



**UNIVERZITET CRNE GORE  
ELEKTROTEHNIČKI FAKULTET**

KATARINA VUKIĆEVIĆ

**Prognoza potrošnje električne energije korišćenjem neuralnih  
mreža sa ciljem omogućavanja upravljanja na strani potražnje**

**MASTER RAD**

**Podgorica, oktobar 2023. godine**

**UNIVERZITET CRNE GORE  
ELEKTROTEHNIČKI FAKULTET**

**KATARINA VUKIĆEVIC**

**Prognoza potrošnje električne energije korišćenjem neuralnih  
mreža sa ciljem omogućavanja upravljanja na strani potražnje**

**MASTER RAD**

**Podgorica, oktobar 2023. godine**

## PODACI O MAGISTRANDU

**Ime i prezime:** Katarina Vukićević

**Datum i mjesto rođenja:** 30.08.1998, Pljevlja, Crna Gora

**Naziv završenog osnovnog studijskog programa i godina završetka studija:**  
Elektrotehnički fakultet u Podgorici, Odsjek za Energetiku i Automatiku, 2020.

## INFORMACIJE O MASTER RADU

**Naziv postdiplomskog studija:** Elektroenergetski sistemi

**Naslov rada:** Prognoza potrošnje električne energije korišćenjem neuralnih mreža sa ciljem omogućavanja upravljanja na strani potražnje

**Fakultet na kojem je rad odbranjen:** Elektrotehnički fakultet Podgorica

## UDK, OCJENA I ODBRANA MAGISTARSKOG RADA

**Datum prijave magistarskog rada:** 23.12.2022. godine

**Datum sjednice Vijeća na kojoj je prihvaćena tema:** 24.04.2023. godine

**Mentor:** prof. dr Zoran Miljanić

**Komisija za ocjenu rada:**

Prof. dr Zoran Miljanić

Prof. dr Vladan Radulović

Prof. dr Saša Mujović

**Komisija za odbranu rada:**

Prof. dr Zoran Miljanić

Prof. dr Vladan Radulović

Doc. dr Snežana Vujošević

**Datum odbrane:**

Ime i prezime autora: Katarina Vukićević, BSc

## ETIČKA IZJAVA

Na osnovu člana 22 Zakona o akademskom integritetu, pod punom krivičnom i materijalnom odgovornošću, izjavljujem da je master rad pod nazivom:

**„Prognoza potrošnje električne energije korišćenjem neuralnih mreža sa ciljem omogućavanja upravljanja na strani potražnje”**

rezultat sopstvenog istraživanja i moje originalno djelo.

**Podnositelj izjave:**

**Katarina Vukićević, BSc**

*KATARINA VUKIĆEVIC*

U Podgorici, dana 10.10.2023. godine

**Posveta**

*Mojoj majci*

## Predgovor

U ovom radu je predstavljena primjena algoritma potpuno povezane neuralne mreže za prognozu potrošnje električne energije, sa ciljem da se doprinese programu upravljanja na strani potražnje kroz upoznavanje obrasca korišćenja energije od strane potrošača u elektroenergetskom sistemu.

Zahvaljujem se mentoru, prof. dr Zoranu Miljaniću, na izdvojenom vremenu i korisnim savjetima, koji su mi pomogli u toku pisanja magistarskog rada. Posebnu zahvalnost dugujem svojoj porodici i prijateljima, koji su mi pružali neizmјernu podršku tokom cjelokupnog perioda studiranja.

## Izvod rada

Rastući trend potrošnje električne energije, integracija obnovljivih izvora energije, distribuirane proizvodnje, električnih vozila i jedinica za skladištenje u električnu mrežu, zahtijeva efikasnije korišćenje postojećih resursa u elektroenergetskom sistemu i optimalno upravljanje energijom. Proizvodnja električne energije iz obnovljivih izvora energije, proizvodne jedinice locirane kod potrošača i električna vozila sa stanicama za punjenje na različitim lokacijama, otežavaju očuvanje stabilnosti sistema, odnosno uspostavljanje ravnoteže između proizvodnje i potrošnje električne energije.

Mogućnost upravljanja energijom na nivou potrošača pruža dodatnu fleksibilnost i rezervu elektroenergetskom sistemu za potrebe očuvanja stabilnosti. Pored toga, upravljanjem na strani potražnje je moguće ostvariti benefite koji se odražavaju na elektroenergetsку kompaniju, ali i na krajnje potrošače u električnoj mreži. Pouzdanom prognozom potrošnje električne energije se omogućava predviđanje budućeg opterećenja za preciznije određivanje optimalnog stanja elektroenergetskog sistema i upoznavanje šablonu korišćenja energije od strane potrošača. Na taj način se ostvaruje pouzdano snabdijevanje električnom energijom.

Predmet istraživanja u ovom radu je prognoza potrošnje električne energije korišćenjem neuralnih mreža, sa ciljem omogućavanja upravljanja na strani potražnje, upoznavanjem karakteristika i preferencija potrošača. Prognoziranje budućeg opterećenja u sistemu se vrši na osnovu istorijskih podataka o faktorima od dominantnog uticaja na potrošnju električne energije.

Rezultat istraživanja je prognoza potrošnje električne energije za bolje upoznavanje buduće potražnje u elektroenergetskom sistemu. Na osnovu dobijenih rezultata, moguće je na pravilan način donositi odluke u okviru programa upravljanja na strani potražnje i definisati strategije za određivanje cijena, kojima se potencijalno može smanjiti upotreba električne energije u vremenskim periodima kada je potražnja za električnom energijom najveća.

U ovom radu, za prognozu potrošnje električne energije se koriste istorijski podaci o potražnji za električnom energijom na satnom nivou, za period od pet godina, uz uvažavanje meteoroloških uslova, više i niže tarife za električnu energiju i uticaja prazničnih, radnih i neradnih dana. Pored toga, ulazni skup podataka je proširen sa srednjim vrijednostima i standardnom devijacijom potrošnje električne energije u prethodnim časovima. Rezultati istraživanja su prikazani u tabelarnom i grafičkom obliku. Zaključno poglavlje će predstaviti zaključak istraživanja rada, uz prijedlog o budućim pravcima istraživanja.

**Ključne riječi:** upravljanje na strani potražnje, prognoza potrošnje električne energije, neuralna mreža

## Abstract

The growing trend of electricity consumption, the integration of renewable energy sources, distributed production, electric vehicles and storage units in the electricity grid, requires more efficient use of existing resources in the electricity system and optimal energy management. Production of electricity from renewable energy sources, production units located at consumers and electric vehicles with charging stations at different locations, make it difficult to preserve the stability of the system, that is, to establish a balance between production and consumption of electricity.

The ability to manage energy at the consumer level provides additional flexibility and reserve to the power system for the purposes of maintaining stability. In addition, by managing the demand side, it is possible to achieve benefits that reflect on the electric power company, but also on the end consumers in the electric network. A reliable forecast of electricity consumption makes it possible to predict the future load for a more precise determination of the optimal state of the power system and to learn about patterns of energy use by consumers. In this way, a reliable supply of electricity is achieved.

The subject of research in this paper is the forecast of electricity consumption using neural networks, with the aim of enabling management on the demand side, by getting to know the characteristics and preferences of consumers. Forecasting of the future load in the system is done on the basis of historical data on factors with a dominant influence on electricity consumption.

The result of the research is a forecast of electricity consumption for a better understanding of future demand in the power system. Based on the obtained results, it is possible to make proper decisions within the demand side management program and define pricing strategies, which can potentially reduce the use of electricity during periods of time when the demand for electricity is the highest.

In this paper, historical data on the demand for electricity at the hourly level, for a period of five years, are used to forecast electricity consumption, taking into account meteorological conditions, higher and lower tariffs for electricity and the impact of holidays, working and non-working days. In addition, the input data set is expanded with the mean values and standard deviation of electricity consumption in the previous hours. The research results are presented in tabular and graphical form. The concluding chapter will present the conclusion of the research work, along with a proposal on future research directions.

**Key words:** demand-side management, electricity consumption forecast, neural network

## Sadržaj

1. UVOD .....	15
2. Koncept pametne mreže i upravljanje na strani potražnje .....	17
2.1. Odziv potrošnje .....	19
2.1.1. Programi zasnovani na podsticajima.....	20
2.1.2. Vremenski zasnovani programi.....	21
2.1.3. Ponude za smanjenje potražnje .....	23
2.2. Upravljanje stambenom potražnjom .....	23
2.2.1. Sistem za upravljanje stambenom energijom.....	24
2.2.1.1. Sistem za nadzor.....	25
2.2.1.2. Sistemi za kontrolu i upravljanje energijom .....	26
2.2.1.3. Komunikacioni sistemi.....	27
2.3. Matematička formulacija upravljanja na strani potražnje .....	28
2.4. Benefiti i izazovi upravljanja na strani potražnje.....	29
2.5. Implementacija programa upravljanja na strani potražnje .....	30
2.5.1. Sjedinjene Američke Države.....	30
2.5.2. Velika Britanija .....	32
2.5.3. Australija .....	33
2.5.4. Azijsko-paciifički region .....	34
3. Prognoza potrošnje električne energije .....	36
3.1. Faktori koji utiču na potrošnju električne energije.....	39
3.2. Metode za prognozu potrošnje električne energije .....	41
3.2.1. Statistički zasnovane metode .....	41
3.2.1.1. Regresione metode .....	42
3.2.1.2. Tehnike vremenskih serija .....	42
3.2.1.3. Ostale metode zasnovane na statistici .....	43
3.2.2. Metode zasnovane na vještačkoj inteligenciji .....	44
3.2.2.1. Fazi logika .....	45
3.2.2.2. Ekspertni sistemi .....	46
3.2.2.3. Metod potpornih vektora .....	46
3.2.2.4. Optimizacija rojem čestica .....	49
3.2.2.5. Vještačke neuralne mreže.....	51
4. Potpuno povezana višeslojna neuralna mreža za prognozu potrošnje električne energije.....	52
4.1. Koncept neuralne mreže.....	52
4.1.1. Aktivacione funkcije .....	54
4.2. Strukture neuralnih mreža .....	56

4.3. Tehnike učenja neuralne mreže .....	57
4.4. Algoritam povratne propagacije za treniranje potpuno povezane višeslojne neuralne mreže .....	58
4.4.1. Propagacija unaprijed .....	59
4.4.2. Propagacija unazad .....	61
4.5. Potencijalni problemi primjene algoritma povratne propagacije .....	63
5. IMPLEMENTACIJA SISTEMA ZA PROGNOZU POTROŠNJE ELEKTRIČNE ENERGIJE .....	66
5.1. Ulazni set podataka .....	66
5.2. Opis algoritma neuralne mreže .....	67
5.2.1. Adam algoritam optimizacije .....	69
5.3. Izbor strukture mreže i parametara modela .....	70
5.4. Modifikacija ulaznog skupa podataka sa ciljem poboljšavanja performansi modela neuralne mreže za prognozu potrošnje električne energije .....	73
5.5. Rezultati implementacije sistem za prognozu potrošnje električne energije na karakterističnim primjerima .....	75
5.5.1. Primjer – srijeda, 28. januar 2015. godine .....	75
5.5.2. Primjer – srijeda, 15. jul 2015. godine .....	77
5.5.3. Primjer – srijeda, 27. maj 2015. godine .....	79
5.5.4. Primjer – srijeda, 7. oktobar 2015. godine .....	81
5.5.5. Primjer – nedjelja, 27. decembar 2015. godine .....	83
5.6. Poređenje predložene metode sa ARIMA statističkom metodom za prognozu potrošnje električne energije .....	86
6. ZAKLJUČAK .....	88
LITERATURA .....	91
PRILOG .....	99

**Lista skraćenica:**

DMS – Demand Side Management  
TOU – Time Of Use  
DR – Demand Response  
RTP – Real Time Pricing  
DLC – Direct Load Control  
CPP – Critical Peak Pricing  
IBR – Inclining Block Rate  
ICT – Information and Communication Technology  
PAR – Peak to Average Ratio  
AI – Artificial Intelligence  
ML – Machine Learning  
RDSM – Residential Demand Side Management  
LDC – Load Duration Curve  
AMI – Advanced Metering Infrastructure  
SCADA – Supervisory Control And Data Acquisition  
HAN – Home Area Network  
NAN – Neighborhood Area Network  
MDMS – Meter Data Management System  
EMS – Energy Management System  
EIS – Energy Information System  
IoT – Internet of Things  
GSM – Global System for Mobile Communication  
GPRS – General Packet Radio Service  
WAN – Wide Area Network  
V2G – Vehicle To Grid  
PLC – Power Line Carrier  
PJM – Pennsylvania – Maryland – New Jersey  
CAISO – California Independent System Operator  
LMP – Locational Marginal Price  
STOR – Short Term Operating Reserve  
NDRC – National Development and Reform Commission  
IEA – International Energy Agency  
MEEP – Montenegro Energy Efficiency Project  
LTLF – Long Term Load Forecasting  
MTLF – Medium Term Load Forecasting  
STLF – Short Term Load Forecasting  
VSTLF – Very Short Time Load Forecasting  
BDP – Bruto Društveni Proizvod  
ARMA – Autoregressive Moving Average  
ARIMA – Autoregresive Integrated Moving Average  
ARIMAX – Autoregresive Integrated Moving Average with Exogenous Input Variables  
FARIMAX – Fuzzy Autoregresive Integrated Moving Average with Exogenous Input Variables  
PCA – Principal Component Analysis  
SVM – Support Vector Machine

DWT – Discrete Wavelet Transformation  
SVR – Support Vector Regression  
PSO – Particle Swarm Optimization  
ACO – Ant Colony Optimization  
ABC – Artificial Bee Colony  
FA – Firefly Algorithm  
ANN – Artificial Neural Network  
ReLU – Rectified Linear Unit  
MSE – Mean Squared Error  
MAE – Mean Absolute Error  
APE – Absolute Percentage Error  
MAPE – Mean Absolute Percentage Error

**Popis slika:**

Slika 2.1 Kategorizacija DSM programa .....	18
Slika 2.2 Koncept odziva potrošnje.....	20
Slika 2.3 Tehnike modifikacije krive potražnje .....	24
Slika 2.4 Komponente sistema za upravljanje stambenom energijom [8] .....	25
Slika 2.5 Proizvodnja električne energije u Velikoj Britaniji 2022. godine [30].....	32
Slika 3.1 Dnevni dijagram opterećenja [43].....	36
Slika 3.2 Proces prognoziranja potrošnje električne energije .....	37
Slika 3.3 Linearno razdvojiv SVM model .....	47
Slika 3.4 Linearni SVR model [90].....	48
Slika 4.1 Struktura biološke neuralne mreže [108] .....	52
Slika 4.2 Model vještačkog neurona .....	53
Slika 4.3 Efekat afine transformacije koju izaziva prisustvo biasa [109] .....	54
Slika 4.4 Grafički prikaz aktivacionih funkcija neuralne mreže .....	54
Slika 4.5 <i>Sign</i> aktivaciona funkcija .....	55
Slika 4.6 Modifikovana (nakošena) ReLU funkcija.....	56
Slika 4.7 Jednoslojna <i>feedforward</i> neuralna mreža.....	56
Slika 4.8 Potpuno povezana višeslojna neuralna mreža sa dva skrivena sloja .....	57
Slika 4.9 Neuralna mreža sa dva skrivena sloja (primjer).....	58
Slika 4.10 Lokalni i globalni minimum .....	64
Slika 4.11 Rani prekid treniranja neuralne mreže .....	65
Slika 5.1 Grafički prikaz promjene temperature i brzine vjetra u toku 24 časa (primjer) [125] ...	66
Slika 5.2 Blok šema algoritma neuralne mreže .....	68
Slika 5.3 Stvarna i predviđena kriva potrošnje za srijedu, 28. januar 2015. godine .....	77
Slika 5.4 Stvarna i predviđena kriva potrošnje za srijedu, 15. jul 2015. godine .....	79
Slika 5.5 Stvarna i predviđena kriva potrošnje za srijedu, 27. maj 2015. godine .....	81
Slika 5.6 Stvarna i predviđena kriva potrošnje za srijedu, 07. oktobar 2015. godine .....	83
Slika 5.7 Stvarna i predviđena kriva potrošnje za nedjelju, 27. decembar 2015. godine.....	85

## **Popis tabela:**

Tabela 2.1 Mehanizmi PJM i CAISO tržišta električne energije [25] .....	31
Tabela 2.2 Implementacija DSM programa u zemljama Azijsko-pacifičkog regiona [41] .....	34
Tabela 3.1 Faktori od uticaja na prognozu potrošnje električne energije .....	41
Tabela 4.1 Matematičke interpretacije aktivacionih funkcija neuralne mreže.....	55
Tabela 5.1 Ulagani podaci u neuralnu mrežu za srijedu, 28. januar 2015. godine u Podgorici .....	67
Tabela 5.2 Izbor strukture mreže na osnovu rezultata dobijenih korišćenjem različitih kombinacija broja slojeva i broja neurona za treniranje neuralne mreže.....	71
Tabela 5.3 Promjena prosječne greške modela i vremena trajanja treniranja u zavisnosti od promjene parametra <i>Batch Size</i> .....	72
Tabela 5.4 Promjena prosječne greške modela i vremena trajanja treniranja u zavisnosti od promjene parametra regularizacije <i>Dropout</i> .....	72
Tabela 5.5 Performanse modela neuralne mreže nakon izbora strukture i parametara modela....	73
Tabela 5.6 Promjena srednje kvadratne i srednje apsolutne greške u zavisnosti od broja $k$ .....	74
Tabela 5.7 Uporedna analiza performansi modela prije i poslije korišćenja <i>rolling mean</i> i <i>rolling standard deviation</i> vrijednosti na ulazu neuralne mreže.....	75
Tabela 5.8 Ulagani podaci u neuralnu mrežu za srijedu, 28. januar 2015. godine .....	75
Tabela 5.9 Rezultati implementacije sistema za prognozu potrošnje električne energije za srijedu, 28. januar 2015. godine .....	76
Tabela 5.10 Ulagani podaci u neuralnu mrežu za srijedu, 15. jul 2015. godine .....	77
Tabela 5.11 Rezultati implementacije sistema za prognozu potrošnje električne energije za srijedu, 15. jul 2015. godine .....	78
Tabela 5.12 Ulagani podaci u neuralnu mrežu za srijedu, 27. maj 2015. godine .....	79
Tabela 5.13 Rezultati implementacije sistema za prognozu potrošnje električne energije za srijedu, 27. maj 2015. godine .....	80
Tabela 5.14 Ulagani podaci u neuralnu mrežu za srijedu, 07. oktobar 2015. godine .....	82
Tabela 5.15 Rezultati implementacije sistema za prognozu potrošnje električne energije za srijedu, 07. oktobar 2015. godine.....	82
Tabela 5.16 Ulagani podaci u neuralnu mrežu za nedjelju, 27. decembar 2015. godine.....	84
Tabela 5.17 Rezultati implementacije sistema za prognozu potrošnje električne energije za nedjelju, 27. decembar 2015. godine.....	84
Tabela 5.18 Poređenje predložene metode sa ARIMA statističkom metodom za kratkoročnu prognozu potrošnje električne energije .....	86

## 1. UVOD

Energetska kriza, povećanje potrošnje električne energije i globalni pokret „Go Green“, iniciraju integraciju obnovljivih izvora energije, električnih vozila i jedinica za skladištenje energije u elektroenergetskom sistemu. Prisustvo više od jednog izvora električne energije u mreži iziskuje potrebu za efikasnim sistemom upravljanja energijom. Ključni izazovi za očuvanje sigurnog pogona mreže su intermitentnost proizvodnje električne energije iz obnovljivih izvora energije, vremenski promjenljivo opterećenje i neizvjesnosti povezane sa električnim priključkom vozila [1].

Pravilno dimenzionisanje elemenata elektroenergetskog sistema, sa ciljem izbjegavanja njihovog potencijalnog preopterećenja, koje bi moglo ugroziti pouzdanost napajanja električnom energijom, vrši se na osnovu podatka o iznosu vršne (maksimalne) snage u sistemu. Zemlje u razvoju, porast broja stanovnika i električna vozila, predstavljaju glavne uzroke povećanja vršne snage u sistemu. Kao posljedica povećanja vršne snage, javlja se potreba za izgradnjom novih jedinica za proizvodnju, kako bi se zadovoljila rastuća potražnja za električnom energijom. Elektrane koje se trenutno koriste za pokrivanje vršnog opterećenja u sistemu, karakterišu visoki troškovi za proizvodnju električne energije i emisija štetnih gasova, usljud čega su prepoznate kao veliki zagađivači životne sredine.

Mogućnost prevazilaženja problema povezanih sa porastom vršne snage u sistemu, ugrožavanjem životne sredine i optimalnim upravljanjem postojećim resursima u elektroenergetskom sistemu, prepoznaje se u realizaciji programa upravljanja na strani potražnje. Upravljanje na strani potražnje podrazumijeva planiranje, implementaciju i evaluaciju niza aktivnosti, koje su dizajnirane da ohrabre potrošače da modifikuju svoje obrasce korišćenja električne energije, u pogledu vremena i nivoa potražnje. Program upravljanja na strani potražnje se fokusira na energetsku efikasnost i pomjeranje potražnje iz perioda maksimalnog opterećenja u period niske potražnje za električnom energijom, sa ciljem postizanja željene krive opterećenja. Vršno opterećenje ili vršna snaga predstavlja najveću registrovanu aktivnu snagu, u toku posmatranog vremenskog perioda.

Aktivnim participiranjem balansno odgovornih potrošača, postiže se obostrana korist za potrošače i elektroenergetsku kompaniju, čime se motiviše razvoj tehnika za omogućavanje i bolje prihvatanje programa upravljanja na strani potražnje. Korist za potrošače se ogleda u mogućnosti smanjenja troškova, izbjegavanjem upotrebe električne energije u periodima kada je potražnja, a posljedično i cijena za preuzetu električnu energiju, najveća. Sa druge strane, elektroenergetske kompanije zaobilaze potrebu da angažuju „skupe“ proizvodne jedinice i/ili da kupuju električnu energiju na energetskom spot tržištu, po veoma visokim cijenama.

Cilj istraživanja u radu je razvijanje sistema za pouzdanu prognozu potrošnje električne energije, za potrebe upravljanja na strani potražnje. Prognoza potrošnje električne energije doprinosi boljem razumijevanju načina na koji potrošači koriste električnu energiju, analizom podataka iz prošlosti i uvažavanjem velikog broja uticajnih faktora. Doprinos prognoze budućeg opterećenja prilikom donošenja odluka u okviru programa upravljanja na strani potražnje, uočava se na primjeru određivanja tarifa za vrijeme korišćenja, koje „kažnjavaju“ određene periode potražnje opterećenja.

U savremenom svijetu, neuralne mreže nalaze široku primjenu u predviđanju, klasifikaciji, prepoznavanju, klasterizaciji i mnogim drugim zadacima, kvalitetnom reperezentacijom ulazno-izlaznih veza. Oponašanjem bioloških neurona u mozgu, neuralna mreža „uči“ na primjerima, nakon čega se uspješno primjenjuje i nad podacima koji se prvi put prosljeđuju algoritmu za predviđanje. Neuralne mreže koriste set podataka na osnovu kojih se vrši treniranje, validacija i testiranje modela, dok se kao rezultat dobija prognoza potrošnje električne energije za budući period, sa određenim stepenom greške.

Ovaj rad predlaže korišćenje potpuno povezane višeslojne neuralne mreže za potrebe prognoze potrošnje električne energije, kod koje su svi neuroni jednog sloja međusobno povezani sa neuronima drugih slojeva. Opisana arhitektura neuralne mreže doprinosi dobijanju rezultata prognoze budućeg opterećenja zadovoljavajuće tačnosti, sa ciljem omogućavanja upravljanja na strani potražnje.

U uvodnom razmatranju je opisana problematika kojom se bavi rad, motiv za istraživanje i prijedlog metodologije koja bi mogla doprinijeti rješavanju predstavljenog problema. Drugo poglavlje prezentuje strukturu, funkciju i značaj upravljanja na strani potražnje, sa mogućim načinima na koje se može realizovati. Pored toga, u ovom poglavlju će biti opisana primjena upravljanja na strani potražnje u stambenom okruženju, budući da stambeni potrošači čine najveći dio konzuma u elektrodistributivnom sistemu.

Treće poglavlje obuhvata značaj i potrebu za prognozom potrošnje električne energije, kao i pregled statističkih metoda i metoda zasnovanih na vještačkoj inteligenciji, koje se mogu koristiti u svrhu prognoziranja potrošnje električne energije. U četvrtom poglavlju je predstavljen algoritam povratne propagacije, koji se koristi za treniranje potpuno povezane višeslojne neuralne mreže. Algoritam za prognozu potrošnje električne energije se implementira u programskom jeziku *Python*, nakon čega je izvršena analiza dobijenih rezultata.

## 2. KONCEPT PAMETNE MREŽE I UPRAVLJANJE NA STRANI POTRAŽNJE

Pametna mreža (eng. *Smart Grid*) predstavlja elektroenergetsku mrežu zasnovanu na digitalnoj tehnologiji, koja se koristi za snabdijevanje potrošača električnom energijom, putem dvosmjerne digitalne komunikacije. Cilj takve mreže je poboljšanje efikasnosti, smanjenje potrošnje energije, smanjenje troškova, kao i povećanje transparentnosti i pouzdanosti snabdijevanja energijom.

Prelaskom na pametnu mrežu se prevazilaze slabosti konvencionalnih električnih mreža, korišćenjem pametnih električnih brojila. Sistem pametne mreže je automatizovan za praćenje, analizu, kontrolu i komunikaciju unutar lanca snabdijevanja. Mrežna arhitektura je kombinovana sa softverom za upravljanje energijom za procjenu potrošnje energije i povezanih troškova za određenu kompaniju.

Uopšteno, cijene električne energije rastu zajedno sa potražnjom. Pružajući potrošačima informacije o trenutnoj potrošnji i cijenama energije, usluge upravljanja energijom pametne mreže pomažu da se minimizuje potrošnja u vremenima visokih troškova i vršne potražnje. Ključne karakteristike pametne mreže uključuju [2]:

- Upravljanje opterećenjem – ukupno opterećenje električne mreže nije stabilno i varira tokom vremena. U slučaju velikog opterećenja, sistem pametne mreže može da savjetuje potrošače da privremeno smanje potrošnju energije.
- Podršku za odziv potrošnje – pruža korisnicima automatizovan način da smanje račune za preuzetu električnu energiju, tako što ih navodi da koriste električne uređaje niskog prioriteta, kada su cijene niže.
- Decentralizaciju proizvodnje električne energije – distribuirani ili decentralizovani mrežni sistem omogućava pojedinačnom korisniku da generiše električnu energiju na licu mjesta, koristeći bilo koji odgovarajući metod, po sopstvenom nahođenju.

Realizacija pametne mreže zahtijeva modifikaciju postojećeg elektroenergetskog sistema, koja podrazumijeva instalaciju senzora, uređaja za komunikaciju u realnom vremenu, podatke procesne centrale, kao i promjene u procesu komercijalizacije [3].

Upravljanje na strani potražnje (eng. *Demand Side Management-DSM*) je veoma značajna komponenta pametne mrežne arhitekture, koja pruža mogućnost potrošačima da modifikuju obrazce korišćenja električne energije. DSM program se koristi za zadovoljavanje potražnje i povećanje efikasnosti korišćenja postojeće infrastrukture distributivnih sistema. Koncept DSM programa je klasifikovan u dvije grupe [4]:

1. Programi za uštedu ili očuvanje energije – ovi programi su osmišljeni tako da podstaknu potrošače da zamijene svoju neefikasnu opremu sa uređajima koji manje troše električnu energiju i proizvode istu uslugu, u pogledu kvaliteta i kvantiteta. Na ovaj način, postiže se promjena ponašanja potrošača.
2. Programi za upravljanje opterećenjem – programi dizajnirani u cilju smanjenja perioda vršne potražnje i ekonomičnijeg korišćenja postojećih resursa, kroz pomjeranje potražnje tokom vremena.

Programi upravljanja opterećenja su od suštinskog značaja za prevazilaženje ograničenja u pogledu zadovoljavanja potražnje za električnom energijom u realnom vremenu.

Jednostavna DSM šema može da obezbijedi novčanu korist potrošačima, ako se koriste uređaji tolerantni na kašnjenje (mašina za pranje sudova, mašina za pranje veša) tokom noći, umjesto tokom dana, posebno u periodima visoke potražnje za električnom energijom. Iako je pojedinačna potrošnja takvih uređaja mala, učešće potrošača na nivou susjedstva ili grada, značajno će uticati na pametnu mrežu. Cilj je da se DSM proširi i na druge tipove uređaja u vlasništvu potrošača, kao što su jedinice za skladištenje ili obnovljivi izvori energije, čija bi potrošnja i korišćenje mogli biti značajniji od standardnih uređaja [5].

Na slici 2.1 je prikazana kategorizacija DSM programa, u zavisnosti od vremena i uticaja promjenljivih veličina na procese potrošača:



Slika 2.1 Kategorizacija DSM programa

Mjere energetske efikasnosti podrazumijevaju trajne promjene na opremi ili poboljšanje fizičkih svojstava sistema, rezultirajući trenutnim i trajnim uštedama energije i emisije štetnih gasova, zbog čega su i najpoželjnija DSM kategorija. Očuvanje energije se može posmatrati kao dio energetske efikasnosti, pri čemu je fokus na promjeni ponašanja potrošača, da bi se postigla efikasnija upotreba energije.

Tarife za vrijeme korišćenja (eng. *Time Of Use*-TOU) kažnjavaju korišćenje energije u određenim vremenskim periodima većom cijenom za preuzetu električnu energiju. Na taj način se motivišu potrošači da preurede svoje procese, kako bi minimizovali troškove za preuzetu električnu energiju. Ova tehnika pomaže u kontroli tarife vršnog opterećenja. Promjena u rasporedu cijena korišćenjem tarifa, prilagođenim određenim vremenskim intervalima koji su kritični u periodu od jednog dana, podrazumijevaju promjenu ugovora o snabdijevanju. Uzimajući u obzir navedeno, ovim aktivnostima se ne pribjegava veoma često.

Obrtna rezerva se odnosi na snagu koja je dostupna operatoru distributivne mreže (eng. *Distribution System Operator*) da obezbijedi ravnotežu između potrošnje i proizvodnje, u slučaju poremećaja u isporuci električne energije.

„Virtuelna“ rezerva, ostvarena pomoću opterećenja, posmatra se kao primarna (izlazna aktivna snaga direktno zavisi od frekvencije) i sekundarna kontrola (stabilizacija frekvencije i stanja mreže sa dodatnom aktivnom snagom). Ovo je obično zadatak regulacionih elektrana.

Programi odziva potrošnje (eng. *Demand Response*-DR) se odnose na odstupanja u preuzimanju električne energije, koja nastaju kao odgovor na promjene jediničnih tarifa i na osnovu podsticajnih programa. Takvi programi se nude sa ciljem smanjenja potrošnje električne energije tokom perioda visokih tarifa na energetskom tržištu ili u slučaju kada je stabilnost mreže ugrožena. DR je DSM rješenje koje cilja na stambene, poslovne i industrijske potrošače, razvijeno u cilju smanjenja ili pomjeranja potražnje u određeno vrijeme, na određeno vremensko trajanje [6]-[8].

Svaki od prethodno navedenih programa doprinosi smanjenju potrebe za izgradnjom novih proizvodnih jedinica. Ulaganje u energetsku efikasnost omogućava efikasnije korišćenje energije, smanjujući potražnju tokom dana. Vremenski varijabilne cijene, kao što su cijene za vrijeme korišćenja, bolje usklađuju cijene električne energije sa troškovima proizvodnje. To znači da će u vrijeme velike potražnje cijena biti veća, uslijed čega su potrošači podstaknuti da koriste manje energije, dok bi koristili više kada je potražnja mala, a cijena niža. Programi odziva potrošnje pružaju finansijske podsticaje za smanjenje potrošnje energije tokom perioda najveće potražnje, u slučaju da to zahtijeva elektroenergetska kompanija [9].

## 2.1. Odziv potrošnje

Federalna regulatorna komisija za energiju (eng. *Federal Energy Regulatory Commission*-FERC) definiše DR kao: „Promjene u upotrebi električne energije od strane resursa na strani potražnje u odnosu na njihove normalne obrasce potrošnje, kao odgovor na promjene cijene za električnu energiju ili na podsticajna plaćanja namijenjena da indukuju nižu potrošnju električne energije u vrijeme visoke veleprodajne tržišne cijene ili kada je ugrožena pouzdanost sistema“ [10].

Programi za upravljanje opterećenjem se obično odnose na tradicionalne aplikacije za DSM, koje se uglavnom bave smanjenjem potrošnje električne energije tokom vršne potražnje i vanrednih uslova. Sa druge strane, DR programi se odnose na nedavne i nove aplikacije za DSM, kao što je poboljšanje pouzdanosti mreže, pružanjem pomoćnih usluga ili smanjenjem veleprodajnih cijena električne energije i njihove volatilnosti [11]. U stvarnoj implementaciji, DR predstavlja privremeno smanjenje ili promjenu opterećenja u periodima korisnim za sistem snabdijevanja električnom energijom. Na osnovu stranke koja je inicirala smanjenje potražnje, DR programi se mogu klasifikovati na način predstavljen na slici 2.2.

Potreba za donošenjem odluka gotovo u realnom vremenu i upotreba velikog broja podataka rezličite prirode, čini vještačku inteligenciju (eng. *Artificial Intelligence*-AI) i mašinsko učenje (eng. *Machine Learning*-ML), ključnim alatima za omogućavanje DR-a. AI metode se mogu koristiti za rješavanje različitih izazova, poput odabira optimalnog skupa potrošača za odziv, učenje njihovih karakteristika i preferencija, dinamičko određivanje cijena, zakazivanje i kontrolu uređaja, predviđanje potrošnje električne energije, pravilno podsticanje potrošača da učestvuju u DR programima i koncipiranje benefita koji im se nude za učešće, na pravičan i ekonomski prihvatljiv način [12].



Slika 2.2 Koncept odziva potrošnje

DR programi se alternativno mogu klasifikovati na osnovu načina učešća u sistemu:

- Tržišni DR
- Fizički DR

Tržišni DR se oslanja na određena tržišta na kojima se formiraju cijene i obavlja trgovina. U ovom slučaju se ne postiže dovoljna brzina procesa, pa se većina transakcija ostvaruje dan unaprijed. Izuzetak predstavlja situacija u kojoj se cijene određuju u realnom vremenu, gdje se cijene energetskog spot tržišta proslijeduju potrošačima, bez odlaganja. Potrošači imaju mogućnost da učestvuju na tržištu električne energije, zauzvrat dobijajući određene benefite za prilagođavanje sopstvene potrošnje. Potrošači malih snaga, kao što je domaćinstvo, mogu na energetskom tržištu imati slična prava, ali ne mogu učestvovati na isti način kao i potrošači velikih snaga (kvalifikovani potrošači) ili velike elektrane za proizvodnju električne energije. Radi olakšanja, pojavljuje se novi subjekt – agregator potrošnje, aktivan na energetskom tržištu za sve potrošače koje zastupa. Agregator potrošnje objedinjuje veliki broj potrošača malih snaga i upravlja njihovom potrošnjom, pod određenim uslovima.

Fizički DR šalje obavezujuće zahteve za upravljanje na strani potrošnje, u slučaju da mreža ili djelovi mrežne infrastrukture imaju smanjene performanse, uslijed održavanja ili kvarova. Odraz zagušenja i prekomjerne ponude energije vjetra na cijenu, može zahtijevati redukovanje ponašanja potrošača. Međutim, ograničena elastičnost potrošača i fizička ograničenja, koja nijesu uključena u cijenu za električnu energiju, ukazuju na činjenicu da se stvarno smanjenje opterećenja u cilju rasterećenja mreže ne može izvršiti samo preko cijena. Kombinacija fizičkog i tržišnog DR-a je obično neophodna za optimalno upravljanje električnom mrežom.

