

Prognoziranje opterećenja u distributivnoj mreži 35 kV Elektroslavonije Osijek

Matić, Marija

Master's thesis / Diplomski rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:210199>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-08-02**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK**

Sveučilišni diplomski studij

**Prognoziranje opterećenja u distributivnoj mreži 35 kV
Elektroslavonije Osijek**

Diplomski rad

Marija Matić

Osijek, 2023.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**Obrazac D1: Obrazac za imenovanje Povjerenstva za diplomski ispit**

Osijek, 18.09.2023.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za diplomski ispit

Ime i prezime Pristupnika:	Marija Matić
Studij, smjer:	Diplomski sveučilišni studij Elektrotehnika
Mat. br. Pristupnika, godina upisa:	D-1336, 11.10.2020.
OIB studenta:	35541922178
Mentor:	izv. prof. dr. sc. Krešimir Fekete
Sumentor:	Slaven Kaluđer,
Sumentor iz tvrtke:	
Predsjednik Povjerenstva:	prof. dr. sc. Zvonimir Klaić
Član Povjerenstva 1:	izv. prof. dr. sc. Krešimir Fekete
Član Povjerenstva 2:	Ružica Kljajić, mag. ing. el.
Naslov diplomskog rada:	Prognoziranje opterećenja u distributivnoj mreži 35 kV Elektroslavonije Osijek
Znanstvena grana diplomskog rada:	Elektroenergetika (zn. polje elektrotehnika)
Zadatak diplomskog rada:	Prognoziranje opterećenja je ključni korak u planiranju razvoja svakog elektroenergetskog sustava, a prognoza opterećenja na distribucijskoj razini utječe na prienosnu i proizvodnu razinu i njihove planove u pogledu razvoja i vođenja sustava. Težina prognoze opterećenja proizlazi iz toga što na nju utječu promjenjivi parametri u vidu variranja opterećenja od vremena do vremena, migracija opterećenja, nepredvidivost pojave novih kupaca i društvene aktivnosti. Prikupljeno znanje služi kako bi se prilikom planiranja utvrdilo do koje su mjere zadovoljene potrebe za kapacitetom sustava. U radu je potrebno izvršiti prognozu opterećenja u transformatorskim stanicama 35/10 kV za narednu godinu koristeći metode umjetne inteligencije i programi.
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 2 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 2 razina
Datum prijedloga ocjene od strane mentora:	18.09.2023.
Potvrda mentora o predaji konačne verzije rada:	<i>Mentor elektronički potpisao predaju konačne verzije.</i>
	Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****IZJAVA O ORIGINALNOSTI RADA**

Osijek, 28.09.2023.

Ime i prezime studenta:	Marija Matić
Studij:	Diplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	D-1336, 11.10.2020.
Turnitin podudaranje [%]:	5

Ovom izjavom izjavljujem da je rad pod nazivom: **Prognoziranje opterećenja u distributivnoj mreži 35 kV Elektroslavonije Osijek**

izrađen pod vodstvom mentora izv. prof. dr. sc. Krešimir Fekete

i sumentora Slaven Kaluđer,

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija. Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

SADRŽAJ

1. UVOD	1
1.1. Zadatak završnog rada	1
2. PREGLED PODRUČJA TEME	2
3. PREDVIĐANJE OPTEREĆENJA.....	3
3.1. Predviđanje opterećenja prema vremenu.....	3
3.1.1. Vrlo kratkoročno predviđanje opterećenja (VSTLF).....	4
3.1.2. Kratkoročno predviđanje opterećenja (STF)	4
3.1.3. Srednjoročno predviđanje opterećenja (MTF).....	5
3.1.4. Dugoročno predviđanje opterećenja (LTF)	5
3.2. Aspekti predviđanja opterećenja.....	6
3.2.1. Vremenske prilike	6
3.2.2. Vremenski faktor	8
3.2.3. Ekonomski faktori	9
4. MODELI PREDVIĐANJA OPTEREĆENJA.....	11
4.1. Klasični modeli	12
4.1.1. Metoda regresijske analize	12
4.1.2. Metoda vremenskih nizova.....	12
4.1.3. Ekstrapolacija trenda	12
4.2. Matematički modeli	13
4.2.1. Višestruka regresija	13
4.2.2. Eksponencijalno izgladivanje	13
4.2.3. Iterativna metoda najmanjih kvadrata.....	13
4.2.4. Autoregresivna metoda.....	14
4.2.5. Pomični prosjek	14
4.2.6. Autoregresivni pomični prosjek	14
4.2.7. Autoregresivni integrirani pomični prosjek.....	14
4.2.8. Kalman filter.....	15
4.3. Modeli računalne inteligencija	16
4.3.1. Metoda umjetne neuronske mreže	16
4.3.2. Metoda potpornih vektora	17
5. OPIS MODELA ZA PREDVIĐANJA OPTEREĆENJA ELEKTRIČNE ENERGIJE	19
5.1. Distribucijska mreža Baranje	19

5.2. Godišnje opterećenje električnom energijom	21
5.3. Model.....	22
6. PROGNOZA PREDVIĐANJA OPTEREĆENJA ZA NAREDNI KVARTAL	26
6.1. Predviđanje opterećenja električne energije za TS Bilje.....	26
6.2. Predviđanje opterećenja električne energije za TS Branjin Vrh.....	34
6.3. Predviđanje opterećenja električne energije za TS Draž	37
6.4. Predviđanje opterećenja električne energije za TS Kneževi Vinogradi.....	40
7. ZAKLJUČAK.....	43
SAŽETAK.....	44
ABSTRACT	44
LITERATURA	45
ŽIVOTOPIS.....	47

1. UVOD

Predviđanje opterećenja je proces predviđanja potrošnje električne energije za određeno geografsko područje, kao što je grad, regija ili cijela država. Cilj predviđanja opterećenja je procijeniti koliko će električne energije biti potrebno u različitim trenucima u budućnosti, obično na kratkoročnoj ili dugoročnoj osnovi.

U ovom diplomskom radu su opisani različiti modeli za predviđanje opterećenja električne energije, te kako različiti parametri mogu utjecati na predviđanje opterećenja. U radu je izvršeno predviđanje opterećenja metodom umjetne neuronske mreže. Predviđanje opterećenja izvršeno je na četiri transformatorske stanice (TS Bilje, TS Branjin Vrh, TS Draž i TS Kneževi Vinogradi) pomoću modela koji je napravljen u programu „Orange“. Na temelju dobivenih rezultata, ROC krivulje i podataka za prethodne godine, donesena je odluka u kojem se intervalu nalazi opterećenje za naredni kvartal.

Diplomski rad se sastoji od sedam poglavlja. U prvom poglavlju je uvod u kojem je kratko opisana tema rada. Drugo poglavlje je pregled područja teme, odnosno u tom je poglavlju napravljena analiza već dosad napravljenih radova na ovu temu. U trećem poglavlju opisano je kako se predviđanje opterećenja može podijeliti prema vremenu, te kako različiti aspekti mogu utjecati na predviđanje opterećenja. Četvrto poglavlje opisuje modele za predviđanje opterećenja, te njihovu podjelu. U petom poglavlju je opisana mreža i model na kojem će se vršiti predviđanje opterećenja. U šestom poglavlju napravljeno je predviđanje opterećenja u TS Bilje, TS Branjin Vrh, TS Draž i TS Kneževi Vinogradi. U posljednjem poglavlju napravljen je zaključak na temelju dobivenih rezultata.

1.1. Zadatak završnog rada

Prognoziranje opterećenja je ključni korak u planiranju razvoja svakog elektroenergetskog sustava, a prognoza opterećenja na distribucijskoj razini utječe na prijenosnu i proizvodnu razinu i njihove planove u pogledu razvoja i vođenja sustava. Težina prognoze opterećenja proizlazi iz toga što na nju utječu promjenjivi parametri u vidu variranja opterećenja od vremena do vremena, migracija opterećenja, nepredvidivost pojave novih kupaca i društvene aktivnosti. Prikupljeno znanje služi kako bi se prilikom planiranja utvrdilo do koje su mjere zadovoljene potrebe za kapacitetom sustava. U radu je potrebno izvršiti prognozu opterećenja u transformatorskim stanicama 35/10 kV za narednu kvartal koristeći metode umjetne inteligencije i napraviti procjenu dostatnosti instaliranih kapaciteta.

2. PREGLED PODRUČJA TEME

Tema ovog rada je analiza opterećenja u distributivnoj mreži 35 kV. Proces koji se koristi za procjenu buduće potražnje za energijom za određenu regiju ili sustav je ključan u upravljanju opterećenjem. Ova analiza ima utjecaj na prijenosnu i proizvodnu razinu, kao i na distribucijsku razinu. Za točno i pouzdano razumijevanje budućih potreba za energijom uključuju se povijesni podaci o potrošnji energije, vremenski uvjeti, ekonomski pokazatelji i druge relevantne informacije.

U literaturi [1] autori opisuju da donositelji odluka energetskega sektora bi trebali predvidjeti buduće potrebe za električnom energijom s velikom točnošću i malom pogreškom kako bi se potrošačima osigurala električna energija bez rasterećenja. Potražnja za električnom energijom može se predvidjeti mnogim tehnikama ML (eng. *Machine Learning* – Strojno učenje), DL (eng. *Deep Learning* – Duboko učenje) i AI (eng. *Artificial Intelligence* – Umjetna inteligencija), među kojima su hibridne metode najpopularnije. Dat je i pregled sadašnjih tehnologija predviđanja opterećenja i sadašnjeg rada na kombinaciji različitih ML, DL i AI algoritama. Također, autori detaljno opisuju pojedinačne i hibridne modele predviđanja opterećenja s funkcijama, te njihove prednosti i nedostatke. Odrađena je usporedba između modela u smislu vrijednosti srednje apsolutne pogreške (eng. *Mean Absolute Error - MAE*), korijena srednje kvadratne pogreške (eng. *Root Mean Squared Error - RMSE*) i srednje apsolutne postotne pogreške (eng. *Mean Absolute Percentage Error - MAPE*) kako bi se istraživačima pomoglo u odabiru najboljeg modela za predviđanje opterećenja.

Autori u literaturi [2] opisuju tipične modele za predviđanje opterećenja te su ih podijelili u tri glavne kategorije: klasični modeli za predviđanje opterećenja, konvencionalni modeli za predviđanje opterećenja i inteligentni modeli za predviđanje opterećenja. Za dugoročno predviđanje opterećenja prikladni modeli su: metoda regresijske analize, metoda vremenskih nizova i metoda ekstrapolacije trenda. Za srednjoročno predviđanje opterećenja prikladni modeli su: metoda regresijske analize, metoda vremenskih nizova te Kalmanova metoda. Za kratkoročno i vrlo kratkoročno predviđanje opterećenja najčešće se koriste modeli računalne inteligencije.

U literaturi [3] autori predstavljaju usporedni pregled predviđanja opterećenja i dinamičkih shema određivanja cijena u pametnim mrežama. Modele predviđanja opterećenja su podijelili u dvije glavne kategorije: matematički i računalni modeli temeljeni na umjetnoj inteligenciji. Također, autori raspravljaju o matematičkim modelima uključujući autorekurziv, pomični prosjek, autorekurzivni pomični prosjek itd.

3. PREDVIĐANJE OPTEREĆENJA

Tehnike predviđanja opterećenja koriste se za predviđanje budućih energetske potrebe sustava na temelju prethodnih podataka, vremenskih uvjeta i dostupnosti obnovljivih izvora energije. Predviđanje opterećenja je baza u planiranju elektroprivrednih usluga. Osigurava ravnotežu između ponude i potražnje za energijom. Predviđanje opterećenja se uglavnom koristi za predviđanje budućeg opterećenja za određeni sustav u određenom vremenskom periodu [3].

