализованог кода, у модел је уведен временски помак од једног сата, тако да се предикција у тренутку t формира на основу расположивих улазних података и вредности из претходног часа ($t-1$). При томе, потрошња која улази у модел представља вредност из претходног временског корака, односно претходну предикцију, чиме се успоставља зависност између узастопних временских тренутака и омогућава прецизније предвиђање будућих вредности.

На слици Сл.25 види се процес формирања, тренирања и тестирања ANN модела у циљу добијања предикције потрошње задовољавајуће тачности. Формирање ANN модела је извршено кроз три фазе, визуелно обележене бојама на поменутој слици.

Подаци првенствено морају бити припремљени и селектовани за обраду. У овом процесу подаци се деле на улазне, x , и излазне, y . Формирана база података пролази кроз процес нормализације како би се омогућило поређење вредности различитих параметара, без да њихова апсолутна величина несразмерно утиче на значај појединих улаза.

У овом поглављу нормализација је извршена применом MinMax технике [28]. У супротном, поједини параметри би могли имати већи утицај искључиво због већих нумеричких вредности. Иако се у литератури често препоручује да се нормализација врши искључиво на тренирајућем скупу, у овом раду је примењена униформна нормализација ради једноставније имплементације и уједначене обраде података. Оваквим приступом постиже се стабилност обучавања модела. С обзиром на то да се ради о подацима познатог опсега из електроенергетског система, овакав приступ не утиче значајно на тачност и поузданост добијених резултата

База података је подељена на део за тренирање који износи 70% укупног броја података и део за тестирање који је преосталих 30% базе података, што је честа пракса у применама ANN-а и МУ-а. Овим се задржава довољна количина различитих података за тренирање док се обезбеђује скуп података на којима се може тестирати истренирани модел. Како се подаци ни у једном скупу не би груписали према неком типу вредности, примењен је Монте Карло алгоритам. Он омогућава насумичан одабир података при дељењу на два скупа, тренирајућег и тестирајућег. У супротном би могло да се деси да је модел трениран на одређеној врсти података која је поделом изузета из базе за тренирање. На пример да је комплетан тестирајући скуп формиран од мерних података из зимског периода, а да се модел тренирао на периодима јесени, лета и пролећа. Овим процесом не само да би грешка при тестирању модела на зимским подацима била превелика, него модел не би био адекватан за целокупну годишњу предикцију.



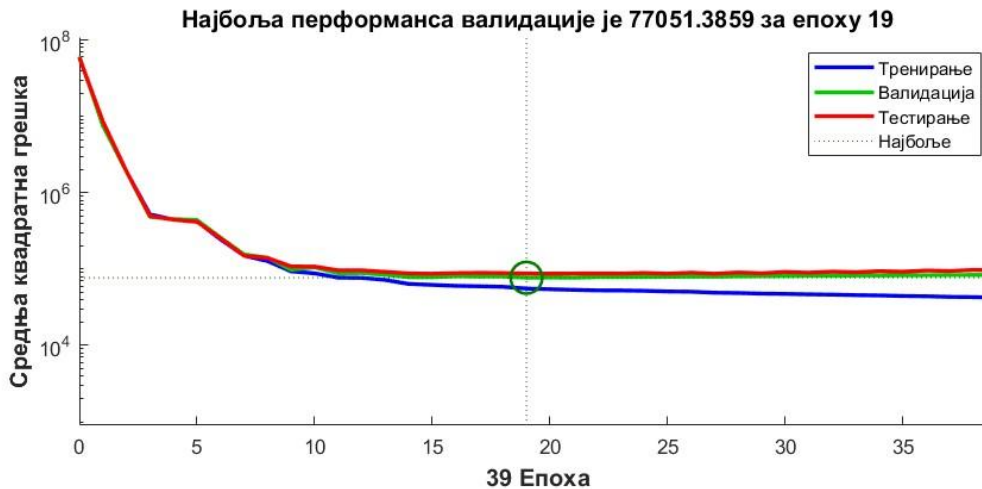
Сл.25 – Алгоритам учења ANN модела.

Одабрани хиперпараметри ANN модела обухватају број скривених слојева, број неурона по слојевима, тип активационе функције и оптимално време тренирања модела. У овом раду није коришћена рекурентна неурална мрежа, већ вишеслојна feedforward ANN структура. Увођењем временског помака у улазним подацима омогућено је да модел индиректно узме у обзир временску зависност, чиме се постиже ефекат сличан ауторегресионом моделу.

Након тренирања ANN модела, на основу израчунате грешке предикције утврђене су оптималне вредности хиперпараметара, које су наведене у Таб.6. Укупна база података садржи 8760 једночасовних узорака и подељена је на тренирајући, валидациони и тест скуп у односу 70%–15%–15%. Регулациони параметри, као што су L2 регуларизација и рано заустављање тренинга, користе се у циљу спречавања преобучавања и побољшања способности генерализације ANN модела.

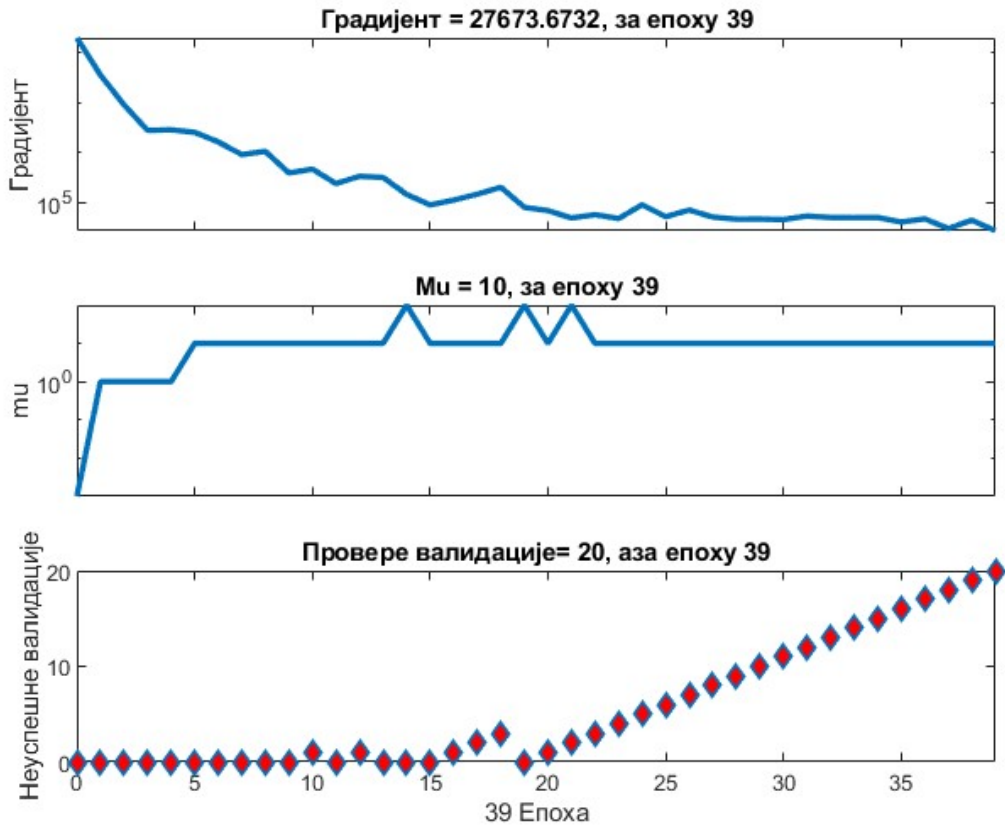
Сл.29 – Годишња предикција потрошње из ANN моделаСл.29 приказује промену средње квадратне грешке током процеса тренирања ANN модела, за тренинг и валидациони скуп података. Уочава се да грешка нагло опада у почетним епохама, што указује на брзо

прилагођавање модела улазним подацима. Након тога, смањење грешке постаје постепеније, све до достизања минималне вредности на валидационом скупу у 19. епохи. Након ове тачке долази до престанка побољшања валидационе грешке, што је довело до заустављања тренинга применом критеријума раног заустављања (early stopping). Мала разлика између тренинг и валидационе грешке указује на добру способност генерализације модела и одсуство израженог преобучавања.




Сл.26 – Промена средње квадратне грешке током тренирања ANN модела

Сл.27 приказује ток промене градијента, параметра μ и броја неуспешних валидација током процеса тренирања ANN модела. Уочава се да вредност градијента опада током епоха, што указује на постепену конвергенцију алгоритма ка оптималном решењу. Параметар μ задржава релативно мале вредности, уз мање осцилације током тренинга, што указује на стабилан рад Levenberg–Marquardt алгоритма у ефикасном режиму обучавања. Са друге стране, број неуспешних валидација почиње да расте након одређеног броја епоха, што указује да даље тренирање не доводи до побољшања перформанси на валидационом скупу. Достизањем максималног броја неуспешних валидација, тренинг се аутоматски зауставља, чиме се спречава појава преобучавања модела.



Сл.27 – Промена градијента, параметра μ и броја неуспешних валидација током тренирања ANN модела.

Сл.28 приказује резултате регресионе анализе ANN модела, кроз поређење стварних (циљних) и предвиђених вредности за тренинг, валидациони, тест и укупни скуп података. Уочава се да су вредности високо корелисане, што потврђују коефицијенти корелације који износе око 0.95 за тренинг, око 0.94 за валидациони и око 0.92 за тест скуп, док је за укупан скуп вредност око 0.94. Тачке су углавном распоређене око идеалне линије $Y = T$, што указује на добру способност модела да апроксимира зависност између улазних и излазних параметара. Мала разлика између резултата на тренинг, валидационом и тест скупу указује на добру генерализацију модела и одсуство значајног преобучавања. Иако је уочено благо одступање од идеалне зависности, укупни резултати показују да модел успешно предвиђа излазне вредности.



Сл.28 – Регресиона анализа ANN модела на тренинг, валидационом, тест и целокупном скупу података.

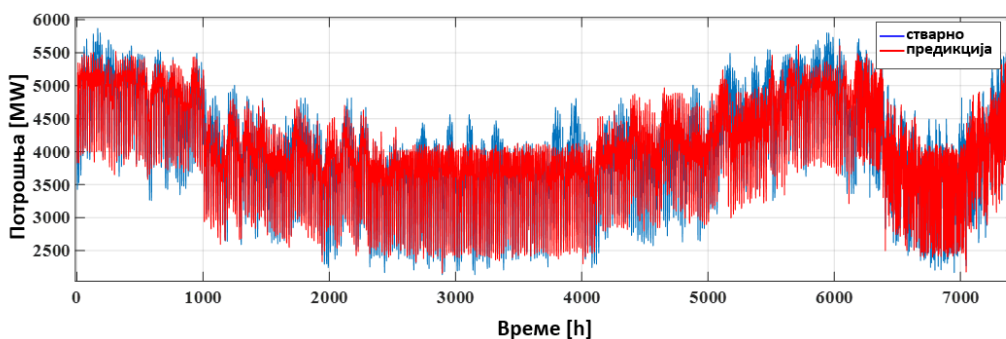
Обучавање мреже вршено је у *batch* режиму, при чему је максималан број епоха постављен на 1000. *Mini-batch* приступ није коришћен, већ се у свакој епохи користи цео тренирајући скуп података.

Таб.6– Параметри тренираног ANN модела

Параметар	Вредност				
Број скривених слојева	5				
Број неурона по слојевима	први	други	трећи	четврти	пети
	24	12	12	12	12
Епохе тренинга	39				

7.2. Резултати предвиђања потрошње

Обучени ANN модел се користи за предвиђање потрошње. Резултат годишњег предвиђања потрошње за податке коришћене у овом прорачуну је приказан на слици Сл.29. Црвена линија представља предвиђене вредности, док су плаве линије стварне вредности са којима се предвиђене упоређују. Графички, преклапање ових линија показује мала одступања између ове две вредности. Грешке направљене овим предвиђањем могу се видети у Таб.7. Оне показују сличне налазе, а грешке су довољно мале да омогућавају задовољавајућа предвиђања. Будући да је MAPE процентуална метрика, лакше је разумети и упоређивати. У наставку анализе, она ће служити као репрезентативна мера грешке.



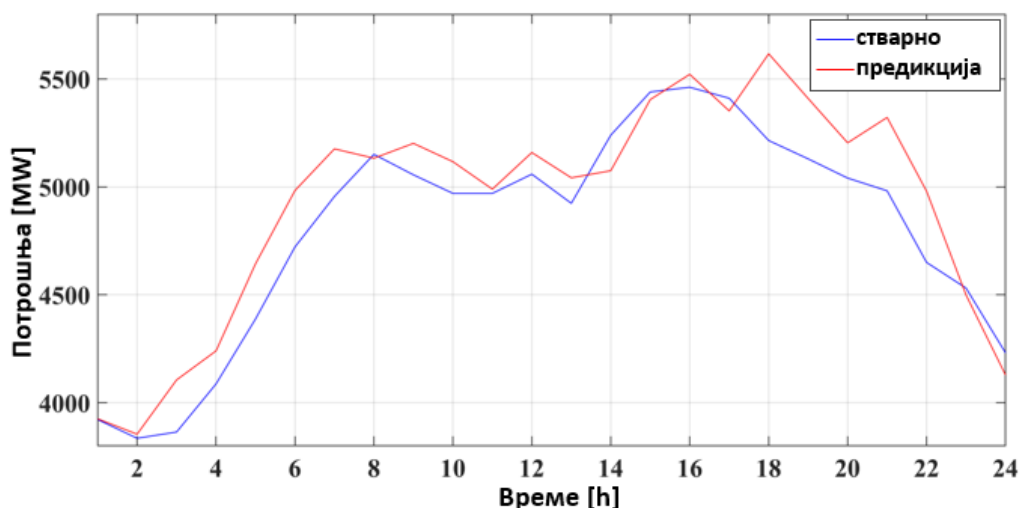
Сл.29 – Годишња предикција потрошње из ANN модела

Прорачуната вредност MAPE је у рангу MAPE < 10%, па се закључује да је овај модел задовољио високу тачност.

Таб.7 – Грешке предикције ANN модела

Врста грешке	MAE [MW]	MSE [MW ²]	RMSE [MW]	MAPE [%]
Вредност грешке	229,91	$7.8 \cdot 10^4$	295,45	5,64

За предикцију преко краћег временског периода, приказана је дневна предност предикције. на Сл.30. Овде, плава линија такође представља стварне вредности, док су црвена предвиђене. Што су ове линије ближе једна другој, већа је тачност предикције. Посматрајући како ове линије имају приближан облик и пикове, предикција је на задовољавајућем нивоу јер девијације, иако постоје, нису значајне. Ово се види и кроз вредност MAPE која износи 5,64 % за целу дневну потрошњу.



Сл.30 – Предикција дневне потрошње

Како би се имао увид у нумеричке вредности, део података за дневну потрошњу је приказан у Таб.8. Овде су приказани тачни улазни подаци који се састоје из брзине ветра, температуре, годишње доба, доба дана и сат су приказани, као и стварна и предвиђана потрошња електричне енергије. За сваку предвиђану вредност, апсолутна процентуална грешка је прорачуната. Ово је пандам грешки MAPE, али се не прорачунава за скуп података него за један пар вредности.

Таб.8 – Предикције ANN модела за један дан у зимској сезони

Улази					Стварна потрошња [MW]	Предвиђана потрошња [MW]	MAPE [%]
Сат	Дан/Ноћ	Годишње доба	Температура [°C]	Брзина ветра [m/s]			
1	ноћ	зима	1,6	0,07	3922	3925,31	0,08
2	ноћ	зима	1,6	0,12	3835	3853,92	0,49
3	ноћ	зима	1,6	0,27	3864	4105,49	6,25
4	ноћ	зима	1,6	0,06	4087	4240,05	3,74
5	ноћ	зима	1,6	0,16	4388	4643,74	5,83
6	ноћ	зима	1,6	0,38	4722	4983,40	5,54
7	дан	зима	1,6	0,09	4956	5176,33	4,45
8	дан	зима	2,1	0,13	5107	5133,40	2,07
9	дан	зима	2,1	0,18	5056	5201,82	2,88
10	дан	зима	2,1	0,21	4970	5116,99	2,93
11	дан	зима	2,1	0,19	4970	4989,64	0,40
12	дан	зима	1,6	0,19	5059	5159,29	1,98
13	дан	зима	1,6	0,36	4924	5042,22	2,40
14	дан	зима	2,1	0,98	5240	5075,14	3,15
15	дан	зима	2,1	1,09	5440	5384,82	0,65
16	дан	зима	2,1	1,03	5462	5521,90	1,09
17	дан	зима	2,1	1,02	5411	5352,14	1,09
18	дан	зима	2,1	1,02	5215	5617,00	4,02
19	ноћ	зима	2,1	0,27	5130	5409,85	5,46

20	ноћ	зима	2,1	0,28	5260	5204,33	0,90
21	ноћ	зима	2,1	0,25	4982	5322,00	3,00
22	ноћ	зима	2,1	0,05	4650	4980,00	3,30
23	ноћ	зима	2,1	0,03	4531	4498,90	0,71
24	ноћ	зима	2,1	0,11	4231	4128,33	2,43

Као што се види са графичког приказа на сликама Сл.29 и Сл.30, разлике између стварних и предвиђених вредности су мале. Узимајући у обзир ово и ниску вредност нумеричких грешака, ова врста предвиђања потрошње је високе тачности.

7.3. Поређење ANN и ARIMA предвиђања потрошње

Како би се потврдила тачност предикције ANN модела, поређена је са класичном статистичком предиктивном методом, ARIMA. ARIMA је линеаран модел који се користи на серијама података уз претпоставку да су ти подаци стационарни. Оба модела су развијена за исту базу података. Четири типа грешака су прорачуната како би се приказало одступање између ова два модела, приказана у Таб.9.

Таб.9 – Поређење грешака предикције за ANN и ARIMA моделе

	ANN	ARIMA
MAE [MW]	229,91	401,50
MSE [MW²]	$8,416 \cdot 10^4$	$16,6254 \cdot 10^4$
RMSE [MW]	295,45	407,74
MAPE [%]	5,64	10,0025

Након посматрања варијације у грешкама предвиђања, примећује се да су грешке предикције 50% мање у односу на грешке предикције из ARIMA модела. Због тога се предикције потрошње добијене ANN моделом користе као део базе података за даљи прорачун и формирање ANFIS модела за наредне предикције.


7.4. Тродимензионална зависност производње електричне енергије од амбијенталних услова

Како би се дефинисао утицај амбијенталних услова на производњу електричне енергије, посматрана је тродимензионална зависност потрошње енергије, производње из различитих извора и амбијенталних услова. На основу ових зависности посматра се доминантност параметара који утичу на производњу и самим тим дефинишу амбијентални услови који ће ући у базу података за тренирање модела који предвиђа производњу електричне енергије.


Тродимензионална зависност производње електричне енергије од температуре и брзине ветра приказана је на Сл.31. Овакве зависности графички представљају преносну функцију између улаза и излаза ANFIS модела. Овакав начин приказивања резултата омогућава увид у очекиване излазе ANFIS модела на основу произвољних улаза.

Из ових графика примећује се да са порастом температуре, расте потрошња енергије, а самим тим производња мора пратити овај тренд. За ниже температуре и нижу потрошњу, производња из термоелектрана је такође нижа. За производњу из хидроелектрана односи трендова су различити, као што је приказано на Сл.32. Ниже температуре пропраћене су нижом потрошњом

енергије, али је производња већа него при вишим температурама када је потрошња покривена производњом из термоелектрана.




(a)




(б)

Сл.31 – Тродимензионална зависност производње из термоелектрана од потрошње и (а) – температуре; (б) – ветра



(a)



(б)

Сл.32 – Тродимензионална зависност производње из хидроелектране од потрошње и (а) – температуре; (б) – ветра

За производњу из термоелектрана, зависност од брзине ветра показује да при већој брзини, производња расте јер мора да пропрати тренд пораста потрошње.