### 2.1.1. Programi zasnovani na podsticajima

U DR programima zasnovanim na podsticajima emituju se signali za smanjenje opterećenja, upućeni potrošačima, a isti se manifestuju kao:

- Direktna kontrola opterećenja (eng. *Direct Load Control-DLC*)
- Prekidne/smanjene tarife (eng. *Interruptible Rate Program*)
- Programi reagovanja na hitne slučajeve (eng. *Emergency DR Programs*)
- Programi licitiranja na zahtjev (eng. *Demand Bidding Programs*)

Direktna kontrola opterećenja podrazumijeva da mrežni operator ima slobodan pristup procesima potrošača, registrovanih od strane operatora, kao i mogućnost daljinskog isključenja i/ili modifikacije radnog ciklusa u toku perioda vršnog opterećenja u sistemu. U DLC programima, opterećenje potrošača je direktno kontrolisano od strane lokalnog operatora ili aggregatora. Tokom trajanja programa, ova opterećenja se uključuju/isključuju sa mreže ili prelaze na period niže potražnje u vrlo kratkom roku. Strategija DLC je u najvećoj mjeri usmjerena na mala komercijalna i stambena opterećenja, dok podsticajne isplate programa uključuju fiksna mjesecna plaćanja koja se pripisuju na račun potrošača.

Postoji nekoliko ograničenja za postojeće vrste DLC programa, kao što je primjena samo u hitnim slučajevima, zbog čega se ne mogu iskoristiti kao resurs za operativnu fleksibilnost u slučaju potrebe uspostavljanja balansa između ponude i potražnje. Pored toga, postoje komplikacije sa aspekta proračuna i komunikacionih zahtjeva u slučaju obimne baze podataka, ali i narušavanje privatnosti potrošača, koji su izloženi daljinskoj kontroli od strane centralnog kontrolera [13].

Prekidne/smanjene tarife se primjenjuju kod kvalifikovanih potrošača, sa vršnom potražnjom od minimum 1 MW, od kojih se može zahtijevati da smanje svoju potrošnju električne energije na traženi nivo, u vremenskom periodu od petnaest minuta. Potrošač se ugovorom obavezuje da će smanjiti najmanje 50% potražnje za električnom energijom, tokom procesa koji je moguće prekinuti [14]. Učešćem u programu, potrošači ostvaruju benefite u vidu mjesecnog kredita, čime troškovi za preuzetu električnu energiju postaju niži, ali mogu biti kažnjeni u slučaju da ne smanje svoju potrošnju kada se to zahtijeva [15].

U sklopu programa reagovanja na hitne slučajeve, potrošači imaju mogućnost da dobrovoljno smanje svoje opterećenje, kada je takva aktivnost potrebna sistemu, dobijajući određene beneficije u vidu podsticaja. Tokom vršnih perioda ili vanredne situacije, potrošači mogu imati koristi svojom spremnošću da redukuju određenu potrošnju, po određenoj tarifi ponude.

Programi licitiranja na zahtjev se obično nude korisnicima sa potrošnjom većom od 1 MW i kod „malih“ potrošača, pri čemu je potrebno zastupanje treće strane za njihovo učešće u nadmetanju.

### 2.1.2. Vremenski zasnovani programi

Vremenski zasnovani DR programi omogućavaju da se potrošačima obezbijede različite tarifne stope u različitim periodima. Na osnovu informacija o tarifi, potrošači će imati niže zahtjeve za električnom energijom tokom perioda visokih cijena, što rezultira smanjenjem potražnje u vršnim periodima u toku dana. Opisani programi ne pribjegavaju direktnoj kontroli električnih aparata, već sami potrošači utiču na sopstvene obrasce potrošnje.

U vremenski zasnovane DR programe spadaju:

- Tarife za vrijeme korišćenja (TOU)
- Kritična vršna cijena (eng. *Critical Peak Pricing-CPP*)

- Određivanje cijena u realnom vremenu (eng. *Real Time Pricing*-RTP)
- Tarifa brzine promjene potrošnje (eng. *Inclining Block Rate*-IBR)

Cijena električne energije se u slučaju TOU tarife razlikuje u zavisnosti od doba dana: za vršni, srednji vršni i vanvršni period. U ovoj kategoriji, cijene su unaprijed poznate potrošačima. TOU tarife su tradicionalno bile obavezne za velike komercijalne i industrijske potrošače i variraju tokom godine, u zavisnosti od sezone, što je u suprotnosti sa paušalim stopama koje plaća većina stambenih potrošača. Nedostatak ovih tarifa je u tome što se na ovaj način ne odražavaju stvarni troškovi isporuke električne energije, kao i statična priroda ovih programa. U slučaju postojanja više od dvije tarife u toku jednog dana, veliki broj potrošača optimizaciju upotrebe energije smatra velikim izazovom. Za primjenu većine vremenski promjenljivih tarifa je potrebno zadovoljiti određeni stepen automatizacije na strani potrošača, kao što je posjedovanje pametnih termostata sa tajmerima.

CPP predstavlja manje unaprijed određenu varijantu TOU tarifa. Ova strategija se primjenjuje uglavnom u slučajevima kada opterećenje prelazi 20 kW, uz mogućnost pametnog mjerjenja koje bilježi potrošnju električne energije, za petnaestominutni vremenski interval. U kritičnom periodu, TOU vršna tarifa se zamjenjuje CPP tarifom.

RTP strategija je takođe poznata kao dinamička strategija određivanja cijena, gdje određeni vremenski intervali imaju različite tarife, o kojima su potrošači obaviješteni sat unaprijed (eng. *Hourly-Ahead Tariffs*) ili dan unaprijed (eng. *Day-Ahead Tariffs*). Za razliku od TOU tarifa, RTP odražava stvarnu veleprodajnu tržišnu cijenu za preuzetu električnu energiju, ali zahtijeva najveći nivo sofisticiranosti za podršku odlučivanju i infrastrukturu informaciono-komunikacionih tehnologija (eng. *Information and Communication Technology*-ICT) na nivou potrošača.

Potrebna infrastruktura uključuje automatizovano intervalno mjerjenje, mehanizme za predviđanje cijena, sisteme komunikacije i naplate, kao i pametni sistem upravljanja energijom na strani potrošača. U praksi, samo mali broj potrošača ima dovoljno elastičnosti potražnje da opravda ulaganje i učešće u RTP programima, ali se ovaj program smatra jednim od najsposobnijih i ekonomski izvodljivijih strategija za određivanje cijena zasnovanih na vremenu.

Različite metode određivanja cijena, usvojene su da bi se postiglo efikasnije korišćenje mreže. TOU tarife se manje koriste jer ne moraju nužno da smanje vršnu potrošnju električne energije, uz rizik stvaranja naglog porasta potražnje u vanvršnom periodu tokom dana. Shodno tome, efikasnijim za primjenu u DR programima se smatraju metode određivanja cijena zasnovane na opterećenju (tarife za električnu energiju variraju proporcionalno opterećenju elektroenergetskog sistema), u odnosu na vremenski zasnovane metode [16].

IBR praktikuje korišćenje dva različita bloka tarifne strukture: blok niske i blok visoke cijene za električnu energiju. Veća potrošnja električne energije dovodi do prebacivanja potrošača na viši tarifni blok, djelujući kao neka vrsta određivanja cijena zasnovanih na kaznama, nakon prekoračenja određene granice potrošnje. IBR daje podsticaje potrošačima, na osnovu kojih oni redukuju upotrebu električne energije prema drugim periodima dnevnog vremenskog okvira, izbjegavajući visoke tarife i rezultirajući smanjenjem odnosa vrha i prosjeka (eng. *Peak to Average Ratio*-PAR). Koristeći numeričke simulacije, ustanovljeno je da se značajno smanjenje PAR-a može postići dinamičkim cijenama koje se prilagođavaju ponašanju potrošača [5].

### 2.1.3. Ponude za smanjenje potražnje

Ponude za smanjenje potrošnje (eng. *Demand Reduction Bids*) prenose informacije potrošačima o raspoloživom kapacitetu za smanjenje potražnje i cijeni električne energije. Ova strategija ubjeđuje velike potrošače da smanje svoje opterećenja, po cijeni koja je prihvatljiva za redukciju potrošnje određene količine električne energije [7].

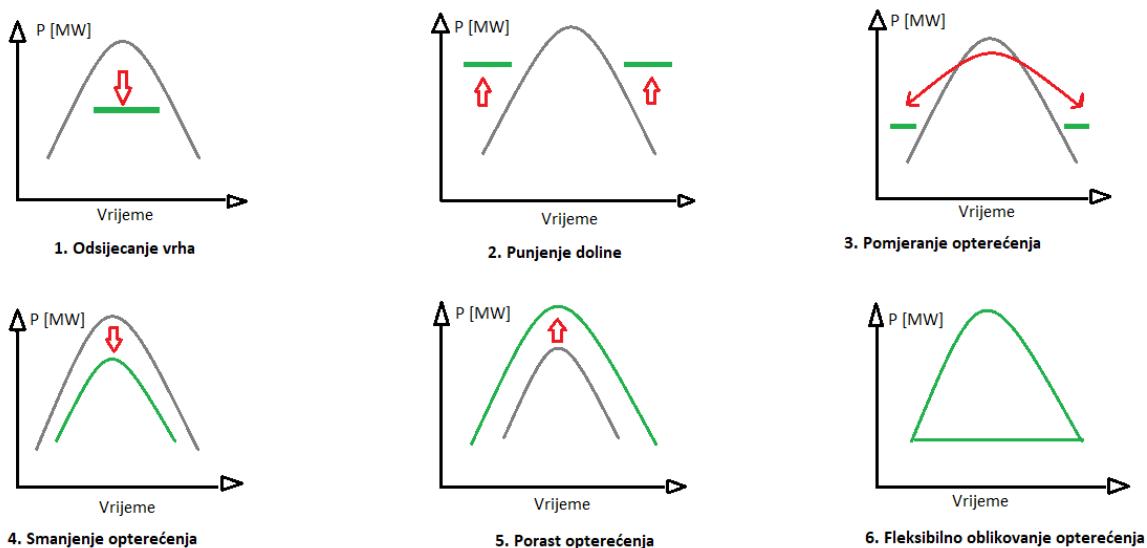
## 2.2. Upravljanje stambenom potražnjom

Stambeno opterećenje čini glavni dio potrošnje električne energije u elektroenergetskom sistemu, uslijed čega je velika pažnja posvećena upravljanju stambenom potražnjom (eng. *Residential Demand Side Management-RDSM*). Fleksibilna implementacija DSM programa na nivou stambenih potrošača obezbjeđuje maksimalnu korist za elektroenergetsku kompaniju, ali i samog potrošača.

Kriva trajanja opterećenja (eng. *Load Duration Curve-LDC*) predstavlja jedan od najvažnijih resursa za analizu elektroenergetskog sistema i optimalno upravljanje električnom energijom. LDC se koristi u elektroenergetici radi ilustracije veze između zahtjeva za proizvodnim kapacitetom i iskorišćenosti kapaciteta. Podaci o potražnji u slučaju LDC su poređani opadajućim redoslijedom, za razliku od hronološkog prikaza podataka potražnje u slučaju krive potražnje [17].

Proces modifikacije krive potražnje kod krajnjih potrošača ima za cilj minimizaciju vršnih opterećenja i jediničnih tarifa električne energije. Postoji šest različitih tehnika oblikovanja krive potražnje, prikazanih na slici 2.3:

1. Odsijecanje vrha (eng. *Peak Clipping*) – odnosi se na DLC tehniku smanjenja potražnje za opterećenjem u toku vršnog perioda. Na ovaj način se izbjegavaju visoki kapitalni troškovi za izgradnju novih proizvodnih jedinica.
2. Punjenje doline (eng. *Valley Filling*) – podrazumijeva podsticanje potrošača da koriste električne uređaje tokom trajanja nižih tarifa, sa ciljem maksimizacije upotrebe energije tokom vanvršnog perioda.
3. Pomjeranje opterećenja (eng. *Load Shifting*) – fokusira se na odlaganje potrošnje sa vršnog na vanvršni period, na osnovu niže cijene za preuzetu električnu energiju. Ova tehnika omogućava smanjenje vršne snage, umanjenje troškova rada elektrana i izbjegavanje potrebe za izgradnjom novih i skupih jedinica za proizvodnju električne energije. *Load Shifting* tehnika je jedan od najznačajnijih tradicionalnih resursa za upravljanje opterećenjem.
4. Smanjenje opterećenja (eng. *Load Reduction*) – predstavlja strategiju uštede energije, koja cilja na modifikaciju opterećenja kod potrošača kroz ciklični rad ili upotrebu efikasnijih električnih uređaja.
5. Porast opterećenja (eng. *Load Growth*) – podrazumijeva povećanje potrošnje električne energije do određenog praga, podsticajima koji su ponuđeni potrošačima, sa ciljem održavanja stabilnosti mreže i normalnog radnog stanja u sistemu.
6. Fleksibilno oblikovanje opterećenja (eng. *Flexible Load Shaping*) – obuhvata preraspoređivanje korišćenja opterećenja na nekoliko slotova perioda. Na ovaj način se pruža mogućnost potrošačima da ostvare benefite za dobrovoljno pružanje fleksibilnosti u svom opterećenju.



Slika 2.3 Tehnike modifikacije krive potražnje

### 2.2.1. Sistem za upravljanje stambenom energijom

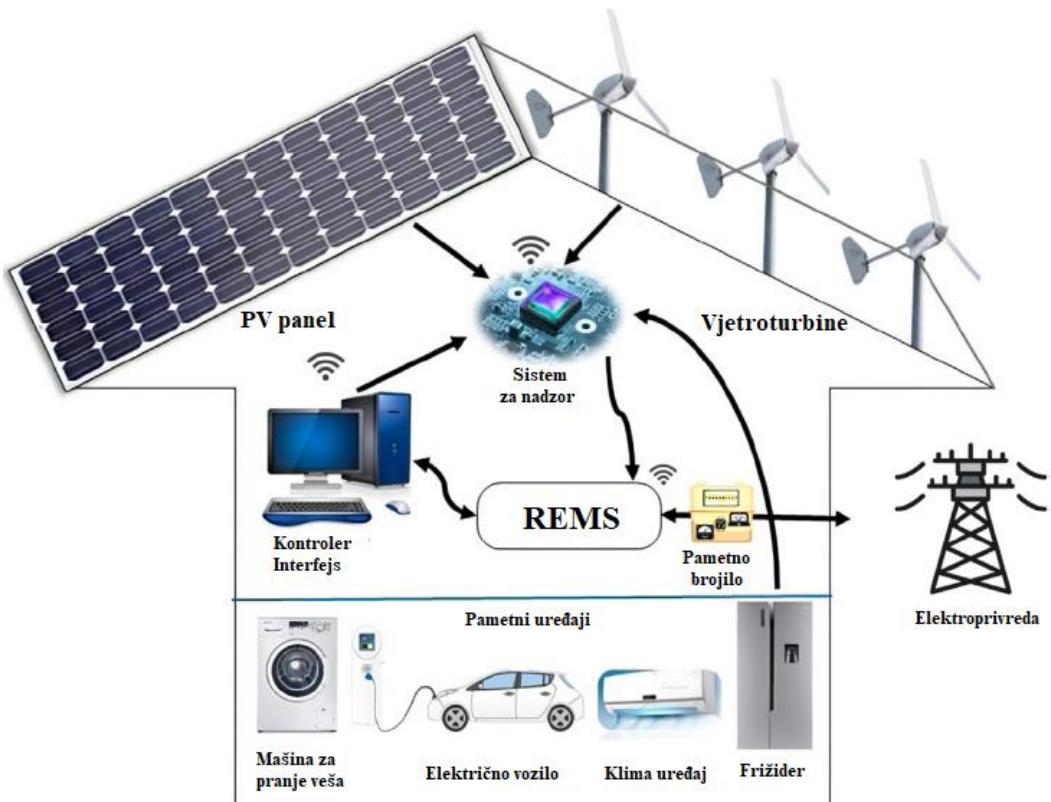
Pametno upravljanje energijom obuhvata upravljanje na strani potražnje, trgovinu energijom i upravljanje jedinicama za skladištenje energije. Primjena efikasnih mehanizama za upravljanje energijom i budućim sistemima pametnih mreža se suočava sa mnogim izazovima, kao što je aktivno korišćenje pametnih brojila i sistema za upravljanje energijom zasnovanih na potrošnji, kako bi se vremenom oblikovalo ukupno opterećenje mreže.

Oblikovanje opterećenja je neophodno za efikasan rad velike pametne mreže. Omogućavanje takvog DSM-a zahtijeva povećanu automatizaciju i aktivno učešće potrošača u mreži. Izazov predstavlja i pravilna integracija i korišćenje uređaja za skladištenje podataka u mreži.

Na kraju, ali ne i najmanje važan, postoji izazov u odlučivanju na koji način integrisati i iskoristiti izvore energije locirane kod potrošača, kao što su solarni paneli, u okviru operativnog sistema mreže. Generalno, upravljanje energijom u pametnoj mreži uključuje planiranje i rad jedinica za proizvodnju i potrošnju energije, posebno kada su takve jedinice u vlasništvu potrošača [5].

Sistem za upravljanje stambenom energijom (eng. *Residential Energy Management System - REMS*) obezbjeđuje automatizaciju i pametnu kontrolu električnih aparata unutar stambenog okruženja, u cilju smanjenja ukupne potrošnje energije. Implementacija REMS-a je omogućena korišćenjem naprednih komunikacionih tehnologija, efikasnim i preciznim upravljanjem senzorima i evolucijom cjelokupnog upravljanja energijom sistema u cjelini.

Doprinos REMS-a se ogleda u smanjenju troškova za preuzetu električnu energiju, minimizaciji vršnog opterećenja, integraciji obnovljivih izvora energije i optimizaciji sa ciljem efikasnije potrošnje električne energije. Na slici 2.4 su prikazane neophodne komponente za pravilnu primjenu DSM tehnika, korišćenjem REMS-a: sistemi za nadzor, sistemi za kontrolu i upravljanje energijom i komunikacioni sistem.



Slika 2.4 Komponente sistema za upravljanje stambenom energijom [8]

### 2.2.1.1. Sistem za nadzor

Sistem za nadzor, kao komponenta REMS- a, odgovoran je za praćenje aktivnosti koje se odnose na profil opterećenja, tok snage, mjerjenje i evidenciju senzornih podataka. Komponente sistema za nadzor su:

- Pametno brojilo (eng. *Smart Meter*)
- Napredna mjerna infrastruktura (eng. *Advanced Metering Infrastructure-AMI*)
- Pametni uređaji (eng. *Smart Appliances*)
- Senzori i pametni senzori (eng. *Sensors and Smart Sensors*)

Pametno brojilo služi za daljinsko mjerjenje potrošnje električne energije, kao i druge neophodne parametre kvaliteta električne energije u određenim periodima, prenoseći prikupljene informacije putem komunikacionih veza do centralnog operatora. Sposobnost komunikacije u realnom vremenu sa kontrolnim centrom elektroenergetske kompanije, pruža operatoru sistema različite mogućnosti za aktivnu kontrolu i praćenje potrošnje električne energije. Pametno brojilo omogućava potrošačima stalni pristup podacima o potrošnji, dok račun preslikava stvarnu šemu korišćenja električne energije.

Klasifikacija pametnih brojila se može izvršiti na osnovu njihovih karakteristika, poput mogućnosti evidentiranja podataka, korišćenog komunikacionog linka, načina rada i protokola za interakciju sa drugim pametnim brojilima u okruženju. Predstavljene mogućnosti nesumnjivo mijenjaju način na koji se energija generiše i distribuira potrošačima. Potrebni su protokoli i mehanizmi za pametno upravljanje energijom, da bi se iskoristile mogućnosti koje donosi nova infrastruktura pametne mreže [5].

AMI predstavlja hardversku i softversku infrastrukturu koja služi za daljinsko očitavanje potrošnje električne energije i direktno (automatsko) prikupljanje statusa napajanja potrošača. Pored toga, AMI ima mogućnost daljinskog očitavanja vrijednosti napona kod krajnjih potrošača.

AMI se sastoji od pametnih brojila, koncentratora podataka i softverskog modula koji prikupljene podatke smješta na jedno, centralno mjesto. Vremenski horizont daljinskog očitavanja pomoću AMI se razlikuje, odnosno može biti na nivou: jednog dana, jednog sata, petnaest minuta ili jednog minuta. Manji vremenski horizont daljinskog očitavanja znači skuplju implementaciju. Podaci prikupljeni na ovaj način su „kvazi-telemetrisani“, budući da vremenski horizont prikupljanja tih podataka nije u realnom vremenu, kao što je to slučaj kod sistema za nadgledanu kontrolu i prikupljanje podataka (eng. *Supervisory Control And Data Acquisition-SCADA*). Vrijednosti potrošnje/proizvodnje dobijene korišćenjem AMI, mogu se koristiti u svrhu ažuriranja prognozirane potrošnje/proizvodnje električne energije [18].

Podsistemi koji su u interakciji sa AMI, na različitim nivoima, su HAN (eng. *Home Area Network*), NAN (eng. *Neighborhood Area Network*) i MDMS (eng. *Meter Data Management System*). Navedeni podsistemi olakšavaju povezivanje pametnih uređaja, pružaju potrošačima fleksibilni pametni interfejs za komunikaciju sa tržistem električne energije, podržavaju bezbjednost upravljanja i praćenje, uz prenos podataka ka centralnoj bazi podataka. Podešavanje baze podataka, koristeći MDMS, podrazumijeva niz operacija, kao što su analiza, validacija, modifikacija i procjena podataka, dostavljenih od strane AMI.

Pametni uređaji obuhvataju električne aparate u domaćinstvima koji su opremljeni računarskim i komunikacionim sposobnostima za preuzimanje nadzora i mjerjenje aktivnosti samostalno, u koordinaciji sa interfejsom za upravljanje energijom. Jedinice za proizvodnju električne energije, poput solarnih panela i vjetroturbina, lociranih kod potrošača, takođe se smatraju pametnim uređajima.

Senzori i pametni senzori imaju sposobnost mjerjenja fizičkih uslova i stanja, kao što su temperatura, vlažnost, kretanje ili osvijetljenost. Ovi uređaji mogu biti bežično ili fizički povezani sa uređajima za praćenje i evidentiranje podataka sa senzora, koji se prenose sistemu za upravljanje energijom i na taj način olakšavaju optimizaciju obrasca korišćenja uređaja.

### **2.2.1.2. Sistemi za kontrolu i upravljanje energijom**

Ove komponente REMS-a su odgovorne za dispečiranje energije, kontrolu i isključivanje uređaja. Komponente, uključene u ovu infrastrukturu, klasifikovane su na sljedeći način:

- Sistem za upravljanje energijom (eng. *Energy Management System-EMS*)
- Energetski informacioni sistem (eng. *Energy Information System-EIS*)
- Pametni termostat (eng. *Smart Thermostat*)
- Pametne utičnice (eng. *Smart Plugs*)

EMS ima mogućnost nadzora, optimizacije i kontrole potrošača, distributivne mreže, prenosne mreže i proizvodnje električne energije. EMS može efikasno koordinisati trgovinu energijom između svih raspoloživih energetskih resursa i ekonomično snabdijevanje u svim uslovima za pouzdan, bezbjedan i efikasan rad elektroenergetskog sistema [1].

U realnom vremenu, sistem za upravljanje energijom uključuje različite kontrolne tehnike, kao što je kontrola opterećenja (eng. *Load Control*), DSM i sistem za upravljanja distributivnom mrežom (eng. *Distribution Management System*).

Najvažnija uloga EMS-a je da obezbijedi ravnotežu između ponude i potražnje na efikasan način, koji bi trebalo da bude isplativ u okviru operativnih ograničenja i neizvjesnosti, koje uključuju varijacije u proizvodnji iz obnovljivih izvora energije, cijenu električne energije i ponašanje potrošača. Pored navedenog, EMS može obavljati ulogu za SCADA aplikacije u realnom vremenu, dispečiranje, kontrolu, planiranje proizvodnje energije i računovodstvo, kao i upravljanje bezbjednošću prenosa.

EIS omogućava dvosmjernu komunikaciju između EMS sistema ili grupe EMS sistema i uslužnog programa. EIS je uglavnom ugrađen u EMS za razmjeru podataka o energiji i upravljanju potrošnjom energije za DSM aplikacije, prijavljujući parametre sistemskih performansi podjedinica, krajnjih jedinica i lokalnog operatera. Prikupljeni podaci iz EIS-a se dalje koriste za analizu profila upravljanja zgradom, informacije o naplati i upozorenja koja se odnose na sistem informacija i operacija.

Pametni termostat je jedan od najznačajnijih djelova sistema kućne automatizacije, koji pruža uvid o radnim stanjima za analizu i obradu parametara održavanja temperature potrošača. Implementacija senzora, zasnovanih na vještačkoj inteligenciji i mašinskom učenju, uključujući i mrežne funkcije ugrađene u same pametne termostate, čine pametni aspekt ovih uređaja. Pametni termostat omogućava daljinski pristup i komunikaciju sa AMI podešavanjima. U kombinaciji sa senzorima blizine, detektorima pokreta i drugim algoritmima za učenje, pametni termostati mogu pomoći uređajima da se prilagode promjenama temperature, vlažnosti i laminaciji, prema unaprijed evidentiranim podacima ambijentalnih uslova kod potrošača, u različitim periodima dana. Smanjenje temperature tokom noćnih sati, dok potrošači spavaju, rezultira uštedom električne energije i prirodnog gasa za oko 20,72% i 17,7%, respektivno. U slučaju smanjenja ili potpunog isključenja termostata, kada su potrošači van domaćinstva na određeni broj sati, ušteda električne energije i prirodnog gasa u prosjeku iznosi 35,41% i 10,28%, respektivno [19].

Pametne utičnice omogućavaju mjerjenje potrošnje električne energije i prepoznavanje tipa priključenih uređaja. Analizom električnog uređaja sa kojim je povezana, pametna utičnica može dodijeliti neophodne kontrolne mehanizme, zasnovane na praćenju profila opterećenja. Evidenciju potrošnje i prenos podataka do EMS-a, omogućavaju komunikacione veze zasnovane na *Internet of Things* (IoT) tehnologiji. Koristeći pametne utičnice, omogućeno je efikasno nadgledanje i kontola upotrebe električne energije od strane krajnjih potrošača [20].

### 2.2.1.3. Komunikacioni sistemi

Komunikacioni sistemi su neophodni za implementaciju DSM tehnika i služe za prenos informacija o tržištu električne energije, kao i prenos signala za nepredviđene slučajeve, putem mjernih podešavanja, koristeći jednosmjerne ili dvosmjerne komunikacione veze između lokalnog operatora i potrošača. Jednosmerna komunikacija je isplativo rješenje u slučaju prenosa informacija za programe upozorenja ili obavještenja o DSM događaju, ali je efikasnije koristiti dvosmjernu komunikaciju, sa aspekta mogućnosti nadgledanja i kontrole operacija.

Iako uređaji za dvosmjernu komunikaciju imaju veću cijenu, velika prednost ovih uređaja je pouzdanost u primjeni kontrole i nadgledanju zadataka, budući da imaju mogućnost identifikacije i raznovrsne distribucije međusobno povezanih jedinica u DSM arhitekturi. Razmjena informacija se postiže putem žičanih ili bežičnih komunikacionih sistema, kao što su:

- žičana komunikacija,
- GSM/GPRS – globalni sistem mobilnih komunikacija/prenos podataka kroz mobilnu mrežu
- bežična komunikacija (ZigBee, WiFi),
- radio-frekvencije, optika i dr.

Arhitektura bežične komunikacije može biti predstavljena kroz HAN, NAN, WAN, ili V2G (eng. *Vehicle to Grid*) komunikacione kanale. Dva najčešće korišćena komunikaciona protokola su ZigBee i Wi-Fi. Bežični komunikacioni kanali su ograničeni rasponom pokrivanja, koji obično iznose od 10 do 15 kilometara i dalje zavise od prenošenja kroz fizičke medijume, putem žičanih komunikacionih tehnika ili putem evidencije podataka.

U posljednje vrijeme, popularna je komunikacija putem prenosnih kapaciteta u energetskoj mreži (eng. *Power Line Carrier-PLC*). Ovaj tip žičane komunikacije, korišćenjem energetske mreže visokog, srednjeg i niskog naponskog nivoa, koristi postojeću infrastrukturu električne mreže i time prenos signala čini veoma jeftinim za implementaciju [21]. PLC komunikacija se zasniva na korišćenju elektroenergetskih vodova za prenos signala na frekvencijama reda kHz.

PLC komunikacija se može realizovati unutar zgrade, kuće ili industrijskog postrojenja, koristeći unutrašnje električne instalacije za prenos signala. PLC komunikacija se široko primjenjuje u sistemima za automatizaciju u domaćinstvima, odnosno upravljanje električnim uređajima u pametnim kućama (eng. *Smart Home*) za kontrolu grijanja i klimatizacije, kontrolu osvjetljenja, kao i kontrolu bezbjednosnih uređaja.

### 2.3. Matematička formulacija upravljanja na strani potražnje

Prije nego što se predstavi matematička pozadina DSM programa, potrebno je definisati pojam faktora opterećenja (eng. *Load Factor*). Faktor opterećenja potrošača  $m$  je matematički formulisan na sljedeći način [22]:

$$m = \frac{W}{P_v \cdot T} \quad (2.1)$$

U izrazu (2.1), faktor opterećenja  $m$  se definiše kao odnos ostvarene potrošnje energije ( $W$ ) i energije koja se mogla ostvariti u slučaju da je opterećenje u cijelom posmatranom periodu ( $T$ ) bilo maksimalno ( $P_v$ ).

Faktor opterećenja predstavlja mjeru efikasnosti korišćenja električne energije od strane potrošača. Troškovi snabdijevanja električnom energijom u velikoj mjeri zavise od faktora opterećenja. Veća vrijednost faktora opterećenja rezultira manjim ukupnim troškom po proizvedenoj jedinici.

Glavni ciljevi DSM programa su:

- Faktor opterećenja blizak vrijednosti 1,0 ;
- Vršno opterećenje unutar određene margine ;
- Smanjenje troškova za preuzetu električnu energiju ;

DSM programi nastoje da optimizuju bilo koju od sljedeće dvije funkcije cilja:

$$\text{Max } m = \frac{\left[ \left[ \sum_{i=1}^N \sum_{j=1}^J P_{(i,j)} \cdot t_{(j)} \right] \right]}{\sum_{i=1}^N P_{(i,k)}} = \frac{\left[ \left[ \sum_{j=1}^J P_{TO(j)} \cdot t_{(j)} \right] \right]}{P_{TO(K)}} \quad (2.2)$$

$$\text{Min } C = \left[ \sum_{i=1}^N \sum_{j=1}^J P_{(i,j)} \cdot t_{(j)} \cdot ce_{(i,j)} \right] + \left[ \sum_{i=1}^N \sum_{j=1}^J P_{(i,j)} \cdot cd_{(i,j)} \right] \quad (2.3)$$

U jednačinama (2.2) i (2.3),  $P_{(i,j)}$  je opterećenje  $i$ -tog tipa (domaćinstva, administrativno-komercijalna potrošnja, ulična rasvjeta, industrija, poljoprivreda, saobraćaj i ostala potrošnja) u vremenskom intervalu  $j$ ,  $N$  je ukupan broj tipova opterećenja,  $J$  je ukupan broj vremenskih intervala,  $P_{TO(j)}$  je ukupno opterećenje tokom vremenskog intervala  $j$ ,  $k$  je vremenski interval u kojem opterećenje ima maksimalnu vrijednost,  $C$  je ukupan trošak za energiju i opterećenje,  $ce_{(i,j)}$  je trošak energije za tip opterećenja  $i$  u vremenskom intervalu  $j$  i  $cd_{(i,j)}$  je trošak  $i$ -tog tipa opterećenja u vremenskom intervalu  $j$  [22], [23].

## 2.4. Benefiti i izazovi upravljanja na strani potražnje

DSM pruža podršku elektroenergetskom sistemu za održavanje normalnog radnog stanja, koje je ugroženo nepredvidljivom proizvodnjom električne energije iz obnovljivih izvora, prisustvom proizvodnih jedinica u vlasništvu potrošača, električnih vozila i drugih elemenata savremenih elektroenergetskih sistema. Najvažniji benefiti realizacije DSM programa u elektroenergetskom sistemu su:

- očuvanje sigurnog pogona sistema
- smanjenje vršne snage u sistemu,
- podrška zagušenjima prenosnih kapaciteta,
- minimizacija tehničkih i komercijalnih gubitaka,
- odlaganje angažovanja elektrana na fosilna goriva,
- smanjenje emisije štetnih gasova,
- smanjenje cijene električne energije,
- smanjenje potrebe za uvozom električne energije (energetska nezavisnost) i
- optimalno dimenzionisanje elemenata sistema.

Takođe, potrošači mogu učestvovati u pružanju pomoćnih usluga na energetskom tržištu [24]. Podsticanje potrošača da pružaju pomoćne usluge ima nekoliko prednosti:

1. veći broj potrošača, kao učesnika na tržištu, doprinosi povećanju konkurencije,

2. pružanje pomoćnih usluga od strane potrošača poboljšava korišćenje raspoloživih resursa,
3. rasterećenje proizvodnih jedinica od pružanja pomoćnih usluga, uslijed čega se koriste za proizvodnju električne energije, što im je i primarna namjena.

Ostvarenje vizije distribuirane, održive i pametne mreže usmjerene na potrošače, prirodno će se suočiti sa mnogim izazovima. S jedne strane, iako je teorijski dokazano da se primjenom DSM programa ostvaruju mnogi benefiti, široko rasprostranjena primjena ovog programa ostaje neostvarena. S druge strane, uticaj trgovine energijom na rad pametne mreže i realna pretpostavka da svaki potrošač može postati proizvođač energije, još uvjek nije prihvaćena na pravi način.

Ključni izazov u realizaciji DSM programa je razvijanje realističnih mehanizma podsticaja, koji mogu biti od koristi elektroenergetskoj kompaniji, ali i potrošačima, ukoliko bi upravljali svojom potrošnjom energije tokom vremena. Suština DSM programa se fokusira na modelovanje interakcija i procesa donošenja odluka različitih učesnika mreže, čiji su ciljevi i akcije u velikoj mjeri međusobno zavisni. Na primjer, promjena u opterećenju određenih potrošača može dovesti do promjene šeme cijena koju koristi elektroenergetska kompanija, što zauzvrat može dovesti do promjene ponašanja drugih potrošača [5].

Izazovi uključuju razvoj optimizovanih tržišnih mehanizama, upravljanje radom mreže i optimizovano korišćenje dostupnih jedinica za skladištenje i proizvodnju energije u vlasništvu potrošača. Pored toga, potrebno je povećati automatizaciju elemenata elektroenergetskog sistema i nivo kućne automatizacije kod krajnjih potrošača.

## **2.5. Implementacija programa upravljanja na strani potražnje**

Među najistaknutijim razvijenim zemljama, u kojima DSM programi imaju veoma važnu ulogu za potrebe balansiranja elektroenergetskog sistema, nalaze se Sjedinjene Američke Države i Velika Britanija. Realizacija DSM programa u zemljama u razvoju takođe može značajno doprinijeti u zadovoljavanju potražnje i izazovima snabdijevanja. Međutim, potrebna je nadogradnja energetske infrastrukture, reforma strukture tržišta i obezbjeđivanje finansijskih podsticaja, da bi se omogućila široka primjena DSM strategija [25].

### **2.5.1. Sjedinjene Američke Države**

Elektroenergetske kompanije u Sjedinjenim Američkim Državama su doprinijele ogromnom razvoju energetske efikasnosti i implementaciji DR strategija, različitim podsticajima, kao što su besplatne ili jeftine energetske revizije domaćinstava i preduzeća, besplatne ili snižene energetski efikasne sijalice i popusti za kupovinu energetski efikasnih električnih aparata [26].