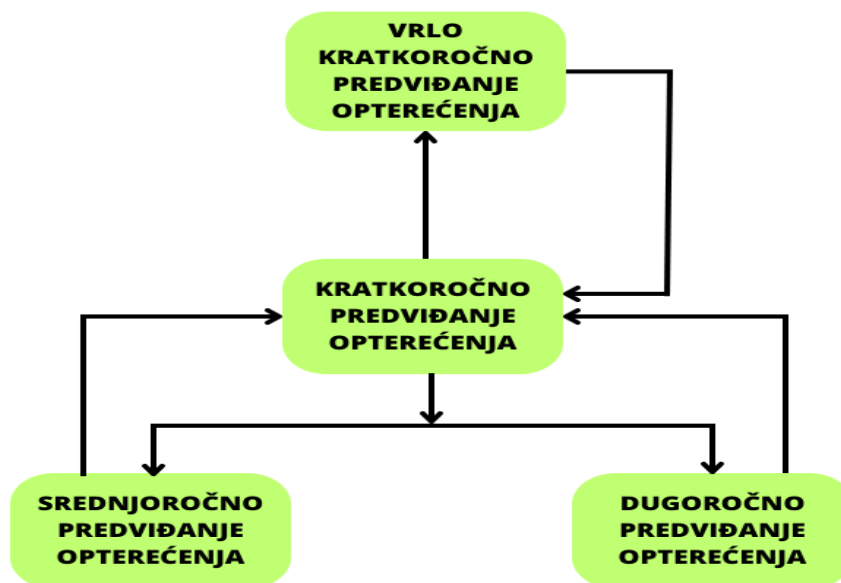
3.1. Predviđanje opterećenja prema vremenu

Vrste predviđanje opterećenja prema vremenu odnose se na različita trajanja ili razdoblja za koja se vrše predviđanja opterećenja električne energije. Predviđanje opterećenja igra ključnu ulogu u energetskom sektoru, pomažući u učinkovitom radu i planiranju elektroenergetskih sustava. Analizom povijesnih podataka i razmatranju različitih čimbenika, modeli predviđanja opterećenja mogu procijeniti potražnju električne energije u različitom vremenskom periodu. Ova mrežna tehnika pomaže mrežnim operatorima, elektroprivrednim poduzećima i dobavljačima energije da donose odluke, optimiziraju raspodjelu resursa i održavaju pouzdanu opskrbu električnom energijom.

Autori u literaturi [1] predviđanje opterećenja prema vremenskom razdoblju dijele u četiri kategorije:

- Vrlo kratkoročno predviđanje opterećenja (eng. *Very short term forecasting, VSTLF*)
- Kratkoročno predviđanje opterećenja (eng. *Short term forecasting, STF*)
- Srednjeročno predviđanje opterećenja (eng. *Medium term forecasting, MTF*)
- Dugoročno predviđanje opterećenja (eng. *Long term forecasting, LTF*)

Buduća opterećenja predviđaju se na temelju prošlih opterećenja u VSTLF. Mnogi čimbenici, uključujući informacije o korištenom zemljištu, ekonomiji i temperaturi mogu utjecati na prognozirane opterećenja. Vremenska skala je vremensko razdoblje koje je potrebno za generiranje podataka. To je važan parametar za klasifikaciju tehnika predviđanja u sustavima pametnih mreža [1]. Na slici 3.1. je prikazan tijek procesa pretvorbe između VSTLF, STF, MTF i LTF.



Slika 3.1. *Proces pretvorbe između VSTLF, STF, MTF i LTF [1]*

3.1.1. Vrlo kratkoročno predviđanje opterećenja (VSTLF)

VSTLF je vrsta predviđanja koja se koristi za predviđanje opterećenja po minuti do nekoliko sati (0-3h). Može pomoći u rješavanju slučajnih varijacija u proizvodnji obnovljive energije koja se može predvidjeti u vrlo kratkom vremenu. Ima mnoge primjene u fotonaponskim elektranama te u vjetroelektranama [1].

VSTLF suočava se s nekoliko izazova, uključujući osjetljivost potrošnje električne energije na vremenske uvjete, promjenjivost potražnje zbog neočekivanih događaja te dostupnost i kvalitetu podataka u stvarnom vremenu. Točni vremenski podaci, pouzdani povijesni podaci o opterećenju i pravovremena ažuriranje vanjskih čimbenika, ključni su za poboljšanje točnosti prognoza. VSTLF podržava strategije upravljanja potražnjom, kao što su programi odgovora za odgovor na potražnju, gdje potrošači mogu prilagoditi svoju potrošnju električne energije tijekom vršnih razdoblja na temelju predviđenog opterećenja.

3.1.2. Kratkoročno predviđanje opterećenja (STF)

STF je vrsta predviđanja koja se koristi za predviđanje opterećenja unaprijed od nekoliko minuta do nekoliko dana. Ima ključnu ulogu u različitim mrežnim operacijama koje uključuju analizu pouzdanosti i dispečersku analizu. Također, pomaže u izbjegavanju precijenjene i podcijenjene potražnje za energijom i time značajno doprinosi pouzdanosti mreže [1].

STF uzima u obzir čimbenike koji utječu na potrošnju električne energije, kao što su vremenski uvjeti, povijesni podaci opterećenja, učinaka dana u tjednu, doba dana, praznika i posebnih događaja. Ova vrsta predviđanja pomaže mrežnim operatorima optimizirati proizvodnju električne energije i uravnotežiti ponudu i potražnju u stvarnom vremenu.

3.1.3. Srednjoročno predviđanje opterećenja (MTF)

MTF je vrsta predviđanja koja se koristi za predviđanje opterećenja od nekoliko dana do nekoliko mjeseci unaprijed. Pomaže pri održavanju, procjeni adekvatnosti i opskrbi gorivom u sustavima pametne mreže. Također, igra važnu ulogu u procjeni financijskih svojstava energetskog sustava pridonoseći upravljanju rizikom [1].

Preciznim predviđanjem budućih obrazaca opterećenja, moguća je bolja raspodjela resursa te je moguće osigurati pouzdano i ekonomično napajanje. MTF pruža uvid u očekivanu potražnju za električnom energijom i pomaže u planiranju kapaciteta, uravnoteženju opterećenja i donošenju odluka o ulaganju. Na točnost MTF-a mogu utjecati neizvjesnosti, kao što su regulatorne politike i nepredviđeni događaji poput prirodnih katastrofa. Stoga je redovito praćenje i ažuriranje prognoze opterećenja ključno za prilagodbu promjenjivim uvjetima i osiguranje pouzdane opskrbe električnom energijom.

3.1.4. Dugoročno predviđanje opterećenja (LTF)

LTF je vrsta predviđanja koja se koristi za predviđanje opterećenja od nekoliko mjeseci do nekoliko godina unaprijed. LTF je vrlo važan za proizvodnju i za planiranje rasta opterećenja na duži vremenski period. Prednosti LTF-a su te što mogu ukloniti učinke nasumičnih fluktuacija koja se javljaju u kratkom roku i napraviti predviđanje dugoročnih trendova [1].

Cilj mu je predvidjeti obrasce potražnje za električnom energijom u dalekoj budućnosti, pomažući u strateškom planiranju i formuliranju politike. LTF uzima u obzir čimbenike poput demografskih promjena, gospodarskog razvoja, tehnološkog napretka, državnih propisa i ekoloških pitanja. Koristeći povijesne podatke, napredne tehnike modeliranja i uzimajući u obzir različite vanjske čimbenike, LTF podupire održivu i pouzdanu opskrbu električnom energijom u budućnosti.

Svaki tip predviđanja opterećenja ima svoju specifičnu svrhu i doprinosi učinkovitim gospodarenju energijom u različitim horizontima planiranja. Dok VSTLF i STF pomažu u radu mreže u stvarnom vremenu, MTF i LTF podržava donošenje odluka koje se odnose na proširenje sustava, upravljanje potražnjom i strategijom energetskog tržišta. Točnim predviđanjem potražnje

za električnom energijom, komunalna poduzeća i operatori mreže mogu optimizirati raspodjelu resursa, poboljšati pouzdanost i promicati održivost u energetsom sektoru.

3.2. Aspekti predviđanja opterećenja

Proces predviđanje opterećenja ovisi o različitim čimbenicima koji utječu na njegovu preciznost. Kako bi se dobila točna predviđanja potrebno je pažljivo odabrati zavisne faktore. Sporedni i glavni čimbenici utječu na prognozu u svakom koraku, ali ekonomski, vremenski i meteorološki faktori su značajni čimbenici. Pri odabiru modela potrebna je značajna pažnja, jer različiti algoritmi imaju različite varijabilne parametre [1].

Pogreška u modelu za predviđanje opterećenja uzrokuje povećanje operativnih troškova, te je potreban točan matematički model koji formira odnos između opterećenja i utjecajnih varijabli kao što su vrijeme, vremenske prilike i ekonomski faktori itd.[3].

3.2.1. Vremenske prilike

Na ponašanje potrošača utječu vremenske prilike. Zahtjev za budućim opterećenjem predviđa se rezultatima vremenske prognoze u različitim modelima. Također, elektroprivredne tvrtke koriste indeks hladnoće vjetra (eng. *Wind chill index - WCI*) i indeks temperature i vlažnosti (eng. *Temperature humidity index - THI*). WCI i THI mjere zimski stres od hladnoće i toplinsku nelagodu ljeti [1].

Vrijeme koje utječe na prognozu opterećenja odnosi se na utjecaj različitih meteoroloških čimbenika. Predviđanje opterećenja uključuje procjenu količine električne energije koja će biti potrebna potrošačima tijekom određenog razdoblja, obično u rasponu od nekoliko sati do nekoliko dana ili tjedana. Vremenski uvjeti igraju značajnu ulogu u određivanju obrazaca potrošnje energije pojedinaca, poduzeća i industrija. Vrijeme je jedan od najznačajnijih čimbenika koji utječu na predviđanje opterećenja. Neki od čimbenika povezani s vremenom koji mogu utjecati na predviđanje opterećenja su: temperatura, vlažnost, brzina vjetra, padaline, dnevno svjetlo, te ekstremni vremenski događaji.

Temperatura je jedan od primarnih vremenskih čimbenika koji izravno utječu na predviđanje opterećenja. Više temperature rezultiraju povećanjem potražnjom za hlađenjem, jer se ljudi više oslanjaju na sustav klimatizacije za održavanje ugodne unutarnje temperature. Suprotno tome, niže temperature dovode do većih potreba za grijanjem, što utječe na potrošnju električne energije za grijanje. Sezonske varijacije temperature, poput ljeta i zime, značajno utječu na modele

predviđanja opterećenja. Također, nagli pad temperature može dovesti do manje potrošnje pa postoji vjerojatnost precijenjenog predviđanja opterećenja.

Razine vlažnosti također utječu na predviđanje opterećenja jer utječu na potražnju za hlađenjem i grijanjem. Visoka vlažnost može utjecati da se ljudi osjećaju neugodno, što dovodi do povećane upotrebe klimatizacijskih sustava. Suprotno tome, niska vlažnost može utjecati na zahtjeve za grijanjem, budući da unutarnje okruženje može učiniti hladnijim. Ove varijacije u razinama vlažnosti dodatno doprinose fluktuacijama u potražnji za električnom energijom.

Brzina vjetra je ključni faktor za proizvodnju energije vjetra. Vjetroturbine proizvode električnu energiju na temelju brzine vjetra, a varijacije brzine vjetra utječu na količinu proizvedene energije. Točno predviđanje opterećenja treba uzeti u obzir podatke o brzini vjetra, kako bi se procijenio doprinos snage vjetra ukupnoj opskrbi električnom energijom.

Padaline, poput kiše ili snijega utječu na obrasce potrošnje energije. Kiša može smanjiti potražnju za električnom energijom za aktivnosti na otvorenom, dok snijeg može povećati potrebe za grijanjem. Oborina također može utjecati na rad obnovljivih izvora energije kao što su solarni paneli, utječući na cjelokupnu mješavinu energije.

Dužina dnevnog svjetla utječe na potrošnju električne energije. Dulje dnevno svjetlo ljeti može smanjiti potrebu umjetnom rasvjetom, dok kraće dnevno svjetlo zimi može povećati zahtjeve za osvjetljivanjem. Modeli za predviđanje opterećenja trebali bi uzeti u obzir varijacije i potrošnji energije povezane s dnevnim satima.

Teški vremenski događaji poput oluja, uragana ili toplinskih valova mogu uzrokovati poremećaje u opskrbi električnom energijom, što dovodi do fluktuacija u potražnji opterećenja. Ovi događaji mogu rezultirati prekidima napajanja, oštećenjima infrastrukture i promjenama u ponašanju potrošača. Potencijalne poremećaje uzrokovane ekstremnim vremenskim uvjetima potrebno je uzeti u obzir u modelima predviđanja opterećenja.

Točno predviđanje opterećenja uzima u obzir povijesne vremenske podatke, vremenske informacije u stvarnom vremenu i sofisticirane statističke tehnike za analizu utjecaja vremena na potražnju za električnom energijom. Uključujući vremenske čimbenike, predviđanje opterećenja pomaže komunalnim poduzećima da učinkovito planiraju i upravljaju proizvodnjom, prijenosom i distribucijom energije kako bi osigurali pouzdanu i učinkovitu opskrbu električnom energijom.

3.2.2. Vremenski faktor

Vremenski faktor koji utječe na predviđanje opterećenja odnosi se na razmatranje i analizu vremenskih obrazaca i trendova koji utječu na točnost i pouzdanost modela za predviđanje opterećenja tijekom određenog vremenskog razdoblja. Predviđanje opterećenja je proces procjene buduće potrošnje električne energije na temelju povijesnih podataka, karakteristika sustava i vanjskih čimbenika. Vremenski faktori uzimaju u obzir: doba dana, dan u tjednu, godišnja doba, praznike, dugoročne trendove i anomalije, kako bi zabilježili dinamičnu prirodu potražnje za električnom energijom.

