UNIVERZITET U NOVOM SADU
FAKULTET TEHNIČKIH NAUKA U
NOVOM SADU

UNIVERZITET U NOVOM SADU
FAKULTET TEHNIČKIH NAUKA
RAČUNARSTVO I AUTOMATIKA

KRA TKOROČNO PREDVIĐANJE POTROŠNJE ELEKTRIČNE ENERGIJE U VELIKIM ELEKTROENERGETSKIM SYSTEMIMA

DOKTORSKA DISERTACIJA

Mentor: Doc. dr Srđan Vukmirović

Kandidat: Slobodan Ilić

Novi Sad, 2013. godine

UNIVERZITET U NOVOM SADU

SADRŽAJ

Lista Ilustracija.....	5
Lista Tabela.....	7
1 UVOD.....	10
1.1 Predviđanje u elektroenergetskim kompanijama	10
1.2 Poslovne potrebe za predviđanjem potrošnje električne energije	11
1.3 Klasifikacija predviđanja potrošnje električne energije	12
1.4 Optimizacija modela za kratkoročno predviđanje potrošnje električne energije	16
2 Pregled literature.....	19
2.1 Stanje u oblasti	19
2.2 Analiza pregleda literature	21
2.2.1 Konceptualni pregledi literature	21
2.2.2 Eksperimentalni pregledi literature.....	25
2.3 Statistički pristupi.....	26
2.3.1 Regresivna analiza	27
2.3.2 Analiza vremenskih serija.....	29
2.4 Tehnike veštačke inteligencije	31
2.4.1 Veštačke neuronske mreže.....	31
2.4.2 Fuzzy logika.....	35
2.4.3 Fuzzy neuronske mreže.....	37
2.4.4 Metoda vektora podrške i ostale metode VI	38
2.5 Vremenske promenljive	39
2.6 Kalendarske promenljive.....	41
2.7 Bibliografija	43
2.8 Pregled.....	45
3 Teorijske osnove.....	48

3.1	Višestruka linearna regresija (MLR).....	48
3.1.1	Generalni modeli linearne regresije	48
3.1.2	Kvantitativne i kvalitativne prediktorske promenljive	49
3.1.3	Polinomijalna regresija	50
3.1.4	Transformisane promenljive	51
3.1.5	Efekti interakcije među promenljivama.....	51
3.1.6	Linearni modeli naspram linearnih funkcija odziva	52
3.2	Veštačke neuronske mreže	52
3.3	Statistička analiza performansi modela.....	58
3.3.1	Srednja prosečna procentualna greška – MAPE.....	59
3.3.2	MAPE – Alternativna definicija	60
4	Dizajn STLTF modela korišćenjem višestruke linearne regresije	61
4.1	Upotreba jednostavnog modela za uporedno testiranje.....	61
4.1.1	Opis modela	61
4.1.2	Skup podataka za testiranje.....	62
4.1.3	Implementacija modela za testiranje sa prikazom rezultata	64
4.2	Dizajn MLR modela putem analize korelacije.....	68
4.2.1	Analiza korelacije između signala potrošnje el. energije i zabeležene temperature	69
4.2.2	Analiza autokorelacije zabeleženog signala potrošnje, kao i njegove korelacije sa transformisanim sopstvenim vrednostima zabeleženih merenja	72
4.2.3	Konstrukcija MLR modela na osnovu rezultata prethodno dobijenih korelativnom analizom	76
4.2.4	Dizajn MLR STLTF modela pomoću genetskog algoritma.....	79
4.3	Zaključak u vezi sa dizajniranjem MLR STLTF modela	85
5	STLTF – veštačke neuronske mreže	88
5.1	Selekcija ulaznih parametara za ANN STLTF modele	88
5.2	Struktura ANN modela za STLTF.....	90

5.2.1	Preprocesirajuća jedinica	90
5.2.2	Struktura upotrebjene ANN (MLP)	91
5.3	Rezultati testiranja.....	92
5.3.1	Korišćeni podaci	92
5.3.2	Performanse modela.....	94
6	STLF – hibridne metode.....	98
6.1	Dizajn ANN STLF modela upotrebom genetskog algoritma.....	98
6.1.1	Određivanje topologije ANN.....	98
6.1.2	Određivanje ulaznih parametara ANN STLF modela pomoću GA.....	99
7	Zaključak	105
8	Literatura	108

Lista Ilustracija

Ilustracija 2.1 Šematski prikaz procesa predviđanja potrošnje el. energije	20
Ilustracija 3.1 Neuronska mreža sa propagacijom signala unapred	55
Ilustracija 3.2 Formiranje ulaznog signala za neurone skrivenog sloja	57
Ilustracija 4.1 Sistemska potrošnja grada Burbank-a, CA, zabeležena u periodu od 3 godine	63
Ilustracija 4.2 Zabeležena temperatura za područje grada Burbank-a, CA, u periodu od 3 godine.....	64
Ilustracija 4.3 Zabeležena potrošnja za period od 22.do28. avgusta 2011. godine.....	65
Ilustracija 4.4 Zabeležena temperatura za period od 22.-do28. avgusta 2011. godine	65
Ilustracija 4.5 Rezultati predviđanja dobijeni korišćenjem jednostavnog modela za komparativnu analizu. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.....	68
Ilustracija 4.6 Korelacija temperature i potrošnje na sistemskom nivou	69
Ilustracija 4.7 Rezultati predviđanja generisani modelom dobijenim korelativne analize temperaturnih uticaja. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.....	72
Ilustracija 4.8 Analiza autokorelacije zabeleženog signala potrošnje el. energije.....	74
Ilustracija 4.9 Rezultati predviđanja generisani modelom dobijenim korelativnom analizom uticaja prethodno zabeležene potrošnje. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.....	76
Ilustracija 4.10 Rezultati predviđanja generisani kombinovanim modelom. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.	78
Ilustracija 4.11 Rezultati predviđanja modelom dobijenim GA optimizacijom, na osnovu kriterijuma MAPE. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.....	81
Ilustracija 4.12 Rezultati predviđanja modelom dobijenim GA optimizacijom, na osnovu kriterijuma MAE. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.....	83
Ilustracija 4.13 Rezultati predviđanja modelom dobijenim GA optimizacijom, na osnovu kriterijuma WAPE. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.....	85
Ilustracija 5.1 Topologija predloženog STLF modela zasnovanog na ANN, sa preprocesirajućom jedinicom.....	91

Ilustracija 5.2 Grafički prikaz časovnih vrednosti potrošnje el. energije za 2006. godinu, za potrošač iz okoline grada Milana.	93
Ilustracija 5.3 Grafički prikaz časovnih vrednosti minimalne, maksimalne i srednje temperature, zabeleženih za celu 2006. godinu.	93
Ilustracija 5.4 Grafički prikaz korelacije između trenutnih vrednosti temperature okoline i ostvarene potrošnje el. energije.....	94
Ilustracija 5.5 Rezultati predviđanja STLF modelom zasnovanom na ANN sa 24 izlaza. Puna linija predstavlja stvarnu, a isprekidana predviđenu potrošnju el. energije.	95
Ilustracija 5.6 Rezultati predviđanja STLF modelom zasnovanom na 24 ANN sa po 1 izlazom. Puna linija predstavlja stvarnu, a isprekidana predviđenu potrošnju el. energije.	96
Ilustracija 5.7 Rezultati predviđanja ANN modelom, sa preprocesirajućom jedinicom. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.	97
Ilustracija 6.1 Topologija jedinstvenog ANN modela sa 1 izlazom	101
Ilustracija 6.2 Rezultati predviđanja STLF modelom sa jedinstvenom ANN sa jednim izlazom. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.....	101
Ilustracija 6.3 Topologija jedinstvenog ANN modela sa 24 izlaza	102
Ilustracija 6.4 Topologija STLF modela sa 24 zasebne ANN jedinice.....	103
Ilustracija 6.5 Rezultati predviđanja STLF modelom sa 24 zasebne ANN. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.	104

Lista Tabela

Tabela 1.1 Potrebe za predviđanjem u elektroenergetskim kompanijama	12
Tabela 1.2 Dostupnost i pouzdanost različitih tipova podataka potrebnih za predviđanje potrošnje električne energije	14
Tabela 1.3 Klasifikacija različitih tipova predviđanja potrošnje električne energije.....	15
Tabela 1.4 Asocijacija različitih tipova predviđanja sa različitim poslovnim potrebama	16
Tabela 2.1 Kodiranje tipa dana u okviru STLF literature	Error! Bookmark not defined.
Tabela 3.1 Različite vrste modela (mreža) i njihovih funkcija greške (rizika)MLP	Error! Bookmark not defined.
Tabela 4.1 Detaljan opis promenljivih STLF modela prikazanog jednačinom 4.1	61
Tabela 4.2 Korelacija između predviđane potrošnje i prethodno zabeleženih temperatura	70
Tabela 4.3 Korelacija između predviđane potrošnje i sopstvenih prethodno zabeleženih vrednosti (osnovnih i transformisanih oblika)	73
Tabela 4.4 Prikaz ostvarenih performansi različitih STLF modela zasnovanih na MLR.....	87
Tabela 5.1 Različite topologije STLF modela upotrebom tehnike ANN.....	Error! Bookmark not defined.

КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА

Редни број, РБР:	
Идентификациони број, ИБР:	
Тип документације, ТД:	
Тип записа, ТЗ:	
Врста рада, ВР:	Докторска дисертација
Аутор, АУ:	Слободан Илић
Ментор, МН:	Др Срђан Вукмировић, доцент
Наслов рада, НР:	Краткорочно предвиђање потрошње електричне енергије у великим електроенергетским системима
Језик публикације, ЈП:	српски
Језик извода, ЈИ:	српски
Земља публикавања, ЗП:	Србија
Уже географско подручје, УГП:	Војводина, Нови Сад
Година, ГО:	2013
Издавач, ИЗ:	Факултет техничких наука, Универзитет Нови Сад
Место и адреса, МА:	Трг Доситеја Обрадовића 6
Физички опис рада, ФО: (поглавља/страна/ цитата/табела/слика/графика/прилога)	8 поглавља; 117 страна; 106 референци; 11 табела; 30 илустрација
Научна област, НО:	Аутоматика и управљање системима
Научна дисциплина, НД:	Предвиђање потрошње електричне енергије
Предметна одредница/Кључне речи, ПО:	Краткорочно предвиђање потрошње електричне енергије, Линеарна регресија, Вештачке неуронске мреже, генетски алгоритми
УДК	
Чува се, ЧУ:	Библиотека Факултета техничких наука, Универзитета у Новом Саду
Важна напомена, ВН:	
Извод, ИЗ:	Предмет истраживања ове дисертације везан је за реализацију система за краткорочно предвиђање потрошње електричне енергије у комплексним електроенергетским системима. Представљена је нова метода за избор улазних променљивих предикционог модела, заснована на генетским алгоритмима. Улазне променљиве се бирају тако да омогућавају успешно моделовање процеса потрошње ел. енергије. За имплементацију предикционог модела коришћена је техника вишеструке линеарне регресије, као и вештачке неуронске мреже. Одзив система у фази експлоатације је прецизан и поуздан.
Датум прихватања теме, ДП:	
Датум одбране, ДО:	
Чланови комисије, КО:	Председник: Др Бранко Ковачевић, редовни професор
	Члан: Др Горан Швенда, редовни професор
	Члан: Др Филип Кулић, ванредни професор
	Члан: Др Александар Ердџан, ванредни професор
	Члан, ментор: Др Срђан Вукмировић, доцент

Потпис ментора

KEY WORDS DOCUMENTATION

Accession number, ANO :			
Identification number, INO :			
Document type, DT :			
Type of record, TR :			
Contents code, CC :			
Author, AU :	MSc Slobodan Ilić		
Mentor, MN :	PhD Srđan Vukmirović, assistant professor		
Title, TI :	Short-term load forecasting in large distribution centers		
Language of text, LT :	serbian		
Language of abstract, LA :	serbian		
Country of publication, CP :	Serbia		
Locality of publication, LP :	Vojvodina, Novi Sad		
Publication year, PY :	2013		
Publisher, PB :	Faculty of technical science, University Novi Sad		
Publication place, PP :	Trg Dositeja Obradovića 6		
Physical description, PD : (chapters/pages/ref./tables/pictures/graphs/appendixes)	8 chapter, 117 pages, 106 referencec, 11 tables, 30 figures		
Scientific field, SF :	Automation and system control		
Scientific discipline, SD :			
Subject/Key words, S/KW :	Short-term load forecasting, Linear regression, Artificial neural networks, genetic algorithms		
UC			
Holding data, HD :	Library of Faculty of technical science, University Novi Sad		
Note, N :			
Abstract, AB :	This dissertation proposes a new method for selecting the input variables for a short-term load forecasting model. The method is based on genetic algorithms, while the prediction model is implemented using the multiple linear regression. The input variables are selected to enable successful modeling of the electrical energy consumption process. In the exploitation phase, the system generates reliable and precise forecasts.		
Accepted by the Scientific Board on, ASB :			
Defended on, DE :			
Defended Board, DB :	President:	PhD Branko Kovačević, professor	Menthor's sign
	Member:	PhD Goran Švenda, professor	
	Member:	PhD Filip Kulić, assosiate professor	
	Member:	PhD Aleksandar Erdeljan, associate professor	
	Member, Mentor:	PhD Srđan Vukmirović, assistant professor	

1 UVOD

Formalne tehnike planiranja i predviđanja se koriste u okviru različitih preduzeća i ustanova, kao i u vladinim i neprofitnim organizacijama, za postizanje određenih ciljeva. U istraživanju predstavljenom u [1] je pokazano da ove tehnike sa različitih aspekata mogu biti od koristi organizacijama u kojima se primenjuju. U elektroenergetskoj industriji, predviđanje potrošnje električne energije je sastavni deo funkcionalnosti elektroenergetskog sistema, čiji cilj je da obezbedi pouzdano snabdevanje električnom energijom, kao i da smanji operativne troškove. Velika elektroenergetska preduzeća često poseduju sopstvene kapacitete za ostvarivanje funkcionalnosti predviđanja, dok za manje organizacije ovakav razvoj često nije moguć zbog ograničenosti resursa, pa se ostvarivanje navedene funkcionalnosti poverava posebnim organizacijama. U ovom poglavlju se opisuju osnovni koncepti kratkoročnog predviđanja potrošnje električne energije, kao i najčešće prakse za postizanje ove funkcionalnosti u okviru elektroenergetske industrije.

1.1 Predviđanje u elektroenergetskim kompanijama

U velikom broju organizacija, predviđanje i planiranje su integrisani u jednu funkcionalnost, pa se zadatak predviđanja dodeljuje odeljenjima zaduženim za planiranje. Ipak, treba naglasiti jasnu razliku između predviđanja i planiranja. Pod planiranjem se podrazumeva definisanje određenih operativnih strategija u zavisnosti od predviđanja, dok se pod predviđanjem podrazumeva procena rezultata neke operacije, u zavisnosti od definisanog operativnog plana. Drugim rečima, planiranje se može definisati kao skup aktivnosti koje bi elektroenergetska kompanija u određenom momentu trebalo da preduzme, dok se predviđanje može definisati kao mogući tok događanja, ukoliko se prate određene strategije u datim uslovima. Predviđanje takođe treba da odredi koji su mogući zadati uslovi u određenom budućem vremenskom periodu [2].

Uobičajena je praksa da jedno odeljenje u okviru neke organizacije bude zaduženo za generisanje predviđanja koja će mu biti potrebna. Ovo podrazumeva potrošnju resursa unutar tog odeljenja, kao što su: dodeljivanje radnih zadataka inženjerima, prikupljanje odgovarajućih potrebnih podataka, izvršavanje same procedure predviđanja, itd. Takođe, u ovakvom autonomnom režimu, ne postoji razvijena komunikacija između različitih odeljenja unutar jedne organizacije, a takav način funkcionisanja može dovesti do nekoliko nedostataka. Prvi od ovih nedostataka je svakako neefikasno korišćenje resursa, s obzirom na to da se može desiti da se jedno predviđanje izvršava na više različitih mesta (za više različitih namena). Drugi nedostatak je svakako razlika u kvalitetu predviđanja, koja su nastala kao rezultat operacije različitih timova, unutar iste organizacije. Na primer, u okviru neke

određene kompanije, odeljenje za prodaju može koristiti zabeležene podatke o izvršenim naplatama da bi generisalo predviđanja za period od jednog dana unapred, dok strateško odeljenje može koristiti podatke prikupljene SCADA sistemom (eng. Supervisory Control and Data Acquisition) za generisanje tih istih predviđanja. S obzirom na to da su u prethodna dva navedena primera korišćeni različiti ulazni podaci, kvalitet ostvarenih predviđanja će se međusobno razlikovati, što može dovesti do neusaglašenosti između odeljenja organizacije, a kasnije i operativnih problema.

1.2 Poslovne potrebe za predviđanjem potrošnje električne energije

U modernim elektroenergetskim preduzećima ostvarivanje funkcionalnosti različitih kategorija često podrazumeva korišćenje distribuiranih aplikacija, koje obuhvataju više različitih odeljenja. Za kvalitetne rezultate ovakvih aplikacija, predviđanje potrošnje, tj. zahteva za električnom energijom, posebno je bitno. Na primer, odeljenja za prodaju, planiranje, kao i operativne odluke, zahtevaju što tačnija predviđanja, da bi na osnovu njih mogla uspešno da izvrše svoje zadatke. Poslovne potrebe elektroenergetskih preduzeća se mogu sumirati, ali ne i ograničiti, u sledećem:

- Kupovina energije. Elektroenergetska kompanija može direktno kupovati energiju na tržištu, ili može ovaj zadatak poveriti nekoj spoljnoj, nezavisnoj organizaciji. U oba slučaja, predviđanja potrošnje su esencijalna za kupovinu energije. Elektroenergetske kompanije mogu dugoročno prodavati električnu energiju međusobno, kao i međusobno dogovarati korišćenje proizvodnih kapaciteta (do deset godina unapred). Premošćavanja rizika, kao i blok-kupovina el. energije, se mogu dogovarati od jedan mesec do tri godine unapred. Energijom se takođe može trgovati (prodaja ili kupovina) u periodu od jednog dana unapred, na otvorenom energetsom tržištu.
- Planiranje prenosa i distribucije [3]. Da bi se održala pouzdanost isporuke električne energije, kao i da bi se odgovorilo na konstantno povećanje zahteva za električnom energijom, elektrodistributivne kompanije moraju konstantno da održavaju sistem, kao i da ga postepeno nadograđuju. Da bi se postavile nove transformatorske stanice, elektrodistributivne kompanije ponekad moraju da planiraju i kupovinu zemljišta u budućnosti. Planiranje prenosa i distribucije se u velikoj meri oslanja na predviđanje potrošnje, tačnije na prostorno predviđanje potrošnje, koje u sebi objedinjuje informacije o tome kada i gde će potražnja za energijom porasti, kao i koliko će se broj potrošača u određenoj regiji povećati.
- Operativne odluke i održavanje. U svakodnevnom funkcionisanju elektroenergetskog sistema, operateri koriste rezultate predviđanja potrošnje (profile, tj. krive potrošnje) da bi mogli optimalno da sprovedu operativne odluke, kao što su uključivanje i

isključivanje prekidača, opterećivanje različitih delova mreže, te njihova planirana isključivanja.

- Menadžment potražnje za električnom energijom. Iako se ova kategorija može ubrojiti u svakodnevne operacije elektroenergetskog sistema, uputno ju je predstaviti kao posebnu kategoriju, zbog važnosti koju ima kada se posmatra kroz koncept pametnih elektroenergetskih sistema (eng. Smart-Grid). Precizna prognoza opterećenja može u velikoj meri podržati odluke vezane za regulaciju opterećenja, kao i za smanjivanje napona u elektroenergetskoj mreži. Pored svakodnevnih operacija, analiza predviđene potrošnje u kombinaciji sa analizom karakteristika određenih potrošača može poslužiti za dugoročna predviđanja.
- Finansijsko planiranje. Izvršni direktori mogu koristiti predviđanje potrošnje električne energije kao pomoć prilikom planiranja srednjoročnih i dugoročnih prihoda, kupovine i prodaje električne energije, kao i prilikom donošenja odluka o budžetu, ljudskim resursima i tehnologijama koje se koriste.

Svaka od prethodno navedenih kategorija ima drugačiji vremenski horizont za koji je potrebno izvršiti predviđanje, kao i različit period obnavljanja podataka na osnovu kojih se navedeno predviđanje izvršava. Različiti vremenski periodi predviđanja, kao i ciklusi obnavljanja podataka su prikazani u **Error! Reference source not found.**

Tabela 1.1 Potrebe za predviđanjem u elektroenergetskim kompanijama

	Minimalni ciklus obnavljanja	Tipičan horizont
Trgovina el. energijom	1 sat	10 godina i više
Planiranje prenosa i distribucije	1 dan	30 godina
Operativne odluke	15 minuta	2 nedelje
Menadžment zahteva	15 minuta	10 godina i više
Finansijsko planiranje	1 mesec	10 godina i više

1.3 Klasifikacija predviđanja potrošnje električne energije

Predviđanja potrošnje električne energije mogu biti različitog tipa, što podrazumeva njihovo korišćenje za različite namene u okviru elektroenergetskih preduzeća. S obzirom na to da postoje mnogi zahtevi na koje je potrebno odgovoriti u cilju što boljeg funkcionisanja elektroenergetskog sistema, ne postoji ni jedan metod za predviđanje potrošnje električne energije, koji bi bio dovoljno univerzalan da obuhvati sve funkcionalnosti koje je potrebno

ostvariti, s obzirom na postavljene zahteve. Uobičajena praksa u elektroenergetskim kompanijama je da se različiti tipovi predviđanja koriste za različite namene, pa se shodno tome koriste i drugačije tehnike za njihovu implementaciju. Klasifikacija različitih tipova predviđanja potrošnje električne energije ne zavisi isključivo od poslovnih potreba elektroenergetskih kompanija, već i od dostupnosti podataka koji su potrebni za njihovu implementaciju i ispravno funkcionisanje, kao što su meteorološki (ili klimatski ukoliko se radi o dugom vremenskom periodu predviđanja) i socijalni parametri.

Meteorološki parametri podrazumevaju trenutno stanje vremenskih elemenata koji mogu imati direktan ili indirektan uticaj na proces potrošnje električne energije. U meteorološke parametre se ubrajaju: temperatura vazduha, vlažnost vazduha, brzina vetra, količina padavina, itd., a posmatraju se varijacije ovih parametara na određenoj teritoriji, vezanoj za određenu grupu potrošača, u periodu od jednog dana, do nedelju dana unapred. Klimatski parametri podrazumevaju iste elemente kao i meteorološki parametri, koji se takođe posmatraju na određenom geografskom području, vezanom za određenu grupu potrošača, s tim što se varijacije tih parametara posmatraju u znatno dužem vremenskom periodu. U sledećem poglavlju će biti opisana upotreba različitih elemenata meteoroloških promenljivih u modelima za predviđanje potrošnje električne energije. S obzirom na to da temperatura okoline ima najveći uticaj na proces potrošnje, pogotovo kada se radi o rezidencijalnim potrošačima, većina modela za predviđanje koristi informaciju o temperaturi kao svoj ulazni parametar. Svi modeli koji su razvijeni u okviru ove disertacije takođe koriste informaciju o temperaturi kao svoj ulazni parametar, dok se u pojedinim modelima koristi i informacija o vlažnosti vazduha kao ulazni parametar. Meteorološka predviđanja temperature su dostupna sa relativno velikom tačnošću u periodu do jednog dana unapred, a sa smanjenom preciznošću, ali relativno velikom pouzdanošću u periodu do nedelju dana unapred. Predviđanja temperature mogu biti dobijena od raznih meteoroloških servisa, iako neke elektroenergetske kompanije investiraju u sopstvenu opremu za merenje i snimanje vremenskih parametara, kao i u posebne metodologije za njihovo predviđanje, radi ostvarivanja preciznijih rezultata predviđanja. U okviru ove disertacije, sva temperaturna merenja koja su korišćena za formiranje različitih prediktivnih modela su dobijena kao snimljene vrednosti iz baze podataka, dok njihovo predviđanje izlazi izvan okvira disertacije. Socijalni faktori, tj. različite ljudske aktivnosti, na nekoliko različitih načina utiču na proces potrošnje električne. Kada se posmatra sam proces potrošnje, u rezoluciji od jednog časa, uticaj socijalnih faktora se menja u skladu sa promenama kalendarskog tipa, kao što su informacije o tome koji je dan u nedelji (za koji se vrši predviđanje) ili koji je mesec u godini. Kalendarske promenljive su unapred poznate, u periodu do deset godina unapred (veoma

retko dolazi do promene kalendara). Ako se proces potrošnje posmatra sa rezolucijom od jednog meseca, ili od jednog kvartala, tada dolaze do izražaja i ekonomski faktori i njihov uticaj na proces konzumiranja električne energije. Na primer, tokom 2009. godine, koja predstavlja rani početak recesije u Sjedinjenim Američkim Državama (SAD) potrošnja električne energije je bila manja u poređenju sa prethodnom godinom (2008.), u celim SAD, iz razloga što su potrošači bili finansijski primorani da se štedljivije ophode prema energentima, kao i zbog činjenice da su se mnoga privatna preduzeća ugasila. Ponašanje ekonomskih parametara, koji se koriste za predviđanje potrošnje električne energije, može biti predviđeno pomoću ekonometrijskih tehnika, čijim se napretkom ostvaruju relativno tačna ekonomska predviđanja u vremenskom periodu do jedne godine unapred, a manje tačna, ali relativno pouzdana, u vremenskom periodu do tri godine unapred. Kada se proces potrošnje električne energije posmatra sa rezolucijom od jedne godine, na njega će svakako uticati ekonomski i klimatski faktori na sistemskom nivou. Ipak, zbog nedostataka tačne prognoze ovih tipova parametara, predviđanje potrošnje na sistemskom nivou je moguće izvršiti jedino kao simulaciju različitih scenarija (klimatskih i ekonomskih). Sa druge strane, razvoj urbanizma, kao i povećavanje broja stanovništva u okviru određene regije, dugoročno utiče na proces potrošnje električne energije. Urbanistički planovi uglavnom poseduju tačne informacije u periodu od jedne godine u napred, a manje tačne, ali relativno pouzdane u periodu do pet godina unapred. Iako postoje određena područja koja poseduju precizne urbanističke planove u periodu do čak 30 godina unapred, ipak se ne može sa sigurnošću znati šta će se tačno dešavati, kao i kada će se određene urbanističke promene desiti u tako dugačkom vremenskom periodu. Predviđanje potrošnje i opterećenja elektroenergetske mreže u odnosu na različite simulacije urbanističkog razvoja se naziva prostorno predviđanje potrošnje električne energije [4]. U **Error! Reference source not found.** je prikazana dostupnost različitih parametara (meteoroloških, ekonomskih i urbanističkih) za potrebe predviđanja potrošnje električne energije. U **Error! Reference source not found.** je prikazan jedan način za klasifikaciju predviđanja potrošnje u zavisnosti od dostupnosti ulaznih parametara, vremenskog perioda predviđanja, kao i ciklusa obnavljanja podataka potrebnih za uspešno funkcionisanje predikcione metode.

Tabela 1.2 Dostupnost i pouzdanost različitih tipova podataka potrebnih za predviđanje potrošnje električne energije

	Precizno	Neprecizno	Nepouzđano
Temperatura	1 dan	2 nedelje	više od 2 nedelje
Ekonometrija	1 mesec	3 godine	više od 3 godine

Urbanizam	1 godina	5 godina	više od 5 godina
-----------	----------	----------	------------------

Tabela 1.3 Klasifikacija različitih tipova predviđanja potrošnje električne energije

	Temperatura	Ekonometrija	Urbanizacija	Obnavljanje podataka	Maks. period predviđanja
VSTLF	opciono	opciono	opciono	manje od 1 sat	1 dan
STLF	zahtevano	opciono	opciono	1 dan	2 nedelje
MTLF	simulirano	zahtevano	opciono	1 mesec	3 godine
LTLF	simulirano	simulirano	zahtevano	1 godina	30 godina

Klase različitih tipova predviđanja s obzirom na maksimalni vremenski period za koji se predviđanje vrši se mogu opisati na sledeći način:

- Predviđanje potrošnje el. energije u veoma kratkom vremenskom periodu (eng. Very Short-Term Load Forecasting – VSTLF). Kada se konstruiše model za ovakav tip predviđanja informacije o meteorološkim uslovima (temperaturi), ekonomskim pokazateljima, kao i o urbanističkom planu, mogu biti zanemarene, s obzirom na to da se potrošnja električne energije u neposrednoj budućnosti može predvideti na osnovu zabeleženih merenja u neposrednoj prošlosti.
- Kratkoročno predviđanje potrošnje el. energije (eng. Short-Term Load Forecasting – STLF). U ovakvom tipu predviđanja je moguće izostaviti ekonomske parametre, kao i informacije o urbanističkom razvoju, s obzirom na to da se ove veličine veoma sporo menjaju (u periodu manjem od dve nedelje). Sa druge strane, vremenske promenljive igraju ključnu ulogu za ovakav tip predviđanja.
- Srednjoročno predviđanje potrošnje el. energije (eng. Medium-Term Load Forecasting – MTLF). Za ovakav tip predviđanja, vremenske promenljive ne mogu biti precizno predviđene (za period do 3 godine unapred). U skladu sa tim, mogu se koristiti različiti simulacioni koncepti, prilikom kojih će se uzeti u obzir zabeleženo ponašanje vremenskih promenljivih u određenom regionu (lokalno ponašanje meteoroloških promenljivih). S obzirom na to da je moguće predvideti ponašanje ekonomskih faktora u periodu do 3 godine unapred, sa relativno visokom tačnošću, dostupnost ovakavog tipa podataka predstavlja jedan od zahteva kada se konstruišu MTLF modeli.
- Dugoročno predviđanje potrošnje el. energije (eng. Long-Term Load Forecasting – LTLF). U prethodna tri tipa predviđanja potrošnje el. energije, upotreba informacija o promeni urbanističkog plana je opcionalna, s obzirom na to da se on ne može mnogo promeniti kada se posmatra u periodu od 3 godine. Međutim, ukoliko se radi o dužim

vremenskim periodima, promena strukture naselja, gustina naseljenosti, kao i povećanje broja stanovnika je jedan od glavnih faktora koji utiče na porast zahteva za električnom energijom. Zbog toga je za konstrukciju LTLF modela neophodno uvrstiti informaciju o urbanističkom planu, kao ulazni parametar za predviđanje potrošnje el. energije. Sa druge strane, ekonomske kao i klimatske faktore je teško predvideti za duge vremenske periode, tako da se u slučaju LTLF predviđanja koriste simulacioni konteksti (simulirane vrednosti podataka).