Prema *Modor* istraživanjima, oko 9,5 miliona potrošača učestvuje u različitim DR programima, koji čine skoro 10% potražnje za električnom energijom, obezbeđujući značajne uštede tokom višne potražnje za energijom [27]. DR igra vitalnu ulogu u strategijama razvoja i planiranja tržišta interkonekcije Pensilvanija-Merilend-Nju Džersi (eng. *Pennsylvania – Maryland – New Jersey-PJM*), srednjearatlantskog mrežnog operatora, koji koordinira veleprodajom električne energije i smatra se najvećim tržištem električne energije u Sjedinjenim Američkim Državama.

Kalifornijski nezavisni sistem operator (eng. *California Independent System Operator*-CAISO) je druga po veličini i najsavremenija električna mreža na globalnom nivou, koja opslužuje Kaliforniju, najnaseljeniju državu u Sjednjenim Američkim Državama. U tabeli 2.1 su prikazani različiti mehanizmi kojima upravljuju PJM i CAISO tržišta električne energije.

Kao odgovor na državnu energetsku politiku, koja se obavezuje na proizvodnju električne energije bez prisustva ugljenika do 2024. godine, uz ogroman izazov u balansiranju rastućeg udjela solarne energije i energije vjetra, Kalifornija se okreće DR programima i energetskoj efikasnosti kao osnovama za suštinski, pouzdan i predvidljiv resurs za stabilniju i ekološki održiviju električnu mrežu.

Tabela 2.1 Mehanizmi PJM i CAISO tržišta električne energije [25]

Usluge	Funkcija
<i>Energetsko tržište</i>	Obezbeđuje električnu energiju kako bi se zadovoljila potražnja u realnom vremenu, istovremeno pružajući mogućnost za korišćenje lokalne marginalne cijene (eng. <i>Locational Marginal Price</i> -LMP) za dobrovoljno smanjenje potrošnje. LMP omogućava da veleprodajne cijene električne energije odražavaju vrijednost električne energije na različitim lokacijama, uzimajući u obzir obrasce opterećenja, proizvodnje, kao i fizičke granice prenosnog sistema [28].
<i>Planiranje dan unaprijed</i>	Tržište električne energije zasnovano na ponudi, koje obezbjeđuje dodatnih 30 minuta rezerve za proizvodnju energije i potražnju resursa.
<i>Tržište kapaciteta</i>	Obezbeđuje sigurnost snabdijevanja električnom energijom, nudeći plaćanje za pouzdane izvore kapaciteta, kako bi se osiguralo snabdijevanje energijom, kada je to neophodno.
<i>Tržište sinhronizovane rezerve</i>	Pomoćne usluge pružaju priliku za konkurentan razvoj redukcije potrošnje pomoću DR, putem ulaganja u infrastrukturu, omogućavajući brz odgovor, u roku od 10 minuta, za održavanje pouzdanosti mreže uslijed neočekivanih poremećaja, bilo kroz smanjenje opterećenja ili povećanje proizvodnje električne energije.
<i>Tržište regulacione rezerve</i>	Koristi DR u prilagođavanju proizvodnje radi održavanja frekvencije, omogućavajući mrežnim operatorima balansiranje ponude i potražnje za bezbjedan i pouzdan elektroenergetski sistem.
<i>Usluge smanjenja opterećenja</i>	Preko posrednika se potrošačima nadoknađuje smanjenje potražnje, koje zahtijevaju elektroenergetske kompanije tokom visokih cijena električne energije ili kada je pouzdanost mreže ugrožena.

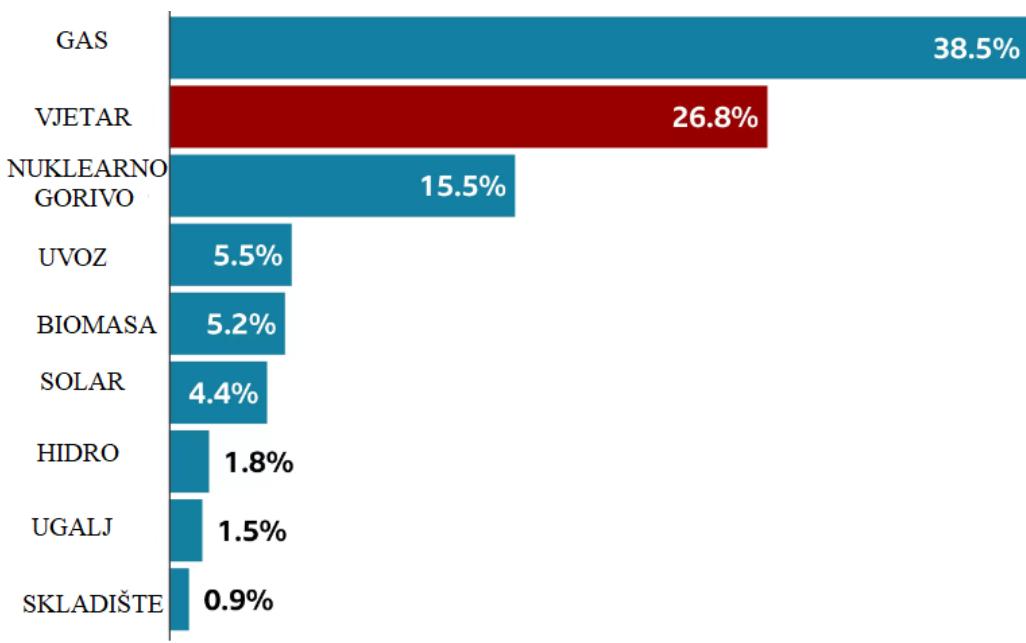
U Kaliforniji je predviđeno pokretanje nove državne „zelene” inicijative za povećanje proizvodnje električne energije bez fosilnih goriva, sa sadašnjih 36% na 60% do 2030. godine i na 100% proizvodnje električne energije bez prisustva fosilnih goriva, do 2045. godine.

S obzirom na intermitentnost proizvodnje električne energije sa kojim će se suočiti elektroenergetski sistem Kalifornije, očekuje se značajno unaprjeđenje DSM mehanizama za olakšano upravljanje sistemom u cjelini.

### 2.5.2. Velika Britanija

Potreba za fleksibilnošću elektroenergetskog sistema Velike Britanije se povećala sa porastom kapaciteta za proizvodnju energije iz obnovljivih izvora, do 47% svog kapaciteta 2020. godine, što je stavilo u drugi plan fosilna goriva [29].

Velika Britanija ima najveći instalirani kapacitet vjetroelektrana na moru u čitavom svijetu – 2022. godine je korišćenjem vjetropotencijala u Velikoj Britaniji proizvedena rekordna količina električne energije. Nakon gasa, vjetroelektrane su u 2022. godine bile najveći izvor električne energije u Velikoj Britaniji, kao što je prikazano na slici 2.5. Veliki dio potražnje je zadovoljen proizvodnjom električne energije iz nuklearnih elektrana i uvozom, dok su nakon toga najdominantniji izvori energije biomasa i solarne elektrane. Može se uočiti da je udio proizvodnje električne energije korišćenjem uglja iznosio 1,5% ukupne proizvedene električne energije, što je veoma povoljno sa aspekta procesa dekarbonizacije i zaštite životne sredine [30].



Slika 2.5 Proizvodnja električne energije u Velikoj Britaniji 2022. godine [30]

Velika Britanija, u odnosu na većinu drugih evropskih zemalja, nudi različita tržišta DR. Takvi DR programi nude promjenu paradigme u funkcionalisanju tržišta električne energije, od jednosmjernog režima u sistem gdje potrošači igraju važnu ulogu u korišćenju energije, kroz povećanje i smanjenje potražnje. Ovaj program djeluje na balansiranje snage kroz pomoćne usluge [31]. Rezidencijalna potražnja u Velikoj Britaniji čini jednu trećinu ukupne potražnja za električnom energijom, sa vršnom potražnjom od 40%. Mreža se sve više suočava sa značajnom količinom vršne potrošnje, uzrokujući neravnotežu između ponude i potražnje, što značajno povećava troškove energije [32].

Nacionalni mrežni operator elektroenergetskog sistema (eng. *National Grid Electricity System Operator*) sprovodi balansni mehanizam obezbjeđivanjem otpornog, fleksibilnog sistema električne energije, preko dobavljača, proizvođača, trgovaca i veleprodajnog tržišta električne energije [33]. Istaknute usluge koje ugovara operator sistema su usluge frekvencijskog odziva, brza i kratkoročna operativna rezerva (eng. *Short Term Operating Reserve-STOR*), kao i TOU tarife.

Usluga frekvencijskog odziva doprinosi sprječavanju naglog pada frekvencije, u slučaju kada generatorske jedinice dožive pad u proizvodnji električne energije. STOR uslugama se nudi najmanje 3 MW proizvodnje ili smanjenje potražnje u roku od 4 sata nakon prihvatanja uputstva od nacionalnog operatora, za održivi period od 2 sata. TOU programi kao što su *Octopus Agile* i *Octopus Go* su igrali značajnu ulogu u pomjeranju upotrebe energije na vanvršni period, pri čemu se potrošačima pružila prilika za uštedu novčanih sredstava [34].

*Octopus Agile* je inovativna energetska tarifa kod koje se cijene mijenjaju na svakih 30 minuta, u skladu sa veleprodajnom cijenom električne energije. Ovakva tarifa omogućava korišćenje energije kada je potrošnja niska, svodeći cijene za preuzetu električnu energiju na minimum, a ponekad čak i besplatno. Prebacivanje potrošnje energije van špica, od 16 do 19 časova, rezultira uštedom novčanih sredstava i korišćenje čistije, zelenije energije, kada je u mreži niska potražnja. Može se desiti da veleprodajna cijena električne energije postane negativna, što znači da se potrošačima plaća za korišćenje energije u određenim satima.

*Octopus Go* predstavlja pametnu tarifu, posebno dizajniranu za vozače električnih vozila u svrhu punjenja zelenom, jeftinjom električnom energijom. *Octopus Go* nudi super jeftinu tarifu za električnu energiju – 12 britanskih penija po kWh između 00:30 - 04:30 svake noći, tako da korisnici mogu napuniti svoj električni automobil za desetinu cijene tradicionalnog automobila. Potrošači koji se prijavljuju za tarifu *Octopus Go* moraju imati ugrađeno pametno brojilo, kako bi se omogućilo daljinsko očitavanje stanja na svakih pola sata [35], [36].

### 2.5.3. Australija

Trgovanje na tržištu električne energije u Australiji je zamišljeno da se odvija kao spot tržište, gdje se balansiranje potražnje i ponude pokreće skoro u realnom vremenu, sa dnevnom ponudom koja se dostavlja u intervalima od 5 minuta na aktuelnu tržišnu cijenu. Potrošač ima izbor da kupi energiju od operatora tržišta električne energije ili da trguje na malo, sa pristupom na spot tržištu [37]. Potencijal DR programa je demonstriran na primjeru kompanije za toppljenje aluminijuma na zapadu Viktorije. Kompanija se isključila na 100 minuta, kada je temperatura porasla, oslobađajući se opterećenja od 400 MW, eliminujući potrebu za rasterećenjem djelova mreže u pogonu [38].

*Meridian Energy*, trgovac na malo, vodi DR program putem mobilnih telefona kojima upravljaju korisnici DR aplikacija za telefon. Učesnici u programu dobijaju obavještenje od mobilne aplikacije kada energija poraste, zahtijevajući od njih da promijene potrošnju energije.

DR inicijative u Australiji takođe imaju za cilj smanjenje potrošnje energije kada rezerve dostignu kritične nivoe, kao i demonstraciju uloge koju DR programi mogu da imaju tokom ljetnjih toplotnih talasa [39]. Uprkos ovim inicijativama, Australija i dalje zaostaje za većinom evropskih i sjevernoameričkih zemalja u korišćenju DR programa za balansne mehanizme [40].

#### 2.5.4. Azijsko-pacifički region

Restrukturiranje i deregulacija energetskog sektora su formirali mnoga konkurentna tržišta električne energije u nekim zemljama Azijsko-pacifičkog regiona. Zbog toga su ove zemlje uspješno implementirale mnoge DSM programe, kao što je prikazano u tabeli 2.2.

Tabela 2.2 Implementacija DSM programa u zemljama Azijsko-pacifičkog regiona [41]

Zemlja	DSM programi	Status	Izazovi
Pakistan	<ul style="list-style-type: none"> <li>– Implementacija DSM u pametnim mrežama</li> <li>– DR programi</li> <li>– Strategije smanjenja opterećenja</li> </ul>	<ul style="list-style-type: none"> <li>– Efikasan sistem nadzora i blagovremeni odziv rezultiraju upravljanjem opterećenjem i doprinose minimizaciji gubitaka i ispada elemenata u pogonu</li> </ul>	<ul style="list-style-type: none"> <li>– Upravljanje prikupljenim podacima</li> <li>– Mjerenje energije</li> <li>– Prihvatljivost od strane potrošača</li> <li>– Kontrola energije</li> </ul>
Malezija	<ul style="list-style-type: none"> <li>– Reforma energetskih subvencija</li> <li>– Potencijalne uštede energije</li> </ul>	<ul style="list-style-type: none"> <li>– Potencijalne uštede energije iz ova dva programa bile su 7 036 kilotona ekvivalenta nafte, od ukupne potražnje za energijom u svim sektorima</li> </ul>	<ul style="list-style-type: none"> <li>– Nametanje poreza</li> <li>– Nametanje tarifa</li> </ul>
Indija	<ul style="list-style-type: none"> <li>– Trenutna procjena stanja na tržištu električne energije</li> <li>– Potražnja krajnje upotrebe</li> <li>– Jasno definisanje oblika krive opterećenja</li> <li>– Identifikovanje izvora finansiranja DSM-a</li> <li>– Analiza isplativosti DSM-a</li> <li>– Nadzor i implementacija DSM</li> </ul>	<ul style="list-style-type: none"> <li>– Neki DSM programi pomažu u smanjenju potrošnje energije, ugradnjom energetski efikasnih aparata</li> <li>– Dobrovoljno ili obavezno usvajanje DSM programa postavljanjem standarda</li> </ul>	<ul style="list-style-type: none"> <li>– Savjesnost potrošača</li> <li>– Određivanje tarifa</li> <li>– Nedostatak tehničkih mogućnosti</li> </ul>
Singapur	<ul style="list-style-type: none"> <li>– DR programi</li> <li>– TOU tarife</li> </ul>	<ul style="list-style-type: none"> <li>– Pouzdaniji sistem i aktivnije učestvovanje potrošača u DSM programima, čime je tržište postalo otpornije uslijed uvođenja konkurenциje</li> </ul>	<ul style="list-style-type: none"> <li>– Nedostatak finansiranja</li> <li>– Tehničke barijere</li> </ul>
Tajland	<ul style="list-style-type: none"> <li>– Ugradnja energetski efikasnih fluorescentnih sijalica</li> <li>– Program naznačavanja efikasnosti frižidera i klima uređaja</li> <li>– Program za hladnu rezervu</li> </ul>	<ul style="list-style-type: none"> <li>– Implementacija DSM-a tokom 2003 – 2017 je rezultirala korišćenjem efikasnijih tehnologija za proizvodnju električne energije, koje su smanjile emisiju gasa <math>CO_2</math> za 8,4%</li> </ul>	<ul style="list-style-type: none"> <li>– Povećani ukupni troškovi sistema</li> </ul>
Bangladeš	<ul style="list-style-type: none"> <li>– TOU tarife</li> <li>– Redukcija vršnog opterećenja</li> </ul>	<ul style="list-style-type: none"> <li>– Primijecene su glavne prednosti TOU tarifa, značajno je smanjena vršna potrošnja u sistemu i troškovi potrošača</li> </ul>	<ul style="list-style-type: none"> <li>– Institucionalne barijere</li> <li>– Nedostatak podsticaja</li> </ul>

U Kini, DSM mjere se primjenjuju od januara 2011. godine, sa ciljem obezbjedivanja uredne potrošnje električne energije, poboljšanja energetske efikasnosti i najbolje alokacije energetskih resursa. Nacionalna komisija za razvoj i reformu (eng. *National Development and Reform Commission-NDRC*) i Državni savjet su odgovorni za preduzimanje DSM mera u Kini. Politika koja se odnosi na implementaciju DSM-a podstiče opštu regulativu na nacionalnom nivou, gdje se od svake pokrajine zahtijeva da formuliše sopstvene DSM šeme.

Energija koja je uštedena pomoću DSM šema čini osnovu plana razvoja energetike, elektroprivrede i plana regionalnog ekonomskog razvoja. Da bi se razvoj DSM-a u Kini podigao na viši nivo, došlo je do unaprjeđivanja TOU tarifa. Primijenjeno je skladištenje energije van vršnih sati, visokopouzdano određivanje cijena, sezonske cijene, određivanje cijena sa prekidnim opterećenjem i mnogi drugi mehanizmi određivanja cijena električne energije.

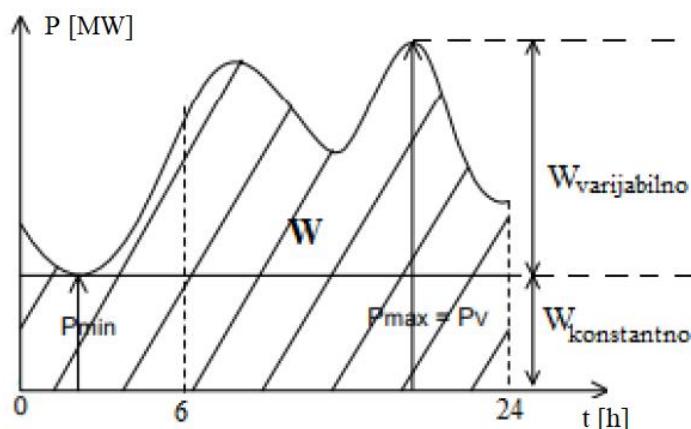
Mrežne kompanije su bile motivisane da poboljšaju prikupljanje podataka o opterećenju, kako bi isti pomogli u pružanju više informacija za implementaciju DSM programa. Proizvodnja električne energije, prenosne i distributivne mreže i krajnji korisnici, stekli su dovoljnu svijest kroz DSM programe, tako da su energetski efikasni uređaji široko prihvaćeni. Štaviše, NDRC je uspostavio „Nacionalnu platformu za upravljanje potražnjom” za nadgledanje, evaluaciju, zagovaranje i obuku, kao i rješavanje monetarnih pitanja, naglašavajući značaj upravljanja opterećenjem i bezbjednosti informacija [41].

Za implementaciju DSM programa, potrebno je povećati nivo automatizacije u distributivnim mrežama, koji je veoma nizak u tradicionalnim sistemima, kao što je elektroenergetski sistem Crne Gore. Proces automatizacije, kroz koji trenutno prolazi elektrodistributivna mreža Crne Gore, potrebno je dodatno razmotriti sa ekonomskog aspekta, odnosno isplativosti uvođenja mjerne infrastrukture kod svih potrošača.

### 3. PROGNOZA POTROŠNJE ELEKTRIČNE ENERGIJE

Prognoza (predikcija, predviđanje) potrošnje električne energije je jedna temeljnih radnji za planiranje pogona i optimalno upravljanje elektroenergetskim sistemom. Najvažniji ciljevi prognoziranja su zadovoljenje budućih zahtjeva, minimizacija neočekivanih troškova i doprinos pravilnom donošenju odluka [42].

Potrošnja električne energije nije konstantna tokom vremena: u toku dana, sedmice, mjeseca, godine ili više godina. Vremenska promjena potrošnje električne energije se predstavlja pomoću dijagrama opterećenja. Dijagram opterećenja predstavlja grafički prikaz zavisnosti aktivne snage  $P$  od vremena  $t$  koje se posmatra [43]. U skladu s tim, dijagram opterećenja može biti formiran za različite vremenske intervale: jedan dan, jednu sedmicu, jedan mjesec, jednu sezonu, za cijelu godinu, kao i za više godina. U analizama rada elektroenergetskog sistema, najčešće se koristi dnevni dijagram opterećenja, prikazan na slici 3.1.



Slika 3.1 Dnevni dijagram opterećenja [43]

Karakteristične veličine dnevnog dijagrama opterećenja su:

- Vremenski period koji se posmatra,  $t = 24h$
- Maksimalna (vršna) snaga u posmatranom periodu,  $P_{max}$  ( $P_v$ )
- Minimalna snaga u posmatranom periodu,  $P_{min}$
- Količnik maksimalne i minimalne snage,  $(P_{max} / P_{min})$
- Ukupna energija koja je utrošena u posmatranom periodu,  $W$
- Faktor opterećenja, definisan u prethodnom poglavlju,  $m$
- Vrijeme trajanja vršne snage, koje se definiše u jednačini (3.1) kao količnik ukupne energije ( $W$ ) i vršne snage ( $P_v$ ), u toku posmatranog perioda:

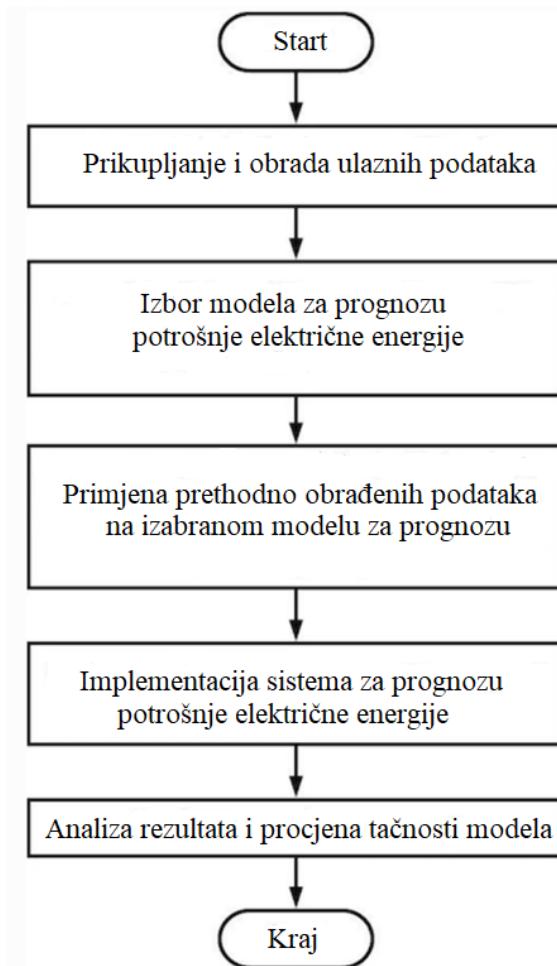
$$T_v = \frac{W}{P_v} [h] \quad (3.1)$$

Kao odgovor na fluktuacije opterećenja, elektroenergetske kompanije moraju obezbijediti dovoljno resursa za proizvodnju i transport, kako bi se zadovoljila potražnja za električnom energijom. Potrebna je ekonomična nabavka resursa u cilju optimizacije operativnih troškova.

Budući da ekonomičnost operacije i optimalno upravljanje sistemom u velikoj mjeri zavise od opterećenja, značajne uštide se mogu postići povećanjem tačnosti prognoze opterećenja. Istraživanje koje su sproveli australijski naučnici, poznat kao Finkelov izveštaj [44], ističe netačnu prognozu potrošnje električne energije kao jedan od glavnih uzroka za probleme australijske električne mreže.

Greška u prognozi buduće potražnje za električnom energijom može rezultirati konzervativnim ili nepouzdanim radom elektroenergetskog sistema. Veća procjena potrošnje električne energije može dovesti do nepotrebnog puštanja u rad dodatnih jedinica za proizvodnju ili prekomjernom kupovinom električne energije na tržištu. Sa druge strane, ishod niže procjene potrošnje električne energije može biti nedovoljna rezerva za napajanje, suprotno zahtjevima bezbjednog rada sistema.

Nedostajuću količinu električne energije, nastalu zbog greške u prognozi potrošnje, neophodno je nadoknaditi trgovinom na spot tržištu, gotovo u realnom vremenu, po cijenama koje su veće u poređenju sa troškovima planiranih transakcija. Jasno je da pouzdani rezultati prognoze potrošnje električne energije imaju direktno pozitivan efekat na bezbjednost i troškove rada elektroenergetskog sistema u cjelini [45]. Proces prognoziranja potrošnje električne energije prikazan je na slici 3.2.



Slika 3.2 Proces prognoziranja potrošnje električne energije

Modeli za prognozu potrošnje električne energije moraju imati određene karakteristike i zadovoljiti kriterijume, koji garantuju kredibilitet i tačnost rezultata. Shodno tome, model za prognozu mora [46]:

1. Pokušati da identificuje uzročnost promjenljivih prognoze – nezavisne promjenljive se procjenjuju na osnovu njihovog uticaja na opterećenje. Na primjer, meteorološki faktori su posljednje sredstvo za prognozu i uzimaju se u obzir samo u slučaju kratkoročne i srednjeročne prognoze, najviše nekoliko godina unaprijed.
2. Biti reproduktivan – postiže se zadovoljavanjem dvije stvari. Prvo, model ne smije da uključuje lične predrasude ili zaključke. Drugo, matematičko modelovanje poboljšava ponovljivost metode prognoziranja. Primer jednostavne, ali ponovljive prognoze potrošnje može biti: „Prognozira se da će opterećenje – potrošnja energije u domaćinstvima, definisana kao izmjerena potražnja u tarifnoj klasi XYZ, imati rastući trend, direktno proporcionalno broju domaćinstava koji su zvanično povezani na mrežu.“ Na ovaj način se jasno precizira osnova prognoze.
3. Biti funkcionalan – model mora biti u skladu sa svrhom prognoze. U slučaju da se odluka odnosi na planiranje održavanja postojećeg elementa, horizont prognoze treba da bude jedna godina, podijeljena na mjesecne ili sedmične priraštaje. Međutim, ako se odluka odnosi na izgradnju nove proizvodne jedinice, prognoza bi trebalo da se fokusira na godišnje povećanje potražnje u vremenskom roku potrebnom za izgradnju postrojenja. Dnevne varijacije opterećenja se moraju uzeti u obzir kod kratkoročnog i dugoročnog planiranja. U dugoročnom planiranju, potencijal za velike promjene u načinu korišćenja električne energije na dnevnom i godišnjem nivou je veći i potrebno ga je eksplicitno analizirati.
4. Održavati jednostavnost – u model treba uključiti samo onoliko informacija koliko je neophodno za prognozu, budući da izrada komplikovanih ili sofisticiranih modela sa niskom tačnošću rezultata ne donosi korist. Jednostavan metod troši manje resursa (vremena, novca) i lakši je za razumjeti kada se okonča. Bilo kakva komplikacija modela za prognozu se mora odmjeriti u odnosu na prednosti stečene preciznijim rezultatima ili korisnim informacijama.
5. Biti testiran na osjetljivost – planeri u svojim modelima moraju uključiti određene mehanizme za testiranje rezultata po promjenama nezavisnih promjenljivih, zbog promjene u pretpostavkama. Prognoza se ponavlja više puta, koristeći različite vrijednosti, da bi se uočile glavne nezavisne promjenljive, u slučaju drastične ili marginalne promjene rezultata. Planeri teže da prenesu uticaj neizvjesnosti na prognozu, pripremom alternativnih scenarija.

S obzirom na vremenski okvir za koji se prognozira, vrši se klasifikacija na [47]:

- Dugoročnu prognozu potrošnje električne energije (eng. *Long Term Load Forecasting-LTLLF*), koja obuhvata vremenski period od jedne do dvadeset godina. LTLLF je značajan indikator za potencijalno proširenje kapaciteta i dugoročne studije povrata kapitalnih investicija. Rezultat ove prognoze je obično vršno opterećenje i godišnji zahtjevi za energijom u sistemu.

- Srednjoročnu prognozu potrošnje električne energije (eng. *Medium Term Load Forecasting*-MTLF), neophodnu prilikom planiranja nabavke goriva, rasporeda održavanja elemenata, trgovine energijom i procjene prihoda. Srednjoročna prognoza se obično naziva i mjesecna prognoza opterećenja, s obzirom da obuhvata period od jednog do dvanaest mjeseci [48].
- Kratkoročnu prognozu (eng. *Short – Term Load Forecasting*-STLF), koja se odnosi na period od jedne sedmice do jednog mjeseca. STLF se koristi kao indikator za planiranje pogonskih operacija, jedinične obaveze proizvodnih jedinica (eng. *Unit Commitment*) i ekonomski dispečing (eng. *Economic Dispatching*).
- Veoma kratkoročnu prognozu (eng. *Very Short Term Load Forecasting*-VSTLF), koja obuhvata period od jednog do sedam dana. Namijenjena je za razmjenu energije i ugovaranje sa susjednim mrežama, ali i za održavanje sigurnosti elektroenergetskog sistema, održavanje profila napona i kompenzaciju reaktivne snage. Mnoge elektroenergetske kompanije posljednja dva tipa prognoze objedinjuju u STLF [49].

Prognoza može biti klasifikovana i prema subjektu koji sprovodi prognozu. Regulatorno tijelo sprovodi prognoze vezane za finansijsko planiranje i tarifna pitanja. Organ vlasti, kao što je Ministarstvo ili administracija, vrši ukupne energetske prognoze, uključujući električnu energiju, za proučavanje pitanja politike i potencijala goriva. Elektroenergetske kompanije sprovode skoro sve prognoze, prema prethodno navedena četiri vremenska okvira, za njihovu posebnu namjenu. Proizvodne kompanije sprovode dugoročne prognoze za planiranje proširenja kapaciteta [50]. Kompanije za prenos i distribuciju sprovode dugoročnu prognozu sa istom namjenom, ali za prenosnu i distributivnu mrežu, respektivno. Cilj srednjeročne prognoze za bilo koju elektroenergetsku kompaniju je isti, kao što je ranije navedeno. S druge strane, cilj kratkoročne prognoze za prenosne i distributivne kompanije je pravilno planiranje manipulacija na dnevnom nivou, prema profilu opterećenja, kao i ekonomičan rad postrojenja, uključujući minimizaciju gubitaka.

Prognoza budućeg opterećenja se može koristiti i za procjenu potencijalnog uspjeha DSM programa i u slučaju djelimičnog ili potpunog raspada sistema (eng. *Black Out*), u svrhu planiranja restauracije sistema i povratka mreže u normalno stanje.

### **3.1. Faktori koji utiču na potrošnju električne energije**

Faktori koji utiču na opterećenje u sistemu se mogu svrstati u kratkoročne, srednjoročne i dugoročne faktore [51]. Faktori od uticaja na kratkoročnu prognozu opterećenja, kao što su nagle promjene vremena, često se pojavljuju u određenom periodu prognoze i gotovo da nemaju karakteristiku vremenskog trajanja. Za srednjoročnu prognozu opterećenja, faktori od uticaja poput sezonskih klimatskih promjena, često traju nekoliko perioda prognoze i imaju određene karakteristike vremenskog trajanja. U slučaju dugoročne prognoze opterećenja, uticajni faktori se obično održavaju mnogo perioda prognoze i imaju karakteristiku vremenskog trajanja. Primjer su promjene bruto društvenog proizvoda (BDP) i naseljenosti.

Dnevni obrazac opterećenja se temelji na dnevnim aktivnostima ljudi, u zavisnosti od radnog vremena, slobodnog vremena i noćnih sati. Vikend i praznični dani rezultiraju manjim opterećenjem u industrijskom okruženju, uslijed smanjene aktivnosti izvođenja radova, za razliku od domaćinstava.

Generalno, opterećenje varira u zavisnosti od posmatranog sata u toku dana, dana u nedjelji i doba godine. Posmatranjem različitih mrežnih stanica, može se uočiti da je karakteristika opterećenja periodična, kako na nivou dana, tako i na nivou sedmice, mjeseca, kvartala i godine. Uzimajući u obzir periodično svojstvo, potrošnja električne energije u budućnosti može biti efikasno predviđena [52].

Ekonomski razvoj i njegov uticaj na životni standard je primarni podsticaj za stimulisanje potražnje za električnom energijom i ima značajan uticaj na dugoročnu, srednjeročnu i kratkoročnu prognozu opterećenja [53]. Potrošnja električne energije je funkcija ekonomskih faktora kao što su industrijski razvoj, porast broja stanovnika, BDP i troškovi električne energije. U skladu s različitim vremenskim horizontima, različiti ekonomski faktori potencijalno utiču na prognoziranje: TOU tarife na kratkoročnu, trgovina električnom energijom na srednjeročnu i BDP na dugoročnu prognozu. Troškovi za preuzetu električnu energiju imaju veliki uticaj na smanjenje/povećanje potražnje. Cijena električne energije na energetskom tržištu nije konstantna, već zavisi od velikog broja faktora. Primjer je cijena naftnih derivata, na osnovu koje varira cijena proizvodnje električne energije, a posljeđeno i cijena za krajnje potrošače. Industrijski razvoj i porast broja stanovnika povećavaju potražnju za električnom energijom.

Meteorološki uticaj na potrošnju električne energije je najizraženiji za domaćinstva i poljoprivredne potrošače, ali može izazvati promjenu profila opterećenja i kod industrijskih potrošača. U cilju dobijanja kvalitetnijih rezultata, modeli za prognozu potrošnje električne energije koriste vremensku prognozu. Meteorološki uslovi mogu izazvati nepouzdanost u snabdijevanju električnom energijom, smanjenjem proizvodnje električne energije i prenosne moći dalekovoda, kao i formiranjem vršnog opterećenja [54]-[56]. Povećanje temperature degradira proces proizvodnje električne energije gasnih elektrana i fotonaponskih ćelija: smanjenjem izlazne snage uslijed smanjenja gustine vazduha kod gasnih elektrana i neefikasnost zbog visoke stope rekombinacije kod fotonaponskih elektrana [57].

Visoke temperature dovode do povećanja otpornosti, istezanjem dužine provodnika, čime se smanjuje provodna moć dalekovoda. Takođe, ekstremno visoke temperature u toku ljetnje i niske temperature u toku zimske sezone iniciraju veliku potrošnju električne energije, zbog potrebe za hlađenjem i grijanjem prostorija.

Ljudsko tijelo tokom vjetrovitih dana osjeća temperaturu koja je niža u odnosu na stvarnu vrijednost, uslijed čega se javlja potreba za grijanjem prostorija. Pored toga, na subjektivni osjećaj o temperaturi uticaj ima vlažnost vazduha, zbog čega se tokom kišnih dana povećava potrošnja električne energije. Efekat oblačnosti na potrošnju električne energije zavisi od vremena u kojem se posmatra. Oblačnost može poremetiti sunčevu svjetlost tokom dana, smanjiti temperaturu i rezultirati nižom potrošnjom električne energije. Od navedenih meteoroloških faktora, najčešće korišćeni prediktori opterećenja su temperatura i vlažnost vazduha, zbog direktnog uticaja na načine potrošnje električne energije, odnosno direktnog uticaja na aktivaciju uređaja za grijanje i hlađenje prostorija.

Oblik krive opterećenja se razlikuje u odnosu na kategoriju potrošača: domaćinstva, industrija i ostala potrošnja. Nasumični faktori koji utiču na potrošnju električne energije su prvenstveno broj, vrsta i snaga električnih uređaja koji su zastupljeni kod potrošača.

Pokretanje ili zaustavljanje rada potrošača velikih snaga, drastično može povećati ili smanjiti proizvodnju električne energije u sistemu i dovesti u pitanje efikasnost korišćenja istorijskih podataka o potrošnji električne energije. Glavni faktori od uticaja na prognozu potrošnje električne energije, dati su u tabeli 3.1.