Potražnja za opterećenjem prati različite obrasce tijekom dana, obično s vršnom potražnjom tijekom jutarnjih i večernjih sati i manjom potražnjom tijekom noći. Na navedene dnevne varijacije utječu čimbenici kao što su radno vrijeme, stambene i poslovne aktivnosti i način života. Modeli za predviđanje opterećenja moraju uzeti u obzir dnevne varijacije kako bi točno predvidjeli potrošnju električne energije.

Potražnja za električnom energijom često se razlikuje između radnih dana i vikenda. Radnim danima postoji potreba za većom potražnjom zbog povećanih industrijskih i komercijalnih aktivnosti, dok vikendima može biti manja potražnja. Modeli predviđanja opterećenja uzimaju u obzir faktor dana u tjednu kako bi zabilježili varijacije i prema tome prilagodili predviđanje.

Na potražnju za opterećenjem utječu i promjene godišnjih doba zbog čimbenika poput vremenskih uvjeta, promjena temperature te dnevno svjetlo. Modeli za predviđanje opterećenja zahtijevaju uzimanje u obzir sezonskih trendova kako bi točno predvidjeli potrošnju električne energije, kao što je već spomenuto u prethodnom poglavlju.

Posebni događaji, praznici ili značajne prilike mogu utjecati na potražnju za opterećenjem. Na primjer, tijekom blagdana, državnih blagdana ili velikih sportskih događaja može doći do promjena u obrascima potrošnje električne energije. Modeli predviđanja opterećenja trebali bi uključivati povijesne podatke povezane s tim događajima kako bi se predvidjeli pomaci u potražnji opterećenja.

Modeli za predviđanjem opterećenja mogu uključivati dugoročne trendove kako bi zabilježili promjene u obrascima potrošnje električne energije tijekom duljeg razdoblja. Čimbenici kao što su porast stanovništva, društveno-ekonomskih čimbenici, urbanizacija i promjena u tehnologiji i industrijskoj praksi uvelike mogu promijeniti obrazac potrošnje. Analiza i uključivanje dugoročnih trendova u modele predviđanja opterećenja ključno je za pouzdana predviđanja.

Odstupanja ili anomalije uobičajenih uzoraka opterećenja također utječu na predviđanje opterećenja. To može uključivati neočekivane događaje kao što su ekstremni vremenski uvjeti, prirodne katastrofe, kvarovi sustava ili iznenadne promjene u ponašanju potrošača. Otkrivanje i pravilno rukovanje s navedenim anomalijama poboljšava točnost predviđanja opterećenja.

Uzimajući u obzir faktor vremena u predviđanje opterećenja, komunalna poduzeća, operatori mreže i energetske planeri mogu donositi informiranije odluke u vezi s raspodjelom resursa, planiranjem infrastrukture, strategijama odgovora na potražnju i operacijama energetskog tržišta. Točno predviđanje opterećenja pomaže u osiguravanju učinkovitog i pouzdanog rada elektroenergetske mreže, optimalnog iskorištenja resursa i učinkovitog upravljanja energijom.

3.2.3. Ekonomski faktori

Stupanj industrijalizacije, upravljanje opterećenjem i cijena električne energije su ekonomski čimbenici koji utječu na maksimalnu potražnju i prosječno opterećenje sustava. Savršenost predviđanja opterećenja određena je utjecajnim razinama kao što su opis uređaja, ponašanje kupaca, lokalno stanovništvo, kompatibilnost opreme i razine zaposlenosti. Takve čimbenike treba izračunati za predviđanje dugoročnog predviđanja u određenim područjima jer potražnja i dodatno generiranje opterećenja utječu na odabir modela kao i na prikupljanje podataka [1].

Ekonomski čimbenici koji utječu na predviđanje opterećenja su različite ekonomske varijable i uvjeti koji utječu na potražnju za električnom energijom ili potrošnju energije. Ovi čimbenici mogu varirati ovisno o određenoj regiji ili tržištu koje se razmatra. Uobičajeni ekonomski čimbenici koji utječu na predviđanje opterećenja uključuje: ekonomski rast, industrijska i komercijalna aktivnost, stanovništvo i demografija, razina zaposlenosti i raspodjela dohotka, cijena energije, državne politike i propisi te vremenski uvjeti.

Ukupni gospodarski rast zemlje ili regije ključni je faktor koji utječe na predviđanje opterećenja. Tijekom razdoblja ekonomske ekspanzije obično dolazi do povećanja industrijske proizvodnje, komercijalnog razvoja i potrošačke potrošnje, što dovodi do veće potrošnje energije. Nasuprot tome, tijekom gospodarske krize može doći do smanjenja potražnje za energijom.

Razina industrijske i komercijalne aktivnosti unutar regije izravno utječe na potražnju električne energije. Proizvodnim pogonima, uredima i komercijalnim objektima potrebna je električna energija za pogon, tako da promjene u industrijskoj proizvodnji ili komercijalnim ulaganjima mogu utjecati na predviđanje opterećenja.

Promjena u porastu populacije i demografiji mogu značajno utjecati na obrasce potrošnje električne energije. Rastuće stanovništvo ili promjene u distribuciji stanovništva, kao što su urbanizacija ili migracija, mogu rezultirati povećanom potražnjom za električnom energijom za stambene, komercijalne i javne infrastrukture.

Razina zaposlenosti i raspodjela prihoda unutar regije mogu utjecati na obrasce korištenja električne energije. Više stope zaposlenosti i povećani raspoloživi dohodak obično rezultiraju povećanom potrošnjom električne energije budući da pojedinci imaju veću kupovnu moć za uređaje, elektroniku i drugu robu koja troši energiju.

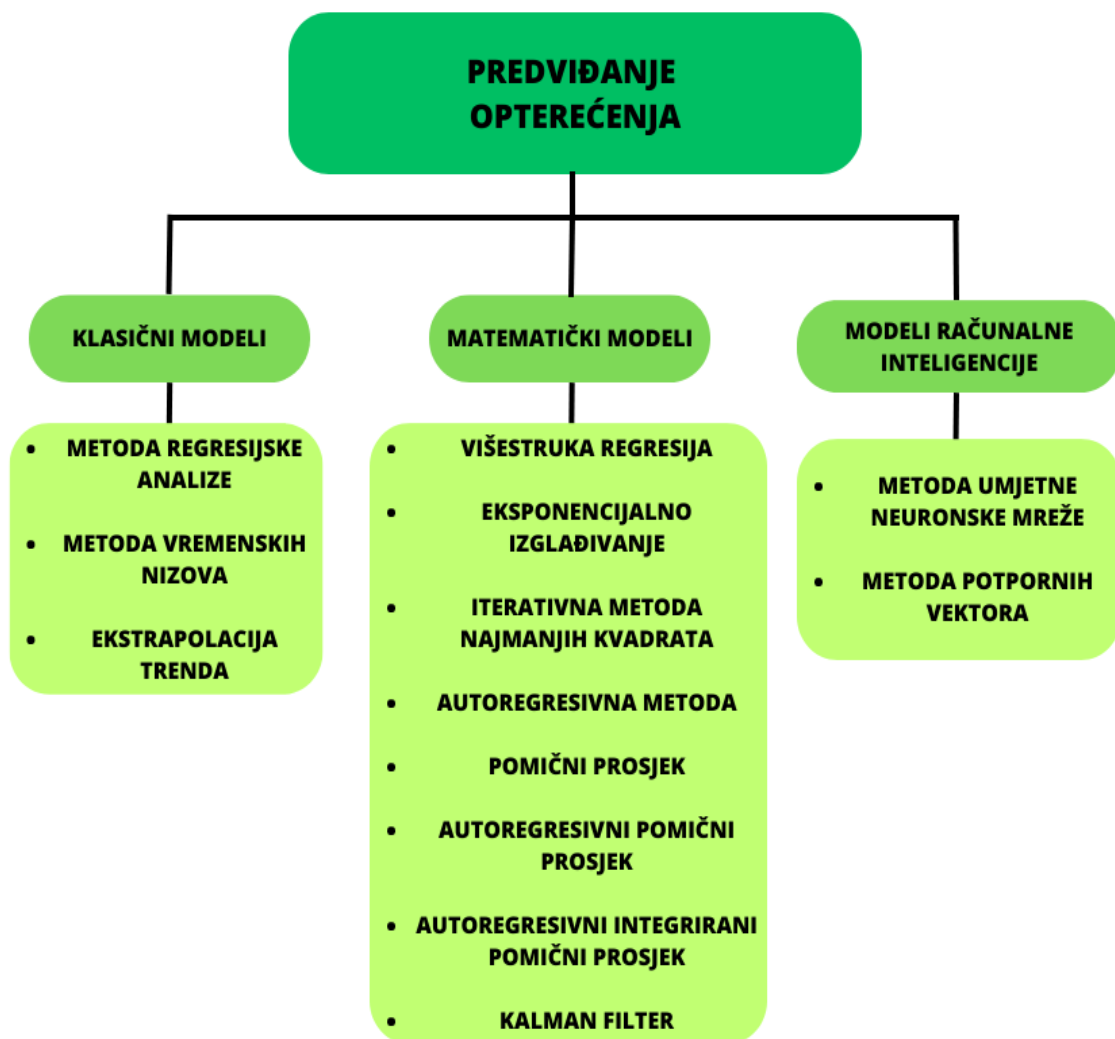
Troškovi energije, uključujući cijene električne energije, cijene goriva i tarife, utječu na predviđanje opterećenja. Oscilacije u cijenama energije mogu utjecati na ponašanje potrošača, inicijative za energetske učinkovitost u ukupnu potražnju za električnom energijom. Više cijene električne energije mogu potaknuti potrošače da štede energiju, dok niže cijene mogu dovesti do povećane potrošnje.

Vladine politike i propisi koji se odnose na korištenje energije, ciljeve obnovljivih izvora energije, standarde učinkovitosti i emisije ugljika, mogu oblikovati predviđanje opterećenja. Promjene energetske politike ili provedba novih propisa mogu utjecati na potražnju za električnom energijom i vrste korištenih izvora energije.

Uključivanje ovih ekonomskih faktora u modele predviđanja opterećenja, energetske planeri, operatori mreže i donositelji odluka mogu napraviti točnija predviđanja buduće potražnje za električnom energijom. To omogućava energetske planiranje, raspodjelu resursa i upravljanje mrežom kako bi se zadovoljile potrebe potrošača i osigurala pouzdana i održiva opskrba energijom.

4. MODELI PREDVIĐANJA OPTEREĆENJA

Predviđanje opterećenja je ključni parametar za rad i planiranje elektroenergetskog sustava i ima veliki potencijal uštede električne energije. Pogreška u modelu predviđanja uzrokuje povećanje operativnih troškova pa je potreban točan matematički model koji je formirao odnos između opterećenja i utjecajnih varijabli kao što su vremenske prilike, vrijeme i ekonomski faktor. Modeli predviđanja zahtijevaju tehnike procjene za određivanje parametara modela [3]. Autori u literaturi [2] i [3] dijele prognozu opterećenja u tri kategorije, te na slici 4.1. je prikazana podjela.



Slika 4.1. Modeli predviđanja opterećenja [2][3]

4.1. Klasični modeli

Klasične metode predviđanja opterećenja odnose se na tradicionalne pristupe koji se koriste za predviđanje potražnje ili opterećenja električne energije. Ove se metode oslanjaju na povijesne podatke i statističke tehnike za predviđanje budućih obrazaca potrošnje energije. Iako su se posljednjih godina pojavili modeli računalne inteligencije, klasične metode predviđanja opterećenja još uvijek imaju značajnu ulogu u upravljanju i planiranju energije.

4.1.1. Metoda regresijske analize

Metoda regresijske analize (eng. *Regression analysis method*) može se koristiti za predviđanje kratkoročnog opterećenja. Regresijska analiza je matematički alat koji može uspostaviti statističke korelacije varijabli i pruža informacije o odnosu između parametara koji se mogu istražiti ispitivanjem njihove veličine i trenda. Regresijska analiza dopušta upotrebu višestrukih parametara i predviđa ishode čak i kada postoji više međusobnih parametara, što je čini razvijenijom u odnosu na pojednostavljene analize temeljene na međusobno povezanim varijablama. Također, regresijska analiza omogućuje ispravljanje pogrešaka proizašlih iz zaključaka na temelju prethodnih rezultata, a dobri rezultati mogu se dobiti s relativno skromnim skupovima podataka. Stoga je regresijska analiza vrijedan alat za predviđanje kratkoročnog opterećenja [4].