Pomoću klasifikacije predstavljene u **Error! Reference source not found.** možemo napraviti asocijaciju između pojedinih poslovnih potreba elektroenergetskih kompanija i uobičajenih vremenskih perioda za koji se izvršavaju određeni tipovi predviđanja. S obzirom na širok spektar obnavljajućih ciklusa podataka, kao i maksimalnih horizonata predviđanja, određena poslovna potreba može biti asociirana sa više različitih tipova predviđanja. Na primer, kupovina i prodaja el. energije se može izvršavati počevši od jednog dana unapred, preko godinu dana unapred, pa sve do deset godina unapred, prilikom čega će se primenjivati različiti tipovi predviđanja, počevši od VSTLF, sve do LTLF.

Tabela 1.4 Asocijacija različitih tipova predviđanja sa različitim poslovnim potrebama

	VSTLF	STLF	MTLF	LTLF
Kupovina električne energije	X	X	X	X
Planiranje prenosa i distribucije		X	X	X
Operativne odluke	X	X		
Menadžment zahteva	X	X	X	X
Finansijsko planiranje			X	X

1.4 Optimizacija modela za kratkoročno predviđanje potrošnje električne energije

Iako postoji veliki broj metoda, kako u literaturi tako i u praksi, dizajniranih za obavljanje funkcionalnosti kratkoročnog predviđanja potrošnje električne energije, činjenica je da su one većinom bile razvijane za konkretne sisteme (konkretne tipove potrošača) te da su zbog toga usko specijalizovane. Problematika koja se generalno javlja u oblasti predviđanja potrošnje električne energije se u velikoj meri sastoji iz pronalaženja međuzavisnosti ulaznih veličina i veličina koje je potrebno predvideti. Ove međuzavisnosti su drugačije za različite

elektroenergetske sisteme (tipove potrošača) pa se zato određene STLF metode ponašaju dobro za jednu klasu potrošača, dok za drugu ne garantuju tačne rezultate, a ponekad čak daju potpuno besmislene rezultate. Sa druge strane, uska specijalizacija STLF funkcionalnosti onemogućuje direktno poređenje metoda koje su primenjene na različite klase problema, pre svega zbog različitih karakteristika vremenskih serija potrošnje električne energije, te specifičnosti primenjenih algoritama za predviđanje, u skladu sa tim karakteristikama.

U okviru ove disertacije predložen je novi algoritam za STLF modeliranje, zasnovan na genetskom algoritmu. Pomoću predloženog algoritma se odabiraju ulazni parametri koji imaju najveći uticaj na potrošnju el. energije koju je potrebno predvideti. S obzirom na različite karakteristike određenih potrošača (ili elektroenergetskih sistema u celini), upotreba pomenutog algoritma će rezultirati drugačijim STLF modelom kada se primeni na svakog od njih. Ovakav pristup predstavlja srž ove disertacije, a ujedno i suštinsku razliku u odnosu na većinu STLF literature, čiji je fokus uglavnom predlaganje konkretnih, poboljšanih modela za određene tipove potrošača. U okviru ove disertacije je takođe predstavljeno jedno novo rešenje za kratkoročno predviđanje potrošnje električne energije – STLF, koje se bazira na nekoliko različitih, do sada korišćenih, STLF metoda, a koje koristi i pomenuti GA algoritam kao svoj sastavni deo, u fazi modeliranja. Zbog raznorodnosti upotrebljenih algoritama predloženo rešenje se može smatrati hibridnim, a ono kao takvo koristi prednosti do sada razrađenih STLF metoda, koje koristi kao svoj sastavni deo. Predloženo rešenje je dizajnirano u kombinaciji sa pomenutim algoritmom za prilagođavanje predikcionog modela određenoj klasi problema.

Drugo poglavlje predstavlja opsežan pregled relevantne literature iz oblasti predviđanja potrošnje električne energije. U trećem poglavlju su prikazane teoretske osnove za tri tehnike koje se koriste u STLF oblasti:

- linearna regresija – kao jedna od tradicionalno primenjivanih tehnika za STLF
- veštačke neuronske mreže (eng. Artificial Neural Network – ANN) – kao jedna od najpopularnijih tehnika u STLF oblasti
- metoda vektora podrške (eng. Support Vector Machine – SVM).

Četvrto poglavlje se bavi razvojem STLF modela korišćenjem linearne regresije, kao i upoređivanjem performansi različitih regresivnih modela na istom skupu podataka. U ovom poglavlju je takođe predstavljen i detaljno opisan algoritam za prilagođavanje predikcionog modela određenoj klasi problema, tačnije tehnika za prilagođavanje određenog STLF modela nekoj konkretnoj grupi potrošača, tj. nekom konkretnom elektroenergetskom sistemu. U petom poglavlju je razvijeno nekoliko STLF modela korišćenjem tehnike veštačkih neuronskih mreža i takođe je izvršeno njihovo međusobno upoređivanje na istom skupu

podataka. Pored toga, napravljena je paralela između performansi modela dobijenih korišćenjem linearne regresije, sa modelima dobijenim korišćenjem veštačke inteligencije, tačnije korišćenjem tehnike veštačkih neuronskih mreža. U šestom poglavlju je razvijeno nekoliko STLTF modela korišćenjem metode vektora podrške i izvršeno je njihovo uporedno testiranje na istom skupu podataka, u zavisnosti od konfiguracije ulaznih podataka predloženih modela. Takođe je napravljena paralela sa prethodna dva poglavlja (četvrtim i petim) prilikom čega je izvršena uporedna analiza performansi STLTF modela dobijenih metodom vektora podrške, tehnikom veštačkih neuronskih mreža, kao i metodom linearne regresije. Sedmo poglavlje opisuje konstrukciju nekih hibridnih modela, koji kao svoj sastavni deo imaju više komponenti dobijenih upotrebom različitih tehnika, a takođe mogu imati i više hijerarhijskih jedinica, od kojih svaka obavlja poseban deo STLTF funkcionalnosti. Osmo poglavlje predstavlja zaključak zajedno sa razmatranjem mogućih daljih pravaca istraživanja vezanih za ovu temu.

2 Pregled literature

U proteklih pedeset godina je objavljeno veoma mnogo radova u oblasti predviđanja potrošnje električne energije. Pregled koji je predstavljen u ovom poglavlju se uglavnom fokusira na literaturu u vezi sa kratkoročnim predviđanjem potrošnje električne energije, koja je objavljena u priznatim naučnim časopisima od međunarodnog značaja. Pregled radova je učinjen na osnovu tri aspekta:

- razvijene ili primenjene tehnike koje su se koristile za implementaciju određenog STLF modela,
- dizajniranje STLF modela sa različitim parametrima, pre svega sa različitim ulaznim promenljivama,
- reprezentativni istraživački rad od strane nekoliko velikih istraživačkih grupa.

Veoma je čest slučaj u naučnoj literaturi da se pregledi fokusiraju na najnovija dostignuća u oblasti, dok je mnogo ređi slučaj da pregledi imaju za cilj detaljno pokrivanje raznovrsnih aspekata nekog polja istraživanja [5]. Komentari koji su izneti u vezi sa različitim naučnim radovima u okviru ovog pregleda imaju za cilj da ukažu pre svega na konceptualni nivo predložene metodologije, te specifičan pristup autora oblasti kratkoročnog predviđanja električne energije.

2.1 Stanje u oblasti

Pristup razvoju STLF metodologije, u okviru elektrodistributivnih kompanija koje se oslanjaju na meteorološke informacije, je prikazan na slici 2.1. Snimljena merenja prethodne potrošnje u sistemu, kao i prethodne temperature u nekoj regiji (koja obuhvata određenu grupu potrošača) se uzimaju kao ulazi procesa za modeliranje potrošnje el. energije. Ovaj proces ima za cilj da odredi parametre modela za STLF (kao što su npr. koeficijenti MLR modela, ili težine veza među neuronima kod ANN modela). Nakon što se parametri modela odrede vrši se ekstrapolacija na osnovu predviđenih meteoroloških prilika, sa ciljem da se dobije konačna predikcija potrošnje električne energije. Vremenska serija koja predstavlja potrošnju el. energije se može rastaviti na dve komponente: sistemske varijacije i šum. Proces modelovanja koji je prikazan na slici 2.1 ima za cilj da prepozna komponentu sistemskih varijacija vremenske serije potrošnje el. energije. Ova komponenta signala je ključna za sledeći korak (ekstrapolaciju), te za ukupnu tačnost finalno generisanih predviđanja. Kao posledica toga, većina istraživačkog rada u STLF oblasti je posvećena upravo procesu modelovanja procesa potrošnje el. energije. Većina aktivnosti vezanih za razvoj prediktivnih modela u STLF oblasti se može posmatrati sa dva aspekta, a to su tehnike koje se koriste i promenljive koje ulaze u sastav STLF modela.

Ilustracija 2.1 Šematski prikaz procesa predviđanja potrošnje el. energije

Sa jednog aspekta razvoja STLF oblasti, istraživači su pokušavali da usvoje različite postojeće tehnike, ili da razviju nove tehnike za potrebe STLF, tretirajući proces potrošnje el. energije kao vremensku seriju. Većina ovakvih tehnika se može grubo podeliti u dve grupe:

- Klasične metode, pod kojima se podrazumevaju razne statističke metode, kao što je regresivna analiza [6] ili analiza vremenskih serija [7].
- Metode veštačke inteligencije, pod kojima se podrazumevaju: veštačke neuronske mreže [8], fuzzy logika [9], kao i metoda vektora podrške [10].

Razne kombinacije pomenutih tehnika su takođe analizirane i primenjivane na probleme u okviru STLF oblasti, sa različitim stepenom uspešnosti.

Sa drugog aspekta razvoja STLF oblasti, istraživači su pokušavali da pronađu skup promenljivih koji bi dao najbolje rezultate predviđanja za svaki konkretan problem na koji su nailazili, dok su istovremeno pokušavali da generalizuju dobijene rezultate i na taj način ustanove određenu kauzalnost za vremensku seriju potrošnje el. energije. Većina ovih pokušaja je bila implicitno sadržana u procesu konstrukcije novog STLF modela, dizajniranog da reši neki konkretan problem. Na primer, uticaji temperature okoline i vlažnosti vazduha na vremensku seriju potrošnje el. energije su proučavani u [11], dok su efekti vlažnosti vazduha i brzine vetra modelovani kao linearna transformacija temperature okoline u [12]. Potrošnja el. energije je proces koji je u vezi sa ponašanjem prirode (okoline potrošača) sa jedne strane, a sa ljudskim aktivnostima (ponašanjem potrošača) sa druge strane. Efekti uticaja okoline na potrošnju el. energije se uglavnom reflektuju kroz promenljive okoline (npr. temperature), dok se karakteristike potrošača uglavnom odražavaju u kalendarskim promenljivama (npr. radno vreme, vikend, itd.). Kombinovani efekti uticaja okoline i ljudskih aktivnosti na sam proces potrošnje el. energije su takođe prisutni, ali analiza ovakvih efekata nije trivijalna.

Sa napretkom deregulacije povećava se broj učesnika na otvorenom energetsom tržištu, gde se električnom energijom trguje kao sa uobičajenim privrednim dobrima. U slučajevima kada je to moguće, potrošači pokušavaju da reorganizuju vremenski raspored potrošnje, kako bi određeni deo potrošnje koji nastaje za vreme veće tarife prebacili u neki drugi period kada je tarifa niža. U takvoj potrošačkoj sredini, koja je osetljiva na promenu cene el. energije, kriva

potrošnje može biti modifikovana u zavisnosti od informacije o trenutnoj ceni el. energije. U skladu sa ovom karakteristikom, istraživači su predložili STLF model [13] koji je osetljiv na cenu el. energije, za čije se performanse tvrdi da su bolje u poređenju sa dotadašnjim tehnikama za STLF. S obzirom na to da ne postoji generički način da se opiše potrošačka sredina osetljivosti potrošnje u zavisnosti od cene analiza modela osetljivih na cenu električne energije izlazi izvan okvira ove disertacije, te takvi sistemi ovde neće biti tretirani.

Iako se većina literature u oblasti STLF bavi modeliranjem procesa potrošnje el. energije, ipak postoje radovi koji se bave drugim aspektima predviđanja, sa ciljem da poboljšaju tačnost STLF modela. Predviđanje ponašanja okoline (uglavnom temperature) je takođe veoma bitan faktor za korektnu STLF funkcionalnost, s obzirom na to da se predviđena temperatura koristi kao ulaz u sam prediktivni model (u koraku ekstrapolacije). Shodno tome, jedna grana istraživačkog rada u STLF oblasti se bavi vremenskom prognozom, tačnije razvojem novih tehnika, poboljšanjem i modifikacijom već postojećih tehnika, kao i implementacijom algoritama za vremensku prognozu u STLF modele [14]. Model za predviđanje temperature je predložen kao osnova za dizajn novog STLF modela [11], uz neophodne modifikacije. Algoritam za vremensku prognozu je implementiran kao sastavni deo STLF modela u [15], sa ciljem da poboljša performanse STLF modela.

Ostatak ovog poglavlja je organizovan na sledeći način: Sekcija 2.2 predstavlja analizu najreprezentativnijih pregledâ literature iz oblasti STLF objavljenih u protekle tri decenije. Sekcija 2.3 predstavlja pregled statističkih metodologija za ostvarivanje STLF funkcionalnosti, uključujući regresivnu analizu, kao i analizu vremenskih serija u kontekstu STLF. Sekcija 2.4 predstavlja pregled metoda veštačke inteligencije primenjenih na STLF oblast, tačnije veštačkih neuronskih mreža, fuzzy logike, kao i metode vektora podrške. U sekcijama 2.5 i 2.6 se opisuju uticaji okoline, tačnije promenljive koje predstavljaju ove uticaje i njihov način uvrštavanja u STLF modele. Nekoliko radova najznačajnijih istraživačkih grupa su prezentovani u sekciji 2.7, a pregled ovog poglavlja je dat u sekciji 2.8.

2.2 Analiza pregledâ literature

2.2.1 Konceptualni pregledi literature

Literatura koja se bavi oblašću predviđanja potrošnje električne energije se može pratiti unatrag barem od 1918. godine [16], [17]. Tokom prve polovine decenije 1980. radna grupa oformljena od strane IEEE je objavila dva rada [16], [18], sa ciljem da sakupi postojeću bibliografiju na temu kratkoročnog predviđanja potrošnje električne energije. U skladu sa modernim razvojem STLF metodologija, većina istraživanja predstavljenih u okviru ovog pregleda datira iz perioda nakon 1980. godine. U proteklih četrdeset godina dostignuća u

STLF oblasti su analizirana sa različitih aspekata, od strane mnogih istraživača. Ovi pregledi (analize) literature se prema pristupu mogu grubo podeliti u dve kategorije, u zavisnosti od toga da li je sprovedeno eksperimentalno testiranje, tj. verifikacija rezultata, ili ne. Pregledi literature koji nisu podrazumevali istovremeno sprovođenje procedura testiranja (konceptualni pregledi) uglavnom tretiraju publikovane istraživačke radove na konceptualnom nivou, a zasnivaju se na razvoju modela, prikazanim rezultatima, kao i prezentovanim zaključcima iz samih radova čijim se pregledom bave [19], [20], [8], [21]. Pregledi literature koji se istovremeno bave i ispitivanjem predloženih metodologija, kao i sprovođenjem različitih eksperimenata u vezi sa publikovanim istraživačkim radovima [14], [22], [23], [24] imaju za cilj da analiziraju, procene i uporede predložene STLF tehnike, koristeći potpuno nove skupove podataka za testiranje (jedan ili više test skupova podataka).

Pregled nekoliko različitih STLF metoda koje se koriste u režimu rada u realnom vremenu (eng. online), kao i onih koje se koriste van radnog režima (eng. offline) je predstavljen u [19], pri čemu taj pregled uključuje sledeće STLF metodologije:

- višestruku regresivnu analizu
- spektralnu dekompoziciju
- metod eksponencijalnog uglađivanja
- pristup zasnovan na stohastičkim vremenskim serijama
- pristup zasnovan na modelu u prostoru stanja
- određene multivarijabilne tehnike modelovanja i identifikacije

Pomenuti izveštaj (pregled literature) skoro u potpunosti ima fokus na onaj deo STLF funkcionalnosti koji se bavi identifikacijom sistema. Prednosti svakog pojedinačnog pristupa, kao i njegove mane, detaljno su prezentovani u tom pregledu. Između različitih ispitanih STLF tehnika, autori u tom pregledu tvrde kako se u tom periodu razvoja STLF oblasti pristup zasnovan na vremenskim serijama, kao i pristup zasnovan na modelu u prostoru stanja veoma često koristio. Modeli zasnovani na analizi vremenskih serija su bili pre svega jednostavni za razumevanje, kao i za implementaciju, a mogli su na dobar način da modeluju ciklično ponašanje procesa potrošnje el. energije, iako je ažuriranje parametara modela u online režimu funkcionisanja bio teško ostvariv u vreme kada su se ove tehnike razvijale. Tehnike zasnovane na modelu u prostoru stanja su mogle relativno lako da se primenjuju u online režimu rada, ali nisu mogle na jednostavan način da predstavljaju uticaj promenljivih okoline (vremenskih promenljivih). Multivarijabilne tehnike za modelovanje procesa potrošnje su od strane autora zavredile najveću pažnju, iako nisu naišle na odgovarajući odziv u praktičnoj primeni u STLF oblasti, najvećim delom zbog njihove velike složenosti, kao i zbog njihove komplikovane implementacije.

2 Pregled literature

Jedna od glavnih stavki ispitivanja svake predložene tehnike u okviru pregleda [19] je svakako bila mogućnost implementacije određene metode, te njene primene u online režimu upotrebe. Pre tri decenije, kako je i naglašeno u pomenutom pregledu, bilo je potrebno veoma mnogo vremena da bi se izvršila offline analiza korišćenjem metode višestruke linearne regresije, dok je ažuriranje parametara modela dobijenih korišćenjem tehnika vremenskih serija takođe zahtevalo relativno dugačak vremenski period. Sa modernim razvojem kompjuterskih tehnologija navedene metode mogu se relativno lako implementirati, pri čemu danas ne postoje pomenuta ograničenja u vremenu izračunavanja parametara modela, kao ni u njihovom online ažuriranju.

U pregledu literature [20] autori tretiraju STLF oblast kao celinu, a ne fokusiraju se na konkretne korišćene tehnike. Ovaj izveštaj izričito definiše STLF oblast kao predviđanje opterećenja elektroenergetskog sistema od jednog časa unapred, do nedelju dana unapred, od trenutka generisanja predviđanja, pri čemu se navedena funkcionalnost obavlja sa rezolucijom od jednog sata, ili od pola sata. Posebno je naglašena važnost STLF funkcionalnosti za potrebe raspoređivanja kapaciteta, kao i za potrebe izračunavanja funkcija sigurnosti (pouzdanosti) u okviru sistema za upravljanje prenosom električne energije (eng. Energy Management System – EMS). Predstavljani su faktori koji utiču na proces potrošnje el. energije, a predstavljena je i klasifikacija najpopularnijih tehnika za modelovanje procesa potrošnje el. energije, kao i za njegovo predviđanje. Takođe je prezentovana i detaljna diskusija na temu praktičnog razvoja, kao i implementacije raznih STLF modela.

U ovom izveštaju autori pokazuju da je trenutna tendencija u STLF oblasti bila takva da se čisto statički modeli koji koriste metode sličnih dana (kriva potrošnje prethodno zabeleženih sličnih dana se uzima kao predviđanje potrošnje predstojećeg dana) zamene dinamičkim modelima, poput vremenskih serija, ili modela u prostoru stanja. Vreme potrebno za obavljanje računskih operacija u okviru dinamičkih metoda razmatranih u navedenom izveštaju nije bilo posebno uzimano u obzir. Jedna od primedbi na celokupno stanje u STLF oblasti (literaturi), izneta u gorepomenutom pregledu, je nedostatak testiranja raznih predloženih metodologija korišćenjem realnih podataka iz elektroenergetskih kompanija, kao i nedostatak standardne procedure za upoređivanje različitih STLF modela uz komparativnu analizu.

Jedan pregled literature u kojoj se analizira aplikacija tehnike veštačkih neuronskih mreža u okviru STLF oblasti je predstavljen u [8]. Specifična namena ovog izveštaja je bila da razjasni nedoumice, kao i potencijalne skepticizme, kada je u pitanju primena veštačkih neuronskih mreža u okviru STLF oblasti. U navedenom izveštaju, autori su na sistematičan način, kritički, izvršili komparativnu analizu oko četrdeset reprezentativnih radova objavljenih u

poslednjoj deceniji prošlog veka, a kao zaključak su izdvojili dve činjenice koje su bile uzrok izvesne odbojnosti prema primeni veštačkih neuronskih mreža za STLF problematiku. Prva od ovih činjenica je ta da veštačke neuronske mreže mogu da dovedu do tzv. pretreniranja (eng. overfitting) tačnije do situacije da se STLF model ponaša sa zadovoljavajućom tačnošću na trening podacima (podacima na osnovu kojih se model kalibriše), a da se na realnim, do tada neviđenim podacima ponaša sa nezadovoljavajućom tačnošću. Druga primedba je bila ta da većina radova pregledanih u okviru navedenog izveštaja, iako testirana sa realnim podacima iz elektroenergetskih preduzeća, nije bila sistematski podvrgnuta testiranju. Dok neki od njih nisu pružili informacije o komparativnoj analizi sa standardnim metodama za testiranje STLF funkcionalnosti, drugi se nisu pridržavali standardnih statističkih procedura prilikom analize performansi modela, tačnije greške modela.

Još jedan od doprinosa izveštaja [8] je sumiranje različitih zahteva i potreba kada se radi o dizajniranju STLF modela primenom veštačkih neuronskih mreža. Koraci koje je potrebno ispoštovati prilikom dizajniranja ovakvog sistema su podeljeni u četiri faze:

- preprocesiranje podataka
- dizajniranje veštačke neuronske mreže
- implementacija modela
- validacija modela

U fazi dizajniranja same neuronske mreže pomoću koje će se izvršiti predviđanje potrošnje, autori prijavljuju tri uobičajena načina, koji se mogu sresti u većini pregledanih načina:

- iterativno predviđanje
- predviđanje pomoću višestrukih modela
- predviđanje pomoću jednog multivarijabilnog modela

U slučaju iterativnog predviđanja, generisanje predviđenih vrednosti za kasnije časove u toku dana predviđanja će se zasnivati na ostvarenim predviđanjima od ranijih časova u toku istog dana (predviđanja). Ovaj koncept je sličan Boks-Dženkinsovim (eng. Box-Jenkins) modelima vremenskih serija, iako se ne može utvrditi da li će srednja vrednost predviđanja konvergirati ka srednjoj vrednosti vremenske serije potrošnje. U slučaju predviđanja pomoću višestrukih modela, nekoliko paralelnih modela se koristi za predviđanje višestrukih vrednosti. Na primer, 24 različite veštačke neuronske mreže se mogu koristiti u paraleli, da bi se dobile 24 predviđene vrednosti (za svaki sat po jedna, za dan za koji se izvršava predviđanje). Autori pregleda su istakli da je ovaj pristup takođe uobičajen za korišćenje regresivnih modela u okviru STLF. U slučaju korišćenja multivarijabilnog modela za predviđanje višestrukih vrednosti, sve vrednosti predviđanja se generišu odjednom, pomoću jedinstvenog modela.

Autori pomenutog izveštaja ističu nedostatak ovakvog pristupa koji se ogleda u povećavanju broja parametara čije je vrednosti potrebno podesiti tokom faze obučavanja.

Za razliku od izveštaja prezentovanog u [8], koji se fokusirao isključivo na primenu tehnike veštačkih neuronskih mreža u okviru STLF oblasti, pregled predstavljen u [21] je predstavio uopšteniji prikaz primene tehnika veštačke inteligencije u STLF oblasti, kao što su: ekspertski sistemi, veštačke neuronske mreže i genetski algoritmi. Ovaj izveštaj je opisao hronološki razvoj svake od pomenutih metoda veštačke inteligencije, primenjenih u STLF oblasti, dok su prednosti njihovog korišćenja sumirane konceptualno i kvalitativno. U pomenutom pregledu autori nisu detaljnije opisivali nedostatke bilo koje od pomenutih metoda veštačke inteligencije u kontekstu primene za STLF problematiku. U pomenutom izveštaju autori tvrde kako su metode veštačke inteligencije sazrele u dovoljnoj meri da pruže praktične koristi u mnogim njihovim aplikacijama, iako ova izjava izlazi iz okvira prezentovanog pregleda (kako su i sami autori to definisali).

2.2.2 Eksperimentalni pregledi literature

U okviru pregleda predstavljenog u [23], pet tehnika za STLF je testirano i upoređeno:

- višestruka linearna regresija
- stohastičke vremenske serije
- generalno eksponencijalno ugađivanje
- model u prostoru stanja
- pristupi zasnovani na bazama znanja (eng. knowledge-based systems)

Značaj pomenutog pregleda je upravo u prezentovanoj komparativnoj analizi između pomenutih pet tehnika, koja je imala za cilj da omogući istraživačima iz STLF oblasti da steknu bolje razumevanje svake od predloženih tehnika, a pogotovo u pogledu stepena kompleksnosti njihovog dizajna i implementacije, kao i rezultata koji se mogu očekivati njihovom primenom. Da bi ostvarili ciljeve testiranja i uporedne analize, autori su implementirali svih pet pomenutih metoda, koje su generisale dvadesetčetvoročasovna predviđanja, sa rezolucijom od jednog časa. Za testiranje su upotrebljeni realna merenja potrošnje električne energije iz jednog elektrokroenergetskog preduzeća iz jugoistočnog dela SAD. Implementacija svake od testiranih tehnika je ukratko opisana, a rezultati su analizirani i upoređivani u skladu sa preporukama autora originalnih (analiziranih) radova. S obzirom na to da autori pomenutog pregleda nisu insistirali na upotrebi najtačnijeg modela za svaku od analiziranih tehnika, ovaj pregled, iako veoma koristan, ne pruža konačne zaključke o definitivnim performansama svake od predloženih tehnika.

U okviru pregleda literature prezentovanog u [22], autori su upoređivali tri tehnike:

- fuzzy logika

2 Pregled literature

- veštačke neuronske mreže
- autoregresivne metode

Uzimajući u obzir sadržaj iznet u okviru pomenutog pregleda, autoregresivne metode nisu pravilno primenjene na STLF problematiku. Proces potrošnje električne energije je po svojoj prirodi nestacionaran, iako su ga autori modelovali bez prethodnih testova stacionarnosti procesa. Stoga zaključak koji je iznet, o superiornosti metoda fuzzy logike, kao i veštačkih neuronskih mreža, u odnosu na autoregresivne metode, nije zasnovan na potpuno korektnim postavkama. Sa druge strane, implementacija, kao i dizajn samih metoda veštačke inteligencije, koje su korišćene u pomenutom pregledu, nije do kraja detaljno opisan.

Evaluacija literature koja je prezentovana u [24] je imala za cilj da uporedi različite metode, kao i da među njima odabere najbolji. Pet metoda je bilo uključeno u proces testiranja i evaluacije:

- autoregresivna metoda, sa integrisanom klizećom srednjom vrednošću (eng. autoregressive integrated moving average – ARIMA)
- periodično autoregresivno modelovanje
- ekstenzija metoda Holt-Winters eksponencijalnog ugađivanja
- modifikovani metod eksponencijalnog ugađivanja
- metoda zasnovana na analizi primarnih komponenti (eng. principal component analysis – PCA)

Za testiranje u okviru pomenutog izveštaja su korišćeni podaci deset različitih vremenskih serija potrošnje električne energije, iz deset različitih evropskih zemalja, u periodu od 30 nedelja. Predviđanje je vršeno za period od 24 časa unapred, sa jednočasovnom rezolucijom. Za potrebe upoređivanja, autori su dizajnirali i dva jednostavna STLF modela sa isključivom namenom za komparativnu analizu. Rezultati su procenjivani na osnovu srednje procentualne greške (eng. mean absolute percentage error – MAPE), kao i na osnovu odnosa srednje apsolutne greške (eng. mean absolute error – MAE) testirane metodologije prema MAE dobijene korišćenjem modela za testiranje. Od pet testiranih metoda, Holt-Winters ekstenzija eksponencijalnog ugađivanja pokazala je konzistentno bolje rezultate u poređenju sa drugim testiranim metodama. U okviru ovog pregleda je pokazano da većina testiranih metoda ostvaruje zadovoljavajuću tačnost predviđanja za kratka vremena predviđanja (od 4 do 6 časova unapred), te da bi se bolja tačnost mogla postići ukoliko bi preciznija vremenska predviđanja bila dostupna.

2.3 Statistički pristupi

2.3.1 Regresivna analiza

Jedan metod za ostvarivanje STLF funkcionalnosti, koji je zasnovan na regresivnoj analizi, predložen je u [6]. U okviru tog rada, dizajnirani modeli su bili testirani na skupu realnih podataka dobijenih iz kompanije „Pacific Gas and Electric Company – PG&E“, a testiranje je izvršeno za prognozu potrošnje el. energije u periodu od naredna 24 časa, kao i za predviđanje maksimalne dnevne potrošnje idućeg dana (dana predviđanja). U pomenutom radu, STLF funkcionalnost je ostvarena isključivo pomoću tehnike regresivne analize, te on predstavlja jedan od nekoliko radova, u proteklih 20 godina, koji u potpunosti imaju fokus na regresivnu analizu u oblasti STLF [25], [26], [27]. U pomenutom radu, primenjeni su neki od koncepata za modeliranje STLF procesa, korišćenjem tehnika višestruke linearne regresije:

- ponderisana tehnika najmanjih kvadrata
- modelovanje temperature korišćenjem stepenskih funkcija za zagrevanje i hlađenje
- modelovanje specijalnih dana (npr. praznika) korišćenjem binarnih promenljivih
- metod za estimaciju robustnih parametara

Kroz ekstenzivne testove primenjene nad skupom podataka za testiranje, autori su u pomenutom radu zaključili da je tehnika koju su razvili superiorna u odnosu na tada već postojeću tehniku, korišćenu u okviru preduzeća PG&E.

Iako je u okviru rada prikazanog u [6] proces dizajniranja STLF modela jasno predstavljen, postoje dve nejasnoće prilikom primene određenih tehnika. Metoda ponderisanih najmanjih kvadrata je primenjena na testirajući skup podataka, sa ciljem da se umanju efekat neregularnih podataka (eng. outliers) na rezultat predviđanja, iako analiza podataka koja bi uopšte detektovala postojanje neregularnih podataka nije prethodno sprovedena, niti su analizirani potencijalni uzroci koji bi mogli dovesti do pojave takvih podataka. Takođe, predloženi model, koji koristi tehniku ponderisanih najmanjih kvadrata, upoređen je jedino sa modelom koji je već bio implementiran, ali ne i sa modelom koji ne koristi tehniku ponderisanih najmanjih kvadrata kao dodatno poboljšanje. Iz navedenih razloga, opšte prednosti novopredloženog modela nisu dovoljno ubedljive, sa stanovišta upotrebe metode ponderisanih najmanjih kvadrata. U okviru istog rada, autori kao jednu od dodatnih tehnika koriste superpoziciju snimljenih temperaturnih merenja sa signalom šuma, sa ciljem da se dobiju robustnija STLF predviđanja, iako ovaj pristup nije u potpunosti opravdan. Na ovaj nedostatak opravdanosti korišćenja pomenute tehnike je i skrenuta pažnja u dodatku samog rada, u jednoj od recenzija, dok komentar samih autora na ovu kritiku nije u potpunosti ubedljiv sa naučnog stanovišta. Imajući u vidu navedene nedostatke, opravdano je ustanoviti da rad autora iznet u [6] predstavlja detaljno utemeljivanje primene tehnika regresivne analize u okviru STLF oblasti.