Tabela 3.1 Faktori od uticaja na prognozu potrošnje električne energije

	Godišnje doba
Vremenski faktori	Dan u nedelji
	Doba dana
	Praznici
	Demografske karakteristike potrošača
Ekonomski i ekološki faktori	BDP
	Varijacije cijene električne energije
	Industrijski rast
Meteorološki faktori	Temperatura
	Vlažnost vazduha
	Brzina vjetra
	Sunčev zračenje
	Padavine i nevrijeme
	Oblačnost
Ostali faktori	Pokretanje ili zaustavljanje rada velikih potrošača
	Neplanirani ispadni elemenata sistema u pogonu
	Kategorija potrošača: domaćinstvo, industrija i ostala potrošnja
	Broj, vrsta i snaga električnih uređaja u domaćinstvu
	Sportski događaji
	Grmljavine i oluje

## 3.2. Metode za prognozu potrošnje električne energije

Metode koje se koriste za prognozu potrošnje električne energije se mogu podijeliti u dvije grupe:

1. Statistički zasnovane metode i
2. Metode zasnovane na vještačkoj inteligenciji.

### 3.2.1. Statistički zasnovane metode

Metode zasnovane na statistici se široko koriste u mnogim granama prognoziranja. Za potrebe prognoze potrošnje električne energije, statističke metode pokazuju dobre osobine u normalnim uslovima, dok njihov učinak opada u slučaju naglih promjena socioloških ili ekoloških promjenljivih koje utiču na obrasce opterećenja. Statističke metode nemaju mogućnost kvalitetne reprezentacije složenih nelinearnih odnosa, kao što su potrošnja električne energije i različiti faktori koji utiču na nju, zbog čega prognoza potrošnje električne energije djeluje kao prilično složen zadatak. Pored toga, statističke metode potencijalno mogu rezultirati numeričkom nestabilnošću, budući da zahtijevaju veliki broj složenih odnosa, praćenih dugim vremenom računanja [58].

Statistički zasnovane metode uključuju:

- Regresione metode
- Metode vremenskih serija
- Ostale metode

### 3.2.1.1. Regresione metode

Regresija je jedna od najčešće korišćenih statističkih tehniki sa fokusom na analizu odnosa između promjenljivih. Prilikom prognoze potražnje za električnom energijom, regresione metode se obično koriste za modelovanje odnosa potrošnje električne energije i drugih faktora, kao što su vrijeme, tip dana i klasa kupaca. Deterministički, stohastički i egzogeni uticaji (na primjer: praznici, prosječno opterećenje i vremenske prilike, respektivno), ugrađuju se u cilju kvalitetnije prognoze.

Rezultati se mogu koristiti za predviđanje ili procjenu vrijednosti jedne od poznatih promjenljivih ili pretpostavljene vrijednosti drugih povezanih promjenljivih. Ove metode uključuju jednostavnu linearu regresiju, polinomijalnu regresiju, funkcionalnu regresiju (na primjer eksponencijalnu ili trigonometrijsku funkciju) i višestruku linearu regresiju [59]-[62].

Najčešće korišćena je višestruka linearna regresija (eng. *Multiple Linear Regression*) sa velikim brojem promjenljivih, na osnovu kojih analizira uzročne veze između promjenljivih i indikatora, uzročnih faktora. Matematički, višestruka linearna regresija je predstavljena u jednačini (3.2) kao:

$$y = \beta_0 + \beta_1 \cdot x_1 + \cdots + \beta_p \cdot x_p + \epsilon \quad (3.2)$$

U prethodnom izrazu,  $y$  predstavlja prognoziranu (izlaznu) vrijednost,  $x_1, x_2, \dots, x_p$  su nezavisne promjenljive ili prediktori (ulazne vrijednosti),  $\beta_0$  je regresioni koeficijent  $y$  prekida,  $\beta_1, \beta_2, \dots, \beta_p$  su regresioni koeficijenti nagiba, dok je  $\epsilon$  slučajna greška.

Slabost ove metode dolazi do izražaja u slučaju nemogućnosti identifikacije glavnih indikatora ili podataka za glavne indikatore [63]. Alternative u takvim situacijama su stacionarne tehnike vremenskih serija, opisane u nastavku.

### 3.2.1.2. Tehnike vremenskih serija

Tehnike vremenskih serija (eng. *Time Series Techniques*) su zasnovane na prepostavci da podaci imaju internu strukturu, kao što je autokorelacija, trend ili sezonska varijacija. Metode predviđanja vremenskih serija otkrivaju i istražuju takvu strukturu i decenijama se koriste u oblastima kao što su ekonomija, digitalna obrada signala i prognoza budućeg električnog opterećenja. Metode vremenskih serija obuhvataju jednu ili više sljedećih komponenti [64]:

- Komponenta trenda - dug terminski obrazac vremenske serije;
- Ciklična komponenta - predstavlja kretanje oko datog trenda;
- Sezonska komponenta - prikazuje fluktuacije tokom datog vremenskog perioda (dan, mjesec, kvartal, godina);
- Nepravilna komponenta - odslikava efekat nepravilnosti ili slučajnosti.

Cilj je pronaći funkciju filtriranja koja istražuje strukturu ponašanja opterećenja i omogućava ekstrapolaciju posmatranih podataka u budućnost, u svrhu prognoziranja [65]. Implementirani matematički modeli su:

1. Autoregresivni pokretni prosjek (eng. *Autoregressive Moving Average-ARMA*), koji se koristi pod pretpostavkom stacionarnih procesa.
2. Autoregresivni integrisani pokretni prosjek (eng. *Autoregressive Integrated Moving Average-ARIMA*), takođe poznat kao *Box-Jenkins* model, autoregresivni integrisani pokretni prosjek sa egzogenim promjenljivim (eng. *Autoregressive Integrated Moving Average with Exogenous Variables-ARIMAX*) i fazi autoregresivni pokretni prosjek sa egzogenim ulaznim promjenljivim (eng. *Fuzzy Autoregressive Moving Average with Exogenous Input Variables-FARIMAX*), koji se koriste pod pretpostavkom nestacionarnih procesa. Prošireni ARIMA i ARIMAX modeli uvažavaju sezonsku komponentu univarijantnih podataka vremenske serije (eng. *Seasonal Autoregressive Integrated Moving Average-SARIMA* i *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables-SARIMAX*) [66],[67].
3. Eksponencijalno izglađivanje, koristi se kada promjenljiva koja se predviđa nije stabilna. Ovo izglađivanje će filtrirati varijacije u korist osnovnog trenda.
4. Analiza glavnih komponenti (eng. *Principal Component Analysis-PCA*) koja se koristi za prognozu potražnje, odvajanjem osnovne strukture ili obrasca opterećenja od poremećaja ili slučajne komponente (proces filtriranja manje-više). Drugim riječima, PCA se koristi za komprimovanje maksimalne količine informacija u prve dvije kolone transformisane matrice, poznate kao glavne komponente, zanemarujući druge vektore koji nose zanemarljive informacije ili suviše podatke [68]. Glavni nedostatak PCA je to što zahtijeva veliko vrijeme računanja i poteškoće u izboru optimalnog poretka od glavnih komponenti.

### 3.2.1.3. Ostale metode zasnovane na statistici

Pored metoda vremenskih serija i regresionih metoda, statističke metode koje se mogu koristiti za prognozu potrošnje električne energije su:

- Pristup sličnog dana
- Ekonometrijski ili kauzalni metod
- Metode simulacije ili krajnje upotrebe

Pristup sličnog dana koristi parametre trenda od sličnih dana prethodnih godina. Pretraga podataka o opterećenju iz prethodnih godina, vrijeme, dan u nedelji i datum, izvode se da identifikuju slične dane. Moguće je usvojiti opterećenje sličnog dana kao prognozu ili napraviti prognozu uzimanjem u obzir nekoliko sličnih dana u postupku linearne kombinacije ili regresije.

Ekonometrijski ili kauzalni metod pokušava da formuliše matematički odnos između nezavisne promjenljive, potrošnje električne energije, sa drugim nezavisnim promjenljivima: populacijom, cijenom električne energije, prihodima itd.

Glavna razlika između ekonometrijskih i metoda vremenskih serija je u tome što ekonometrijske metode pomažu u razumijevanju na koji način se dešavaju promjene opterećenja.

Takve promjene imaju najveći uticaj u slučaju dugoročnog posmatranja, pa su samim tim ove metode efikasnije od metoda vremenskih serija za dugoročnu prognozu. Dodatne informacije pomažu u donošenju ispravnih budućih odluka i pravilnom planiranju. Međutim, ovo zahtijeva više vremena, truda i razumijevanja uzročno-posljeđičnih veza između potrošnje električne energije i drugih društveno-ekonomskih promjenljivih. Ponekad ovakve situacije navode planere da procjenjuju buduću evoluciju ovih promjenljivih, umjesto opterećenja direktno.

Prognoza potrošnje električne energije zahtijeva opsežna istraživanja i ekonomske studije, koje se moraju sprovoditi periodično ili kada god dođe do promjene trenda opterećenja, ali i društvenog ili ekonomskog trenda. Mnoge elektroenergetske kompanije imaju odeljenja koja obavljaju ove vrste redovnih studija i istraživanja ili se takve aktivnosti ugovaraju sa konsultantskim kancelarijama ili istraživačkim institucijama. Tehnike višestruke regresije se najviše koriste za ovu vrstu prognoze, oslanjajući se na povezivanje procjene buduće potrošnje električne energije i skupa nezavisnih društveno-ekonomskih i tehnoloških faktora. Mjera kvaliteta odnosa između potrošnje električne energije i nezavisnih promjenljivih zahtijeva primjenu određenih statističkih alata, kao što su koeficijent regresije, faktor korelacije, t-statistika i drugi.

Metode simulacije ili krajnje upotrebe su procesno-inženjerski modeli koji se koriste da emuliraju sistem do detalja i u najvećoj realističnoj mjeri. Primjena ovakvih metoda za prognozu potrošnje električne energije podrazumijeva razlaganje ukupnog opterećenja sistema na opterećenje različitih klasa potrošača (domaćinstvo, industrija, ostala potrošnja).

Svaka klasa potrošača ima različit obrazac potrošnje i na njega različito utiču signali cijena i drugi instrumenti. Električna energija u domaćinstvima pruža komfor i udobnost, dok za industriju i komercijalne potrošače donosi profitabilnost i zadovoljstvo kupaca. Analiza različitih grupa potrošnje i procjena budućeg opterećenja su potrebni za svaku krajnju upotrebu električne energije. U analizi opterećenja domaćinstava potrebno je uvažiti svaki električni uređaj ili krajnju upotrebu, kao što su: grijanje prostora, klimatizacija, osvjetljenje itd. Konačan rezultat se postiže kada se sve krajnje upotrebe sumiraju, kako bi se formiralo ukupno opterećenje sistema. Veliki broj modela za simulaciju ili krajnju upotrebu je dizajnirano, testirano i primjenjeno istraživanjem institucija i međunarodnih organizacija. Odlikuje ih jednostavnost i mogućnost primjene u bilo kojoj zemlji ili elektroenergetskoj kompaniji.

U idealnom slučaju, ovaj pristup je veoma tačan. Međutim, osjetljiv je na količinu i kvalitet podataka o krajnjoj upotrebi. Prognoza krajnje upotrebe zahtijeva manje istorijskih podataka, ali više informacija o potrošačima i njihovoj opremi.

### **3.2.2. Metode zasnovane na vještačkoj inteligenciji**

Osnovni cilj upotrebe vještačke inteligencije (AI) je konstruisanje mašina koje imaju sposobnost da obavljaju procese za koje bi bila neophodna inteligencija, ukoliko bi te procese obavljali ljudi [69]. Mašinsko učenje (ML) je dio AI i uključuje adaptivne mehanizme koji omogućavaju računarima učenje iz iskustva, učenje na primjerima i učenje po analogiji.

Istorijski gledano, glavne barijere za primjenu AI za potrebe prognoziranja potrošnje električne energije, bili su ograničeni računarski resursi i vremenski zahtjevni procesi. Međutim, razvoj informacionih tehnologija, uz uvođenje višeprocesnih tehnika i povećanu efikasnost softvera, rezultira značajnim smanjenjem vremena potrebnog za implementaciju [70], [71].

Metode AI se fokusiraju na prognozu potrošnje električne energije za kratkoročni period (STLF). Razlog za to je nizak nivo slučajnosti i visoka tačnost prilikom implementacije STLF modela. Nasuprot tome, dugoročna prognoza potrošnje električne energije (LTLF) sadrži visok stepen neizvjesnosti, obuhvatanjem većeg vremenskog okvira, koji čini metode zasnovane na AI manje efikasnim i rezultira velikim greškama u prognoziranju potrošnje električne energije, u poređenju sa tradicionalnim metodama.

Za potrebe prognoze potrošnje električne energije, mogu se koristiti sljedeće AI metode:

- Fazi logika (eng. *Fuzzy Logic*)
- Ekspertni sistemi (eng. *Expert Systems*)
- Metod potpornih vektora (eng. *Support Vector Machine-SVM*)
- Optimizacija rojem čestica (eng. *Particle Swarm Optimization-PSO*)
- Vještačka neuralna mreža (eng. *Artificial Neural Network-ANN*)

### 3.2.2.1. Fazi logika

Naziv ovog pristupa nagovještava da postoji logika sa neočigledno definisanim pravilima, koja se odnose na ulaz i izlaz. Rasplinuta ili fazi logika je primjenljiva za rješavanje pitanja koja su nesigurna i neprecizna [72]. Ovaj pristup karakteriše generalizacija klasične logike dvije vrijednosti (0 i 1), odnosno *Boole*-ove logike korišćene za dizajn digitalnih kola.

Fazi logika omogućava rezonovanje u nelinearnim i neizvjesnim uslovima, kada većina klasičnih modela za predviđanje ima ograničene mogućnosti [73], [74]. Među prednostima ovog pristupa, izdvaja se odsustvo potrebe za preciznim ulazima i preciznim matematičkim modelom koji preslikava ulaze u izlaze. Fazi ulazi su preslikani na izlaze kroz definisana kvalitativna pravila. Kada se ovi ulazi logički procesuiraju, inverzni proces, poznat kao defuzifikacija, može se koristiti za generisanje izlaza.

Za pretvaranje fazi ulaza u fazi izlaze, koristi se baza pravila „AKO – ONDA“ (eng. *IF - THEN*) [75]. Predloženi razvoj i implementacija algoritma, zasnovanog na rasplinutoj logici za prognoziranje opterećenja, sastoji se od sljedećih faza:

1. Dizajn fazi baze pravila – svaki par ulaznih i izlaznih podataka predstavlja bazu pravila i isti se koriste kao podaci za obuku. Na primer: AKO je prisutna visoka temperatura, izražena vlažnost i brzina vjetra koja je iznad prosjeka, ONDA je i opterećenje iznad prosjeka.
2. Računanje predviđene vrijednosti opterećenja – fazi sistem zaključivanja implementira nelinearno preslikavanje iz svog ulaznog prostora u izlazni prostor, koristeći AKO – ONDA bazu pravila, od kojih svako pravilo opisuje lokalno ponašanje preslikavanja.
3. Testiranje performansi, procjena i ažuriranje baze pravila – tačnost prognoze se testira korišćenjem skupa istorijskih podataka, koji se razlikuju od podataka za formiranje baze pravila. Nova pravila, dizajnirana na osnovu zapažanja, postaju dio postojeće baze pravila.
4. Analiza greške – pronalazak apsolutne i srednje apsolutne greške, u procentima.

Kombinacija neuralne mreže i fazi logike, poznata kao hibridna neuralna mreža, može se koristiti za prognozu krive opterećenja za sljedeći dan [76].

Ovakav pristup pokazuje značajno povećanje tačnosti prognoze tokom perioda testiranja. Razvojem neuro-fazi pristupa omogućava se efikasan dizajn STLF u deregulisanom tržištu, uzimajući u obzir uticaj cijene električne energije na opterećenje [77].

### 3.2.2.2. Ekspertni sistemi

Ekspertni sistemi uključuju pravila i procedure koje koriste stručnjaci u oblasti od interesa, za softver koji će imati sposobnost automatske prognoze, bez ljudskog udjela. Upotreba tehnika zasnovanih na ekspertnim sistemima je počela 1960-ih godina, primjenom u geološkim istraživanjima i kompjuterskom dizajnu [78]. Ekspertni sistemi pružaju najbolje rezultate kada stručnjaci iz datog područja sarađuju sa programskim inženjerima, uklapajući stručno znanje u upravljački program. Stručnjaci moraju biti sposobni da objasne proces zaključivanja programerima, kako bi stručno znanje, predloženo za uklapanje u program, bilo primjerenog.

U domenu prognoze potrošnje električne energije, uvažavanje svih važnih faktora koji imaju uticaj na opterećenje, doprinosi kvalitetnoj izgradnji ekspertnog sistema [79]. Pokazuje se da razvijeni algoritmi rade bolje u poređenju sa konvencionalnim statističkim metodama.

### 3.2.2.3. Metod potpornih vektora

Metod potpornih vektora (SVM) zasnovan je na ideji vektorskog prostora i predstavlja metodologiju mašinskog učenja koja služi za nadgledanje klasifikacije velikog broja podataka. SVM je prvi put predstavljen od strane Vladimira Vapnika [80], [81].

Osnovna ideja SVM metode je maksimizovati marginu između hiper-ravnih i tačaka koje se nalaze „na ivici“ potencijalnih klasa. Hiper-ravan, koja razdvaja dvije klase, potpuno je određena specifičnim podskupom podataka za treniranje, koji se nazivaju potpurni vektori. Treniranje se svodi na pronalazak optimalne hiper-ravnih, odnosno ravni sa maksimalnim rastojanjem od podataka za trening, tako da se svi podaci koji pripadaju jednoj klasi nalaze sa iste strane te ravni [82], [83].

Optimalna hiper-ravan se može izvesti pomoću (3.3):

$$\vec{w} \cdot \vec{x} - b = 0 \quad (3.3)$$

pri čemu  $\vec{w}$  predstavlja normalni vektor hiper-ravnih, dok je sa  $b$  označen offset (eng. *Offset*). Jednačine (3.4) i (3.5) označavaju margine, kada je slučaj linearno razdvojiv:

$$w \cdot x - b = +1 \quad (3.4)$$

$$w \cdot x - b = -1 \quad (3.5)$$

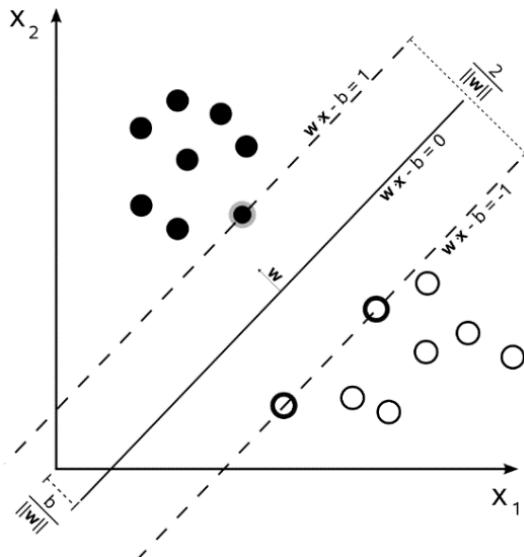
Maksimalna širina između margina je  $\frac{2}{\|w\|}$ , pa se optimizacioni problem svodi na:

$$\max \frac{2}{\|w\|} \quad (3.6)$$

odnosno:

$$\min \frac{1}{2} \cdot \|w\|^2 \quad (3.7)$$

Linearno razdvojiv SVM model je prikazan na slici 3.3.



Slika 3.3 Linearno razdvojiv SVM model

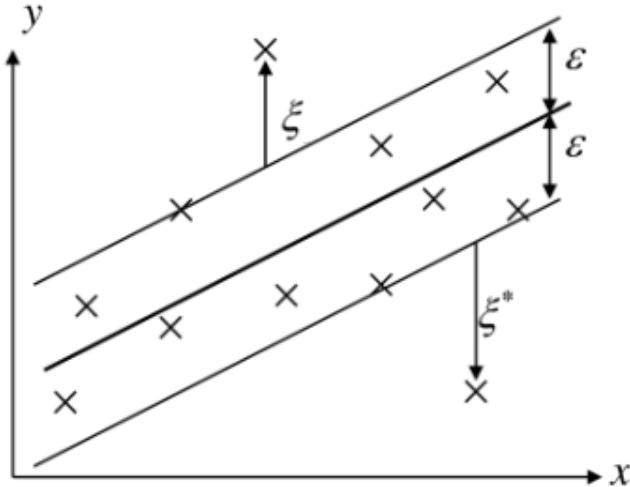
SVM je u najjednostavnijem obliku linearni binarni klasifikator. Za aplikacije sa više klasa, predložena su dva glavna pristupa primjene SVM, sa osnovnom idejom da se multiklase svede na skup binarnih problema:

1. Pristup jedan protiv svih (eng. *One vs All*) – generiše n klasifikatora, gdje je n broj klasa. Izlaz je klasa sa najvećom marginom. Pristup zahtijeva n problema optimizacije kvadratnog programiranja, pri čemu svaki odvaja jednu klasu od preostalih.
2. Pristup jedan protiv drugog (eng. *One vs One*) – kombinuje nekoliko klasifikatora i ima mogućnost poređenja u paru, između svih n klasa. Mogući klasifikatori se procjenjuju iz skupa za obuku od n klasa, pri čemu je svaki klasifikator obučen za samo dvije klase.

Iako je SVM dizajniran za linearne klasifikacije, krajem XX vijeka počinje da se koristi za nelinearnu klasifikaciju. Za omogućavanje nelinearne klasifikacije se koriste kerneli, matematičke funkcije koje koriste SVM klasifikatori za preslikavanje potpornih vektora u višedimenzioni prostor. Postoji više tipova kernela koji se koriste, ali se obično najbolji rezultati dobijaju korišćenjem funkcije radikalne osnove (eng. *Radial Basis Function*). Takođe, mogu se primjeniti linearna, polinomska i sigmoidna kernel funkcija.

Za potrebe prognoze potrošnje električne energije, mogu se koristiti dvodimenzionalni ili multivarijabilni SVM [84]-[86]. Analiza talasa zajedno sa SVM modelom može služiti za prognozu udara vjetra [87]. Pokazuje se da je kombinacija diskretnog talasnog transformacije (eng. *Discrete Wavelet Transformation-DWT*) i SVM značajno efikasnija u poređenju sa korišćenjem SVM i vještačkih neuralnih mreža bez prisustva DWT [88]. SVM model sa imunološkim algoritmom može imati bolje karakteristike prognoze od klasičnog SVM, regresione metode i vještačkih neuralnih mreža [89].

Budući da se SVM najčešće koristi za rješavanje problema klasifikacije, za potrebe regresije se koristi SVR (eng. *Support Vector Regression*). SVR daje fleksibilnost korisniku da definiše kolika je vrijednost greške prihvatljiva u izabranom modelu i pronalazi odgovarajuću liniju (ili hiper-ravan u višim dimenzijama) koja odgovara definisanim podacima. Na slici 3.4 prikazan je linearni SVR model, dok se za formiranje nelinearnog modela koriste ranije pomenute kerne funkcije.



Slika 3.4 Linearni SVR model [90]

U slučaju SVR modela, ako je optimalna hiper-ravan data u jednačini (3.8), funkcija cilja se svodi izraz (3.9) [90]:

$$y = w \cdot x + b \quad (3.8)$$

$$\min \frac{1}{2} \cdot \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \quad (3.9)$$

uz sljedeća ograničenja (3.10)-(3.12):

$$y_i - w \cdot x_i - b \leq \varepsilon + \xi_i \quad (3.10)$$

$$w \cdot x_i + b - y_i \leq \varepsilon + \xi_i^* \quad (3.11)$$

$$\xi_i, \xi_i^* \geq 0, i = 1, \dots, m \quad (3.12)$$

U jednačinama (3.8)-(3.12),  $\varepsilon$  je udaljenost graničnih linija od optimalne hiper-ravni ili parametar tolerancije prilikom optimizacije greške,  $C$  je regularizacioni parametar, dok je dodatna margina greške za primjere  $x_i$  definisana vrijednostima  $\xi_i$ , i  $\xi_i^*$ . Drugi sabirak u jednačini (3.9) odražava koliko parametar regularizacije  $C$  kontroliše nivo dodatne dozvoljene greške:

- Manja vrijednost parametra regularizacije  $C \Rightarrow$  veća margina greške
- Veća vrijednost parametra regularizacije  $C \Rightarrow$  manja margina greške

### 3.2.2.4. Optimizacija rojem čestica

Optimizacija rojem čestica (PSO) je stohastički algoritam zasnovan na socijalno-psihološkim principima, koji se mogu koristiti za pronalaženje optimalnih (ili skoro optimalnih) rješenja za numeričke i kvalitativne probleme. PSO, zajedno sa optimizacijom kolonije mrava (eng. *Ant Colony Optimization*-ACO), vještačkom kolonijom pčela (eng. *Artificial Bee Colony*-ABC) i algoritmom svitaca (eng. *the Firefly Algorithm*-FA), inspiriran je socijalnim interakcijama između jedinki u okviru određene populacije i spada u grupu algoritama inteligencije roja (eng. *Swarm Intelligence*) [91]-[97].

Elementi skupa jedinki (roja) su čestice koje na unaprijed definisan način lete u prostoru pretraživanja i mijenjaju svoj položaj, na bazi sopstvenog iskustva i iskustva ostalih čestica u roju. Svaka od čestica usmjerava kretanje na osnovu najbolje pozicije koju je do tog trenutka sama pronašla (eng. *Personal Best*- $P_{best}$ ) i najbolje pozicije do koje su došle susjedne čestice (eng. *Local Best*- $L_{best}$ ). Najbolje rješenje čitavog roja, sačinjenog od čestica koje su topološki susjedi, predstavlja najbolji globalni rezultat (eng. *Global Best*- $G_{best}$ ).

Brzina čestice je ograničena između minimalne ( $v_{min}$ ) i maksimalne ( $v_{max}$ ) vrijednosti. Ukoliko bi se čestica kretala veoma sporo, potencijalno bi ostala zaglavljena u lokalnom minimumu. Suprotno, ako bi se kretala prevelikom brzinom, postoji mogućnost da „preleti“ područje dobrih rješenja. Sve dok se ne zadovolji kriterijum zaustavljanja, koji može biti postizanje maksimalnog broja iteracija ili slučaj kada se tokom iteracija rezultati ne poboljšavaju, trenutni položaj čestica se ažurira korišćenjem vektora brzine, na osnovu pamćenja pojedinačne čestice i iskustva koje je stekao cjelokupni roj.

Ako je sa  $x_i^t$  označen vektor položaja čestice  $i$  u višedimenzionalnom prostoru (i.e.  $R^n$ ) u vremenskom intervalu  $t$ , pozicija svake od čestica se ažurira u prostoru pretraživanja na sljedeći način [98]:

$$x_i^{t+1} = x_i^t + v_i^{t+1}, \quad x_i^0 \sim U(x_{min}, x_{max}) \quad (3.13)$$

U jednačini (3.13) je sa  $v_i^t$  označen vektor brzine čestice koji pokreće proces optimizacije, odražavajući sopstveno iskustvo i iskustvo cjelokupnog roja, dok je  $U(x_{min}, x_{max})$  uniformna raspodjela, čije su minimalna i maksimalna vrijednosti označene sa  $x_{min}$  i  $x_{max}$ , respektivno.

Postoje dva PSO algoritma, koja se razlikuju po veličini broja susjeda:

1. *Global Best* PSO
2. *Local Best* PSO

U slučaju *Global Best* PSO algoritma, na poziciju svake čestice uticaj ima čestica koja je postigla najbolje rezultate u cjelokupnom roju.

Svaka pojedinačna čestica  $i \in [1, \dots, n], n > 1$  ima:

- trenutnu poziciju u prostoru pretraživanja ( $x_i$ ),
- trenutnu brzinu ( $v_i$ ) i
- lični najbolji rezultat u prostoru pretraživanja ( $P_{best}$ ).

Lični najbolji rezultat ( $P_{best}$ ) odgovara poziciji u prostoru pretraživanja gdje je čestica imala najmanju vrijednost, određenu funkcijom cilja  $f$ , u odnosu na problem minimizacije. Kao što je ranije navedeno, najbolja pozicija koju je postigla čestica u cjelokupnom roju, odgovara globalno najboljem rezultatu ( $G_{best}$ ).

Pozicija svake čestice, u slučaju *Local Best* PSO algoritma, pod uticajem je najbolje pozicije čestice iz njenog susjedstva. Brzina čestice u slučaju *Global Best* i *Local Best* PSO algoritma se izračunava na način predstavljen u jednačinama (3.14) i (3.15), respektivno [97]:

$$v_{ij}^{t+1} = v_{ij}^t + c_1 \cdot r_{1j}^t [P_{best,i}^t - x_{ij}^t] + c_2 \cdot r_{2j}^t [G_{best} - x_{ij}^t] \quad (3.14)$$

$$v_{ij}^{t+1} = v_{ij}^t + c_1 \cdot r_{1j}^t [P_{best,i}^t - x_{ij}^t] + c_2 \cdot r_{2j}^t [L_{best} - x_{ij}^t] \quad (3.15)$$

U jednačinama (3.14) i (3.15), oznake imaju sljedeća značenja:

- $v_{ij}^t$  je vektor brzine čestice  $i$  u dimenziji  $j$  u vremenu  $t$ ;
- $x_{ij}^t$  je vektor pozicije čestice  $i$  u dimenziji  $j$  u vremenu  $t$ ;
- $P_{best,i}$  predstavlja lični najbolji položaj čestice  $i$  u pronađenoj dimenziji  $j$ , od inicijalizacije do vremena  $t$ ;
- $G_{best}$  je najbolja globalna pozicija čestice  $i$  u dimenziji  $j$ , postignuta kroz vrijeme  $t$ ;
- $L_{best}$  je najbolja pozicija koju je bilo koja čestica  $i$  imala u susjedstvu, postignuta kroz vrijeme  $t$ ;
- $c_1$  i  $c_2$  su pozitivne konstante ubrzanja koje se koriste za poravnanje doprinosa kognitivne i socijalne komponente, respektivno;
- $r_{1j}^t$  i  $r_{2j}^t$  su slučajni brojevi iz uniformne raspodjele  $U(0,1)$ , u trenutku  $t$ .

Prvobitno, postoje dvije razlike između *Global Best* i *Local Best* PSO algoritma:

1. Zbog veće povezanosti čestica, *Global Best* PSO algoritam konvergira brže od *Local Best* PSO algoritma.
2. *Local Best* PSO je manje podložan „zarobljavanju“ u lokalnom minimumu, zbog veće raznolikosti.

Najvažnije prednosti korišćenja PSO algoritma su: odsustvo proračuna diferencijala promjenljivih veličina, jednostavna implementacija koja ne zahtijeva previše vremena, lako se implementira i može se primijeniti u naučnim istraživanjima za rješavanje inženjerskih problema. Takođe, PSO je manje zavisan od skupa početnih vrijednosti parametara i ima ograničen broj parametara, sa neizraženim uticajem na dobijanje konačnih rješenja, u odnosu na druge metode optimizacije. Sa druge strane, nedostaci PSO algoritma su potencijalna djelimična optimizacija, koja degradira regulisanje njegove brzine i pravca, kao i problemi sa nekoordinisanim sistemom, poput energetskog polja.

PSO tehnika se koristi za estimaciju parametara u različitim modelima za kratkoročnu i dugoročnu prognozu potrošnje električne energije, pri čemu se često kombinuje sa neuralnim mrežama, metodom potpornih vektora i fazi logikom [99], [100].

### 3.2.2.5. Vještačke neuralne mreže

Sposobnost rješavanja nelinearnih problema velike dimenzionalnosti, čini vještačku neuralnu mrežu (ANN) veoma zastupljenim alatom za prognozu potrošnje električne energije [101]-[103]. Upotreba ANN za potrebe prognoze potrošnje električne energije je zastupljena od 1990-ih godina, kada su ANN prvi put predstavljene u kombinaciji sa vremenskim serijama i regresionim analizama [104].

U poređenju sa statističkim metodama, ANN imaju bolju generalizaciju, manju računsku složenost, smanjen period obuke i otpornije su na različite ulazne scenarije. Takođe, hibridizacijom više tehnika se postižu bolji rezultati, u odnosu na konvencionalne statističke metode. Neki od hibridnih modela koji se predlažu u literaturi su kombinacije neuralnih mreža sa fazi logikom i genetičkim algoritmom, eksperimentnim sistemom i metodom regresije, talasnim i vremenskim serijama, kao i kombinacija neuralne mreže sa SVM-om i vještačkim imunološkim sistemom.

Tačnost modela za prognozu zavisi od nekoliko faktora:

1. strukture mreže,
2. algoritma učenja,
3. mrežnih parametara i
4. kvaliteta prikupljenih istorijskih podataka.

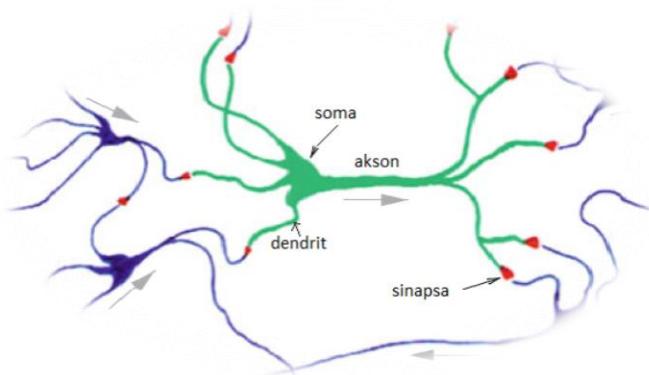
Za prognozu potrošnje električne energije, moguće je koristiti različite tipove neuralnih mreža: višeslojna neuralna mreža (eng. *Multilayer Perceptron*), funkcija radikalne osnove (eng. *Radial Basis Function*), samoorganizujuće mape (eng. *Self-Organizing Maps*), rekurentna neuralna mreža (eng. *Recurrent Neural Network*), generalizovana regresiona neuralna mreža (eng. *Generalized Regression Neural Network*), probabilistička neuralna mreža (eng. *Probabilistic Neural Network*), teorija adaptivne rezonance (eng. *Adaptive Resonance Theory*), funkcionalne veze (eng. *Functional Links*) i kontrapropagacija (eng. *Counterpropagation*) [105], [106].

U ovom radu, posebna pažnja je posvećena potpuno povezanoj višeslojnoj neuralnoj mreži, koja se predlaže za prognozu potrošnje električne energije, sa ciljem omogućavanja DSM programa.

## 4. POTPUNO POVEZANA VIŠESLOJNA NEURALNA MREŽA ZA PROGNOZU POTROŠNJE ELEKTRIČNE ENERGIJE

### 4.1. Koncept neuralne mreže

Neuralna mreža se definiše kao model rasuđivanja, zasnovan na ljudskom mozgu. Mozak je najvažniji dio nervnog sistema i sastoji se od velikog broja međusobno povezanih skupova nervnih ćelija, osnovnih jedinica za obradu informacija, koje se nazivaju neuroni [107]. Veze između neurona nazivaju se sinapse. Sastavni djelovi biološkog neurona su tijelo ćelije (soma), brojna nervna vlakna (dendriti) i jedno dugačko vlakno (akson). Struktura biološke neuralne mreže je prikazana na slici 4.1. Dendriti se granaju u mrežu oko some, dok se akson proteže do dendrita i soma drugih neurona.



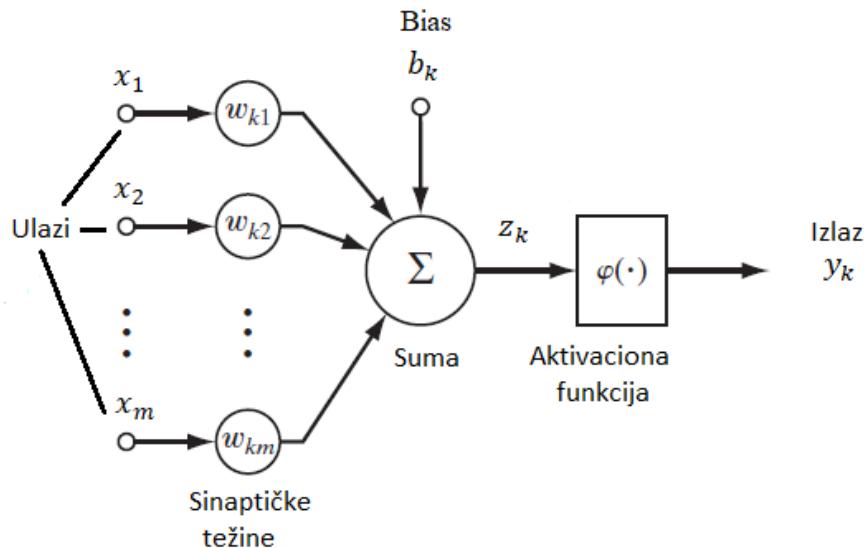
Slika 4.1 Struktura biološke neuralne mreže [108]

Neuroni proizvode akcione potencijale (signale), koji se preko sinaptičkih veza prenose na druge neurone. Do neurona dolazi određeni broj ulaznih signala, pri čemu jedan neuron nikada ne proizvodi više od jednog izlaznog signala. Izlazni signal se prenosi kroz izlaznu vezu, koja odgovara biološkom aksonu i dalje se odlazna veza dijeli na veliki broj grana koje prenose isti signal. Odlazne grane se završavaju na ulaznim vezama drugih neurona u neuralnoj mreži.