Како расте брзина ветра, тако расту и захтеви за енергијом од стране потрошача. Ове захтеве покрива примарно производња из термоелектране, тако да производња из хидроелектрана само незнатно варира. У већим ЕЕС, где је производња из ветроелектрана значајнија, ова зависност би више варијала. Ово значи да ће се приказане зависности мењати за друге електроенергетске системе и предиктивни модели би морали бити тренирани за сваки од њих.

7.5. Предикција производње из термоелектрана и хидроелектрана помоћу ANFIS–а

У овом поглављу, ANFIS је употребљен како би пратио искуства стручњака који се баве електроенергетским системима и доносио одлуке на основу њиховог дугогодишњег рада како би предвидео потрошњу из хидро и термоелектрана. На тај начин, одређује се проценат удела сваке врсте производње неопходан за адекватно постизање балансираног система. ANFIS користи фази правила како би ова људска искуства уврстио у базу података из које се добијају предвиђања за будућност.

ANFIS је овде кориштен јер у поређењу са другим фази техникама, има ефикасан начин учења. Обучавање му је брже, а методологија је једноставнија за употребу. Иако је један од првих интегрисаних модела, показао се као најбољи у апроксимацији, са најбржом конвергенцијом у поређењу са другим неуро–фази моделима.

Главна предност овог метода је та што параметри функције припадности нису насумично изабрани. Они су дефинисани на основу улазних и излазних података. Параметри који су повезани преко функција припадности се мењају за време учења. ANFIS користи хибридни алгоритам који комбинује методу пропагације грешке уназад са методом најмање квадратне грешке како би створио фази систем способан за учење. Базирано на овом принципу, функција припадности је итеративно подешавана према бази података која садржи улазне и излазне вредности [36].


Резултат предвиђања потрошње на основу ANN модела који је добијен у поглављу 7.2, уврштен је у базу података на основу које се обучава ANFIS модел који треба да предвиђа производњу електричне енергије. Циљ је да се предвиђа производња електричне енергије из два различита извора, термо- и хидро-електрана, као и да се предвиђа емисија CO₂ на сатном нивоу за дефинисани временски период. Резултат оваквог модела је поседовање информација о потреби за активацијом одређене врсте енергетског извора за одређени период и количине енергије коју треба да допреме. Поседовањем ових информација, ток енергије би се могао организовати унапред чиме би се олакшао рад стручњака и потенцијално избегли већи проблеми.

У овом прорачуну, развијена су два ANFIS модела у MATLAB софтверу. Један за предвиђање производње из термоелектрана, а други за предвиђање из хидроелектрана. Оба модела имају исте типове и број улаза који су приказани у Таб.10.

Таб.10– Улазни и излазни подаци ANFIS модела

Улази	Израз ANFIS модела за термоелектране	Израз ANFIS модела за хидроелектране
Сат	Количина енергије неопходна на сатном нивоу из термоелектрана	Количина енергије неопходна на сатном нивоу из хидроелектрана
Обданица/ноћ		
Температура		
Брзина ветра		
Предвиђана производња из ANN модела		

Сл.33 приказује архитектуру ANFIS модела за предвиђање производње из термоелектрана. Овде се види који су улазни подаци кориштени и који је излаз ANFIS модела. ANFIS модел за предвиђање из хидроелектрана је исте структуре.



Сл.33 – Структура ANFIS модела

7.6. Резултати предикције производње помоћу ANFIS модела

База података која се користи за обуку ANFIS модела је подељена у четири скупа према годишњим добима. Познато је да временске прилике и људске навике у одређеним годишњим периодима директно утичу на захтеве потрошње електричне енергије. Како би се модел поједноставио, а тиме му се подигла тачност, предвиђања су вршена за пролеће, лето, јесен и зиму, појединачно.


ANFIS модел је обучаван на делу базе података за тренирање који одговара сезони и тестиран на тестирајућем делу података из исте сезоне. Грешке предвиђања за производњу из хидро- и термо-електрана, изражене преко MAPE, приказане су у Таб.11 за свако годишње доба из вредности појединачних грешака. На Сл.34 и Сл.35 дати су примери по два дана из сваког годишњег доба графичког приказа ових предвиђања. Овде се види одступање између предвиђаних (црвена линија) и стварних (плава линија) вредности. Иако постоји нумеричко одступање међу појединим вредностима, тренд промене је исти. Примећује се да је највеће одступање предвиђања и стварних вредности за термоелектране у летњем периоду, када су и температуре и захтеви за производњом највећи услед повећаног оптерећења система изазваног хлађењем док остатак годишњих доба има приближну девијацију. За хидроелектране, највећа грешка предвиђања је у јесен, али и за остале сезоне тренд је сличан.

Предикције производње из различитих извора енергије је кључни за планирање рада система у будућим временским периодима. Са тачном предикцијом, оператори система могу имати информације о сатној потрошњи, чиме би електране могле бити припремљене да одговоре сатним захтевима. Оваква припрема потпомаже спречавању потенцијалних незгода које би могле да се десе, уколико је, на пример, захтевана активације термоелектрана, али особље није спремно да реагује у моменту. Поседовањем сатних захтева месецима унапред омогућава бољу организацију система и експерата, чиме се повећава сигурност у поузданост самог електроенергетског система.


Таб.11– Сезонске вредности MAPE за производњу из хидро- и термоелектрана

	Производња хидроелектрана	Производња термоелектрана
MAPE _{Зима} [%]	2,01	2,12
MAPE _{Пролеће} [%]	2,54	2,51

MAPE _{Лето} [%]	3,12	3,51
MAPE _{Јесен} [%]	3,23	1,94



Сл.34 – Предикција производње термоелектрана за а) Зиму; б) Пролеће; в) Лето; г) Јесен




Сл.35 – Предикција производње хидроелектрана за а) Зиму; б) Пролеће; в) Лето; г) Јесен

При прорачуну MAPE за податке по појединачним сезонама, вредност грешке за свако предвиђање износи испод 10%. Кумулативна MAPE на нивоу целокупне године износи 2,73% за производњу из хидроелектрана, односно 2,52% за термоелектране. Ови резултати указују на висок ниво прецизности предвиђања, у складу са критеријумом MAPE < 10%.

7.7. Резултати предикције емисије CO₂

Са порастом глобалне индустријализације и претераном експлоатацијом необновљивих извора енергије, емитују се многи гасови са ефектом стаклене баште. Ово доводи до пораста глобалне температуре и изазива велики број еколошких проблема [58]. Растућа глобална температура већ је проузроковала оштећења животне средине, као што су нестанак појединих врста, губитак биодиверзитета, суше, поплаве, шумски пожари, закисељавање океана, топљење поларних глечера и пораст нивоа мора [59]–[61].


Иако различити сектори, попут саобраћаја, грађевинарства и индустријских процеса, доприносе укупним емисијама, највећи удео у Републици Србији (око 67%) потиче управо из енергетског сектора, што јасно указује на његову доминантну улогу у укупном угљеничном отиску земље. Ови подаци су приказани на Сл.36 [62].



Сл.36 – Емисија CO₂ по изворима у Србији


Пораст емисије гасова са ефектом стаклене баште подстакао је бројна истраживања која анализирају утицај електрана и производње енергије на емисију [62]–[66]. Тачно одређивање количине емисије CO₂ је комплексно, јер електрична енергија потиче из више различитих извора [67].

Познавањем будућих вредности емисије CO₂ могу се благовремено предузети мере за њено смањење. С обзиром на јаку повезаност између производње енергије и емисије CO₂, модел предвиђања може се обучити на истој бази података која је коришћена и за прогнозу производње. Развијени модел заснива се на ANFIS методологији и омогућава предвиђање емисије CO₂ на сатном нивоу, како за један дан, тако и за целу годину унапред. Резултати предикције емисије CO₂ на основу базе податакака проистекле из ANN модела предикције за потрошњу су приказани Сл.37, где се може уочити да су одступања између предвиђених и стварних вредности минимална.




Сл.37 – *Годишња предикција емисије CO₂*

Сл.38 приказује промену средње квадратне грешке (MSE) током процеса тренирања ANN модела за тренинг, валидациони и тест скуп података. Уочава се брз пад грешке у почетним епохама, након чега следи стабилизација све до достизања минималне вредности на валидационом скупу у деветој епохи. Након тога не долази до даљег побољшања, што је довело до заустављања тренинга применом критеријума раног заустављања. Сличне вредности грешке за све скупове података указују на добру способност генерализације модела.



Сл.38 – *Промена средње квадратне грешке током тренирања ANN модела*

Сл.39 приказује ток промене градијента, параметра μ и броја неуспешних валидација током процеса тренирања ANN модела. Уочава се да градијент опада током епоха, што указује на конвергенцију алгоритма. Параметар μ расте и достиже више вредности, што је карактеристично за завршну фазу обучавања. Број неуспешних валидација почиње да расте након одређене епохе, што указује да даље тренирање не доприноси побољшању модела, те се тренинг зауставља применом раног заустављања.




Сл.39 – Промена градијента, параметра μ и броја неуспешних валидација током тренирања ANN модела.

Сл.40 приказује резултате регресионе анализе ANN модела кроз поређење стварних и предвиђених вредности за тренинг, валидациони, тест и укупни скуп података. Уочава се веома висока корелација између вредности, при чему коефицијенти корелације за све скупове износе око 0,99. Тачке су скоро у потпуности распоређене дуж идеалне линије $Y = T$, што указује на високу тачност модела. Мала одступања и уједначени резултати на свим скуповима потврђују добру генерализацију и стабилност обученог модела.

Хиперпараметри ANN модела обухватају архитектуру мреже, број неурона и параметре тренирања. У раду је коришћена вишеслојна feedforward мрежа, без рекурентних елемената, док је временска зависност уведена применом временског помака у улазима.

Након тренирања, на основу грешке предикције одређене су оптималне вредности хиперпараметара. Скуп од 8760 узорака подељен је на тренинг, валидациони и тест скуп (70%–15%–15%), уз примену L2 регуларизације и раног заустављања ради спречавања преобучавања.



Сл.40 – Регресиона анализа ANN модела на тренинг, валидационом, тест и укупном скупу података.

Помоћу модела који врши предикцију CO₂ могуће је предвидети годишњи ниво емисије угљендиоксида са грешком од MAPE која је 1,27%, што указује на висок степен прецизности предвиђања. ANN модел је трениран, при чему је на основу прорачунате грешке утврђено да оптималне вредности излаза одговарају параметрима тренирања дефинисаним у Таб.12. Као улазни параметри у модел коришћени су сат, информација о делу дана (дан/ноћ), годишње доба, температура, брзина ветра и потрошња електричне енергије.

Таб.12– Параметри тренираног ANN модела

Параметар	Вредност			
Број скривених слојева	4			
Број неурона по слојевима	први	други	трећи	четврти
	48	24	12	12
Епохе тренинга	29			

Висока тачност овог модела представља потенцијално решење за будуће планирање емисија CO₂, јер омогућава доношење информисаних одлука о мерама за њихово смањење.

У даљој анализи представљена је још једна предност предикције употребом ANN модела у поређењу са ARIMA моделом. Развијена су два ANFIS модела за предикцију емисије CO₂. Један модел је обучаван на бази података у којој су вредности потрошње добијене применом ANN модела, док је други ANFIS модел обучаван на бази података формираној на основу предикције потрошње применом ARIMA модела.

При предикцији емисије CO₂, уочено је да модел заснован на ANN предикцији потрошње постиже мању грешку MAPE од 5,64%, што указује на боље перформансе у односу на друге приступе. Ова грешка се даље преноси у процес предикције емисије, чиме се утиче на укупну тачност модела. Ова два модела су међусобно повезана, јер се излаз ANN модела користи као улаз у ANFIS модел. Уколико је иницијални ANN модел високе тачности, добијене предикције представљају поуздану основу за даље моделирање, што резултира високом тачношћу ANFIS модела. Насупрот томе, у случају ниже тачности ANN модела, грешке се преносе на ANFIS модел, што доводи до смањења укупног квалитета предикције.

Како би се дефинисао утицај модела предикције потрошње, из ARIMA-е и ANN-а, урађена је следећа анализа. Излазна предикција потрошње на основу ARIMA модела је кориштена за други ANFIS модел који треба да предвиђа емисију CO₂. Грешке предикција ова два ANFIS модела су приказане у Таб.13.

Таб.13–Грешка MAPE за годишњу предикцију емисије CO₂ употребом различитих база података

	Потрошња из ANN модела предикције	Потрошња из ARIMA модела предикције
MAPE	1,27 %	8,35 %

За оба ANFIS модела, остатак базе података на основу које је обучаван, је остао идентичан. Једино што се мењало су вредности предвиђане потрошње проистекле из ANN и ARIMA модела. Примећује се да вредност потрошње електричне енергије има значајан утицај на тачност предвиђања емисије CO₂. Иако грешка при предвиђању кориштењем базе података са предикцијама из ARIMA модела спада у грешке ниске вредности, употребом вредности које су последица ANN предвиђања ова грешка се значајно смањује. Ово је исход ком се при развијањима предиктивних модела константно тежи, мања грешка предикције. Постизање мањих грешака у предвиђању омогућава већу флексибилност у дефинисању и примени стратегија за смањење емисије CO₂. Овим прорачуном поново су потврђене предности метода предвиђања заснованих на ANN–у у односу на класичне приступе прогнозирању.

Како се ЕЕС развијају интеграцијом нових компоненти као што су обновљиви извори енергије, системи за складиштење енергије и купаца–произвиђача, обезбеђивање њиховог ефикасног функционисања представља све већи изазов за стручњаке. Иако су ови напретци од суштинског значаја и доносе бројне предности, они истовремено уносе додатну сложеност која захтева примену напредних стратегија управљања и координације.

Ослањајући се на богато искуство и обимне податке из досадашњег рада електроенергетских система, могуће је развити предиктивни модел који омогућава прогнозу производње енергије по изворима, као и увид у утицај сваког од њих. У овом истраживању дефинисана је и тестирана јединствена комбинација ANN и ANFIS методологија. Њиховом интеграцијом искоришћене су предности оба приступа, што је резултирало минималном грешком у предвиђању. Модел ANN-а, који узима у обзир амбијенталне услове, време и енергетске параметре, постигао је прецизност

са грешком од само 5,64%. Иако је методологија у раду [69] имала мању грешку од 4,57%, она је обухватала само предвиђање потрошње. У овом истраживању, предвиђање емисије CO₂ применом ANFIS модела обученог на бази података из ANN модела дало је грешку од свега 1,27%. Методолошки приступи попут Holt–Winters из рада [70] постигли су нижу грешку (0,75%), али нису предвиђали целокупно стање система. То потврђује кључну предност предложене методологије која је могућност предвиђања свеобухватног стања система и издвајања критичних информација као што је емисија CO₂.

Интеграција знања и искуства диспечера у процес обучавања модела представља један од најзначајнијих доприноса овог истраживања. Диспечери поседују дубоко стручно знање и способност доношења одлука засновану на искуству из реалних оперативних ситуација. Уношењем тих увида у процес обучавања ANN модела, добијене су прецизније прогнозе и боље разумевање суптилних шаблона понашања система који нису увек видљиви у подацима. Овим приступом не само да је побољшана тачност предвиђања, већ је модел постао отпорнији и прилагодљивији динамичним и сложеним условима рада у енергетским системима.

Предвиђање годишње емисије CO₂ постигнуто је са минималном грешком захваљујући интегрисаној употреби ANN и ANFIS модела. Ови резултати су посебно значајни у времену глобалних настојања да се смањи емисија гасова са ефектом стаклене баште и побољша стање животне средине. Правовременим предвиђањем емисије могу се благовремено планирати мере ублажавања, оптимално распоредити финансијски ресурси и организовати функционисање система тако да се укупне емисије минимизују.

Резултати предикције из овог поглавља представљају улазне податке за анализу у поглављу 10. Предикције производње електричне енергије из различитих извора на територији Србије, као и предикције потрошње, имплементирани су у алгоритам развијен у поглављу 10. Ово представља први корак у формирању улазних података за даљу анализу

8. Предиктивно моделовање за процену стања ЕЕС–а

Прорачун токова снага је кључна анализа за дефинисање стања електроенергетског система. Опскрбљује инжењере и операторе система знањем о токовима снага, предвиђање потенцијалних проблема и даје могућност да систем функционише ефикасно и сигурно. Планирање енергетског система, дизајн, контрола, анализа сигурности и стабилности се ослањају на прорачун токова снага [71]–[74]. Константна потреба да се одржи баланс између производње и потрошње захтева решавање комплексних, нелинеарних оптимizacionих проблема сталним прорачунавањем токова снага на дневном, сатном па чак и минутном нивоу[1]. При прорачуну токова снаге, многи прорачуни уводе одређен ниво апроксимације и занемарења како би се дошло до корисних резултата [75]. Прорачун токова снага се ради до нивоа тачности од 0,1% грешке оптималности, али уз занемарења зависности од амбијенталних услова[1].

Растућа количина обновљивих извора енергије и осталих аспеката технологије у системима значајно компликује прорачун токова снага и анализу самог система. Многа истраживања имплементирају методе машинског учења и циљу решавања овог проблема. Од процене поузданости система и контроле [76], до прорачуна оптималних токова снага [77] и употребе машинског учења информисаног претходним знањима са обрадом велике количине података [78].

Предности ANN-а и метода машинског учења у погледу времена прорачуна показане су у бројним радовима. У раду [79] анализирана је нова архитектура *Heterogeneous Multi-view Graph Neural Network* заснована на механизму пажње (attention-based). Архитектура заснована на граф неуралним мрежама примењена је у раду [80], док је у раду [31] алгоритам за прорачун токова снага интегрисан у процес обуке модела машинског учења. Ови радови успостављају директну везу између вештачке интелигенције и оптимизације у решавању проблема токова снаге. Међутим, прорачуни токова снаге у наведеним истраживањима спроведени су коришћењем класичних метода, без уважавања утицаја амбијенталних услова. Утицај амбијенталних услова значајно утиче на прорачун токова снага иако се у већини приступа занемарује. Циљ прорачуна у овом поглављу је да уврсти и амбијенталну зависност елемената система, као и потрошње и производње, у процес прорачуна токова снаге.

У [81] приказан је алгоритам који уважава термичку зависност надземног вода од амбијенталних услова на прорачуне токова снага. Прорачун је извршен за један временски тренутак, при чему је уочено добро поклапање са стварним стањем система. Ипак, упркос постигнутој тачности, овакав приступ није погодан за анализу на сатном нивоу, с обзиром на повећану рачунску сложеност. Овакви прорачуни имају значајно дуже време неопходно за прорачун услед чега нису примењиви за планирање у реалном времену. Приступ зависности система од амбијенталних услова је примењен у овом поглављу да би се добиле база података за обуку ANN модела који би предвиђао стање система са мањим временом потребним за рачун, а веће тачности попут прорачуна који уважава амбијенталну зависност надземних водова. У [82] развијен је систем рачунања токова снага уз уважавање амбијенталних услова уз анализу временске зависности прорачуна.

Уврштавањем зависности од амбијенталних услова у природу производње, потрошње и надземних водова, прорачун токова снага би дао резултате који тачније рефлектују слику стварног стања система. Ово би омогућило инжењерима и операторима система да доносе одлуке утемељене на већој количини корисних информација и тиме оптимизују рад система. У

овом прорачуну уважене су овакве зависности елемената система. Ово укључује зависност од доба дана, периода у години и амбијенталних услова на параметре елемената система, потрошњу и производњу из соларних панела.

Употребљен је термални математички модел за надземне водове који уважава варирање реактансе и резистансе проводника у односу на соларну ирадијацију, брзину ветра и температуру околине.