2 Pregled literature

U radovima koji su publikovani posle [6], a koji se tiču primene regresivne analize u okviru STLF oblasti, autori se uglavnom fokusiraju na različite aspekte višestruke linearne regresije. U radu prezentovanom u [25], autori su predstavili tehniku transformisanja koja služi za modelovanje nelinearnih odnosa između signala potrošnje el. energije i vremenskih promenljivih. Funkcije koje predstavljaju temperaturu okoline i vlažnost vazduha su korišćene kao nezavisne promenljive u regresivnom STLF modelu. Predložena metodologija u pomenutom radu je testirana na zabeleženim podacima koji predstavljaju realna merenja u okviru elektroenergetskog preduzeća iz Tokija (Tokyo Electric Power Company), a rezultati testiranja su bili zadovoljavajući.

U radu prezentovanom u [26], autori su predstavili proceduru za ostvarivanje STLF funkcionalnosti zasnovanu na regresiji. Njihov rad se uglavnom bavio predviđanjem maksimalne dnevne potrošnje (eng. peak load), zato što se predviđanje celokupnog profila potrošnje, u okviru elektroenergetske kompanije za koju je rađeno istraživanje, zasnivalo upravo na predviđenoj maksimalnoj vrednosti dnevne potrošnje. U pomenutom radu, vršena je dekompozicija signala potrošnje el. energije na dve komponente:

- komponentu neosetljivu na vremenske uslove
- komponentu osetljivu na vremenske uslove

Predloženi algoritam je korišćen za generisanje uporednih predviđanja, sa periodom predviđanja od jednog dana unapred, sa zadovoljavajućim nivoom tačnosti.

Procedura za predviđanje potrošnje el. energije koja se sastoji iz dva odvojena koraka, a koja se zasniva na višestrukoj linearnoj regresiji, predložena je u [27]. Bitna razlika između ove metode i većine drugih radova zasnovanih na regresivnim metodama se ogleda u tome da se u prvom koraku STLF algoritma predviđa celokupna potrošena energija u danu za koji se vrši predviđanje, pre nego što se generišu predviđanja koja predstavljaju časovnu potrošnju. Predloženi algoritam je razvijan i testiran u okviru Elektroprivrede Srbije, gde se i koristi, u okviru dispečerskog centra, za ostvarivanje STLF funkcionalnosti za vremenske periode od jedan do sedam dana unapred.

Pristup za ostvarivanje STLF funkcionalnosti, zasnovan na regresiji bez parametara je predožen u radu prezentovanom u [28]. Model za predstavljanje procesa potrošnje el. energije je konstruisan na način da predstavlja funkciju gustine verovatnoće procesa potrošnje, kao i faktora koji utiču na proces potrošnje. Odgovarajuće STLF predviđanje u pomenutom radu je predstavljalo uslovnu očekivanu vrednost potrošnje el. energije, u skladu sa prezentovanim faktorima koji utiču na potrošnju, kao što su vreme u toku dana, vremenski uslovi, itd. Pomenuta metodologija predstavljena u tom radu ne zahteva rezultate vremenske prognoze, da bi generisala očekivane vrednosti potrošnje, što je bitna razlika u odnosu na ostale

pomenute radove koji se bave primenom regresivne analize u okviru STLF oblasti. Zabeležena merenja potrošnje el. energije, kao i temperature okoline, u trajanju od tri nedelje su korišćena za generisanje predviđanja nedelju dana unapred. Rezultati testiranja su po preciznosti bili uporedivi sa nekim tehnikama koje koriste veštačke neuronske mreže, što upućuje na zaključak da za uspešno obavljanje STLF funkcionalnosti nije presudna tehnika koja se koristi za izračunavanje predviđanja, već ispravno modeliranje (odabiranje odgovarajućih ulaznih promenljivih). Ipak, s obzirom da je celokupan metod bio testiran na malom uzorku podataka (samo jedan deo leta, u okviru jedne sezone), testiranje nije dovoljno ubedljivo, te nije moguće izvući generalne zaključke o tome da li bi se model dobro ponašao u drugačijim uslovima (tokom čitave sezone, tj. u drugim sezonama). Estimacija pomoću gustine verovatnoće bez parametara je primenjena na predviđanje zahteva za električnom energijom, na nivou različitih klasa potrošača, od strane iste istraživačke grupe, u radu prezentovanom u [29].

2.3.2 Analiza vremenskih serija

U okviru rada prezentovanog u [30], regresivne tehnike su korišćene u kombinaciji sa ARIMA modelima. Korišćenje regresivnih tehnika ima dve namene:

- predviđanje maksimalne, kao i minimalne dnevne potrošnje
- normalizovanje vremenskih serija potrošnje, tačnije uklanjanje trenda koji predstavlja osetljivost vremenske serije na promene promenljivih okoline (temperature, vlažnosti vazduha, itd.).

Nakon prethodno izvršenih koraka, ARIMA metod je primenjivan za generisanje predviđanja potrošnje, sa pomenutom normalizovanom vremenskom serijom kao ulazom. Generisana predviđanja se u poslednjem koraku prilagođavaju, na osnovu predviđenih vrednosti minimalne i maksimalne dnevne potrošnje iz prvog koraka predviđanja.

Autori su u radu prezentovanom u [7] primenili ARIMA modele, zajedno za još nekim Box-Jenkins tehnikama, za ostvarivanje STLF funkcionalnosti. Autori u pomenutom radu tvrde kako su ove tehnike veoma pogodne za primenu u okviru STLF oblasti. Nelinearna transformacija vremenskih promenljivih, tačnije eksponent trećeg stepena temperature, je predložen da predstavi nelinearnu zavisnost signala potrošnje el. energije od signala temperature okoline. U okviru pomenutog rada, tri modela dobijena korišćenjem vremenskih serija su upoređena sa konvencionalnim metodama korišćenim u elektroenergetskim preduzećima, koja se oslanjaju na iskustvo operatera, a to su:

- ARIMA modeli
- modeli koji koriste standardnu funkciju prenosa
- modeli koji koriste funkciju prenosa zajedno sa nelinearnim transformacijama

Testovi su vršeni za tri perioda dužine 20 dana, od kojih je svaki pripadao određenom godišnjem dobu (zima, proleće i leto), u toku 1984. godine. Na osnovu rezultata testova moglo se zaključiti da je ponašanje sva tri predložena metoda bolje od do tada korišćenih tehnika, sa aspekta tačnosti predviđanja. Model koji koristi funkciju prenosa zajedno sa nelinearnim transformacijama je od sve tri predložene metode ostvario najbolje rezultate.

Pristup u kome su korišćene vremenske serije, a koji može da inkorporira ARIMA metode, u kombinaciji sa iskustvom iskusnih sistemskih operatora, predstavljen je u radu [31]. Ovaj modifikovani ARIMA model je kao inicijalnu tačku predviđanja prihvatao vrednosti potrošnje predložene od strane sistemskog operatora, koje se kasnije kombinuju sa zabeleženim merenjima temperature i potrošnje u prošlosti, u procesu višestruke linearne regresije, da bi se dobila finalna predviđanja potrošnje el. energije. Za razliku od već opisanog pristupa, iznetog u [7], u kome su konstruisana četiri posebna modela za svaku godišnju sezonu, pristup iznesen u [31] podrazumeva korišćenje 8 modifikovanih ARIMA modela za predviđanje profila potrošnje (četiri različita tipa dana, u kombinaciji sa hladnom i toplom sezonom u toku godine), kao i još 8 različitih modela za predviđanje maksimalne dnevne potrošnje. Za testiranje pomenutog modela su korišćena merenja iz nacionalnog dispečerskog centra Irana zabeležena u periodu od 3 godine, pri čemu su podaci u toku dve godine korišćeni za definisanje parametara svih 16 modela, dok su podaci u toku jedne godine korišćeni za utvrđivanje performansi modela. Predložena metodologija je takođe testirana, u okviru komparativne analize, u odnosu na obične ARIMA modele, veštačke neuronske mreže, kao i u odnosu na predviđanja generisana od strane sistemskih operatora. Zaključak pomenutog istraživačkog rada je da, sa aspekta tačnosti predviđanja, modifikovani ARIMA model daje najbolje rezultate u poređenju sa ostalim metodama.

U literaturi se takođe mogu pronaći drugačiji pristupi koji koriste tehnike vremenskih serija, za potrebe ostvarivanja STLTF funkcionalnosti. Autoregresivni modeli sa pragom odbacivanja u kombinaciji sa pravilima razdvajanja različitih klasa predviđanja su prezentovani u okviru istraživačkog rada [32]. Modifikovani model koji koristi autoregresivnu tehniku klizeće srednje vrednosti (eng. Auto Regressive Moving Average – ARMA), sa ciljem da uvrsti informaciju o procesu potrošnje dobijenu analizom ne-Gausovog tipa, predstavljen je u [33]. Adaptivni ARMA model je implementiran i analiziran u poređenju sa Box-Jenkins metodama u okviru rada prezentovanog u [34], pri čemu autori tvrde da njihov model generiše predviđanja veće tačnosti. Metod koji koristi periodične autoregresivne modele je prezentovan u okviru rada [35]. Autoregresivni model sa klizećom srednjom vrednošću i spoljnim ulazima (eng. Autoregressive Moving Average model with exogenous inputs – ARMAX), koji koristi optimizacionu metodu roja čestica (eng. Particle Swarm Optimization – PSO) za

identifikaciju parametara, predložen je u okviru rada [36]. U radu predstavljenom u [35], tehnika za nelinearnu identifikaciju sistema je primenjena na STLF problematiku. Sve tehnike, kao i inženjerska rešenja koja prate njihovu implementaciju i korišćenje, pružaju koristan uvid u određene aspekte STLF oblasti.

2.4 Tehnike veštačke inteligencije

2.4.1 Veštačke neuronske mreže

Upotreba metoda veštačke inteligencije, tačnije veštačkih neuronskih mreža, za rešavanje STLF problematike, može se postaviti na početak 1990-tih godina [37], kada su neuronske mreže predložene u kombinaciji sa regresivnom analizom i vremenskim serijama, kao deo posebnog algoritma. Od primenjene neuronske mreže se u pomenutoj aplikaciji očekivalo da može uspešno da modeluje nelinearne zavisnosti između promenljivih koje predstavljaju sistemsko opterećenje i promenljivih koje predstavljaju efekte okoline (vremenske promenljive), kao i da mogu da se prilagode novim podacima (da budu adaptivne). Predloženi algoritam je testiran korišćenjem realnih merenja, zabeleženih u okviru kompanije „Puget Sound Power and Light Company“, koja su sadržavala podatke o sistemskom opterećenju na nivou cele elektroenergetske mreže, kao i o temperaturi okoline, u rezoluciji od jednog časa. Podaci su bili dostupni u vremenskom periodu od 1.11.1988. do 30.1.1989. za područje Sijetla i Takome (eng. Seattle-Tacoma). U okviru pomenutog rada, bila su konstruisana tri scenarija za testiranje:

- predviđanje maksimalne dnevne potrošnje
- predviđanje celokupne potrošnje
- predviđanje časovne potrošnje

prilikom čega su uobičajeni radni dani bili od glavnog interesa za sprovođenje procedura testiranja. Predstavljeni algoritam je testiran u poređenju sa STLF procedurom koja je tada bila implementirana u okviru kompanije, iako poređenja sa klasičnim metodama vremenskih serija i regresivne analize nisu učinjena u okviru pomenutog rada.

Metoda zasnovana na ANN [38] je razvijena u okviru kompanije „Pacific Gas & Electric Company“, pri čemu je izvršena komparativna analiza sa tehnikama zasnovanim na regresiji [6], ranije razvijenim u okviru iste kompanije. Oba modela su testirana pomoću zabeleženih podataka iz 1991. godine, pri čemu su podaci za određivanje parametara modela zabeleženi u periodu od 1986. do 1990. godine. Testovi su vršeni za predviđanje maksimalne dnevne potrošnje, kao i za predviđanje satne potrošnje. U navedenom radu, autori su demonstrirali da model zasnovan na ANN generiše rezultate povećane tačnosti predviđanja u obe klase testova

2 Pregled literature

(predviđanje maksimalne dnevne, kao i časovne potrošnje). Potrebno je naglasiti nekoliko doprinosa učinjenih u pomenutom radu, a to su:

- robustno predviđanje
- precizno modelovanje temperature
- precizno modelovanje specijalnih događaja

Ovde treba dodati informaciju o načinu na koji su birane ulazne promenljive u oba modela, pošto je jedan deo istraživanja u okviru ove disertacije posvećen upravo tome. Po rečima autora, ulazne promenljive su birane skoro isključivo po sistemu pokušaja i greške, tj. na osnovu inženjerske procene, kao i prethodnog iskustva samih autora, što ukazuje na činjenicu da ne postoji standardizovana i formalizovana metoda za izbor ulaznih promenljivih priilkom dizajniranja STLF modela. Inherentna vrednost rada predstavljenog u [38], koja nije eksplicitno naglašena u samom njegovom sadržaju, je sadržana u činjenici da su autori analizirali dva različita modela, oba razvijana od strane iste grupe, u okviru iste kompanije, sa vremenskom razlikom od tri godine. S obzirom na to da je pomenuta grupa u oba slučaja pokušala da dizajnira model maksimalnih performansi, oba modela se mogu smatrati najboljima u domenu korišćenih tehnika, u okviru rada iste grupe. Iako autori tvrde da je izbor ulaznih promenljivih „verovatno“ optimalan, ili „skoro“ optimalan, ne postoje formalni dokazi koji podupiru ovakve tvrdnje. Čak i u novijem periodu razvoja STLF, optimalan izbor ulaznih promenljivih, pogotovo za metode koje koriste tehnike veštačke inteligencije, ostaje jedan od izazova koji nisu u potpunosti rešeni.

Veštačka neuronska mreža upotrebljena u [38] koristi algoritam sa propagacijom greške unatrag za obučavanje (eng. Back Propagation Network – BPN), dok je u [39] predstavljena ANN drugačijeg tipa, koja koristi radijalne funkcije (eng. Radial Basis Function Network – RBFN). Model dizajniran upotrebom RBFN metodologije je testiran od strane autora sa modelom dizajniranim upotrebom BPN metodologije, pri čemu je konstatovano da RBFN model daje bolje rezultate predviđanja u pogledu preciznosti. Iako su oba modela bila testirana na ranije pomenutom skupu podataka, u okviru kompanije PG&E, treba naglasiti da je BPN korišćena za potrebe testiranja u [39] bila drugačija nego ona predstavljena u [38]. Oba modela predstavljena u [39] su obučavana korišćenjem istog skupa podataka, pri čemu su zabeležena merenja iz 1985. godine služila kao obučavajući skup, a iz 1986. kao skup za verifikaciju rezultata. Pošto su se pomenuti modeli fokusirali na uobičajene radne dane, merenja zabeležena za datume šest praznika slavljenih u SAD (Nova Godina, dan sećanja, dan nezavisnosti, dan rada, dan zahvalnosti, Božić) su izbačena iz obučavajućeg i iz verifikacionog skupa podataka. Oba modela koja su korišćena generišu predviđanja za maksimalnu dnevnu potrošnju, kao i za celokupnu potrošenu energiju na dan predviđanja.

2 Pregled literature

Kao dodatak osnovnoj funkcionalnosti, RBFN model poseduje mogućnost da izračuna određene mere pouzdanosti, koje podrazumevaju intervale pouzdanosti za generisana predviđanja, kao i ekstrapolacijske indekse koji služe da odrede u kolikoj meri je trenutni skup ulaznih podataka (u fazi eksploatacije modela) sličan sa već viđenim podacima (u fazi obučavanja modela). Još jedna od značajnih prednosti predloženog RBFN modela je bila skraćeno vreme obučavanja, u odnosu na BPN metodu razvijenu od strane istih autora.

Istaknuti rad na razvoju ANN modela za potrebe rešavanja STLF funkcionalnosti je učinjen pod pokroviteljstvom instituta „Electric Power Research Institute – EPRI“, a predstavljen je od strane grupe autora u radovima [40], [11], [12], [13]. Dizajnirani modeli koji su predstavljali rezultat rada pomenute grupe su označeni akronimom ANNSTLF (eng. Artificial Neural Network Short-Term Load Forecaster), pri čemu su raspoređeni po generacijama (prva [40], druga [11] i treća [12] generacija, respektivno). Takođe je u okviru pomenutog istraživanja razvijen i jedan ANN model [11], namenjen za korišćenje u situacijama kada vremenski podaci iz bilo kog razloga nisu dostupni. Modeli razvijeni u okviru ANNSTLF istraživanja predstavljaju pokušaj da se podigne kvalitet STLF funkcionalnosti na nivou koji prevazilazi primenu u okviru konkretnog elektroenergetskog preduzeća, a koji bi se ogledao u poboljšanju preciznosti predviđanja, kao i povećavanju ekonomskih prednosti. Modeli nastali kao rezultat ovog istraživanja su implementirani u nekoliko elektroenergetskih kompanija [41]. Skoriji razvoj modela iz ANNSTLF grupe podrazumeva povećavanje tačnosti STLF predviđanja u skladu sa informacijama o tržišnoj ceni električne energije (u tzv. okruženju osetljivom na cenu el. energije), pri čemu su za ostvarivanje ove funkcionalnosti implementirani modeli koji simultano koriste tehnike ANN, kao i Fuzzy logike (eng. Neuro-Fuzzy models) [13].

Razvoj različitih metodologija za potrebe ostvarivanja STLF funkcionalnosti koji koristi pristup zasnovan na ANN, prošao je tokom istorije STLF oblasti sličnu putanju kao i razvoj koji koristi pristup zasnovan na regresivnoj analizi. Na primer, procedura minimizacije greške koja koristi metod ponderisanih najmanjih kvadrata je primenjena u modelu implementiranom korišćenjem regresivne analize [6], dok je ista metoda (ponderisanih najmanjih kvadrata) predložena za obučavanje ANN modela za STLF [42]. Osetljivost STLF modela na vremenske promenljive je takođe razmatrana u okviru pristupa koji koristi regresivnu analizu [6], dok je za potrebe korišćenja modela, u uslovima kada se greška predviđene i ostvarene temperature povećava, predložena ANN sačinjena od više različitih modula [15].

STLF modeli koji koriste tehniku ANN su najviše bili primenjivani u SAD, ali se zanimljivi primeri njihove primene mogu naći u Evropi, na primer u Grčkoj, pri čemu je odgovarajući

istraživački rad prezentovan u radovima [43], [44]. Navedena studija je rezultirala sa nekoliko zanimljivih zaključaka:

- U skladu sa grčkom mediteranskom klimom, koja podrazumeva blage i vlažne zime, kao i topla i suva leta, opterećenje rashladnih i grejnih uređaja je umereno tokom čitave sezone, te uvrščavanje informacija o vremenskim promenljivama nema uticaja na poboljšanje preciznosti STLF predviđanja.
- Broj skrivenih neurona u okviru ANN korišćene za implementaciju modela, nema izraženog uticaja na preciznost predviđanja, ali zato ima uticaja na vreme obučavanja (koje se povećava sa povećanjem broja skrivenih neurona ANN).
- Sprovedena su tri eksperimenta, iz kojih se mogu izvesti jedinstveni zaključci o tome da je korišćenje jedne ANN za predviđanje potrošnje za svih sedam dana u nedelji (prilikom čega navedena ANN ima poseban ulaz koji pruža informaciju o tome za koji dan u nedelji se izvršava predviđanje) bolje (u smislu preciznosti i kompleksnosti) nego korišćenje 7 odvojenih ANN.
- Različiti ciklusi ažuriranja parametara STLF modela rezultiraju različitom tačnošću tih modela. U poređenju sa ciklusom ažuriranja parametara od godinu dana, smanjenje ciklusa na mesec dana povećava preciznost predviđanja za 8%, dok smanjenje ciklusa na nedelju dana povećava preciznost predviđanja za 11%.
- Predviđanje potrošnje za posebne dane ili praznike se može poboljšati putem posebnog odabira podataka koji sačinjavaju obučavajući skup.

Rani razvoj STLF modela upotrebom ANN je takođe bio praksa u elektroenergetskim kompanijama u Tajvanu, što je prikazano u radovima [45], [46], [47].

U literaturi vezanoj za primenu ANN u STLF oblasti se takođe mogu sresti sledeći pristupi, tj. različiti aspekti poboljšavanja STLF ANN modela:

- selekcija ulaznih parametara
- selekcija podataka koji sačinjavaju obučavajući skup
- dizajn strukture ANN

pri čemu su navedeni aspekti STLF modeliranja obrađeni u sledećim radovima [48], [49], [50], [51]. Sveobuhvatni pregled koji tretira korišćenje ANN u STLF oblasti, u kome je sumiran razvoj tokom devedesetih godina prošlog veka, prikazan je u [8]. Skoriji razvoj oblasti obuhvata razvoj ANN modela koji koriste nekoliko paralelnih (različitimvremenskih prognoza [52], kao i praktičnu upotrebu i implementaciju STLF modela koji koriste ANN, među kojima je bitan aspekt kombinacija STLF funkcionalnosti sa raspoređivanjem proizvodnih kapaciteta (eng. Unit Commitment) [53].

2.4.2 Fuzzy logika

U periodu od druge polovine osamdesetih do prve polovine devedesetih godina prošlog veka, istraživači su bili zainteresovani za dizajniranje ekspertskog sistema, koji bi u svoju funkcionalnost inkorporirao ljudsko iskustvo, konkretno iskustvo sistemskih operatora, pri čemu je rezultat odgovarajućih istraživanja prikazan u radovima [54], [55], [56], [57]. Od takvih modela se očekivalo da daju pouzdane prognoze, visoke tačnosti, u vremenu koje je prihvatljivo sa aspekta praktične upotrebe, unutar elektroenergetskog sistema. Jedan ekspertski STLF sistem je razvijen za potrebe preduzeća „Dominion Electric Cooperative in Virginia“ iz SAD, pri čemu je odgovarajući razvoj prikazan u radovima [55], [56], [57]. Za potrebe Tajvanskog elektroenergetskog sistema, autori istraživačkog rada prikazanog u [58] su razvili ekspertski sistem zasnovan na iskustvu operatora. Nekoliko godina kasnije, ista grupa autora je razvila fuzzy ekspertski sistem u okviru istog elektroenergetskog sistema, a odgovarajuće istraživanje je predstavljeno u radu [58]. Predloženi fuzzy ekspertski sistem koristi teoriju fuzzy skupova za modelovanje ponašanja vremenskih promenljivih, kao i za statističko modelovanje STLF procesa, pri čemu se parametri modela mogu ažurirati sa ciklusom od jednog časa.

U ranijoj fazi razvoja oblasti ekspertskih sistema u okviru STLF, modeli su se u većini slučajeva u velikoj meri oslanjali na ulazne informacije zadate od strane ljudi (sistemskih operatora), dok su istraživači nešto kasnije pokušavali da dizajniraju automatske fuzzy ekspertске sisteme [59], [60], [61], [9], [62].

STLF model koji koristi teoriju fuzzy skupova je predstavljen u [9], pri čemu se za formiranje fuzzy pravila koristi automatska procedura obučavanja, koja generiše fuzzy pravila na osnovu obučavajućeg skupa podataka. Pomenuti model je korišćen da bi se predvidele maksimalna dnevna potrošnja, kao i ukupna potrošnja za dan predviđanja. Ulazi u model su odabirani na osnovu iskustvenih procena inženjera, kao i na osnovu statističke analize, pa su tako ulazi za STLF modele koji predviđaju maksimalnu dnevnu potrošnju (odnosno ukupnu potrošenu energiju) formulisani kao maksimalna dnevna potrošnja (odnosno ukupna potrošena energija) za trenutni dan, u kombinaciji sa kompozitnim indeksima temperature sledećeg dana (dana predviđanja).

Još jedan model za STLF koji koristi metod optimalnog fuzzy zaključivanja je predstavljen u radu [61]. Za potrebe identifikacije modela su korišćene tehnike najstrmijeg silaska (eng. Steepest Descent), kao i simuliranog kaljenja (eng. Simulated Annealing). Ulazi koji su korišćeni za potrebe predviđanja potrošnje sledećeg časa su bili: potrošnja zabeležena (za jedan čas pre časa predviđanja, razlika između poslednje zabeležene potrošnje i srednje potrošnje (pri čemu se srednja potrošnja definiše kao aritmetička sredina zabeleženih

vrednosti potrošnje u toku tri dana u prošlosti, za isti dan u nedelji, za isti sat za koji se generiše predviđanje), kao i razlika između izračunate srednje temperature za čas predviđanja (izračunavanje se vrši na isti način kao i za prethodno opisani ulaz) i za čas koji mu prethodi. Za potrebe predviđanja za jedan čas unapred, kao i za 24 časa unapred, u okviru rada [62] je predstavljena tehnika za formiranje klastera, koja ima za cilj da odredi broj fuzzy pravila kao i funkcija pripadnosti. Ulazni parametri STLF modela su određeni korišćenjem tehnika za analizu varijanse signala (eng. Analysis of Variance – ANOVA), koje su implementirane u okviru softvera za statističku analizu - SAS. Za potrebe predviđanja u okviru pomenutog rada, generisano je 24 različita fuzzy modela, pri čemu svaki od njih odgovara određenom mesecu u toku godine, kao i određenom tipu dana (radni ili neradni).

Pristup fuzzy modelovanju koji identifikuje premise i konsekvantna pravila u dve odvojene faze, pomoću ortogonalne metode najmanjih kvadrata je predstavljen u [60]. Fuzzy modeli razvijeni u okviru pomenutog istraživanja su testirani u okviru elektroenergetskog sistema Grčke, a komparativne analize su izvršene između fuzzy modela i ANN modela prethodno razvijenih od strane istih autora. Upoređena su tri različita modela, prilikom čega je konstatovano da svaki od njih generiše predviđanja slične preciznosti, s tim što fuzzy modeli predloženi u okviru pomenutog istraživanja imaju manje složenu strukturu.

U skorijoj fazi razvoja STLF oblasti, primena fuzzy logike je prikazana u radu [59], pri čemu je model konfigurisan tako da ulazi predstavljaju predviđenu temperaturu, kao i čas u toku dana za koji se izvršava predviđanje, dok je izlaz iz modela predviđena potrošnja el. energije za taj čas. Za ulaz koji predstavlja čas u toku dana, model je posedovao 8 fuzzy funkcija pripadnosti, za temperaturu 4, a za predviđenu potrošnju takođe 8. Predloženi pristup je testiran pomoću podataka zabeleženih u okviru jednog elektroenergetskog preduzeća iz Indije. Iako je fokus pomenutog rada bio isključivo na fuzzy logiku u okviru STLF oblasti, postoje neke nejasnoće, kao na primer način na koji su formirane funkcije pripadnosti, koji nije do kraja opisan.

Fuzzy linearna regresija, tačnije regresija verovatnoće, je takođe bila predmet istraživanja [63], u skladu sa tendencijama da se ostvari pouzdanost i robustnost STLF modela, kao i sa težnjom da se predviđanja za specijalne dane u toku godine generišu sa većom preciznošću [64]. Autori su u okviru rada prezentovanom u [63] razvili dva različita STLF modela, koristeći pristup regresije verovatnoće, pri čemu je svaki model bio namenjen za specifičnu sezonu, tj. letnju ili zimsku. Model korišćen za potrebe predviđanja u toku zimske sezone je bio zasnovan na metodi GLM, pri čemu su ulazne promenljive bile odabrane na sledeći način:

- eksponent trećeg stepena temperature, za čas predviđanja
- zabeležene temperature u toku tri časa, pre časa predviđanja

- rashladni faktor vetra za čas predviđanja
- rashladni faktori vetra za dva časa, pre časa predviđanja

U okviru letnjeg STLF modela, korišćene su iste ulazne promenljive, s tom razlikom što je umesto rashladnog faktora vetra korišćen stepen vlažnosti vazduha. Glavni doprinos pomenutog istraživanja se ne ogleda u poboljšanju tačnosti predviđanja, već u pouzdanosti generisanih rezultata, kao i u donjim i gornjim granicama predviđanja.

Još jedna primena fuzzy linearne regresije je zabeležena u radu predstavljenom u [64], pri čemu je dizajnirani model demonstrirao zadovoljavajući nivo tačnosti. Predviđanja su bila zasnovana isključivo na pretnodnim zabeleženim vrednostima potrošnje, pri čemu nisu korišćene dodatne ulazne promenljive, poput informacija o temperaturi, vlažnosti, itd. Ovaj model je u kasnijoj fazi nadograđen korišćenjem generalnog eksponencijalnog uglađivanja, pri čemu su rezultati ove modifikacije prikazani u radu [65].

2.4.3 Fuzzy neuronske mreže

Pristup zasnovan na korišćenju fuzzy neuralnih mreža (eng. Fuzzy Neural Network – FNN) je bio primenjen za potrebe ostvarivanja STLF funkcionalnosti u okviru grčkog elektroenergetskog sistema, koji je imao maksimalnu ostvarenu potrošnju od 5.5GW u toku 1993. godine, pri čemu je odgovarajući istraživački rad predstavljen u [66]. Primenjena FNN tehnika je bila fuzzy model sa strukturom mreže, pri čemu je korišćena procedura obučavanja uobičajena za ANN. Podaci zabeleženi u toku 1992. godine su korišćeni kao obučavajući skup, dok je 1993. godina služila za izvršavanje testova, pri čemu podaci zabeleženi za specijalne, kao i za neregularne dane nisu ulazili u proceduru testiranja. Ukupno je formirano 168 različitih FNN modela, po jedan za svaku kombinaciju određenog tipa dana i određenog časa u toku dana. U okviru ovog istraživanja je izveden zaključak da je funkcionalnost FNN modela bolja u odnosu na funkcionalnost ANN modela, zbog njihove mogućnosti da inkorporiraju ekspertsko znanje sistemskih operatora, kao i da se njihovi parametri inicijalizuju na osnovu realnih fizičkih veličina.

U okviru istraživačkog rada prezentovanog u [67], autori su razvili drugačiji mehanizam za primenu FNN tehnika u okviru STLF problematike. Umesto konstrukcije pojedinačnog FNN modela za svaku kombinaciju određenog časa u toku dana, kao i određenog tipa dana, formulisani su pojedinačni modeli koji odgovaraju određenom tipu dana u kombinaciji sa određenom sezonom u toku godine. Kao prvi korak predviđanja, generisani su rezultati za minimalnu i maksimalnu potrošnju idućeg dana (dana predviđanja). Kao drugi korak, generisana je kriva potrošnje, u skladu sa predviđenim minimalnim i maksimalnim vrednostima, a na osnovu istorijskih podataka o potrošnji. U pomenutom radu nije učinjena komparacija sa modelom predstavljenim u [66].