4.1.2. Metoda vremenskih nizova

Standardizirani pristup koji pomaže u rješavanju matematičkih i statističkih pitanja koja postavljaju vremenske korelacije, poznat je kao metoda vremenskih nizova (eng. *Time series method*). Poznata je po širokoj upotrebi tehničkih elemenata kao i matematičkih postupaka, uključujući mnoge jednadžbe. Prednost metode vremenskih nizova je njena sposobnost da se nosi s velikim brojem vremenskih sekvencionalnih promatranja koja su jednako razmaknuta [5]. Metoda je jednostavna, praktična i učinkovita, ali može opisati samo linearni model, te ima neka ograničenja.

4.1.3. Ekstrapolacija trenda

Ekstrapolacija trenda (eng. *Trend extrapolation*) je metoda koja se obično koristi u predviđanju opterećenja za predviđanje buduće potrošnje energije ili potražnje na temelju povijesnih podataka i utvrđivanja temeljnih trendova. Ekstrapolacija trenda uključuje analizu povijesnih podataka o opterećenju tijekom određenog razdoblja i identificiranje dugoročnih obrazaca ili trendova koji se promatraju. Ti trendovi mogu biti uzlazni (povećanje opterećenja

tijekom vremena), silazni (smanjenje opterećenja tijekom vremena) ili čak ravni (bez značajne promjene opterećenja).

4.2. Matematički modeli

Matematički modeli za predviđanje opterećenja u električnim sustavima dizajnirani su za predviđanje buduće potražnje za električnom energijom na temelju povijesnih podataka i relevantnih čimbenika.

4.2.1. Višestruka regresija

Višestruka regresija (eng. *Multiple regression*) je model koji koristi tehniku procjene najmanjeg kvadrata i pomaže u razvijanju odnosa između opterećenja, vremenskih uvjeta, vrste dana i klase potrošača. Za analizu izmjerene opterećenja primijenjuje se izraz (1), gdje je t vrijeme uzrokovanja, Y_t je izmjereno opterećenje, v_t je vektor prilagodljive varijable kao što su vrijeme, temperature, tip dana, te e_t predstavlja pogrešku modela u trenutku t [3].

$$Y_t = v_t a_t + e_t \quad (1)$$

4.2.2. Eksponencijalno izgladivanje

Eksponencijalno izgladivanje (eng. *Exponential smoothing*) je model predviđanja koji koristi prethodno opterećenje za predviđanje budućeg opterećenja. Ovaj model omogućuje smanjenje pogreške u predviđanju potražnje za 12% u usporedbi s klasičnim modelom predviđanja. Funkcija opterećenja modelirana je kao funkcija prilagodbe i matematički prikazana u izrazu (2), gdje je $Y(t)$ opterećenje u trenutku t , $f(t)$ je vektor funkcije prilagodne procesa, $\beta(t)$ je vektor koeficijenta, $\varepsilon(t)$ je bijeli šum i T je transponirani operator [3].

$$Y(t) = \beta(t)^T * f(t) + e(t) \quad (2)$$

4.2.3. Iterativna metoda najmanjih kvadrata

Iterativna metoda najmanjih kvadrata (eng. *Iterative reweighted least-squares*) koriste se za identifikaciju poretka i parametara modela. Jednadžba linearnog mjerenja prikazana je u izrazu (3).

$$Y = X\beta + e \quad (3)$$

Gdje je $Y = n \times 1$ je vektor promatranja, $X = n \times p$ je matrica poznatog koeficijenta (prethodni podaci opterećenja), $\beta = p \times 1$ je vektor nepoznatih parametara i $e = n \times 1$ je vektor slučajne pogreške. Nepoznati vektor β može se pronaći iterativnom metodom. Ako je β poznat, tada se mogu koristiti Newton ili Beaton-Turkey iterativne metode najmanjih kvadrata [3].

4.2.4. Autoregresivna metoda

Autoregresivna metoda (eng. *Autoregressive - AR*) je stohastički model vremenske serije. U ovom modelu opterećenje se pretpostavlja kao linearna kombinacija prethodnih podataka o opterećenju. Matematički se može prikazati kao što je vidljivo u izrazu (4).

$$L_k = \sum_{i=1}^m a_{ik} L_{k-1} + w_k \quad (4)$$

L_k predstavlja predviđeno opterećenje u vremenu k jedinica, w_k je slučajni poremećaj opterećenja i a_i gdje $i = 1, 2, 3, \dots, m$ su nepoznati koeficijenti [3].

4.2.5. Pomični prosjek

Pomični prosjek (eng. *Moving average - MA*) je model u kojem se trenutna vrijednost vremenske serije $Y(t)$ i izražava se u smislu linearne kombinacije trenutnih i prethodnih vrijednosti serije bijelog šuma. Matematički izraz je prikazan u izrazu (5):

$$Y(t) = a(t) - \phi_1 a(t-1) - \phi_2 a(t-2) - \dots - \phi_q a(t-q) \quad (5)$$

Operator pomaka unazad na bijelom šumu modificiran jednažbu (6) na sljedeći način:

$$Y(t) = \phi(B)a(t) \quad (6)$$

Gdje je:

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_q B^q \quad (7)$$

4.2.6. Autoregresivni pomični presjek

Autoregresivni pomični presjek (eng. *Autoregressive moving average - ARMA*) je model u kojem su trenutne vrijednosti vremenske serije $Y(t)$ izražene linearno u odnosu na prethodno razdoblje ($y(t-1), y(t-2), \dots$) i trenutne i prethodne vrijednosti bijelog šuma ($a(t), a(t-1), a(t-2), \dots$). Matematički model prikazan je u izrazu (8):

$$Y(t) = \phi_1 y(t-1) + \dots + \phi_p y(t-p) + a(t-1) + \dots + \phi_q a(t-q) \quad (8)$$

U ovom izrazu vremenska serija mjesečnog vršnog opterećenja razdvojena je na determinističku i stohastičku komponentu, koju je kasnije odredio autoregresivni model. Adaptivni model autoregresivnog pomičnog presjeka za predviđanje opterećenja koristi dostupnu pogrešku prognoze za ažuriranje parametara modela [3].

4.2.7. Autoregresivni integrirani pomični prosjek

Prethodno definirane vremenske serije bili su stacionirani procesi. Ako je proces nestacioniran, treba ga transformirati u stacionirani proces. Da bi se postigao taj proces, potrebno

je provesti proces diferenciranja uvođenjem ∇ operatora u jednadžbu. Matematički model zapisan je u izrazu (9).

$$\phi(B)\nabla^d y(t) = (B)a(t) \quad (9)$$

Ovaj model koristi komponente za predviđanje rasta opterećenja sustava, vremensku komponentu za predviđanje opterećenja osjetljivog na vremenske uvjete, a autoregresivni integrirani pomični prosjek koristi se za proizvodnju cikličke nevremenske komponente tjednog vršnog opterećenja. Sezonski autoregresivni integrirani pomični prosjek koristi povijesne podatke za predviđanje sezonskih varijacija opterećenja [3].

4.2.8. Kalman filter

Predviđanjem, posebice dugoročno predviđanje opterećenja, karakterizira visoka razina nezvjesnosti zbog velike ovisnosti o socioekonomskim čimbenicima te je zbog toga prihvatljiva razina pogreške do 10%. Primjena Kalmanovog algoritma za filtriranje može značajno minimizirati srednju kvadratnu vrijednost pogreške modela. Kalmanov filter je skup matematičkih jednadžbi u prostoru stanja koji može pružiti učinkovito računalno (rekurzivno) sredstvo za procjenu stanja promatranog procesa, a intenzivno se koristi za praćenje u iterativnoj računalnoj grafici. Koristio se za predviđanje kretanja, a koristio se i za višesezonsku fuziju. Naime, ovaj filter je vrlo moćan u nekoliko drugih aspekata: podržava procjene prošlih, sadašnjih i budućih stanja, čak i kada je točna priroda modeliranog sustava nepoznata. Kalmanov filter također je moćan alat kada se radi o upravljanju bučnim sustavima, u koje se nedvojbeno mogu svrstati elektroenergetski sustavi.

Glavni elementi koji utječu na ponašanje električnog opterećenja mogu se klasificirati na sljedeći način:

- Vremenske prilike
- Vrijeme
- Ekonomija
- Nasumične smetnje
- Utjecaj korisnika

Navedeni faktori mogu se unijeti kao ulazni podaci u Kalmanov filter. Budući da je izuzetno teško nositi se sa složenim ulaznim podacima (ekonomija, nasumične smetnje i utjecaj kupaca). Obično su uključeni samo čimbenici vremenskih prilika i vremena [6].

4.3. Modeli računalne inteligencija

Tradicionalni statistički modeli ograničeni su i ponekad mogu dovesti do nezadovoljavajućih rješenja. Razlog je prevelik broj računalnih mogućnosti što dovodi do dužeg vremena rješavanja te složenosti nelinearnih obrazaca podataka. Stoga strojno učenje i tehnike temeljene na umjetnoj inteligenciji pružaju obećavajuću i bolju alternativu [6].

4.3.1. Metoda umjetne neuronske mreže

Pristup umjetne neuronske mreže (eng. *Artificial Neural Network - ANN*) otkrili su 1990. Warren McCulloch i Walter Pitts kao alternativni mehanizam za predviđanje vremenskih serija. ANN su uspješno primijenjene u mnogim različitim područjima, posebno za predviđanje i klasifikaciju. Modeli ANN-a korišteni su i intenzivno proučavani kao alat koji se koristi za predviđanje električnog opterećenja i stekle su veliku popularnost u posljednjih nekoliko desetljeća.

U osnovi, neuronska mreža je nelinearni sklop koji je sposoban izvršiti nelinearno prilagođavanje krivulje. Predstavlja paradigmu obrade informacija koja je inspirirana načinom na koji biološki sustavi čovjeka, poput mozga, mogu obraditi određenu informaciju. U ovom procesu, ANN-ovi pokušavaju prepoznati pravilnosti i obrasce u ulaznim podacima, uče iz iskustva, a zatim daju generalizirane rezultate na temelju svog poznatog prethodnog znanja. ANN se sastoji od nekoliko međusobno povezanih procesnih elemenata, koji se nazivaju neuroni, koji mijenjaju svoje dinamičko stanje u odnosu na vanjske ulaze.

Autori u literaturi [6] navode najčešće korištene algoritme ANN-a za predviđanje električnog opterećenja:

- Neuronske mreže s unaprijednim prijenosom podataka (eng. *Feed-forward neural network*)
- Nelinearne autoregresivne s egzogenim ulazima neuronske mreže (eng. *Nonlinear autoregressive with exogenous input neural network- NARX*)
- Neuronske mreže povratnog širenja (eng. *Back-propagation neural network*)
- Neuronske mreže radijalne bazične funkcije (eng. *Radial basis function neural network*)
- Slučajne neuronske mreže (eng. *The random neural network*)
- Ponavljajuće neuronske mreže (eng. *Reccurent neural networks*)
- Samoorganizirajuće kompetitivne neuronske mreže (eng. *Self-organizing competative neural networks*)

Nelinearne autoregresivne s egzogenim ulazima neuronske mreže obično nadmašuju klasične neuronske mreže. Naime, nelinearne autoregresivne s egzogenim ulazima neuronske mreže, zajedno s neuronskim mrežama radijalne bazične funkcije, posjeduju izvrsna svojstva kao što su njihova jednostavnost, pouzdanost, nizak postotak pogreške, visoka točnost i sposobnost stvaranja nelinearnih odnosa između varijabli. Nelinearne autoregresivne s egzogenim ulazima neuronske mreže i neuronske mreže radijalne bazične funkcije pružaju vrlo precizno predviđanje opterećenja za pet dana unaprijed, dok se relativna pogreška nalazi između 0,1% i 3,9%.

ANN modeli se mogu klasificirati u dvije glavne skupine:

- Prva skupina uključuje one ANN koje imaju samo jedan izlazni čvor, koji se koristi za predviđanje opterećenja sljedećeg sata, vršnog opterećenja sljedećeg dana ili ukupnog opterećenja sljedećeg dana.
- Druga skupina uključuje modele koji imaju nekoliko izlaznih čvorova za predviđanje slijeda opterećenja po satu, obično 24 čvora, sa svrhom predviđanja cijelog profila opterećenja za sljedeći dan.

Druga skupina ima jaku robusnost i snažnu sposobnost učenja. Međutim, ANN brzo pada u lokalni minimum zbog ograničenja sposobnosti generalizacije i ne može u potpunosti iskoristiti informacije zbog male odabrane veličine uzoraka. Osim toga, brzina konvergencije učenja je spora [6].