Овакав тип прорачуна, који је приближнији стварним условима, захтева значајно време и није погодан за примену у реалном времену. Како би се овај недостатак превазишао, алгоритам прорачуна је унапређен. Прорачун који уважава утицај амбијенталних услова извршен је једнократно, на почетку, за све доступне мерне вредности, обухватајући промене у оптерећењу, производњи и елементима система током посматраног временског периода.

Резултати овог прорачуна чине базу података за обучавање ANN модела. Након обучавања, модел се користи за предикцију стања електроенергетског система без потребе за поновним извршавањем сложеног прорачуна, с обзиром на то да је утицај амбијенталних услова већ имплицитно садржан у подацима на којима је модел обучен.

Оваквим приступом постиже се висока тачност уз значајно смањење времена потребног за прорачун, што омогућава ефикасније планирање система и брже доношење одлука од стране оператора.

Главни доприноси који овакав алгоритам пружа су:

- уважавање динамичког утицаја амбијенталних услова на стање електроенергетског система.
- уважавање промене потрошње и производње из соларних панела са амбијенталним условима.
- развијање ANN модела који уважава промене у параметрима система и варијацију у производњи и потрошњи енергије.
- постизање баланса између потребе за већом тачношћу, а мањим временом прорачуна чиме се омогућава операторима система да са сигурним и брзо доступним информацијама доносе ефикасне одлуке за оптимизацију рада мреже.

Предложени алгоритам је тестиран на реалној дистрибутивној мрежи напонског нивоа 35 kV са 28 чворова, лоцираној у Банату, при чему су коришћена стварна мерења потрошње и производње са те мреже.

8.1. Развијени алгоритам

Како би се оформио комплетан процес за предикцију стања система, развијени модел се састоји од споја класичног прорачуна токова снага и уважавања зависности система од околних услова.

Основни прорачун токова снага изведен је применом Ширмохамаци методе, која је изабрана због добре тачности и мањег рачунског оптерећења. У оквиру овог прорачуна, у модел су интегрисане временски и амбијентални услови како би се параметри елемената мреже (отпорност, реактанса и губици) динамички прилагођавали реалном стању система.

Оваквом интеграцијом добијен је модел који задржава високу прецизност класичног прорачуна, али истовремено значајно скраћује време симулације, јер се резултати ових прорачуна користе као база за тренирање ANN-а. ANN модел затим омогућава брзу предикцију стања система за

будуће временске интервале, без потребе за поновним комплетним термичким и електричним прорачунима.

Резултат оваквог приступа је модел високе тачности и ефикасности, који реалније одражава стање система у променљивим условима рада.

Развијени алгоритам је приказан на Сл.41. Логички је подељен у два сегмента:

1. Креирање базе података за обучавање ANN модела – прорачуни токова снага,
2. Обучавање ANN модела за предикцију стања система.

Креирање базе података на којој се обучава ANN модел је процес у ком се одвијају прорачуни токова снага за дефинисану мрежу уз уважавање услова са којима се вредности у тој мрежи мењају. Овај прорачун се извршава за сваки сат у току једне године за коју су доступни мерни подаци стања система.


Како би се применио термички зависан модел надземног вода, описан у поглављу 8.2.1, неопходно је израчунати Цулове губитке. Иницијална вредност струје, која се користи за прорачун Цулових губитака, одређена је Шимо–Хамадијевим методом без уважавања амбијенталних услова. Ова вредност је затим искоришћена као полазна тачка за поновни прорачун струје применом истог метода, али уз уважавање амбијенталних услова.

На основу тако добијене струје врши се прорачун температуре проводника и параметара система, након чега се поново спроводи прорачун токова снага, чиме се добијају вредности струја у гранама мреже и напона у чворовима.

Први део алгоритма, који је процес оформљивања базе података на којој се обучава ANN, се састоји из два корака:

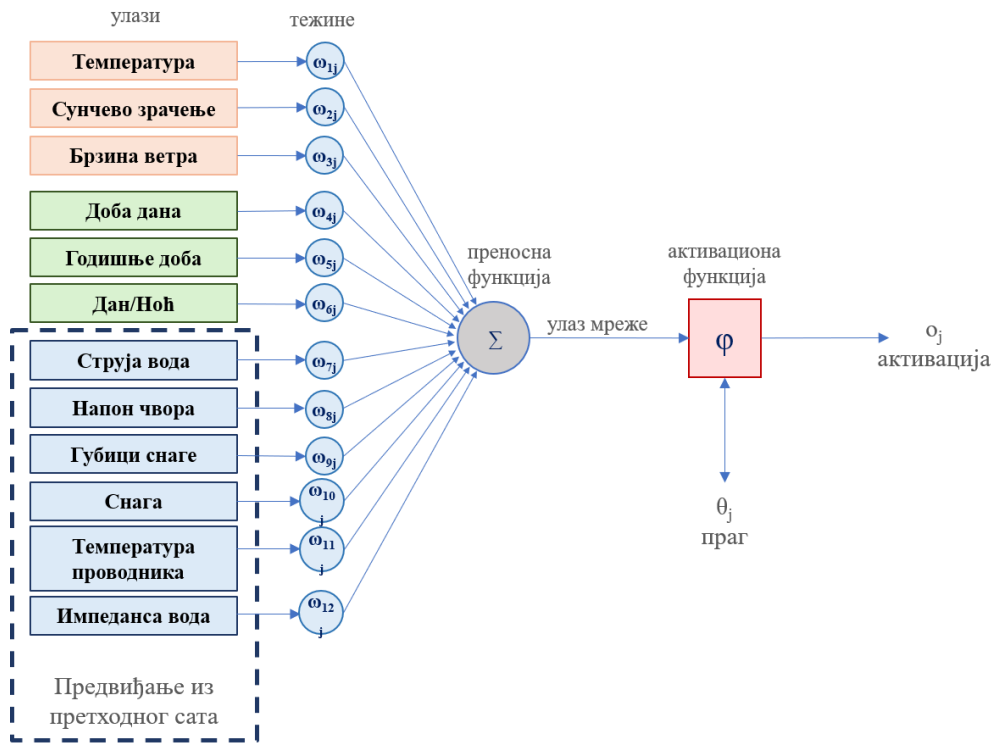
1. Први корак
 - Примена Шимо–Хамади методе на дефинисану мрежу без уважавања амбијенталних услова
 - Добијена струја користи се као иницијална вредност температуре проводника за посматрани сат.
2. Други корак
 - У модел се уводе амбијентални услови и вредност температуре проводника из првог корака.
 - Поновна примена Ширмохамади методе, сада са коригованим параметрима система, ради добијања реалнијег стања мреже.

За сваки сат, прорачун стања целокупне мреже пролази кроз ова два корака. Резултат прорачуна је стање мреже на сатном нивоу за дефинисани период од годину дана. Ови резултати се користе као база података за обучавање ANN модела.



Сл.41 – Алгоритам прорачуна и предикције ANN моделом

На основу велике количине података и размене информација између неурона, ANN модел омогућава предикцију стања електроенергетског система [55]. Сл.42 представља неурон тренираног ANN модела који одговара развијеном алгоритму. Како би се постигла већа тачност предвиђања, за предикције у текућем сату кориштене су предвиђане вредности из претходног сата као додатни улазни подаци текуће предикције. Информације из једног слоја неурона преносе се у наредни. Унутрашња структура ANN-а састоји се од улазног слоја, који прима и прослеђује сигнал, излазног слоја, који одређује коначан излаз мреже, и скривених слојева, који представљају везу између ова два. Тачност ANN модела директно зависи од броја скривених слојева и њихове структуре.



Сл.42 – Математички модел ANN мреже у прорачуну

Снага веза између неурона у моделу дефинисана је кроз синаптичке тежине, ω_{ij} , где позитивне вредности представљају побуђујуће везе, а негативне инхибиторне везе. У овом моделу, сваки улазни параметар помножен је са одговарајућом тежином, а добијене вредности сабирају се унутар трансфер функције неурона. Излаз трансфер функције затим се пореди са прагом активације, на основу чега се одређује да ли ће се неурон активирати, вредност 1, или не, вредност 0, [83].

Овај принцип омогућава да мрежа препозна нелинеарне зависности између улазних и излазних параметара система и да на основу њих формира предикцију стања мреже.

Сви параметри су претходно нормализовани методом Min–Max у опсегу од -1 до 1 , како би се избегла неравномерна заступљеност појединих утицајних фактора и спречила сатурација сигнала током обучавања. Оваква нормализација осигурава да ниједан параметар (нпр. напон, струја, температура или брзина ветра) не добије превелику тежину само због своје апсолутне вредности, већ искључиво на основу стварног утицаја на стање система.


Процес обучавања и тестирања ANN модела изведен је у три фазе. Од целокупног скупа података, 70% је коришћено за обучавање, 15% за тестирање, а преосталих 15% за валидацију модела. Податке је систем насумично расподелио како би се избегло груписање и обезбедила репрезентативност различитих радних услова система. Улазни део базе, x , чине амбијентални и оперативни параметри система, температура, брзина ветра, соларна радијација, доба дана и активна потрошња, док излазни део, y , представља предикцију стања мреже, односно напоне у чворовима и активне губитке по грананама.

Повећање количине података за обучавање представља кључни фактор за побољшање тачности предикције [84]. ANN модел постиже најбоље резултате када је обучен на великом броју временских узорака који обухватају различите услове рада система. Тачност модела приказана је кроз прорачун грешака MAPE, MAE, MSE и RMSE.

8.2. Моделовање система

8.2.1. Термички завистан модел надземног вода

У овом прорачуну, надземни вод је моделован преко своје реактансе и резистансе које се налазе између два чвора, Сл.43.



Сл.43 – Модел надземног вода

Вредности ових параметара вода су вариране у зависности од амбијенталних услова на основу IEEE Std. 738™ –2006 [85], IEEE Std. 738™ –2012 [86], and CIGRE WG 22.12 [87], што је приказано у једначинама 22 и 23.

$$R(T_{con}) = \left[\frac{R(T_h) - R(T_l)}{T_h - T_l} \right] (T_{con} - T_l) + R(T_h) \quad 22$$

$$X(T_{con}) = X(T_{ref}) [1 + \beta (T_{con} - T_{ref})], \quad 23$$

где су:

T_{con} – температура проводника надземног вода [$^{\circ}\text{C}$];

T_h – горња температура проводника [$^{\circ}\text{C}$];

T_l – доња температура проводника [$^{\circ}\text{C}$];

$R(T_h)$ – отпорност проводника при горњој температури [Ω];

$R(T_l)$ – отпорност проводника при доњој температури [Ω];

T_{ref} – референтна / тренутна температура проводника [Ω];

β – температурни коефицијент проводника [$1/^\circ\text{C}$].

Како би се прорачунала резистанца и реактанса проводника, неопходно је доћи до вредности температуре проводника, T_{con} , [86][87]. До ове вредности се долази решавањем нелинеарне једначине топлотне равнотеже у стабилном стању 24.

$$H_s + H_j = H_c + H_r \quad 24$$

где је:

H_s – добитак топлоте услед соларног зрачења

H_j – џулови губици (електрична топлота)

H_c – губици топлоте конвекцијом

H_r – губици топлоте зрачењем

Губитак топлоте услед конвекције дат је једначином 25, док је губитак топлоте зрачењем приказан једначином 26.

$$H_c = 0.754 \cdot K_{angle} N_{Re}^{0.6} \cdot K_f (T_{con} - T_a) \quad 25$$

$$H_r = 1.78 \cdot D \cdot \varepsilon \cdot \left[\left(\frac{T_{con} + 273}{100} \right)^4 - \left(\frac{T_a + 273}{100} \right)^4 \right] \quad 26$$

где је:

K_{angle} – фактор правца ветра

N_{Re} – Рејнолдсов број

k_f – термална проводљивост ваздуха [$\text{W}/(\text{m}\cdot^\circ\text{C})$],

T_a – амбијентална температура [$^\circ\text{C}$]

ρ_f – густина ваздуха [Kg/m^3]

ε – емисивност

Топлотни добитак услед соларног зрачења приказан је једначином 27, док је топлотни добитак услед Џулових губитака дат једначином 28.

$$H_s = \alpha_s \cdot S_g \cdot D \quad 27$$

$$H_j = I^2 \cdot (T_{con}) \quad 28$$


где је:

α_s – апсорпциона способност површине проводника;


S_g – глобална соларно зрачење [W/m^2];

D – пречник проводника [m].

Како би се илустровала разлика у случајевима када је уважена варијација реактансе и резистансе са амбијенталним условима, графички је приказана процентуална девијације између ова два случаја на Сл.44 и Сл.45.



Сл.44 – Одступање реактансе услед амбијенталних услова




Сл.45 – Одступање резистансе услед амбијенталних услова

Решавањем једначине температурног баланса, долази се до вредности температуре проводника. Ова температура се затим користи као базна вредност за израчунавање резистансе и реактансе свих надземних водова у мрежи.


8.2.2. Моделовање производње и потрошње

Како обновљиви извори енергије имају интермитентну природу, неопходно ју је уважити при моделовању функционисања система у ком она има удео. Мерења за недељу дана сунчевог зрачења и производње енергије из соларних панела кориштена у овом прорачуну су приказани на сликама Сл.46 и Сл.47, [88]. На Сл.48 приказана је зависност потрошње домаћинстава у току истих недељу дана који одговарају мерењима сунчевог зрачења. Из ових графичких приказа се

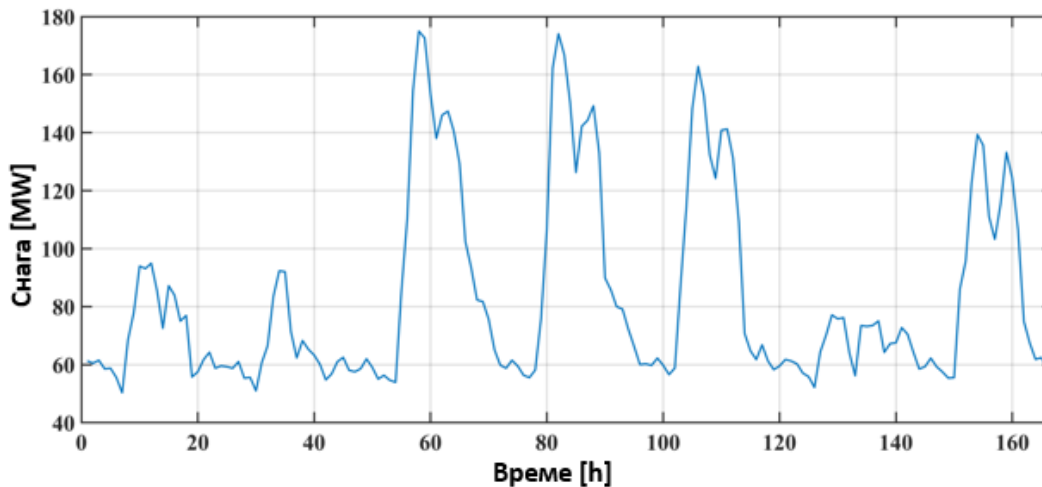
види јасно одступање у периодима када су соларни панели активни и способни да опскрбе потрошњу и стварних захтева домаћинства која треба да буду подмирена.



Сл.46 – Варирање сунчевог зрачења током месеца



Сл.47 – Производња енергије соларних панела током недеље



Сл.48 – Потрошња домаћинства током недеље

Промене у производњи електричне енергије из соларних извора условљене су варијацијама амбијенталних услова, које обухватају интензитет сунчевог зрачења, брзину ветра и доба дана. Слично томе, потрошња енергије показује временске флукуације које зависе од навика корисника, као и од временских услова, доба дана и годишњег доба.


Ове промене у производњи и потрошњи интегрисане су у предложени алгоритам за прорачун стања система. Почетне вредности потрошње и производње добијене су на основу мерних података за Банатски регион Србије, а затим су вариране у складу са мереним амбијенталним условима тог подручја брзином ветра, соларним зрачењем и температуром. Временски услови који су узети у обзир обухватају сат у дану, део дана (дан/ноћ), дан у недељи и годишње доба. Ово је табеларно приказано у Таб.14.

Таб.14 – Улазни подаци за анализу

Варирани подаци	Услови за у односу на које варира	
	Амбијентални услови	Временски услови
Потрошња	Брзина ветра	Сат у дану
	Соларна радијација	Дан/Ноћ
Производња	Температура	Дан у недељи

8.2.3. Посматрана мрежа

Како би се развијени алгоритам тестирао, врши се прочун на стварном делу дистрибутивне мреже у Банату. Сл.49 приказује 35 kV тест мрежу од 28 чворова.




Сл.49 – Анализирана дистрибутивна мрежа у Банату

У [89] предложено је да се на чвор 22 повеже соларна продукција од 1244,8 kW чиме се минимизују губици активне снаге у мрежи. Ова производња је имплементирана у анализираној мрежи.

8.3. Резултати прорачуна

У првом сегменту развијеног алгорита, ток снага на сатном нивоу је прорачунат за целу годину Шимо–Хамадијевим методом. Уважени су амбијентални и временски услови, као и сатне промене производње и потрошње. Ово је резултовало у 8760 прорачунатих струја грана за сваку грану, напона чворова за сваки чвор и губитака снага за целокупну мрежу. Вредности међусобно одступају с обзиром на уважене варијације.

Сл.50 приказује колико варирају вредности уз промену амбијенталних услова. Приказан је губитак активне снаге за сваку грану мреже за 8 различитих сетова амбијенталних услова који највише варирају једни од других. Одавде се уочава да губици снаге могу да варирају и до 50% између појединих вредности амбијенталних услова. За различите амбијенталне услове, битно је установити колика је девијација између појединих прорачуна уколико је ова зависност уважена и уколико је занемарена.



Сл.50 – Губици активне снаге у мрежи за различите услове за један сат

После завршеног прорачуна токова снага, оформљена је база података од 8760 вредности за 12 параметара који дефинишу стање мреже. ANN модел је трениран да предвиди напоне за 28 чворова и губитке активне снаге за 26 грана. Параметри самог модела, број скривених слојева, тип активационе функције, регулациони параметри, дати су у Таб.15. Како би се проценила тачност предвиђања ANN модела, резултати су приказани графички, док је нумерична тачност дата кроз грешке предвиђања.

Таб.15– Параметри тренираног ANN модела

Параметар	Вредност				
Број скривених слојева	5				
Број неурона по слојевима	први	други	трећи	четврти	пети
	48	24	24	12	12
Епохе тренинга	25				

У Таб.16 дате су вредности грешке предвиђања за део базе који се односи на тренирање и тестирање ANN модела. Грешке које се примећују за предвиђање амплитуде напона, фазног става и кумулативних активних губитака су редом 0,9326 %, 3,79 % и 7,4 %.

Таб.16 – Вредности MAPE за анализирани сценарије


MAPE	$U_{\text{чвора}}$	θ	$P_{\text{губици}}$
MAPE _t [%] (тренирања)	0,8868	2,54	6,2
MAPE _{test} [%] (тестирања)	0,9326	3,79	7,4

Различити типови грешака су такође прорачунати и дати у Таб.17 како би се потврдио ниво тачности развијеног ANN модела.


Таб.17 – Грешке предвиђања за анализиране параметре

	$ U_{\text{чвора}} $	θ	$P_{\text{зубици}}$
MAE	0,375 kV	$2,233 \cdot 10^{-3}$ rad	$2,903 \cdot 10^{-4}$ MW
MSE	0,251 kV ²	$9,960 \cdot 10^{-8}$ rad ²	$1,497 \cdot 10^{-7}$ MW ²
RMSE	0,501 kV	$3,156 \cdot 10^{-4}$ rad	$3,869 \cdot 10^{-4}$ MW
MAPE	0,933 %	3,791 %	7,432 %

Као репрезент показатеља напонског нивоа, на Сл.51 приказане су стварне и предвиђане вредности амплитуде напона у мрежи, док Сл.52 приказује стварне и предвиђане вредности фазног става свих чворова мреже. Одступања између вредности које одређују ове линије су показатељи тачности предиктивног модела.