Još jedan tip FNN metodologije u okviru STLF oblasti je prezentovan u [68], pri čemu su ulazne promenljive modela formulisane kao vrednosti fuzzy funkcije pripadnosti, za određenu vrednost potrošnje ili vremenske promenljive, a izlaz iz modela je predstavljen pomoću vrednosti fuzzy funkcije pripadnosti za predviđenu potrošnju. Nakon generisanja inicijalnih vrednosti predviđanja od strane FNN modela, korišćen je fuzzy ekspertski sistem, za korekciju predviđenih vrednosti, te su na taj način formulisane konačne vrednosti za predviđenu potrošnju. Za pomenuti istraživački rad su korišćena merenja iz elektroenergetske kompanije u Virdžiniji, SAD, pri čemu su rezultati predviđanja srednje dnevne potrošnje, kao i maksimalne i minimalne, te rezultati predviđanja časovnog profila potrošnje bili zadovoljavajuće precizni. U okviru pomenutog rada učinjene su različite analize, koje su imale za cilj da pokažu opravdanosti fuzzy korekcije rezultata.

Za potrebe predviđanja potrošnje sa periodom od jednog dana unapred, grupa autora je predstavila novi FNN model u okviru istraživanja iznetom u [69], pri čemu je standardna ANN korišćena za utvrđivanje nelinearnih zavisnosti između ulaznih i izlaznih parametara, te za generisanje inicijalnih predviđanja potrošnje, dok je fuzzy sistem korišćen za naknadno procesiranje rezultata ANN. Predloženi model je testiran na zabeleženim merenjima elektroenergetske kompanije „Singapore Power Ptd Ltd.“. Obučavajući skup je formiran na osnovu godinu i po dana zabeleženih merenja, dok je skup za testiranje formiran na osnovu idućih pola godine zabeleženih merenja. Predloženi FNN model je u okviru pomenutog istraživanja bio upoređen sa već postojećim modelom, dobijenim korišćenjem višestruke linearne regresije, pri čemu su greške predviđanja, nastale korišćenjem FNN modela, bile manje za sve tipove dana u toku godine, uključujući praznike.

2.4.4 Metoda vektora podrške i ostale metode VI

Metoda vektora podrške (eng. Support Vector Machine – SVM) predstavlja metodu veštačke inteligencije primenjivanu u raznim oblastima [70], kao što su finansijsko predviđanje ponašanja tržišta, predviđanje potrošnje električne energije, itd. U toku 2001. godine, organizovano je takmičenje pod pokroviteljstvom EUNITE, čiji je cilj bio srednjoročno predviđanje potrošnje električne energije, konkretno predviđanje maksimalne dnevne potrošnje u toku januara 1999. godine. Podaci na osnovu kojih je trebalo generisati rezultate su podrazumevali sledeće:

- zabeležene potrošnje za 1997. i 1998. godinu, sa polučasovnom učestalošću
- zabeleženu srednju dnevnu temperaturu
- datume praznika

Model koji je u okviru pomenutog takmičenja ostvario najbolje rezultate, koristio je pristup zasnovan na SVM, pri čemu su u fazi obučavanja bili uzeti u obzir samo podaci iz zimskih

perioda prethodnih godina, a podaci o temperaturi okoline su bili isključeni iz obučavajućeg skupa. Pomenuti istraživački rad je predstavljen u [10]. Iako je pomenuto takmičenje imalo za cilj predviđanje u okviru MTLF funkcionalnosti, treba uzeti u obzir činjenicu da je tehnika zasnovana na SVM generisala najbolje rezultate, te razmotriti mogućnost njene primene u STLF oblasti.

U skorije vreme, kombinacija SVM i regresije je predložena za predviđanje u okviru elektroenergetskih sistema rasprostranjenih na velikim geografskim površinama [71], pri čemu se regionalnim particionisanjem unutar zadate geografske oblasti, te kombinacijom lokalnih rezultata, ostvaruje finalno predviđanje zadovoljavajuće tačnosti.

Pored tehnike zasnovane na ANN, još nekoliko pristupa koji koriste strukturu mreže je bilo predloženo za rešavanje STLF problematike, kao na primer mreže funkcionalne povezanosti (eng. Funcional Link Network) [72] i evolutivnih mreža zasnovanih na wavelet transformaciji (eng. Evolutive Wavelet-based Network – EWN) [73]. Nekoliko hibridnih modela, koji su koristili jednu metodologiju za identifikaciju parametara modela konstruisanog upotrebom drugačije metodologije, takođe se mogu pronaći u STLF literaturi.

Za potrebe identifikacije fuzzy funkcija pripadnosti, kao i različitih pravila odlučivanja u okviru neuralnog fuzzy modela, grupa autora je iskoristila genetski algoritam, pri čemu je odgovarajuće istraživanje prikazano u okviru rada [74].

Identifikacija parametara ARMAX modela je izvršena pomoću evolutivnog programiranja, kao i pomoću metode optimizacije rojem čestica (PSO), a odgovarajuće istraživanje je prikazano u [75], [76].

Metode u kojima se primenjuje nekoliko koraka, pri čemu svaki od njih podrazumeva upotrebu drugačije tehnologije se takođe mogu sresti u literaturi. U nekima od ovih višekoračnih metoda se koriste različite tehnike za generisanje inicijalnih predviđanja, (npr. regresija [77], ANN [13], [78], [79], [69], ili RBF ANN [80]), dok se za njihovo naknadno procesiranje koristi fuzzy logika.

U okviru STLF literature se mogu pronaći i višekoračne metode koje koriste jednu vrstu metodologije za preprocesiranje podataka, tačnije za njihovu klasifikaciju, a potom drugu metodologiju za generisanje finalnih rezultata predviđanja. Neki od radova na ovu temu su predstavljeni u [81], [82], [83], [84].

2.5 Vremenske promenljive

Proces potrošnje električne energije je u tesnoj vezi sa vremenskim uslovima, pogotovo u područjima gde se električni uređaji za klimatizaciju intenzivno koriste. Iako postoje pristupi u okviru STLF oblasti, koji omogućavaju predviđanje bez korišćenja informacija o vremenskim uslovima [24], većina pristupa ipak koristi takve informacije kao ulazne

2 Pregled literature

promenljive STLF modela. U STLF literaturi se može naići na različite vrste vremenskih promenljivih, kao i na različit način njihove upotrebe u sastavu STLF modela. Neke od vremenskih promenljivih, na čiju se upotrebu u okviru STLF modela može često naići, predstavljaju:

- temperaturu vazduha
- relativnu vlažnost vazduha
- brzinu vetra
- pokrivenost oblacima

Vremenske promenljive koje se takođe mogu sresti u literaturi [38], [56], ali sa manjom učestalošću upotrebe su:

- temperatura saturacije vazduha
- temperatura orošavanja
- pravac vetra
- indeks kombinacije temperature i vlažnosti (eng. Temperature Humidity Index – THI)
- rashladni faktor vetra (eng. Wind Chill Index – WCI)

Među svim navedenim vremenskim promenljivama, ubedljivo najviše i najčešće korišćena je temperatura vazduha, merena u senci (eng. Dry Bulb Temperature). Postoje razni načini na koje je moguće uvrstiti informaciju o temperaturi vazduha u sastav ulaznih promenljivih STLF modela:

- trenutna temperatura
- temperature zabeležene u prethodnih nekoliko časova
- razlika između temperature prethodnog časa i trenutne temperature
- minimalna, maksimalna ili prosečna temperatura u proteklih nekoliko časova

Zavisnosti koje se javljaju između procesa potrošnje el. energije i između temperature vazduha su takođe modelovane i interpretirane na različite načine u okviru STLF literature. Autori su u okviru rada [7] predložili stepenovanje na eksponent trećeg reda, za prikazivanje nelinearne međuzavisnosti, dok su u okviru rada [71] ukazali na zavisnost koja se može modelirati linearnom, deo po deo, interpolacijom.

Upotreba informacija o vremenu je zavisna od nekoliko faktora, pri čemu dostupnost vremenske prognoze, kao i istorijski zabeleženih vremenskih podataka igraju bitnu ulogu. Takođe, sezona u toku godine može imati velikog uticaja na relevantnost vremenskih promenljivih. U okviru istraživanja u Južnoj Koreji, predstavljenog u radu [65], konstatovano je da su temperaturne promene tokom tri sezone u godini (proleće, jesen i zima) relativno male, te da stoga ne predstavljaju važan faktor za funkcionalnost STLF modela, jer nemaju izraženog uticaja na profil potrošnje u toku dana. Međutim, promene temperature tokom

letnje sezone su drastične, pa se u skladu sa tim menja i ponašanje potrošača, što se pre svega ogleda u mnogo većoj opterećenosti uređaja za klimatizaciju. Analogno ponašanje se može sresti u geografskim regionima gde se prilikom zimske sezone dodatno aktiviraju uređaji za klimatizaciju koji za pogon koriste el. energiju, dok tokom letnje (i ostalih) sezona uticaj temperature na profil potrošnje nije preterano izražen.

2.6 Kalendarske promenljive

U okviru STLF literature, većina predstavljenih radova koristi informaciju o tome za koji se mesec u toku godine obavlja predviđanje, prilikom čega je ta informacija na određeni način uvrštena u ulaz STLF modela. Treba naglasiti da postoje neki radovi koji takve informacije nisu razmatrali prilikom dizajniranja STLF modela ([40], [11], [85], [12], [39]).

Još jedan od načina za grupisanje ulaznih podataka može biti njihovo raspoređivanje po sezonama (proleće, leto, jesen i zima), a ovaj pristup je korišćen u velikom broju različitih STLF istraživanja ([36], [83], [67], [55], [65], [75]).

Zanimljiv pristup za grupisanje ulaznih podataka je korišćenjem 7 grupa, pri čemu se neke grupe koriste da označe prelazni period između dve sezone [7]:

- zima (1. decembar – 15. februar)
- kasna zima, rano proleće (16. februar – 30. mart)
- proleće (31. mart – 31. maj)
- kasno proleće, rano leto (1. jun – 30. jun)
- leto (1. jul – 15. septembar)
- kasno leto, rana jesen (16. septembar – 7. oktobar)
- jesen (8. oktobar – 30. novembar)

U okviru rada predstavljenog u [31], koristi se drugačiji pristup, u okviru kog se podaci grupišu u odnosu na „hladne“ i „tople“ dane, dok se informacija o mesecu u toku godine zanemaruje.

U zavisnosti od geografske lokacije teritorije na kojoj se izvršava STLF predviđanje za određenu grupu potrošača, definicija sezone u toku godine može biti formulisana na različite načine. Tako je za teritorije sa manjom geografskom širinom karakteristično dugačko leto, dok je za teritorije sa većom geografskom širinom karakteristična dugačka zima. U skladu sa navedenim razlikama, grupisanje na osnovu 12 meseci u toku godine ne mora biti optimalno za gnerički način dizajniranja STLF modela.

Karakteristike procesa potrošnje u toku dana mogu biti različite kada se radi o različitim danima u toku jedne nedelje, zbog mnogih uticaja. Na primer, zgrade u kojima se nalaze većinom poslovni prostori mogu tokom vikenda biti zatvorene, što rezultira znatno smanjenom potrošnjom u odnosu na radne dane. Takođe, ljudi ustaju kasnije tokom vikenda,

2 Pregled literature

pa je vrhunac jutarnje potrošnje pomećen za jedan do dva časa unapred u odnosu na radne dane. Postoji više načina za grupisanje različitih tipova dana u toku radne nedelje, od kojih je sedam najčešćih prikazano u **Error! Reference source not found.** Potrebno je naglasiti da su neki od referenciranih STLF modela bili razvijani za elektroenergetske kompanije iz drugih geografskih oblasti, odnosno iz drugih zemalja, te da su iz tog razloga drugačije podele na tipove dana u toku nedelje suštinski iste. Na primer, grupisanje prikazano u 5. vrsti tabele je suštinski isto sa onim prikazanim u 4. s obzirom na to da je u Iranu, kao i u drugim islamskim zemljama, prvi radni dan nedelja, a ne ponedjeljak. U zemljama sa istim rasporedom radnih i neradnih dana, i dalje se može naići na različita grupisanja, s obzirom na različite običaje unutar tih zemalja, koje za rezultat imaju drugačije ponašanje potrošača, a konsekvantno i na proces potrošnje el. energije. Čak i u okviru istih zemalja (npr. SAD), grupisanje dana u toku nedelje može biti učinjeno na različite načine, s obzirom na to da se predviđanja mogu izvršavati za različite tipove potrošača, kao na primer za rezidencijalne i za industrijske potrošače. Većina grupisanja iznetih u okviru **Error! Reference source not found.** je zasnovano na iskustvu inženjera, ili na upoređivanju krivih potrošnje koje nastaju različitih dana u toku nedelje, drugim rečima, nisu izvršavane posebne komparativne analize koje bi pokazale kvantitativnu prednost jednog načina grupisanja dana u toku nedelje u odnosu na drugi. S obzirom na to da je proces potrošnje takođe zavisen i od vremenskih promenljivih, zasnivanje grupisanja dana u toku nedelje isključivo na iskustvu, ili na upoređivanju uprosječenih krivih potrošnje, ponekad nije dovoljno.

Tabela 2.1 Kodiranje tipa dana u okviru STLF literature

	Tip dana	Reference
1	2 tipa: Pon-Pet; Sub, Ned (radni i neradni)	[34], [36], [55], [75]
2	3 tipa: Pon-Pet; Sub; Ned	[30]
3	4 tipa: Pon; Uto-Čet; Pet; Sub, Ned	[15]
4	4 tipa: Pon; Uto-Pet; Sub; Ned	[47], [64]
5	4 tipa: Sub; Ned-Sre; Čet; Pet	[31]
6	5 tipova: Pon; Uto-Čet; Pet; Sub; Ned	[7], [83], [51]
7	7 tipova: Pon; Uto; Sre; Čet; Pet; Sub; Ned	[85], [12], [67], [9], [69]

Kada se posmatra časovna potrošnja u toku jednog dana, podaci se mogu grupisati na različite načine u zavisnosti od toga za koji se čas u toku dana generiše predviđanje. U okviru rada prezentovanog u [23], autori su grupisali potrošnju na šest intervala u toku jednog dana. U toku leta, intervali su formulisani kao:

- 12 PM-4 AM

- 5-9 AM
- 10 AM-1 PM
- 2-5 PM
- 6-8 PM
- 9-11 PM

dok su u toku zime intervali formulisani kao:

- 12-4 AM
- 5-8 AM
- 9-12 AM
- 1-4 PM
- 5-7 PM
- 8-11 PM

U okviru rada [85], [12] sačinjeno je četiri dnevna intervala koji su definisani kao:

- rano jutro (1 AM-9 AM)
- jutro, rano popodne, rano veče (10 AM-2 PM, 7-10 PM)
- popodnevni vrhunac (3-6 PM)
- noć (11-12 PM).

U okviru rada prezentovanog u [27], korišćeno je 24 tipa časa, za svaki čas u toku dana po jedan.

Predviđanje potrošnje za specijalne tipove dana, kao na primer za praznike, predstavlja posebnu problematiku u okviru STLF oblasti. Posebne izazove prilikom ovakvog tipa predviđanja predstavlja varijabilnost i nestacionarnost vremenskih serija potrošnje u toku takvih dana. Još jedan otežavajući faktor prilikom konfiguracije STLF modela za predviđanje u toku specijalnih dana predstavlja smanjena količina dostupnih podataka, tj. zabeleženih merenja, zato što su takvi dani retki u toku godine. U nekim radovima u okviru STLF literature se predlažu modeli namenjeni za isključivu upotrebu u svrhu predviđanja potrošnje za specijalne dane [64]. Praznici su u okviru određenih istraživačkih radova predstavljeni kao posebni tipovi dana, pored uobičajenih tipova radnih i neradnih dana, pri čemu je ovakav pristup analiziran u radovima [40], [69]. Takođe postoje radovi u okviru kojih se specijalni dani tretiraju na isti način kao i vikend (npr. Subota [55], Nedelja [47], [30], ili Petak [31] u islamskim zemljama). Takođe se u STLF literaturi može naići na pristup da se dani koji nastupaju pre ili posle praznika tretiraju kao posebni tipovi dana, nezavisno od toga na koji dan nedelje padaju, pa se tako u radu predstavljenom u [47] dan koji nastupa posle praznika tretira kao ponedeljak.

2.7 Bibliografija

2 Pregled literature

U okviru STLF oblasti je veoma teško uporediti dve nezavisno razvijene metode u okviru iste komparativne analize. Za ovo postoje mnogi razlozi, ali su sledeća dva najznačajnija:

- Podaci koji se koriste za dizajniranje STLF modela uglavnom potiču iz elektroenergetskih preduzeća, te vrlo često nije moguće doći do tih podataka za potrebe istraživanja
- STLF algoritmi su najčešće razvijani za određene namene, tačnije za poseban tip potrošača (ili grupu potrošača), pa je za njihovu implementaciju, kao i za ostvarivanje performansi navedenih u okviru istraživačkog rada često potrebno mnogo truda i finog podešavanja parametara.

U veoma retkim situacijama, kao što je slučaj sa javnim takmičenjima, organizatori omoguće javni pristup podacima, pri čemu se ostvareni rezultati (od strane raznih učesnika) testiraju na istim skupovima podataka, te je na taj način automatski moguće učiniti komparativnu analizu različitih STLF metodologija [10]. U praksi, elektroenergetsko preduzeće može objaviti poziv za dizajniranje nove STLF metode, pomoću javno dostupnih podataka, pri čemu se ostvareni rezultati porede sa već implementiranim algoritmima u okviru tog preduzeća. Ipak, rezultati ovakvih internih provera su veoma retko objavljivani u literaturi. Iako u STLF literaturi postoje primeri poređenja novorazvijenih modela sa već postojećim modelima, akcenat takvih istraživačkih radova je uglavnom na predstavljanju prednosti novih modela. S toga je jedan način za analiziranje performansi različitih STLF modela praćenje razvoja unutar određenih istraživačkih grupa, pogotovo ukoliko su u okviru razvoja učinjene komparacije između novih modela i prethodno razvijanih. Sa druge strane, praćenje rada velikih istraživačkih grupa može pružiti određeni uvid u tendencije razvoja STLF metodologija unutar tih grupa. U ovoj sekciji je prikazan pregled rada dve istraživačke grupe, uz konstatovanje korišćenih metodologija, njihovih prednosti i mana.

U okviru rada jedne istraživačke grupe (Rahman, Dash, Liew et al.), autori su razvili nekoliko različitih STLF metodologija, koje su bile zasnovane na četiri različite tehnike:

- ekspertske sistemi ([55], [56], [57])
- fuzzy neuronske mreže ([68])
- funkcionalno povezane mreže ([72])
- ANN ([49], [50])

Početak razvoja je bio 1988. godine, pri čemu je predložena metodologija zasnovana na ekspertskom sistemu, koja je razvijana i testirana pomoću podataka dobijenih iz elektroenergetske kompanije „Virginia Power Company“, a odgovarajuće istraživanje je predstavljeno u [55]. Zatim je usledio rad 1989. godine [23], u kome je predstavljena detaljna komparativna analiza između prethodno razvijene metodologije i četiri različite statističke

2 Pregled literature

tehnike za STLF. 1990. godine je predstavljen STLF algoritam zasnovan na pravilima odlučivanja [56], od strane iste istraživačke grupe. U 1993. godini, razvijen je generalizovani model za STLF, zasnovan na inkorporiranom ljudskom znanju (iskustvu) pri čemu je razvoj i testiranje obavljeno korišćenjem zabeleženih merenja iz četiri različite elektroenergetske kompanije, dok je odgovarajući razvoj predstavljen u [57]. STLF model zasnovan na ANN, sa tehnikom obučavanja korišćenjem adaptivnih Kalmanovih filtera je predstavljen 1995. godine u [48]. Hibridna metoda koja koristi FNN u kombinaciji sa fuzzy ekspertskim sistemom je predstavljena 1996. godine u [68]. Mreža funkcionalne povezanosti je predložena kao rešenje za STLF u okviru [72], 1997. godine. Metod za odabiranje ulaznih parametara STLF modela zasnovanog na ANN je predstavljen 1998. godine u [49]. Selekcija obučavajućih podataka, kao način za poboljšavanje performansi STLF modela je predložena 1999. godine, u okviru rada [50], pri čemu je za razvoj i testiranje bio korišćen skup merenja iz dva elektroenergetska preduzeća. U prethodno pobrajanim radovima nije bilo predstavljano poređenje sa prethodno razvijenim tehnikama razvijanim od strane iste istraživačke grupe. Ipak, posmatranjem rada pomenute grupe, mogu se konstatovati sledeći pravci razvoja u okviru STLF istraživanja:

- prvobitni fokus je bio na samostalnim tehnikama ([55], [56], [57])
- usledio je razvoj hibridnih algoritama ([68], [48], [72])
- finalni fokus je bio na specifičnim aspektima primene tehnika zasnovanih na ANN ([49], [50])

Slično kao i u prethodnom slučaju, druga istraživačka grupa (Hsu et al.) je započela svoje istraživanje u oblasti ekspertskih sistema zasnovanih na inkorporiranom ljudskom znanju, 1990. godine, a odgovarajući rad je predstavljen u [58]. Dve godine kasnije, ista grupa je predložila STLF model zasnovan na fuzzy ekspertskom sistemu, a odgovarajuće istraživanje je prezentovano u [86]. Na žalost, poređenje između prethodno dve navedene STLF metode nije učinjeno ni u jednom od prezentovanih radova. Drugi pravac razvoja ove istraživačke grupe je bio u oblasti primene ANN na STLF problematiku. U okviru rada prezentovanog u [46], 1991. godine, predložena je višeslojna neuronska mreža, sa propagacijom signala unapred (eng. Feed Forward), dok je u okviru rada prezentovanog u [45] predstavljena samo-organizujuća mapa, za potrebe identifikacije tipa dana. Metod za ubrzavanje procedure obučavanja ANN, zasnovan na adaptivnom doobučavanju je predložen 1992. godine, u radu predstavljenom u [45]. U okviru ove istraživačke grupe, poređenja sa njihovim prethodnim dostignućima na žalost nisu bila predstavljana prilikom objavljivanja novog STLF razvoja.

2.8 Pregled

Tokom proteklih nekoliko decenija, veliki broj različitih STLF tehnika je predstavljen u literaturi, dok su mnoge od njih primenjene u praksi. Pregled literature predstavljen u ovom

2 Pregled literature

poglavlju pokriva veliki broj radova koji zastupaju upotrebu različitih tehnika za potrebe rešavanja STLF problematike, kao što su: regresivna analiza, analiza vremenskih serija, ANN, FL, itd. U skladu sa narastajućom popularnošću tehnika veštačke inteligencije u protekle dve decenije, istraživački resursi su u velikoj meri bili posvećeni upravo razvoju i testiranju ovakvih tehnika, u kontekstu primene u okviru STLF oblasti. Sa druge strane, napredni razvoj statističkih tehnika, kao i odgovarajućih softverskih paketa nije podjednako zastupljen u okviru razvoja unutar STLF oblasti. U praksi, elektroenergetske kompanije mogu paralelno razvijati STLF modele zasnovane na nekoliko različitih tehnika, pri čemu se svaki put kada je potrebno generisati predviđanje odabira rezultat sa najviše izgleda da da kvalitetan rezultat, a statistički STLF modeli se veoma često nalaze u paralelnoj operaciji sa drugim STLF tehnikama.

Zadatak na koji je potrebno odgovoriti u okviru dizajniranja STLF modela, nezavisno od određene tehnike na kojoj se taj model zasniva, svakako predstavlja tretiranje, odnosno odabir odgovarajućih ulaznih promenljivih. Na primer, temperatura vazduha se koristi kao ulazni parametar u većini STLF tehnika (regresivna analiza, ANN, itd.). U okviru modela zasnovanih na regresivnoj analizi, merenja temperature, zajedno sa svojim transformisanim vrednostima, koriste se kao regresori, dok se u okviru ANN tehnika pomenute vrednosti koriste kao neki od ulaza ANN. Slična analogija se može primeniti i na kalendarske promenljive. U okviru regresivne analize, kao i u okviru tehnika zasnovanih na ANN, kalendarske promenljive se mogu koristiti za podelu obučavajućeg skupa podataka, što može rezultirati korišćenjem različitih (nezavisnih) modela za predviđanje potrošnje različitih tipova dana, ili različitih sezona u toku godine. Upotreba vremenskih, kao i kalendarskih promenljivih, u okviru STLF literature, predstavljena je u ovom pregledu literature.

Uprkos napretku STLF tehnologija, i dalje postoji određeni skepticizam kada je u pitanju komparativna analiza, tačnije dizajniranje referentnih testirajućih modela, koji bi poslužili za objektivno rangiranje i evaluaciju različitih STLF modela. Treba naglasiti da prilikom predlaganja novog STLF modela, komparacija sa već postojećim modelom razvijenim od strane iste grupe autora, ili sa modelom koji se već nalazi u upotrebi unutar nekog elektroenergetskog preduzeća, nije uvek učinjena. Sa druge strane, u okviru STLF oblasti ne postoji široko prihvaćeni model za referentnu analizu, kao ni odgovarajući javno dostupni skup podataka. U skladu sa pomenutim, istraživači iz različitih regiona, ili iz različitih delova sveta, nemaju zajednički referentni model, na osnovu kojeg bi mogli da izvrše komparaciju sa tehnikama koje su oni razvijali. Na kraju, bitno je pomenuti da u STLF oblasti ne postoji zvanično prihvaćena metrika za testiranje performansi, kao ni za validaciju modela. Većina radova u oblasti koristi srednju apsolutnu procentualnu grešku (eng. Mean Absolute

2 Pregled literature

Percentage Error – MAPE), međutim, njeno izračunavanje se u okviru različitih istraživačkih radova zasniva na različitim vremenskim periodima, različitoj rezoluciji, različitim horizontima predviđanja, itd. Takođe, u okviru drugih radova, koriste se različite statističke metode za predstavljanje kvaliteta predviđanja predložene STLF metodologije, što dodatno otežava međusobno upoređivanje različitih tehnika, kao i njihovu realnu evaluaciju.

3 Teorijske osnove

U okviru drugog poglavlja, pomenuto je mnoštvo tehnika za ostvarivanje STLF funkcionalnosti, tačnije za formiranje STLF modela. U ovoj disertaciji, tri tehnike će biti detaljno predstavljene, za potrebe daljeg razvoja i komparativne analize:

- Višestruka linearna regresija (eng. Multiple Linear Regression – MLR), koja ujedno predstavlja jednu od najstarijih, kao i najviše primenjivanih STLF tehnika.
- Veštačke neuronske mreže (eng. Artificial Neural Network – ANN), koja ujedno predstavlja jednu od najpopularnijih STLF tehnika, počevši od godina.
- Metoda vektora podrške (eng. Support Vector Machine – SVM), tehnika veštačke inteligencije koja pruža obećavajuće rezultate u okviru STLF oblasti.

U ovom poglavlju će biti predstavljene teorijske osnove tri pomenute tehnike, prilikom čega će naglasak biti na njihovoj prmenji u STLF oblasti. Statističke metode analiziranja performansi STLF modela će takođe biti predstavljene u okviru ovog poglavlja, nakon predstavljanja konkretnih STLF tehnika.

3.1 Višestruka linearna regresija (MLR)

3.1.1 Generalni modeli linearne regresije

U statistici, linearna regresija se odnosi na svaki pristup modeliranju relacija između jedne ili više promenljivih označenih sa Y , te jedne ili više promenljivih označene sa X , na način da takav model linearno zavisi od nepoznatih parametara, koji se estimiraju iz podataka. Najčešće se linearna regresija odnosi na model u kojem je uslovna srednja vrijednost promenljive Y , uz datu vrednost nezavisno promenljive X , afina funkcija od X [87].

Linerana regresija je bila prvi tip regresivne analize koja je detaljno proučavana i koja se ekstenzivno koristila u praktičnim primenama. Razlog za ovo je taj što se modeli koji linerano zavise od svojih nepoznatih parametara lakše modeliraju nego modeli sa nelinearnom zavisnošću od parametara. Takođe, statistička svojstva rezultirajućih estimatora se lakše određuju.

Uz zadati skup podataka $\{y_i, x_{i1}, \dots, x_{ip}\}_{i=1}^n$ od n statističkih jedinica, model linearne regresije pretpostavlja da se relacija između zavisne varijable y_i i p -vektora regresora x_i može aproksimativno uzeti kao linearna. „Aproksimativno“ se u ovom slučaju odnosi na element greške ε_i – nepromatranu slučajnu promenljivu koja dodaje šum u linearnu relaciju između zavisne promenljive i regresora. Stoga, model ima oblik:

$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \varepsilon_i = x_i' \beta + \varepsilon_i, \quad i = 1, \dots, n \quad 3.1$$

gde je $x_i' \beta$ unutrašnji proizvod između vektora $\mathbf{x}_i$ i $\boldsymbol{\beta}$. Ovaj sistem od n jednačina se često prikazuje u matričnom obliku kao:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad 3.2$$

gde je:

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} x'_1 \\ x'_2 \\ \vdots \\ x'_n \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1p} \\ x_{21} & \cdots & x_{2p} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{np} \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}, \quad \boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} \quad 3.3$$

regresivna funkcija dobijena ovakvim modelom je zadata na sledeći način:

$$E[Y] = \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_p X_p \quad 3.4$$

pri čemu $X_1 \dots X_p$ predstavljaju p prediktorskih promenljivih.

Pretpostavka prilikom modeliranja pomoću linearne regresije je da je sistem koji se modelira dobro definisan, te je njegov izlaz jasno definisan linearnom funkcijom, dok je svako odstupanje izazvano „greškom posmatranja“ u zabeleženim ulaznim podacima.

3.1.2 Kvantitativne i kvalitativne prediktorske promenljive

U mnogim slučajevima primene analize pomoću linearne regresije, promenljive predviđanja su kvantitativne. Na primer, broj potrošača određenog regiona, u okviru neke elektroenergetske kompanije se tokom vremena može povećavati, što će dovesti do promene u vidu porasta potrošnje el. energije, na posmatranoj teritoriji. Ukoliko imamo za cilj da linearno modelujemo ovakvo ponašanje, tačnije da predstavimo potrošnju kao linearnu funkciju broja potrošača na određenoj teritoriji, tada se promenljiva koja predstavlja broj potrošača može smatrati kvantitativnom promenljivom predviđanja.