4.3.2. Metoda potpornih vektora

Metoda potpornih vektora (eng. *Support vector machine - SVM*) je regresijski i klasifikacijski mehanizam, koji je predstavio Vapnik 1992. godine. Kasnije, 1995. godine, Cortes i Vapnik su predložili klasifikatore meke margine koristeći teoriju statičkog učenja. U početku su SVM razvijeni za rješavanje problema klasifikacije uzoraka (npr. identifikacija lica, optičko prepoznavanje znakova, rana medicinska dijagnostika, klasifikacija teksta itd.). nakon toga, Vapnik je proširio upotrebu SVM-a koje će koristiti i za regresijske algoritme. Tijekom posljednja dva desetljeća, SVM su dobili sve veću pozornost ne samo za prepoznavanje uzoraka i regresijsku analizu, već i za potrebe predviđanja i rješavanja problema predviđanja vremenskih nizova. Glavni cilj SVM-a je zaključiti specifično pravilo odlučivanja sa zadovoljavajućom sposobnošću generalizacije odabirom nekog specifičnog podskupa podataka za obuku, koji se nazivaju vektori podrške.

U SVM modelima primjenjuje se nelinearno preslikavanje ulaznog prostora u višedimenzionalni prostor značajki, a nakon toga se izdvaja optimalno razdvajajuća hiperravnina. Sukladno tome, složenost i kvaliteta SVM-a rješenja ne ovise izravno o ulaznom prostoru. Prilikom projektiranja SVM modela provodi se proces obuke koje je usporediv s rješavanjem problema linearno ograničenog kvadratnog programiranja. Stoga se, nasuprot obuci drugih mreža, SVM rješenja čine uvijek globalno optimalnima i jedinstvenima. S druge strane, glavna slabost SVM-a je to što zahtijeva ogromnu količinu izračunavanja, a posljedično, vremenska složenost rješenja je radikalno povećana [6].

Cilj SVM-a je pronaći hiperravninu u N-dimenzionalnom prostoru (N-broj značajki) koja jasno klasificira podatkovne točke. Za razdvajanje dviju klasa podatkovnih točaka postoji mnogo mogućih hiperravnina koje se mogu odabrati. Cilj je pronaći ravninu koja ima najveću marginu, tj. najveću udaljenost između podatkovnih točaka obje klase. Maksimiziranje udaljenosti margine daje određeno pojačanje tako da se buduće podatkovne točke mogu klasificirati s više povjerenja.

Hiperravnine su granice odlučivanja koje pomažu u klasifikaciji podatkovnih točaka. Podatkovne točke koje padaju s obje strane hiperravnine mogu se pripisati različitim klasama. Također, dimenzija hiperravnine ovisi o broju značajki. Ako je broj ulaznih značajki 2, tada je hiperravnina samo linija. Ako je broj ulaznih značajki 3, tada hiperravnina postaje dvodimenzionalna ravnina. Potporni vektori su podatkovne točke koje su bliže hiperravnini i utječu na položaj i orijentaciju hiperravnine. Koristeći ove potporne vektore, maksimiziramo marginu klasifikatora. Brisanjem nosivih vektora promijenit će se položaj hiperravnine, te su to točke koje pomažu izgraditi SVM.

5. OPIS MODELA ZA PREDVIĐANJA OPTEREĆENJA ELEKTRIČNE ENERGIJE

5.1. Distribucijska mreža Baranje

Predviđanje opterećenja izvršeno je na 35 kV mreži Baranje, koja je prikazana na slici 5.1. Prikazana mreža je radijalna. Autori u literaturi [7] su radijalnu mrežu definirali: „Radijalne niskonaponske mreže su najjednostavnije i najekonomičnije, tako da se ovo rješenje najviše koristi u praksi. Zbog nemogućnosti rezervnog napajanja, kvar na bilo kojem mjestu u mreži izaziva prekid napajanja kompletnog izvoda na kojem se dogodio kvar.“


Mreža Baranje sadrži pet transformatorskih stanica 35/10 kV i to su: Beli Manastir, Branjin Vrh, Kneževi Vinogradi, Draž i Bilje. 110 kV mreža je spojena na transformatorsku stanicu Beli Manastir. Iz Belog Manastira idu dva voda, jedan vod ide prema transformatorskoj stanici Branjin Vrh, dok drugi vod ide prema transformatorskoj stanici Kneževi Vinogradi. Iz transformatorske stanice Kneževi Vinogradi idu također dva voda, jedan vod ide prema transformatorskoj stanici Draž, dok drugi vod ide prema transformatorskoj stanici Bilje. Sve transformatorske stanice rade na jednom transformatoru 35/10 kV, dok je drugi transformator isključen i služi kao rezerva. Dva transformatora mogu raditi u paraleli, ali trenutačno nije potrebno jer je opterećenje premalo.

Na slici 5.1. zelenom bojom prikazane su sve mjerne točke. U transformatorskim stanicama Branjin Vrh, Bilje i Kneževi Vinogradi postoje tri mjerne točke. Jedna se nalazi ispred transformatorske stanice na 35 kV strani, dok se druge dvije nalaze u trafo polju na 35 kV strani i na 10 kV strani. U transformatorskoj stanici Draž nalaze se dvije mjerne točke i one se nalaze u trafo polju na 35 kV strani i na 10 kV strani.

Na slici 5.1. može se vidjeti elektrane koje su povezane na transformatorske stanice. Navedene su samo elektrane koje su veće od 0.3 MW. U transformatorskoj stanici Branjin Vrh nalazi se bioplinska elektrana, snage 1.8 MW puštena u pogon 2015. godine. U transformatorskoj stanici Kneževi Vinogradi nalaze se dvije bioplinske elektrane i jedna sunčana elektrana. Bioplinske elektrane su snage 2 MW i jedna je puštena u pogon 2013. godine, dok je druga puštena u pogon 2014. godine. Sunčana elektrana je snage 0.3 MW i puštena je u pogon 2014. godine. U transformatorskoj stanici Bilje nalaze se bioplinska elektrana i sunčana elektrana. Bioplinska elektrana je snage 0.5 MW i 2017. godine je puštena u pogon, dok je sunčana elektrana snage 0.3 MW i 2013. godine je puštena u pogon.

Predviđanje opterećenja će se izvršiti na četiri transformatorske stanice i to su: Branjin Vrh, Bilje, Kneževi Vinogradi i Draž. Predviđanje opterećenja se neće vršiti na transformatorskoj stanici Beli Manastir jer je trafostanica trenutno pod rekonstrukcijom. Također, za predviđanje opterećenja koristit se podatci koji su izmjereni na 10 kV strani trafo polja, na strani koja je bliže teretu. Teret je na slici 5.1. označen crvenom bojom.

35 kV MREŽA BARANJE



Slika 5.1. Distribucijska mreža Baranje

5.2. Godišnje opterećenje električnom energijom

Prije predviđanja opterećenja, proučena su godišnja opterećenja do 2023. godine za četiri navedene transformatorske stanice na 10 kV strani. U tablici 5.1. prikazana su godišnja opterećenja, te su godišnja opterećenja slikovitije prikazana na slici 5.2.

Tablica 5.1. Godišnja opterećenja

Godina	P [MW]			
	Branjin Vrh	Bilje	Draž	Kneževi Vinogradi
2016	1.42051582	3.341448556	0.357714017	0.560667114
2017	1.238667039	3.136148719	0.36457583	0.493991028
2018	0.988549856	2.850676011	0.424848863	0.363951649
2019	0.013226185	3.029431066	0.552445461	0.261909266
2020	-0.040013182	3.065721843	0.526230065	0.209390016
2021	0.010124698	3.037473252	0.53521886	0.239549813
2022	-0.075834161	2.971608736	0.51629251	0.128152479

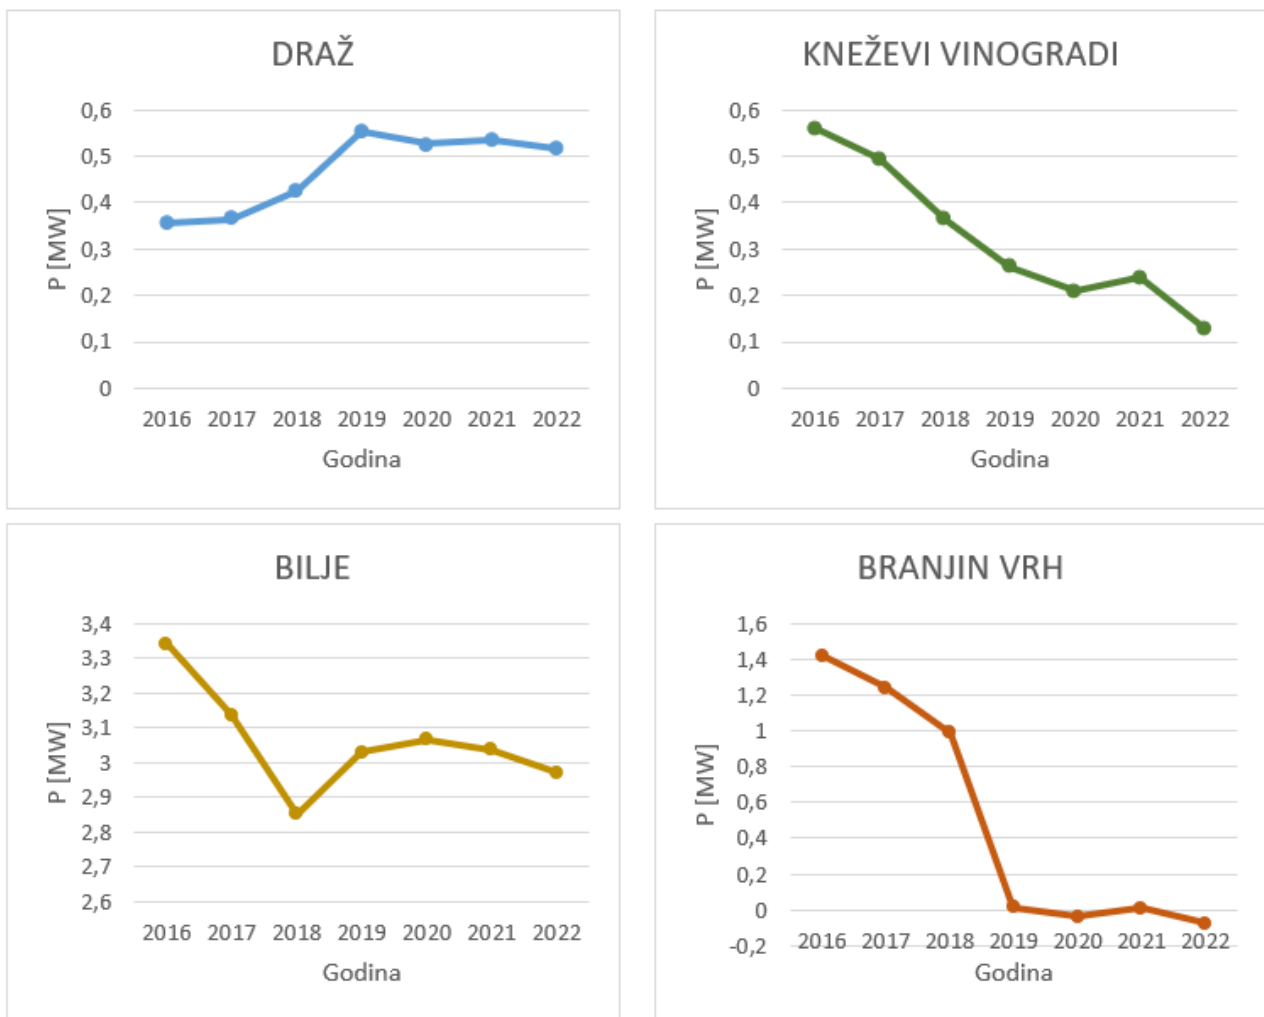
Prvi graf prikazuje opterećenje transformatorske stanice Draž. Iz grafa je vidljivo kako nakon 2017. godine dolazi do veće potražnje za energijom, te nakon 2019. godina pa sve do 2022. godine, potražnja za energijom je podjednaka.

Drugi graf prikazuje opterećenje transformatorske stanice Kneževi Vinogradi. Na grafu je prikazana krivulja gdje je vidljivo da se opterećenje s godinama smanjuje. U transformatorskoj stanici Kneževi Vinogradi nalaze se tri elektrane, te nakon puštanja u pogon elektrana dolazi do smanjenja opterećenja.

Treći graf prikazuje opterećenje transformatorske stanice Bilje. Iz grafa se vidi kako se potražnja za energijom smanjuje do 2018. godine, te nakon 2018. godine dolazi do veće potražnje za energijom. U Bilju postoji elektranu koja je puštena u pogon 2015. godine, te nakon njenog puštanja u pogon dolazi do smanjena opterećenja.