Сл.51 – Предвиђање амплитуде напона




Сл.52 – Предвиђање фазног става напона

Одступања између стварних и предвиђаних вредности за губитке активне снаге за један месец добијене од развијеног ANN модела који уважава амбијенталне зависности је приказан на Сл.53. Како би се детаљније приказало ово одступање, приказано је на Сл.54 за 24 сата.



Сл.53 – Предвиђање губитака активне снаге за месец дана



Сл.54 – Предвиђање губитака активне снаге за један дан

У Таб.18 нумерички су дате вредности предвиђаних вредности губитака снаге и стварних, као и апсолутна грешка одступања за сваку од вредности.

Таб.18 – Нумеричке вредности предвиђања за 24 сата

Сат	Стварни губици [kW]	Предвиђани губици [kW]	АРЕ [%]	Сат	Стварни губици [kW]	Предвиђани губици [kW]	АРЕ [%]
1	5,8	6,5	12,07	13	12,4	11,7	5,65
2	7,3	8,4	15,07	14	10,1	8,8	12,87
3	11,6	13,3	14,66	15	4,5	4,2	6,67
4	14	12,6	10,00	16	5	4,8	4,00
5	13,1	12,2	6,87	17	8,2	8,5	3,66
6	12,2	11,7	4,10	18	10,6	11,1	4,72
7	10	11,3	13,00	19	12,8	13,5	5,47
8	7,4	9,6	29,73	20	12,6	10,3	18,25
9	7,4	9,4	27,03	21	11	10,4	5,45
10	10,2	9,4	7,84	22	10,1	10,3	1,98
11	11,8	9,5	19,49	23	9,2	10	8,70
12	12,5	9,3	25,60	24	6,4	8	25,00

На основу излазних вредности ANN модела приказаних графички и преко вредности грешке предикције MAPE, закључује се да је тачност овог предиктивног модела према дефиницији из [28] на високом нивоу. Задовољавајуће тачности да могу да се користе за планирање рада система. Пошто се ANN модел оформи, долази се до резултата који дефинишу стање система за будућност. С обзиром на комплексност података који су кориштени како би се оформила база података задужена за тренирање ANN модела и да су подаци добијени из прорачуна токова снага који уважава зависности од различитих услова, предвиђања су на високом нивоу тачности. Како прорачун токова снага не мора да буде кориштен за добијање вредности при свакој активацији

предвиђања већ обученог ANN модела, значајно се штети на времену неопходном за рачун. Овакав принцип може да се примени и на системима који имају обновљиве изворе енергије, као што су у овом случају били соларни панели.

Класичан прорачун токова снага често не огледа стварно стање система јер се уважавају одређене претпоставке, занемарења која игноришу промене амбијенталних услова и параметара мреже с њима. Алгоритам који је у овом поглављу развијен је унапређена верзија приступа планирању стања система који користи ANN и уважава занемарене факторе, чиме побољшава тачност процене стања система.

Алгоритам користи промењиви модел надземних водова на који утичу временске прилике, што доприноси тачности модела за планирање, оптимизацију и контролу. Иако овакав приступ изискује значајно време, имплементацијом ANN метода овај процес се убрзава јер се своди на модел који је трениран на резултатима ових комплексних прорачуна зависних од амбијенталних и временских услова.

Овај алгоритам је примењив на било који електроенергетски систем који има доступне податке, а његова тачност расте временом уколико је храњен додатним количинама података које се скупљају кроз време. Овим се побољшава функционалност рада читавог система. Будуће планирање стања система постаје тачније и приближније стварном стању употребом ANN-а. Без метода вештачке интелигенције, овакав детаљан прорачун не би био употребљив за мониторинг и планирање у реалном времену, какво је неопходно за модерне електроенергетске системе.

Логика алгоритма развијена у овом поглављу, као и кључни делови самог алгоритма су део истраживања у поглављу 10. Уважава се систем где се прорачунава стање система и мења у зависности од амбијенталних услова како би се дошло до нумеричних резултата који што тачније приказују стварно стање система.

9. Изоловани рад микромреже са вишеструким складиштима енергије

У овом поглављу анализиран је независан електроенергетски систем који функционише у острвском режиму. У потпуности је одвојен од било какве врсте веће мреже и производња која се оствари у систему треба да се у истом и потроши. Систем је оформљен искључиво из обновљивих извора енергије уз складишта енергије и елемената система који су новији трендови у енергетици. Потрошња је оформљена од купаца–произвођача и класичних домаћинстава. Циљ је да се максимално искористи сва енергија произведена из обновљивих извора, без обзира на тренутне потребе потрошње. Сваки вишак енергије који не може бити одмах потрошен складишти се у систему за складиштење енергије. Ова складиштена енергија може се затим користити у тренуцима када потражња за енергијом премашује капацитет производње.

Ово поглавље даље истражује принципе складиштења водоника и могућу интеграцију електричних возила у кућне системе. Концепт подразумева коришћење вишка енергије из обновљивих извора за електролизу воде, чиме се добија водоник који се складишти у резервоарима за будућу употребу.

Принцип добијања водоника из обновљивих извора анализиран је у више студија [90]–[91], у којима су разматрани различити типови електролизера [92]–[94] и приказани су резултати који потврђују ефикасност примене ових технологија.

Да би било могуће складиштење и функционално коришћење водоника, спроведена су обимна истраживања о принципима његовог настанка, складиштења и дизајна елемената који подржавају развој ове технологије [92]. Начини производње водоника могу имати различите еколошке утицаје, у зависности од примењених принципа. Најчистији облик водоника добија се из обновљивих извора енергије, јер има минималне негативне споредне ефекте [95]–[96]. Како чистоћа складиштеног водоника зависи од иницијалног извора енергије, тако је чистоћа водоника који складишти енергију добијену из соларних панела једнака чистоћи те саме енергије [94].

Принцип коришћења енергије из водоника нуди неколико предности, укључујући високу енергетску ефикасност, еколошке и друштвене користи, као и повећану економску конкурентност у односу на друге изворе енергије [97]–[98]. Када се водоник користи у горивним ћелијама, као нуспроизвод јављају се само вода и топлота, без директних штетних испарења. Ово смањује загађење ваздуха и побољшава квалитет животне средине. Значајна предност водоника је и велика технолошка флексибилност: водоник се може користити за различите примене. У производњи електричне енергије, као и у секторима грејања, транспорта и индустрије, водоник налази широку примену, што га чини конкурентним са традиционалним изворима енергије.

Приликом имплементације система за производњу водоника из обновљивих извора, као што су соларни панели и електролизери, од кључне је важности уређај који контролише њихов рад. Овај уређај игра важну улогу у одређивању периода када се вишак енергије усмерава ка електролизеру ради производње и складиштења водоника, уместо да се троши у мрежи [99].

Стварање таквог управљачког принципа подразумева дефинисање скупа услова под којима сваки елемент ради најефикасније, а затим његову имплементацију у реални систем. Постоји неколико метода за развој управљачких принципа. У овом поглављу, у систем је имплементирана програмска процедура за праћење тренутног нивоа складиштене енергије. На основу ових информација и унапред дефинисаних услова, систем шаље сигнале одговарајућим елементима, обезбеђујући оптималан рад и контролу процеса производње и складиштења водоника [100].


Анализиран је дистрибутивни систем који користи енергију из ветротурбина, соларних панела и електролизера. Циљ је искористити вишак енергије из обновљивих извора за добијање и складиштење водоника, као и складиштење у појединачним батеријама и батеријама електричних возила (ЕВ). Фокус потрошње у анализираном подручју су домаћинства. Потребни подаци за анализу добијени су мерењима обезбеђеним од локалних оператора система, спроведеним у Републици Србији.

9.1. Складишта енергије у моделу система


Производња моделована у систему за овај прорачун се посматра искључиво из обновљивих извора енергије, соларних панела и ветротурбина. Вредности сатних излаза из ових електрана су дефинисане на основу мерења на територији Републике Србије.

Сл.55 приказује просечне сатне промене брзине ветра и сунчевог зрачења измерене на подручју Србије где се налазе ветро- и соларне- електране, које директно утичу на количину енергије коју производе ветротурбине и соларни панели. Сл.56 приказује варијације у производњи обновљиве енергије и потрошњи током недеље. Како се ова енергија производи у неконтролисаним тренуцима, често је није могуће одмах искористити или испоручити потрошачима. Складиштење енергије представља могуће решење ових изазова, јер омогућава да се вишак енергије акумулира у мрежи и користи онда када је потребан.

Из примера мерења која су кориштена при моделовању система за овај прорачун, примећује се значајна интермитентност самих извора из којих се добија електрична енергија. Како су извори интермитентни и сама производња ће бити таква. На Сл.56– б приказана су мерења која су кориштена за моделовање потрошње домаћинстава у систему. Из самих графика је очигледно да се ова два скупа података не поклапају те да производња никако не може задовољити потребе потрошача на сатном нивоу. Ово значи да потрошачи у датом систему неће добити енергију онда када им је неопходна, него онда када је извор у могућности да је створи. Ово је проблем услед ког систем не може функционисати јер постоји временски јаз иако је количина произведене енергије на читавом временском хоризонту једнака количини потрошене енергије. Као решење овог проблема имплементирани су различите врсте складишта електричне енергије.




а)




б)

Сл.55 – Промена а) Брзине ветра; б) Соларне ирадијације



а)



б)

Сл.56 – За недељу дана: а) Производња из обновљивих извора; б) Потрошња домаћинства

FES и SMES имају брзо време одзива уз дуг животни век, али је њихова цена по јединици складиштене енергије висока. Наспрам њих, батерије и складиштење енергије у виду водоника имају ниже трошкове по јединици складиштене енергије, што их чини погодним за веће количине. Ипак, њихово време одзива је дуже у односу на FES и SMES. Комбинацијом ових технологија (нпр. батерија + водоник) може се постићи оптималан баланс између флексибилности, цене и брзине одзива, што је суштинска идеја система који се анализира у овом раду. Количина складиштене енергије зависи од капацитета складишног система, који је директно условљен величином резервоара и ефикасношћу процеса електролизе.

Повећањем притиска и оптимизацијом рада електролизера може се повећати количина произведеног водоника по јединици времена. Укупна ефикасност процеса производње и поновне конверзије водоника у електричну енергију зависи од више фактора као што су температура рада, струјна густина, материјал електрода и мембране у ПЕМ електролизеру. [101] Савремени системи електролизе користе напредне мембране са ниским електричним отпором и високом проводљивошћу, чиме се смањују губици и повећава ефикасност конверзије енергије.

Овај рад анализира принцип складиштења водоника у комбинацији са складиштењем мање количине електричне енергије у батеријама. Вишак енергије из обновљивих извора користи се за производњу водоника путем електролизе, док се батерије користе за краткорочно складиштење. Овим се максимизира предност оба вида складиштења енергије, уз адекватну употребу оба.

9.2. Технологија рада електролизера у моделу система

Електролиза је процес који користи електричну енергију за разлагање молекула воде на водоник и кисеоник. Уколико се ова једносмерна струја добија из обновљивих извора, код производње водоника, једини нуспроизвод настаје чист кисеоник [102][103].

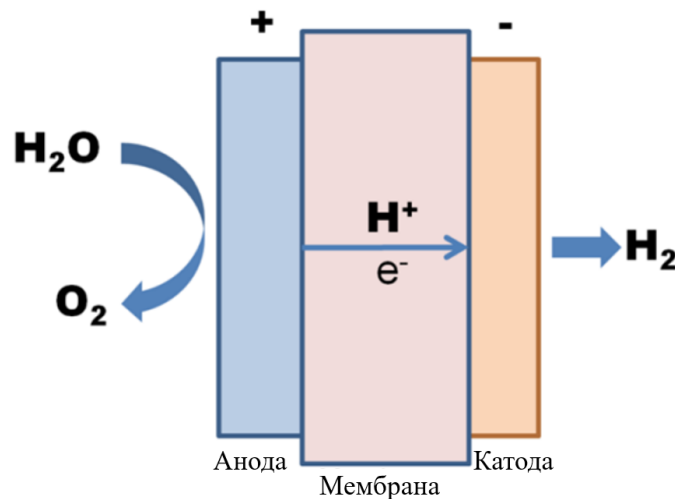


Постоје четири типа електролизе на основу електролита, услова рада и јонских агенаса. У овом раду је анализирана ПЕМ електролиза воде [104]. Ова метода се сматра једном од најпогоднијих за конверзију обновљиве енергије у чист водоник, због чега се активно развија за примену у енергетским системима [105]. Из Таб.19 где су приказане особине различитих врста електролизе, примећује се да је ПЕМ електролиза технологија са највише перспективе за примену у микромрежама које су засноване на обновљивим изворима енергије. Има значајну способност рада у динамичким условима и висок степен ефикасности, што је прикладно за интермитентну природу ветро и соларних електрана.

Таб.19 – Преглед технологија различитих врста електролизе

	Електролит/ Мембрана	Ефикасност [%]	Предности	Мане
Алкална (АЕЛ)	Водени раствор КОН или NaOH	60–80	Поуздана; дуг век трајања; ниска цена амтеријала; погодно за веће капацитете	Нижа густина струје значи већи системи; спорија динамика одзива; ограничена флексибилност при променама снаге
Полимерно– електролитна мембрана (PEM – <i>Proton Exchange Membrane Electrolysis</i>)	Сулфонирани полимер	65–85	Висока густина струје; брз одзив; компактан дизајн; погодна за интеграцију са обновљивим изворима; висок притисак водоника без компресије	Високи капитални трошкови; употреба племенитих метала (Pt, Ir, Ru); деградација мембране током дуготрајног рада
Чврсти оксид (SOE – <i>Solid Oxide Electrolysis</i>)	Керамички електролит	80–90	Висока ефикасност услед рада на високим температурама; могућност коришћења отпадне топлоте; погодна за интеграцију са индустријом	Високи захтеви за термичку стабилност; сложено одржавање; спор старт; ограничена дуготрајност мембрана
Анион– мењајућа мембрана (AEM – <i>Anion Exchange Membrane Electrolysis</i>)	Катионски полимер са OH ⁻ преносом	60–75	Комбинује предности АЕЛ и ПЕМ; не користи племените метале; потенцијално нижи трошкови	Технологија у развоју; нестабилност мембрана; краћи животни век у поређењу са ПЕМ
*ПЕМ – напредни систем; велике скале	Напредне перфлуорисане мембране (PFSA)	70–85	Могућност динамичког рада при променљивој снази; висока чистоћа H ₂ ; погодна за интеграцију у електроенергетске системе и микромреже	Захтева прецизну контролу температуре и влажности; високи оперативни трошкови

На Сл.57 приказан је принцип рада ПЕМ електролизера [91]. Применом једносмерне струје на електроде, молекули воде се на аноди разлажу на кисеоник, протоне и електроне. Протони (H^+) пролазе кроз полимерно–електролитну мембрану (протон–проводну мембрану), док електрони путују спољним електричним колом ка катоди. На катоди долази до њихове рекомбинације, где се протони и електрони спајају и формирају молекуле водоника (H_2). На аноди се истовремено ослобађа кисеоник (O_2).

Протон–проводна мембрана обезбеђује пренос H^+ јона, али не дозвољава пролаз гасова, чиме се спречава њихово мешање и омогућава висок степен чистоће произведеног водоника. Напон електролизера (U_{el}) обезбеђује енергију потребну за прекид $O-H$ веза у молекулу воде и покретање целокупне електрохемијске реакције.



Сл.57 – Принцип ПЕМ електролизе

За рад електролизера потребно је применити једнофазни напон на аноду и катоду, који представља збир напона електрода и губитака, укључујући активационе, јонске и концентрационе губитке. Кључно је да овај напон буде обезбеђен из обновљивих извора енергије како би електролизер радио ефикасно [106].

$$U_{el} = U_{rev} + \eta_{act} + \eta_{\Omega} + \eta_{conc}, \quad 31$$

где су $U_{ГЕВ}$ – напон између електрода; η_{act} – активациони губици; η_{Ω} – јонски губици; η_{conc} – концентрациони губици.

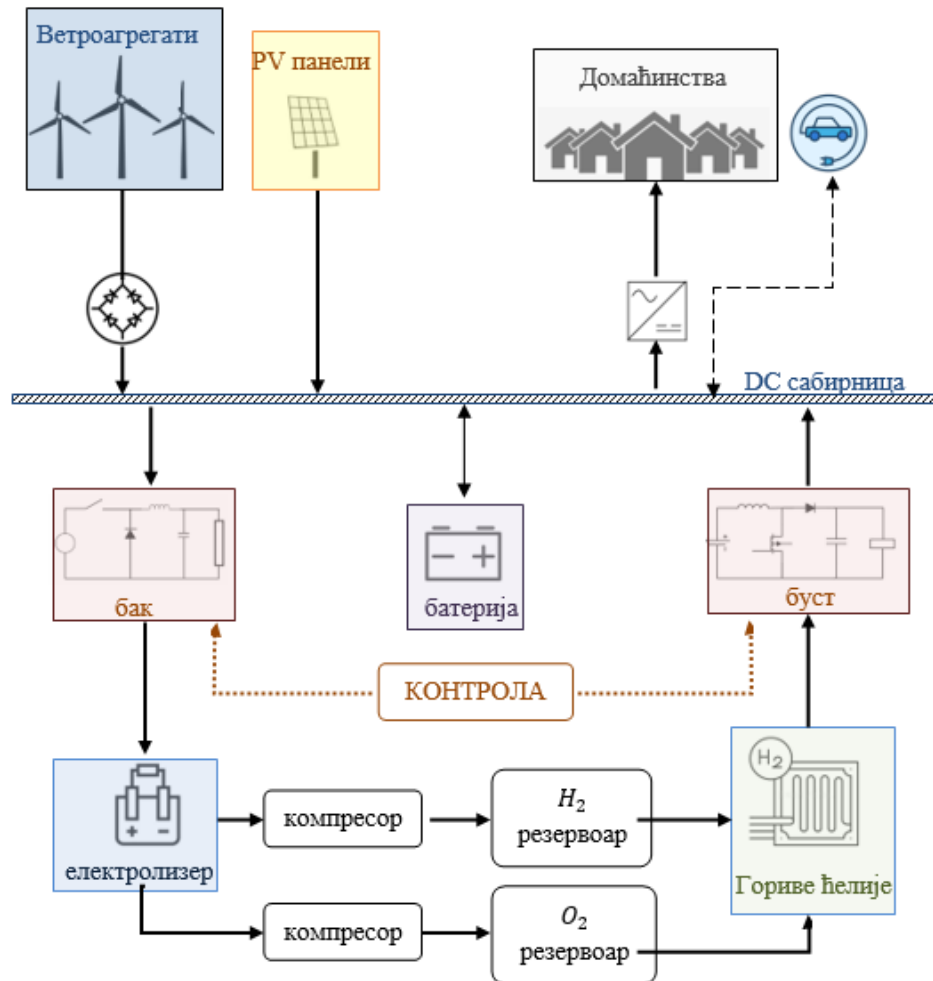
9.3. Принцип рада система

Анализирани систем је пројектован за интеграцију обновљивих извора енергије, посебно ветротурбина и соларних панела. Вишак електричне енергије из ових извора усмерава се ка складиштима. Основни принцип система приказан је на Сл.58.

Приказан је модел система са једном DC сабирницом као заједничком тачком свих појединачних целина елемената система. Преко ове сабирнице повезани су извори енергије,

потрошачи у виду домаћинстава и електричних возила, као и принцип складиштења вишка енергије ради нормалног функционисања целог система.