Međutim, definicija 3.1 ne ograničava korišćenje promenljivih predviđanja na isključivo kvantitativne. Kvalitativne promenljive predviđanja, koje se ponekad nazivaju i klasnim promenljivama, poput podataka o tome da li se radi o vikendu ili o random danu, takođe mogu biti uključene u model. Indikatorske promenljive sa vrednostima 0 i 1 mogu biti iskorišćene za identifikaciju klasa kvalitativnih promenljivih. Na primer, ako predviđamo električno opterećenje (Y) u zavisnosti od toga da li se radi o vikendu ili o radnom danu u toku nedelje, kvalitativna promenljiva predviđanja X_1 se može definisati na sledeći način:

$$X_1 = \begin{cases} 1, & \text{za radni dan} \\ 0, & \text{za neradni dan} \end{cases} \quad 3.5$$

Tada se regresivni model može definisati na sledeći način:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \varepsilon_i \quad 3.6$$

gde je:

$$\begin{cases} X_{i1} = 1, & \text{za radni dan predviđanja} \\ X_{i1} = 0, & \text{za neradni dan predviđanja} \end{cases} \quad 3.7$$

Funkcija odziva se tada može napisati kao:

$$E(Y) = \beta_0 + \beta_1 X_{i1} \quad 3.8$$

3 Teorijske osnove

Za predviđanje potrošnje el. energije za radni dan, formula 3.8 postaje:

$$E(Y) = \beta_0 + \beta_1 \quad 3.9$$

dok za predviđanje potrošnje el. energije u toku vikenda, formula 3.8 postaje:

$$E(Y) = \beta_0 \quad 3.10$$

Generalno posmatrano, kvalitativna promenljiva koja modeluje c različitih klasa, može se predstaviti sa $c-1$ indikatorskih promenljivih, pri čemu svaka od njih može imati vrednosti 0 ili 1, u zavisnosti od toga da li je ispunjen uslov da trenutno izračunavanje pripada određenoj klasi. Na primer, kvalitativna promenljiva koja predstavlja određeni tip dana u toku nedelje može modelovati 7 različitih klasa (ponedeljak, utorak, ..., nedelja), može se u okviru regresivnog modela predstaviti pomoću 6 različitih indikatorskih promenljivih, na sledeći način:

$$\begin{cases} X_1 = 1, & \text{ukoliko je dan predviđanja nedelja} \\ X_1 = 0, & \text{ukoliko dan predviđanja nije nedelja} \\ X_2 = 1, & \text{ukoliko je dan predviđanja ponedeljak} \\ X_2 = 0, & \text{ukoliko dan predviđanja nije ponedeljak} \\ & \vdots \\ X_6 = 1, & \text{ukoliko je dan predviđanja petak} \\ X_6 = 0, & \text{ukoliko dan predviđanja nije petak} \end{cases} \quad 3.11$$

Tada se regresivni model koji sadrži informaciju o danu u nedelji za koji se izvršava predviđanje, u vidu kvalitativne promenljive predviđanja, može napisati kao:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_6 X_{i6} + e_i \quad 3.12$$

gde je:

$$\begin{cases} X_{i1} = 1, & \text{ukoliko je dan predviđanja nedelja} \\ X_{i1} = 0, & \text{ukoliko dan predviđanja nije nedelja} \\ X_{i2} = 1, & \text{ukoliko je dan predviđanja ponedeljak} \\ X_{i2} = 0, & \text{ukoliko dan predviđanja nije ponedeljak} \\ & \vdots \\ X_{i6} = 1, & \text{ukoliko je dan predviđanja petak} \\ X_{i6} = 0, & \text{ukoliko dan predviđanja nije petak} \end{cases} \quad 3.13$$

3.1.3 Polinomijalna regresija

Modeli polinomijalne regresije sadrže polinome promenljive predviđanja, čineći na taj način funkciju odziva krivolinijskom (eng. Curvilinear). Ukoliko se na primer opterećenje el. energije (Y) predviđa u zavisnosti od promenljive koja predstavlja temperaturu (T_i), pomoću modela polinomijalne regresije trećeg stepena, tada se može konstruisati predikcioni model sledećeg oblika:

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_1^2 + \beta_3 X_1^3 + e_i \quad 3.14$$

pri čemu se model predstavljen jednačinom 3.14 može smatrati specijalnim slučajem generalnog oblika linearno regresivnog modela predstavljenog jednačinom 3.1, jer se može zapisati u sledećem obliku:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i3} + e_i \quad 3.15$$

gde je $X_{i1} = X_i$, $X_{i2} = X_i^2$, i $X_{i3} = X_i^3$.

Ovde je potrebno primetiti da se kvantitativne promenljive predviđanja drugog, ili višeg stepena, u okviru regresivnog modela ponašaju ekvivalentno običnim promenljive predviđanja (prvog reda). Ove promenljive se mogu bez posebnog tretiranja uvrštavati u regresivne modele, iz razloga što funkcija koja predstavlja regresivni model ostaje linearna u pogledu svojih parametara, što se može videti upoređivanjem jednačina 3.14 i 3.15.

3.1.4 Transformisane promenljive

U modelima polinomijalne regresije, funkcija odziva, tj. oblik prediktorskih promenljivih, može se transformisati na takav način da uvek ima formu standardne linearne regresije, opisane jednačinom 3.1. Zavisno promenljiva se takođe može transformisati, pomoću složenijih, kao i nelinearnih transformacija, sa ciljem da se modeluju kompleksne međuzavisnosti, tj. krive odziva. Ukoliko razmatramo regresivni model koji prikazuje zavisnost opterećenja el. energije od temperature, tada se model sa transformisanom promenljivom Y može zapisati kao:

$$\ln(Y_i) = \beta_0 + \beta_1 X_{i1} + \beta_3 X_{i3} + e_i \quad 3.16$$

pri čemu možemo konstatovati da je jednačina 3.16 samo specijalni oblik generalnog oblika modela linearne regresije, predstavljenog jednačinom 3.1. Ukoliko nelinearnu transformaciju predviđanog opterećenja Y predstavimo kao transforisanu promenljivu:

$$Y'_i = \ln(Y_i) \quad 3.17$$

tada model opisan jednačinom 3.16 možemo predstaviti kao:

$$Y'_i = \beta_0 + \beta_1 X_{i1} + \beta_3 X_{i3} + e_i \quad 3.18$$

3.1.5 Efekti interakcije među promenljivama

Postoje slučajevi u okviru STLF problematike kada uticaj jedne prediktorske promenljive na posmatranu veličinu može biti izmenjen u zavisnosti od veličine neke druge prediktorske promenljive. Na primer, temperatura okoline će imati različit subjektivni uticaj na ljude (a time i na rezidencijalne potrošače) u zavisnosti od toga da li se radi o predviđanju za letnju ili za zimsku sezonu. Ovi različiti subjektivni doživljaji će uticati na specifično (različito) korišćenje uređaja za klimatizaciju u različitim sezonama u toku godine, pri čemu temperatura može imati istu vrednost (ista temperatura u letnjoj sezoni može biti konstatovana kao zahlađenje, dok u zimskoj može biti konstatovana kao otopljenje). Ovakvo ponašanje

prediktorskih promenljivih se naziva efektom interakcije, a takođe se može predstaviti pomoću linearnog regresivnog modela. Ovakvi modeli se još nazivaju i neaditivnim modelima, prilikom čega se efekti interakcije mogu modelirati međusobnim množenjem dve ili više prediktorskih promenljivih (u okviru jednog člana funkcije odziva). Primer jednog neaditivnog modela sa dve prediktorske promenljive X_1 i X_2 , dat je sledećom jednačinom:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i1} X_{i2} + e_i \quad 3.19$$

pri čemu se ovaj oblik i dalje može podvesti pod specijalan slučaj opšteg oblika funkcije linearne regresije, prikazane jednačinom 3.1. Ukoliko uvrstimo transformaciju za prikazivanje efekta interakcije:

$$X_{i3} = X_{i1} X_{i2} \quad 3.20$$

tada model predstavljen jednačinom 3.19 možemo predstaviti kao:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i3} + e_i \quad 3.21$$

3.1.6 Linearni modeli naspram linearnih funkcija odziva

Prilikom korišćenja metodologije linearne regresije treba biti svestan da se pomoću nje može modelovati veliki broj nelinearnih funkcija odziva. Drugim rečima, linearni modeli nisu ograničeni na isključivo linearne funkcije odziva, iako njihov naziv možda to može sugerisati. Termin „linearan“ u okviru konstrukcije „linearan model“ se odnosi isključivo na parametre modela, pri čemu promenljive koje ga sačinjavaju mogu biti transformisane na razne načine, kao što je prikazano u jednačinama 3.14, 3.16, i 3.19. Regresivni model može biti smatran „linearnim“ ukoliko se može predstaviti u sledećem obliku:

$$\mathbf{Y} = \mathbf{XB} + \mathbf{E} \quad 3.22$$

pri čemu promenljive imaju sledeće značenje:

- vektor Y predstavlja odzive,
- vektor B predstavlja parametre modela,
- matrica X predstavlja konstante, dobijene selekcijom merenja nezavisnih promenljivih, ili njihovih nelinearnih transformacija,
- vektor E predstavlja normalno distribuiranu slučajnu grešku.

3.2 Veštačke neuronske mreže

Veštačke neuronske mreže (eng. Artificial Neural Networks – ANNs) su modeli inspirisani strukturom i ponašanjem bioloških neurona, iako osim strukturne i konceptualne veze nemaju mnogo toga zajedničkog sa biološkim sistemima. ANN mogu biti implementirane u vidu čisto softverskih algoritama, a takođe mogu biti implementirane i u okviru hardvera za posebne namene. Postoji oko 50 različitih vrsta ANN [88], pri čemu se u okviru STLF oblasti najčešće koriste ANN sa propagacijom signala unapred (eng. Feed Forward ANN). FF ANN se koriste

za rešavanje različitih problema, na osnovu učenja iz podataka, pri čemu se problemi mogu grupisati u dve osnovne grupe, a to su:

- problemi klasifikacije
- problemi regresije

Zbog lakšeg poimanja, ANN se često predstavljaju grafički, prilikom čega se ne dodaje nikakvo novo značenje u okviru aproksimativne teorije. Takođe, sa stanovišta paralelnog procesiranja, kao i zahtevnih računarskih operacija, mogućnost predstavljanja ANN metodologije u formi mreže je poželjna osobina.

ANN se sastoje od velikog broja procesorskih jedinica (u konceptualnom smislu) koje se popularno nazivaju neuronima. Snaga povezanosti određenih neurona, naziva se težina, pri čemu težine predstavljaju stvarne parametre ANN, čije se vrednosti u stvari podešavaju prilikom procedure obučavanja. U zavisnosti od problematike na koju se primenjuju, težine ANN mogu imati različita fizička značenja, dok je u nekim slučajevima teško povezati vrednosti težina sa bilo kakvim fizičkim značenjem, dok je njihovo grafičko značenje mnogo razumljivije. Težine definišu pozicije i oblik baznih funkcija u okviru ANN modela [88].

Neuroni su obično raspoređeni u slojeve u okviru ANN, pri čemu svi neuroni istog sloja obično poseduju istu aktivacionu funkciju (AF). Najčešće korišćene konfiguracije ANN poseduju ulazni sloj, izlazni sloj i barem jedan skriveni sloj neurona, pri čemu svi neuroni skrivenog sloja poseduju nelinearne i diferencijabilne aktivacione funkcije. ANN konstruisana na ovaj način poseduje dva sloja težina, koje su tipično organizovane u matrice težina.

Nelinearne aktivacione funkcije u neuronima skrivenog sloja omogućavaju ANN svojstvo univerzalnog aproksimatora, te iz tog razloga nelinearnost AF rešava problem reprezentacije. Diferencijabilnost AF neurona skrivenog sloja omogućava rešavanje problema nelinearnog obučavanja (iako u skorije vreme primene slučajnih optimizacionih tehnika, poput genetskih algoritama, omogućuju korišćenje AF koje nisu diferencijabilne).

U ovakvoj strukturi ANN, ulazni sloj ne predstavlja skup procesnih jedinica, već samo ulazne čvorove. Generalno se u okviru ulaznog sloja ANN neće vršiti nikakvo procesiranje, te stoga on ne predstavlja zaista sloj neurona, iako grafička reprezentacija ANN modela može uputiti na takav zaključak. Ulazni sloj ANN predstavlja ulazni vektor, eventualno proširiv tzv. bias elementom, čije će se komponente proslediti sledećem sloju (skrivenom ili izlaznom) neuralnih procesirajućih jedinica. Neuroni izlaznog sloja uglavnom imaju linearne AF (za potrebe rešavanja problema regresije), ili sigmoidne AF (za potrebe rešavanja problema klasifikacije ili prepoznavanja oblika). Za potrebe adaptivnih upravljačkih algoritama, kao i za potrebe analize vremenskih serija, što podrazumeva i primenu u okviru STLF oblasti, neuroni ANN u okviru izlaznog sloja imaju tipično linearnu AF. Grafička reprezentacija elementarne

3 Teorijske osnove

ANN je prikazana na Ilustracija 3.1. Ova ilustracija predstavlja grafički prikaz aproksimativne šeme, izražene sledećom jednačinom:

$$o(\mathbf{x}, \mathbf{V}, \mathbf{w}, \mathbf{b}) = F(\mathbf{x}, \mathbf{V}, \mathbf{w}, \mathbf{b}) = \sum_{j=1}^J w_j \sigma_j(\mathbf{v}_j^T \mathbf{x} + b_j) \quad 3.23$$

gde σ_j predstavlja sigmoidne aktivacione funkcije. Ova mreža se takođe može označavati nazivom „višeslojni perceptron“ (eng. Multilayer Perceptron – MLP). J predstavlja broj neurona u skrivenom sloju. Pišući $o = o(x, V, w, b)$, naglašavamo da izlaz iz ANN zavisi od težina koje nisu poznate pre obučavanja, a koje se sadrže u vektorima V , w i b . Ulazni vektor x , bias vektor b , matrica težina skrivenog sloja V i vektor težina izlaznog sloja w se definišu na sledeći način:

$$\mathbf{x} = [x_1 \quad x_2 \quad \cdots \quad x_n]^T \quad 3.24$$

$$\mathbf{V} = \begin{bmatrix} v_{11} & \cdots & v_{1i} & \cdots & v_{1n} \\ \vdots & & \vdots & & \vdots \\ v_{j1} & \cdots & v_{ji} & \cdots & v_{jn} \\ \vdots & & \vdots & & \vdots \\ v_{J1} & \cdots & v_{Ji} & \cdots & v_{Jn} \end{bmatrix} \quad 3.25$$

$$\mathbf{b} = [b_1 \quad b_2 \quad \cdots \quad b_J]^T \quad 3.26$$

$$\mathbf{w} = [w_1 \quad w_2 \quad \cdots \quad w_J \quad w_{J+1}]^T \quad 3.27$$

Ilustracija 3.1 Neuronska mreža sa propagacijom signala unapred

Ilustracija 3.1 predstavlja generalnu strukturu sledećih tipova mreža:

- višeslojni perceptron (MLP)
- mreže sa radialnim funkcijama (eng. Radial Basis Function Networks – RBF)
- SVM

U slučaju MLP, ulazni član mreže, označen sa x_{n+1} , biće konstanta jednaka 1, pri čemu će on predstavljati tzv. „bias“. Vektor težina bias-a, predstavljen pomoću $\mathbf{b}$ se može integrisati u matricu težina skrivenog sloja $\mathbf{V}$, pri čemu će on predstavljati njenu poslednju kolonu. Posle ovakve konkatencije, formula prikazana jednačinom 3.23 može biti pojednostavljena na sledeći način:

$$o = \mathbf{w}^T \sigma(\mathbf{V}\mathbf{x}) \quad 3.28$$

U slučaju RBF mreža, ulazni član predstavljen sa x_{n+1} će biti jednak 0, što znači da u takvim mrežama ne postoji bias ulaz, iako se može koristiti u okviru izlaznog sloja.

U mrežama tipa MLP, kao i u mrežama tipa RBF, ulazni element bias je moguće koristiti, iako njegova upotreba generalno nije neophodna. Aktivacione funkcije neurona u skrivenom sloju ANN, prikazane na Ilustracija 3.1, sigmoidalnog su tipa, što ukazuje na to da je ova konkretna ANN u stvari MLP, iako su strukture različitih tipova mreža (MLP, RBF) u stvari veoma slične, ponekad i identične. Osnovna razlika između ANN različitih tipova (MLP i RBF) je u načinu na koji se izračunavaju ulazne vrednosti u svaki pojedinačni neuron.

3 Teorijske osnove

Osnovni skup računskih operacija, koje se izvršavaju kao deo funkcionalnosti ANN, je u suštini jednostavan. Nakon što se određeni vektor vrednosti dovede na ulaz ANN, signali na ulazu u sloj skrivenih neurona se izračunavaju ili kao skalarni proizvod između vektora $\mathbf{v}_j$ i $\mathbf{x}$ (za linearne i za sigmoidalne AF), ili kao euklidsko rastojanje između RBFcentara $\mathbf{c}_j$ i $\mathbf{x}$ (za RBF aktivacione funkcije). RBF AF se obično definiše pomoću dva parametra, od kojih jedan predstavlja centar RBF - c_j , dok drugi predstavlja oblik RBF (širinu, tj. formu). U slučaju jednodimenzionalne, Gausove funkcije, drugi parametar predstavlja standardnu devijaciju σ (treba obratiti pažnju da se simbol σ u ovom slučaju odnosi na standardnu devijaciju, dok se u jednačini 3.23 odnosi na aktivacionu funkciju neurona u skrivenom sloju ANN, te ove dve upotrebe simbola ne treba mešati). U slučaju multivarijabilnog ulaznog vektora $\mathbf{x}$, parametri koji definišu oblik hiper-Gausovske funkcije su elementi matrice kovarijanse Σ . Drugim rečima, odnosi težina bias-a i drugih težina unutar matrice skrivenog sloja za sigmoidalne AF su analogni sa centrima RBF funkcija, dok težine predstavljene sa v_{ij} , koje definišu nagib sigmoidalnih funkcija u odnosu na svaku ulaznu promenljivu, odgovaraju parametrima koji predstavljaju širinu RBF. Stoga se ulazi u skrivene neurone sa sigmoidalnim AF mogu predstaviti kao:

$$u_j = \mathbf{v}_j^T \mathbf{x}, \quad j = 1, \dots, J \quad 3.29$$

dok se za skrivene neurone sa RBF AF euklidska rastojanja računaju kao:

$$r_j = \sqrt{(\mathbf{x} - \mathbf{c}_j)^T (\mathbf{x} - \mathbf{c}_j)}, \quad u = f(r, \sigma) \quad 3.30$$

U slučaju trodimenzionalnog vektora ulaza, kada je $\mathbf{x} = [x_1, x_2, x_3]^T$, a $\mathbf{c} = [c_1, c_2, c_3]^T$, euklidsko rastojanje r_j se može izračunati kao:

$$r_j = \sqrt{(\mathbf{x} - \mathbf{c}_j)^T (\mathbf{x} - \mathbf{c}_j)} = \sqrt{(x_1 - c_1)^2 + (x_2 - c_2)^2 + (x_3 - c_3)^2} \quad 3.31$$

Ilustracija 3.2 Formiranje ulaznog signala za neurone skrivenog sloja

Izlaz iz svakog skrivenog neurona zavisi od tipa AF koja se koristi. Najuočajaniji tip AF u okviru ANN tipa MLP su sigmoidalne funkcije:

- unipolarna logistička funkcija (jednačina 3.32)
- bipolarna sigmoidalna funkcija (hiperbolički tangens) (jednačina 3.33)

$$o = \frac{1}{1 + e^{-u}} \quad 3.32$$

$$o = \tanh\left(\frac{u}{2}\right) = \frac{2}{1 + e^{-u}} - 1 \quad 3.33$$

Na Ilustracija 3.2 je šematski prikazana osnovna razlika između izračunavanja ulaza za neurone skrivenog sloja MLP i RBF tipa veštačkih neuronskih mreža.

Sve tri tehnike modeliranja zavisnosti između ulaznih i izlaznih podataka (MLP, RBF i SVM) predstavljaju veoma moćne alate veštačke inteligencije [88]. Ovde je bitno napomenuti da sve tri pobrojane tehnike imaju suštinski istu strukturu. Zbog toga su njihove mogućnosti reprezentacije nelinearnih modela skoro jednake (ili veoma slične) nakon uspešno izvršene procedure obučavanja. Sve tri pomenute tehnike imaju isti zadatak, koji se može formulisati kao najkvalitetnije moguće modeliranje zavisnosti [88], na osnovu skupa obučavajućih podataka, koji tipično pripadaju visoko dimenzionalnom prostoru, retki su (eng. Sparse) i poseduju šumove pri merenju (ni jedna od gorenavedenih osobina ne olakšava zadatak modeliranja na osnovu skupa podataka). Izlazi iz ovakvih modela se najbolje mogu razumeti kao hiperpovršni u prostoru $\mathbb{R}^n \times \mathbb{R}^m$, gde n predstavlja dimenziju ulaznog prostora, dok m

predstavlja dimenziju izlaznog prostora. Prilikom pronalaženja najboljeg mogućeg modela, potrebno je posedovati određeni kriterijum za procenu njegovog kvaliteta. Suštinska razlika između MLP, RBF i SVM se sastoji u formulisanju ovih kriterijuma. Svaki od ovih modela koristi drugačiju normu (funkciju greške, rizika ili troška), na osnovu koje se procenjuje kvalitet ponašanja modela, pri čemu optimizacija zasnovana na različitim normama rezultira drugačijim parametrima modelima, ukoliko težine smatramo parametrima modela. Primenjivanje različitih normi takođe vodi do drugačijih procedura obučavanja (optimizacionih procedura). U tabeli su prikazane osnovne norme (funkcije greške ili rizika), koj se primenjuju prilikom razvijanja tri različite vrste mreže (MLP, RBF, SVM).

Tabela 3.1 Različite vrste modela (mreža) i njihovih funkcija greške (rizika) MLP

ANN	RBF	SVM
$E = \sum_{i=1}^P (d_i - f(x_i, \mathbf{w}))^2$	$E = \sum_{i=1}^P (d_i - f(x_i, \mathbf{w}))^2 + \lambda \ \mathbf{P}f\ ^2$	$E = \sum_{i=1}^P (d_i - f(x_i, \mathbf{w}))^2 + \Omega(l, h, \eta)$

3.3 Statistička analiza performansi modela

U literaturi vezanoj za kratkoročno predviđanje potrošnje električne energije najčešće korišćene mere za preciznost određenog modela su srednja apsolutna greška – MAE, kao i srednja procentualna greška – MAPE. Za potrebe detaljnijeg opisivanja apsolutne greške, kao i apsolutne procentualne greške, pored njihove srednje vrednosti možemo takođe posmatrati i druge statističke mere posmatranog procesa:

- standardna devijacija
- medijana
- maksimum

Izračunavanje performansi modela se u praksi može izvršavati za različite veličine, u različitim vremenskim periodima, u zavisnosti od specifičnih potreba sistema za koji se izvršava predviđanje:

- Časovno opterećenje el. energije. U prestupnim godinama se koriste vrednosti 8784 zabeležena merenja potrošnje, dok se za obične godine koriste 8760 vrednosti.
- Časovno opterećenje za specifičan čas u toku dana, za specifičan dan u toku nedelje, ili za specifičan mesec u godini.
- Dnevna, mesečna ili godišnja energija. Na primer, ukupna dnevna energija se može izračunati integraljenjem vrednosti potrošnje el. energije za čitav dan.
- Časovni maksimumi potrošnje.

Kombinovanjem pomenutih statističkih tehnika, sa različitim fizičkim veličinama, mogu se dobiti formalne analize kvaliteta performansi određenog STLF modela.

Za potrebe ove disertacije, najviše se koristi MAPE i MAE metrika, s obzirom da su ove dve mere greške najšire prihvaćene u STL literature, a sem toga veoma su intuitivne i pružaju jasan uvid u kvalitet performansi nekog modela, pogotovo ukoliko se grafički predstave.

3.3.1 Srednja prosečna procentualna greška – MAPE

Srednja prosečna procentualna greška (eng. Mean Average Percentage Error – MAPE), takođe poznata i kao srednja procentualna devijacija (eng. Mean Average Percentage Deviation – MAPD) predstavlja meru tačnosti modela za konstruisanje fitovanih vremenskih serija u statistici, najčešće za estimaciju trendova. Obično se pomoću MAPE rezultat definiše u procentima, a izračunava se pomoću sledeće formule:

$$M = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - f_t}{y_t} \right| \times 100 \quad 3.34$$

pri čemu y_t predstavlja izmerenu (istinsku) vrednost, dok f_t predstavlja predviđenu vrednost. Iako je koncept izračunavanja MAPE veoma jednostavan, a njena primena za statističku analizu intuitivna, treba naglasiti dva bitna nedostatka, pogotovo kada se radi o praktičnim situacijama gde je potrebno analizirati statističke performanse modela:

- Ukoliko postoje vrednosti jednake 0, što se može desiti u praktičnim aplikacijama (nedostajući podatak u zabeleženim merenjima, pogrešno funkcionisanje mernog uređaja, itd.), prilikom izračunavanja MAPE će se pojaviti deljenje sa nulom (koje matematički nije definisano, te ga je neophodno tretirati kao izuzetak)
- Ukoliko se izmereni i predviđeni podaci savršeno poklapaju, vrednost MAPE je 0. Ukoliko međutim nema savršenog poklapanja, što je mnogo češći slučaj u praktičnoj primeni prediktivnih metoda, MAPE ne vrši nikakvu restrikciju u pogledu maksimalne vrednosti odstupanja između izmerene i predviđene vrednosti (koliko god da je greška velika, maksimalna moguća vrednost MAPE će u najvećem broju slučajeva biti 100, ukoliko se radi o pozitivnim vrednostima koje nisu manje od 1)

U procesu izračunavanja MAPE, kao i prilikom analiziranja performansi prediktivnog modela njenim korišćenjem, može se naići na nekoliko praktičnih problema, pogotovo ukoliko se međusobno upoređuju performanse nekoliko različitih modela za predviđanje, ili ukoliko se upoređuju performanse određenog modela na osnovu različitih vremenskih serija. Naime, ukoliko se za nekoliko elemenata vremenske serije detektuje veoma visoka MAPE, tada ona može uticati na srednju vrednost MAPE za celu posmatranu vremensku seriju, te na taj način može pružiti pogrešnu sliku prilikom poređenja dve ili više metoda, na osnovu srednjih vrednosti MAPE. Za potrebe izbegavanja ovog problema, razvijene su dodatne statističke metode, kao na primer:

3 Teorijske osnove

- simetrična srednja apsolutna procentualna greška (eng. Symmetrical Mean Absolute Percentage Error- sMAPE),
- težinska apsolutna procentualna greška (eng. Weighted Absolute Percentage Error – WAPE),
- realna procentualna greška agregacije (eng. Real Aggregated Percentage Error – RAPE),

pri čemu se u ovoj disertaciji za prikazivanje performansi modela koristim kriterijum MAPE, zbog mogućnosti upoređivanja sa većinom STL literature, dok se za određivanje parametara modela, kao sastavni deo algoritma modeliranja, koriste i kriterijumi MAE i WAPE.

3.3.2 MAPE – Alternativna definicija

Prilikom izračunavanja MAPE za neku vremensku seriju, mogu nastati određeni problemi ukoliko su izmereni izlazi sistema bliski nuli (u okviru jednačine 3.34). Može se pojaviti problem singularnosti tipa deljenja sa nulom. Takođe, mogu se pojaviti veoma velike promene MAPE, koje su izazvane veoma malim devijacijama greške (između predviđanja i merenih vrednosti).

Zbog ovoga se uvodi dodatna definicija MAPE, u vidu sledeće jednačine:

$$M = \frac{1}{n} \sum_{t=1}^n \left| \frac{\bar{y}_t - f_t}{\bar{y}_t} \right| \times 100 \quad 3.35$$

Razlika u odnosu na prvobitnu jednačinu (3.34) se sastoji u tome da se svaka izmerena vrednost y_t zameni sa izračunatom srednjom vrednošću za celokupnu vremensku seriju - $\bar{y}_t$. Na taj način se ublažavaju eventualne distorzije. Ova alternativa se takođe koristi u STL oblasti, a takođe i u oblasti predviđanja cene električne energije.

4 Dizajn STLF modela korišćenjem višestruke linearne regresije

Analiza korišćenjem višestruke linearne regresije je jedna najčešće i najduže upotrebljivanih tehnika u okviru STLF oblasti. Ipak MLR modeli koji su predstavljeni u prošlosti za STLF namenu, nisu u potpunosti koristili prednosti ove tehnike, što je delimično uzrokovano nedostatkom računarskih resursa u periodu njihovog razvoja i primene. U okviru ovog poglavlja se predstavlja moderan pristup dizajniranju STLF modela upotrebom MLR.

4.1 Upotreba jednostavnog modela za uporedno testiranje

4.1.1 Opis modela

STLF oblast se izučava već veoma dugo vremena, što je rezultiralo brojnim radovima prezentovanim u literaturi, kao i praktičnim aplikacijama STLF metodologija, u okviru elektroenergetskih preduzeća. U okviru STLF literature se često može zaključiti kako je cilj svakog konkretnog rada upravo promovisanje novo-razvijene metode koju su kreirali autori [89], pa se u skladu sa time retko može naići na komparativne analize, a još ređe se ti modeli mogu reprodukovati (kao što je objašnjeno u poglavlju 2). S obzirom na takvo generalno stanje u oblasti, ne postoji dobro definisan formalistički pristup analiziranju STLF metodologija, osim u smislu opštih smernica, kao što su:

- prihvatljiva vrednost MAPE
- dobar trend praćenja originalnih vrednosti krive potrošnje
- robustna predviđanja
- dobra generalizacija STLF modela

Kao pokušaj da odgovore na potrebe postojanja takvog modela, autori su u okviru rada prezentovanog u [89] dizajnirali jednostavan STLF model zasnovan na MLR, sa ciljem da on posluži kao polazna osnova istraživačima za uporedno testiranje drugih STLF modela.

Pomenuti model se može predstaviti sledećom jednačinom:

$$L_d(h) = \alpha_0 + \alpha_1 * Trend + \alpha_2 * d * h + \alpha_3 * m + \alpha_4 * m * T_d(h) + \alpha_5 * m * T_d^2(h) + \alpha_6 * m * T_d^3(h) + \alpha_7 * h * T_d(h) + \alpha_8 * h * T_d^2(h) + \alpha_9 * h * T_d^3(h) \quad 4.1$$

Predstavljeni model se sastoji od nekoliko promenljivih koje predstavljaju: konstantnu vrednost, linearni trend, kombinovani uticaj trenutne temperature i tipa dana predviđanja, različite efekte interakcije između eksponenta temperature i trenutnog sata (meseca). Detaljan prikaz promenljivih korišćenih u pomenutom modelu je prikazan u Tabela 4.1

Tabela 4.1 Detaljan opis promenljivih STLF modela prikazanog jednačinom 4.1

Promenljiva modela	Opis
α_0	Konstantna vrednost

<i>Trend</i>	Linearni trend
$d * h$	Efekat interakcije između trenutnog časa i tipa dana u nedelji
m	Mesec u godini
$m * T_d(h)$	Efekat interakcije između trenutne temperature i meseca u godini
$m * T_d^2(h)$	Efekat interakcije između drugog eksponenta trenutne temperature i meseca u godini
$m * T_d^3(h)$	Efekat interakcije između trećeg eksponenta trenutne temperature i meseca u godini
$h * T_d(h)$	Efekat interakcije između trenutne temperature i časa u toku dana
$h * T_d^2(h)$	Efekat interakcije između drugog eksponenta trenutne temperature i časa u toku dana
$h * T_d^3(h)$	Efekat interakcije između trećeg eksponenta trenutne temperature i časa u toku dana

U okviru ove disertacije, kao deo analize različitih MLR modela za STLTF, upravo model opisan jednačinom 4.1 je uzet kao polazna tačka, pre svega zbog mogućnosti referenciranja u okviru postojeće skorašnje STLTF literature, a potom i zbog svoje jednostavnosti, te mogućnosti implementacije.