Vještačka neuralna mreža (ANN) u suštini predstavlja računski model biološke neuralne mreže - obuhvata veliki broj međusobno povezanih vještačkih neurona, analognih biološkom neuronu. Model vještačkog neurona je prikazan na slici 4.2.

Vještački neuron se sastoji od skupa sinapsi, međusobno povezanih sinaptičkim vezama, sume i aktivacione funkcije. Sinaptičkim vezama su dodijeljene numeričke težine, kojima se odsljikava značaj svake od ulaznih vrijednosti. Ažuriranjem sinaptičkih težina, koje mogu imati pozitivnu ili negativnu vrijednost, vrši se treniranje neuralne mreže. Negativna vrijednost sinaptičke težine prezentuje inhibitornu vezu, dok se sa pozitivnom vrijednošću težine označavaju ekscitatorne veze.

Aktivaciona funkcija služi za ograničavanje amplitude izlaznog signala, obično u opsegu  $[0,1]$  ili  $[-1,1]$ , dok se sumom vrši sabiranje proizvoda ulaznih signala i sinaptičkih težina. Takođe, model vještačkog neurona sadrži bias, eksterni parametar, označen sa  $b_k$ . Bias ima efekat povećanja ili smanjenja ulaza  $z_k$  u funkciju aktivacije, u zavisnosti od toga da li je pozitivan ili negativan, respektivno.



Slika 4.2 Model vještačkog neurona

Vještački neuron  $k$  se matematički može formulisati na sljedeći način [109]:

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (4.1)$$

$$y_k = \varphi(u_k + b_k) \quad (4.2)$$

$$z_k = u_k + b_k \quad (4.3)$$

$$z_k = \sum_{j=0}^m w_{kj} \cdot x_j \quad (4.4)$$

$$y_k = \varphi(z_k) \quad (4.5)$$

U izrazima (4.1)-(4.5),  $w_{k1}, w_{k2}, \dots, w_{km}$  su sinaptičke težine,  $x_1, x_2, \dots, x_m$  ulazne vrijednosti,  $u_k$  je izlaz linearog kombinatora uslijed ulaznih signala,  $b_k$  je eksterni parametar neurona  $k$  (bias),  $z_k$  je suma proizvoda sinaptičkih težina i ulaznih vrijednosti sabrana sa  $b_k$ , odnosno vrijednost neurona prije primjene aktivacione funkcije  $\varphi(z_k)$ , dok je sa  $y_k$  označen izlaz iz neurona.

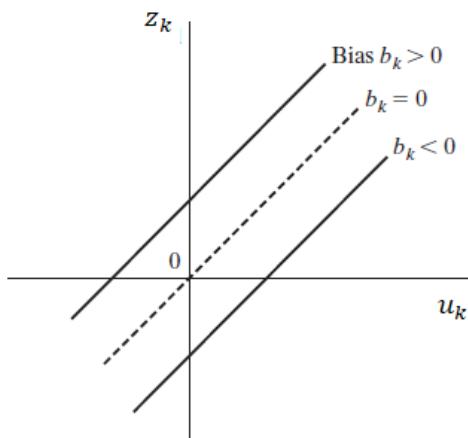
Kao što se vidi iz jednačine (4.3), prisustvo biasa ima efekat affine transformacije (eng. *Affine Transformation*) na izlaz  $u_k$  linearog kombinatora. U jednačini (4.4) uvedena je nova sinapsa, čiji je ulaz:

$$x_0 = +1 \quad (4.6)$$

Težina dodijeljena ovoj sinapsi je jednaka biasu neurona  $k$ :

$$w_{k0} = b_k \quad (4.7)$$

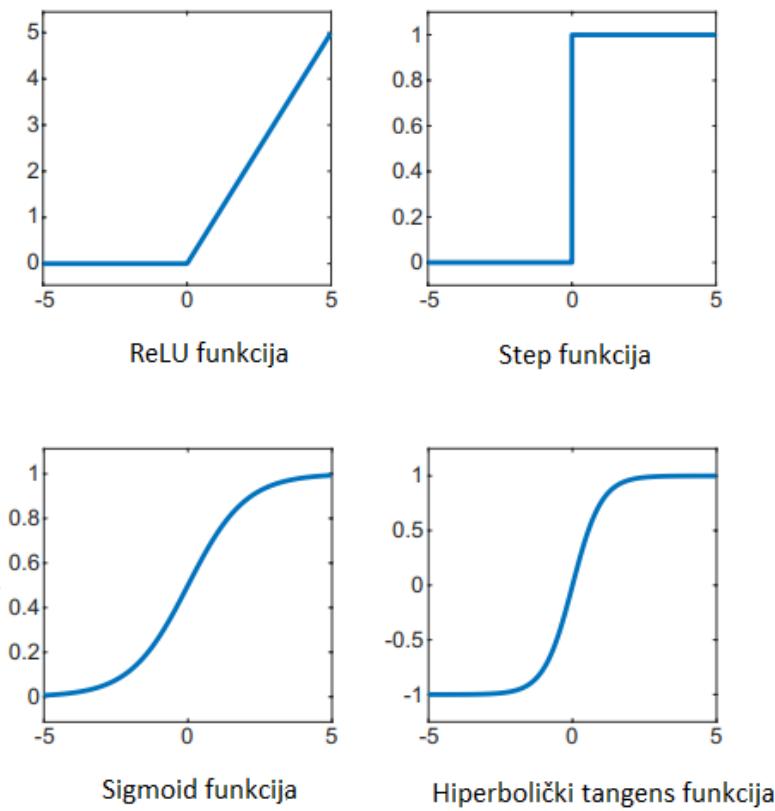
U zavisnosti od toga da li je bias pozitivan ili negativan, odnos između ulaza aktivacione funkcije  $z_k$  i izlaza linearnog kombinatora  $u_k$  je modifikovan na način prikazan na slici 4.3.



Slika 4.3 Efekat afine transformacije koju izaziva prisustvo biasa [109]

#### 4.1.1. Aktivacione funkcije

Aktivaciona funkcija, kao što je ranije navedeno, ograničava izlaz iz neurona i može imati oblik ispravljene linearne funkcije (eng. *Rectified Linear Unit-ReLU*), jedinične step funkcije, sigmoid funkcije ili hiperboličke tangens funkcije [110]. Na slici 4.4 je grafički prikaz različitih tipova aktivacionih funkcija, dok su matematičke formulacije date u tabeli 4.1.



Slika 4.4 Grafički prikaz aktivacionih funkcija neuralne mreže

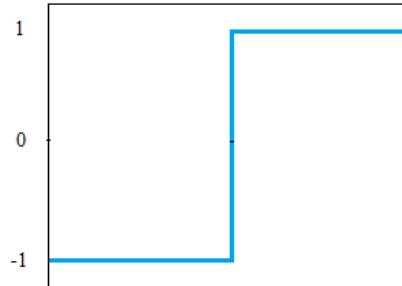
Tabela 4.1 Matematičke interpretacije aktivacionih funkcija neuralne mreže

ReLU funkcija	$\varphi(z) = \begin{cases} 0, z < 0 \\ z, z \geq 0 \end{cases}$
Step funkcija	$\varphi(z) = \begin{cases} 1, z \geq 0 \\ 0, z < 0 \end{cases}$
Sigmoid funkcija	$\varphi(z) = \frac{1}{1 + e^{-az}}$
Hiperbolički tangens	$\varphi(z) = \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$

Sigmoid funkcija je bila široko korišćena aktivaciona funkcija u neuralnim mrežama. Međutim, bez obzira na svojstvo diferencijabilnosti, u praksi nije pogodna za upotrebu zbog problema u optimizaciji [111]. Sigmoid funkcija je skoro konstantna u svakoj tački, osim u okolini nule, praktično dovodeći do anuliranja (iščezavanja) gradijenta, čime se otežava ili onemogućava treniranje neuralne mreže, objašnjeno u nastavku. Za razliku od sigmoid funkcije, step funkcija nije diferencijabilna. Izlaz iz jedinične step funkcije ima vrijednost 1 ili 0, dok izlaz iz sigmoid funkcije ima vrijednost između 1 i 0.

Ukoliko postoji potreba da se kao izlaz generiše vrijednost u opsegu [-1,1], onda se kao aktivaciona funkcija koristi funkcija znaka (eng. *Sign*), prikazana na slici 4.5, koja se može zapisati kao (4.8):

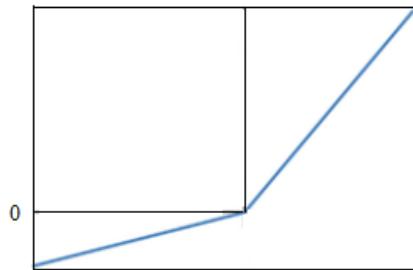
$$\varphi(z) = \begin{cases} 1, z > 0 \\ 0, z = 0 \\ -1, z < 0 \end{cases} \quad (4.8)$$

Slika 4.5 *Sign* aktivaciona funkcija

Hiperbolički tangens se takođe široko primjenjivao kao aktivaciona funkcija, pokazujući veći uspjeh od sigmoid funkcije. Razlog je to što je hiperbolički tangens u blizini nule blizak identitetu i liči na linearnu funkciju, pa je na taj način olakšana optimizacija [112].

ReLU funkcija je trenutno najčešće korišćena aktivaciona funkcija. Iako nije diferencijabilna u svakoj tački, ReLU funkciju karakterišu dobra svojstva za optimizaciju. Pored toga, korišćenje ReLU funkcije ne zahtijeva previše vremena za treniranje neuralne mreže [113]. Vjerovatnoća da će ReLU funkcija naići na tačku nediferencijabilnosti je veoma mala, ali čak i da se to dogodi, greška će biti nadomještена u krajnjem toku optimizacije.

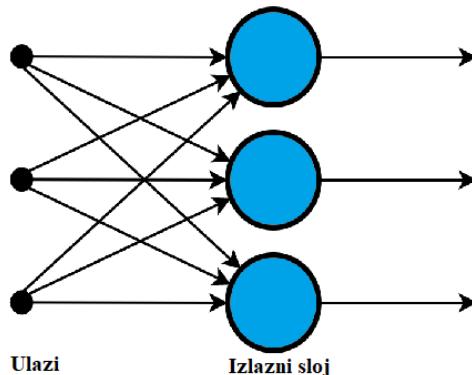
Modifikovana ReLU funkcija, prikazana na slici 4.6, je nakošena ispravljena linearna funkcija (eng. *Leaky Rectified Linear Unit*), koja lijevo od nule ima vrijednost  $\alpha z$ , za malu vrijednost parametra  $\alpha$ . Obično se uzima da je  $\alpha = 0.01$ . Umjesto da je lijevi dio funkcije konstantan, u tom slučaju će biti nagnut pod nekim malim uglom i izvod će biti različit od nule [114].



Slika 4.6 Modifikovana (nakošena) ReLU funkcija

## 4.2. Strukture neuralnih mreža

Način na koji su neuroni struktuirani, blisko je povezan sa algoritmom učenja koji se koristi za treniranje neuralne mreže. Najjednostavnija struktura neuralne mreže je jednoslojna *feedforward* mreža (eng. *Single-Layer Neural Network*), prikazana na slici 4.7. Jednoslojna neuralna mreža se sastoji od jednog (izlaznog) sloja, dok se ulazni sloj ne računa, budući da u njemu nema procesiranja.

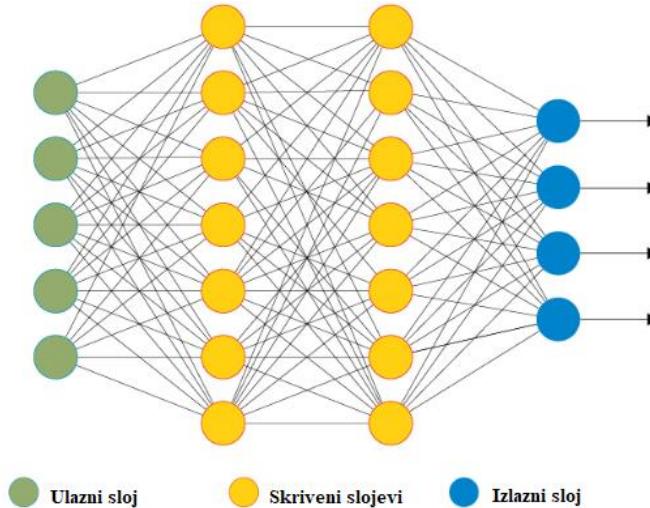


Slika 4.7 Jednoslojna *feedforward* neuralna mreža

Termin *feedforward* podrazumijeva odsustvo povratne sprege, odnosno mreža nema memoriju i informacije se kreću samo unaprijed. Za razliku od nje, neuralna mreža sa povratnom spregom (eng. *feedback*) omogućava da se informacije kreću u oba smjera, kao struktura mreže zatvorene petlje. Izlaz mreže utiče na ulaz, kako bi se dospjela funkcija cilja mreže, povratnim širenjem informacija o grešci. Međutim, mreža povratnih informacija je dinamička po prirodi zbog kontinualnih promjena stanja u cilju postizanja ravnoteže. Promjena ulaza mreže se vrši da bi se došlo do novog ravnotežnog stanja, na osnovu prethodnog stanja. Neuralna mreža sa povratnom informacijom je pogodna za dinamičke i složene procese, kao i za probleme sa promjenljivim vremenom ili vremenskim kašnjenjem.

Složenija struktura neuralne mreže se obično sastoji od ulaznog sloja, minimum jednog srednjeg ili skrivenog sloja (eng. *Hidden Layer*) i posljednjeg, izlaznog sloja. Struktura takve mreže se naziva višeslojna neuralna mreža (eng. *Multi-Layer Perception Neural Network-MLPNN*).

Podaci koji se proslijeđuju na ulaz neuralne mreže se dijele na podatke za treniranje, podatke za validaciju i podatke za testiranje modela. Na slici 4.8 je prikazana potpuno povezana MLPNN sa dva skrivena sloja.



Slika 4.8 Potpuno povezana višeslojna neuralna mreža sa dva skrivena sloja

Kod potpuno povezane neuralne mreže, svi neuroni iz jednog sloja su međusobno povezani sa neuronima iz susjednih slojeva. Višeslojna neuralna mreža ima mogućnost da bolje nauči ulazne obrazce i proizvede bolji rezultat, u odnosu na jednoslojnu neuralnu mrežu, koja nema sposobnost da nauči složene veze između ulaza i izlaza.

### 4.3. Tehnike učenja neuralne mreže

Tehnike učenja neuralne mreže se mogu podijeliti u dvije kategorije:

1. učenje pod nadzorom i
2. učenje bez nadzora.

Učenje pod nadzorom je tehnika obuke neuralne mreže u kojoj mreža pokušava da minimizuje srednju kvadratnu grešku (eng. *Mean Square Error*-MSE) za poznati skup željenih vrijednosti. U slučaju ovog tipa učenja, ulazni i izlazni vektori su specificirani. Ulazni i izlazni vektori neuralne mreže dati su u izrazima (4.9) i (4.10), respektivno:

$$x = [x_1, x_2, \dots, x_n] \quad (4.9)$$

$$y = [y_1, y_2, \dots, y_m] \quad (4.10)$$

Veza između ulaza i izlaza neuralne mreže se može predstaviti kao:

$$y = x \cdot E \quad (4.11)$$

U posljednjem izrazu,  $E$  odgovara aproksimaciji greške između izlaza mreže i željenih vrijednosti, odnosno vektoru koji sadrži višestruke vrijednosti greške,  $x$  je vektor ulaznih vrijednosti, dok je  $y$  označen vektor izlaznih vrijednosti neuralne mreže.

Vrijednosti sinaptičkih težina i bias mreže se ažuriraju na osnovu greške i novog skupa vrijednosti biasa i težina, primjenjenih na mrežu sa ciljem generisanja željenog izlaza. Greška se ponovo izračunava i vraća nazad u mrežu, kako bi se postigla minimalna vrijednost greške i pronašao tačan skup izlaznih vrijednosti.

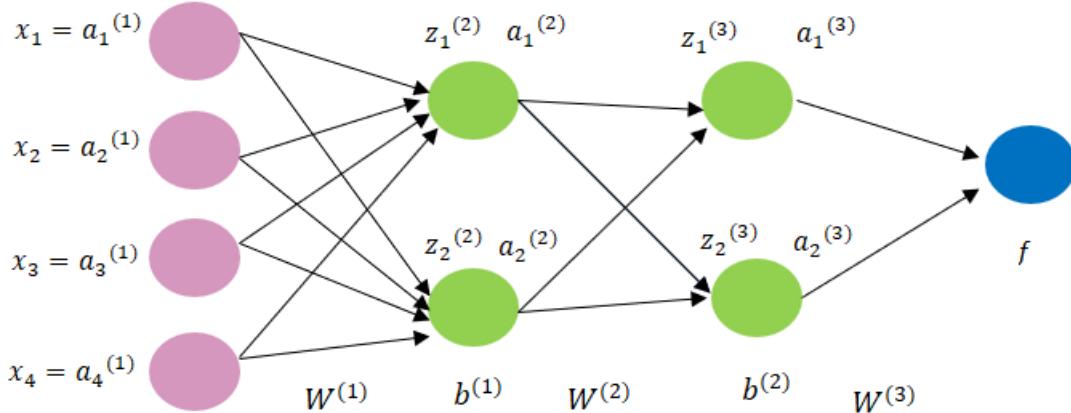
Tehnika učenja pod nadzorom se obično koristi za treniranje neuralne mreže. Takođe, široko se primjenjuje za dinamičke sisteme, posebno za reprezentaciju nelinearnog odnosa između ulaza i izlaza u sistemu.

Za razliku od procesa učenja pod nadzorom, učenje bez nadzora ne zahtijeva eksplisitne željene izlazne podatke kao mentora za učenje. Tokom nenadgledanog učenja, sistem pokušava da se prilagodi različitim obrascima ulaza, nakon čega predstavlja drugačiji ulazni obrazac u obliku izlaza neuralne mreže.

#### 4.4. Algoritam povratne propagacije za treniranje potpuno povezane višeslojne neuralne mreže

Za treniranje potpuno povezane višeslojne neuralne mreže, koja se sastoji od ulaznog sloja, proizvoljnog broja skrivenih slojeva i izlaznog sloja, koristi se algoritam povratne propagacije (eng. *Back Propagation Algorithm*). Algoritam povratne propagacije prvi put je predstavljen 1960-ih godina, a nakon skoro trideset godina kasnije je popularizovan od strane Rumelhart-a, Hinton-a i Williams-a [115].

Matematički proces obuke i optimizacije potpuno povezane višeslojne neuralne mreže, korišćenjem algoritma povratne propagacije, biće objašnjen na primjeru neuralne mreže prikazane na slici 4.9. Mreža se sastoji od četiri sloja: ulazni sloj, dva skrivena sloja i izlazni sloj [116]. Ulazni sloj sadrži četiri neurona, skriveni slojevi po dva, dok izlazni sloj sadrži jedan neuron.



Slika 4.9 Neuralna mreža sa dva skrivena sloja (primjer)

Na slici 4.9, u indeksu oznaka je upisan redni broj neurona u jednom sloju, dok eksponent označava redni broj sloja na koji se oznaka odnosi. U nastavku će se koristiti sljedeće oznake [116]:

$$z^{(2)} = \begin{bmatrix} z_1^{(2)} \\ z_2^{(2)} \end{bmatrix} \quad (4.12)$$

$$z^{(3)} = \begin{bmatrix} z_1^{(3)} \\ z_2^{(3)} \end{bmatrix} \quad (4.13)$$

U izrazima (4.12) i (4.13), sa  $z^{(2)}$  i  $z^{(3)}$  su označene matrice čiji su elementi vrijednosti na ulazu u drugi sloj i treći sloj, prije primjene aktivacione funkcije  $\varphi(z^{(2)})$  i  $\varphi(z^{(3)})$ . Vrijednosti na izlazu iz drugog i trećeg sloja neuralne mreže, nakon primjene aktivacione funkcije, predstavljene su matrično u izrazima (4.14) i (4.15), respektivno:

$$a^{(2)} = \begin{bmatrix} a_1^{(2)} \\ a_2^{(2)} \end{bmatrix} \quad (4.14)$$

$$a^{(3)} = \begin{bmatrix} a_1^{(3)} \\ a_2^{(3)} \end{bmatrix} \quad (4.15)$$

Sinaptičke težine između slojeva neuralne mreže su date u obliku težinskih matrica (4.16) i (4.17):

$$W^{(1)} = \begin{bmatrix} W_{11}^{(1)} & W_{12}^{(1)} & W_{13}^{(1)} & W_{14}^{(1)} \\ W_{21}^{(1)} & W_{22}^{(1)} & W_{23}^{(1)} & W_{24}^{(1)} \end{bmatrix} \quad (4.16)$$

$$W^{(2)} = \begin{bmatrix} W_{11}^{(2)} & W_{12}^{(2)} \\ W_{21}^{(2)} & W_{22}^{(2)} \end{bmatrix} \quad (4.17)$$

gdje matrica  $W^{(1)}$  označava sinaptičke težine između ulaznog i prvog skrivenog sloja, dok su sinaptičke težine između prvog i drugog skrivenog sloja date u obliku matrice  $W^{(2)}$ . Bias, eksterni parametar neuralne mreže prikazane na slici 4.9, može se predstaviti matrično:

$$b^{(1)} = \begin{bmatrix} b_1^{(1)} \\ b_2^{(1)} \end{bmatrix} \quad (4.18)$$

$$b^{(2)} = \begin{bmatrix} b_1^{(2)} \\ b_2^{(2)} \end{bmatrix} \quad (4.19)$$

Matrice  $z^{(l)}$ ,  $a^{(l)}$  i  $b^{(l)}$  imaju dimenziju  $nx1$ , pri čemu je  $n$  broj neurona u  $l$ -tom sloju neuralne mreže, dok je dimenzija težinske matrice  $W$  određena brojem neurona u slojevima neuralne mreže između kojih postoje sinaptičke veze. Na prikazanom primjeru (slika 4.9) dimenzija matrice  $W^{(1)}$  i  $W^{(2)}$  je  $2x4$  i  $2x2$ , respektivno.

#### 4.4.1. Propagacija unaprijed

Prvi korak implementacije algoritma je inicijalizacija biasa i sinaptičkih težina na malu vrijednost (obično između 0 i 1). Ulazni podaci, koji mogu biti jednostavnii kao skalari ili složeniji poput vektora ili višedimenzionalnih matrica, proslijedjeni su svim neuronima ulaznog sloja i dalje se propagiraju na skrivene slojeve u neuralnoj mreži [116]:

$$x_i = a_i^{(1)}, i = 1, 2, 3, 4 \quad (4.20)$$

U izrazu (4.20) je sa  $a$  označena aktivacija, odnosno vrijednost neurona nakon primjene aktivacione funkcije  $\varphi(z)$ . Iz jednačine (4.20) se vidi da je prvi set aktivacije jednak ulaznim vrijednostima.

Ulagne i izlazne vrijednosti na skrivenim slojevima, označenim zelenom bojom na slici 4.9, date su formulama za  $z^l$  i  $a^l$ , pri čemu je  $l$  broj sloja ( $l = 1, 2, 3, 4$ ). Za prvi skriveni sloj ( $l = 2$ ), ulazi i izlazi iz neurona su respektivno:

$$z^{(2)} = W^{(1)} \cdot x + b^{(1)} \quad (4.21)$$

$$a^{(2)} = \varphi(z^{(2)}) \quad (4.22)$$

Za drugi skriveni sloj ( $l = 3$ ), ulazi i izlazi iz neurona su:

$$z^{(3)} = W^{(2)} \cdot a^{(2)} + b^{(2)} \quad (4.23)$$

$$a^{(3)} = \varphi(z^{(3)}) \quad (4.24)$$

U prethodnim izrazima,  $b^{(1)}$  i  $b^{(2)}$  su oznake za eksterni parametar skrivenih slojeva, bias, dok su  $z^l$  i  $a^l$  vrijednosti neurona prije i poslije primjene aktivacione funkcije  $\varphi(z^l)$ , respektivno. Za prvi i drugi skriveni sloj neuralne mreže,  $a^{(2)}$  i  $a^{(3)}$  se izračunavaju korišćenjem nelinearne aktivacione funkcije  $\varphi$  (na primjer sigmoid ili ReLU funkcije). Posljednji dio neuralne mreže je izlazni sloj, koji generiše prognoziranu vrijednost  $f$  (eng. *Forecast*):

$$f = W^{(3)} \cdot a^{(3)} \quad (4.25)$$

Sa  $W^{(3)}$  su u izrazu (4.25) označene sinaptičke veze između drugog skrivenog sloja i izlaznog sloja.

Učenje neuralne mreže je zasnovano na grešci generisanoj tokom procesa treniranja, koja je definisana kao srednji kvadrat razlike između izmjerene vrijednosti i izlazne vrijednosti mreže (MSE). Funkcija greške neuralne mreže se može izraziti kao:

$$MSE = E = E(f, g) = \frac{1}{N} \cdot \sum_{i=1}^N (g_i - f_i)^2 \quad (4.26)$$

U izrazu (4.26),  $g$  je izmjerena vrijednost na izlazu neuralne mreže,  $f$  je vrijednost izlaza, dobijena primjenom formule (4.25), dok je  $N$  broj podataka koji se koriste za treniranje neuralne mreže.

#### 4.4.2. Propagacija unazad

Propagacija unazad ima za cilj da minimizuje funkciju greške, prilagođavanjem sinaptičkih težina i biasa neuralne mreže. Nivo prilagođavanja je određen gradijentima funkcije greške u odnosu na te parametre. Algoritam povratne propagacije koristi metod gradijentnog spuštanja (eng. *Gradient Descent*) da dostigne minimum funkcije greške  $E$ , odnosno da ažurira sinaptičke težine i bias. Računanje gradijenta funkcije greške po sinaptičkoj težini  $w^l$ , pri čemu je  $l$  redni broj sloja neuralne mreže, vrši se na sljedeći način [116]:

$$\frac{\partial E}{\partial w^l} = \frac{\partial E}{\partial z^l} \cdot \frac{\partial z^l}{\partial w^l} \quad (4.27)$$

gdje je u jednačini (4.27) sa  $z^l$  označen ulaz u  $l$ -ti sloj neurona, jednak vrijednosti neurona prije primjene aktivacione funkcije  $\varphi(z^l)$ :

$$z^l = w^l \cdot a^{l-1} + b^l \quad (4.28)$$

U jednačini (4.28),  $w^l$  je oznaka za sinaptičku težinu,  $b^l$  je bias u  $l$ -tom sloju, dok je sa  $a^{l-1}$  označena vrijednost neurona na izlazu iz  $(l-1)$ -og sloja neurona, nakon primjene aktivacione funkcije  $\varphi(z^{l-1})$ :

$$a^{l-1} = \varphi(z^{l-1}) \quad (4.29)$$

Dalje se izračunava diferencijal od ulazne funkcije  $z^l$  i funkcije greške  $E$  po sinaptičkoj težini  $w^l$ , na način prikazan u jednačinama (4.30) i (4.31):

$$\frac{\partial z^l}{\partial w^l} = a^{l-1} \quad (4.30)$$

$$\frac{\partial E}{\partial w^l} = \frac{\partial E}{\partial z^l} \cdot a^{l-1} \quad (4.31)$$

Gotovo isti set jednačina se može primijeniti za gradijent funkcije greške u slučaju biasa  $b^l$ :

$$\frac{\partial E}{\partial b^l} = \frac{\partial E}{\partial z^l} \cdot \frac{\partial z^l}{\partial b^l} \quad (4.32)$$

$$\frac{\partial z^l}{\partial b^l} = 1 \quad (4.33)$$

Diferencijal funkcije greše po biasu  $b_j^l$  ima oblik:

$$\frac{\partial E}{\partial b^l} = \frac{\partial E}{\partial z^l} \cdot 1 \quad (4.34)$$

Zajednički dio u jednačinama (4.31) i (4.34) naziva se lokalni gradijent funkcije greške u  $l$ -tom sloju neurona [116]:

$$\delta^l = \frac{\partial E}{\partial z^l} \quad (4.35)$$

Pomoću gradijenta funkcije greške, datog u jednačinama (4.31) i (4.34), vrši se ažuriranje sinaptičkih težina i biasa, sa ciljem da se postigne željeni izlaz iz neuralne mreže. Ukoliko bi povećavanje vrijednosti parametara modela (sinaptičkih težina i biasa) dovelo do povećavanja funkcije greške  $E$ , tada je gradijent funkcije greške pozitivan i obrnuto. Gradijent funkcije greške je indikator koliko je parametre modela potrebno smanjiti/povećati, da bi se funkcija greške  $E$  minimizovala.

Lokalni gradijent funkcije greške, zapisan u jednačini (4.35), može se odrediti korišćenjem lančanog pravila (eng. *Chain Rule*), sumiranjem lokalnog gradijenta funkcije greške za svaki neuron u narednom sloju [117]:

$$\delta_k^l = \frac{\partial E}{\partial z_k^l} = \sum_{i=1}^m \frac{\partial E}{\partial z_i^{l+1}} \cdot \frac{\partial z_i^{l+1}}{\partial z_k^l} \quad (4.36)$$

Gradijent funkcije greške u  $(l + 1)$ -om sloju je:

$$\delta_i^{l+1} = \frac{\partial E}{\partial z_i^{l+1}} = \left[ \frac{\partial E}{\partial z_1^{l+1}}, \frac{\partial E}{\partial z_2^{l+1}}, \dots, \frac{\partial E}{\partial z_m^{l+1}} \right] \quad (4.37)$$

Određivanje gradijenta funkcije greške neurona  $k$  u  $l$ -tom sloju, korišćenjem gradijenta funkcije greške neurona  $i = 1, 2, 3, \dots, m$  u  $(l + 1)$ -om sloju, može se zapisati kao:

$$\delta_k^l = \sum_{i=1}^m \delta_i^{l+1} \cdot \frac{\partial z_i^{l+1}}{\partial z_k^l} \quad (4.38)$$

U jednačinama (4.36)-(4.38), oznake imaju sljedeća značenja:

- $\delta_k^l$  – lokalni gradijent funkcije greške neurona  $k$  u  $l$ -tom sloju,
- $z_k^l$  – vrijednost neurona  $k$  na ulazu  $l$ -tog sloja, prije primjene aktivacione funkcije  $\varphi(z_k^l)$ ,
- $z_i^{l+1}$  – vrijednost neurona  $i$  na ulazu  $(l + 1)$ -og sloja, prije primjene aktivacione funkcije  $\varphi(z_i^{l+1})$ ,
- $\delta_i^{l+1}$  – lokalni gradijent funkcije greške neurona  $i$  u  $(l + 1)$ -om sloju,
- $m$  – broj neurona u  $(l + 1)$ -om sloju.

Proces optimizovanja parametara modela, odnosno ažuriranja sinaptičkih težina i biasa neuralne mreže tokom procesa treniranja, vrši se na sljedeći način:

$$w := w - \eta \cdot \frac{\partial E}{\partial w} \quad (4.39)$$

$$b := b - \eta \cdot \frac{\partial E}{\partial b} \quad (4.40)$$

Znak gradijenta funkcije greške po sinaptičkim težinama i biasu neuralne mreže pokazuje da li greška varira direktno ili obrnuto proporcionalno parametrima modela. Iz navedenog razloga, parametri modela se ažuriraju u suprotnom smjeru, „spuštajući“ gradijent.

Ažuriranje vrijednosti parametara modela je proporcionalno, ali ne i nužno jednak gradijentu funkcije greške  $\partial E$ . U izrazima (4.39) i (4.40),  $\eta$  predstavlja stopu učenja (eng. *Learning Rate*), koja dodatno doprinosi ažuriranju parametara modela [118]. Vrijednost stope učenja se optimizuje uzimajući u obzir sljedeće:

- Korišćenjem male vrijednosti stope učenja, minimizacija funkcije greške zahtijeva previše vremena.
- Ukoliko se stopa učenja inicijalizuje na veliku vrijednost, minimum funkcije greške može biti preskočen.

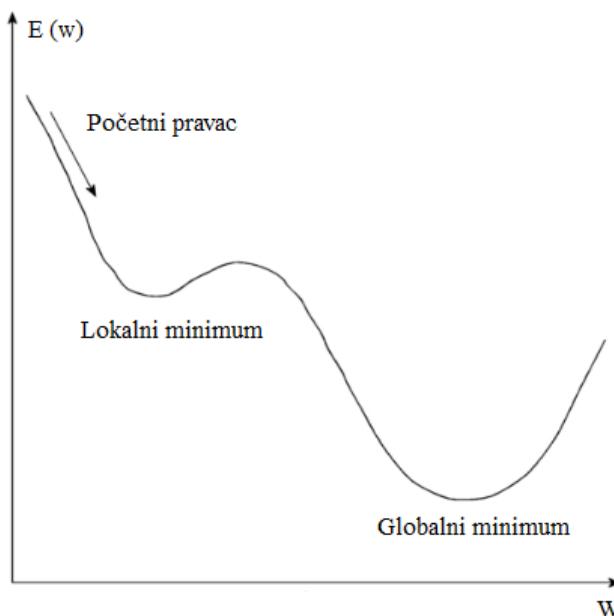
#### 4.5. Potencijalni problemi primjene algoritma povratne propagacije

U toku treniranja neuralne mreže, mogu se pojaviti problemi prilikom implementacije algoritma povratne propagacije, koji nepovoljno utiču na performanse obuke MLPNN. Ovakve situacije se odnose na postizanje lokalnog, umjesto globalnog minimuma i pretreniranje (eng. *Overfitting*) neuralne mreže.

Cilj algoritama za treniranje neuralne mreže je postizanje globalnog minimuma, kako bi se postigao veći učinak obuke mreže. Međutim, može se desiti da neuralna mreža ostane “zaglavljena” u lokalnom minimumu, ilustrovanim na slici 4.10. U takvoj situaciji, čak i stalnim ažuriranjem sinaptičkih težina, veoma je teško prevazići tačku lokalnog minimuma. Kao rezultat toga, loša obuka neuralne mreže će smanjiti performanse mreže i uticati na izlaznu vrijednost.

Da bi se izbjegla tačka lokalnog minimuma, sinaptičke težine se na samom početku algoritma inicijalizuju na malu vrijednost. Nakon toga, ažuriranje parametara modela se vrši korišćenjem malih vrijednosti stope učenja, kako bi se omogućila njihova modifikacija sve dok se ne dostigne globalni minimum.

Generalizacija je mjera sposobnosti neuralne mreže da se prilagodi različitim skupovima ulaznih podataka. Za mrežu se kaže da je dobro generalizovana, kada je izlaz iz mreže dovoljno blizu željenim vrijednostima, koje se ne nalaze na ulazu neuralne mreže. Glavni faktori koji utiču na generalizaciju su veličina i kvalitet podataka za obuku, struktura i složenost mreže.



Slika 4.10 Lokalni i globalni minimum

Pretreniranje se odnosi na scenario u kojem se neuralna mreža prekomjerno prilagodi trening podacima, dok za podatke koji se razlikuju od njih pokazuje neefikasnost prilikom postizanja zadovoljavajuće tačnosti. Pored toga, nepoželjna situacija je podtreniranje (eng. *Underfitting*) neuralne mreže, odnosno onemogućavanje formiranja ulazno-izlaznih veza na skupu podataka za trening i testiranje, stvarajući veliku grešku. Problem pretreniranja modela neuralne mreže potencijalno može biti prevaziđen proširenjem skupa podataka za treniranje i/ili regularizacijom.