Идеја је да се складиштена енергија користи да покрије захтеве потрошача у тренуцима кад обновљиви извори не задовољавају потребе потрошача. Коришћењем водоника као носиоца енергије систем превазилази разлике између производње обновљиве енергије и потрошње, омогућавајући стабилно и континуирано снабдевање [107][108].



Сл.58 – Модел система

Енергија се складишти у виду водоника за веће количине енергије и батерија или ЕВ за мање количине енергије. Како се подразумева да су ЕВ ноћу повезани на пуњаче унутар домаћинстава, из перспективе система они се виде као још један вид батерија.

Енергија се транспортује у резервоаре за водоник за веће количине вишка енергије која се појави у систему јер је тај принцип економски исплативији кад се уважи функционисање овог принципа складишта енергије. Више температуре, које се постижу при дужем складиштењу већих количина енергије, побољшавају ефикасност електролизера. Међутим, овакав систем није економичан за мале и тренутне размене енергије са мрежом.

Батерије или ЕВ користе се за краткорочно складиштење мањих количина енергије. Како велики број циклуса пуњења и пражњења смањује век трајања батерија, циљ је да се овај процес

минимизује. Батерије се штеде смањивањем периода њихове употребе, уз коришћење ЕВ током ноћних сати. Логички је активација батеријског типа складишта подељена тако да се дању активирају искључиво батерије, док се ноћу активирају ЕВ. Размена енергије са ЕВ се врши када су возила повезана на пуњаче у домаћинствима [109][110].

За детаљније моделовање и планирање рада оваквог система неопходно је размотрити конверзију енергије из једног облика уз други. Циљ ове анализе је приказ интегрисаног функционисања обновљивих извора енергије, домаћинства, ЕВ и различитих типова складишта енергије повезаних преко сабирнице једносмерне струје.

У овом систему фигурише енергетска електроника чији је рад такође уважен кроз анализу. Ветроелектране се повезују на DC сабирницу преко исправљача, потрошачи преко инвертора док је електролизер повезан преко конвертора спуштача напона. Батерије за привремено складиштење мање количине енергије повезане су директно на DC сабирницу. Енергија из горивих ћелија које су повезане са радом електролизера се на DC сабирницу спајају преко дизача напона. Како би целокупни систем функционисао, систем мониторинга стања и контроле која усмерава токове енергије и активира различите елементе је имплементиран.

9.4. Моделовање елемената система

Ради тачне процене тока електричне енергије, сви елементи су појединачно моделовани. Целине система су груписане заједно са својим претварачким елементима. Целине су подељене на:

1. Електролизер + Buck (спуштач напона)
2. Батерије
3. ЕВ
4. Гориве ћелије + Boost (Подизач напона)
5. Ветрогенератори + исправљачи
6. Соларни панели
7. Домаћинства + инвертори

Контрола је имплементирана тако да утиче на претвараче при испоруци енергије из складишта и при преузимању енергије за електролизу. Производња ради темпом који јој је својствен у ритму са изворима енергије и потрошња не контролише своје захтеве него се они испуњавају преко контроле. Улазни подаци система су једносатна мерења производње ветротурбина, соларних панела, потрошње, као и подаци о елементима мреже и њиховом функционисању. На основу ових вредности и дефинисаних правила врши се подешавање контроле.

9.4.1. Електролизер и спуштач напона

Пошто су динамика конвертора и њихово време одзива знатно бржи у односу на остале делове система, они се посматрају као идеални извор напона на који је повезан електролизер. Излазна снага електролизера P_{El} је снага која улази у бак претварач P_{Bu} , умањена за коефицијент ефикасности η_{Bu} . Математички приказ функционисања електролизера дат је кроз једначине 32-35.

$$P_{El} = \eta_{Bu} \cdot P_{Bu} \quad 32$$

$$U_{El} = \frac{P_{El}}{I_{El}} \quad 33$$

$$U_{El} = U_{El,0} + C_{1El} \cdot T_{El}(t) + C_{2El} \cdot \ln\left(\frac{I_{El}(t)}{I_{El,0}}\right) + \frac{R_{El} \cdot I_{El}(t)}{T_{El}(t)} \quad 34$$

Напон потребан за електролизу изражава се као однос снаге електролизера и струје коју прима из конвертора. Једначина 34 описује зависност напона од струје и температуре. Коefицијенти $U_{El,0}$, C_{1El} , C_{2El} , R_{El} и $I_{El,0}$ су експериментално дефинисани за електролизер, а T_{El} представља његову радну температуру. Из ових једначина добија се веза између излазне снаге конвертора и струје електролизе, чиме се дефинише степен производње електролизера:

$$\dot{V}_{El} = N_{Cell,El} \cdot \frac{\eta_{I,El} \cdot I_{El}(t)}{C_{H_2}} \quad 35$$

где су:

$N_{Cell,El}$ – број ћелија;

$\eta_{I,El}$ – фактор искориштења електролизера;

C_{H_2} – коефицијент конверзије.

9.4.2. Батерије и ЕВ

Батерије повезане на DC сабирницу и батерије електричних возила симулиране су истим принципом рада. Димензиониране су на исти начин, а исти принцип конверзије енергије примењује се у овој анализи. Батерије су повезане паралелно са DC сабирницама, а струја која тече кроз батерију дата је једначином 36.

$$I_B(t) = I_{PV}(t) + I_{Wind}(t) + I_{B0}(t) - I_{Bu}(t) - I_{Load}(t) \quad 36$$

где су:

I_{PV} – струја из соларних панела;

I_{Wind} – струја из ветроагрегата;

I_{Bu} – струја ка бак претварачу;

I_{B0} – струја ка буст претварачу;

I_{Load} – струја система.

Напон батерије је дат једначином 37, док је стање напуњености математички дефинисано кроз једначину 38.

$$U_B(t) = 1 + \alpha \cdot t \cdot U_{B,0} \cdot t + R_i \cdot I_B t + K_i \cdot Q_R t, \quad 37$$

$$SOC_B = 100 \cdot \frac{E_B}{E_{B,max}} \quad 38$$

где је:

α – фреквенција пражњења;

$U_{B,0}$ – напон отвореног кола за $t = 0$;

E_B – енергија батерије.

9.4.3. Гориве ћелије и подизач напона

Динамика конвертора је знатно бржа од осталих делова система, као у случају спуштача напона. Они се представљају као идеални извори енергије чији излаз зависи од ефикасности конвертора. Једначина 39 представља излазну снагу boost претварача, која се добија као производ ефикасности претварача и снаге гориве ћелије. Једначина 40 дефинише напон гориве ћелије као однос снаге гориве ћелије и струје коју она испоручује. На основу ових односа успоставља се веза између снаге гориве ћелије, њеног напона и рада boost претварача у систему. У једначини 41 приказана је зависност напона од струје и температуре. Коефицијенти $U_{FC,0}$, C_{1FC} , C_{2FC} , R_{FC} , и $I_{FC,0}$ су експериментално дефинисани за гориву ћелију, а T_{FC} је њена радна температура. Степен производње гориве ћелије изражава се кроз једначину 42.

$$P_{Bo} = \eta_{Bo} \cdot P_{FC} \quad 39$$

$$U_{FC} = \frac{P_{FC}}{I_{FC}} \quad 40$$

$$U_{FC} = U_{FC,0} + C_{1FC} \cdot T_{FC}(t) + C_{2FC} \cdot \ln\left(\frac{I_{FC}(t)}{I_{FC,0}}\right) + \frac{R_{FC} \cdot I_{FC}(t)}{T_{FC}(t)} \quad 41$$

$$\dot{V}_{FC} = N_{Cell,FC} \cdot \frac{\eta_{I,FC} \cdot I_{FC}(t)}{C_{H_2}} \quad 42$$

где су:

$N_{Cell,FC}$ – број ћелија;

$\eta_{I,FC}$ – фактор искориштења горивих ћелија;

C_{H_2} – коефицијент конверзије

9.4.4. Складиште водоника

Енергија складиштена у водонику може се моделовати једначином 43. Једначина 44 представља зависност енергије складиштене у облику водоника од улазних снага електролизераи гориве ћелије као и од параметара система. Процент енергије у водонику је дат једначином 45 кроз HL [%].

$$E_{H_2} = E_{H_2,0} + \int_{t_0}^t (P_{El} - P_{FC}) dt \quad 43$$

$$E_{H_2} = E_{H_2,0} + \frac{1}{S} \cdot \left(\frac{\dot{V}_{El} \cdot \Delta H}{V_T} - \frac{\dot{V}_{FC} \cdot \Delta H}{V_T} \right) \quad 44$$

$$HL = 100 \cdot \frac{E_{H_2}}{E_{H_2,max}} \quad 45$$

где су:

E_{H_2} – иницијална енергије у водороду;

P_{El} – снага електролизера;

P_{FC} – снага апсорбована у гориве ћелије;

t_0 – почетни тренутак;

t – посматрани тренутак.

9.4.5. Контрола система

Организација рада целокупног система је сложен проблем. Једноставно усмеравање вишка енергије у складиште није довољно. Контролни систем мора одредити да ли ће енергија бити послата у складиште водоника или у батерије, у зависности од количине енергије. Контролни систем мора одредити да ли ће енергија бити послата у складиште водоника или у батеријске системе, у зависности од количине енергије и расположивих капацитета складиштења. Складиштење у виду водоника није ефикасно за мање количине енергије. Због тога се енергија шаље у складиште водоника само ако је количина довољно велика да оправда покретање електролизера. У супротном, енергија се складишти у батеријама.

Исти принцип важи у супротном смеру. Ако је потражња мала и не може се покрити производњом, енергија се узима из батерија. Ако је потражња велика, енергија се преузима из

горивих ћелија. Једначина 46 представља биланс активне снаге у систему, при чему је укупна расположива снага дефинисана као збир производње из ветроелектрана и соларних електрана, умањен за потрошњу.

$$ТОК = P_{Wind} + P_{PV} - P_{opt} \quad 46$$

Батерије су укључене као привремено складиште за мање количине енергије, уз складиштење у водонику. Приликом избора методе складиштења мора се узети у обзир ефикасност конверзије енергије из електричне у водоник и обрнуто.

Рационално коришћење батерија је такође важно. Не треба их празнити испод одређене границе, а чести циклуси пуњења и пражњења треба да се избегну како би се очувао њихов век трајања. Због тога контролни систем мора пратити стање складиштене енергије и управљати њиховом употребом.

Улазни подаци за контролни систем су тренутно стање мреже, односно разлика између производње и потрошње, ток енергије и стање батерија, које је дефинисано вредношћу стања напуњености, *SOC*. Ови подаци омогућавају доношење одлука у систему контроле.

H₂ граница представља унапред дефинисану границу енергије при којој се електролизери и гориве ћелије активирају. Његова вредност је одређена капацитетом електролизера, који је одабран за конкретан енергетски систем. У овом истраживању, ова вредност је фиксна и износи 50 kW. Ако је потребна количина складиштене енергије мања од ове границе, активирају се батерије и ЕВ.

Информације неопходне за контролу система:

1. Ток енергије: дефинише да ли постоји вишак или мањак енергије за потрошаче
 - А) $ТОК > 0$: постоји вишак енергије која треба да се складишти; енергија иде ка електролизеру, батеријама или ЕВ.
 - Б) $ТОК < 0$: постоји мањак енергије која се узима из горивих ћелија, батерија или ЕВ.
2. Количина вишка енергије:
 - А) $ТОК > H_2$ граница: довољно енергије да се пали електролизер
 - Б) $ТОК < H_2$ граница: мања количина вишка енергије; складишти се у батеријама или ЕВ
3. Доба дана:
 - А) 18h – 8h: ЕВ су на пуњачима, користе се за складишта мање количине енергије
 - Б) 8h – 18h: у току дана се за складиштење мање количине енергије користе батерије

Жељено понашање овог система може се лако дефинисати кроз правила, што нуди бројне предности за управљање. Коришћењем овакве контроле засноване на правилима, цео спектар улазних параметара може се ефикасно укључити без повећања сложености управљања. Овај облик контроле има одређене предности у односу на алгоритме машинског учења, јер не захтева

велику количину историјских података, који можда нису лако доступни за поједине технологије и системе у којима су сви наведени елементи имплементирани.

9.5. Резултати прорачуна

9.5.1. Ток снага и активација складишта

Резултати симулације приказани су у графичком облику како би се могло пратити активирање различитих врста складишта енергије и количина снаге размењене између сваког складишта понаособ и читавог система. Подаци мерења коришћени у овој анализи за снагу ветра, сунца и потрошњу приказани су преко графика на Сл.55 и Сл.56. Параметри елемената система дати су у Таб.20.

Таб.20 – Стање система током недеље

Електролизер				Гориве ћелије			
$U_{EL,0}$ [V]	22.25	R_{1E} [°C]	-3.3198	$U_{FC,0}$ [V]	33.18	R_{FC} [°C]	-2.04
C_{1EL} [V/°C]	-0.1765	C_{2EL} [V]	5.5015	C_{1FC} [V/°C]	-0.013	C_{2FC} [V]	-1.57
$I_{EL,0}$ [A]	0.1341	$N_{Cell,EL}$	24	$I_{FC,0}$ [A]	8.798	$N_{Cell,FC}$	35
$\eta_{I,EL}$	0.7	C_{H2} [Ah/L]	8604	$\eta_{I,FC}$	0.45	C_{H2} [Ah/L]	8604
η_{Bu}	0.95	-	-	η_{Bo}	0.95	-	-
Батерије				ЕВ			
α [Hz]	0	R_i [Ω]	0.076	α_{EV} [Hz]	0	$R_{i,EV}$ [Ω]	0.076
$U_{B,0}$ [V]	48	K_i	0	$U_{B,0,EV}$ [V]	48	$K_{i,EV}$	0
Складиште Водоника							
ΔH [kJ/mol]	286			V_T [L/mol]	22.4		


Сл.59 приказује временске варијације захтева система за складиштењем или потрошњом енергије. Позитивне вредности указују на периоде када је постојао вишак произведене енергије која је требало да буде складиштена, док негативне вредности означавају периоде када је енергија требало да буде преузета из складишта. Сл.60 илуструје периоде у којима је која врста складишта енергије активирана. Вредности снаге су позитивне и представљају количину снаге размењене са појединачним складиштима. Мање количине енергије се размењују са електричним возилима (ЕВ) током ноћи (љубичаста линија на графу), док се током дана размењују са батеријама (жута линија на графу). Електролизери представљени плавом линијом на графу и гориве ћелије представљене црвеном раде и током дана и ноћи, јер нису ограничени временским условима.

Улазни подаци који се дају систему управљања укључују тренутно стање мреже. Ови улази усмеравају процес доношења одлука у контролном систему.


Разматрају се следеће две вредности:

1. ТОК – разлика између производње и потрошње, тј. ток енергије, што је изражено у једначини 46;
2. Стање батерија – дефинисано вредношћу стања напуњености, SOC .



Резултати приказани на сликама Сл.59–Сл.61 показују снагу појединачних елемената размењену са системом у току једне недеље. Правац тока енергије јасно је означен за снагу складиштену у виду водоника и снагу генерисану активирањем горивих ћелија. У случају електролизера, енергија тече из система у складиште водоника, док за гориве ћелије енергија тече из складишта у систем када постоји недостатак енергије за подмиривање захтева потрошње.




Сл.59 – Стање система у току недеље




Сл.60 – Активација различитих врста складиштења у току недеље



- а) Снага складиштена у виду водоника у току недеље б) Снага узета из горивих ћелија у току недеље



в) Снага размењена с батеријама у току недеље




г) Снага размењена с ЕВ у току недеље

Сл.61 – Снага за недељу дана

За батерије и ЕВ, енергија може тећи у оба смера, што се уочава кроз негативне вредности снаге. Негативан знак указује на то да се енергија доводи у складиште, док позитиван знак означава да се енергија из складишта користи за напајање потрошача. Ови резултати пружају увид у динамику размене енергије и употребу различитих елемената складиштења у оквиру система.

На Сл.62 приказано је процентуално стање напуњености складишта водоника и батерија. Ова графичка репрезентација омогућава праћење варијација у стању напуњености током рада система, као и процентуални однос ангажовања између два типа складиштења.



Сл.62 – SOC батерија и ЕВ

Како се вишак енергије у систему јавља чешће у мањим количинама, батерије се користе више. Ово доводи до већих динамичких промена у њиховом стању напуњености. У овом конкретном систему, батерије су биле ангажоване у већој мери у односу на свој капацитет, за разлику од складишта водоника. Међутим, већа количина енергије је била складиштена у виду водоника, што је у складу са принципом оваквог начина складиштења енергије.

Ова запажања истичу динамичко понашање система и различиту употребу врста складиштења у зависности од потреба за енергијом и њене доступности.

Овај прорачун се фокусирао на принцип функционисања изолованог система који има сопствену производњу из обновљивих извора енергије, потрошњу која се огледа у снабдевању домаћинства и различите типове складиштења енергије који су одговорни за одржавање стабилности такве мреже. Посматрана је снага појединачних складишта и однос њиховог ангажовања у раду читавог система. Такође, анализирана је способност независног и

функционалног рада оваквог система, упркос великом броју различитих врста непредвидивих извора енергије и њихових складишта.

Очекивано динамичко понашање батерија је потврђено. Како би се олакшао рад батерија и продужио њихов век као додатног складишта, током ноћи су кориштена доступна електрична возила. Успешно су примењена правила којима се веће количине енергије складиште у виду водоника.

У оваквом систему, међусобна подршка елемената представља најзначајнију предност, што омогућава значајан напредак у функционисању овог типа мреже. Приказана је имплементација нових технологија и идеја, попут складиштења водоника, са циљем ублажавања интермитентности обновљивих извора и балансирања микромреже, која не мора да се ослања на већу дистрибутивну мрежу ради одржавања своје стабилности. На основу свих добијених резултата, закључено је да би хибридни систем који подразумева гориве ћелије, соларне панеле и електролизере могао бити перспективно решење у земљама у развоју.

Иzolована микромрежа која је у овом поглављу развијена и начин њеног функционисања су употребљени као један део система посматраног у поглављу 10. Микромрежа развијена овде је управо та која се имплементира као испомоћ ЕЕС–а на сатном нивоу не би ли помогла у нивелацији напонских нивоа и смањењу укупних губитака које мрежа ЕЕС–а има.

10. Прорачун стања ЕЕС-а уз ангажовање микромреже


У овом поглављу приказује се спајање свих појединачно развијених логика и методологија докторске дисертације у циљу сагледавања ефеката предиктивног рада микромреже на преносни систем ЕЕС-а Србије. Из поглавља 7 и на бази метода вештачке интелигенције формирана су једночасовна предвиђања производње електричне енергије из различитих извора енергије и њене потрошње. Ово су уједно и улазни подаци који се користе за прорачун токова снага и напонских нивоа мреже ЕЕС-а Србије. Прорачун стања система уважава амбијенталне услове у којима се делови мреже налазе и мења параметре мреже сходно њима, као што је приказано у поглављу 8. Резултат ових прорачуна је реално стање система из ког се долази до прецизних губитака снаге по гранама и напонских нивоа чворова мреже приказане на Сл.63. Пошто се прорачунају вредности напона чворова и губитака активе и реактивне снаге у читавој мрежи, врши се анализа потенцијалних стања мреже. Ова потенцијална стања су исход прикључивања микромреже развијене у поглављу 9 на различите локације у мрежи у циљу ефикаснијег функционисања преносног система. У овом поглављу дисертације се прорачунавају потенцијалне локације чвора преносног система за прикључење микромреже не би ли се максимизовао позитиван утицај интервенције микромреже на захтеве оператора система. Последњи део прорачуна се базира на активацији складишта и логици рада саме микромреже не би ли се испунили захтеви система на најоптималнији начин. Сви ови прорачуни се врше на сатном нивоу, што значи да се стање преносног система мења из сата у сат и да је микромрежа задужена да испуњава захтеве у реалном времену.