4.1.2 Skup podataka za testiranje

Za konstruisanje različitih MLR modela koji će biti predstavljeni u ovom poglavlju, potrebno je koristiti skup podataka koji u sebi poseduje zabeležena merenja o proteklom ponašanju procesa potrošnje el. energije na sistemskom nivou (grupi potrošača koja se nalazi u određenoj regiji), kao i zabeležena merenja temperature okoline, u regiji u kojoj se nalaze potrošači za koje se izvršava predviđanje. U okviru ovog poglavlja će biti konstruisano nekoliko različitih regresivnih modela, od kojih neki koriste isključivo informacije o temperaturi okoline, a drugi isključivo informacije o proteklom ponašanju vremenske serije potrošnje el. energije. Na kraju poglavlja predstavljamo kombinovane modele, koji koriste informacije o oba skupa podataka (temperaturi i potrošnji), kao i napredniji model dobijen pomoću optimizacione procedure, korišćenjem genetskog algoritma, koji koristi informacije o temperaturi i potrošnji, kao i dodatne promenljive, koje će biti detaljno opisane prilikom konstrukcije samog modela. Većina elektroenergetskih kompanija ima mogućnost pristupa skupovima podataka koji predstavljaju zabeleženu temperaturu okoline i zabeležene časovne vrednosti potrošnje el. energije. Neke kompanije čak imaju i sopstvene kapacitete, u vidu meteoroloških stanica, za potrebe dobavljanja preciznijih informacija o temperaturi okoline (kao i o ostalim meteorološkim parametrima), dok druge kompanije za te potrebe koriste meteorološke servise.

Podaci koji se koriste u okviru ove disertacije, prilikom konstrukcije svih prezentovanih modela, predstavljaju zabeležena merenja temperature, kao i sistemske potrošnje el. energije, sa časovnom učestanošću, za područje grada sa zapadne obale severnoameričkog kontinenta, veličine 100.000 stanovnika.. Podaci su dobijeni putem saradnje sa elektroenergetskom kompanijom koja vrši snabdevanje el. energijom u toj regiji. U okviru pomenute saradnje, razvijani su različiti modeli za STLTF, od kojih se neki nalaze u upotrebi u okviru pomenute

kompanije, kao komercijalno sredstvo predviđanja potrošnje el. energije. Zbog zakonske regulative, kao i zbog bezbednosti podataka, u okviru ove disertacije su prikazane samo pojedine faze razvoja komercijalnih STLF modela trenutno upotrebljavanih u Burbanku.

Vremenski period u kome su zabeleženi navedeni podaci počinje 1. januara 2009., a završava se 31. decembra 2011., predstavljajući na taj način tri godine zabeleženih podataka, što u generalnom poređenju sa aktuelnom STLF literaturom predstavlja obučavajući skup dovoljne veličine. Vremenska serija koje predstavlja zabeležena merenja potrošnje el. energije na sistemskom nivou prikazana je na Ilustracija 4.1, dok je vremenska serija koja predstavlja zabeležena merenja temperature okoline prikazana na Ilustracija 4.2.

Ilustracija 4.1 Sistemska potrošnja grada Burbank-a, CA, zabeležena u periodu od 3 godine

Ilustracija 4.2 Zabeležena temperatura za područje grada Burbank-a, CA, u periodu od 3 godine

4.1.3 Implementacija modela za testiranje sa prikazom rezultata

U svrhu testiranja razvijenih metoda, potrebno je odabrati određeni period u okviru zabeleženih merenja, koji će poslužiti kao obučavajući skup, a takođe je potrebno odabrati i neki period nad kojim će se vršiti upoređivanje zabeleženih i predviđenih podataka. Pošto elektroenergetske kompanije uglavnom imaju problema sa stabilnošću sistema i raspoređivanjem kapaciteta u slučaju kada je sistemska potrošnja na gornjoj granici, u ovoj disertaciji je odabran period od nedelju dana, u okviru 2011. godine, pri čemu je prethodnom analizom utvrđeno da je za taj period ukupna potrošena energija u sistemu bila najveća u toku 2011. godine. Pomenuti period počinje 22. avgusta 2011.godine, a završava se 28. avgusta 2011. godine. Potrošnja za navedeni period, kao i odgovarajuća zabeležena temperatura, prikazane su na Ilustracija 4.3 i Ilustracija 4.4 uporedno.

4 STL – linearna regresija

Ilustracija 4.3 Zabeležena potrošnja za period od 22.do28. avgusta 2011. godine

Ilustracija 4.4 Zabeležena temperatura za period od 22.-do28. avgusta 2011. godine

4.1.3.1 Izračunavanje parametara MLR modela za testiranje

U jednačini 4.1 je prikazan generalni izgled modela koji je korišćen kao polazna tačka za komparativnu analizu u okviru ove disertacije. Kao što se iz pomenute formule može videti, model ima 10 parametara, prikazanih koeficijentima $\alpha_0, \alpha_1, \dots, \alpha_9$, koje je potrebno izračunati da bi se moglo pristupiti korišćenju modela u svrhe predviđanja. Za izračunavanje ovih koeficijenata se koriste zabeleženi podaci u periodu od 1. januar a 2009. godine, do 21. avgusta 2011. godine, dok se samo izračunavanje obavlja pomoću metode najmanjih kvadrata. Dobijanje rezultata pomoću metode najmanjih kvadrata se zasniva na rešavanju sledeće matrične jednačine:

$$\mathbf{S} * \mathbf{b} = \mathbf{y} \quad 4.2$$

pri čemu matrica S predstavlja zabeležene vrednosti merenja temperature, vektor b predstavlja nepoznate koeficijente modela, koji su predmet izračunavanja, dok vektor y predstavlja zabeležene vrednosti sistemske potrošnje el. energije. Za potrebe rešavanja matrične jednačine 4.2, za model prikazan jednačinom 4.1, matrica S se formira na sledeći način:

$$S = \begin{bmatrix} 1 & h_1 & d_1 * h_1 & m_1 & m_1 * T(h_1) & m_1 * T^2(h_1) & \dots & h_1 * T^3(h_1) \\ 1 & h_2 & d_1 * h_2 & m_1 & m_1 * T(h_2) & m_1 * T^2(h_2) & \dots & h_2 * T^3(h_2) \\ 1 & h_3 & d_1 * h_3 & m_1 & m_1 * T(h_3) & m_1 * T^2(h_3) & \dots & h_3 * T^3(h_3) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & h_n & d_m * h_n & m_p & m_p * T(h_n) & m_p * T^2(h_n) & \dots & h_n * T^3(h_n) \end{bmatrix} \quad 4.3$$

pri čemu svaka kolona matrice S odgovara jednom koeficijentu modela, a svaka vrsta matrice S odgovara jednom slogu zabeleženih podataka, vezanih za određeni čas. Prva kolona odgovara parametru modela koji predstavlja konstantu, pa su zato sve vrednosti u okviru nje jednake 1. Druga kolona predstavlja vrednost časa za koji su zabeleženi posmatrani podaci u određenoj vrsti matrice, pri čemu su ove vrednosti predstavljene brojevima od 0 do 24, jer predstavljaju časove u toku jednog dana. Treća kolona predstavlja vrednost časa za koji je zabeleženo merenje, pomnoženu sa vrednošću dana (predstavljenom od 0 do 7, pošto se radi o određenom danu u toku nedelje), pri čemu se podrazumeva da čas pripada tom danu. Po analogiji se može formulisati značenje preostalih kolona u matrici. Broj vrsta matrice odgovara broju zabeleženih slogova merenja u okviru skupa podataka, što u slučaju kada se posmatra period od 1. januara 2009. godine, do 21. avgusta 2011. godine, iznosi 963.

Vektor b se definiše kao:

$$b = \begin{bmatrix} \alpha_0 \\ \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \\ \alpha_5 \\ \alpha_6 \\ \alpha_7 \\ \alpha_8 \\ \alpha_9 \end{bmatrix} \quad 4.4$$

dok se vektor y definiše kao:

$$y = \begin{bmatrix} L(h_1) \\ L(h_2) \\ L(h_3) \\ \vdots \\ L(h_n) \end{bmatrix} \quad 4.5$$

Jednačinu 4.3 je potrebno rešiti metodom najmanjih kvadrata, da bi se kao rezultat dobio vektor nepoznatih koeficijenata b , a rešenje se dobija na sledeći način:

$$b = \left(\mathbf{S}^T * \mathbf{S} \right)^{-1} * \mathbf{S}^T * \mathbf{y} \quad 4.6$$

Nakon što se dobiju koeficijenti modela, može se izvršiti predviđanje za jedan dan unapred. Navedeno predviđanje se izvršava za svih sedam dana perioda od 22. avgusta do 28. avgusta 2011. godine, da bi se kvalitet performanse STLF modela izračunao na osnovu perioda od nedelju dana.

4.1.3.2 Prikaz rezultata predviđanja pomoću uporednog MLR modela

Na Ilustracija 4.5 je prikazan rezultat predviđanja za pomenuti period. Kao što se opravdano može zaključiti, čak i na prvi pogled, rezultati su potpuno neprihvatljivi jer kriva generisana predviđanjem uopšte ne prati zabeležena merenja. Greška predviđanja (MAPE) za period od nedelju dana iznosi 24.64%, što nije uporedivo sa potrebama koje se nameću u okviru elektroenergetskih kompanija, a nažalost čak ni za komparativnu analizu. Ipak, ovaj primer može poslužiti kao realan prikaz aktuelnog stanja u STLF oblasti, pogotovo u literaturi, pri čemu se može zaključiti da reprodukcija modela pomenutih u literaturi, pa čak i onih vrlo jednostavnih, čak i kada je moguća, ne mora dati prihvatljive rezultate.

Ilustracija 4.5 Rezultati predviđanja dobijeni korišćenjem jednostavnog modela za komparativnu analizu. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

4.2 Dizajn MLR modela putem analize korelacije

Ukoliko se analizira model predstavljen jednačinom 4.1, može se videti da sve trenutne vrednosti potrošnje el. energije, na način na koji su formulisane predloženim modelom, zavise isključivo od trenutnih vrednosti temperature okoline. Ovakav model može biti opravdan u nekim slučajevima, pogotovo ukoliko se radi o geografskoj regiji sa ekstremnim klimatskim uslovima, u kojima potrošnja električne energije nastala upotrebom klimatizacionih uređaja igra veliku ulogu. Ipak, imajući u vidu toplotni koeficijent životne okoline ljudi (ukoliko se radi o rezidencijalnim potrošačima), temperatura okoline, tj. vazduha, neće imati istovremeni efekat na subjektivni osećaj klimatske promene, već će postojati neki period akumulacije energije, koji će biti potreban za promene nastale u temperaturi vazduha da se odraze na potrošnju el. energije. Sem toga, pomenute vrednosti nisu dostupne u trenutku generisanja rezultata predviđanja, već je neophodno koristiti predviđene temperature, što uvodi još jedan stepen nesigurnosti u već ionako neupotrebljiv model. Na Ilustracija 4.6 je prikazana zavisnost potrošnje od trenutne temperature, za sve tri godine zabeleženih merenja. Može se primetiti da na pomenutoj ilustraciji nije moguće uočiti jasnu zavisnost, te se i sa stanovišta korelacione analize može zaključiti da predloženi jednostavni model nije dobar.

U skladu sa konstatacijama u vezi sa performansama modela za testiranje, uputno je uraditi korelacionu analizu podataka i modifikovati predloženi model u skladu sa rezultatima takve analize. Za potrebe analiziranja, iskorišćeni su podaci od 1. januara 2009. godine, do 21. avgusta 2011. godine, da bi se osiguralo realistično prikazivanje performansi modela (podaci iz testirajućeg skupa, tj. od 22. avgusta, do 28. avgusta 2011. godine nisu uzeti u obzir prilikom analize korelacije).

4.2.1 Analiza korelacije između signala potrošnje el. energije i zabeležene temperature

U prvoj fazi korelacione analize, osnovni model je proširen na način da se ne uzimaju u obzir samo trenutne temperature, već i zabeležene vrednosti temperature u prošlosti, u periodu od proteklih nedelju dana. U skladu sa predoženim korišćenjem transformisanih vrednosti temperature, u vidu eksponenta određenog stepena zabeleženih vrednosti, takođe je analizirana korelacija signala potrošnje el. energije sa složenim promenljivama koje odražavaju interakcione efekte. Detaljni rezultati korelacione analize između zabeleženog signala potrošnje el. energije i zabeleženih vrednosti temperature (osnovnih i transformisanih oblika, kao i efekata interakcije), prikazani su u **Error! Reference source not found..**

Ilustracija 4.6 Korelacija temperature i potrošnje na sistemskom nivou

Tabela 4.2 Korelacija između predviđane potrošnje i prethodno zabeleženih temperatura

Promenljiva modela	Opis	Stepen korelacije sa signalom potrošnje
$T_d(h - 15)$	Temperatura 15 časova pre predviđane potrošnje	0.75
$T_d(h - 16)$	Temperatura 16 časova pre predviđane potrošnje	0.73
$T_d^2(h - 14)$	Kvadrat temperature, 14 časova pre predviđane potrošnje	0.716
$T_d^2(h - 15)$	Kvadrat temperature, 15 časova pre predviđane potrošnje	0.75
$T_d^2(h - 16)$	Kvadrat temperature, 16 časova pre predviđane potrošnje	0.75
$T_d^2(h - 17)$	Kvadrat temperature, 17 časova pre predviđane potrošnje	0.73
$T_d^3(h - 14)$	Treći stepen temperature, 14 časova pre predviđane potrošnje	0.72
$T_d^3(h - 15)$	Treći stepen temperature, 15 časova pre predviđane potrošnje	0.76
$T_d^3(h - 16)$	Treći stepen temperature, 16 časova pre predviđane potrošnje	0.77
$T_d^3(h - 17)$	Treći stepen temperature, 17 časova pre predviđane potrošnje	0.74
$T_d^4(h - 14)$	Četvrti stepen temperature, 14 časova pre predviđane potrošnje	0.72
$T_d^4(h - 15)$	Četvrti stepen temperature, 15 časova pre predviđane potrošnje	0.76
$T_d^4(h - 16)$	Četvrti stepen temperature, 16 časova pre predviđane potrošnje	0.77
$T_d^4(h - 17)$	Četvrti stepen temperature, 17 časova pre predviđane potrošnje	0.75
$T_{d-1}^2(h - 15)$	Kvadrat temperature, 15 časova pre časa predviđanja, jedan dan pre dana predviđanja	0.71
$T_{d-1}^2(h - 16)$	Kvadrat temperature, 16 časova pre časa predviđanja, jedan dan pre dana predviđanja	0.71
$T_{d-1}^3(h - 15)$	Treći stepen temperature, 15 časova pre časa predviđanja, jedan dan pre dana predviđanja	0.71
$T_{d-1}^3(h - 16)$	Treći stepen temperature, 16 časova pre časa predviđanja, jedan dan pre dana predviđanja	0.72
$T_{d-1}^4(h - 15)$	Četvrti stepen temperature, 15 časova pre časa predviđanja, jedan dan pre dana predviđanja	0.71
$T_{d-1}^4(h - 16)$	Četvrti stepen temperature, 16 časova pre časa predviđanja, jedan dan pre dana predviđanja	0.72

Model koji je dobijen ovakvom analizom se može predstaviti pomoću sledeće formule:

$$L(h) = \mathbf{b} * \mathbf{x} \quad 4.7$$

pri čemu je $L(h)$ potrošnja koju je potrebno predvideti, dok su $\mathbf{b}$ i $\mathbf{x}$ vektori koeficijenata i ulaznih promenljivih modela, respektivno. Ovi vektori su definisani na sledeći način:

$$\mathbf{x} = \begin{bmatrix} T_d(h-15) \\ T_d(h-16) \\ T_d^2(h-14) \\ T_d^2(h-15) \\ T_d^2(h-16) \\ T_d^2(h-17) \\ T_d^3(h-14) \\ T_d^3(h-15) \\ T_d^3(h-16) \\ T_d^3(h-17) \\ T_d^4(h-14) \\ T_d^4(h-15) \\ T_d^4(h-16) \\ T_d^4(h-17) \\ T_{d-1}^2(h-15) \\ T_{d-1}^2(h-16) \\ T_{d-1}^3(h-15) \\ T_{d-1}^3(h-16) \\ T_{d-1}^4(h-15) \\ T_{d-1}^4(h-16) \end{bmatrix}^T, \mathbf{b} = \begin{bmatrix} 38.5079 \\ -27.8289 \\ -0.0317 \\ -0.8515 \\ 0.7186 \\ -0.1550 \\ 4.7927 * 10^{-4} \\ 8.3892 * 10^{-3} \\ -7.592 * 10^{-3} \\ 2.4273 * 10^{-4} \\ -1.821 * 10^{-6} \\ -3.027 * 10^{-5} \\ 2.8563 * 10^{-5} \\ -9.801 * 10^{-6} \\ 0.0493 \\ -0.0624 \\ -7.4 * 10^{-4} \\ 1.128 * 10^{-3} \\ 2.748 * 10^{-6} \\ -5.226 * 10^{-6} \end{bmatrix} \quad 4.8$$

Predviđanje potrošnje el. energije pomoću modela dobijenog korelativnom analizom isključivo temperaturnih merenja, kao i njihovih transformisanih vrednosti, dobijaju se rezultati koji su po kvalitetu bolji od početnog referentnog modela, iako i dalje neprihvatljivi za praktičnu primenu (kako u komercijalnom, tako i u uporednom smislu). Rezultati dobijeni ovakvim modelom, za navedeni period testiranja, prikazani su na Ilustracija 4.7. Ovde je potrebno naglasiti da početni model predstavlja pogrešnu referencu, pošto potpuno promašuje predviđanja, te je potrebno naći bolju referencu za poređenje. Model dobijen korelativnom analizom predstavlja upravo takvu referencu, te se nadalje u disertaciji on može smatrati referentnim modelom.

Ilustracija 4.7 Rezultati predviđanja generisani modelom dobijenim korelativne analize temperaturnih uticaja. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

Iako se za ostvarene rezultate može reći da po kvalitetu daleko prevazilaze performanse uporednog modela, pre svega zbog oblika generisanih dnevnih profila potrošnje, koji u nekoj meri prate ostvarenu potrošnju, oni ipak nisu zadovoljavajući po preciznosti, s obzirom na to da mera performansi modela, izražena u MAPE iznosi 14.44%. Ovaj iznos nije prihvatljiv kako za praktičnu upotrebu u okviru elektroenergetskih preduzeća, tako ni za uporednu analizu sa drugim metodama (čak ni kao polazna osnova za testiranje), imajući u vidu prijavljene rezultate u većini STL literature. Iz tog razloga formirana su još dva modela dobijena korelacionom analizom. U prvom slučaju je reč o autokorelaciji zabeleženog signala potrošnje el. energije, pri čemu se analiziraju i uticaji transformisanih zabeleženih merenja, a u drugom se kombinuju dva prethodno dobijena modela, pri čemu se analiziraju dobijeni rezultati.

4.2.2 Analiza autokorelacije zabeleženog signala potrošnje, kao i njegove korelacije sa transformisanim sopstvenim vrednostima zabeleženih merenja

Analogno formiranju čisto temperaturnog modela, opisanog u sekciji 4.2.1, formira se i model zasnovan isključivo na prošlim zabeleženim merenjima potrošnje el. energije. Ovde treba napomenuti da se prilikom analize korelacije vrednosti posmatraju počevši od jednog dana

pre predviđanja (pri čemu vrednosti zabeležene za dan predviđanja ne ulaze u korelacionu analizu, pošto u vreme generisanja rezultata predviđanja te vrednosti nisu dostupne), za razliku od temperaturnog modela, gde su se analizirale i vrednosti zabeležene za dan predviđanja, podrazumevajući pri tome da se u eksploatacionoj fazi modela koriste predviđene vrednosti. Autokorelacija signala je prikazana na Ilustracija 4.8, a iz prikazanog dijagrama se vidi koliku korelaciju imaju časovne vrednosti potrošnje u prošlosti sa trenutnom posmatranom potrošnjom, dok je izbor elemenata sa najvećim stepenom korelacije (pri čemu u analizu ulaze i transformisane vrednosti) prikazan u **Error! Reference source not found..**

Tabela 4.3 Korelacija između predviđane potrošnje i sopstvenih prethodno zabeleženih vrednosti (osnovnih i transformisanih oblika)

Promenljiva modela	Opis	Stepen korelacije sa signalom potrošnje
$L_{d-1}(h)$	Potrošnja za isti čas, prethodnog dana	0.89
$L_{d-1}(h-1)$	Potrošnja zabeležena 1 čas pre časa predviđanja, prethodnog dana	0.86
$L_{d-1}(h-2)$	Potrošnja zabeležena 2 časa pre časa predviđanja, prethodnog dana	0.79
$L_{d-6}(h)$	Potrošnja za isti čas, 6 dana pre dana predviđanja	0.78
$L_{d-6}(h-23)$	Potrošnja zabeležena 23 časa pre časa predviđanja, 6 dana pre dana predviđanja	0.83
$L_{d-7}(h)$	Potrošnja za isti čas, 7 dana pre dana predviđanja	0.85
$L_{d-7}(h-1)$	Potrošnja zabeležena 1 čas pre časa predviđanja, 7 dana pre dana predviđanja	0.83
$L_{d-1}^2(h)$	Kvadrat potrošnje za isti čas, prethodnog dana	0.88
$L_{d-1}^2(h-1)$	Kvadrat potrošnje zabeležene 1 čas pre časa potrošnje, prethodnog dana	0.85
$L_{d-1}^2(h-2)$	Kvadrat potrošnje zabeležene 2 časa pre časa potrošnje, prethodnog dana	0.78
$L_{d-6}^2(h-23)$	Kvadrat potrošnje zabeležene 23 časa pre časa potrošnje, 6 dana pre dana potrošnje	0.79
$L_{d-7}^2(h)$	Kvadrat potrošnje za isti čas, 7 dana pre dana potrošnje	0.81
$L_{d-7}^2(h-1)$	Kvadrat potrošnje zabeležene 1 čas pre časa potrošnje, 7 dana pre dana potrošnje	0.79
$\ln(L_{d-1}(h))$	Logaritam potrošnje za isti čas, prethodnog dana	0.88
$\ln(L_{d-1}(h-1))$	Logaritam potrošnje zabeležene 1 čas pre časa predviđanja, prethodnog dana	0.85
$\ln(L_{d-1}(h-2))$	Logaritam potrošnje zabeležene 2 časa pre časa predviđanja, prethodnog dana	0.78
$\ln(L_{d-6}(h))$	Logaritam potrošnje za isti čas, 6 dana pre dana potrošnje	0.79
$\ln(L_{d-6}(h-23))$	Logaritam potrošnje zabeležene 23 časa pre časa predviđanja, 6 dana pre dana potrošnje	0.84
$\ln(L_{d-7}(h))$	Logaritam potrošnje za isti čas, 7 dana pre dana potrošnje	0.86
$\ln(L_{d-7}(h-1))$	Logaritam potrošnje zabeležene 23 časa pre časa predviđanja, 7 dana pre dana potrošnje	0.84

Ilustracija 4.8 Analiza autokorelacije zabeleženog signala potrošnje el. energije

Model koji je dobijen ovakvom analizom se može predstaviti pomoću sledeće formule:

$$L(h) = \mathbf{b} * \mathbf{x} \quad 4.9$$

pri čemu je $L(h)$ potrošnja koju je potrebno predvideti, dok su $\mathbf{b}$ i $\mathbf{x}$ vektori koeficijenata i ulaznih promenljivih modela, respektivno. Ovi vektori su definisani na sledeći način:

$$\mathbf{x} = \begin{bmatrix} T_{(d-0)}(h-15) \\ T_{d-0}(h-16) \\ T_{d-0}^2(h-14) \\ T_{d-0}^2(h-15) \\ T_{d-0}^2(h-16) \\ T_{d-0}^2(h-17) \\ T_{d-0}^3(h-14) \\ T_{d-0}^3(h-15) \\ T_{d-0}^3(h-16) \\ T_{d-0}^3(h-17) \\ T_{d-0}^4(h-14) \\ T_{d-0}^4(h-15) \\ T_{d-0}^4(h-16) \\ T_{d-0}^4(h-17) \\ T_{d-1}^2(h-15) \\ T_{d-1}^2(h-16) \\ T_{d-1}^3(h-15) \\ T_{d-1}^3(h-16) \\ T_{d-1}^4(h-15) \\ T_{d-1}^4(h-16) \end{bmatrix}^T, \mathbf{b} = \begin{bmatrix} -0.3664 \\ 2.9262 \\ -0.8093 \\ -0.0372 \\ 1.958 \\ -2.7352 \\ 0.1741 \\ 0.0027 \\ -0.005 \\ 0.0021 \\ -0.0036 \\ 0.0055 \\ -0.0021 \\ 23.4778 \\ -212.21 \\ 10.54 \\ 18.895 \\ -128.54 \\ 193.7 \\ 92.658 \end{bmatrix} \quad 4.10$$

Predviđanjem potrošnje el. energije pomoću modela dobijenog korelativnom analizom isključivo prethodno zabeleženih sopstvenih merenja, kao i njihovih transformisanih vrednosti, dobijaju se rezultati koji su po kvalitetu bolji od testirajućeg-uporednog modela, kao i od isključivog temperaturnog modela. Iako ovi rezultati i dalje nisu prihvatljivi za praktičnu primenu, njihova upotreba u uporednom smislu, pre svega kao osnova za komparaciju sa drugim metodama, može biti prihvatljiva. Rezultati dobijeni ovakvim modelom, za navedeni period testiranja, prikazani su na Ilustracija 4.9

Ilustracija 4.9 Rezultati predviđanja generisani modelom dobijenim korelativnom analizom uticaja prethodno zabeležene potrošnje. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

Iako se za ostvarene rezultate može reći da po kvalitetu daleko prevazilaze performanse uporednog modela, dok su od čisto temperaturnog modela značajno bolji, pre svega zbog oblika generisanih dnevnih profila potrošnje, koji u dosta velikoj meri prate ostvarenu potrošnju, oni ipak nisu zadovoljavajući po preciznosti, s obzirom na to da mera performansi modela, izražena u MAPE iznosi 7.76%. Ovaj iznos nije prihvatljiv za praktičnu upotrebu u okviru elektroenergetskih preduzeća, ali za uporednu analizu sa drugim metodama (najviše kao polazna osnova za testiranje), može imati izvesnu upotrebnu vrednost.

4.2.3 Konstrukcija MLR modela na osnovu rezultata prethodno dobijenih korelativnom analizom

Na osnovu rezultata dobijenih u sekcijama 4.2.2 i 4.2.3, konstruisan je model koji u sebi sadrži elemente sa prethodno zabeleženim vrednostima temperature, kao i sa prethodno zabeleženim vrednostima potrošnje. S obzirom na to da se u ovom slučaju koriste više promenljivih koje nisu eksplicitno zavisne jedna od druge (ni u fizičkom ni u matematičkom smislu), dobija se model veće preciznosti. Promenljive koje sačinjavaju model su opisane prilikom opisivanja dva prethodno razvijana modela, pri čemu se odgovarajući opisi mogu pronaći u **Error! Reference source not found.** i **Error! Reference source not found.**

Model koji je dobijen ovakvom analizom se može predstaviti pomoću sledeće formule:

$$L(h) = \mathbf{b} * \mathbf{x} \quad 4.11$$

pri čemu je $L(h)$ potrošnja koju je potrebno predvideti, dok su $\mathbf{b}$ i $\mathbf{x}$ vektori koeficijenata i ulaznih promenljivih modela, respektivno. Ovi vektori su definisani na sledeći način:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_{40} \end{bmatrix}, \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_{40} \end{bmatrix} \quad 4.12$$

dok su ulazne promenljive $x_1, x_2, \dots, x_{40}$, kao i koeficijenti $b_1, b_2, \dots, b_{40}$ predstavljene u Tabela 4.4, radi bolje preglednosti.

Tabela 4.4 Ulazne promenljive modela i odgovarajući parametri

i	x_i	b_i	i	x_i	b_i
1	$T_d(h - 15)$	0.391	21	$L_{d-1}(h)$	8.49
2	$T_d(h - 16)$	0.127	22	$L_{d-1}(h - 1)$	2.64
3	$T_d^2(h - 14)$	0.975	23	$L_{d-1}(h - 2)$	-0.037
4	$T_d^2(h - 15)$	-0.073	24	$L_{d-6}(h)$	-0.181
5	$T_d^2(h - 16)$	2.994	25	$L_{d-6}(h - 23)$	-0.038
6	$T_d^2(h - 17)$	-3.592	26	$L_{d-7}(h)$	-0.035
7	$T_d^3(h - 14)$	1.258	27	$L_{d-7}(h - 1)$	$6.26 \cdot 10^{-3}$
8	$T_d^3(h - 15)$	$2.22 \cdot 10^{-5}$	28	$L_{d-1}^2(h)$	$1.68 \cdot 10^{-3}$
9	$T_d^3(h - 16)$	$9.74 \cdot 10^{-5}$	29	$L_{d-1}^2(h - 1)$	$2 \cdot 10^{-4}$
10	$T_d^3(h - 17)$	$-1.13 \cdot 10^{-3}$	30	$L_{d-1}^2(h - 2)$	$5.49 \cdot 10^{-4}$
11	$T_d^4(h - 14)$	$-5.6 \cdot 10^{-3}$	31	$L_{d-6}^2(h - 23)$	$-2.56 \cdot 10^{-6}$
12	$T_d^4(h - 15)$	$7.55 \cdot 10^{-3}$	32	$L_{d-7}^2(h)$	$-5.7 \cdot 10^{-6}$
13	$T_d^4(h - 16)$	$-4 \cdot 10^{-3}$	33	$L_{d-7}^2(h - 1)$	$-2.16 \cdot 10^{-7}$
14	$T_d^4(h - 17)$	-4.278	34	$\ln(L_{d-1}(h))$	$-1.78 \cdot 10^{-6}$
15	$T_{d-1}^2(h - 15)$	-20.772	35	$\ln(L_{d-1}(h - 1))$	$8.54 \cdot 10^{-3}$
16	$T_{d-1}^2(h - 16)$	-107.17	36	$\ln(L_{d-1}(h - 2))$	$-4.1 \cdot 10^{-3}$
17	$T_{d-1}^3(h - 15)$	17.179	37	$\ln(L_{d-6}(h))$	$-1.32 \cdot 10^{-4}$
18	$T_{d-1}^3(h - 16)$	-197.731	38	$\ln(L_{d-6}(h - 23))$	$1.11 \cdot 10^{-4}$
19	$T_{d-1}^4(h - 15)$	255.24	39	$\ln(L_{d-7}(h))$	$3.04 \cdot 10^{-7}$
20	$T_{d-1}^4(h - 16)$	8.57	40	$\ln(L_{d-7}(h - 1))$	$-7.78 \cdot 10^{-7}$

Performanse kombinovanog modela (kombinacija uticaja temperature i prethodne potrošnje) su prikazane na Ilustracija 4.10.