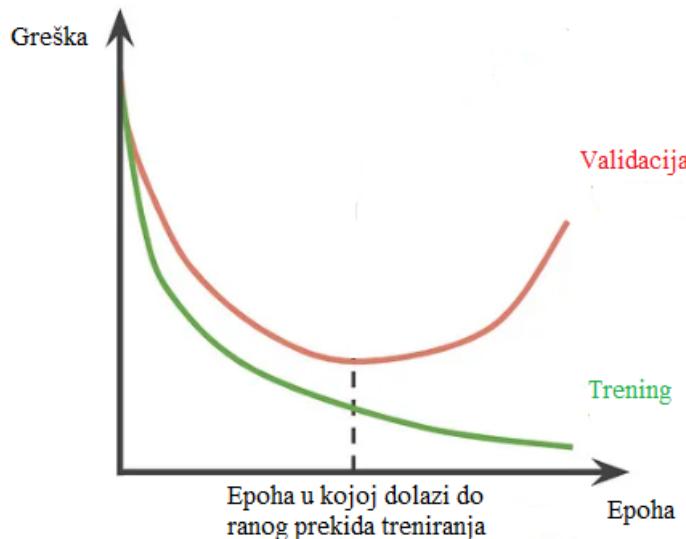
Povećavanje broja ulaznih podataka rezultira poboljšavanjem sposobnosti generalizacije i ukupnih performansi modela neuralne mreže, smanjenjem prekomjernog prilagođavanja i proširenjem granice odlučivanja modela. Na taj način, model prevazilazi male skupove podataka ili skupove podataka sa neuravnoteženim klasama [119]-[122]. Međutim, podaci za treniranje neuralne mreže moraju uključivati samo relevantne podatke, koji odražavaju stvarni proces, pa proširenje skupa trening podataka često nije moguće realizovati na pravi način.

Neki od mogućih načina na koje se vrši regularizacija su upotreba jednostavnije strukture, rani prekid treniranja, *Dropout* metod regularizacije i drugi. Jednostavnija struktura neuralne mreže je tip regularizacije kojem se vrlo rijetko pribjegava, budući da se smanjenjem broja skrivenih slojeva u strukturi neuralne mreže smanjuju performanse modela za prognozu potrošnje električne energije. Za metode regularizacije u ovom radu, korištene su *Dropout* regularizacija i rani prekid treniranja neuralne mreže.

*Dropout* regularizacija služi za proizvoljno eliminisanje određenog broja neurona u slojevima neuralne mreže, obično od 10 do 50%. Na ovaj način se model prilagođava scenariju u kojem neuralna mreža nema na raspolaganju sve neurone iz svoje strukture, smanjujući uticaj pojedinih neurona na tačnost dobijenih rezultata. Ovaj tip regularizacije se primjenjuje prilikom treniranja neuralne mreže, dok će u fazi testiranja modela svi neuroni biti uključeni u prognozi potrošnje električne energije [123].

Rani prekid treniranja (slika 4.11) je najzastupljeniji metod za sprječavanje pretreniranja neuralne mreže i obično se primjenjuje u kombinaciji sa nekim od ostalih tipova regularizacije.

Završena iteracija u toku procesa treniranja, u kojoj su svi podaci „propušteni“ kroz neuralnu mrežu, označava jednu završenu epohu (eng. *Epoch*). Dostizanje maksimalnog broja epoha je jedan od kriterijuma zaustavljanja procesa treniranja i definisan je na samom početku algoritma neuralne mreže.



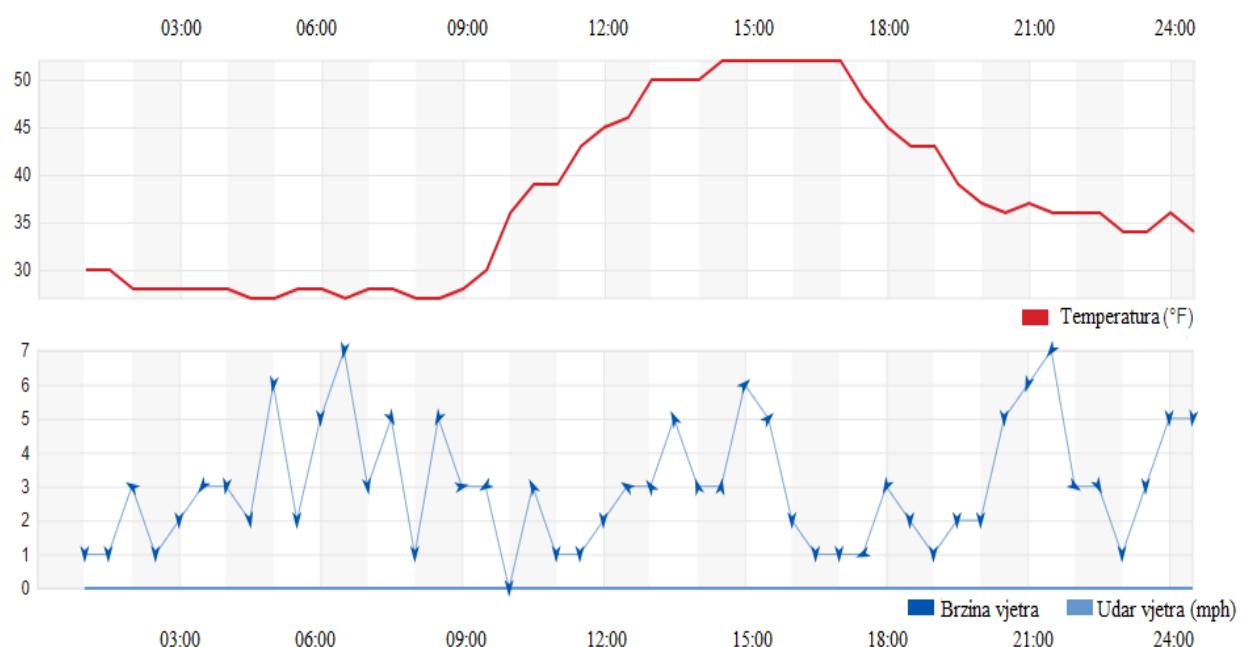
Slika 4.11 Rani prekid treniranja neuralne mreže

Prekid treniranja neuralne mreže se sprovodi i u slučaju kada greška nad podacima za validaciju uzastopno, nakon određenog broja epoha, zadržava istu vrijednosti ili se povećava. U tom slučaju, za broj epoha koji je definisan parametrom *Patience*, izvršiće se rani prekid treniranja neuralne mreže, sa ciljem da se spriječi pogoršavanje performansi modela neuralne mreže [124].

## 5. IMPLEMENTACIJA SISTEMA ZA PROGNOZU POTROŠNJE ELEKTRIČNE ENERGIJE

### 5.1. Ulagani set podataka

Prognoza potrošnje električne energije se vrši na osnovu podataka o satnoj potrošnji električne energije za konzum Podgorice, koja se odnosi na period od 2011. do 2015. godine. Pored istorijskih podataka o opterećenju, ulazi u mrežu sadrže podatke o meteorološkim uslovima (temperatura, vlažnost vazduha i brzina vjetra), prikupljene sa internet sajta *Weather Underground* [125]. Na slici 5.1 je grafički prikazana promjena temperature, brzine i udara vjetra, u toku 24 časa na području Podgorice. Za potrebe ovog rada, jedinica za temperaturu je pretvorena u Celzijus ( $^{\circ}\text{C}$ ), dok je brzina vjetra izražena u  $\text{km}/\text{h}$ .



Slika 5.1 Grafički prikaz promjene temperature i brzine vjetra u toku 24 časa (primjer) [125]

Pored navedenih meteoroloških faktora, ulagani podaci koji su u ovom radu korišćeni za prognozu potrošnje električne energije su:

- mjesec u godini (1 - januar, 2 - februar, 3 - mart, 4 - april, 5 - maj, 6 - jun, 7 - jul, 8 - avgust, 9 - septembar, 10 - oktobar, 11 - novembar, 12 - decembar)
- dan u nedelji (1 - ponedeljak, 2 - utorak, 3 - srijeda, 4 - četvrtak, 5 - petak, 6 - subota, 7 - nedelja)
- sat u toku dana (0-23)
- radni/neradni dan (1 – radni dan, 0 - neradni dan)
- praznični dan (1 - praznik, 0 - običan dan)
- jeftina/skupa tarifa (1 - jeftina tarifa, 0 - skupa tarifa)

Ulagani podaci za jedan radni dan su prikazani u tabeli 5.1. Faktori koji imaju uticaj na prognozu potrošnje električne energije su broj stanovnika i cijena za električnu energiju, ali te vrijednosti nijesu uključene u tabelu sa ulaganim podacima u ovom radu.

Broj stanovnika u Podgorici je fiksna vrijednost za period od 10 godina, dok se cijena za preuzetu električnu energiju u ovom radu uvažava posmatranjem perioda niže i više tarife u toku dana.

Tabela 5.1 Ulagani podaci u neuralnu mrežu za srijedu, 28. januar 2015. godine u Podgorici

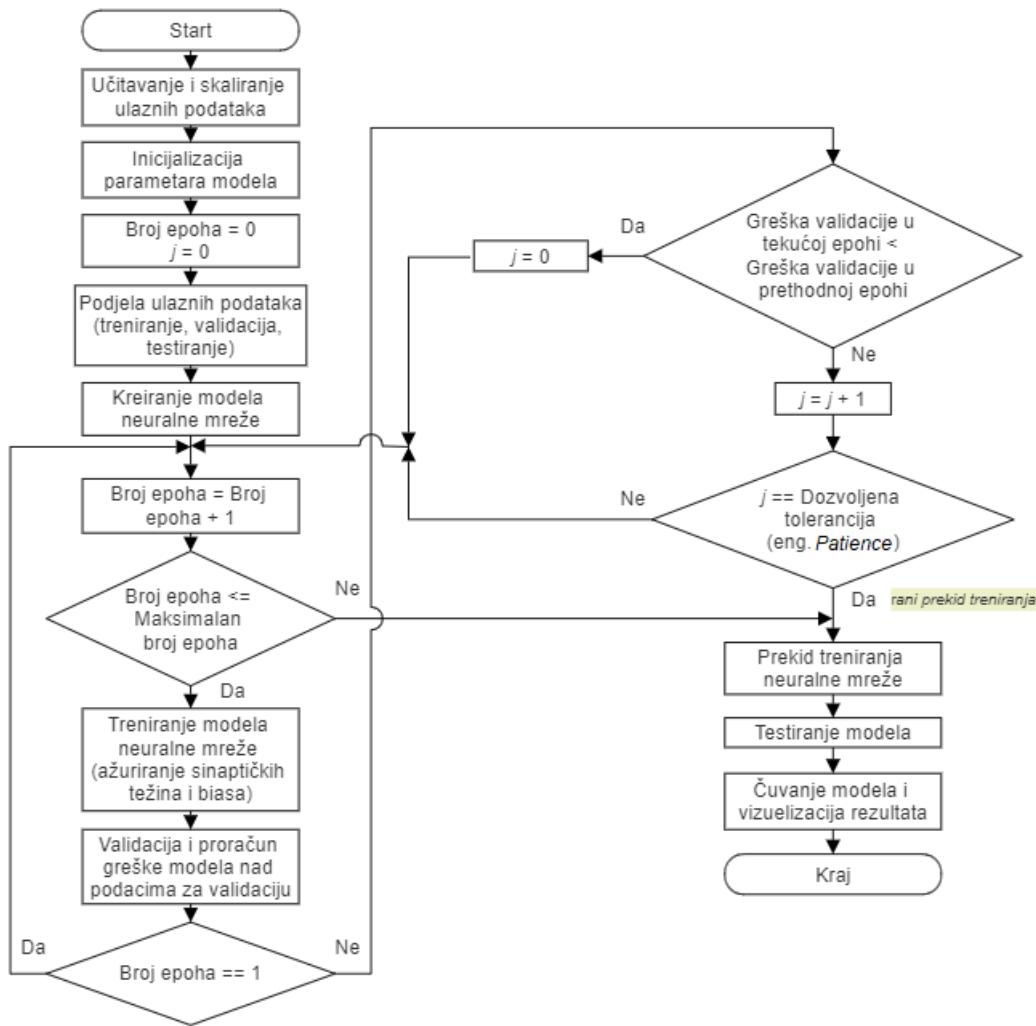
Mjesec (1-12)	Dan u nedelji (1-7)	Sat u toku dana (0-23)	Radni / Neradni dan (1/0)	Praznični dan (1/0)	Jeftina / Skupa tarifa (1/0)	Temperatura (°C)	Vlažnost vazduha (%)	Brzina vjetra (km/h)
1	3	0	1	0	1	6	81	3
1	3	1	1	0	1	6	81	2
1	3	2	1	0	1	6	76	2
1	3	3	1	0	1	6	66	13
1	3	4	1	0	1	6	66	8
1	3	5	1	0	1	6	66	5
1	3	6	1	0	1	6	61	5
1	3	7	1	0	0	5	65	6
1	3	8	1	0	0	6	61	3
1	3	9	1	0	0	7	53	6
1	3	10	1	0	0	8	57	5
1	3	11	1	0	0	10	58	3
1	3	12	1	0	0	9	66	6
1	3	13	1	0	0	10	50	3
1	3	14	1	0	0	10	40	6
1	3	15	1	0	0	10	40	1
1	3	16	1	0	0	9	46	3
1	3	17	1	0	0	8	50	8
1	3	18	1	0	0	7	53	10
1	3	19	1	0	0	6	53	8
1	3	20	1	0	0	5	57	10
1	3	21	1	0	0	6	53	10
1	3	22	1	0	0	5	57	9
1	3	23	1	0	1	4	61	6

Na prikazani način, prikupljeni su podaci za svaki dan, koji se odnose na cijelokupan period od 5 godina. Ulagani skup se sastoji od ukupno 43 823 podatka, od čega neuralna mreža koristi 26 303 podataka za treniranje, 8 760 podataka za validaciju i 8 760 podataka za testiranje sistema.

## 5.2. Opis algoritma neuralne mreže

Blok šema algoritma neuralne mreže, koji se koristi za prognozu potrošnje električne energije u ovom radu, prikazana je na slici 5.2. Na samom početku, vrši se učitavanje i skaliranje ulaznih podataka. Skaliranje podataka je potrebno da bi gradijentno spuštanje rezultiralo glatkim približavanjem minimumu funkcije greške, odnosno kako bi se ažurirano veličina prilikom gradijentalnog spuštanja odvijalo istom brzinom za sve karakteristike. Skalirani podaci u ML doprinose bržoj konvergenciji algoritma.

Nakon učitavanja i skaliranja ulaznih podataka, vrši se inicijalizacija vrijednosti parametara modela, stope učenja, broj podataka koji se istovremeno proslijedi za treniranje neuralne mreže, prije ažuriranja parametara modela (eng. *Batch Size*), parametra regularizacije *Dropout*, kao i parametra *Patience* kojim je određen broj epoha nakon kojeg dolazi do ranog prekida treniranja modela neuralne mreže (potpoglavlje 4.5). Ulazni podaci se dijele na podatke za treniranje, podatke za validaciju i podatke za testiranje modela. Od ukupnog broja podataka, najveći dio se koristi za treniranje modela neuralne mreže – u ovom slučaju 60%, dok se za validaciju i testiranje modela koristi po 20% podataka.



Slika 5.2 Blok šema algoritma neuralne mreže

Treniranje neuralne mreže se vrši pomoću algoritma povratne propagacije, opisanog u potpoglavlju 4.4. Prvi kriterijum zaustavljanja procesa treniranja neuralne mreže je definisan maksimalnim brojem epoha.

Nakon svake epohe, računa se srednja kvadratna greška modela (MSE) nad podacima za validaciju, koji nijesu korišćeni za treniranje neuralne mreže. Validacija služi za procjenu vještine neuralne mreže prilikom podešavanja parametara modela (sinaptičkih težina i biasa) [126]. U okviru algoritma prikazanog na slici 5.2, korišćenjem operatora  $j$  se uvažava vrijednost greške validacije nakon svake završene epohe. U slučaju smanjenja greške nad podacima za validaciju u tekućoj epohi, u odnosu na vrijednost greške u prethodnoj epohi, operator  $j$  će imati vrijednost  $j = 0$ , nakon čega će se treniranje modela nastaviti u sljedećoj epohi.

Međutim, ukoliko greška nad validacionim podacima uzastopno ima rastući trend ili zadržava istu vrijednost, operator  $j$  će se povećavati nakon svake uzastopne epohe sa takvim ishodom. Kada operator  $j$  dostigne vrijednost jednaku dozvoljenoj toleranciji, odnosno parametru *Patience*, ispunjen je drugi kriterijum zaustavljanja i proces treniranja neuralne mreže je završen.

Dostizanjem maksimalnog broja epoha ili ranim prekidom treniranja, na istrenirani model se proslijeduju podaci za testiranje (20% ukupnog broja ulaznih podataka). Testiranje modela neuralne mreže služi za nepristrasnu procjenu performansi neuralne mreže, slično procesu validacije. Međutim, u odnosu na proces validacije, koji je prisutan nakon svake epohe u kojoj se neuralna mreža trenira, testiranje modela se vrši na kraju, kada se ispuni jedan od kriterijuma zaustavljanja treniranja neuralne mreže [127].

### 5.2.1. Adam algoritam optimizacije

U ovom radu, za optimizaciju stope učenja i ažuriranje parametara modela neuralne mreže, koristi se *Adaptive Estimation Moment (Adam)* algoritam optimizacije, poznat kao prošireni stohastički metod gradijentnog spuštanja (eng. *Stochastic Gradient Descent*). Stohastički metod gradijentnog spuštanja vrši nasumičan odabir skupa podataka i ažuriranje parametara modela korišćenjem funkcije greške  $E$ . Na taj način se prevazilazi nedostatak potencijalnog globalnog minimuma funkcije greške, koji se može pojaviti u slučaju kada postoji više lokalnih minimuma (potpoglavlje 4.5). Pored toga, stohastički metod brže konvergira nad velikim skupom podataka, u odnosu na obični metod gradijentnog spuštanja [128]-[130].

*Adam* algoritam optimizacije koriguje individualne stope učenja za različite parametre modela  $p$  (sinaptičke težine i bias u slučaju neuralnih mreža), estimacijom prvog ( $m$ ) i drugog ( $v$ ) momenta gradijenta. Pomoću promjenljivih  $m$  i  $v$ , procjenjuje se pravac kretanja gradijeta [128]:

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \quad (5.1)$$

$$v_t = \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (5.2)$$

U jednačinama (5.1) i (5.2) oznake imaju sljedeća značenja:

- $m_t$  – prvi moment gradijenta funkcije u vremenskom koraku  $t$ ;
- $v_t$  – drugi moment gradijenta funkcije u vremenskom koraku  $t$ ;
- $\beta_1 \in [0,1]$  – eksponencijalni stopa opadanja za estimaciju momenta  $m$ ;
- $\beta_2 \in [0,1]$  – eksponencijalni stopa opadanja za estimaciju momenta  $v$ ;
- $g_t$  – gradijent funkcije greške  $E$  po parametru  $p$ , u vremenskom koraku  $t$ :

$$g_t = \nabla E(p_t) = \frac{\partial E(p_t)}{\partial p_t} \quad (5.3)$$

Procjena novog pravca kretanja gradijenta je:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (5.4)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (5.5)$$

Ažuriranje parametara modela se vrši na sljedeći način:

$$p_{t+1} = p_t - \eta_{t+1} \frac{\hat{m}_{t+1}}{\sqrt{\hat{v}_{t+1}} + \epsilon} \quad (5.6)$$

gdje je  $\eta$  stopa učenja (eng. *Learning Rate*) i  $\epsilon$  konstanta. Po defaultu (eng. *Default*) stopa učenja je inicijalizovana na vrijednost  $\eta = 0.001$ , eksponencijalni parametri  $\beta_1 = 0.9$  i  $\beta_2 = 0.999$ , dok se za konstantu obično uzima vrijednost  $\epsilon = 10^{-8}$  [128], [129].

*Adam* algoritam optimizacije prilagođava stopu učenja za svaki parametar modela neuralne mreže. Karakteristika ažuriranja vrijednosti stope učenja u toku procesa treniranja je veoma važna prednost korišćenja *Adam* optimizacionog algoritma, u odnosu na druge algoritme optimizacije, koji stopu učenja definišu kao fiksnu vrijednost. Opisani postupak skraćuje vrijeme trajanja optimizacije i ima niske zahtjeve za računarskom konfiguracijom [131].

### 5.3. Izbor strukture mreže i parametara modela

Za prognozu potrošnje električne energije korišćenjem MLPNN, potrebno je izabrati optimalnu strukturu neuralne mreže, odnosno definisati broj skrivenih slojeva i broj neurona koji sadrže, za postizanje rezultata zadovoljavajuće tačnosti. Prilikom definisanja ovih veličina, vodi se računa da broj skrivenih slojeva i broj neurona ne budu velike vrijednosti, budući da postoji mogućnost da takav izbor strukture dovede do potencijalnog pretreniranja modela neuralne mreže. U tabeli 5.2 je prikazan primjer različitih kombinacija broja slojeva i broja neurona, na osnovu kojih je moguće izvršiti optimalan izbor strukture neuralne mreže.

Sa aspekta srednje kvadratne greške (MSE), najbolji rezultat, odnosno najmanja greška modela, postiže se korišćenjem MLPNN sa dva skrivena sloja, koji sadrže 150 i 100 neurona, respektivno. U tom slučaju greška modela iznosi 0,0397 nakon 53 epohe, u trajanju od 164,79 sekundi, kada se treniranje neuralne mreže zaustavlja. S obzirom da posljednji (izlazni) sloj sadrži jedan neuron, ima smisla redom, postepeno smanjivati broj neurona u skrivenim slojevima neuralne mreže.

Maksimalan broj epoha, čije dostizanje dovodi do prekida treniranja modela neuralne mreže, u ovom radu iznosi 1000. Međutim, parametar *Patience* inicira prijevremeno zaustavljanje treniranja neuralne mreže u slučaju da se nakon određenog broja uzastopnih epoha, definisanog ovim parametrom, validaciona greška modela ne smanjuje – tada će se izvršiti rani prekid treniranja. U ovom radu, rani prekid treniranja se vrši nakon pet uzastopnih epoha u kojima ne dolazi do smanjenja greške nad validacionim podacima.

Tabela 5.2 Izbor strukture mreže na osnovu rezultata dobijenih korišćenjem različitih kombinacija broja slojeva i broja neurona za treniranje neuralne mreže

	<i>Broj neurona u prvom skrivenom sloju</i>	<i>Broj neurona u drugom skrivenom sloju</i>	<i>Broj neurona u trećem skrivenom sloju</i>	<i>Greška (MSE)</i>	<i>Broj epoha</i>	<i>Vrijeme (s)</i>
<i>Jedan skriveni sloj</i>	50	/	/	0,0736	31	71,9037
	100	/	/	0,0503	33	75,7549
	150	/	/	0,0543	27	66,4526
<i>Dva skrivena sloja</i>	50	50	/	0,0461	32	104,6196
	50	100	/	0,0485	22	53,1071
	50	150	/	0,0438	27	65,0744
	100	50	/	0,0421	34	113,0522
	100	100	/	0,0424	30	74,2074
	100	150	/	0,0467	25	62,0434
	150	50	/	0,0441	24	62,3214
	150	100	/	0,0397	53	164,7958
<i>Tri skrivena sloja</i>	150	100	50	0,0437	23	68,5450
	150	100	100	0,0427	25	72,0267
	150	100	150	0,0461	18	55,5089

Iz tabele 5.2 se vidi da je prosječna greška modela niža korišćenjem dva, umjesto jednog skrivenog sloja, dok se dodavanjem trećeg skrivenog sloja ne doprinosi smanjenju prosječne greške u prognozi potrošnje električne energije. Iz navedenog razloga, treći skriveni sloj neće biti dio strukture neuralne mreže, iako je korišćenje MLPNN sa tri skrivena sloja dobra opcija sa aspekta vremena trajanja procesa prognoziranja. Povećavanje broja skrivenih slojeva i neurona rezultira većim brojem sinaptičkih težina koje model može da prilagodi, pa će treniranje neuralne mreže imati kraće trajanje. Međutim, veći broj skrivenih slojeva i neurona u strukturi neuralne mreže dovodi do prevelikog prilagođavanja podacima za trening, uslijed čega model daje veoma loše rezultate nad podacima za testiranje (potpoglavlje 4.5).

Prosljeđivanje podataka neuralnoj mreži za treniranje, prije ažuriranja parametara modela, određeno je parametrom *Batch Size*:

$$1 \leq \text{Batch Size} \leq N \quad (5.7)$$

gdje je u jednačini (5.7) sa  $N$  označen ukupan broj podataka za treniranje modela neuralne mreže [132]. Primjer odabira optimalne veličine parametra *Batch Size* je prikazan u tabeli 5.3. Manji broj istovremeno prosljeđenih podataka rezultira manjim memorijskim zahtjevima i učestalijim ažuriranjem sinaptičkih težina.

Tabela 5.3 Promjena prosječne greške modela i vremena trajanja treniranja u zavisnosti od promjene parametra *Batch Size*

<i>Batch Size</i>	<i>Greška (MSE)</i>
20	0,0418
40	0,0412
60	0,0468
80	0,0445
100	0,0456

U cilju sprječavanja pretreniranja neuralne mreže, pored ranog prekida treniranja, koji je definisan pomoću parametra *Patience*, u ovom radu se primjenjuje i *Dropout* regularizacija (potpoglavlje 4.5), koja se obično mijenja u opsegu od 10 do 50 %, kao što je prikazano u tabeli 5.4.

Tabela 5.4 Promjena prosječne greške modela i vremena trajanja treniranja u zavisnosti od promjene parametra regularizacije *Dropout*

<i>Dropout parametar regularizacije</i>	<i>Greška (MSE)</i>
0,1	0,0472
0,2	0,0537
0,3	0,0549
0,4	0,0550
0,5	0,0651

Očekivano, veća vrijednost *Dropout* parametra regularizacije znači eliminisanje većeg broja neurona iz strukture neuralne mreže, čime se postiže veća prosječna greška modela za prognozu potrošnje električne energije.

U tabeli 5.5 su prikazane performanse neuralne mreže za izabranu strukturu i parametare modela:

- 150 neurona u prvom skrivenom sloju;
- 100 neurona u drugom skrivenom sloju;
- *Dropout* parametar regularizacije = 0,1;
- *Batch Size* = 40;

Dok je MSE indikativna za izbor strukture i parametara modela neuralne mreže (tabela 5.2), u ovom slučaju se, prilikom poređenja stvarne i predviđene vrijednosti potrošnje električne energije, uzima u obzir i srednja apsolutna greška (eng. *Mean Absolute Error-MAE*), definisana na sljedeći način [133]:

$$MAE = \frac{1}{m} \cdot \sum_{k=1}^m |y_k - f_k| \quad (5.8)$$

U jednačini (5.8),  $m$  je broj ulaznih podataka koji se odnose na potrošnju električne energije,  $y_k$  je vrijednost potrošnje električne energije, dok je  $f_k$  prognozirana vrijednost. MAE ima jedinicu koja odgovara prognoziranoj vrijednosti [MWh].

Tabela 5.5 Performanse modela neuralne mreže nakon izbora strukture i parametara modela

Srednja kvadratna greška (MSE)	0,0499
Srednja apsolutna greška (MAE)	4,6185
Broj epoha	37
Vrijeme (s)	58,334

#### 5.4. Modifikacija ulaznog skupa podataka sa ciljem poboljšavanja performansi modela neuralne mreže za prognozu potrošnje električne energije

Neuralna mreža zahtijeva veliki broj ulaznih podataka, čiji kvalitet predstavlja ključni faktor za dobijanje rezultata zadovoljavajuće tačnosti. Korišćenje podataka lošeg kvaliteta može ozbiljno degradirati rezultate i dovesti do nepravilnog donošenja odluka, koje se oslanjaju na dobijene rezultate. Pored toga, u slučaju neuravnoteženih ulaznih podataka, javlja se pristrasnost neuralne mreže u korist vrijednosti podataka koji dominiraju u ulaznom skupu [134], [135].

U ovom radu, ulazni skup sadrži podatke o istorijskoj potrošnji električne energije i faktorima od dominantnog uticaja, koji se odnose na period od 2011. do 2015. godine (potpoglavlje 5.1). Imajući u vidu periodično svojstvo, u ulaznom skupu su prisutne varijacije potrošnje električne energije na satnom, dnevnom, sedmičnom, mjesecnom i godišnjem nivou.

Sa ciljem postizanja tačnije prognoze potrošnje električne energije korišćenjem neuralnih mreža, u ovom radu je korišćena metoda pokretnog prosjeka (eng. *Moving Average*), koja je u literaturi poznata kao *rolling mean* metoda. Metoda pokretnog prosjeka je statistička metoda koja omogućava praćenje prosječne promjene podataka u posmatranom vremenskom intervalu. Koristi se za identifikaciju trendova u fluktuacijama određene veličine, smanjujući efekat odstupanja prilikom prognoziranja u skupu mjernih podataka koji su poređani hronološki (eng. *Time Series Data*) [136].

Za potrebe prognoziranja korišćenjem neuralnih mreža, *rolling mean* se koristi za izračunavanje srednjih vrijednosti veličina i njihovo korišćenje u ulaznom skupu podataka [137]-[139]. Pored *rolling mean* metode, za poboljšavanje performansi modela neuralne mreže, u upotrebi je i pokretna standardna devijacija, poznata kao *rolling standard deviation*.

Standardna devijacija predstavlja mjeru koliko podaci variraju od prosjeka [140]:

- niska standardna devijacija – podaci su usko grupisani oko srednje vrijednosti (prosjeka),
- visoka standardna devijacija – podaci se nalaze u širokom opsegu vrijednosti.

Pokretna standardna devijacija je statistička mjera koja izračunava standardnu devijaciju tokom određenog vremenskog perioda, identificujući periode visoke volatilnosti i periode stabilnosti posmatranih podataka [141]. Ako su  $x_1, x_2, \dots, x_n$  hronološki poređane vrijednosti, srednja vrijednost  $k$  vrijednosti, koji prethode  $x_n$ , se može izračunati kao [142]:

$$\bar{x}_n(k) = \frac{x_{n-k} + x_{n-k+1} + \dots + x_{n-1}}{k} = \frac{1}{k} \cdot \sum_{i=n-k}^{n-1} x_i \quad (5.9)$$

dok standardna devijacija ima oblik:

$$\bar{\sigma}_n(k) = \sqrt{\frac{1}{k} \cdot \sum_{i=n-k}^{n-1} (x_i - \bar{x}_n(k))^2} \quad (5.10)$$

gdje su u jednačinama (5.9) i (5.10) sa  $\bar{x}_n(k)$  i  $\bar{\sigma}_n(k)$  označene srednja vrijednost i standardna devijacija prethodnih  $k$  vrijednosti, respektivno.

U ovom radu, korišćenjem *rolling mean* i *rolling standard deviation* metoda, dobijaju se dva nova ulazna podatka, koja utiču na prognozu potrošnje električne energije u posmatranom satu – srednja vrijednost potrošnje električne energije i standardna devijacija u prethodnih  $k$  sati, pri čemu je vrijednost  $k$  izabrana na način prikazan u tabeli 5.6.

Tabela 5.6 Promjena srednje kvadratne i srednje apsolutne greške u zavisnosti od broja  $k$

$k$	Srednja kvadratna greška (MSE)	Srednja apsolutna greška (MAE)	Broj epoha	Vrijeme (s)
$k = 3$	0,0126	2,1221	26	43,825
$k = 4$	0,0151	2,3206	24	45,600
$k = 5$	0,0190	2,6524	15	27,370
$k = 6$	0,0174	2,5192	29	49,964

U tabeli 5.6 se vidi da se za najkraće vrijeme trajanja prognoze potrošnje električne energije, najmanja srednja kvadratna i srednja apsolutna greška postiže proračunom srednje vrijednosti i standardne devijacije za tri sata koja prethode satu u kojem se vrši prognoza potrošnje električne energije. U odnosu na model prije korišćenja *rolling mean* i *rolling standard deviation* vrijednosti na ulazu neuralne mreže, mogu se uočiti bolje performanse, kako sa aspekta srednje kvadratne i srednje apsolutne greške, tako i sa aspekta vremena potrebnog za implementaciju (tabela 5.7).

Tabela 5.7 Uporedna analiza performansi modela prije i poslije korišćenja *rolling mean* i *rolling standard deviation* vrijednosti na ulazu neuralne mreže

	Model prije korišćenja <i>rolling mean</i> i <i>rolling standard deviation</i>	Model poslije korišćenja <i>rolling mean</i> i <i>rolling standard deviation</i>
MSE	0,0499	0,0126
MAE	4,6185	2,1221
Broj epoha	37	26
Vrijeme (s)	58,334	43,825

Korišćenjem *rolling mean* i *rolling standard deviation* vrijednosti, neuralna mreža na ulazu ima više podataka, pa se kao rezultat dobija pouzdanija prognoza potrošnje električne energije i kraće vrijeme potrebno da model postigne zadovoljavajuću tačnost. Ovaj pristup zahtijeva hronološki poređane ulazne podatke i vrijednosti potrošnje električne energije prethodna tri časa, uslijed čega postiže visoku tačnost u slučaju kratkoročne prognoze potrošnje električne energije.

## 5.5. Rezultati implementacije sistem za prognozu potrošnje električne energije na karakterističnim primjerima

U ovom radu, sistem za prognozu potrošnje električne energije je treniran nad skupom podataka koji se odnosi na period od 2011. do 2013. godine, dok se validacija vrši nad skupom podataka za 2014. godinu. Nakon toga, sistem je testiran nad podacima koji se odnose na karakteristične dane u 2015. godini, čiji će rezultati biti posebno analizirani u ovom radu.

### 5.5.1. Primjer – srijeda, 28. januar 2015. godine

Posmatra se jedan dan u zimskom periodu, u ovom slučaju radni dan – srijeda, 28. januar 2015. godine. Ulagani podaci sa satnom rezolucijom, koji se odnose na ovaj datum, dati su u tabeli 5.8.