Сл.63 – Преносна мрежа Републике Србије

10.1. Развијени алгоритам

Алгоритам развијен за овај прорачун је структурирано настао спајањем већ развијених алгоритама у претходним поглављима и њиховом дорадом како би се прилагодили конкретном проблему. Његов графички приказ се налази на Сл.64.



Сл.64 – Развијени алгоритам проачуна

Улазни подаци који се користе у овом прорачуну су излазне вредности сатних предвиђања производње и потрошње из поглавља 7.

Први део алгоритма базиран је на прорачунавању токова снага у преносној мрежи Србије. Ови прорачуни се у алгоритму врше Њутн–Рапсоновом методом јер она најпрецизније решава проблеме прорачуна токова снага у преносној електроенергетској мрежи. Иницијални прорачун токова снага је извршен уз занемарење утицаја амбијенталних услова на параметре мреже. Резултат овог иницијалног прорачуна је струја на основу које се одређује почетна температура свих проводника, надземних водова, преносне мреже за први сат. Иницијалне струје за сваки други сат се узимају из претходног како би почетна позиција била приближна реалном стању.

Са иницијалном вредношћу температуре проводника, улази се у други корак алгоритма. Други корак подразумева прорачунавање параметара елемената ЕЕС–а како би се уважио утицај амбијенталних услова на њене елементе. Овај прорачун се врши за све водове система на сатном нивоу. Затим се са добијеним новим вредностима параметра водова, R и X , поново покреће прорачун токова снага. Излаз овог прорачуна је стање система које је најприближније реалном стању јер уважава спољне утицаје на параметре мреже и прецизније и реалније прорачуне губитака у преносној мрежи.

Са овим стањем мреже познати су губици активне и реактивне снаге по водовима, као и напони на 33 чвора мреже. Следећи корак у алгоритму је анализа овог стања мреже и избор чвора који би био потенцијална локација микромреже. Циљ повезивања микромреже са једним чвором је побољшање стања система, смањењем губитака снаге или побољшањем напонских прилика. Проблем оптималног места прикључења мреже решава се претрагом свих чворова у мрежи. За сваки чвор симулира се прикључење микромреже и врши прорачун токова снага за различите комбинације активне и реактивне снаге микромреже. Оптимално место прикључења је оно које доводи до најбољег побољшања стања мреже дефинисаног критеријумом смањења губитака снаге или побољшања напона.

Пошто се дефинише чвор најпогоднији из аспекта токова снага и побољшања стања мреже, захтевана размена енергије на једночасовном нивоу се прослеђује као захтев микромрежи. Унутар микромреже се врши оптимизација њеног рада како би задовољила услове свог функционисања и уз то припомогла стању електроенергетског система, смањила губитке или побољшала напонске прилике. У зависности од тога да ли је приоритет побољшање губитака снаге или нивелација напона, неопходна је микромрежа другачијих енергетских способности. У раду су анализирана два случаја захтева система, уколико је приоритет приближити напон сваког чвора номиналном напону мреже и ако је приоритет смањење губитака снаге на водовима уз одржавање напона у опсегу стабилности система од $\pm 5\%$.

Конечан излаз овог алгоритма су нивелисани напонски нивои, смањени губици активне и оптимална активација ресурса у микромрежи.

10.2. Подаци прорачуна

Улазни подаци који су већ дефинисани у овом раду су предвиђања потрошње и производње електричне енергије унутар Србије на сатном нивоу. Предвиђања производње била су дефинисана кумулативно према врсти извора енергије. За анализу система, неопходно је предвиђати производњу сваке електране дефинисане у овом систему са Сл.5 која приказује модел преносне мреже Републике Србије. Кумулативна предвиђања енергије су подељена на појединачне електране на основу инсталисане снаге сваке од њих.


Називи чворова, а самим тим и њихова улога у мрежи, су дати у Таб.21. У прорачуну токова снага чворовима потрошње је додељен PQ тип, док је чворовима где се налазе електране додељен PV тип.

Таб.21 – Чворови преносне мреже

Редни број	Назив чвора	Редни број	Назив чвора
1 – ХЕ	РП Ђерпад	15 – потрошња	ТС Београд 8
2 – ТЕ	ТЕ Косово Б	16 – потрошња	ТС Лесковац 2
3 – ТЕ	ТЕНТ Б	17 – потрошња	ТС Сомбор 3
4 – потрошња	ТС Јагодина 4	18 – потрошња	ТС Обреновац
5 – ТЕ	ТЕНТ А	19 – потрошња	ТС Пећ
6 – ТЕ	РП Дрмно	20 – потрошња	ТС Урошевац
7 – потрошња	ТС Суботица 3	21 – потрошња	Гвоздена врата (Румунија)
8 – потрошња	ТС Сремска Митровица	22 – потрошња	Ернестиново (Хрватска)
9 – потрошња	РП Младост	23 – потрошња	Угљевик (БиХ)
10 – потрошња	ТС Панчево 2	24 – потрошња	Софија (Бугарска)
11 – потрошња	ТС Нови Сад 3	25 – потрошња	Шандорфалва (Мађарска)
12 – потрошња	ТС Ниш 2	26 – потрошња	Скопље (Македонија)
13 – потрошња	ТС Крагујевац 2	27 – потрошња	Рибаревина
14 – потрошња	ТС Бор 2	28 – ВЕ	ПРП Чибук

Параметри водова, R и X , се кроз прорачун прерачунавају на сваких сат времена. Према формулама из поглавља 8 уважава се утицај амбијенталних услова на њихове физичке карактеристике. Како би се дефинисале што приближније вредности ових амбијенталних услова,

Србија је подељена на пет различитих зона на којима су примењени различити амбијентални услови. Дефинисано је који чворови и које гране припадају одговарајућим зонама како би утицај амбијенталних услова што верније одражавао стварно стање система. Ово подразумева чињеницу да се не примењују исти временски услови на територији целе државе, већ да су они конкретизовани за део у ком се делови мреже налазе. Подела на амбијенталне зоне је дата на Сл.65.



Сл.65 – Амбијенталне зоне Србије


Подела чворова према амбијенталним условима је приказана према Таб.22. Према овој класификацији чворова различити сетови амбијенталних услова су узимани као утицај на тај део мреже.

Таб.22 – Чворови преносне мреже груписани по зонама амбијенталних услова

Груписање чворова према амбијенталним зонама				
Зона 1	Зона 2	Зона 3	Зона 4	Зона 5
ТС Суботица 3	ТЕНТ Б	Угљевик (БиХ)	РП Ђерпад	ТС Јагодина 4
ТС Сремска Митровица	ТЕНТ А		ТС Бор 2	Рибаревина
ТС Нови Сад 3	РП Дрмно		Гвоздена врата (Румунија)	ТЕ Косово Б
ТС Сомбор 3	РП Младост			ТС Ниш 2
Ернестиново (Хрватска)	ТС Панчево 2			ТС Лесковац 2
Шандорфалва (Мађарска)	ТС Крагујевац 2			ТС Пећ
ПРП Чибуk	ТС Београд 8			ТС Урошевац
	ТС Обреновац			Софија (Бугарска)

10.3. Резултати прорачуна

На графику са Сл.66 приказан је резултат иницијалног прорачуна токова снага који занемарују утицај амбијенталних услова. Потом је на истом графику приказана варијација губитака активне снаге за сваку грану за различите амбијенталне услове који одговарају различитим сатима. На овом графику се приказује колико варирају вредности уколико се амбијентални услови уваже или занемаре за прорачун снага губитака у преносној мрежи Србије за 24 сата. Губици процентуално варирају до чак 60 % у различитим сатима дефинисаним својим амбијенталним условима.



Сл.66 – Промена губитака снаге услед амбијенталних услова


При одабиру места прикључивања микромреже и количине захтеване енергије, неопходно је јасно дефинисати захтеве. У овом прорачуну анализирана су два могућа случаја:

1. Одржавање напонског нивоа у преносној мрежи што ближе 1p.j. Овакав случај подразумева да захтев за одржавањем напона има већу тежину од потребе да се смање губици снаге у мрежи. Циљ њиховог смањења је и даље присутна, али није фокус задатка;
2. Смањење губитака активне снаге у преносној мрежи. Главни циљ активације микромреже је смањење губитака у преносној мрежи. Услов који прати напоне је да остану унутар граница од $\pm 5\%$.

Изворно, микромрежа је димензионисана као изоловани систем оптимизован за самостални рад. Његови капацитети су дефинисани складиштима енергије и локалном производњом из ветро и соларних електрана. Оригинални прорачун који уважава њене изворне капацитете је дат у поглављу 9. Максимални капацитети батерија су 60 kVA, док горивих ћелија износи 150 kVA. У циљу системске подршке ове капацитете је неопходно скалирати како би једна микромрежа могла имати позитиван ефекат на преносни систем Србије. Ово скалирање своди случај на то да се прикључује само једна микромрежа на једну физичку локацију, али могуће су и опције прикључења микромрежа мањих капацитета на различите локације у Србији.


10.3.1. Нивелисање напонског нивоа

У циљу нивелисања напонских нивоа, претрагом по свим чворовима долази се до препорученог места повезивања микромреже на преносни систем, чвора број 27. Напонски нивои пре и после интервенције микромреже за 24 сата су дати на Сл.67. У зависности од доступне енергије коју је могуће разменити са микромрежом долази се до већих или мањих ефеката. Уколико микромрежа има веће капацитете, нивелација напона је значајнија. Како би микромрежа имала позитиван утицај на напонске нивое преносне мреже, њени оригинални капацитети су у овом прорачуну скалирани са 10. Потенцијално већи ефекат би имао већи број мањих микромрежа повезаних на различите делове преносне мреже. Кумулативна енергија која се од њих добија била би ефикаснија у нивелисању напона, а уз то би се имало и распоређено инјектирање унутар система чиме је одржавање напона лакше. Из графика са Сл.67 се примећује да су напони преносне мреже свакако унутар дефинисаних граница од $\pm 5\%$, али да теже ка горњој граници. Овим процесом, максимални напони у мрежи су приметно снижени.

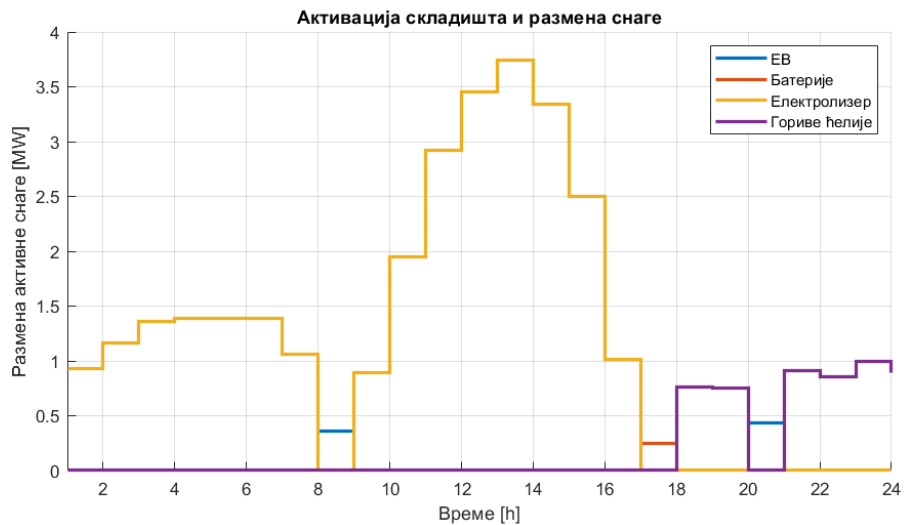


Сл.67 – Напонски нивои преносне мреже пре и после активације микромреже

Као што се види са слике Сл.68, у ову сврху је највећи терет у микромрежи преузео електролизер са мањом активацијом горивих ћелија. Тип активираних складишта је дефинисан билансом активне снаге у микромрежи. На Сл.69 приказана је активација складишта са количином активне снаге која је из поједине врсте складишта захтевана.




Сл.68 – Распоред активирања складишта




Сл.69 – Активација складишта и размена енергије

У циљу смањења напонских нивоа унутар преносне мреже, задатак микромреже од које се захтевао овакав ефекат је био преваходно да апсорбује веће количине реактивне енергије. Опскрбљивање реактивном снагом је приказано на Сл.70. Негативан предзнак указује на природу захтеване услуге. Природа напона у преносној мрежи Србије је да иду ближе горњој граници. У процесу нивелације напона ка 1 р.ј., то је већински било његово смањивање. У циљу смањења напона у мрежи неопходно је било да микромрежа апсорбује одређене количине реактивне енергије. Из ове логике долази негативан предзнак за ток реактивне снаге који се огледа у активацији инвертора батерија и горивих ћелија.



Сл.70 – Реактивна снага унутар микромреже

Ток активне и реактивне снаге, промена ових снага у 24 сата унутар микромреже која је повезана са преносном мрежом је дата Сл.71. Приметно је да је већа количина реактивне снаге била неопходна за нивелацију напона, него што је активне снаге дато преносној мрежи у циљу смањења губитака. Овде се примећује тежина приоритизације захтеваних услуга. Фокус је на напонима и микромрежа такав захтев извршава.




Сл.71 – Ток активне и реактивне снаге

Размењене енергија на сатном нивоу унутар микромреже је приказана на Сл.72 за све типове складишта. Прикључењем микромреже на преносни систем, њен унутрашњи режим рада се суштински мења. Више није локални систем који је задужен искључиво за оптимизацију сопственог функционисања, већ је постао елемент који приоритетно пружа системске услуге. У случају нивелисања напона преносног система унутар микромреже долази до значајне прерасподеле ангажованих складишта. Повећана је циркулација реактивне енергије унутар саме микромреже услед чега су повећани губици конвертора. На тај начин микромрежа делимично жртвује сопствена оптималност како би била испомоћ већем систему.

Складишта се не активирају искључиво онда када је то најоптималнији случај за саму микромрежу, већ је условљена захтевима спољашњег система. Електролизери и гориве ћелије постају регулациони елементи често уз повећање оперативних трошкова. Микромрежа ради као систем услуге, а не као економски оптималан изоловани систем.

Овим процесом микромрежа губи предности независног система, али се истовремено повећава њена вредност као инфраструктуре, уз генерално бољу искоришћеност постојећих ресурса. Пружањем системских услуга ради повећања стабилности већих система, микромрежа представља користан ресурс у случају дистрибуираних извора енергије.




Сл.72 – Размењена енергије у систему


10.3.2. Смањивање губитака снаге

Како би се приметно смањили губици активне снаге, неопходно је да микромрежа буде у приправности да систем опскрби са већом количином активне снаге. У ову сврху потребно је да она има значајне капацитете. Порастом капацитета микромреже, расте и енергија коју је могуће допремити преносном систему у циљу смањења губитака. Са порастом ињектиране снаге из микромреже, укупни губици у преносној мрежи се у почетку смањују услед растеређења токова снага, али након достизања одређене граничне вредности долази до промене смера токова снага и поновног раста губитака. Оваква промена потврђује постојање оптималног нивоа ињектирања снаге. Чвор на ком је на основу прорачуна за све чворове, препоручено да се налази микромрежа у циљу смањења губитака снаге је број 23. Укупно смањење губитака у преносној мрежи на дневном нивоу је 1200 MWh. На дневном нивоу процентуално смањење губитака у преносној мрежи је 7%. Смањење губитака је директно пропорционално капацитетима микромреже. Иницијални капацитети микромреже у овом циљу су повећани 30 пута. У овом случају, максимална дозвољена снага коју микромрежа може да доприми преносном систему по сату је 50 MW. У зависности од капацитета микромреже, овај учинак може бити већи или мањи. Губици активне снаге пре и после активације микромреже су дати на Сл.73. Напони унутар преносне мреже су остали унутар дозвољених $\pm 5\%$, што се види на Сл.74. Како су напони у преносној мрежи свакако унутар дозвољених опсега, интервенција микромреже није никако утицала на њих. Фокус је био да се одрже онаквим какви су, а да се ради на смањењу губитака снаге.


Такође, микромрежа је активно учествовала у регулисању нивоа реактивне снаге, што је приказано на Сл.75.



Сл.73 – Губици активне снаге пре и после активације микромреже




Сл.74 – Напони преносне мреже при смањењу губитака снаге

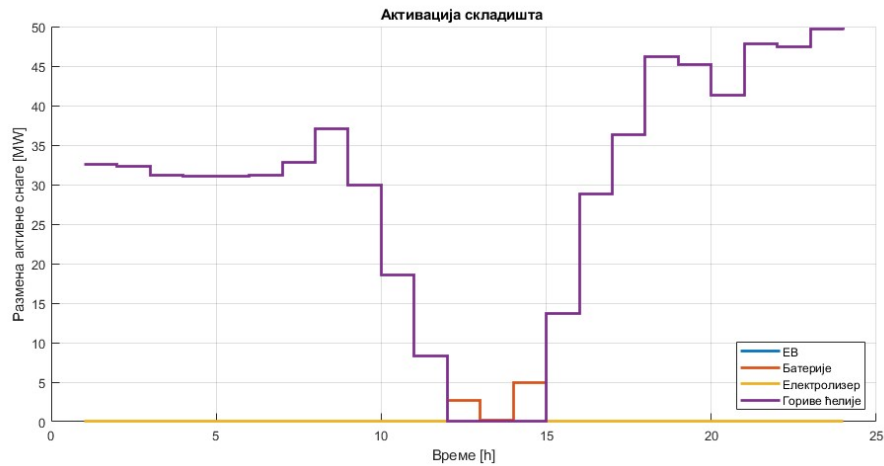


Сл.75 – Губици реактивне снаге пре и после активације микромреже

На Сл.76 примећује се распоред активације различитих типова складишта енергије у микромрежи у процесу смањивања губитака снаге преносне мреже. Како преносна мрежа захтева да јој се достави што већа количина енергије, главна покренута складишта су гориве ћелије. Са Сл.77 примећује се активација батерија уколико је захтевана енергија у мањим количинама.




Сл.76 – Распоред активирања складишта




Сл.77 – Активација складишта и размена енергије

Ради одржавања напона у дозвољеним границама, у процесу имплементације микромреже у рад преносног система, посматран је баланс достављених снага који задовољава смањење губитака снаге, али не утиче негативно на напонске нивое. Реактивна снага којом микромрежа располаже и њена активација у току 24 сата приказана је на Сл.78. Микромрежа је већински радила на одузимању реактивне снаге од преносне мреже у различитим нивоима у току дана. Овај процес је већински покривен инверторима горивих ћелија.




Сл.78 – Реактивна снага унутар микромреже

Ток активне и реактивне снаге, промена ових снага у 24 сата унутар микромреже која је повезана са преносном мрежом је дата на Сл.79. Негативне вредности активне снаге указују на то да је захтев потражње за њом био значајнији, док је реактивна снага морала да се одузима од преносног система.



Сл.79 – Ток активне и реактивне снаге

Размењена енергија на сатном нивоу унутар микромреже је приказана на Сл.80 за све типове складишта. Како преносна мрежа захтева подмирење својих губитака, приметно су више ангажоване гориве ћелије помоћу којих се увећава активна снага. Батерије се користе за фина подешавања и брзу компензацију мањих одступања, а електролизер је чешће у стању мировања, јер њихово активирање у режиму захтевања снаге нема сврхе. Стање напуњености складишта приказује израженије и дуготрајније промене. У овом режиму, микромрежа престаје да буде локално оптималан систем и постаје активни елемент оптимизације преносне мреже. Овим њена економска оправданост зависи од постојања адекватних механизма компензације за пружене системске услуге.



Сл.80 – Укупна размењена енергија

11. Закључак

Актуелне промене у електроенергетском систему, као што су повећана пенетрација обновљивих извора, децентрализација производње, активнија улога потрошача и развиј нових технологија, доводе до повећане сложености самог система. Усред растуће сложености рада система, он постаје све захтевнија за планирање, управљање и процену његовог стања. У оваквим системима, традиционалне методе наилазе на одређене потешкоће. Како би се рад експерата олакшао и убрзао и како би се заобишле потенцијалне људске грешке, јавља се простор за примену напредних метода вештачке интелигенције.