Ilustracija 4.10 Rezultati predviđanja generisani kombinovanim modelom. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

Za rezultate dobijene kombinovanim modelom se može zaključiti da su po svojoj preciznosti bolji nego prethodno konstruisani modeli. Ukoliko se posmatra Ilustracija 4.10, može se zaključiti da generisani dnevni profili potrošnje el. energije svojim oblikom u potpunosti prate zabeležene ostvarene dnevne profile, iako u nekim tačkama dolazi do poremećaja. Sa druge strane, u trenucima maksimalne potrošnje, predviđene vrednosti su u skoro svim slučajevima manje od ostvarenih vrednosti, što nije pogodno za potrebe koje se nameću u okviru elektroenergetskih kompanija. Može se konstatovati da su performanse modela zadovoljavajuće za uporednu analizu sa drugim metodama, s obzirom na to da performanse modela, analizirane pomoću MAPE iznose 5.99%, što predstavlja prihvatljive vrednosti [89] (za teorijsku primenu).

Ovde je potrebno napomenuti da se drugačije zavisnosti između temperature i potrošnje mogu javiti u drugim godišnjim sezonama. Zbog ove činjenice, uputno je izvršiti selekciju obučavajućeg skupa, pre nego što se pristupi proceduri određivanja parametara modela. Prethodna izjava podrazumeva detaljnu analizu sa posebnom problematikom i kao takva ne predstavlja fokus ove disertacije, iako će u njenom sastavu biti prikazano nekoliko primera uticaja manualnog selektovanja obučavajućeg skupa podataka na rezultate predviđanja.

4.2.4 Dizajn MLR STLTF modela pomoću genetskog algoritma

4.2.4.1 Upotreba GA za modeliranje zavisnosti

Genetski algoritam se upotrebljava za određivanje ulaznih promenljivih MLR STLTF modela, pomoću kojih model daje najbolje performanse, u vidu preciznosti predviđanja. U prethodnim sekcijama je objašnjeno da drugačiji tipovi procesa potrošnje el. energije, pri čemu se prvenstveno misli na različite tipove potrošača u okviru jednog elektroenergetskog preduzeća, kao i na sistemske potrošnje potpuno različitih elektroenergetskih preduzeća, imaju različite karakteristike, posmatrano kroz koncept vremenskih serija. U skladu sa time, međuzavisnosti faktora koji utiču na potrošnju el. energije i samog procesa potrošnje, nisu iste u svakom elektroenergetskom sistemu. Zbog ovoga nije moguće formulisati jedan STLTF model koji bi bio podjednakih performansi (ili barem približnih), kada se primeni generalno.

Predložena procedura omogućuje prilagođavanje MLR STLTF modela različitim klasama procesa, u okviru različitih elektroenergetskih preduzeća. Takođe, njegova primena ne mora biti ograničena na modele zasnovane na MLR, već se na ovaj način može optimizovati bilo koja od predloženih STLTF tehnika navedenih u literaturi (pod uslovom da za to postoje praktični uslovi, pre svega u vidu dovoljne računarske snage procesiranja). Kada je potrebno odabrati promenljive koje će sačinjavati ulazni skup podataka za STLTF model, postoji mogućnost izbora između zabeleženih merenja temperature okoline i prethodne potrošnje el. energije. Međutim, kao što je navedeno u sekciji 3.1, moguće je modelovati dodatne uticaje, međusobnom kombinacijom osnovnih vrednosti zabeleženih merenja, kao i njihovom kombinacijom sa kvalitativnim i kalendarskim promenljivama. Takođe je moguće modelovati razne međuzavisnosti pomoću nelinearnih transformacija osnovnih vrednosti zabeleženih merenja.

Za potrebe optimizacije ulaznog skupa promenljivih pomoću GA, potrebno je formirati skup podataka, koji će u sebi sadržati sve navedene promenljive, uključujući efekte interakcije, nelinearne transformacije, kao i kvalitativne i kalendarske promenljive. Potrebno je naglasiti da neke od ovih promenljivih nemaju značajan stepen korelacije sa signalom koji je potrebno modelovati, a u nekim slučajevima je taj stepen potpuno zanemariv. Ipak, čak i takve promenljive mogu imati uticaja na performanse modela. Kada se formira navedeni skup podataka, GA vrši optimizaciju birajući određeni, unapred fiksirani broj kandidata (promenljivih) koje sačinjavaju MLR STLTF model. Validacija odabranog modela se zatim vrši za svaki odabrani skup promenljivih (za svaku jedinku GA), pri čemu se greška predviđanja na testirajućem periodu uzima za fitness funkciju GA.

Ovde je potrebno naglasiti da se drugačiji rezultati mogu očekivati u zavisnosti od kriterijuma optimizacije za GA. Naime, performanse STLTF modela, u vidu ostvarene preciznosti, kao i u

vidu oblika generisanog profila potrošnje, razlikuju se u zavisnosti od korišćene metrike, (MAPE, MAE, WAPE).

4.2.4.2 Rezultati optimizacije MLR STLF modela, korišćenjem kriterijuma optimizacije MAPE

Kao što je već definisano u sekciji 3.3 srednja procentualna greška, čija je definicija ovde ponovljena zbog lakšeg praćenja dokumenta, može se definisati na sledeći način:

$$M = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - f_t}{y_t} \right| \times 100 \quad 4.13$$

Ukoliko se ova definicija upotrebi za kriterijum optimizacije pomoću GA, tačnije, ukoliko se fitness funkcija definiše upravo na ovaj način, mogu se dobiti rezultati koji su po svojoj preciznosti bolji nego prethodna tri formirana modela (upotrebom korelativne analize). Obučavajući i testirajući period su isti kao i u prethodna tri slučaja (kao i tokom čitave disertacije), da bi se obezbedilo ravnopravno poređenje predstavljenih modela. Model koji je dobijen ovakvom analizom se može predstaviti pomoću sledeće formule:

$$L(h) = \mathbf{b} * \mathbf{x} \quad 4.14$$

pri čemu je $L(h)$ potrošnja koju je potrebno predvideti, dok su $\mathbf{b}$ i $\mathbf{x}$ vektori koeficijenata i ulaznih promenljivih modela, respektivno. Ovi vektori su definisani na sledeći način:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_{40} \end{bmatrix}, \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_{40} \end{bmatrix} \quad 4.15$$

dok su ulazne promenljive $x_1, x_2, \dots, x_{40}$, kao i koeficijenti $b_1, b_2, \dots, b_{40}$ predstavljene u Tabela 4.5, radi bolje preglednosti. Oznaka m u tabeli predstavlja mesec za koji su zabeleženi podaci, čija je vrednost kodirana brojevima od 1 do 12.

Tabela 4.5 Ulazne promenljive modela i odgovarajući parametri

i	x_i	b_i	i	x_i	b_i
1	$d * T_{d-0}(h - 3)^2$	$-1.01 * 10^{-4}$	21	$d * T_{d-7}(h - 20)$	0.001
2	$T_{d-0}^3(h - 14)$	$3.44 * 10^{-5}$	22	$L_{d-0}^2(h - 4)$	13.48
3	$T_{d-0}^3(h - 17)$	$-7.74 * 10^{-6}$	23	$\ln(L_{d-0}(h - 17))$	0.011
4	$\ln(T_{d-1}(h - 8))$	-9.94	24	$L_{d-0}^2(h - 23)$	0.001
5	$\ln(T_{d-3}(h - 0))$	-0.69	25	$\text{int}(L_{d-1}(h - 21))$	-0.002
6	$d * T_{d-3}^2(h - 2)$	$-5.54 * 10^{-5}$	26	$d * L_{d-2}(h - 12)$	-0.001
7	$\ln(T_{d-3}(h - 18))$	4.1	27	$\text{int}(L_{d-3}(h - 16))$	$-8.36 * 10^{-4}$
8	$h * T_{d-3}^2(h - 20)$	$-1.54 * 10^{-5}$	28	$L_{d-3}^2(h - 23)$	$6.22 * 10^{-5}$
9	$h * T_{d-4}^2(h - 16)$	$6.08 * 10^{-6}$	29	$L_{d-4}^2(h - 21)$	$-1.21 * 10^{-4}$
10	$d * T_{d-4}^2(h - 23)$	$5.9 * 10^{-5}$	30	$L_{d-5}^2(h - 0)$	$-1.12 * 10^{-4}$

11	$m * T_{d-5}^2(h-3)$	$-2.61 * 10^{-5}$	31	$d * L_{d-5}(h-10)$	0.006
12	$T_{d-5}^2(h-7)$	$3.67 * 10^{-4}$	32	$\ln(L_{d-5}(h-23))$	30.58
13	$d * T_{d-5}(h-15)$	-0.013	33	$L_{d-6}^2(h-1)$	$-3.87 * 10^{-4}$
14	$m * T_{d-5}(h-16)$	-0.002	34	$L_{d-6}^2(h-12)$	$-9.26 * 10^5$
15	$d * T_{d-6}(h-2)$	0.005	35	$\ln(L_{d-6}(h-14))$	-5.73
16	$h * T_{d-7}^3(h-0)$	$-2 * 10^{-8}$	36	$d * L_{d-6}(h-17)$	-0.01
17	$\text{int}(T_{d-7}(h-1))$	-0.001	37	$L_{d-7}(h-0)$	0.5
18	$h * T_{d-7}^2(h-8)$	$7.35 * 10^{-7}$	38	$\text{int}(L_{d-7}(h-2))$	-0.02
19	$d * T_{d-7}^3(h-16)$	$-2.85 * 10^{-7}$	39	$\ln(L_{d-7}(h-4))$	-13.3
20	$m * T_{d-7}(h-20)$	0.004	40	$L_{d-7}^2(h-13)$	$5.9 * 10^{-4}$

Rezultati dobijeni pomoću GA, upotrebom MAPE kao kriterijuma, prikazani su na Ilustracija 4.11.

Ilustracija 4.11 Rezultati predviđanja modelom dobijenim GA optimizacijom, na osnovu kriterijuma MAPE. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

4.2.4.3 Rezultati optimizacije MLR STLTF modela, korišćenjem kriterijuma optimizacije MAE

Još jedan od načina za ocenjivanje performansi STLTF modela, koji se može naći u literaturi, predstavlja srednju apsolutnu grešku – MAE. Ona se može definisati na sledeći način:

$$M = \frac{1}{n} \sum_{t=1}^n |y_t - f_t| \quad 4.16$$

Vidi se da je ova definicija slična kao i MAPE, iako se ne izražava u procentima. Rezultati dobijeni GA optimizacijom, upotrebom kriterijuma MAE, po svojoj suštini nisu drugačiji od rezultata dobijenih upotrebom kriterijuma MAPE i ovde su dati isključivo u svrhe demonstracije raznolikih mogućnosti upotrebe predloženog algoritma optimizacije STLFL modela pomoću GA. Model koji je dobijen ovakvom analizom se može predstaviti pomoću sledeće formule:

$$L(h) = \mathbf{b} * \mathbf{x} \quad 4.17$$

pri čemu je $L(h)$ potrošnja koju je potrebno predvideti, dok su $\mathbf{b}$ i $\mathbf{x}$ vektori koeficijenata i ulaznih promenljivih modela, respektivno. Ovi vektori su definisani na sledeći način:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_{40} \end{bmatrix}, \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_{40} \end{bmatrix} \quad 4.18$$

dok su ulazne promenljive $x_1, x_2, \dots, x_{40}$, kao i koeficijenti $b_1, b_2, \dots, b_{40}$ predstavljene u Tabela 4.6, radi bolje preglednosti. Oznaka m u tabeli predstavlja mesec za koji su zabeleženi podaci, čija je vrednost kodirana brojevima od 1 do 12.

Tabela 4.6 Ulazne promenljive modela i odgovarajući parametri

i	x_i	b_i	i	x_i	b_i
1	$m * T_{d-0}^2(h - 0)$	$2.06 * 10^{-6}$	21	$m * T_{d-6}^3(h - 18)$	$-5.44 * 10^{-6}$
2	$T_{d-0}^2(h - 6)$	$-2.71 * 10^{-4}$	22	$d * T_{d-6}(h - 18)$	$1.07 * 10^{-3}$
3	$T_{d-0}^2(h - 12)$	$1.48 * 10^{-3}$	23	$d * T_{d-6}^3(h - 23)$	$5.52 * 10^{-7}$
4	$m * T_{d-0}^3(h - 13)$	$1.05 * 10^{-6}$	24	$h * T_{d-7}^2(h - 5)$	$-2.41 * 10^{-5}$
5	$h * T_{d-0}(h - 19)$	$4.13 * 10^{-3}$	25	$d * T_{d-7}^2(h - 10)$	$1.26 * 10^{-5}$
6	$T_{d-1}^2(h - 1)$	$-8.01 * 10^{-4}$	26	$T_{d-7}(h - 17)$	$3.18 * 10^{-2}$
7	$d * T_{d-1}(h - 6)$	$-5.25 * 10^{-3}$	27	$h * T_{d-7}^2(h - 19)$	$-4.74 * 10^{-5}$
8	$m * T_{d-1}(h - 11)$	$-8.92 * 10^{-3}$	28	$\ln(T_{d-7}(h - 20))$	6.21
9	$h * T_{d-1}^3(h - 18)$	$-3.28 * 10^{-7}$	29	$L_{d-0}^2(h - 1)$	$2.38 * 10^{-3}$
10	$d * T_{d-2}(h - 13)$	$3.15 * 10^{-3}$	30	$L_{d-0}(h - 9)$	$2 * 10^{-2}$
11	$d * T_{d-2}^2(h - 22)$	$-4.67 * 10^{-5}$	31	$\text{int}(L_{d-1}(h - 1))$	$5.85 * 10^{-3}$
12	$d * T_{d-3}^2(h - 14)$	$4.96 * 10^{-5}$	32	$L_{d-1}^2(h - 6)$	$-1.64 * 10^{-4}$
13	$d * T_{d-3}^2(h - 21)$	$-2.59 * 10^{-5}$	33	$d * L_{d-1}(h - 9)$	$3.89 * 10^{-3}$
14	$m * T_{d-3}^3(h - 22)$	$2.72 * 10^{-7}$	34	$L_{d-3}^2(h - 2)$	$-7.72 * 10^{-5}$
15	$T_{d-4}^2(h - 14)$	$3.86 * 10^{-4}$	35	$d * L_{d-4}(h - 14)$	$3.65 * 10^{-3}$
16	$h * T_{d-5}^3(h - 2)$	$6.66 * 10^{-8}$	36	$d * L_{d-6}(h - 10)$	$-8.79 * 10^{-3}$
17	$\ln(T_{d-5}(h - 4))$	-8.96	37	$L_{d-6}(h - 23)$	$2.34 * 10^{-1}$

18	$h * T_{d-6}^3(h-1)$	$-2.58 * 10^{-8}$	38	$L_{d-7}^2(h-21)$	$-3.02 * 10^{-4}$
19	$d * T_{d-6}(h-5)$	$1.17 * 10^{-2}$	39	$\ln(L_{d-7}(h-22))$	12.6
20	$m * T_{d-6}^2(h-18)$	$4.09 * 10^{-4}$	40	$\text{int}(L_{d-7}(h-23))$	$-3.12 * 10^{-3}$

Rezultati dobijeni pomoću GA, upotrebom MAE kao kriterijuma, prikazani su na Ilustracija 4.12.

Ilustracija 4.12 Rezultati predviđanja modelom dobijenim GA optimizacijom, na osnovu kriterijuma MAE. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

4.2.4.4 Rezultati optimizacije MLR STLFL modela, korišćenjem kriterijuma optimizacije WAPE

U prethodna dva slučaja, kad se korist kriterijumi performansi modela izraženi pomoću MAPE i MAE, zanimljivo je primetiti da uticaj greške na celokupne performanse modela ne zavisi od toga kolika je bila ostvarena potrošnja u tom trenutku (kada je greška zabeležena). Sa praktične strane, ovakvo ponašanje nije potpuno odgovarajuće u svrsi upotrebe u okviru elektroenergetskih preduzeća, s obzirom na to da su sistemski operatori uvek orijentisani balansiranju sistema i održavanju njegove stabilnosti, u uslovima maksimalnog opterećenja. Zbog prethodno rečenog se u okviru STLFL literature pojavljuje još jedna mera za ocenjivanje performansi STLFL modela, izražena u vidu ponderisane srednje greške predviđanja. Suština ovakve definicije je da se greška tretira sa većim uvažavanjem ukoliko je nastala za vreme

velike opterećenosti sistema, dok se njen značaj umanjuje ukoliko je nastala u vreme male opterećenosti sistema. Postoje brojni načini za matematičku formulaciju WAPE, ali je suština svakog od njih da se na neki način pomnoži vrednost ostvarene potrošnje sa vrednošću greške nastale generisanim predviđanjem (naravno u okviru obučavajućeg skupa). U okviru ove disertacije izveden je veliki broj eksperimenata sa različitim stepenom uspeha, u okviru kojih su isprobane različite matematičke formulacije WAPE. Sistemom pokušaja i greške, ustanovljeno je da se najbolji rezultati dobijaju pomoću WAPE definisane na sledeći način (pri čemu treba naglasiti da je ovo suboptimalno rešenje):

$$M = \frac{1}{n} \sum_{t=1}^n |(y_t - f_t) * y_t| / 100 \quad 4.19$$

U kontekstu komparativne analize sa prethodno razvijenim modelima, može se zaključiti da model dobijen na osnovu WAPE kriterijuma performansi, a pomoću optimizacije metodom GA, pruža rezultate najvećeg kvaliteta, kako u pogledu preciznosti izražene kroz MAPE, tako i u pogledu samog oblika generisanih profila potrošnje, koji mnogo bolje prate zabeležena merenja ostvarenih vrednosti, nego u prethodnim slučajevima. Model koji je dobijen ovakvom analizom se može predstaviti pomoću sledeće formule:

$$L(h) = \mathbf{b} * \mathbf{x} \quad 4.20$$

pri čemu je $L(h)$ potrošnja koju je potrebno predvideti, dok su $\mathbf{b}$ i $\mathbf{x}$ vektori koeficijenata i ulaznih promenljivih modela, respektivno. Ovi vektori su definisani na sledeći način:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_{40} \end{bmatrix}, \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_{40} \end{bmatrix} \quad 4.21$$

dok su ulazne promenljive $x_1, x_2, \dots, x_{40}$, kao i koeficijenti $b_1, b_2, \dots, b_{40}$ predstavljene u tabeli TBL, radi bolje preglednosti. Oznaka m u tabeli predstavlja mesec za koji su zabeleženi podaci, čija je vrednost kodirana brojevima od 1 do 12.

i	x_i	b_i	i	x_i	b_i
1	$d * T_{d-0}^3(h-7)$	$-1.49 * 10^{-6}$	21	$T_{d-5}^2(h-3)$	$-3.24 * 10^{-5}$
2	$T_{d-0}(h-12)$	$-1.39 * 10^{-1}$	22	$d * T_{d-5}(h-13)$	$-1.16 * 10^{-2}$
3	$T_{d-0}^3(h-12)$	$4.60 * 10^{-5}$	23	$T_{d-5}(h-17)$	$-1.38 * 10^{-1}$
4	$int(T_{d-0}(h-13))$	$-2.51 * 10^{-2}$	24	$d * T_{d-6}^3(h-7)$	$3.57 * 10^{-6}$
5	$m * T_{d-0}^3(h-17)$	$2.60 * 10^{-6}$	25	$h * T_{d-6}^2(h-12)$	$4.90 * 10^{-6}$
6	$T_{d-0}^2(h-20)$	$3.61 * 10^{-3}$	26	$d * T_{d-6}(h-22)$	$-1.99 * 10^{-2}$
7	$h * T_{d-0}^2(h-21)$	$2.09 * 10^{-5}$	27	$d * T_{d-7}^2(h-17)$	$2.23 * 10^{-4}$
8	$d * T_{d-1}(h-3)$	$1.56 * 10^{-2}$	28	$L_{d-0}(h-23)$	$5.56 * 10^{-1}$
9	$int(T_{d-1}(h-16))$	$-1.40 * 10^{-2}$	29	$int(L_{d-1}(h-1))$	$4.62 * 10^{-3}$
10	$m * T_{d-1}^2(h-21)$	$-8.87 * 10^{-5}$	30	$L_{d-1}^2(h-19)$	$-3.58 * 10^{-4}$

11	$m * T_{d-1}^2(h - 23)$	$4.53 * 10^{-5}$	31	$d * L_{d-2}(h - 20)$	$3.85 * 10^{-3}$
12	$T_{d-2}^2(h - 6)$	$1.23 * 10^{-3}$	32	$\ln(L_{d-3}(h - 0))$	$1.35 * 10$
13	$d * T_{d-2}(h - 12)$	$4.64 * 10^{-3}$	33	$\ln(L_{d-4}(h - 21))$	-9.85
14	$h * T_{d-2}^2(h - 19)$	$-6.64 * 10^{-6}$	34	$d * L_{d-5}(h - 4)$	$1.91 * 10^{-2}$
15	$d * T_{d-3}^2(h - 9)$	$6.75 * 10^{-5}$	35	$\ln(L_{d-5}(h - 10))$	$-1.42 * 10$
16	$h * T_{d-3}^3(h - 15)$	$-6.49 * 10^{-8}$	36	$\ln(L_{d-5}(h - 15))$	4.14
17	$T_{d-3}(h - 16)$	$-4.05 * 10^{-2}$	37	$L_{d-6}^2(h - 1)$	$4.25 * 10^{-5}$
18	$m * T_{d-3}^2(h - 18)$	$-1.17 * 10^{-4}$	38	$\ln(L_{d-6}(h - 1))$	$2.55 * 10$
19	$d * T_{d-4}(h - 3)$	$-1.78 * 10^{-3}$	39	$d * L_{d-6}(h - 19)$	$-1.88 * 10^{-2}$
20	$d * T_{d-4}^3(h - 14)$	$3.30 * 10^{-6}$	40	$L_{d-7}(h - 11)$	$-4.51 * 10^{-2}$

Rezultai dobijeni na ovaj način (upotrebom kriterijuma performansi modela WAPE) su prikazani na Ilustracija 4.13.

Ilustracija 4.13 Rezultati predviđanja modelom dobijenim GA optimizacijom, na osnovu kriterijuma WAPE. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

4.3 Zaključak u vezi sa dizajniranjem MLR STLf modela

U ovoj sekciji je predstavljeno nekoliko modela za STLf koji su realizovani upotrebom metode MLR.

Kao polazni model za uporedno testiranje je predstavljen jednostavan MLR model, u kojem predviđene vrednosti potrošnje zavise isključivo od predviđenih vrednosti temperature (u tim istim časovima kada se izvršava predviđanje). Iako ovaj model može biti prihvatljiv kao osnova za razvijanje sofisticiranijih modela [89], njegova upotreba se može ostvariti isključivo u sistemima gde je zavisnost potrošnje od trenutne temperature veoma izražena, dok u uslovima umerene klime ovakav model pruža apsolutno nezadovoljavajuće rezultate.

Pomoću analize zasnovane na korelaciji signala, konstruisana su još tri različita MLR modela za STLTF, pri čemu se u jednom od njih koriste isključivo zabeležene vrednosti o protekloj potrošnji el. energije, u drugom isključivo zabeležene vrednosti o prethodnim meteorološkim podacima (temperaturi), dok se u trećem modelu kombinuju vrednosti o protekloj temperaturi i potrošnji el. energije. Greška ovako dobijenih modela je prihvatljiva za uporednu analizu sa drugim modelima, dok se sami modeli mogu iskoristiti kao polazna osnova za dizajn sofisticiranijih metoda, u skladu sa konkretnom aplikacijom STLTF funkcionalnosti.

Kao finalni korak, kreirana su tri MLR modela za STLTF upotrebom optimizacione metode zasnovane na GA, na osnovu različitih kriterijuma optimizacije (MAPE, MAE i WAPE). Modeli dobijeni na ovaj način predstavljaju potpuno upotrebljive alate za uporednu analizu i re-evaluaciju raznovrsnih STLTF metoda, pa čak i za praktičnu primenu u industrijskim uslovima. Ovde je potrebno naglasiti da prilikom dizajniranja pomenutih modela nije korišćena selekcija podataka iz obučavajućeg skupa zasnovana na sličnosti podataka (takva analiza izlazi izvan okvira ove disertacije), te da postoji prostor da se performanse navedenih metoda još više poboljšaju. Takođe, upotrebom drugih parametara, kao što je informacija o vlažnosti vazduha, moguće je postići dodatno poboljšanje rezultata, u specifičnim uslovima. Rezultati predstavljenih modela upotrebom kriterijuma MAPE, predstavljeni su u Tabela 4.7.

Model	MAPE [%]
Jednostavni uporedni MLR model	24.64
MLR model dobijen korelativnom analizom na osnovu merenja potrošnje	14.44
MLR model dobijen korelativnom analizom na osnovu merenja temperature	7.76
MLR model dobijen korelativnom analizom na osnovu kombinovanih merenja temperature i potrošnje	5.99
MLR model dobijen optimizacijom pomoću GA na osnovu kriterijuma MAPE	3.87
MLR model dobijen optimizacijom pomoću GA na osnovu kriterijuma MAE	2.89

MLR model dobijen optimizacijom pomoću GA na osnovu kriterijuma WAPE	3.76
---	------

Tabela 4.7 Prikaz ostvarenih performansi različitih STLFL modela zasnovanih na MLR

5 STLF – veštačke neuronske mreže

Zbog svoje velike ekonomske važnosti, kao i zbog visoke složenosti elektroenergetskih sistema, tehnike za STLF su konstantno bile podvrgavane preispitivanju i re-evaluaciji, što je rezultiralo mnogim metodama za njihovo poboljšavanje [36], [90], [91]. U proteklim decenijama, veoma važnu ulogu u okviru STLF oblasti je imala primena ANN [92], [93], [94], [95]. U okviru ovog poglavlja su prikazane neke od osnovnih struktura ANN modela primenjenih u STLF oblasti, kao i neke od tehnika za selekciju ulaznih parametara ANN STLF modela.

5.1 Selekcija ulaznih parametara za ANN STLF modele

Glavni cilj upotrebljavanja ANN tehnika u okviru STLF oblasti je ustanovljavanje nelinearnih zavisnosti između ulaznih i izlaznih podataka, koje se zasnivaju na parovima (ulaz-izlaz) obučavajućih podataka. Ukoliko odabrane ulazne promenljive nisu odabrane na način da predstavljaju najrelevantnije moguće ulazne promenljive, ne može se očekivati kvalitetna performansa ANN modela, u vidu predviđanja zavisnih promenljivih (izlaza). Takođe, ukoliko se za ulaze odaberu promenljive koje međusobno imaju veliki stepen korelacije, kao i promenljive koje nemaju veliki značaj u određivanju zavisne promenljive, dolazi do nepotrebnog trošenja računarskih resursa u toku faze obučavanja ANN, što dodatno produžava vreme obuke ANN i ponekad dovodi do rezultata koji nisu prihvatljivi u pogledu tačnosti predviđanja [49]. Zbog prethodno navedenog, može se zaključiti da adekvatna selekcija ulaznih parametara prilikom dizajniranja STLF modela predstavlja veoma važan zahtev.

U STLF literaturi su predložene mnoge metodologije za obavljanje zadatka određivanja ulaznih promenljivih za ANN STLF modele. Većina ovih metoda koristi tehnike koje se zasnivaju na korelacionoj analizi, pri čemu se takođe koristi i heuristika, kao i iskustvo sistemskih operatora. Zajednička karakteristika većine korišćenih metoda je da one pokušavaju da odrede uglavnom linearne zavisnosti između skupa određenog broja promenljivih koje predstavljaju kandidate za ulazne promenljive i zavisnih, tj. izlaznih promenljivih. Zbog linearne prirode metoda za određivanje međuzavisnosti raznih promenljivih, neki autori pribegavaju korišćenju izvedenih promenljivih, pri čemu se koriste usrednjavanje, diferencijacija ili stepenovanje osnovnog oblika zabeleženih merenja [96], [97], [98]. U okviru istraživanja prezentovanog u [98], autori su u okviru postojeće STLF literature identifikovali 32 različita tipa promenljivih, koje se koriste kao ulazi STLF modela zasnovanih na ANN. U skladu sa time, može se zaključiti da se za potrebe dizajniranja ANN STLF modela ulazne promenljive mogu kombinovati na veoma mnogo načina. U radu

prezentovanom u [99], istraživači su eksperimentisali sa preko 500 različitih ulaznih promenljivih, prilikom dizajniranja STLF modela. Prikaz nekoliko različitih pristupa odabiranju ulaznih promenljivih u ANN STLF modele (FF ANN), zajedno sa rezultujućim topologijama, prikazan je u **Error! Reference source not found.**

Zaključak koji se može doneti na osnovu postojeće STLF literature je da ne postoji konzistentna i formalizovana metodologija za utvrđivanje ulaznih promenljivih prilikom dizajniranja STLF modela zasnovanog na ANN. U skladu sa time, ovaj proces je uglavnom vremenski opterećen i mahom zasnovan na procesu pokušaja i promašaja (eng. trial and error). Iako ANN imaju kapacitet za modelovanje proizvoljne nelinearne funkcije, proces odabiranja ulaznih promenljivih se zasniva na linearnoj korelativnoj analizi sa izlaznim (zavisnim) promenljivama. Ishod ovakvih empirijskih analiza je skup ulaznih promenljivih, čiji elementi zavise od slučaja do slučaja (primene STLF tehnika), koji se obično ne može upotrebljavati u različitim situacijama [43], tj. na različitim tipovima el. potrošača.