Četvrti graf prikazuje opterećenje transformatorske stanice Branjin Vrh. Iz grafa je vidljivo da se opterećenje s godinama smanjuje, te od 2019. godine vrijednosti opterećenja su ispod 0. To znači da energija mijenja smjer, odnosno elektrana usmjerava energiju sa 10 kV strane prema 35 kV strani. Događa se obrnuta situacija, elektrana je prejaka u odnosu na teret i usmjerava energiju u obrnutom smjeru. U Branjinom Vrh se nalazi elektranu koja je puštena u pogon 2015. godine,

snage 1.8 MW. Iz grafa je vidljivo da je elektrana srušila opterećenje sa 1.4 MW na vrijednosti ispod 0.



Slika 5.2. Godišnja opterećenja za Draž, Kneževe Vinograde, Bilje i Branjin Vrh

5.3. Model

Predviđanja opterećenja u ovom diplomskom radu radit će se u programu „Orange“ [8]. Povijest programa „Orange“ seže do 1997. godine i nastao je na sveučilištu u Ljubljani. „Orange“ je program koji se koristi za vizualizaciju podataka, strojno učenje i rudarenje podataka otvorenog koda.


Na slici 5.3. prikazana je podjela elemenata programa:

- Podaci (eng. *Data*) – služi za unos podataka, filtriranje podataka, uzimanje uzoraka, manipulaciju značajkama i izbor značajki
- Transformirati (eng. *Transform*) – služi za strukturiranje unesenih podataka

- Vizualizirati (eng. *Visualize*) – sadrži elemente za vizualizaciju podataka i multivarijantnu vizualizaciju
- Model (eng. *Model*) – skup nadziranih algoritama strojnog učenja za regresiju i klasifikaciju
- Ocijeniti (eng. *Evaluate*) – unakrsna provjera valjanosti, postupci temeljeni na uzrokovanju i procjena pouzdanosti
- Bez nadzora (eng. *Unsupervised*) – algoritmi učenja bez nadzora za grupiranje i tehnike projekcije podataka
- Dodaci (eng. *Add-ons*) – program omogućuje instaliranje raznih dodataka (u ovom slučaju je to *Time Series*)

	Data
	Transform
	Visualize
	Model
	Evaluate
	Unsupervised
	Time Series

Slika 5.3. Glavni elementi programa



Slika 5.4. Model za predviđanje opterećenja

Na slici 5.4. prikazan je model koji će se koristiti u ovom radu za predviđanje opterećenja primjenom metode neuronskih mreža (NN). Primijenjeni model sastoji se od četiri faze. Prvi korak je priprema podataka, drugi korak je odabir atributa, treći korak je validacija odabranih atributa i četvrti korak je predviđanje opterećenja.

Priprema podataka na slici 5.4 predstavlja ekstrahiranje i diskretizaciju. Priprema podataka uključuje čišćenje, transformaciju i organiziranje podataka u format prikladan za analizu, te je to početak postupka rudarenja podataka. Rezultati rudarenja podataka oslanjaju se na kvalitetu podataka pripremljenih prije procesa rudarenja. Rudarenje je postupak koji zahtjeva obavljanje različitih zadataka te se taj proces ne može automatizirati.

Odabir atributa na slici 5.4. predstavlja iteraciju u krug, označenu crvenim strelicama. U procesu odabira atributa, biraju se statistički atributi. Neki od ponuđenih statističkih atributa su: median, mode, minimum, maksimum, standardna devijacija, lineari pomični presjek, eksponencijalni pomični presjek... Cijeli proces odabira atributa je zapravo metoda pokušaja i pogrešaka. Različitim kombinacijama atributa nastoji se doći do kombinacije koja će najbolje odgovarati.

Validacija atributa na slici 5.4. uključuje ROC analizu (eng. *Receiver operating characteristic - ROC Analysis*), te se ikonu može pronaći u gornjem desnom kutu. Na slici 5.5. prikazana je ROC krivulja. Autor u literaturi [9] ROC krivulju opisuje kao krivulju vjerojatnosti koja se iscrtava sa istinski pozitivnom stopom (eng. *true positive rate - TPR*) na y-osi i sa lažno pozitivnom stopom na x-osi (eng. *false positive rate - FPR*). TPR, također je poznat kao osjetljivost, te se izračunava prema izrazu (10):

$$TPR = \frac{TP}{TP+FN} \quad (10)$$

TP predstavlja istinski pozitivne vrijednosti (eng. *true positive - TP*), dok FN predstavlja lažno negativne vrijednosti (eng. *false negative - FN*).


Dobar model će pokušati izbjeći lažno negativne rezultate kako bi postigao dobar TPR rezultat. Istinski negativna stopa (eng. *true negative rate - TNR*) ili specifičnost je mjera izvedbe modela u stvarnim negativima. Dobar model pokušava izbjeći lažno pozitivne rezultate kako bi imao dobre rezultate, te je to prikazano u izrazu (11):

$$TNR = \frac{TN}{TN+FP} \quad (11)$$

Gdje TN predstavlja istinski negativne vrijednosti (eng. *true negative - TN*), dok FP predstavlja lažno pozitivne vrijednosti (eng. *false positive - FP*).

FPR mjeri performanse u smislu promašaja u TNR-u, izračunava se prema izrazu (12):

$$FPR = 1 - TNR \quad (12)$$



Slika 5.5. ROC krivulja

Predviđanja opterećenja na slici 5.4. predstavljaju posljednje tri ikone: *predictions*, *tree* i *tree viewer*. *Tree* i *tree viewer* koriste se za vizualni prikaz podataka.

6. PROGNOZA PREDVIĐANJA OPTEREĆENJA ZA NAREDNI KVARTAL

Kao što je spomenuto u ranijem poglavlju, za primjer prognoze predviđanja opterećenja električne energije korištena je 35 kV mreža Baranje. Simulacijski se dio odvija u programu „Orange“, a za predviđanje opterećenja korišteni su podaci sa 10 kV strane trafo polja. Prognoza predviđanja električne energije izvršena je za naredni kvartal (srpanj, kolovoz i rujan 2023. godine, tj. 2023-3), te se ono svrstava u srednjoročno predviđanje opterećenja. U modelu kojeg se koristi za predviđanje opterećenja primjenjuje se metoda neuronskih mreža (NN).

U ovom diplomskom radu predviđanje opterećenja električne energije provesti će se na četiri transformatorske stanice:

1. TS Bilje
2. TS Branjin Vrh
3. TS Draž
4. TS Kneževi Vinogradi


6.1. Predviđanje opterećenja električne energije za TS Bilje

Za ulazne podatke za predviđanje opterećenja električne energije su se uzimali svi kvartali od 1.1.2016. godine do 1.7.2023. godine, što bi kumulativno bilo 30 podataka. Podaci za TS Bilje prikazani su u tablici 6.1., te su slikovitije prikazani na slici 6.1.

Tablica 6.1. Kvartalno opterećenje TS Bilje

KVARTAL	P [MW]
2016-1	3.68
2016-2	2.97
2016-3	2.93
2016-4	3.78
2017-1	3.78
2017-2	2.88
2017-3	2.71
2017-4	3.18
2018-1	3.23
2018-2	2.38
2018-3	2.52
2018-4	3.27
2019-1	3.36
2019-2	2.75
2019-3	2.73


KVARTAL	P [MW]
2019-4	3.28
2020-1	3.31
2020-2	2.75
2020-3	2.85
2020-4	3.35
2021-1	3.34
2021-2	2.71
2021-3	2.70
2021-4	3.40
2022-1	3.35
2022-2	2.66
2022-3	2.62
2022-4	3.25
2023-1	3.38
2023-2	2.70



Slika 6.1. Kvartalno opterećenje TS Bilje


Prvi korak u programu je učitati podatke. Dvostrukim klikom na prvu ikonu *File* otvara se prozor prikazan na slici 6.2., a nakon što se otvorio novi prozor, potrebno je kliknuti na ikonu *Open* te odabrati .xlsx dokument u kojem se nalaze podaci za TS Bilje. Zatim u prozoru *Columns* za P[MW] *Role* postaviti na *target*, dok je ostale potrebno postaviti na *skip*. Time su podaci iz stupca

s opterećenjima odabrani kao ulazni podaci za prognoziranje dok će ostali stupci biti zanemareni. Nakon što je sve postavljeno, potrebno je kliknuti na gumb *Apply*, te zatvoriti prozor *File*.




Slika 6.2. File prozor za učitavanje podataka

U idućem koraku dvostrukim klikom na ikonu *Moving Transform* otvara se prozor koji je vidljiv na slici 6.3. U tom prozoru se odabiru statistički atributi kao i broj godina za koje se uzimaju podaci. Kako bi se dobili zadovoljavajući rezultati, broj atributa treba biti manji od deset. U ovoj simulaciji, broj godina koje se uzimaju pri predviđanju je pet, a to se postavlja u gornjem lijevom kutu u opciji *Window width*.



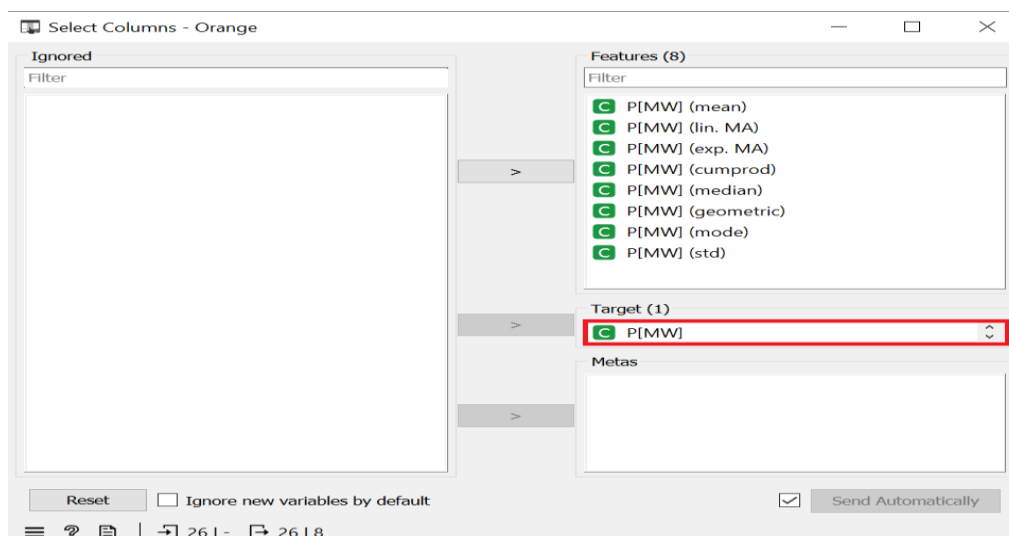
Slika 6.3. Moving Transform prozor

Sljedeći korak je dvostruki klik na ikonu *Discretize*, nakon toga se otvara novi prozor koji je prikazan na slici 6.4. Diskretizacija je bitan dio pripreme podataka, a njome se unesene vrijednosti dijele u intervale. U ovom slučaju korišteni broj intervala je 7, kao što je prikazano na slici 6.4.




Slika 6.4. Discretize prozor

Naredni korak je odabir atributa pomoću kojih će se vršiti predviđanje opterećenja. Dvostruki klik na ikonu *Select Columns* otvara novi prozor koji je vidljiv na slici 6.5. U polje *Target* postaviti P[MW], dok ostali atributi ostaju u polju *Features*. Nakon što su odabrani atributi, program je već izvršio prognozu.




Slika 6.5. Select Columns

Sljedeći korak je validacija rezultata. Dvostrukim klikom na ikonu *ROC Analysis* otvara se novi prozor prikazan na slici 6.6. Na slici je vidljiva ROC krivulja, te je vrlo važno da krivulja prvo ide prema gore pa tek onda desno do točke (1,1), gdje svaka krivulja treba završit.




Slika 6.6. ROC krivulja za interval <2.58 (dobra)

ROC krivulja uspoređuje attribute sa numeričkom mrežom, te pokazuje koliko su rezultati dobri. Ako se krivulja nalazi iznad iscrtanog pravca koji je pod 45°, tada su rezultati zadovoljavajući. Potrebno je provjeriti u kojem intervalu su rezultati točniji. Na slici 6.6. prikazana je krivulja za interval <2.58. U slučaju da krivulja prvo ide desno pa tek onda gore, kao na slici 6.7., to znači da krivulja nije dobra i da točnost neće biti dobra.




Slika 6.7. ROC krivulja (loša)

Idući interval u kojem je ROC krivulja zadovoljavajuća je interval < 2.58,2.78 >, te je prikazana na slici 6.8. U ovom slučaju postoje dva moguća ishoda, te kako bi se odredilo koji interval je vjerojatniji, potrebno je pogledati koji interval ima veću vjerojatnost.