У оквиру ове дисертације развијена је методологија за приступ управљање ресурсима у ЕЕС–у, са посебним акцентом на микромреже и системе са високим уделом обновљивих извора и савремених технологија. Предложен приступ обједињује ANN и ANFIS који се пореде са класичном статистичком методом ARIMA, уз временски зависне параметре система и узимајући у обзир утицај амбијенталних услова.

Први значајни допринос је развој ANN модела за предикцију потрошње електричне енергије на сатном нивоу, уз уважавање утицаја амбијенталних услова и сезонских фактора. Развијени ANN модел је трениран на реалним мерним подацима на територији Републике Србије. Висока тачност модела је потврђена прорачуном више врсти грешака, од којих вредност грешке MAPE показала као најбољи показатељ тачности и износи 5,64%. У поређењу са ARIMA моделом, који је имао грешку приближно 10%, модел развијен коришћењем метода вештачке интелигенције показао је значајну предност у односу на стандардни статистички приступ.

На основу резултата ANN модела, развијен је ANFIS модел за предикцију производње термоелектрана и хидроелектрана, као и предикцију емисије CO₂. Сједињавањем ове две методе вештачке интелигенције, постигнута је грешка предвиђања за производњу електричне енергије од 2,52% за термоелектране и 2,73% за хидроелектране. У поређењу са грешком употребом ARIMA методе од 8,35%, показана је значајна предност обједињених метода вештачке интелигенције. Потврђена је способност развијеног метода да у своје одлучивање имплементира оперативну логику експерата и њихово искуство, као и да узме у обзир параметре који би били превише комплексни за људско око. Модел успешно моделира зависност између потрошње, амбијенталних параметара и структуре производње.

Нумерички је потврђена важност тачне иницијалне предикције потрошње и производње. Комбинована примена ANN и ANFIS модела значајно смањује акумулацију грешке у вишестепеном процесу предикције, што доводи до тачније процене емисије CO₂. Грешка ове предикције применом комбинације ANN и ANFIS модела износи 1,27%, док применом ARIMA модела износи 8,35%.

У поглављу 8, спроведено је 8760 сатних прорачуна токова снаге за 35 kV дистрибутивну мрежу у Банату која има 28 чворова. Увођењем амбијенталних зависности у термичке моделе водова показано је да активни губици у мрежи могу одступати и више од 50% у односу на прорачуне који ове зависности занемарују. Како су термички прорачуни комплексни и временски захтевни да се врше у реалном времену, уз ову методологију развијен је ANN модел. Процена напона и губитака овим поступком извршена је са грешкама MAPE 0,93 % за амплитуду напона, 3,79% за углове напона и 7,43 % за активне губитке снаге. Овим је показано да се висока тачност може постићи уз значајно смањење времена рачунања и уважавање амбијенталних зависности.

Модел микромреже који ради у изолованом независном систему показао је да је могуће остварити стабилно и поуздано функционисање система сачињеног из нових технологија као што су обновљиви извори, купци–произвођачи, ЕВ, различити типови складишта од батерија до складишта водоника. Резултати симулације потврдили су да комбиновано коришћење краткорочних и дугорочних складишта уз адекватан систем контроле, повећава искориштење обновљивих извора и способност самосталног рада оваквог система.

Интеграцијом микромреже у преносну мрежу Србије показано је да предиктивно управљање омогућава оптимизацију токова снага, смањење губитака, способност да се напони читаве мреже нивелишу и бољу координацију између централизованог система и децентрализованих извора енергије. У процесу интеграције испомоћи микромреже у преносни систем, показано је да би потенцијално већи ефекат имао већи број мањих микромрежа повезаних на различите делове преносне мреже. Кумулативна енергија која се од њих добија била би ефикаснија у нивелисању напона, а уз то би се имало и распоређено инјектирање унутар система чиме је одржавање напона лакше. Напони преносне мреже свакако су унутар дефинисаних граница од $\pm 5\%$, али теже ка горњој граници. Имплементацијом микромреже у циљу нивелисања напона, максимални напони у мрежи у току 24 сата су приметно снижени. Овим је потврђена претпоставка да се применом метода вештачке интелигенције може ублажити негативан утицај процеса децентрализације на стабилност система и истовремено повећати његова флексибилност.

Свеобухватна анализа потврђује да развијени модели:

- Омогућавају прецизну предикцију производње енергије на сатном нивоу са грешком испод 3%;
- Обезбеђују прецизну процену емисије CO_2 са грешком испод 2%;
- Смањују грешку прорачуна токова снага за приближно 50%, приближавајући се реалном стању;
- Омогућавају процену стања система са грешком у предвиђању напона испод 1%;
- Приказују ангажовање микромреже као флексибилног ресурса за подршку ЕЕС–у.

На основу спроведених анализа и валидација на реалним подацима и проблемима, може се закључити да предложене методологије, које укључују принципе вештачке интелигенције у планирање рада ЕЕС–а, представљају поуздан, прецизан и примењив приступ за рад савремених електроенергетских система.

Литература

- [1] Velloso A, Hentenryck PV. Combining deep learning and optimization for preventive security-constrained DC optimal power flow. *Trans Power Syst* 2021; 36(4):3618–28
- [2] Amirhossein Sajadi, Luka Strezoski, Amin Khodaei, Kenneth Loparo, Mahmoud Fotuhi-Firuzabad, Robin Preece, Meng Yue, Fei Ding, Victor Levi, Pablo Arboleya, Vladimir Terzija, Guest Editorial: Special Issue on recent advancements in electric power system planning with high-penetration of renewable energy resources and dynamic loads, *International Journal of Electrical Power & Energy Systems*, Volume 129, 2021, 106597, ISSN 0142-0615, <https://doi.org/10.1016/j.ijepes.2020.106597>.
- [3] IEA; World energy outlook 2020, (2020), <https://www.iea.org/reports/world-energy-outlook-2020>
- [4] IEA, Energy Policy review – Denmark 2023; (2023), <https://www.iea.org/reports/denmark-2023>
- [5] Bp. Statistical review of world energy, <https://www.bp.com/>
- [6] Sezen Ece Kayacik, Albert H. Schrottenboe, Evrim Ursavas, Iris F.A. Vis, Towards low-carbon power networks: Optimal location and sizing of renewable energy sources and hydrogen storage, *Sustainable Energy, Grids and Networks*, Volume 38, June 2024. 101394
- [7] Yuan, R., Pourmousavi, S.A., Soong, W.L. et al. A synthetic dataset of Danish residential electricity prosumers. *Sci Data* 10, 371 (2023). <https://doi.org/10.1038/s41597-023-02271-3>
- [8] Schoen, A., Ringelstein, J., Mende, D. et al. Modeling control strategies for prosumers in a Python-based modular simulation tool. *Energy Inform* 6 (Suppl 1), 39 (2023). <https://doi.org/10.1186/s42162-023-00275-2>
- [9] Yuan, T., Liu, D., Yun, F. et al. Quantum-enhanced multi-objective collaboration for wind and solar hydrogen storage optimization. *Opt Quant Electron* 56, 295 (2024). <https://doi.org/10.1007/s11082-023-05883-6>
- [10] Saha, P., Akash, F. A., Shovon, S. M., Monir, M. U., Ahmed, M. T., Khan, M. F. H., ... Akter, R. (2023). Grey, blue, and green hydrogen: A comprehensive review of production methods and prospects for zero-emission energy. *International Journal of Green Energy*, 21(6), 1383–1397. <https://doi.org/10.1080/15435075.2023.2244583>
- [11] Arbel Yaniv, Parteek Kumar, Yuval Beck, Towards adoption of GNNs for power flow applications in distribution systems, *Electric Power Systems Research* Volume 216, March 2023., 109005
- [12] Jordan Jalving, Michael Eydenberg, Logan Blakely , Anya Castillo, Zachary Kilwein, J. Kyle Skolfield, Fani Boukouvala, Carl Laird, Physics-informed machine learning with optimization-based guarantees: Applications to AC power flow, *International Journal of Electrical Power and Energy Systems*, *Electrical Power and Energy Systems* 157 (2024) 109741
- [13] Hanachi, R., Sellami, A., Farah, I.R. et al. Multi-view graph representation learning for hyperspectral image classification with spectral-spatial graph neural networks. *Neural Comput & Applic* 36, 3737–3759 (2024). <https://doi.org/10.1007/s00521-023-09275-5>
- [14] Berraies, A.A., Tzanetos, A., Blondin, M. (2023). Machine Learning to Facilitate the Integration of Renewable Energies into the Grid. In: Fathi, M., Zio, E., Pardalos, P.M. (eds) *Handbook of Smart Energy Systems*. Springer, Cham. https://doi.org/10.1007/978-3-030-97940-9_65

- [15] IEA. World Energy Outlook 2023, International Energy Agency, 2023., <https://www.iea.org/reports/world-energy-outlook-2023>
- [16] H. Saboori, M. Bagheri, and M. Mohammadi, "Optimal operation of multi-energy microgrids with integrated hydrogen storage systems," *Energy*, vol. 263, p. 125859, 2023.
- [17] IEA. Global Energy Review: CO2 Emissions in 2021. 2021. Available online: <https://www.iea.org/reports/global-energy-review-co2-emissions-in-2021-2>
- [18] M. Rahman et al., "EV and battery technologies: State of the art," *Energies*, vol. 13, p. 3938, 2020.
- [19] Barton, J.P.; Infield, D.G. Energy storage and its use with intermittent renewable energy. *IEEE Trans. Energy Convers.* 2004, 19, 441–448.
- [20] European Association for Storage of Energy. Available online: <https://ease-storage.eu/>
- [21] T. Parra-Domínguez, J. Carpio-Pinedo, C. Rabadán-Gómez, and J. A. García-Martín, "The Prosumer: A Systematic Review of the New Paradigm," *Sustainability*, vol. 15, no. 13, p. 10552, 2023., doi: 10.3390/su151310552
- [22] CIGRÉ Working Group C6.22, "Microgrid Evolution Roadmap," CIGRÉ Technical Brochure No. 799, Paris, 2020. ISBN: 978-2-85873-497-0
- [23] IEEE Std 2030.7-2017, "IEEE Standard for the Specification of Microgrid Controllers," IEEE Std 2030.7-2017, pp. 1-43, 2017. doi: 10.1109/IEEESTD.2017.8016706
- [24] IEEE Std 1547-2018, "IEEE Standard for Interconnection and Interoperability of Distributed Energy Resources with Associated Electric Power Systems Interfaces," IEEE Std 1547-2018, pp. 1-138, 2018. doi: 10.1109/IEEESTD.2018.8332112
- [25] PAC World, "Machine Learning in Artificial Intelligence Systems," PACW.org. Accessed: Dec. 3, 2025., доступно: <https://www.pacw.org/machine-learning-in-artificial-intelligence-systems>
- [26] Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [27] T. M. Mitchell, *Machine Learning: A Probabilistic Perspective (Updated Edition)*. 2023
- [28] A.K. Yadav, S. Chandel, Solar radiation prediction using artificial neural network, techniques: a review, *Renew. Sustain. Energy Rev.* 33 (2014) 772–781, <https://doi.org/10.1016/j.rser.2013.08.055>
- [29] Anand Singh Rajawat, Omair Mohammed, Rabindra Nath Shaw, Ankush Ghosh, Chapter six – Renewable energy system for industrial internet of things model using fusion-AI, *Applications of AI and IOT in Renewable Energy*, 2022, Pages 107–128, <https://doi.org/10.1016/B978-0-323-91699-8.00006-1>
- [30] Singla, P., Duhan, M. & Saroha, S. A point and interval forecasting of solar irradiance using different decomposition based hybrid models. *Earth Sci Inform* 16, 2223–2240 (2023). <https://doi.org/10.1007/s12145-023-01020-9>
- [31] Laurent Pagnier, Michael Chertkov. Embedding power flow into machine learning for parameter and state estimation, *Electrical Engineering and Systems Science*, 2021.
- [32] Nasab, M.A., Zand, M., Miri, M. et al. Predicting solar power potential via an enhanced ANN through the evolution of cub to predator (ECP) optimization technique. *Electr Eng* (2024). <https://doi.org/10.1007/s00202-024-02302-1>
- [33] Thota, R., & Sinha, N. (2024). A novel optimized hybrid machine learning model to enhance the prediction accuracy of hourly building energy consumption. *Energy Sources*,

- Part A: Recovery, Utilization, and Environmental Effects, 46(1), 9112–9135.
<https://doi.org/10.1080/15567036.2024.2374750>
- [34] Pasandidehpour, M., Mendes–Moreira, J., Rahman Mohammadpour, S., Sousa, R.T. (2023). Predicting US Energy Consumption Utilizing Artificial Neural Network. In: Fathi, M., Zio, E., Pardalos, P.M. (eds) Handbook of Smart Energy Systems. Springer, Cham. https://doi.org/10.1007/978-3-030-97940-9_136
- [35] Jialun Zhang, Yi Wang, Gabriela Huga, Cost-oriented load forecasting, Electric Power Systems Research Volume 205, April 2022, 107723
- [36] Ghasemi, M., Rajabi, M.S. (2023). Big Data Analytics in Smart Energy Systems and Networks: A Review. In: Fathi, M., Zio, E., Pardalos, P.M. (eds) Handbook of Smart Energy Systems. Springer, Cham. https://doi.org/10.1007/978-3-030-97940-9_203
- [37] Banik, R., Das, P., Ray, S. et al. Prediction of electrical energy consumption based on machine learning technique. Electrical Eng. 103, 909–920 (2021). <https://doi.org/10.1007/s00202-020-01126-z>
- [38] Mijwil, Maad. (2021). Artificial Neural Networks Advantages and Disadvantages. Mesopotamian Journal of Big Data. 2021. 29–31. 10.58496/MJBD/2021/006.
- [39] H. Ouifak and A. Idri, “Application of neuro–fuzzy ensembles across domains: systematic review of the two last decades (2000–2022),” Eng. Appl. Artif. Intell., vol. 124, 2023
- [40] J.–S. R. Jang, C.–T. Sun, and E. Mizutani, Neuro–Fuzzy and Soft Computing. Prentice–Hall, 1997.
- [41] M. M. Lafifi, “A Review of Training Methods of ANFIS for Applications in Business and Economics,” ResearchGate, accessed: Jan. 2025.
- [42] Nokhbeh Dehghan, K., Rahamti, S.H.A., Rahman Mohammadpour, S. (2023). A Hybrid Smart Neural Network Model for Short–Term Prediction of Energy Consumption. In: Fathi, M., Zio, E., Pardalos, P.M. (eds) Handbook of Smart Energy Systems. Springer, Cham. https://doi.org/10.1007/978-3-030-97940-9_123
- [43] Seyed Arman Shirmardi, Mahmood Joorabian, Hassan Barati, Flexible–reliable operation of green microgrids including sources and energy storage–based active loads considering ANFIS–based data forecasting method, Electric Power Systems Research Volume 210, September 2022, 108107
- [44] Zahra Mahdavi, Tina Samavat, Anita Sadat Jahani Javanmardi, Mohammad Ali Dashtaki, Mohammad Zand, Morteza Azimi Nasab, Mostafa Azimi Nasab, Sanjeevikumar Padmanaban, Baseem Khan, Providing a Control System for Charging Electric Vehicles Using ANFIS, International Transactions on Electrical Energy Systems, 2024., <https://doi.org/10.1155/2024/9921062>
- [45] R. J. Hyndman and G. Athanasopoulos, Forecasting: Principles and Practice, 3rd ed. OTexts, 2021.
- [46] R. H. Shumway and D. S. Stoffer, Time Series Analysis and Its Applications: With R Examples, 4th ed. Springer, 2017/2020.
- [47] J. de Lacalle, “Unit roots, stationarity and ARIMA modelling in modern forecasting practice,” Econometrics and Statistics, vol. 25, pp. 72–95, 2023.
- [48] V. Pavlidis and D. Talagala, “Modern model selection criteria for ARIMA–type models: a comprehensive review,” Stat. Sci. Rev., vol. 41, 2022.
- [49] X. Zhang, J. Wang and Y. Chen, “Short–term electricity load forecasting using hybrid ARIMA and machine learning models: A 2024 update,” Applied Energy, vol. 356, 122145, 2024.

- [50] S. Nair, A. Sharma and N. R. Singh, "Short-term electricity price forecasting using ARIMA-family models: A systematic review (2018–2023)," *Electric Power Systems Research*, vol. 222, 109195, 2023.
- [51] M. D. Khan, S. Ali and K. Rehman, "ARIMA and hybrid ARIMA-based models for solar PV power forecasting: Recent advances and future trends," *Renewable Energy*, vol. 224, pp. 1200–1218, 2024.
- [52] A. Keßler and R. Fried, "SARIMA modelling for short-term load forecasting and energy consumption analysis: An updated review," *WIREs Energy and Environment*, vol. 12, no. 2, e460, 2023.
- [53] D. Kriesel, "A Brief Introduction to Neural Networks ", downloading location: http://www.dkriesel.com/en/science/neural_networks
- [54] Chong, S.S., Ng, Y.S., Wang, HQ. et al. Advances of machine learning in materials science: Ideas and techniques. *Front. Phys.* 19, 13501 (2024). <https://doi.org/10.1007/s11467-023-1325-z>
- [55] Zadeh, L. A. (1994). Fuzzy Logic, Neural Networks, and Soft Computing. *Communications of the ACM*, 37, 77–84, <https://doi.org/10.1145/175247.175255>
- [56] Manoj Yadav, Bhaven Tandel, M. Mansoor Ahammed, Chapter 15 – Advanced soft computing techniques in modeling noise pollution health impacts, *Current Trends and Advances in Computer-Aided Intelligent Environmental Data Engineering, Intelligent Data-Centric Systems*, 2022, Pages 337–352, <https://doi.org/10.1016/B978-0-323-85597-6.00014-8>
- [57] Jang, J.S.R., Sun, C.T. and Mizutani, E. (1997) A computational approach to learning and machine intelligence. *Neuro-Fuzzy and Soft Computing*, Upper Saddle River, NJ: Prentice-Hall., *IEEE Transactions on Automatic Control* 42(10):1482 – 1484, 1997, 10.1109/TAC.1997.633847
- [58] Wang X, Huang J, Liu H (2022) Can China's carbon trading policy help achieve carbon neutrality?– A study of policy effects from the five-sphere integrated plan perspective. *J Environ Manag* 305:114357. <https://doi.org/10.1016/j.jenvman.2021.114357>
- [59] Maximillian J, Brusseau ML, Glenn EP and Matthias AD (2019) Pollution and environmental perturbations in the global system. In: *Environmental and pollution science*, Academic Press, pp 457–476. <https://doi.org/10.1016/B978-0-12-814719-1.00025-2>
- [60] Zhihao Chen, Yong He, Nuo Liao, Can carbon emission trading policy enhance the synergistic emission reduction of carbon dioxide and air pollutants? A comparative study considering different pollutants, *Energy*, Volume 305, 2024, 132364, <https://doi.org/10.1016/j.energy.2024.132364>.
- [61] Mihut L, Odagiu A, Mihut S (2019) The use of the LiDAR technology in calculation of the ecosystems carbon footprint. *Res J Agricultural Sci* 51:239–246
- [62] Osman AI, Hefny M, Abdel Maksoud MIA, Elgarahy AM, Rooney DW (2020) Recent advances in carbon capture storage and utilisation technologies: a review. *Environ Chem Lett* 19:797–849. <https://doi.org/10.1007/s10311-020-01133-3>
- [63] Rodrigues R, Pietzcker R, Fragkos P, Price J, McDowall W, Siskos P, Fotiou T, Luderer G, Capros P (2022) Narrative-driven alternative roads to achieve mid-century CO₂ net neutrality in Europe. *Energy* 239:121908. <https://doi.org/10.1016/j.energy.2021.121908>
- [64] Chen, L., Msigwa, G., Yang, M. et al. Strategies to achieve a carbon neutral society: a review. *Environ Chem Lett* 20, 2277–2310 (2022). <https://doi.org/10.1007/s10311-022-01435-8>