Tabela 5.8 Ulagani podaci u neuralnu mrežu za srijedu, 28. januar 2015. godine

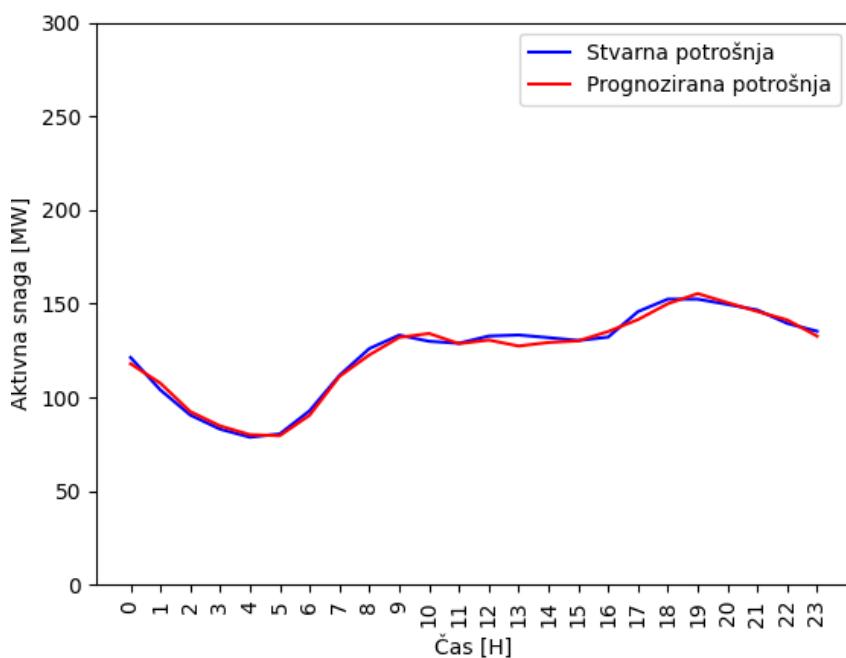
Mjesec (1-12)	Dan u nedelji (1-7)	Sat u toku dana (0- 23)	Radni / Neradni dan (1/0)	Praznični dan (1/0)	Jeftina / Skupa tarifa (1/0)	Temperatura (°C)	Vlažnost vazduha (%)	Brzina vjetra (km/h)	Rolling mean	Rolling std
1	3	0	1	0	1	6	81	3	135,86	4,94
1	3	1	1	0	1	6	81	2	129,35	7,44
1	3	2	1	0	1	6	76	2	118,69	13,68
1	3	3	1	0	1	6	66	13	105,24	15,40
1	3	4	1	0	1	6	66	8	92,48	10,59
1	3	5	1	0	1	6	66	5	84,09	5,98
1	3	6	1	0	1	6	61	5	80,73	2,15
1	3	7	1	0	0	5	65	6	84,02	7,72
1	3	8	1	0	0	6	61	3	95,02	15,75
1	3	9	1	0	0	7	53	6	110,21	16,64
1	3	10	1	0	0	8	57	5	123,65	10,92

1	3	11	1	0	0	10	58	3	129,71	3,58
1	3	12	1	0	0	9	66	6	130,65	2,26
1	3	13	1	0	0	10	50	3	130,49	1,99
1	3	14	1	0	0	10	40	6	131,61	2,40
1	3	15	1	0	0	10	40	1	132,61	0,71
1	3	16	1	0	0	9	46	3	131,82	1,47
1	3	17	1	0	0	8	50	8	131,44	0,97
1	3	18	1	0	0	7	53	10	136,08	8,44
1	3	19	1	0	0	6	53	8	143,44	10,34
1	3	20	1	0	0	5	57	10	150,19	3,83
1	3	21	1	0	0	6	53	10	151,47	1,62
1	3	22	1	0	0	5	57	9	149,53	2,90
1	3	23	1	0	1	4	61	6	145,22	5,21

Tabela 5.9 Rezultati implementacije sistema za prognozu potrošnje električne energije za srijedu, 28. januar 2015. godine

Čas [h]	Stvarna potrošnja električne energije [MWh]	Predviđena potrošnja električne energije [MWh]	Apsolutna greška [MWh]	Greška [%]
00:00	121,26	117,9	3,36	2,77
01:00	103,91	107,52	3,61	3,47
02:00	90,54	92,38	1,84	2,03
03:00	83	84,74	1,74	2,09
04:00	78,72	80,05	1,32	1,68
05:00	80,46	79,53	0,93	1,15
06:00	92,87	90,47	2,4	2,59
07:00	111,73	111,19	0,54	0,48
08:00	126,04	122,64	3,4	2,7
09:00	133,18	131,95	1,23	0,93
10:00	129,91	134,08	4,17	3,21
11:00	128,86	128,65	0,21	0,16
12:00	132,7	130,56	2,15	1,62
13:00	133,27	127,39	5,88	4,41
14:00	131,86	129,27	2,59	1,96
15:00	130,33	130,14	0,19	0,14
16:00	132,14	135,12	2,98	2,26
17:00	145,76	141,5	4,26	2,92
18:00	152,41	149,97	2,44	1,6
19:00	152,4	155,37	2,98	1,95
20:00	149,6	150,54	0,94	0,63
21:00	146,6	145,8	0,8	0,54
22:00	139,46	141,32	1,86	1,33
23:00	135,27	132,65	2,62	1,94

Poređenje stvarne i prognozirane vrijednosti potrošnje električne energije, računanjem apsolutne vrijednosti greške i procentualne greške modela, dato je u tabeli 5.9. Stvarna i predviđena kriva potrošnje električne energije su prikazane na slici 5.3.



Slika 5.3 Stvarna i predviđena kriva potrošnje za srijedu, 28. januar 2015. godine

Srednja apsolutna greška (MAE) između stvarnih i prognoziranih vrijednosti potrošnje električne energije za ovaj primjer iznosi  $\pm 2,26$  [MWh]. U noćnim časovima, kada je smanjena aktivnost ljudi na radnim mjestima i u domaćinstvima, potražnja za električnom energijom ima opadajući trend, sve do početka novog radnog dana – od 6 časova ujutru potrošnja električne energije očekivano raste.

Sa slike 5.3 se može uočiti da model neuralne mreže u ovom slučaju veoma dobro prognozira period vanvršnog opterećenja (od 0 do 6 časova), kada bi se u sklopu DSM programa moglo definisati niže cijene, sa ciljem podsticanja potrošača da u datom periodu koriste više električne energije. Pored toga, model dobro prognozira period nakon 19 časova, kada potrošnja za posmatrani konzum počinje da opada. Sa druge strane, vršno opterećenje je u posmatranom danu prognozirano sa procentualnom greškom koja je manja od 5%, kada bi se moglo sprovoditi strategije za smanjenje potrošnje električne energije.

### 5.5.2. Primjer – srijeda, 15. jul 2015. godine

Prognoza potrošnje električne energije za jedan dan u ljetnjem periodu je prikazana na primjeru za srijedu, 15. jul 2015. godine. Ulazni podaci su dati u tabeli 5.10, dok su stvarne vrijednosti potrošnje, prognozirane vrijednosti, apsolutne i procentualne greške, date u tabeli 5.11.

Tabela 5.10 Ulazni podaci u neuralnu mrežu za srijedu, 15. jul 2015. godine

Mjesec (1-12)	Dan u nedelji (1-7)	Sat u toku dana (0- 23)	Radni / Neradni dan (1/0)	Praznični dan (1/0)	Jeftina / Skupa tarifa (1/0)	Temperatura (°C)	Vlažnost vazduha (%)	Brzina vjетra (km/h)	Rolling mean	Rolling std
7	3	0	1	0	1	28	37	13	100,52	6,63
7	3	1	1	0	1	27	39	10	91,78	10,82
7	3	2	1	0	1	26	42	10	81,19	11,74
7	3	3	1	0	1	26	42	10	71,56	8,00

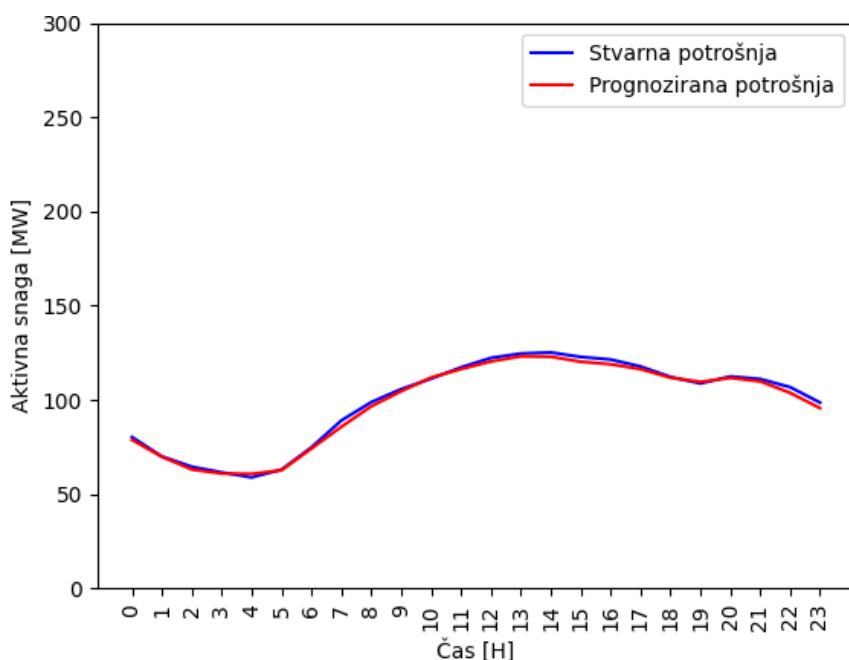
7	3	4	1	0	1	26	42	10	65,31	4,29
7	3	5	1	0	1	26	39	9	61,61	2,82
7	3	6	1	0	1	28	37	9	61,11	2,09
7	3	7	1	0	0	29	33	9	65,54	8,27
7	3	8	1	0	0	31	29	6	75,61	13,06
7	3	9	1	0	0	32	26	3	87,54	12,07
7	3	10	1	0	0	32	36	12	97,84	8,36
7	3	11	1	0	0	33	29	9	105,24	6,24
7	3	12	1	0	0	34	28	6	111,40	5,78
7	3	13	1	0	0	35	25	8	116,92	5,51
7	3	14	1	0	0	36	23	9	121,36	3,74
7	3	15	1	0	0	36	22	10	123,99	1,52
7	3	16	1	0	0	36	23	8	124,16	1,23
7	3	17	1	0	0	36	23	6	123,11	1,89
7	3	18	1	0	0	34	34	6	120,63	2,62
7	3	19	1	0	0	32	33	2	117,10	4,64
7	3	20	1	0	0	30	43	3	112,86	4,55
7	3	21	1	0	0	30	43	1	111,09	2,09
7	3	22	1	0	0	28	45	6	110,72	1,89
7	3	23	1	0	1	28	42	5	110,07	2,96

Tabela 5.11 Rezultati implementacije sistema za prognozu potrošnje električne energije za srijedu, 15. jul 2015. godine

Čas [h]	Stvarna potrošnja električne energije [MWh]	Predviđena potrošnja električne energije [MWh]	Apsolutna greška [MWh]	Greška [%]
00:00	80,24	78,76	1,48	1,85
01:00	69,96	69,75	0,2	0,29
02:00	64,48	63,04	1,44	2,23
03:00	61,49	60,86	0,63	1,02
04:00	58,85	60,7	1,86	3,15
05:00	62,98	62,62	0,36	0,57
06:00	74,79	74,16	0,63	0,84
07:00	89,05	85,7	3,35	3,76
08:00	98,79	96,58	2,21	2,24
09:00	105,69	104,57	1,12	1,06
10:00	111,25	111,83	0,58	0,53
11:00	117,25	116,33	0,92	0,79
12:00	122,26	120,36	1,9	1,55
13:00	124,56	123,1	1,46	1,17
14:00	125,14	122,9	2,25	1,8
15:00	122,78	120,24	2,54	2,07
16:00	121,41	118,9	2,51	2,06
17:00	117,71	116,3	1,4	1,19
18:00	112,18	111,76	0,42	0,37
19:00	108,68	109,52	0,83	0,77

20:00	112,42	111,64	0,78	0,69
21:00	111,06	109,81	1,25	1,12
22:00	106,75	103,7	3,04	2,85
23:00	98,56	95,63	2,93	2,97

Stvarne i predviđene krive potrošnje za posmatrani datum, prikazane su na slici 5.4. Visoke temperature, karakteristične za ljetnji period u Podgorici, izražene su tokom cijelog posmatranog dana. U periodu od 12 do 17 časova, temperatura dostiže vrijednost od  $36^{\circ}\text{C}$ , kada se i dešava vršno opterećenje u električnoj mreži. Posmatranjem prognozirane krive potrošnje na slici 5.4, moguće je uočiti period niske (od 0 do 5 časova i nakon 20 časova, kada potrošnja započinje opadajući trend) i period visoke potrošnje (od 5 do 20 časova) i na osnovu toga definisati DSM strategije za povećanje/smanjenje potrošnje električne energije. Najniža potrošnja električne energije je u 4 časa ujutru, dok se maksimalna potrošnja u mreži dešava u 14 časova. Srednja apsolutna greška (MAE) ima vrijednost od  $\pm 1,5$  [MWh].



Slika 5.4 Stvarna i predviđena kriva potrošnje za srijedu, 15. jul 2015. godine

### 5.5.3. Primjer – srijeda, 27. maj 2015. godine

Niska potrošnja električne energije je za posmatrani konzum karakteristična za mjesec maj, zbog čega će se kao primjer posmatrati jedan dan u tom mjesecu – srijeda, 27. maj 2015. godine. Ulazni podaci, na osnovu kojih se vrši prognoza potrošnje električne energije, dati su u tabeli 5.12.

Tabela 5.12 Ulazni podaci u neuralnu mrežu za srijedu, 27. maj 2015. godine

Mjesec (1-12)	Dan u nedelji (1-7)	Sat u toku dana (0-23)	Radni / Neradni dan (1/0)	Praznični dan (1/0)	Jeftina / Skupa tarifa (1/0)	Temperatura ( $^{\circ}\text{C}$ )	Vlažnost vazduha (%)	Brzina vjetra (km/h)	Rolling mean	Rolling std
5	3	0	1	0	1	16	82	6	80,62	7,50
5	3	1	1	0	1	15	82	5	71,25	11,30
5	3	2	1	0	1	14	88	0	60,76	11,18

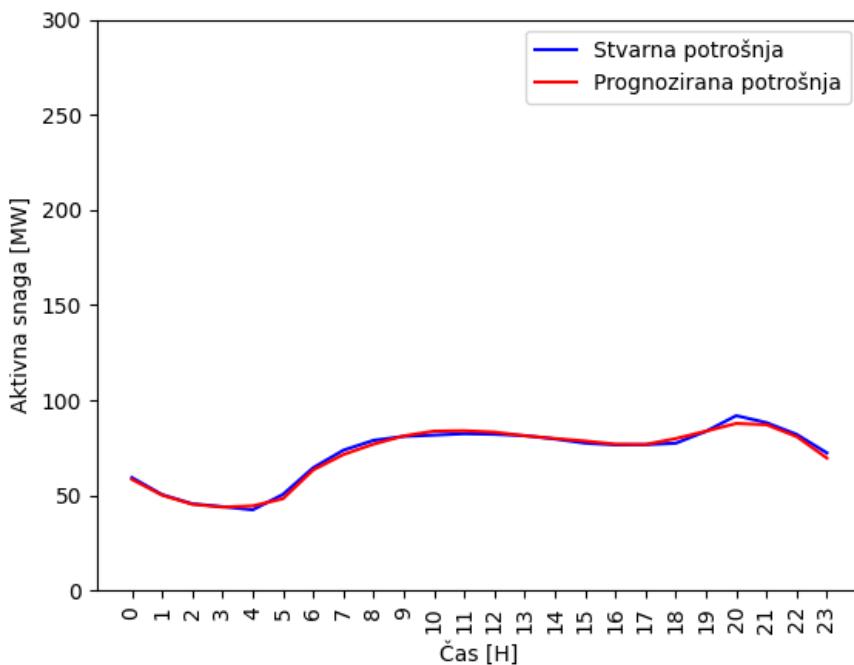
5	3	3	1	0	1	14	88	2	51,74	7,01
5	3	4	1	0	1	14	82	3	46,64	3,31
5	3	5	1	0	1	15	72	5	43,98	1,57
5	3	6	1	0	1	18	56	8	45,62	4,27
5	3	7	1	0	0	20	52	9	52,45	11,19
5	3	8	1	0	0	22	43	14	62,89	11,71
5	3	9	1	0	0	24	38	20	72,37	7,30
5	3	10	1	0	0	24	36	21	77,86	3,74
5	3	11	1	0	0	24	36	21	80,51	1,44
5	3	12	1	0	0	25	34	21	81,67	0,69
5	3	13	1	0	0	24	36	20	82,03	0,35
5	3	14	1	0	0	24	36	20	81,93	0,51
5	3	15	1	0	0	23	36	26	81,02	1,27
5	3	16	1	0	0	22	38	23	79,47	1,97
5	3	17	1	0	0	21	38	22	77,86	1,59
5	3	18	1	0	0	19	43	21	76,86	0,49
5	3	19	1	0	0	18	45	20	76,85	0,47
5	3	20	1	0	0	18	42	17	79,22	3,85
5	3	21	1	0	0	18	40	16	84,30	7,26
5	3	22	1	0	0	17	42	14	87,90	4,12
5	3	23	1	0	1	17	42	14	87,36	4,99

Rezultati implementacije sistema za prognozu potrošnje električne energije su prikazani u tabeli 5.13, dok je grafički prikaz stvarne i predviđene krive potrošnje dat na slici 5.5. Srednja apsolutna greška (MAE) za ovaj dan iznosi  $\pm 1,24$  [MWh].

Tabela 5.13 Rezultati implementacije sistema za prognozu potrošnje električne energije za srijedu, 27. maj 2015. godine

Čas [h]	Stvarna potrošnja električne energije [MWh]	Predviđena potrošnja električne energije [MWh]	Apsolutna greška [MWh]	Greška [%]
00:00	59,34	58,38	0,96	1,61
01:00	50,36	50,09	0,27	0,54
02:00	45,52	45,31	0,22	0,47
03:00	44,03	43,83	0,2	0,45
04:00	42,38	44,45	2,07	4,89
05:00	50,46	48,19	2,27	4,5
06:00	64,5	63,31	1,19	1,84
07:00	73,71	71,44	2,28	3,09
08:00	78,9	76,9	2	2,53
09:00	80,98	81,23	0,25	0,31
10:00	81,66	83,74	2,08	2,54
11:00	82,36	83,93	1,58	1,92
12:00	82,08	83,21	1,14	1,39
13:00	81,37	81,28	0,09	0,11
14:00	79,61	79,86	0,24	0,31
15:00	77,43	78,53	1,1	1,42

16:00	76,53	76,88	0,35	0,46
17:00	76,64	76,73	0,09	0,12
18:00	77,39	79,83	2,44	3,16
19:00	83,64	83,72	0,08	0,1
20:00	91,87	87,77	4,1	4,46
21:00	88,2	87,12	1,08	1,23
22:00	82	80,87	1,14	1,39
23:00	72,29	69,57	2,72	3,76



Slika 5.5 Stvarna i predviđena kriva potrošnje za srijedu, 27. maj 2015. godine

Model neuralne mreže veoma uspješno prognozira periode vanvršnjog i vršnjog opterećenja po satima, na osnovu kojih je moguće formulisati strategije za modifikaciju opterećenja u okviru DSM programa – u periodu od 0 do 6 časova opterećenje opada, kao i nakon 20 časova, kada se dešava maksimalno opterećenje u električnoj mreži. Međutim, uvažavanje činjenice da je usljud povoljnih meteoroloških uslova u ovom periodu, za posmatrani konzum karakteristična niska potražnja za električnom energijom, sprječava sprovođenje strategija koje ne donose benefite elektroenergetskom sistemu u cijelini. U ovom slučaju, DSM strategije za smanjenje opterećenja mogu nepotrebno demotivisati potrošače da koriste električnu energiju u periodima kada potrošnja električne energije nema visoke vrijednosti.

#### 5.5.4. Primjer – srijeda, 7. oktobar 2015. godine

Slično primjerima na kojima je sistem za prognozu potrošnje električne energije testiran u ljetnjoj i zemskoj sezoni, posmatra se radni dan sredinom nedelje za kišni jesenji period u 2015. godini – srijeda, 7. oktobar. U tabeli 5.14 su prikazani ulazni podaci nad kojima je model neuralne mreže testiran u ovom slučaju, dok su rezultati implementacije sistema dati u tabeli 5.15. Srednja apsolutna greška (MAE) u ovom primjeru ima vrijednost  $\pm 1,15$  [MWh].

Tabela 5.14 Ulagani podaci u neuralnu mrežu za srijedu, 07. oktobar 2015. godine

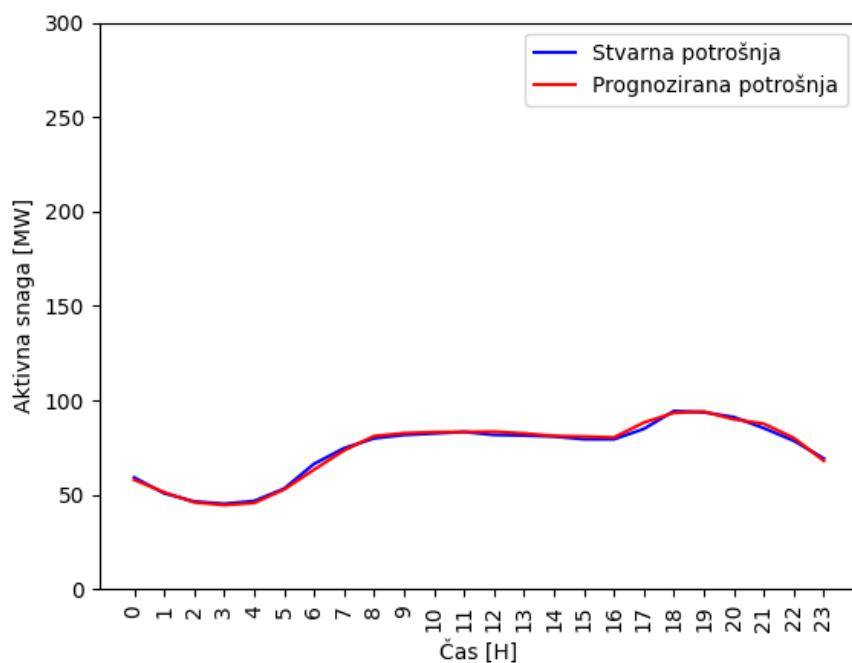
Mjesec (1-12)	Dan u nedelji (1-7)	Sat u toku dana (0- 23)	Radni / Neradni dan (1/0)	Praznični dan (1/0)	Jefrina / Skupa tarifa (1/0)	Temperatura (°C)	Vlažnost vazduha (%)	Brzina vjetra (km/h)	<i>Rolling mean</i>	<i>Rolling std</i>
10	3	0	1	0	1	19	83	5	77,04	6,99
10	3	1	1	0	1	18	88	5	68,85	9,33
10	3	2	1	0	1	17	94	9	59,86	9,53
10	3	3	1	0	1	17	94	8	52,08	6,46
10	3	4	1	0	1	17	94	7	47,44	2,92
10	3	5	1	0	1	17	94	7	46,06	0,78
10	3	6	1	0	1	17	94	2	48,33	4,28
10	3	7	1	0	0	17	94	0	55,38	10,03
10	3	8	1	0	0	17	100	2	64,71	10,79
10	3	9	1	0	0	19	83	1	73,58	6,81
10	3	10	1	0	0	19	83	3	78,69	3,65
10	3	11	1	0	0	21	64	1	81,29	1,33
10	3	12	1	0	0	22	60	2	82,44	0,81
10	3	13	1	0	0	24	57	2	82,45	0,80
10	3	14	1	0	0	23	57	2	82,10	1,02
10	3	15	1	0	0	23	61	2	81,28	0,43
10	3	16	1	0	0	22	64	6	80,52	1,02
10	3	17	1	0	0	22	64	2	79,85	0,84
10	3	18	1	0	0	21	73	2	81,20	3,16
10	3	19	1	0	0	20	78	2	86,16	7,55
10	3	20	1	0	0	21	73	3	90,92	5,27
10	3	21	1	0	0	20	83	3	93,00	1,69
10	3	22	1	0	0	18	88	12	89,98	4,30
10	3	23	1	0	1	17	94	3	84,95	6,27

Tabela 5.15 Rezultati implementacije sistema za prognozu potrošnje električne energije za srijedu, 07. oktobar 2015. godine

Čas [h]	Stvarna potrošnja električne energije [MWh]	Predviđena potrošnja električne energije [MWh]	Apsolutna greška [MWh]	Greška [%]
00:00	59,1	57,89	1,21	2,05
01:00	50,74	51,27	0,54	1,06
02:00	46,4	45,97	0,42	0,91
03:00	45,17	44,49	0,68	1,51
04:00	46,62	45,6	1,02	2,2
05:00	53,2	52,74	0,46	0,86
06:00	66,32	63,26	3,06	4,62
07:00	74,6	73,41	1,19	1,6
08:00	79,83	81,05	1,23	1,54
09:00	81,64	82,55	0,91	1,12

10:00	82,41	83,12	0,71	0,86
11:00	83,26	83,24	0,02	0,02
12:00	81,67	83,37	1,7	2,08
13:00	81,36	82,44	1,08	1,33
14:00	80,82	81,11	0,29	0,36
15:00	79,39	80,79	1,4	1,76
16:00	79,35	80,31	0,96	1,21
17:00	84,85	88,19	3,34	3,94
18:00	94,28	93,35	0,94	0,99
19:00	93,62	94,01	0,39	0,41
20:00	91,08	89,92	1,16	1,28
21:00	85,23	87,57	2,34	2,74
22:00	78,55	80,04	1,48	1,89
23:00	69,17	67,95	1,22	1,76

Stvarna i predviđena kriva potrošnje električne energije su prikazane na slici 5.6.



Slika 5.6 Stvarna i predviđena kriva potrošnje za srijedu, 07. oktobar 2015. godine

Kao što je prikazano u tabeli 5.14, najizraženiji meteorološki faktor za posmatrani dan je vlažnost vazduha, koja je prisutna tokom cijelog dana. Stvarna i predviđena kriva potrošnje električne energije su prikazane na slici 5.6. Model neuralne mreže tokom cijelog dana precizno prognozira oblik krive potrošnje. Korišćenjem DSM strategija, krajnji korisnici se mogu motivisati da izbjegavaju upotrebu električnih aparata nižeg prioriteta u periodu od 16 do 20 časova, posebno u 18 časova kada se dešava maksimalna potrošnja za posmatrani konzum. Sa druge strane, u periodu od 0 do 5 časova, od 12 do 16 časova i nakon 20 časova, potrošnja ima opadajući trend, koji model neuralne mreže prognozira sa visokom tačnošću.

### 5.5.5. Primjer – nedjelja, 27. decembar 2015. godine

Sistem za prognozu potrošnje električne energije je testiran nad podacima iz tabele 5.16, koji se odnose na neradni dan (viked) u 2015. godini, pri čemu se radi o prazniku (katolički Božić) – nedjelja, 27. decembar. Rezultati implementacije sistema za prognozu potrošnje električne energije za ovaj dan su prikazani u tabeli 5.17.

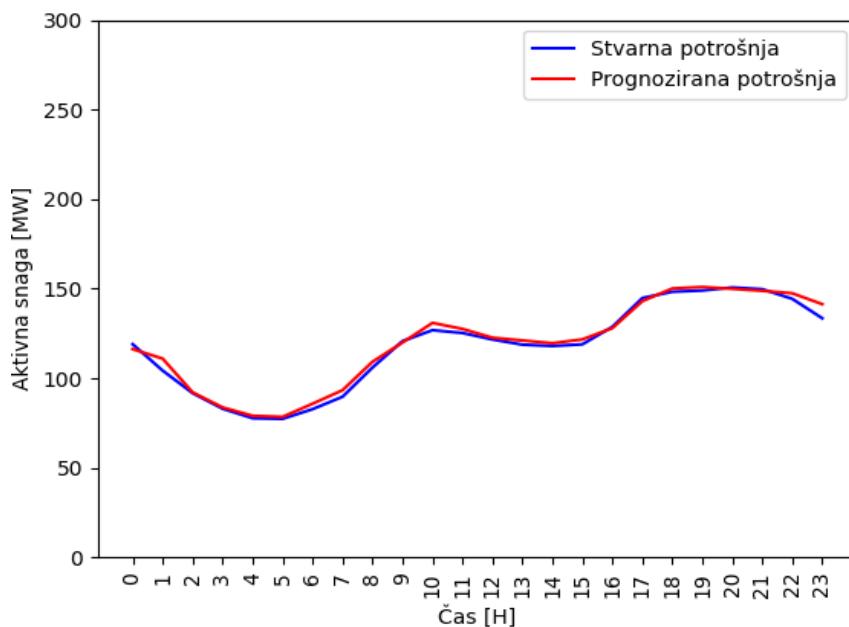
Tabela 5.16 Ulazni podaci u neuralnu mrežu za nedjelju, 27. decembar 2015. godine

Mjesec (1-12)	Dan u nedelji (1-7)	Sat u toku dana (0- 23)	Radni / Neradni dan (1/0)	Praznični dan (1/0)	Jeftina / Skupa tarifa (1/0)	Temperatura (°C)	Vlažnost vazduha (%)	Brzina vjetra (km/h)	<i>Rolling mean</i>	<i>Rolling std</i>
12	7	0	0	1	1	4	81	2	130,53	5,39
12	7	1	0	1	1	3	87	0	124,83	5,61
12	7	2	0	1	1	3	81	1	116,19	10,82
12	7	3	0	1	1	2	87	3	104,96	13,68
12	7	4	0	1	1	2	87	3	92,95	10,71
12	7	5	0	1	1	2	87	1	84,08	7,07
12	7	6	0	1	1	2	87	2	79,29	3,17
12	7	7	0	1	1	1	87	2	79,21	3,03
12	7	8	0	1	1	2	81	3	83,21	6,19
12	7	9	0	1	1	5	81	0	92,76	11,93
12	7	10	0	1	1	9	66	1	105,42	15,53
12	7	11	0	1	1	12	54	2	117,81	10,72
12	7	12	0	1	1	14	48	1	124,24	3,18
12	7	13	0	1	1	15	42	3	124,55	2,67
12	7	14	0	1	1	16	36	2	121,86	3,27
12	7	15	0	1	1	16	39	1	119,43	1,92
12	7	16	0	1	1	15	45	1	118,53	0,51
12	7	17	0	1	1	8	66	2	121,85	5,93
12	7	18	0	1	1	7	71	2	130,78	13,05
12	7	19	0	1	1	6	76	3	140,57	10,44
12	7	20	0	1	1	4	81	2	147,33	2,25
12	7	21	0	1	1	4	81	3	149,30	1,24
12	7	22	0	1	1	5	76	5	149,78	0,86
12	7	23	0	1	1	4	81	3	148,22	3,43

Tabela 5.17 Rezultati implementacije sistema za prognozu potrošnje električne energije za nedjelju, 27. decembar 2015. godine

Čas [h]	Stvarna potrošnja električne energije [MWh]	Predviđena potrošnja električne energije [MWh]	Apsolutna greška [MWh]	Greška [%]
00:00	118,99	116,21	2,77	2,33
01:00	104,25	110,94	6,69	6,42
02:00	91,65	92,09	0,44	0,48
03:00	82,95	83,68	0,74	0,89
04:00	77,64	79,00	1,36	1,75
05:00	77,29	78,41	1,12	1,45
06:00	82,71	85,74	3,04	3,67
07:00	89,63	93,30	3,67	4,10
08:00	105,95	109,19	3,24	3,06
09:00	120,68	119,90	0,78	0,65

10:00	126,81	130,88	4,07	3,21
11:00	125,24	127,53	2,29	1,82
12:00	121,60	122,61	1,01	0,83
13:00	118,72	121,07	2,34	1,97
14:00	117,96	119,51	1,55	1,32
15:00	118,91	121,68	2,76	2,33
16:00	128,68	127,94	0,74	0,57
17:00	144,76	143,01	1,75	1,21
18:00	148,26	150,11	1,85	1,25
19:00	148,96	150,93	1,97	1,33
20:00	150,67	149,91	0,76	0,51
21:00	149,70	148,78	0,92	0,61
22:00	144,30	147,42	3,12	2,16
23:00	133,46	141,33	7,86	5,89



Slika 5.7 Stvarna i predvidena kriva potrošnje za nedjelju, 27. decembar 2015. godine

Budući da je u pitanju neradni dan (vikend), povećana aktivnost ljudi i prisustvo jeftine tarife tokom cijelog dana, rezultira visokom potrošnjom električne energije. Srednja apsolutna greška (MAE) između stvarnih i prognoziranih vrijednosti iznosi  $\pm 2,37$  [MWh]. Na slici 5.7 su prikazane stvarna i prognozirana kriva potrošnje električne energije. Model neuralne mreže za prognozu potrošnje električne energije u periodu od 0 do 5 časova ujutru, od 12 do 15 časova u toku dana i nakon 21 čas uveče, prognozira smanjenje potrošnje električne energije, kao što je to i slučaj. U pomenutim vanvršnim periodima, model nakon 0 časova i nakon 21 časa na samom početku prognozira blaži pad potrošnje električne energije, nego što je to u stvarnosti (tabela 5.17). Međutun, nakon toga se performanse modela poboljšavaju i prognozirana kriva potrošnje precizno prati stvarnu krivu potrošnje u posmatranom danu. Sa druge strane, model maksimalnu potrošnju električne energije u prvom dijelu dana (10 časova – prvi maksimum) i u drugom dijelu dana (20 časova – drugi maksimum) prognozira sa greškom koja je manja od 4% i 1%, respektivno. Takvi rezultati opravdavaju definisanje DSM strategija za smanjenje potrošnje električne energije u vršnom periodu, koje se zasnivaju na prognozi potrošnje električne energije korišćenjem predloženog algoritma.

## 5.6. Poređenje predložene metode sa ARIMA statističkom metodom za prognozu potrošnje električne energije

Sa ciljem poređenja predložene metode u ovom radu sa statističkom metodom za prognozu potrošnje električne energije, posmatra se kratkoročna prognoza potrošnje električne energije u 48-časovnom periodu korišćenjem ARIMA metode (potpoglavlje 3.2.1.2) [143]. Za procjenu učinka metode koja se koristi za prognozu potrošnje električne energije, indikativno je posmatrati minimalnu i maksimalnu vrijednost apsolutne procentualne greške (eng. *Absolute Percentage Error-APE*), medijane apsolutnih procentualnih grešaka i srednju vrijednost apsolutne procentualne greške (eng. *Mean Absolute Percentage Error-MAPE*) [144]:

$$APE = \frac{|A - F|}{A} \cdot 100 (\%) \quad (5.11)$$

$$MAPE = \frac{1}{N} \cdot \sum_{i=1}^N \frac{|A_i - F_i|}{F_i} \cdot 100 (\%) \quad (5.12)$$

U izrazima (5.11) i (5.12),  $A$  (eng. *Actual*) je stvarna potrošnja električne energije,  $F$  (eng. *Forecast*) je prognozirana vrijednost, koja se dobija na izlazu iz algoritma za prognozu potrošnje električne energije, dok je  $N$  ukupan broj sati za koje se vrši prognoza.

Prikazani primjer iz literature je prvenstveno izabran na osnovu veličine ulaznog skupa podataka (period od pet godina), budući da ona ima veliki uticaj na dobijanje pouzdanih rezultata korišćenjem predložene metode. Međutim, pored podataka o godini, mjesecu, danu, satu, tipu dana i meteorološkim uslovima (temperatura, vlažnost vazduha i brzina vjetra), ulazni skup ARIMA modela dodatno uzima u obzir sljedeće meteorološke faktore: minimalna, srednja i maksimalna temperatura, temperatura subjektivnog osjećaja, pritisak i tačka rosišta [143]. Sa druge strane, ulazni skup podataka predložene metode je, pored „osnovnih“ podataka, proširen sa vrijednostima prosječne potrošnje i standardne devijacije za prethodna tri časa. U tabeli 5.18 su prikazane vrijednosti minimalne i maksimalne apsolutne procentualne greške (MinAPE i MaxAPE), medijane apsolutnih procentualnih grešaka (MdAPE) i srednje apsolutne procentualne greške (MAPE) u slučaju prognoze potrošnje električne energije u 48-časovnom periodu korišćenjem predložene metode i ARIMA statističke metode.

Tabela 5.18 Poređenje predložene metode sa ARIMA statističkom metodom za kratkoročnu prognozu potrošnje električne energije

Metoda	MinAPE (%)	MaxAPE (%)	MdAPE (%)	MAPE (%)
Predložena metoda	0,203553	5,2749277	1,476091	1,795466
ARIMA	0,000318	47,61356	3,499393	5,071455

U tabeli 5.18 se uočava da se korišćenjem predložene metode za prognozu potrošnje električne energije (Prilog – Tabela sa rezultatima implementacije sistema za prognozu potrošnje električne energije u 48-časovnom periodu 01.08. – 03.08.2015. godine) dobija manja vrijednost srednje apsolutne procentualne greške, u odnosu na ARIMA statističku metodu. Pored toga, prednost predložene metode je primjetna i u slučaju proračuna maksimalne apsolutne procentualne greške (MaxAPE) i medijane apsolutnih procentualnih grešaka (MdAPE). Sa druge strane, korišćenjem ARIMA metode se dobija minimalna vrijednost APE u 48-časovnom periodu (0,000318 %). Međutim, značajno manje vrijednosti ostalih grešaka odsupanja, čine predloženu metodu pouzdanijim algoritmom za prognozu potrošnje električne energije.