Slika 6.8. ROC krivulja za interval $\langle 2.58, 2.78 \rangle$

Posljednji korak je prikaz vjerojatnosti. Dvostrukim klik na ikonu *Tree Viewer* otvara se prozor koji je vidljiv na slici 6.9. Na slici je vidljiv postotak vjerojatnosti za ciljani razred (eng. *target class*), u opisanom slučaju $\langle 2.58$, te on iznosi 15.4%.




Slika 6.9. Tree viewer za interval $\langle 2.58$

Za drugi mogući interval, postotak vjerojatnosti je prikazan na slici 6.10. i iznosi 69.2%. Na temelju dobivenih rezultata može se zaključiti da se opterećenje električne energije za naredni kvartal, za TS Bilje, nalazi u intervalu $\langle 2.84$ MW.



Slika 6.10. Tree viewer za interval $\langle 2.58, 2.78 \rangle$

Također, izborom statističkih atributa moguće je utjecati na vjerojatnost. Kako bi se uočio utjecaj atributa na vjerojatnosti, potrebno je vratiti se na ikonu *Select Columns* i neke od atributa prebaciti u prozor *Ignored*. Atributi koji su postavljeni u prozor *Ignored* su: *mode*, *standard deviation*, *geometric mean* i *median*. Dobivena ROC krivulja vidljiva je na slici 6.11. za interval $\langle 2.58, 2.78 \rangle$, pri čemu postotak vjerojatnosti iznosi 61.5% i prikazan je na slici 6.12.



Slika 6.11. ROC krivulja za interval $\langle 2.58, 2.78 \rangle$



Slika 6.12. Tree viewer za interval $\langle 2.58, 2.78 \rangle$


Iz dobivenih rezultata je vidljivo da izbor atributa utječe na postotak vjerojatnosti. U drugom slučaju je postotak manji za 7.7%. Interval vjerojatnosti opterećenja za TS Bilje u obje situacije je $\langle 2.84 \text{ MW}$, ali zbog većeg postotka odlučili bi se na izbor svih statističkih atributa. Program za predviđanje opterećenja nikad ne daje točno jednu vrijednost, nego uvijek daje vrijednosti izražene u intervalima. Također, podaci za prethodne godine, za treći kvartal, mogu pomoći u odabiru intervala opterećenja. Na temelju prethodnih podataka i na temelju rezultata dobivenih predviđanjem dolazi se do zaključka da će se opterećenje, za naredni kvartal, za TS Bilje nalaziti u intervalu $\langle 2.84 \text{ MW}$ s vjerojatnosti 69.2%.

6.2. Predviđanje opterećenja električne energije za TS Branjin Vrh

Za ulazne podatke za predviđanje opterećenja električne energije, kao i u prethodnom slučaju, uzimani su svi kvartali od 1.1.2016. godine do 1.7.2023. godine. Podaci za TS Branjin Vrh prikazani su u tablici 6.2., te je opterećenje slikovitije prikazano na slici 6.13.

Tablica 6.2. Kvartalno opterećenje TS Branjin Vrh


KVARTAL	P [MW]	KVARTAL	P [MW]
2016-1	1.6	2019-4	0.07
2016-2	1.24	2020-1	0.17
2016-3	1.28	2020-2	-0.23
2016-4	1.56	2020-3	-0.22
2017-1	1.66	2020-4	0.12
2017-2	1.18	2021-1	0.12
2017-3	1.1	2021-2	-0.11
2017-4	1.01	2021-3	-0.13
2018-1	0.99	2021-4	0.16
2018-2	1.26	2022-1	0.21
2018-3	1.23	2022-2	-0.23
2018-4	0.48	2022-3	-0.29
2019-1	0.25	2022-4	0.01
2019-2	-0.07	2023-1	0.03
2019-3	-0.2	2023-2	-0.33



Slika 6.13. Kvartalno opterećenje TS Branjin Vrh

Za predviđanje opterećenja za TS Branjin Vrh koristit ćemo isti postupak kao i u prethodnom slučaju, te je potrebno ponoviti sve korake sa uključenim svim atributima u ikoni *Select Columns*.


Nakon što su izvršeni svi koraci, sljedeći korak je ROC krivulja. Dobivena zadovoljavajuća ROC krivulja sa uključenim svim atributima, za interval $\langle 0.2386, 0.5229 \rangle$, vidljiva je na slici 6.14.



Slika 6.14. ROC krivulja za interval $\langle 0.2386, 0.5229 \rangle$

Dobiveni postotak vjerojatnosti iznosi 20%, te na temelju dobivenih rezultata zaključuje se da opterećenje električne energije za naredni kvartal, za TS Branjin vrh, nalazi u intervalu $\langle 0.07, 0.30 \rangle$ MW.


Također, i za ovaj slučaj nastoji se postaviti neke od atributa u prozor *Ignored*, kako bi se uočio njihov utjecaj. Kao i u prvom slučaju u prozor *Ignored* stavit ćemo statičke attribute: *mode*, *standard deviacion*, *geometric mean* i *median*. Dobivena zadovoljavajuća ROC krivulja prikazana je na slici 6.15.



Slika 6.15. ROC krivulja za interval $\langle 0.2386, 0.5229 \rangle$


Dobiveni postotak vjerojatnosti i u ovom slučaju iznosi 20%, te se i u ovom slučaju opterećenje električne energije za naredni kvartal nalazi u intervalu $\langle 0.07, 0.30 \rangle$ MW.

Ukoliko se ponovno izberu atributi, no ovoga puta u prozor *Ignored* postave sljedeće vrijednosti: *mean, mode, standard deviacion i geometric mean*, a ostali statistički atributi ostanu uključeni, dobiva se ROC krivulja prikazana na slici 6.16., dok dobivena vjerojatnost za navedeni slučaj iznosi 50%.



Slika 6.16. ROC krivulja za interval $\langle -0.0457, 0.2386 \rangle$

U posljednjem slučaju izmjenjuju se statistički atributi u ikoni *Moving Transform*. Odabrani su sljedeći statistički atributi: *span, median, linear MA i exponential MA*, te se u ikoni *Discretize* broj intervala postaviti na 8. Uključeni su svi atributi u ikoni *Select Columns*, a dobivena ROC krivulja je prikazana na slici 6.17. Dobivena vjerojatnost za posljednji slučaj iznosi 70% te se u ovom slučaju opterećenje električne energije nalazi u intervalu $\langle -0.01, 0.22 \rangle$ MW.



Slika 6.17. ROC krivulja za interval $\langle -0.0813, 0.1675 \rangle$


Iz dobivenih rezultata zaključuje se da izbor atributa i broj intervala utječu na postotak vjerojatnosti. Opterećenje za naredni kvartal, za TS Branjin Vrh, nalazi se u intervalu $\langle -0.01, 0.22 \rangle$ MW. Iz podataka za prethodne godine može se vidjeti kako opterećenje s godinama opada za TS Branjin Vrh. Kako je ranije navedeno, 2015. godine bioplinska elektrana puštena je u pogon i to snage 1.8 MW, te puštanjem u pogon elektrane dolazi do smanjenja opterećenja. Na temelju podataka za prethodne godine i na temelju rezultata dobivenih predviđanjem zaključak je da se opterećenje, za naredni kvartal, za TS Branjin Vrh nalazi u intervalu $\langle -0.01, 0.22 \rangle$ MW s vjerojatnosti 70%.

6.3. Predviđanje opterećenja električne energije za TS Draž

Kao i u prethodna dva slučaja, za ulazne podatke za predviđanje opterećenja električne energije uzeti su svi kvartali od 1.1.2016. godine do 1.7.2023. godine. Podaci za TS Draž prikazani su u tablici 6.3. sa grafičkim prikazom na slici 6.18.


Tablica 6.3. Kvartalno opterećenje TS Draž

KVARTAL	P [MW]	KVARTAL	P [MW]
2016-1	0.31	2019-4	0.58
2016-2	0.4	2020-1	0.59
2016-3	0.43	2020-2	0.5
2016-4	0.3	2020-3	0.47
2017-1	0.3	2020-4	0.54
2017-2	0.41	2021-1	0.55
2017-3	0.44	2021-2	0.49
2017-4	0.33	2021-3	0.53
2018-1	0.29	2021-4	0.57
2018-2	0.41	2022-1	0.57
2018-3	0.44	2022-2	0.48
2018-4	0.57	2022-3	0.48
2019-1	0.6	2022-4	0.52
2019-2	0.52	2023-1	0.54
2019-3	0.51	2023-2	0.39



Slika 6.18. Kvartalno opterećenje TS Draž


Za predviđanja opterećenja za TS Draž ponavljaju se svi koraci kao i u prvom slučaju sa uključenim svim atributima. Nakon ponovljenih svi koraka, idući korak je ROC krivulja. Dobivena zadovoljavajuća ROC krivulja sa uključenim svim atributima, za interval $\langle 0.4229, 0.4671 \rangle$, prikazana je na slici 6.19.



Slika 6.19. ROC krivulja za interval $\langle 0.4229, 0.4671 \rangle$


Dobiveni postotak vjerojatnosti u ovom slučaju iznosi 20%, te se u ovom slučaju opterećenje električne energije za naredni kvartal nalazi u intervalu $\langle 0.38, 0.41 \rangle$ MW.

Povratkom na izbor atributa, ovoga puta u prozor *Ignored* postavljaju se sljedeći statistički atributi: *geometric mean, cumulative product, mean value, standard deviation i mode*. Ostali statistički atributi su uključeni i dobivena ROC krivulja je prikazana na slici 6.20. Vjerojatnost dobivena za ovaj slučaj je 41.7%.



Slika 6.20. ROC krivulja za interval ≥ 0.5557

No ako pri povratku na ikonu *Moving Transform* broj godina koje se uzimaju unazad postavi na 7, te odaberu sljedeće statističke atribute: *span*, *median*, *linear MA* i *exponential MA*. Zatim se u ikoni *Discretize* broj intervala postavlja na 8 i u ikoni *Select Columns* uključeni su svi atributi. Dobivena ROC krivulja za navedeni slučaj prikazana je na slici 6.21. Vjerojatnost za navedeni slučaj iznosi 60% te se u ovom slučaju opterećenje električne energije nalazi u intervalu $<0.4, 0.43>$ MW.



Slika 6.21. ROC krivulja za interval ≥ 0.5613

Na temelju rezultata zaključuje se da izbor atributa, broj godina i broj intervala utječu na postotak vjerojatnosti. Iz dobivenih rezultata zaključak je da se opterećenje za naredni kvartal, za TS Draž, nalazi u intervalu $<0.4, 0.43>$ MW. Pomoću podataka za prethodne godine, također se može donijeti odluku u kojem intervalu će se nalaziti opterećenje za naredni kvartal. Pomoću prethodnih

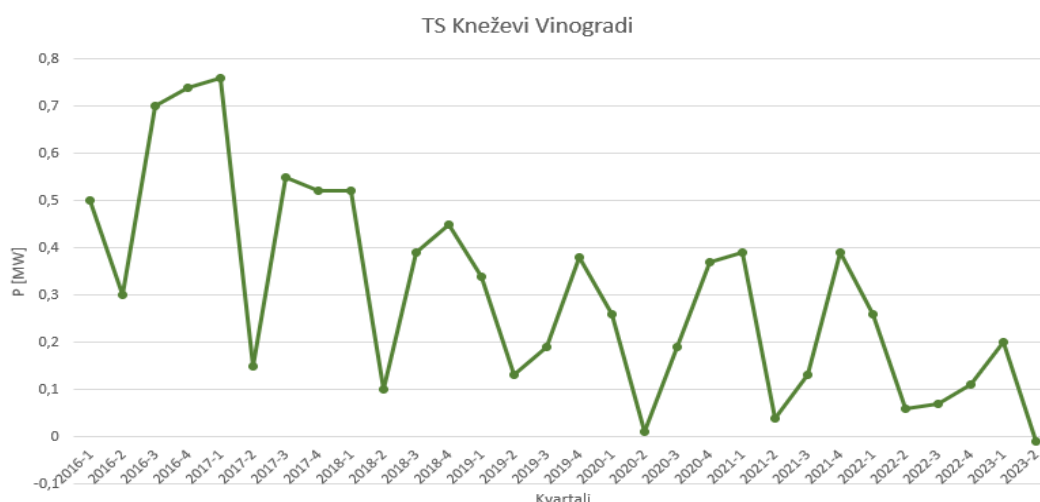
podataka i rezultata dobivenih predviđanjem, dolazi se do zaključka da će se opterećenja za naredni kvartal, za TS Draž, nalaziti u intervalu $<0.4, 0.43>$ MW s vjerojatnosti 60%.