- [65] Troster, V., Shahbaz, M. (2019). Globalization and CO2 Emissions: Addressing an Old Question with New Techniques. In: Shahbaz, M., Balsalobre, D. (eds) Energy and Environmental Strategies in the Era of Globalization. Green Energy and Technology. Springer, Cham. https://doi.org/10.1007/978-3-030-06001-5_10
- [66] Güney, T., İnce, D. Solar Energy and CO2 Emissions: CCEMG Estimations for 26 Countries. *J Knowl Econ* (2023). <https://doi.org/10.1007/s13132-023-01337-2>
- [67] Charu C. Aggarwal, *Neural Networks and Deep Learning*, Springer Cham, 25 August 2018, <https://doi.org/10.1007/978-3-319-94463-0>
- [68] <https://www.worldometers.info/co2-emissions/serbia-co2-emissions/>
- [69] Anh, N.T.N., Anh, N.N., Thang, T.N. et al. Online SARIMA applied for short-term electricity load forecasting. *Appl Intell* 54, 1003–1019 (2024). <https://doi.org/10.1007/s10489-023-05230-y>
- [70] Singh, P.K., Pandey, A.K., Ahuja, S. et al. Multiple forecasting approach: a prediction of CO2 emission from the paddy crop in India. *Environ Sci Pollut Res* 29, 25461–25472 (2022). <https://doi.org/10.1007/s11356-021-17487-2>
- [71] Janković S. Jovanovic B. Application of combined Newton–Raphson method to large load flow models *Electral Power System Research* 127 2015.
- [72] Lumbreras S. Ramos A., The new challenges to transmission expansion planning. Survey of recent practice and literature review; *Electral Power System Research Volume* 134, 2016.
- [73] Coletta G., Vaccaro A., A review of the enabling methodologies for PMUs-based dynamic thermal rating of power transmission lines, *Electral Power System Research Volume* 152, 2017.
- [74] Abul’Wafa A.R., A network-topology-based load flow for radial distribution networks with composite and exponential load, *Electral Power System Research* 2012., doi: 10.1016/j.eprsr.2012.04.016
- [75] Dvijotham K, Molzahn D. Error bounds on the DC power flow approximation: A convex relaxation approach. In: 2016 IEEE 55th conference on decision and control. 2016, p. 2411–8. <http://dx.doi.org/10.1109/CDC.2016.7798623>
- [76] Duchesne L, Karangelos E, Wehenkel L. Recent developments in machine learning for energy systems reliability management. *Proc IEEE* 2020;108(9):1656–76
- [77] Hasan F, Kargarian A, Mohammadi A. A survey on applications of machine learning for optimal power flow. In: 2020 IEEE texas power and energy conference. IEEE; 2020, p. 1–6
- [78] von Rueden L, et al. Informed machine learning – a taxonomy and survey of integrating
- [79] Li Z., Xing Y., Huang J., Wang H., Large-scale online multi-view graph neural network and applications; *Future Generation Computer Systems* 116(1):145–155
- [80] Balthazar Donon, Rémy Clément, Benjamin Donnot, Antoine Marot, Isabelle Guyon, et al.. *Neural Networks for Power Flow : Graph Neural Solver*. *Electric Power Systems Research*, 2020., 189, pp.106547. [ffhal-02372741f](https://doi.org/10.1016/j.epsr.2020.106547)
- [81] Trinadha Burle, V.V.S. Bhaskara Reddy Chintapalli, “Modified load flow algorithm suitable for modern power systems under variable weather conditions”, *Electric Power Systems Research* 211, 2022
- [82] Ahmed, Arif & Stevens McFadden, Fiona & Rayudu, Ramesh. Weather-Dependent Power Flow Algorithm for Accurate Power System Analysis Under Variable Weather

- Conditions. IEEE Transactions on Power Systems. (2019).PP. 1–1. 10.1109/TPWRS.2019.2892402.
- [83] D. Kotur and M. Žarković, "Neural network models for electricity prices and loads short and long-term prediction," 2016 4th International Symposium on Environmental Friendly Energies and Applications (EFEA), Belgrade, Serbia, 2016, pp. 1–5, doi: 10.1109/EFEA.2016.7748787.
- [84] Yagang Zhang, "New Advances in Machine learning", IntechOpen 2010.
- [85] I.T. Committee, et al., Ieee standard for calculating the currenttemperature of bare overhead conductors, 2007, IEEE Standard 738.
- [86] Transmission, D. Committee, et al., Ieee standard for calculating the current temperature relationship of bare overhead conductors, 2012, IEEE Std 738.
- [87] C. WG22.12, The thermal behaviour of overhead conductors, *Electra* 144 (1992) 107–125.
- [88] Knežević S, Šošić D. Isolated Work of a Multi-Energy Carrier Microgrid. *Energies*. 2024; 17(12):2948. <https://doi.org/10.3390/en17122948>
- [89] M. Zarkovic, G. Dobric, D. Sosic, Refernca Fuzzy based prediction of wind distributed generation impact on distribution network: Case study – Banat region, Serbia, *Journal of Renewable and Sustainable Energy* 2014, DOI: 10.1063/1.4862988
- [90] Dimitrios, A.; Peter, E. The past, present and potential of hydrogen as a multifunctional storage application for wind power. *Renew. Sustain. Energy REB*. 2019, 112, 917–929.
- [91] Kumar, S.S.; Himabindu, V. Hydrogen production by PEM water electrolysis– A rEBiew. *Mater. Sci. Energy Technol*. 2019, 2, 442–454.
- [92] Basile, A.; Dalena, F.; Tong, J.; Veziroğlu, T.N. *Hydrogen Production Separation and Purification for Energy*; Institution of Engineering and Technology (IET): London, UK, 2017.
- [93] Strunz, K.; Brock, E.K. Stochastic Energy Source Access Management: Infrastructure–integrative modular plant for sustainable hydrogen–electric co–generation. *Int. J. Hydrogen Energy* 2006, 31, 1129–1141.
- [94] Ribeiro, P.F.; Johnson, B.K.; Crow, M.L.; Arsoy, A.; Liu, Y. Energy storage systems for advanced power applications. *Proc. IEEE* 2001, 89, 1744–1756
- [95] Rasul, M.G.; Hazrat, M.A.; Sattar, M.A.; Jahirul, M.I.; Shearer, M.J. The future of hydrogen: Challenges on production, storage and applications. *Energy Convers. Manag.* 2022, 272, 116326.
- [96] Li, X.; Machiel, M. Value of power-to-gas as a flexibility option in integrated electricity and hydrogen markets. *Appl. Energy* 2021, 304, 117863
- [97] Schrottenboer, A.; Veenstra, A.T.; het Broek, M.A.J.U.; Ursavas, E. A green hydrogen energy system–optimal control strategies for integrated hydrogen storage and power generation with wind energy. *Renew. Sustain. Energy REB*. 2022, 168, 112744.
- [98] Karayel, G.K.; Javani, N.; Dincer, I. A comprehensive assessment of energy storage options for green hydrogen. *Energy Convers. Manag.* 2023, 291, 117311.
- [99] Singh, P.; Lather, J.S. Artificial neural network–based dynamic power management of a DC microgrid: A hardware–in–loop real–time verification. *Int. J. Ambient. Energy* 2022, 43, 1730–1738
- [100] Wang, J.; Li, H.; Li, Q. A hierarchical control strategy for microgrids with renewable energy sources. *Electr. Power Syst. Res.* 2016, 131, 128–139

- [101] Bessarabov, D.; Millet, P.; Pollet, B.G. PEM Water Electrolysis; Academic Press: Cambridge, MA, USA, 2018.
- [102] Barbir, F. PEM electrolysis for production of hydrogen from renewable energy sources. *Sol. Energy* 2005, 78, 661–669.
- [103] Ulleberg, Ø. Modeling of advanced electrolyzers: A system simulation approach. *Int. J. Hydrogen Energy* 2003, 28, 21–33
- [104] Hug, W.; Bussmann, H.; Brinner, A. Intermittent operation and operation modeling of an alkaline electrolyzer. *Int. J. Hydrogen Energy* 1993, 18, 973–977.
- [105] Asiaban, S.; Bozalakov, D.; VandEBelde, L. DEBelopment of a dynamic mathematical model of PEM electrolyser for integration into large–scale power systems. *Energy Convers. Manag. X* 2024, 23, 100610
- [106] Deshmukh, S.S.; Boehm, R.F. REBiew of modeling details related to renewably powered hydrogen systems. *Renew. Sustain. Energy REB.* 2008, 12, 2301–2330.
- [107] Bessarabov, D.; Wang, H.; Li, H.; Zhao, N. PEM Electrolysis for Hydrogen Production: Principles and Applications; CRC Press: Boca Raton, FL, USA, 2015.
- [108] Bilgen, E. Solar hydrogen from photovoltaic–electrolyzer systems. *Energy Convers. Manag.* 2001, 42, 1047–1058.
- [109] Rahman, M.; Alam, M.A.; StoEB, A.; Pota, H.R. Electric Vehicle and its Battery Technologies: State–of–the–Art, Challenges, and Future Directions. *Energies* 2020, 13, 591.
- [110] Vosen, S.R.; Keller, J.O. Hybrid energy storage systems for stand–alone electric power systems: Optimization of system performance and cost through control strategies. *Int. J. Hydrogen Energy* 1999, 24, 1139–1156
- [111] Bilodeau, A.; Agbossou, K. Control analysis of renewable energy system with hydrogen storage for residential applications. *J. Power Sources* 2006, 162, 757–764.
- [112] <https://www.plugpower.com/>
- [113] <https://venair.com/en>

Прилози

Прилог 1 – Нумеричке вредности уз поглавље 10

Нивелисање напонских нивоа

Сат	Преносна мрежа				Микромрежа - Укупна размењена енергија					
	Минимални напони	Минимални напони после интервенције микромреже	Максимални напони	Максимални напони после интервенције микромреже	Ptok	Qtok	Батерије	ЕВ	Електролизер	Гориве ћелије
1	1	1	1.0303	1.0234	0.9343	42270	0	0	0.9343	0
2	1	1	1.0266	1.0205	1.1599	42325	0	0	2.0941	0
3	1	1	1.0273	1.0211	1.3596	42485	0	0	3.4538	0
4	1	1	1.0267	1.0206	1.3863	42492	0	0	4.8401	0
5	1	1	1.0273	1.021	1.3897	42491	0	0	6.2297	0
6	1	1	1.0275	1.0212	1.3856	42485	0	0	7.6154	0
7	1	1	1.0285	1.022	1.0614	42245	0	0	8.6768	0
8	1	1	1.0295	1.0228	0.3568	41609	0	0.3568	8.6768	0
9	1	1	1.0293	1.0226	0.8916	41882	0	0.3568	9.5684	0
10	1	1	1.0296	1.0228	1.944	42372	0	0.3568	11.5124	0
11	1	1	1.0289	1.0223	2.9215	42828	0	0.3568	14.4339	0
12	1	1	1.0292	1.0225	3.4547	43035	0	0.3568	17.8886	0
13	1	1	1.0285	1.022	3.7385	43283	0	0.3568	21.6271	0
14	1	1	1.0292	1.0225	3.3385	42996	0	0.3568	24.9656	0
15	1	1	1.0295	1.0228	2.5046	42559	0	0.3568	27.4702	0
16	0.9998	0.9998	1.0301	1.0232	1.0107	41537	0	0.3568	28.4808	0
17	1	1	1.0297	1.0229	0.2504	41526	0.2504	0.3568	28.4808	0
18	0.9996	0.9996	1.0307	1.0237	-0.7631	40390	0.2504	0.3568	28.4808	0.7631
19	1	1	1.0302	1.0233	-0.754	40527	0.2504	0.3568	28.4808	1.5171
20	1	1	1.0304	1.0234	-0.4305	41038	0.2504	0.7873	28.4808	1.5171
21	1	1	1.0314	1.0243	-0.9107	40180	0.2504	0.7873	28.4808	2.4278
22	1	1	1.0309	1.0238	-0.8584	40229	0.2504	0.7873	28.4808	3.2862
23	1	1	1.0326	1.0252	-0.9963	39927	0.2504	0.7873	28.4808	4.2825
24	1	1	1.0316	1.0244	-0.8954	39956	0.2504	0.7873	28.4808	5.1779

Смањење губитака снаге

Сат	Преносна мрежа				Микромрежа - Укупна размењена енергија									
	Губици активне снаге [MW]	Губици активне снаге после интервенције микромреже [MW]	Губици реактивне снаге [MVar]	Губици реактивне снаге после интервенције микромреже [MVar]	Минимални напони [p.u.]	Минимални напони после интервенције микромреже [p.u.]	Максимални напони [p.u.]	Максимални напони после интервенције микромреже [p.u.]	Ptok	Qtok	Батерије	ЕВ	Електролизер	Гориве ћелије
1	18.1826608	16.47582516	-7393.4167	-7408.175329	1	1	1.0303	1.0303	-32.5662	20359	0	0	0	32.5662
2	16.12318552	14.7896035	-7410.675796	-7422.03905	1	1	1.0266	1.0266	-32.2684	20512	0	0	0	64.8346
3	21.91471985	20.0098791	-7362.138913	-7378.36733	1	1	1.0273	1.0273	-31.1382	21936	0	0	0	95.9728
4	32.56637261	29.46037943	-7273.335181	-7299.608261	1	1	1.0267	1.0267	-31.1036	21953	0	0	0	127.0764
5	31.7690203	28.8086584	-7279.733683	-7304.844169	1	1	1.0273	1.0273	-31.1082	21942	0	0	0	158.1846
6	47.40522815	43.53655184	-7146.746415	-7179.639316	1	1	1.0275	1.0275	-31.1545	21878	0	0	0	189.3381
7	56.02504105	51.70580956	-7072.659336	-7109.557318	1	1	1.0285	1.0285	-32.8367	19794	0	0	0	222.1757
8	57.013404	52.6216498	-7061.678787	-7099.423474	1	1	1.0295	1.0295	-37.0673	14010	0	0	0	259.2431
9	159.2049449	150.7279457	-6183.436539	-6256.457936	1	1	1.0293	1.0293	-29.9002	17109	0	0	0	289.1432
10	54.24086776	50.16394119	-7097.579388	-7131.697518	1	1	1.0296	1.0296	-18.6108	22157	0	0	0	307.7541
11	63.42352994	58.6219927	-6997.037971	-7039.002221	1	1	1.0289	1.0289	-8.3565	26820	0	0	0	316.1105
12	57.79475191	53.41898781	-7054.571926	-7092.177612	1	1	1.0292	1.0292	-2.6876	28962	2.6876	0	0	316.1105
13	103.3273428	96.86725359	-6658.59973	-6714.446673	1	1	1.0285	1.0285	-0.1766	31369	2.8641	0	0	316.1105
14	143.9763787	136.2078126	-6329.244664	-6395.343543	1	1	1.0292	1.0292	-4.9947	28338	7.8588	0	0	316.1105
15	201.4344616	191.9758294	-5856.281187	-5936.153668	1	1	1.0295	1.0295	-13.6675	23899	7.8588	0	0	329.778
16	134.2024916	127.033929	-6442.135541	-6501.632384	0.9998	1	1.0301	1.0301	-28.7892	13637	7.8588	0	0	358.5673
17	39.63744337	36.29846095	-7212.610495	-7241.145537	1	1	1.0297	1.0297	-36.3703	13539	7.8588	0	0	394.9376
18	52.7725165	48.615860814	-7088.595246	-7125.046847	0.9996	1	1.0307	1.0307	-46.2231	2236	7.8588	0	0	441.1607
19	44.2192992	40.5422066	-7168.601582	-7200.478469	1	1	1.0302	1.0302	-45.1652	3797	7.8588	0	0	486.3258
20	38.54752064	35.17037736	-7214.303084	-7243.81083	1	1	1.0304	1.0304	-41.3727	9019	7.8588	0	0	527.6985
21	42.95806263	39.32764185	-7176.913554	-7208.579797	1	1	1.0314	1.0314	-47.7754	118	7.8588	0	0	575.474
22	32.04819206	29.05670847	-7271.446647	-7297.574377	1	1	1.0309	1.0309	-47.4254	571	7.8588	0	0	622.8994
23	25.88331877	23.24322742	-7323.64774	-7346.859825	1	1	1.0326	1.0326	-49.6988	-2632	7.8588	0	0	672.5982
24	20.46387569	18.61521514	-7370.555432	-7386.838818	1	1	1.0316	1.0316	-49.5326	-2514	7.8588	0	0	722.1308

Биографија аутора

Соња Кнежевић рођена је 17.03.1998. године у Београду, Република Србија. Основну школу завршила је у Кули. Потом је похађала гимназију „Петро Кузмјак“ у Руском Крстуру. Након завршене средње школе, 2016. године уписује Електротехнички факултет Универзитета у Београду. На Електротехничком факултету изабрала је Одсек за енергетику, а затим и Смер за електроенергетске системе. Дана 16.07.2020. године завршила 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 9,02.

Мастер студије на Електротехничком факултету, Смер за електроенергетске системе, уписала је 2020. године. У току мастер студија остварила је просечну оцену 10,00. Мастер академске студијена студијском програму Електротехника и рачунарство, модул Електроенергетски системи завршила је 15.06.2021. године, са оценом 10 на одбрани мастер рада на тему „Утицај фреквенцијски зависних параметара тла на ударне карактеристике уземљивача“. Ментор на изради мастер рада је био проф. др Златан Стојковић.

Докторске студије на Електротехничком факултету у Београду уписала је школске 2021/2022. године на модулу Електроенергетске мреже и системи. Тренутно је студент докторских студија.

Била је запослена у Електротехничком институту Никола Тесла Београд, у Центру за Електроенергетске објекте где је добила звање истраживача приправника. Од 2022. бави се израдом стручних студија електромагнетних прелазних процеса и тренутно је запослена у фирми Mott Macdonald. Учествовала је у изради стручног рада на тему примене вештачке интелигенције (Машинско учење; Big Data) за дигитализоване технологије у ВН постројењима (IEC61850; МПЛС; Cyber Security).

Аутор је три рада у научним часописима међународног значаја са SCI листе, у категорији M23. Такође, аутор је научног рада учасопису националног значаја категорије M52, као и четири рада у зборницима скупова националног значаја.

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

Изјава о ауторству

Име и презиме аутора: Соња Кнежевић

Број индекса: 2021/5013

Изјављујем

Да је докторска дисертација под насловом

Предиктивно управљање ресурсима у микромрежи

- резултат сопственог истраживачког рада
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа
- да су преузимања коректно наведена и
- да нисам кршио/ла ауторска права и користио/ла интелектуалну својину других лица.

Потпис аутора

У Београду, 19. 02. 2026.



Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора: Соња Кнежевић

Број индекса: 2021/5013

Студијски програм: Електротехника и рачунарство

Наслов рада: Предиктивно управљање ресурсима у микромрежи

Ментор: Милета Жарковић

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла ради похране 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.

Потпис аутора

У Београду, 19. 02. 2026.



Изјава о коришћењу

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

Предиктивно управљање ресурсима у микромрежи

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла 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 одабраној 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)

(Молимо да заокружите само једну од шест понуђених лиценци. Кратак опис лиценце је саставни део ове изјаве.)

Потпис аутора

У Београду, 19. 02. 2026.



1. Ауторство. Дозвољава 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 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 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 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 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 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 отвореногкода.