## 6. ZAKLJUČAK

U ovom radu je predstavljena struktura, funkcija i značaj upravljanja na strani potražnje, koje se u najvećoj mjeri oslanja na automatizaciju svih djelova mrežne infrastrukture i razvoj novih informacionih tehnologija. Fokus ovog rada je razvijanje algoritma za prognozu potrošnje električne energije, sa ciljem upoznavanja obrasca korišćenja energije od strane krajnjih potrošača, u sklopu programa upravljanja na strani potražnje. Pored toga, dat je pregled metoda zasnovanih na statistici i metoda zasnovanih na vještackoj inteligenciji, koje se u literaturi koriste za prognozu potrošnje električne energije. Ovaj rad predlaže korišćenje potpuno povezane višeslojne neuralne mreže za prognozu potrošnje električne energije.

Prikupljen je skup podataka o istorijskoj potrošnji električne energije i faktorima od dominantnog uticaja na potrošnju, sa satnom rezolucijom, koji se odnose na period od 2011. do 2015. godine. Ulazni skup podataka je podijeljen na podatke za treniranje, koji čine najveći dio (od 2011. do 2013. godine), podatke za validaciju (2014. godina) i podatke za testiranje (2015. godina) modela neuralne mreže. Prikazana je promjena tačnosti modela u zavisnosti od promjene strukture neuralne mreže (za različite brojeve slojeva i neurona u neuralnoj mreži i različite parametre modela). Najbolji rezultati su postignuti za strukturu neuralne mreže koju čine dva skrivena sloja, sa 150 i 100 neurona (respektivno) i parametre modela koji imaju vrijednosti *Dropout* parametar regularizacije = 0.1 i *Batch Size* = 40. Pored toga, poseban dio rada je posvećen dodavanju podataka o srednjoj vrijednosti i standardnoj devijaciji potrošnje električne energije u prethodnih  $k$  sati u ulaznom skupu, koje se pokazalo kao dobar izbor za poboljšavanje performansi modela za prognozu potrošnje električne energije. Najbolji rezultati su postignuti u slučaju  $k=3$ , odnosno uvažavanjem srednje vrijednosti i standardne devijacije potrošnje električne energije u prethodna tri časa.

Za vrijeme izvršavanja koje je manje od jednog minuta, postignuta srednja absolutna procentualna vrijednost greške (MAPE) u prognozi potrošnje električne energije je 2,32%, dok su minimalna i maksimalna absolutna procentualna odstupanja (APE) u jednom času, nad svim podacima za testiranje (8760 podataka)  $6,88 \cdot 10^{-5}$  i 47,6 %, respektivno. Iako se očekuje da će se opseg vrijednost greške nalaziti u blizini  $\pm 5\%$ , nagle promjene potrošnje električne energije, izazvane nekarakterističnim i neočekivanim pojavama u električnoj mreži (ne primjer isključenje/uključenje „velikog“ potrošača, neraspoloživost elemenata i/ili *Blackout* elektroenergetskog sistema), mogu rezultirati izraženim vrijednostima greške u prognozi potrošnje električne energije. Takve situacije u okviru programa upravljanja na strani potražnje izazivaju posljedice:

- Manjom procjenom potrošnje električne energije se može stvoriti potreba za dodatnim smanjenjem potrošnje ili kupovinom električne energije na spot tržištu, u realnom vremenu
- Veća procjena potrošnje električne energije, posebno u periodu vršnog opterećenja, može rezultirati nepravilnim definisanjem cijena za električnu energiju kroz realizaciju programa upravljanja na strani potražnje

Pored prikaza rezultata prognoze potrošnje električne energije na karakterističnim primjerima (dan u zimskom periodu, dan u ljetnjem periodu, dan sa niskom potrošnjom električne energije, dan u jesenjem periodu, vikend), izvršena je komparacija rezultata predložene metode sa rezultatima kratkoročne prognoze potrošnje električne energije korišćenjem ARIMA statističke metode.

Za kratkoročnu prognozu potrošnje električne energije u 48-časovnom periodu, ARIMA metoda pokazuje blagu prednost u pogledu minimalne absolutne procentualne greške (0,000318 %), u odnosu na predloženu metodu (0,203553 %). Sa druge strane, korišćenjem predložene metode se postižu značajno manje vrijednosti maksimalne absolute procentualne greške (5,2749277 %), medijane absolutnih procentualnih grešaka (1,476091 %) i srednje absolutne procentualne greške (1,795466 %), u odnosu na ARIMA metodu (47,61356 % ; 3,499393 % ; 5,071455 % ; respektivno).

Na osnovu analize dobijenih rezultata, može se zaključiti sljedeće:

- Potpuno povezana višeslojna neuralna mreža je efikasan alat za prognozu potrošnje električne energije
- Izbor strukture i parametara modela neuralne mreže ima veliki uticaj na performanse za prognozu potrošnje električne energije
- Dodavanjem prosječne vrijednosti i standardne devijacije potrošnje električne energije prethodna tri časa u ulaznom skupu, smanjuje se zavisnost modela od istorijskih podataka i povećava tačnost modela
- Povećavanjem broja ulaznih podataka mogu se postići bolji rezultati prognoze potrošnje električne energije
- Korišćenjem potpuno povezane višeslojne neuralne mreže, mogu se postići pouzdaniji rezultati kratkoročne prognoze potrošnje električne energije, u odnosu na statističke metode
- Pouzdaniji rezultati prognoze potrošnje električne energije se postižu za kratkoročni period, s obzirom na manju neizvjesnost i pouzdanost ulaznih podataka

Iako algoritam neuralne mreže za prognozu potrošnje električne energije ima mnoge prednosti, potrebno je napomenuti i ograničenja u primjeni predloženog modela:

- Validnost rezultata dobijenih korišćenjem ove metode u najvećoj mjeri zavisi od kvaliteta i dostupnosti podataka koji se dovode na ulaz neuralne mreže, prvenstveno onih koji se odnose na meteorološke faktore
- Kao i svaka metoda zasnovana na podacima, potpuno povezana višeslojna neuralna mreža ne radi dobro izvan svog opsega obuke, odnosno izvan okvira određenog skupom podataka koji se koristi za treniranje neuralne mreže. Ukoliko se za treniranje neuralne mreže koriste stariji podaci, koji više nijesu relevantni zbog promjena u potrošnji električne energije, nastalih uslijed različitih faktora (klimatskih promjena, porasta cijene za električnu energiju, porasta broja stanovnika, instalacije novih uređaja), ova metoda može pokazati veoma loše performanse
- Neadekvatan izbor strukture i parametara modela u fazi razvoja algoritma neuralne mreže može rezultirati lošim performansama modela i dugim trajanjem procesa prognoziranja. Automatizovane metode izbora strukture su tek u fazi razvoja, pa se većina modela neuralne mreže formira ručno
- Modeli neuralnih mreža su sami po sebi „crna kutija“ čiji unutrašnji djelovi nijesu poznati. Iako mogu da postignu rezultate prognoziranja zadovoljavajuće tačnosti, nedostaje im razumijevanje osnovnih parametara potrošnje električne energije i njene promjene tokom vremena

Budući pravac istraživanja rada bi se mogao odnositi na proširenje postojećeg skupa ulaznih podataka, obuhvatanjem što većeg broja faktora koji imaju uticaj na tačnost prognoze buduće potrošnje električne energije: energetska kriza i porast cijena za električnu energiju, integracija distribuiranih izvora energije i električnih vozila u elektrodistributivnom sistemu, klimatske promjene, kao i uticaj pandemije COVID-19. Pored toga, bolji rezultati bi se mogli postići proširivanjem skupa ulaznih podataka sa dodatnim meteorološkim faktorima (pritisak, minimalna / srednja / maksimalna temperatura, subjektivni osjećaj, dnevni intenzitet sunčevog zračenja, rosište), kao i vremenskim faktorima, poput uvažavanja noćnih i dnevnih sati i početka / sredine / kraja mjeseca.

Drugi pavac istraživanja bi mogao biti hibridizacija predložene metode sa drugim metodama za prognozu potrošnje električne energije, koje su zasnovane na vještačkoj inteligenciji i/ili statistici, sa ciljem postizanja veće tačnosti i široke primjene takvog modela za prognozu buduće potrošnje električne energije.

## LITERATURA

- [1] S. K. Rathor, D. Saxena, „Energy Management System for Smart Grid: an overview and key issues,“ *International Journal of Energy Research*, pp. 1 – 41, 2020.
- [2] „Smart Grid: What Does Smart Grid Mean?“ *Technopedia*, 2017.
- [3] P. Balakumar, S. Sathiya, „Demand Side Management in Smart Grid using Load Shifting Techique,“ *IEEE International Conference on Electrical, Instrumentation and Communication Engineering*, 2017.
- [4] A. A. Sallam, O. P. Malik, „Electric Distribution Systems - Demand Side Management and Energy Efficiency,“ *Wiley – IEEE Press*, pp. 429 - 463, 2019.
- [5] W. Saad, A. L. Glass, N. B. Mandayam, H. V. Poor, „Toward a Consumer – Centric Grid: A Behavioral Perspective,“ *Proceedings of the IEEE*, pp. 865 – 882, 2016.
- [6] P. Palensky, D. Dietrich, „Demand Side Management: Demand Response, Intelligent Energy Systems and Smart Loads,“ *IEEE Transactions on Industrial Informatics*, pp. 381 – 388, 2011.
- [7] S. Panda, S. Mohanty, P. K. Rout, B. K. Sahu, M. Bajaj, H. M. Zawbaa, S. Kamel, „Residential Demand Side Management model, optimization and future perspective: A review,“ *Energy Reports*, pp. 3727-3766, 2022.
- [8] S. Mohagheghi, N. Raji, „Managing Industrial Energy Intelligently: Demand Response,“ *IEEE Industry Applications Magazine*, pp. 53 - 62, 2013.
- [9] B. Bratrud, „Energy Demand-Side Management Benefits Costumers,“ *Citizenus Utility Board*, 2017.
- [10] „Reports on Demand Response and Advanced Metering,“ *FERC*, 2022.
- [11] A. Losi, P. Mancarella, A. Vicino, „Demand Response in Smart Grids,“ *Integration of Demand Response Into the Electricity Chain*, pp. 1 – 10, 2015.
- [12] I. Antonopoulos, V. Robu, B. Couraud, D. Kirli, S. Norbu, A. Kiprakis, D. Flynn, S. E. Gonzalez, S. Wattam, „Artificial Intelligence and Machine Learning Approaches to Energy Demand – Side Response: A systematic review,“ *Renewable and Sustainable Energy Reviews*, 2020.
- [13] C. Chen, J. Wang, S. Kishore, „A Distributed Direct Load Control Approach for Large-Scale Residential Demand Response,“ *IEEE Transactions on Power Systems*, pp. 2219 – 2228, 2014.
- [14] „Interruptible rate schedule,“ *Imperial Irrigation District*, 2010.
- [15] M. H. Imani, K. Yousefpour, M. T. Andani, M. J. Ghadi, „Effect of Changes in Incentives and Penalties on Interruptible/Curtailable Demand Response Prvisioogram in Microgrid Operation,“ *IEEE Texas Power of Energy Conference*, 2019.
- [16] S. Devi, N. Ayswarya, „Artificial Neural Network Approach for Load Forecasting in Demand Side Management,“ *International Journal of Advanced Research in Electrical, Electronics nad Instrumentation Engineering*, pp. 581 – 586, 2015.
- [17] T. Edison, „Load Duration Curve in Power Station,“ *Study Electrical*
- [18] J. Radović, „Optimizacija distributivnog sistema,“ *Elektrotehnički fakultet, Univerzitet Crne Gore*

- [19] O. Ayan, B. Turkay, „Smart Termostats for Home Automation Systems and Energy Saving for Smart Termostats,“ *6<sup>th</sup> International Conference on Control Engineering & Information Technology*, 2018.
- [20] H. Morsali, S. M. Shekarabi, K. Ardekani, H. Khayami, „Smart Plugs for Building Energy Management Systems,“ *2<sup>nd</sup> Iranian Conference on Smart Grids*, 2012.
- [21] M. Čanović, „Virtuelni instrument za kvalitativnu analizu PLC komunikacije u AMM sistemu, Specijalistički rad,“ *Elektrotehnički fakultet, Univerzitet Crne Gore*
- [22] J. Radović, „Elektrodistributivni sistemi,“ *Elektrotehnički fakultet, Univerzitet Crne Gore*
- [23] H. A. Attia, „Mathematical Formulation of the Demand Side Management (DSM) Problem and its Optimal Solution,“ *14<sup>th</sup> International Middle East Power Systems Conference*, 2010.
- [24] „Tržište električne energije i deregulacija“, *Elektrotehnički fakultet u Beogradu*
- [25] R. Usman, P. Mirzania, S. W. Alnaser, P. Hart, C. Long, „Systematic review of demand-side management strategies in power systems of developed and developing countries,“ *Energies*, 2022.
- [26] V. J. Martinez, H. Rudnick, „Design of Demand Response programs in emerging countries,“ *2012 IEEE International Conference on Power System Technology*, pp. 1 – 6, 2012.
- [27] „United States Demand Response Management Systems (DRMS) Market,“ *Mordor Intelligence*, 2020.
- [28] S. Ozkan, „An intro to locational marginal pricing,“ *ENVERUS*, 2022.
- [29] J. Ambrose, „How renewable energy could power Britain’s economic recovery,“ *The Guardian*, 2020.
- [30] „Wind generated a record amount of electricity in 2022,“ *British Broadcasting Corporation (BBC)*, 2023.
- [31] E. T. Lau, Q. Yang, L. Stokes, G. Taylor, A. B. Forbes, P. Clarkson, P. S. Wright, V. N. Livina, „Carbon savings in the UK demand side response programmes,“ *Applied Energy*, pp. 478–489, 2015.
- [32] J. Palmer, I. Cooper, „United Kingdom housing energy fact file 2013,“ *Applied Energy*, pp. 478–489, 2013.
- [33] „Demand side response,“ *Centrica Business Solutions*, 2020.
- [34] „Energy consumption in the UK 2021,“ *GOV.UK: Department for Business, Energy & Industrial Strategy*, 2021.
- [35] „Octopus energy: UK green energy suppliers with a difference,“ *Deege solar*, 2023.
- [36] „What is Octopus Go, and how do I join?“ *OctopusEnergy*, dostupno online: <https://octopus.energy/help-and-faqs/articles/what-is-octopus-go-and-how-do-i-join/> (datum pristupa: 02.10.2022)
- [37] „An introduction to Australia’s National Electricity Market,“ *Aemo-Mo*, 2010.
- [38] „AEMC rules on demand response wholesale mechanism,“ *ArenaWire*, 2019.
- [39] „AEMO and ARENA demand response trial to provide 200 megawatts of emergency reserves for extreme peaks,“ *ArenaWire*, 2017.
- [40] J. Deign, „As Renewables Surge, Australia Ponders Options for Demand Response Market,“ *Greentech Media*, 2020.

- [41] H. Khalid, F. R. Amin, C. Chen, „Comparing the status and challenges of demand-side management (DSM) implementation in Asia-Pacific region: a case study of China’s power sector,“ *Energy Procedia*, pp. 101-108, 2018.
- [42] D. C. Montgomery, L. A. Johnson, J. S. Gardiner, „Forecasting and Time Series Analysis Subsequent Edition,“ *McGraw-Hill*, 1990.
- [43] J. Radović, „Optimizacija elektroodistributivnih sistema,“ *Elektrotehnički fakultet, Univerzitet Crne Gore*
- [44] A. Finkel, K. Moses, C. Munro, T. Effeney, M. O’Kane, „Independent review into the future security of the national electricity market: blueprint for the future,“ *Commonwealth of Australia*, 2017.
- [45] „Expansion Planning for Electrical Generating Systems: a guidebook,“ *International Atomic Energy Agency, Vienna*, 1984.
- [46] F. Elkami, N. A. Shikhah, „Electricity Demand Forecasting: an Essential Tool for Power System Planning, Operation and Control,“ *International Journal of Productivity Management and Assessment Technologies*, pp. 1 – 19, 2014.
- [47] N. Phuangpornpitak, W. Prommee, „A Study of Load Forecasting Models in Electric Power System Operation and Planning,“ *GMSARN International Journal*, pp. 19 – 24, 2016.
- [48] N. Amjady, „Short-Term Hourly Load Forecasting using Time Series Modeling with Peak Load Estimation Capability,“ *IEEE Transactions on Power Systems*, pp. 498 – 505, 2001.
- [49] S. A. Soliman, R. Alammari, M. El-Hawary, H. K. Termraz, „Long-Term Electric Peak Load Forecasting for Power System Planning: A comparative study,“ *Arabian Journal for Science and Engineering*, 2004.
- [50] B. Xue, J. Geng, „Dynamic transverse correction method of middle and long term energy forecasting based on statistic of forecasting errors,“ *10<sup>th</sup> International Power & Energy Conference*, 2012.
- [51] M. U. Fahad, N. Arbab, „Factor Affecting Short Term Load Forecasting,“ *Journal of Clean Energy Technologies*, 2014.
- [52] S. Khatoon, Ibraheem, A. Kr. Singh, Priti, „Effects of various factors on electric load forecasting: An overview,“ *6<sup>th</sup> IEEE Power India International Conference*, 2014.
- [53] M. Bartos, M. Chester, „Impacts of climate change on electric power supply in the Western United States,“ *Research Gate: Nature Climate Change* 5(8), 2015.
- [54] M. V. Vilet, J. R. Yearsley, F. Ludwig, S. Vogege, „Vulnerability of US and European Electricity Supply to Climate Change,“ *Research Gate: Nature Climate Change* 2(9), pp. 676 – 681, 2012.
- [55] J. Sathaye, L. Dale, P. Larsen, G. Fitts, K. Koy, S. Lewis, A. Lucena, „Estimating risk to California energy infrastructure from projected climate change,“ *Environmental Energy Technologies Division*, 2011.
- [56] J. A. Dirks, W. J. Gorrissen, J. Hathaway, D. Skorski, „Impacts of climate change on energy consumption and peak demand in buildings: A detailed regional approach,“ *Research Gate: Energy* 79(2), 2015.

- [57] S. Dubey, J. N. Sarvaiya, B. Seshadri, „Temperature Dependent Photovoltaic (PV) Efficiency and Its Effects on PV Production in the World – A Review,“ *Energy Procedia*, pp. 311 – 321, 2013.
- [58] E. A. Feinberg, D. Genethliou, „Load Forecasting“, *Applied Mathematics for Restructured Electric Power Systems*, pp. 269 – 285, 2005.
- [59] C. W. Ostrom, „Time Series Analysis: Regression Techniques, Second edition,“ *Michigan State University*, 1990.
- [60] G. A. F. Seber, A. J. Lee, „Linear Regression Analysis, second edition,“ *University of Auckland*, 2003.
- [61] J. Fox, „Applied regression analysis generalized linear models, third edition,“ SAGE Publications, 2016.
- [62] T. Haida, S. Muto, „Regression based peak load forecasting using a transformation technique,“ *IEEE Transactions on Power Systems*, pp. 1788 – 1794, 1994.
- [63] Farizal, Y. Qaradhawi, C. I. Cornelis, M. Dachyar, „Fast Moving Product Demand Forecasting Model with Multi Linear Regression,“ *AIP Conference Proceedings*, 2020.
- [64] Y. W. Lee, K. G. Tay, Y. Y. Choy, „Forecasting Electricity Consumption Using Time Series Model,“ *International Journal of Engineering & Technology*, pp. 218 – 223, 2018.
- [65] N. Abu-Shikhah, F. Elkami, „Medium – Term Electric Load Forecasting using Singular Value Decomposition,“ *Fuel and Energy Abstracts*, pp. 4259 – 4271, 2011.
- [66] H. T. Yang, C. M. Huang, „A new Short – Term Load Forecasting Approach using Self – Organizing Fuzzy ARMAX models,“ *IEEE Transactions on Power Systems*, pp. 217 – 225, 1998.
- [67] B. Artley, „Time Series Forecasting with ARIMA , SARIMA and SARIMAX,“ *Towards Data Science*, 2022.
- [68] S. Sehgal, H. Singh, M. Agarwal, V. Bhasker, Shantanu, „Data Analysis using Principal Component Analysis,“ *International Conference on Medical Imaging, m-Health and Emerging Communication Systems*, 2014.
- [69] M. A. Boden, „Artificial Intelligence and Natural Man,“ *The British Journal for the Philosophy of Science*, 1977.
- [70] K. El-Naggar, K. A. AL-Rumaih, „Electric Load Forecasting Using Genetic Based Algorithm, Optimal Filter Estimator and Least Error Squares Technique: Comparative Study,“ *International Journal of Electrical, Computer, Energetic, Electronic and Communication Engineering*, 2007.
- [71] P. Bunnoon, K. Chalermyanont, C. Limsakul, „A Computing Model of Artificial Intelligent Approaches to Mid – Term Load Forecasting: a state of the art survey for the researcher,“ *International Journal of Engineering and Technology*, 2010.
- [72] J. L. Castro, C. J. Mantas, J. M. Benitez, „Interpretation of artificial neural networks by means of fuzzy rules,“ *IEEE Transactions on Neural Networks*, 2002.
- [73] J. Blancas, J. Noel, „Short – Term Load Forecasting Using Fuzzy Logic,“ *IEEE PES Transmission & Distribution Conference and Exhibition – Latin America*, 2018.
- [74] P. Gohil, M. Gupta, „Short term load forecasting using fuzzy logic,“ *International Journal of Engineering Development and Research*, 2014.

- [75] L. X. Wang, J. M. Mendel, „Generating fuzzy rules by learning from examples,“ *IEEE Transactions on Systems, Man, and Cybernetics*, pp. 1414 – 1427, 1992.
- [76] T. Senju, P. Mandal, K. Uezato, T. Funabashi, „Next day load curve forecasting using hybrid correction method,“ *IEEE Transactions on Power Systems*, pp. 102 – 109, 2005.
- [77] A. Khotanzad, E. Zhou, H. Elragal, „A neuro-fuzzy approach to short-term load forecasting in a price-sensitive environment,“ *IEEE Transactions on Power Systems*, pp. 1273 – 1282, 2002.
- [78] B. M. Miller, „Future Applications of Expert Systems for the Evaluation of Energy Resources,“ *J Pet Technol* 40(03), pp. 348 – 352, 1988.
- [79] S. Rahman, R. Bhatnager, „An expert system based algorithm for short term load forecast,“ *IEEE Transactions on Power Systems*, pp. 392 – 399, 1988.
- [80] V. N. Vapnik, „The Nature of Statistical Learning Theory, Second Edition,“ 2000.
- [81] V. Vapnik, S. E. Golowich, A. Smola, „Support vector method for function approximation, regression estimation and signal processing,“ *9<sup>th</sup> International Conference on Neural Information Processing Systems*, pp. 281 – 287, 1996.
- [82] S. Ghosh, A. Dasgupta, A. Swetapadma, „A Study on Support Vector Machine based Linear and Non-Linear Pattern Classification,“ *International Conference on Intelligent Sustainable Systems*, 2019.
- [83] „Support Vector Machine classifier,“ *PCI Geomatics Enterprises*, 2022.
- [84] E. Vinagre, T. Pinto, S. Ramos, Z. Vale, J. M. Corchado, „Electrical Energy Consumption Forecasting Using Support Vector Machines,“ *27<sup>th</sup> International Workshop on Database and Expert Systems Applications (DEXA)*, 2016.
- [85] J. Yang, J. Stenzel, „Application of two-dimensional support vector machine in short-term Load forecasting,“ *IEEE Russia Power Tech*, 2005.
- [86] Q. L. Tan, H. Z. Yuan, X. F. Li, Y. K. Tan, X. P. Zhang, „Energy Consumption Forecasting Using Support Vector Machines for Beijing,“ *International Conference on E-Product E-Service and E-Entertainment*, 2010.
- [87] Z. Songlin, M. Meiqin, L. Chang, „Forecasting of wind speed based on wavelet analysis and support vector machine,“ *The 2<sup>nd</sup> International Symposium on Power Electronics for Distributed Generation Systems*, 2010.
- [88] J. Pahasa, N. T. Umpon, „Short-term load forecasting using wavelet transform and support vector machines,“ *International Power Engineering Conference*, 2007.
- [89] W. C. Hong, „Electric load forecasting by support vector model,“ *Applied Mathematical Modelling*, pp. 2444 – 2454, 2009.
- [90] S. Sayad, „Support Vector Machine - Regression,“ dostupno online: [https://www.saedsayad.com/support\\_vector\\_machine\\_reg.htm](https://www.saedsayad.com/support_vector_machine_reg.htm) (datum pristupa: 20.12.2022)
- [91] K. Kaur, Y. Kumar, „Swarm Intelligence and its applications towards Various Computing: A Systematic Review,“ *International Conference on Intelligent Engineering and Management*, 2020.
- [92] Y. Qawqzeh, M. T. Alharbi, A. Jaradat, K. N. A. Sattar, „A review of swarm intelligence algorithms deployment for scheduling and optimization in cloud computing environments,“ *The Open Access journal for Computer Science research*, 2021.

- [93] M. Dorigo, M. Birattari, T. Stutzle, „Ant colony optimization,“ *IEEE Computational Intelligence Magazine*, PP. 28 – 39, 2006.
- [94] S. Agarwal, A. P. Singh, N. Anand, „Evaluation performance study of Firefly algorithm, particle swarm optimization and artificial bee colony algorithm for non-linear mathematical optimization functions,“ *Fourth International Conference on Computing, Communications and Networking Technologies*, 2013.
- [95] I. Fister, X. S. Yang, J. Brest, „A comprehensive review of firefly algorithms,“ *Swarm and Evolutionary Computation*, pp. 34 – 46, 2013.
- [96] J. Kennedy, R. Eberhart, „Particle swarm optimization,“ *Proceedings of ICNN'95 - International Conference on Neural Networks*, 1995.
- [97] D. Karaboga, B. Basturk, „A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm,“ *Journal of Global Optimization*, pp. 459 – 471, 2007.
- [98] S. Talukder, „Mathematical Modelling and Applications of Particle Swarm Optimization,“ *School of Engineering at Blekinge Institute of Technology*, 2011.
- [99] M. E. Telebany, F. E. Karmy, „Short-term forecasting of Jordanian electricity demand using particle swarm optimization,“ *Electric Power Systems Research*, pp. 425 – 433, 2008.
- [100] M. R. Alrashidi, K. M. El-Naggar, „Long term electric load forecasting based on particle swarm optimization,“ *Research Gate: Applied Energy* 87(1), pp. 320-326, 2010.
- [101] M. L. Abdulrahman, K. M. Ibrahim, A. Y. Gital, F. U. Zambuk, B. Ja'affaru, Z. I. Yakubu, A. Ibrahim, „A Review on Deep Learning with Focus on Deep Recurrent Neural Network for Electricity Forecasting in Residential Building,“ *Procedia Computer Science*, pp. 141 – 154, 2021.
- [102] A. R. Portabales, M. L. Nores, J. J. P. Arias „ Systematic Review of Electricity Demand Forecast Using ANN – based Machine Learning Algorithms,“ *Sensors*, 2021.
- [103] M. Negnevitsky, „Artificial Intelligence: A guide to Intelligent Systems, Second Edition,“ 2005.
- [104] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas, M. J. Damborg, „Electric Load Forecasting Using An Artificial Neural Network,“ *IEEE Transactions on Power Systems*, 442 – 449, 1991.
- [105] H. S. Hippert, C. E. Pedreira, R. C. Souza, „Neural Networks for Short – Term Load Forecasting: a review and evaluation,“ *IEEE Transactions on Power Systems*, pp. 44 – 55, 2001.
- [106] C. Tranchita, A. Torres, „Soft Computing Techniques for Short – Term Load Forecasting,“ *IEEE PES Power Systems Conference and Exposition*, 2004.
- [107] M. Negnevitsky, „Artificial Intelligence, Second Edition,“ *Pearson Education (Singapore) Pte Ltd*, 2008.
- [108] W. Ertel, „Introduction to Artificial Intelligence, Second Edition,“ *Springer International Publishing*, 2017.
- [109] S. Haykin, „Neural Networks and Learning Machines, Third Edition,“ *Pearson Education*, 2009.
- [110] S. Sharma, „Activation Functions in Neural Networks,“ *Towards Data Science*, 2017.

- [111] N. Tapper, „Sigmoid Activation Function: An Introduction,“ *Builtin*, 2023.
- [112] P. Antoniadis, „Activation Functions: Sigmoid vs Tanh,“ *Baeldung*, dostupno online: <https://www.baeldung.com/cs/sigmoid-vs-tanh-functions> (datum pristupa: 25.05.2023)
- [113] J. Brownlee, „A gentle introduction to the rectified linear unit (RELU),“ *Machine Learning Maestry*, 2019.
- [114] „Neuronske mreže i mašinsko učenje,“ *Matematički fakultet, Univerzitet u Beogradu*, 2020.
- [115] D. E. Rumelhart, G. E. Hinton, R. J. Williams, „Learning representations by back-propagating errors,“ *Nature*, pp. 533–536, 1986.
- [116] S. Kostadinov, “Understanding Backpropagation Algorithm,” *Towards Data Science*, 2019.
- [117] M. A. Nielsen, „Neural Networks and Deep Learning,“ *Determination Press*, 2015.
- [118] I. Ševo, „Specijalizovana neuronska mreža za klasifikaciju i segmentaciju aerosnimaka,“ *Elektrotehnički fakultet u Banjoj Luci*, 2020.
- [119] B. K. Iwana, S. Uchida, „An empirical survey of data augmentation for time series classification with neural networks,“ *Plos One*, 2021.
- [120] C. Shorten, T. M. Khoshgoftaar, „A survey on image data augmentation for deep learning,“ *Journal of Big Data*, 2019.
- [121] M. Olson, A. Wyner, R. Berk, „Modern neural networks generalize on small data sets,“ *NeurIPS*, pp. 3619–3628, 2018.
- [122] R. Blagus, L. Lusa, „SMOTE for high-dimensional class-imbalanced data,“ *BMC Bioinformatics*, 2013.
- [123] P. Marimuthu, „Dropout Regularization in Deep Learning,“ *Data Science Blogathon*, 2022.
- [124] M. S. Rohith, „Keras EarlyStopping Callback to train the Neural Networks Perfectly,“ *Towards AI*, 2022.
- [125] *Weather Underground*, dostupno online: <https://www.wunderground.com/> (datum pristupa: 25.12.2022)
- [126] „Training and Validation Loss in Deep Learning,“ *Baeldung*, 2023.
- [127] J. Brownlee, „What is the Difference Between Test and Validation Datasets?,“ *Machine Learning Maestry*, 2017.
- [128] A. Saha, „ML | ADAM (Adaptive Moment Estimation) Optimization,“ dostupno online: <https://www.geeksforgeeks.org/adam-adaptive-moment-estimation-optimization-ml/> (datum pristupa: 10.09.2023)
- [129] D. P. Kingma, J. L. Ba, „ADAM: A method for stochastic optimization,“ *ICLR*, 2015.
- [130] A. Ajagekar, „Adam,“ *Cornell University*, 2021.
- [131] J. Brownlee, „Gentle Introduction to the Adam Optimization Algorithm for Deep Learning,“ *Machine Learning Maestry*, 2017.
- [132] J. Brownlee, „Difference Between a Batch and an Epoch in a Neural Network,“ *Machine Learning Maestry*, 2022.
- [133] „Mean Absolute Error,“ *DEEPCHECKS GLOSSARY*, dostupno online: <https://deepchecks.com/glossary/mean-absolute-error/> (datum pristupa: 23.12.2022)

- [134] „Challenges and limitations of neural networks and deep learning?“ *LinkedIn community*, dostupno online: <https://www.linkedin.com/advice/3/what-current-challenges-limitations-neural> (datum pristupa: 16.09.2023)
- [135] A. McDonald, „Data Quality Considerations for Machine Learning Models,“ *Towards Data Science*, 2022.
- [136] A. Kumar, „Moving Average Method for Time-series forecasting,“ *Analytics Yogi*, 2022.
- [137] Suryani and D. C. P. Buani, „Stock price prediction using artificial neural network integrated moving average,“ *Journal of Physics*, 2020.
- [138] E. Bozkus, „Using Machine Learning for Time Series Forecasting,“ *Data Driven Investor*, 2023.
- [139] S. Parera, „Rolling Window Regression: a Simple Approach for Time Series Next value Predictions,“ *Making Sense of Data*, 2016.
- [140] Alan M, „Bollinger Bands: Rolling Mean and Rolling Standard Deviation,“ *LinkedIn community*, dostupno online: <https://www.linkedin.com/pulse/qb4-bollinger-bands-rolling-mean-standard-deviation-alan-mcdowell> (datum pristupa 16.09.2013)
- [141] „What is Pandas Rolling Standard Deviation,“ *Saturn Cloud*, 2023.
- [142] „Rolling Descriptive Statistics,“ *Rolling Analysis of Time Series*, pp. 313–316
- [143] V. Urošević, Ž. Marković, „Kratkoročna prognoza potrošnje električne energije putem modifikovanog KNN algoritma i ARIMA statističkog modela,“ *13<sup>th</sup> Conference on electricity distribution with regional participation (Congrès International des Réseaux Electriques de Distribution-CIRED)*, Kopaonik, Srbija, 2022.
- [144] M. Riva, „Understanding Forecast Accuracy: MAPE, WAPE, WMAPE,“ *Baeldung*, 2021.

## PRILOG

**Prilog 1.** Rezultati implementacije sistema za kratkoročnu prognozu potrošnje električne energije korišćenjem predložene metode za 48-časovni period (01.08 – 03.08.2015. godine)

Tabela P.1.1 Rezultati kratkoročne prognoze potrošnje električne energije za 01.08. (plavom bojom) i 02.08. (zelenom bojom) 2015. godine

Čas [h]	Stvarna potrošnja električne energije [MWh]	Predviđena potrošnja električne energije [MWh]	APE [%]
00:00	84,565000	83,854950	0,839650
01:00	76,052000	73,792650	2,970799
02:00	71,254000	68,673040	3,622193
03:00	68,776000	66,208560	3,733051
04:00	66,652000	66,062980	0,883723
05:00	67,318000	67,767784	0,668148
06:00	74,764000	74,166840	0,798727
07:00	84,392000	86,612785	2,631512
08:00	94,501000	93,852240	0,686510
09:00	103,130000	101,283890	1,790081
10:00	108,851000	110,109870	1,156508
11:00	115,942000	115,503560	0,378152
12:00	121,742000	119,944980	1,476091
13:00	123,497000	123,976135	0,387973
14:00	120,837000	123,553925	2,248421
15:00	121,792000	119,411090	1,954901
16:00	119,259000	117,995705	1,059287
17:00	118,205000	115,362670	2,404576
18:00	113,586000	112,675920	0,801227
19:00	112,340000	112,568670	0,203554
20:00	117,203000	113,619050	3,057900
21:00	115,774000	110,986275	4,135406
22:00	111,865000	107,922420	3,524412
23:00	103,425000	105,195465	1,711835
00:00	91,985000	92,949610	1,048658
01:00	82,873000	80,825150	2,471071
02:00	77,285000	74,312096	3,846677
03:00	73,505000	72,282585	1,663036
04:00	70,189000	71,041405	1,214442
05:00	68,723000	69,831436	1,612904
06:00	73,745000	76,276405	3,432647
07:00	80,386000	80,585170	0,247763
08:00	91,764000	86,923515	5,274928
09:00	100,184000	99,073190	1,108771
10:00	106,596000	107,237740	0,602030
11:00	113,022000	111,796880	1,083964
12:00	116,233000	116,564070	0,284834
13:00	118,022000	117,504395	0,438567
14:00	116,745000	115,660940	0,928569
15:00	114,694000	115,755264	0,925301
16:00	111,427000	113,131470	1,529674
17:00	106,116000	108,799706	2,529030
18:00	102,987000	103,899920	0,886440
19:00	105,762000	105,002884	0,717759
20:00	114,131000	109,187580	4,331359
21:00	114,363000	109,766390	4,019317
22:00	110,707000	108,496990	1,996273
23:00	100,515000	103,439950	2,909963