6.4. Predviđanje opterećenja električne energije za TS Kneževi Vinogradi

U četvrtom slučaju, također za ulazne podatke za predviđanje opterećenja električne energije su se uzimali svi kvartali od 1.1.2016. godine do 1.7.2023. godine, što bi kumulativno bilo 30 podataka. Podaci za TS Kneževi Vinogradi prikazani su u tablici 6.4. i slikovitije prikazani na slici 6.22.


Tablica 6.4. Kvartalno opterećenje TS Kneževi Vinogradi

KVARTAL	P [MW]	KVARTAL	P [MW]
2016-1	0.5	2019-4	0.38
2016-2	0.3	2020-1	0.26
2016-3	0.7	2020-2	0.01
2016-4	0.74	2020-3	0.19
2017-1	0.76	2020-4	0.37
2017-2	0.15	2021-1	0.39
2017-3	0.55	2021-2	0.04
2017-4	0.52	2021-3	0.13
2018-1	0.52	2021-4	0.39
2018-2	0.1	2022-1	0.26
2018-3	0.39	2022-2	0.06
2018-4	0.45	2022-3	0.07
2019-1	0.34	2022-4	0.11
2019-2	0.13	2023-1	0.2
2019-3	0.19	2023-2	-0.01



Slika 6.22. Kvartalno opterećenje TS Kneževi Vinogradi


Kao i u prethodna tri slučaja i u četvrtom slučaju prvo se obrađuje predviđanje opterećenja sa svim uključenim atributima. Idući korak je ROC krivulja, no u ovom slučaju sa uključenim svim atributima, niti za jedan interval ne dobije se zadovoljavajuća ROC krivulja. Stoga se ponovno izabiru atributi, u prozor *Ignored* postavljaju se sljedeći atributi: *geometric mean*, *cumulative product*, *median* i *standard deviation*. Dobivena zadovoljavajuća ROC krivulja prikazana je na slici 6.23.



Slika 6.23. ROC krivulja za interval $\langle 0.32, 0.43 \rangle$

Postotak vjerojatnosti dobiven u ovom slučaju iznosi 40%, te se u ovom slučaju opterećenje električne energije za naredni kvartal, za TS Kneževi Vinogradi, nalazi u intervalu $\langle 0.25, 0.33 \rangle$ MW.

U sljedećem slučaju se ponovno izboru atributi, u prozor *Ignored* postavljaju se sljedeći atributi: *mode*, *geometric mean*, *standard deviation* i *median*. Dobivena zadovoljavajuća ROC krivulja vidljiva je na slici 6.24. Dobiveni postotak vjerojatnosti i u ovom slučaju iznosi 40%, te također i opterećenje električne energije za naredni kvartal nalazi se u intervalu $\langle 0.25, 0.33 \rangle$ MW.



Slika 6.24. ROC krivulja za interval $\langle 0.32, 0.43 \rangle$

Pomoću podataka za prethodne godine donosi se odluku u kojem će se intervalu nalaziti opterećenje električne energije za naredni kvartal. Kako je ranije navedeno 2013.godine u pogon je puštena bioplinska elektrana, te 2014.godine u pogon su puštene bioplinska i sunčana elektrana. Na temelju podataka za prethodne godine vidljivo je kako se s godinama opterećenje smanjuje, te se može zaključiti da puštanje elektrana u pogon utječe na smanjenje opterećenja. Pomoću prethodnih podataka i dobivenih rezultata zaključuje se da će se opterećenje za naredni kvartal, za TS Kneževi Vinogradi, nalaziti u intervalu $\langle 0.25, 0.33 \rangle$ MW.

Nakon četiri simulirana slučaja, zaključak je da je veoma važna priprema podataka pomoću kojih će se vršiti predviđanje opterećenja. Izbor atributa, odabir broja intervala i broj godina koje se promatraju unazad mogu utjecati na predviđanje opterećenja i na izgled ROC krivulje. Pri donošenju odluke u kojem će se intervalu nalaziti opterećenje mogu pomoći podaci za prethodne godine. U tablici 6.5. prikazana su predviđena opterećenja, za naredni kvartal, za četiri transformatorske stanice.

Tablica 6.5. Predviđanje opterećenja za naredni kvartal

Transformatorska stanica TS 35/10 kV	Prognoziranje opterećenje P [MW] za period 2023-3	Vjerojatnost [%]
TS Bilje	$\langle 2.84 \rangle$	69.2
TS Branjin Vrh	$\langle -0.01, 0.22 \rangle$	70
TS Draž	$\langle 0.4, 0.43 \rangle$	60
TS Kneževi Vinogradi	$\langle 0.25, 0.33 \rangle$	40

Uspoređujući slučajeve vidljivo je kako se u prvom slučaju za TS Bilje dobiju najbolji rezultati kada su svi atributi bili uključeni. U drugom slučaju dobiju se najbolji rezultati kada se poveća broj intervala i promijene neki od atributa. U trećem slučaju bilo je potrebno povećati broj godina unazad koje se promatraju, broj intervala i promijeniti neke od atributa, dok je u posljednjem slučaju bilo potrebno samo promijeniti neke od atributa kako bi se dobilo najbolje rješenje. Također, zaključak je kako nema određenog pravila koji atributi trebaju biti uključeni, a koji trebaju biti isključeni. Potrebno je iskušati više mogućnosti, te proučiti podatke iz prethodnih godina i na kraju se odlučiti za one koji daju najbolje rezultate.

7. ZAKLJUČAK

Predviđanje opterećenja veoma je važno jer dobiveni podaci iz prognoze koriste se u procesu operativnog i strateškog planiranja distribucijskog sustava. Postoje različiti modeli za predviđanje opterećenja električne energije te mnogi čimbenici mogu utjecati na prognozu. Nakon što je obrađena teorija o predviđanju opterećenja, izvršeno je srednjeročno planiranje opterećenja, za sljedeći kvartal, korištenjem metode neuronske mreže u programu „Orange“. Program radi tako da dobivene vrijednosti sortira u intervale, svi rezultati su važeći, no na analitičaru je da odabere interval koji bi najviše odgovarao kao krajnje predviđanje opterećenja. Program radi bolje ako ima veću količinu podataka, te bi predviđanje opterećenja bilo još točnije da postoji veći broj podataka. Prognoza je rađena za naredni kvartal i predviđanje je rađeno za TS Bilje, TS Branjin Vrh, TS Draž i TS Kneževi Vinogradi. Nema određenog pravila koji atributi trebaju biti uključeni, koliko godina se promatra unazad te koji broj intervala se uzima. U slučaju TS Bilje najbolji rezultati se dobiju kada su uključeni svi atributi i opterećenje iznosi <2.84 MW s vjerojatnosti od 69.2%, a u istom slučaju za TS Branji Vrh, TS Draž rezultati su zadovoljavajući međutim s nešto manjom vjerojatnošću, dok za TS Kneževi Vinogradi isti parametri ne donose zadovoljavajuće rezultate. Dobiveni rezultati predviđanja sa različitom grupom atributa ne razlikuju se mnogo, ali je potrebno iskušati više mogućnosti kako bi se došlo do što boljih rezultata, odnosno kako bi ROC krivulja bila zadovoljavajuća i kako bi postotak vjerojatnosti bio što veći.

SAŽETAK

U ovom diplomskom radu opisano je kako se predviđanje opterećenja može podijeliti prema vremenu, te kako određeni aspekti mogu utjecati na predviđanje opterećenja. Opisani su različiti modeli za predviđanje opterećenja električne energije. Zatim je odrađena simulacija u programu „Orange“ korištenjem metode neuronske mreže na 35 kV mreži Baranje. Predviđanje opterećenja izvršeno je na četiri transformatorske stanice (TS Bilje, TS Branjin Vrh, TS Draž i TS Kneževi Vinogradi) koristeći podatke sa 10 kV strane trafo polja. Vremenski interval za koji je rađeno predviđanje iznosi jedan kvartal. Potvrđeno je da odabir atributa, broj intervala i broj promatranih godina utječe na validnost rezultata, te same vjerojatnosti opterećenja. U sklopu diplomskog rada izvršeno je nekoliko simulacija gore navedenom metodom, a dobiveni rezultati za pojedine slučaje dosežu vjerojatnost i do 70%.

Ključne riječi: predviđanje opterećenja, umjetna neuronska mreža, ROC krivulja

ABSTRACT

This thesis describes how load forecasting can be divided according to time, and how certain aspects can affect load forecasting. Different models for forecasting electricity load are described. Then a simulation was performed in the "Orange" program using the neural network method on the 35 kV network of Baranja. Load forecasting was performed at four transformer stations (TS Bilje, TS Branjin Vrh, TS Draž and TS Kneževi Vinogradi) using data from the 10 kV side of the transformer field. The time interval for which the forecast was made is one quarter. It has been confirmed that the selection of attributes, the number of intervals and the number of observed years affects the validity of the results, as well as the load probabilities themselves. As part of the thesis, several simulations were performed using the above-mentioned method, and the obtained results for certain cases reach a probability of up to 70%.

Keywords: load prediction, artificial neural network, ROC curve

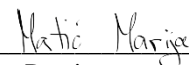
LITERATURA

- [1] N. Ahmad, Y. Ghadi, M. Adnan, M. Ali, Load Forecasting Techniques for Power System: Research Challenges and Survey, IEE Access, 10, 1-3, 2022. godina (dostupno na: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9812604>) [15.06.2023.]
- [2] Z. Wang, J. Li, S. Zhu, J. Zhao, S. Deng, S. Zhong, H. Yin, Y. Qi, Z. Gan, A Review of Load Forecasting of the Distributed Energy System, IOP Conference Series: Earth and Environmental Science, 237, 1-5, China, 2019.godina (dostupno na: <https://iopscience.iop.org/article/10.1088/1755-1315/237/4/042019/pdf>) [15.06.2023]
- [3] A.R. Khan, A. Mahmud, A. Safdar, Z. A. Kahn, N.A. Khan, Load forecasting, dynamic pricing and DSM in smart grid: A review, EE, COMSATS Institute of Information Technology, Islamabad, EPE, Mirpur University of Science and Technology, Renewable and Sustainable Energy Reviews, 2015. godina (dostupno na: https://www.researchgate.net/publication/283119722_Load_forecasting_dynamic_pricing_and_DSM_in_smart_grid_A_review) [20.06.2023.]
- [4] S. Gochhait, D.K. Sharma, Regression model-based short-term load forecasting for load dispatch center, Symbiosis Institute of Digital and Telecom Management, a constituent of Symbiosis International Deemed University, Journal of Applied Engineering and Technological Science, Vol 4(2),693 – 710, 2023. godina, (dostupno na : https://www.researchgate.net/publication/371313959_REGRESSION_MODEL-BASED_SHORT-TERM_LOAD_FORECASTING_FOR_LOAD_DISPATCH_CENTER) [21.06.2023]
- [5] D. Xu, Time series analysis as an emerging method for researching L2 affective variables, Heliyon, 9, e16931, 2023. godina, (dostupno na: https://www.researchgate.net/publication/371228583_Time_series_analysis_as_an_emerging_method_for_researching_L2_affective_variables) [22.06.2023.]
- [6] M.A. Hammad, B. Jereb, B. Rosi, D. Dragan, Methods and Models for Electric Load Forecastin: A Comprehensive Review, Logistics & Sustainable Transport, Vol. 11, No. 1, 51-76, 2020. godina, (dostupno na: https://www.researchgate.net/publication/339403486_Methods_and_Models_for_Electric_Load_Forecasting_A_Comprehensive_Review) [23.06.2023.]
- [7] R. Goić, D. Jakus, I. Penović, Distribucija električne enenrgije, interna skripta, Split, 2008.godina (dostupno na: <http://marjan.fesb.hr/~rgoic/dm/skriptaDM.pdf>) [28.08.2023.]
- [8] Program: Orange (dostupno na: <https://orangedatamining.com>) [28.08.2023.]

[9] K.Y. Ji, Analysis of ROC for Edge Detector, 2023.godina (dostupno na: https://www.researchgate.net/publication/371120369_Analysis_of_ROC_for_Edge_Detector) [29.08.2023.]

ŽIVOTOPIS

Marija Matić rođena je 1.2.1998. u Vinkovcima. Odrasla u Babinoj Gredi gdje je i pohađala Osnovnu školu Mijat Stojanović. Godine 2012. upisuje III. gimnaziju Osijek, istu završava 2016. Nakon srednjoškolskog obrazovanja upisuje sveučilišni preddiplomski studij elektrotehnike na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija u Osijeku. Nakon završetka preddiplomskog studija upisuje diplomski sveučilišni studij elektroenergetike, izborni blok elektroenergetski sustavi. Zatim, od jeseni 2022. godine sudjeluje na Erasmus Internship programu u tvrtki Infineon Technologies u Austriji gdje radi kao Component validation engineer.


Potpis autora