Tabela 5.1 Različite topologije STLF modela upotrebom tehnike ANN

Rad	Topologija Ulaz Skr. Sloj Izlaz	Ulazni podaci
[96]	30 10 1	1.-3. Srednja Temperatura (d-i), $i = 0, 1, 2$ 4.-6. Temperatura (h-i), $i = 0, 1, 2$ 7.-13. Dan u nedelji (binarni kod) 14.-18. Sat predviđanja (binarni kod) 19.-30. Potrošnja (h-i), $i = 1, 2, 3, 25, 26, 27, 169, 170, 171, 193, 194, 195$
[97]	28 8 1 38 10 24	1., 2. Srednja Temperatura (d-i), $i = 1, 2$ 3.-6 Temperatura (d, h-i), $i = 1, \dots, 4$ 7. Predviđanje temperature (d, h) 8-12, Sat predviđanja (binarni kod) 13.-19. Dan u nedelji (binarni kod) 20.-28. Potrošnja (d, h-i), $i = 1, \dots, 7, 15, 16$ 1-24 Potrošnja (h-i), $I = 1, \dots, 24$ 25. Temperatura (d-i) 26-31. Predviđane Temperature (h+i), $i = 0, \dots, 23$ 32.-38. Dan u nedelji (binarni kod)
[43]	63 24 24 A i B predstavljaju različite lokacije	1.-48. Potrošnja (h i), $i = 1, \dots, 48$ 49. Max. Temperatura A* (d-1) 50. Min. Temperatura A (d-1) 51. Max. Temperatura B* (d-1) 52. Min. Temperatura B (d-1) 53. Max. Predv. Temperatura A (d) 54. Min. Predv. Temperatura A (d) 55. Max. Predv. Temperatura B (d) 56. Min. Predv. Temperatura B (d)

prikupljanja meteoroloških podataka	57.-63. Dan u nedelji (binarni kod)
-------------------------------------	-------------------------------------

5.2 Struktura ANN modela za STL

Struktura ANN za STL koja je prezentovana u okviru ove disertacije je inspirisana idejom da se jednostavna ANN može koristiti za predviđanje integrisane potrošnje (ukupne el. energije) idućeg dana [100]. Takođe, u [37], jednostavni višeslojni perceptron (eng. multilayer perceptron – MLP) se koristi u okviru više različitih STL konfiguracija, pri čemu se u jednoj od njih na ulaz ove ANN dovodi informacija o ostvarenoj ukupnoj potrošnji za prethodni dan (pre predviđanja). **Istraživanje u vezi s upotrebom ovde prezentovane topologije STL modela upotrebom ANN je objavljeno u međunarodnom časopisu sa ISI liste [93].**

Predložena struktura STL modela se sastoji iz dva modula ANN, kao i preprocesirajuće jedinice (eng. preprocessing unit – PPU). Zadaci preprocesirajuće jedinice su izračunavanje integrisanih vrednosti zabeleženih merenja ostvarene potrošnje el. energije u prošlosti, kao i izračunavanje integrisane vrednosti predviđene temperature za dan predviđanja. Korišćenjem PPU se postiže smanjivanje dimenzionalnosti ulaznog prostora prilikom obučavanja ANN, što rezultira većom sposobnošću generalizacije, kao i smanjenim vremenom obučavanja.

Ulazi u predloženi STL model se mogu predstaviti kao:

- zabeležena merenja potrošnje prethodnog dana (24 vrednosti)
- predviđene vrednosti temperature za dan predviđanja (24 vrednosti)
- tip dana predviđanja (0-neradni dan, 1-radni dan)

Šematski prikaz konfiguracije predloženog STL modela je dat na Ilustracija 5.1.

5.2.1 Preprocesirajuća jedinica

Zadatak preprocesirajuće jedinice je da izračuna integral potrošnje zabeleženih merenja potrošnje el. energije (što se fizički može posmatrati kao ukupna energija potrošene struje), kao i integral predviđenih vrednosti temperature za dan predviđanja (što se fizički može posmatrati kao ukupna energija okoline), na sledeći način:

$$- \int_{t=0}^{t=24h} L_{d-1}(t) dt - \text{Integral potrošnje prethodnog dana}$$

$$- \int_{t=0}^{t=24h} T_d(t) dt - \text{Integral predviđenih vrednosti temperature}$$

Ilustracija 5.1 Topologija predloženog STLf modela zasnovanog na ANN, sa preprocesirajućom jedinicom.

5.2.2 Struktura upotrebljene ANN (MLP)

Struktura ANN koja se najčešće koristi za dizajniranje STLf modela u okviru bogate STLf literature je svakako mreža sa propagacijom signala unapred, pri čemu je tip mreže višeslojni perceptron. U okviru ove disertacije, za ostvarivanje ANN STLf modela je upotrebljena ista tehnika, pre svega zbog jednostavnosti implementacije, a potom i zbog mogućnosti izvođenja generalnih zaključaka. Model poseduje tri sloja neurona:

- ulazni
- izlazni
- skriveni

Aktivacione funkcije skrivenog sloja neurona su sigmoidalnog tipa, dok su aktivacione funkcije izlaznog sloja linearne. Ulazni sloj ne predstavlja neurone (procesirajuće jedinice) u pravom smislu te reči, već radije ulazne čvorove ANN, pošto ovi elementi ne poseduju aktivacione funkcije.

U skladu sa konceptom o minimizaciji dimenzije ulaznog prostora za ANN, radi povećane mogućnosti generalizacije, kao i radi lakšeg određivanja parametara ANN, u predloženom STLf modelu se koriste svega 3 promenljive kao ulazi MLP:

- Integral zabeležene potrošnje prethodnog dana
- Integral predviđene temperature
- Tip dana predviđanja

Broj neurona koji se koristi u skrivenom sloju je utvrđen eksperimentalno i on iznosi 7, iako treba napomenuti da ovaj parametar ANN modela, a na osnovu sprovedenih eksperimenata u okviru ove disertacije, ne utiče na preciznost predviđanja u presudnom smislu.

Što se tiče izlaznih promenljivih, one predstavljaju 24 časa za dan predviđanja. U okviru istraživanja je sprovedeno nekoliko eksperimenata sa različitim strukturama ANN, pri čemu su u jednom slučaju bile korišćene 24 nezavisne ANN, od kojih svaka služi za predviđanje tačno jedne vrednosti časovne potrošnje u toku dana predviđanja, a u drugom je bila korišćena jedinstvena struktura ANN sa 24 izlaza koji predstavljaju časovne vrednosti potrošnje. Treba napomenuti da se u slučaju jedinstvene ANN sa 24 izlaza procedura obučavanja izvršava samo jednom, pri čemu se određuju svi parametri ANN modela, dok se u slučaju 24 ANN sa jednim izlazom procedura obučavanja izvršava 24 puta, po jednom za svaku postojeću ANN.

5.3 Rezultati testiranja

5.3.1 Korišćeni podaci

5.3.1.1 Evropa

Početak istraživanja prezentovanog u okviru ove disertacije je bio vezan za procenjivanje najekonomičnijeg oblika ANN za potrebe STLF, a istraživanje je bilo inicirano potrebom implementacije takvog modela u okviru elektroenergetskog sistema u Kanadi, kao jedne od stavki saradnje DMS grupe sa vodećim svetskim elektroenergetskim kompanijama. Za inicijalno testiranje su korišćeni podaci koji su bili dostupni u okviru DMS grupe, koji su predstavljali potrošnju el. energije za određene potrošače u okviru elektroenergetskog sistema Italije. Podaci koji su bili dostupni su predstavljali zabeležene vrednosti temperature i potrošnje za 2006 godinu.

Grafički prikaz zabeleženih merenja potrošnje za 2006. godinu je prikazan na Ilustracija 5.2, dok su izmerene temperature (minimalna, srednja i maksimalna časovna temperatura) za navedeni period prikazane na Ilustracija 5.3.

5.3.1.2 SAD

Drugi deo istraživanja vezan za ANN STLF modele je sproveden nad novijim setom podataka, opisanim u sekciji 4.1.2. Upoređivanjem kvaliteta rezultata za dva različita skupa podataka, mogu se izvući određeni zaključci o upotrebljivosti predložene metode na različite tipove potrošača, što pruža uvid u mogućnost generalizacije predloženog modela.

Ilustracija 5.2 Grafički prikaz časovnih vrednosti potrošnje el. energije za 2006. gorinu, za potrošač iz okoline grada Milana.

Ilustracija 5.3 Grafički prikaz časovnih vrednost minimalne, maksimalne i srednje temperature, zabeleženih za celu 2006. godinu.

Ilustracija 5.4 Grafički prikaz korelacije između trenutnih vrednosti temperature okoline i ostvarene potrošnje el. energije.

5.3.2 Performanse modela

5.3.2.1 Evropa

Navedena konfiguracija modela je testirana sa podacima opisanim u sekciji 4.1.2. Analiza korelacije između zabeležene trenutne temperature okoline (srednje časovne temperature) i ostvarene potrošnje (u vidu zavisnosti potrošnje od temperature) je prikazana na Ilustracija 5.4, sa koje se može primetiti da ne postoji izražena međuzavisnost između ove dve veličine. Iako je početna pretpostavka prilikom dizajniranja modela netačna (uticaj temperature na potrošnju), rezultat dobijen upotrebom tehnike ANN, uz pomenutu konfiguraciju, daje rezultate koji mogu biti prihvatljivi kao polazna osnova za uporednu analizu STLF modela. Rezultati predviđanja za jedan dan unapred izvršavani u toku prve nedelje novembra prikazani su na Ilustracija 5.5. Skup podataka koji je bio korišćen za obučavanje predstavlja sve dostupne podatke u trenutku izvršavanja simulacije, što podrazumeva zabeležene podatke za 2006. godinu, počevši od januara, pa do kraja oktobra. Čak i u ograničenim uslovima, kada je smanjena dostupnost podataka za obučavanje, metode veštačke inteligencije pokazuju izvesnu fleksibilnost, jer mogu da se obučavaju da funkcionišu i u takvim situacijama.

Ilustracija 5.5 Rezultati predviđanja STLF modelom zasnovanom na ANN sa 24 izlaza. Puna linija predstavlja stvarnu, a isprekidana predviđenu potrošnju el. energije.

U slučaju konfiguracije mreže sa 24 posebne jedinice, pri čemu se svaka koristi za predviđanje tačno jednog određenog časa u toku narednog dana, rezultati su prikazani na Ilustracija 5.6. Kao što se može primetiti, performanse ovako dobijenog modela su lošije u poređenju sa inicijalno konstruisanim modelom koji koristi jedinstvenu konfiguraciju sa 24 izlaza, zato što obučavanje 24 operativne jedinice nije povezano, te ne postoji mogućnost korigovanja vrednosti predviđanja za pojedinačne časove u toku dana u odnosu na susedne vrednosti.

Ilustracija 5.6 Rezultati predviđanja STLF modelom zasnovanom na 24 ANN sa po 1 izlazom. Puna linija predstavlja stvarnu, a isprekidana predviđenu potrošnju el. energije.

5.3.2.2 SAD

Predstavljena konfiguracija modela je takođe testirana sa podacima opisanim u sekciji 4.1.2, pri čemu su dobijeni rezultati prikazani na Ilustracija 5.7. S obzirom na to da ovi podaci predstavljaju sistemsku potrošnju za grad Burbank postoji veća međuzavisnost između meteoroloških promenljivih i posmatrane veličine potrošnje el. energije, što se može i grafički demonstrirati, upoređivanjem Ilustracija 5.1 i Ilustracija 4.6.

Ilustracija 5.7 Rezultati predviđanja ANN modelom, sa preprocesirajućom jedinicom. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

6 STLFL – hibridne metode

Hibridne metode u toku poslednjih decenija predstavljaju jedan od bitnih pravaca razvoja u okviru STLFL oblasti [101], [93], [102], [103], [104], [105], [94], a ciljevi ovakvih pristupa mogu biti dizajniranje STLFL modela sa većom mogućnošću generalizacije, kao i primena određenih tehnika za postizanje boljih performansi STLFL modela u određenim specifičnim uslovima.

Model koji je predstavljen u sekciji 5.2 je dizajniran intuitivno, na osnovu pretpostavki o uticaju dostupnih zabeleženih promenljivih na proces potrošnje el. energije koji je potrebno predvideti. Iako ne postoji izražena korelacija između zabeleženih vrednosti temperature okoline i vrednosti potrošnje u određenim časovima u toku dana, konstruisani model koristi informaciju o ukupnoj energiji okoline, na taj način što izračunava integral temperature u danu koji prethodi predviđanju, kao i integral predviđene temperature za dan predviđanja, i na taj način ostvaruje minimizaciju ulaznog prostora STLFL modela konstruisanog pomoću ANN. Ovakav model može biti koristan kao polazna osnova za uporedno testiranje, ali i kao osnova za industrijski algoritam u uslovima smanjene dostupnosti podataka (imajući u vidu činjenicu da se sa povećanjem dimenzionalnosti ulaznog prostora povećava i zahtev za brojem obučavajućih parova ulaza i izlaza).

Ipak, za potrebe funkcionalnosti u realnim aplikacijama u okviru elektroenergetskih kompanija, za odgovarajuću STLFL funkcionalnost potrebno je konstruisati sofisticiranije modele. U literaturi vezanoj za STLFL postoji određeni trend kada je u pitanju primena hibridnih metoda, pri čemu se pod ovim terminom može naići na najrazličitije kombinacije prethodno ustanovljenih i oprobanih metoda (reference). U ovoj disertaciji, predloženo je jedno hibridno rešenje zasnovano na kombinaciji višestruke linearne regresije, veštačkih neuronskih mreža, kao i evolutivnih (genetskih) algoritama.

6.1 Dizajn ANN STLFL modela upotrebom genetskog algoritma

U okviru poglavlja 5.1 je navedeno da uspešnost nekog određenog STLFL modela u velikoj meri zavisi od odgovarajućeg izbora ulaznih podataka, tj. onih koji imaju najviše uticaja na veličinu koju je potrebno predvideti. U ovom poglavlju je predstavljen algoritam odabiranja ulaznih parametara za potrebe dizajniranja ANN STLFL metode, tj. za njeno prilagođavanje određenom elektroenergetskom sistemu, koji podrazumeva vremensku seriju potrošnje el. energije sa specifičnim karakteristikama.

6.1.1 Određivanje topologije ANN

Za potrebe određivanja optimalnih parametara ANN, testirane su tri različite topologije ANN STLFL modela.

U prvom slučaju se radi o ANN sa 24 izlaza, od kojih svaki predstavlja predviđenu potrošnju za odgovarajući sat u toku dana predviđanja. Ova konfiguracija je slična kao i ona predstavljena u sekciji 5.2, s tim što se broj ulaznih parametara, kao i sami parametri naknadno određuju.

U drugom slučaju se kreira jedinstvena ANN sa samo jednim izlazom, koja se potom sekvencijalno koristi za predviđanje svake pojedinačne časovne vrednosti potrošnje, za dan predviđanja. Ovde treba naglasiti da prethodno predviđene vrednosti nisu korišćene kao ulazi u ANN sa navedenom topologijom, iako ovakvi pristupi postoje u literaturi (ref). Ovakvo ograničenje je učinjeno zbog dostupnosti podataka u trenutku generisanja predviđanja, te mogućnosti uvođenja dodatnih poremećaja ukoliko iz nekog razloga dođe do povećane greške u jednom koraku (jednoj časovnoj vrednosti). Takođe, poređenje između ANN i MLR metoda je ravnopravnije ukoliko se koriste iste konfiguracije ulaza i izlaza, a kao takvo pruža bolji uvid u karakteristike pojedinih metoda. .

Treća testirana topologija STLF modela koristi 24 različite ANN jedinice, po jednu za svaki čas predviđanja potrošnje, u toku dana predviđanja. U ovoj topologiji takođe nisu korišćene predviđene vrednosti kao ulazi u preostale ANN jedinice, iz razloga navedenih u prethodnom pasusu.

6.1.2 Određivanje ulaznih parametara ANN STLF modela pomoću GA

Za potrebe određivanja ulaznih parametara STLF ANN modela je korišćen genetski algoritam, na sličan način kao što je opisano u sekciji 4.2.4. U prvoj fazi se konstruiše prošireni skup podataka koji predstavljaju kandidate za ulaze u STLF metodu, pri čemu se osnovni oblici zabeleženih merenja temperature i potrošnje modifikuju na razne načine, pre svega nelinearnim transformacijama, a potom i simulacijom međusobnih uticaja pojedinih parametara. Za detaljnije objašnjenje ove procedure pogledati sekciju 4.2.4

Procedura obučavanja ANN koja se zasniva na propagiranju greške unazad (eng. Error Back Propagation – EBP) uvek kreće od slučajne polazne tačke u prostoru funkcije greške koju je potrebno minimizovati (zbog nemogućnosti egzaktnog pronalaženja globalnog minimuma funkcije greške), s obzirom na to da se inicijalne vrednosti težina ANN zadaju na slučajan način. U skladu sa ovom konstatacijom, može se zaključiti da će svaka zasebna procedura obučavanja ANN dati suboptimalno rešenje, pri čemu su takva rešenja međusobno različita, pri čemu se razlika pojedinih modela (tj. njihovih odziva na iste ulazne podatke) kreće u unapred zadatom stepenu tolerancije. Zbog ove činjenice se ne može pristupiti direktnoj minimizaciji greške upotrebom kriterijuma performansi ANN modela, pošto bi pokretanje procedure obučavanja ANN za istu konfiguraciju ulaznih parametara davalo drugačije rezultate u različitim iteracijama GA (iako bliske po performansama). Pored toga, svaka

pojedinačna procedura obučavanja ANN može biti vremenski zahtevna, što u opštem slučaju dovodi do praktične neupotrebljivosti procedure optimizacije upotrebom GA.

Da bi optimizaciju pomoću GA bilo moguće izvršiti, neophodno je koristiti determinističku metodu prilikom određivanja performanse određene konfiguracije ulaznih parametara, kako bi se obezbedila konvergencija čitavog postupka. Jedna od najbržih i najšire prihvaćenih metoda, koja će za svaku konfiguraciju ulaznih parametara uvek dati identično rešenje, jeste upravo metoda najmanjih kvadrata koja se primenjuje za potrebe određivanja parametara MLR modela za STLF. Primena ove metode za potrebe dizajniranja STLF modela je detaljno opisana u sekciji 3.1. Kada se izvrši procedura optimizacije odabira ulaznih parametara pomoću GA, pristupa se fazi dizajniranja ANN. Ulazni parametri MLR metode koji su dobijeni GA optimizacijom postaju ulazi konkretnog ANN STLF modela, a zatim se pristupa fazi obučavanja. Logika koja stoji iza ovakvog postupanja (dovođenja ulaza linearnog modela MLR na nelinearan model ANN) opravdava se činjenicom da ANN mogu da modeluju bilo koju nelinearnu zavisnost do željenog stepena tačnosti [88], te ukoliko je modelovanje već relativno uspešno obavljeno pomoću linearnog modela postoji razlog za očekivanje boljih performansi nelinearnog modela. Obučena ANN sa navedenom konfiguracijom ulaznih parametara predstavlja finalno rešenje koje se može podvrgnuti procesu eksploatacije. Zbog raznorodnosti upotrebljenih metoda (GA, MLR, ANN), predloženo rešenje se može smatrati hibridnim, pri čemu ovakva, ili slična procedura za određivanje konfiguracije STLF modela, na osnovu autoru dostupnih izvora, nije prethodno predstavljena u okviru STLF literature.

6.1.2.1 Određivanje ulaznih parametara jedinstvenog ANN STLF modela sa 1 izlazom

Topologija STLF ANN modela sa 1 izlazom koji predstavlja časovnu potrošnju je prikazana na Ilustracija 6.1. Ovaj model je konceptualno najbliži MLR modelu prikazanom u sekciji 4.2.4, čije su ulazne promenljive određene putem GA. Pretpostavka je da nelinearne aktivacione funkcije skrivenih neurona ANN mogu podjednako dobro ili bolje da modeliraju nelinearne zavisnosti, ukoliko su one već modelirane pomoću linearnog modela (MLR). U testovima sprovedenim u okviru ove disertacije, navedena ANN topologija je pokazala skoro identične rezultate kao i MLR model formiran pomoću istih ulaznih promenljivih, ustanovljenim pomoću GA.

Ilustracija 6.1 Topologija jedinstvenog ANN modela sa 1 izlazom

Rezultati predviđanja pomoću ovog modela su predstavljani na IL. Radi omogućavanja direktnog poređenja različitih tehnika za implementaciju STLF metoda, testovi su izvršeni nad istim obučavajućim, kao i validacionim skupom podataka.

Ilustracija 6.2 Rezultati predviđanja STLF modelom sa jedinstvenom ANN sa jednim izlazom. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

6.1.2.2 Određivanje ulaznih parametara jedinstvenog ANN STL modela sa 24 izlaza

Ilustracija 6.3 Topologija jedinstvenog ANN modela sa 24 izlaza

6.1.2.3 Određivanje ulaznih parametara 24 različitih ANN STL modela sa po 1 izlazom

Topologija modela koji koristi 24 paralelne ANN jedinice je prikazana na Ilustracija 6.4. Ideja ovakvog pristupa je da se maksimizuje uticaj informacije o tome u kom se času u toku dana predviđa potrošnja, s obzirom da je ovo intuitivno jedan od najuticajnijih parametara na proces potrošnje el. energije. U fazi određivanja ulaznih promenljivih pomoću GA, iz

proširenog skupa kandidata se selektuju samo one kombinacije koje utiču na određeni čas u toku dana, za čije se predviđanje kreira model.

Rezultati predviđanja pomoću STLF modela sa 24 zasebne ANN jedinice su prikazani na Ilustracija 6.5. Na osnovu oblika predviđene krive potrošnje, kao i na osnovu kriterijuma preciznosti predviđanja $MAPE = 3.81\%$, može se zaključiti da se pomoću predstavljene topologije STLF ANN modela dobijaju precizna predviđanja, u pogledu prosečne vrednosti greške. Ipak, odstupanja greške u pojedinim časovima predviđanja koja se javljaju kao posledica 24 međusobno nezavisne procedure obučavanja, veća su nego kod prethodno predstavljenih ANN topologija, predstavljenih u ovoj sekciji.

Ilustracija 6.4 Topologija STLF modela sa 24 zasebne ANN jedinice

Ilustracija 6.5 Rezultati predviđanja STL modelom sa 24 zasebne ANN. Puna linija predstavlja stvarnu potrošnju, dok isprekidana predstavlja generisana predviđanja.

7 Zaključak

U okviru ove disertacije predstavljena je formalna studija o tehnikama za kratkoročno predviđanje potrošnje električne energije (STLF). Dve tehnike su iskorišćene za formiranje STLF modela, a to su višestruka linearna regresija (MLR) i veštačka inteligencija, tj. neuronske mreže (ANN). Za potrebe određivanja ulaznih promenljivih različitih STLF modela iskorišćen je genetski algoritam (GA). Umesto predstavljanja jednog konkretnog modela, kao krajnjeg rezultata ove disertacije, ona se bavi sistematskom analizom modela predloženih u STLF literaturi, dok kao svoj doprinos predlaže novu metodologiju za određivanje ulaznih promenljivih STLF modela, koja se može proširiti i na bilo koji proces vremenskih serija, koji je zavistan od više različitih faktora.

Predložena metodologija koristi GA za optimizaciju izbora ulaznih parametara u STLF model, koristeći pri tome prošireni skup podataka iz koga bira kandidate za formiranje finalnog STLF modela. Prošireni skup pored osnovnih zabeleženih podataka o protekloj potrošnji električne energije, kao i meteoroloških promenljivih, takođe sadrži njihove nelinearne transformacije, kalendarske promenljive, kao i promenljive koje modeliraju efekat interakcije između različitih ulaznih parametara. Za određivanje kvaliteta izabranih ulaza se formira model pomoću MLR tehnike, s obzirom da se njeni parametri mogu deterministički odrediti pomoću metode najmanjih kvadrata, te se na taj način obezbeđuje konvergencija predložene metodologije, tj. genetskog algoritma. U tradicionalnim MLR pristupima u okviru STLF literature se ne koriste promenljive koje modeliraju međuzavisnosti ulaznih parametara, dok se u većini modela formiranih od strane GA metodologije one pojavljuju kao sastavni delovi, što pokazuje opravdanost njihovog uvrščavanja u skup kandidata za kreiranje STLF modela. U okviru autorima dostupne STLF literature, iako se može naići na određene analize optimalnih ulaznih parametara za STLF model, nije predstavljena upotreba GA u tu svrhu, kao ni bilo koja slična metodologija izbora najboljih kandidata iz proširenog skupa ulaznih promenljivih.

U pogledu kvaliteta STLF predviđanja predložena metodologija se pokazala opravdanom, bilo da se radi o modelima formiranim pomoću višestruke linearne regresiji ili o modelima formiranim korišćenjem tehnike veštačkih neuronskih mreža. U disertaciji je prvo prikazano korišćenje veoma jednostavnog MLR modela, kao osnove za uporednu analizu, koji u uslovima primene nad skupom podataka korišćenim u ovoj disertaciji nije pokazao ni približno zadovoljavajuće rezultate. Potom su konstruisana tri modela upotrebom analize korelacije između signala potrošnje el. energije koji je potrebno predvideti i prethodno zabeleženih vrednosti temperature i potrošnje el. energije. Modeli formirani na ovakav način predstavljaju znatno poboljšanje u odnosu na inicijalni jednostavni model, pri čemu je njihova

upotreba u komparativnoj analizi potpuno opravdana, dok upotreba u komercijalne svrhe zahteva sofisticiranije modele, sa više finih podešavanja. Kao finalni deo prve faze disertacije, konstruisani su MLR modeli upotrebom predloženog optimizacionog algoritma zasnovanog na GA, upotrebom različitih kriterijuma greške (MAPE, MAE i WAPE). Korišćenjem ove procedure dobijaju se modeli čije performanse prevazilaze performanse modela dobijenih korelativnom analizom. Bitno je konstatovati da se najbolji rezultati, kako u pogledu preciznosti predviđanja, tako i u pogledu oblika predviđene krive potrošnje, dobijaju ukoliko se za optimizaciju pomoću GA iskoristi kriterijum WAPE, što je i očekivano ponašanje, s obzirom da su situacije kada je sistem na gornjoj granici opterećenja od mnogo većeg interesa za neometano svakodnevno funkcionisanje elektroenergetskog sistema.

U drugoj fazi istraživanja, ispitana je primena predložene procedure optimizacije za dizajniranje STLFL modela upotrebom ANN tehnike. Ulazni parametri su odabirani na isti način kao i u slučaju kreiranja MLR modela, dok je određivanje samih parametara STLFL modela rađeno za 3 različite ANN topologije. Svi dobijeni modeli pomoću ANN produkuju prihvatljive rezultate u pogledu komparativne analize i re-evaluacije drugih STLFL modela. Topologija sa jedinstvenom ANN sa 24 izlaza generiše predviđanja sa oblikom krive potrošnje koji najrealnije prati stvarnu potrošnju. Topologija sa 24 zasebne ANN sa po jednim izlazom generiše najmanju ukupnu grešku predviđanja, iako korišćenjem ovakve konfiguracije nastaju najveće oscilacije između pojedinih časova. Razlog ovakvom ponašanju je činjenica da se jednostavnim metodama obučavanja ANN uvek kreće sa druge polazne tačke u funkciji greške koji treba minimizovati, pa je rezultat svake zasebne procedure obučavanja suboptimalan.

Predložena procedura optimizacije predikcionog modela pomoću GA može sa sobom nositi skrivene opasnosti koje se pre svega ogledaju u preteranom optimizovanju modela, tj. izbora ulaznih parametara koji bi dali odlično ponašanje modela isključivo na obučavajućem skupu podataka, ali ne i van njega. Ovde treba napraviti razliku između situacije u kojoj se dešava preterano obučavanje nekog već postojećeg modela, bilo da se radi o MLR, ANN, SVM, itd., u kojoj se podešavaju parametri tog modela i situacije kada se optimizacija dešava za jedan korak ranije, prilikom samog dizajniranja modela. Dodatna istraživanja na ovu temu bi trebalo da ustanove kolika je moć generalizacije modela konstruisanih pomoću predložene optimizacione procedure, kao i mogućnost njene upotrebe na različitim tipovima podataka.

Na kraju treba dodati da postoji mogućnost daljeg usavršavanja predložene metode, pre svega u kombinaciji sa različitim tipovima selekcije obučavajućeg skupa podataka, na osnovu nekog od zadatih kriterijuma (sličnost sa podacima u fazi eksploatacije). Moguće je ispitivati i performanse dobijenih modela u zavisnosti od podešavanja parametara GA, kao i uvođenje

lokalnih metoda pretrage u kombinaciji sa GA. Korišćenje drugačijih kriterijuma optimalnosti prilikom kreiranja samog MLR modela u svakoj iteraciji GA, kao što su linearno programiranje, L1 norma, kao i težinska L2 norma, takođe predstavljaju moguće pravce daljeg razvoja. Predloženu metodu je moguće primeniti na razne klase podataka kada su u pitanju vremenske serije i njihovo predviđanje, kao što su npr. ekonomske, ali i razne druge, uz podrazumevanje određenih adaptacija u skladu sa vrstom podataka u okviru posmatranih procesa.

8 Literatura

- [1] J. S. Armstrong, "Strategic Planning And Forecasting Fundamentals," *General Economics and Teaching 0502066*, 2005.
- [2] Mohammad Shahidehpour, Zuyi Li, and Hatim Yamin, *Market operations in electric power systems*. New York: John Wiley and sons Inc., 2002.
- [3] H.L.Willis, *Power Distribution Planning Reference Book, Second Edition, Revised and Expanded*. New York: Marcel Dekker, 2002.
- [4] H.L.Willis, *Spatial Electric Load Forecasting*. New York: Macel Decker, 2002.
- [5] Tao Hong, "Short Term Electric Load Forecasting," Graduate Faculty of North Carolina State University, Raleigh, North Carolina, PhD Thesis 2010.
- [6] AD Papalexopoulos and TC Hesterberg, "A regression based approach to short term system load forecasting," in *Proceedings of PICA conference*, Seattle, Washington, 1989.
- [7] M T Hagan and S M Behr, "The Time Series Approach to Short Term Load Forecasting," *IEEE Transactions on Power Systems*, vol. 2, pp. 785-791, 1987.
- [8] HS Hippert, CE Pedreira, and RC Souza, "Neural networks for short-term load forecasting: A review and evaluation," *IEEE Trans Power Syst*, vol. 16, no. 1, pp. 44-45, 2001.
- [9] D K Ranaweera, N F Hubele, and G K Karady, "Fuzzy logic for short term load forecasting," *International Journal of Electrical Power & Energy Systems*, vol. 18, pp. 215-222, 1996.
- [10] B -J Chen, M -W Chang, and C -J Lin, "Load forecasting using support vector Machines: a study on EUNITE competition 2001," *IEEE Transactions on Power Systems*, vol. 19, pp. 1821-1830, 2004.
- [11] A Khotanzad, M H Davis, A Abaye, and D J Maratukulam, "An artificial neural network hourly temperature forecaster with applications in load forecasting," *IEEE Transactions on Power Systems*, vol. 1, pp. 870-876, 1996.
- [12] A Khotanazad, R Afkhami-Rohani, and D Maratukulam, "ANNSTLF-Artificial Neural Network Short-Term Load Forecaster generation three," *IEEE Transactions on Power Systems*, vol. 13, pp. 1413-1422, 1998.
- [13] A Khotanazad, Z Enwang, and H Elragal, "A neuro-fuzzy approach to short-term load forecasting in a price-sensitive environment," *IEEE Transactions on*, vol. 17, pp. 1273-1282, 2002.

- [14] H S Hippert and C E Pedreira, "Estimating temperature profiles for short-term load forecasting: neural networks compared to linear models," *IEEE Proceedings - Generation, Transmission and Distribution*, vol. 151, pp. 543-547, 2004.
- [15] K Methaprayoon, W -J Lee, S Rasmiddatta, R J Liao, and R J Ross, "Multistage Artificial Neural Network Short-Term Load Forecasting Engine With Front-End Weather Forecast," *IEEE Transactions on Industry Applications*, vol. 43, pp. 1410-1416, 2007.
- [16] G E Huck, A A Mahmoud, R B Comerford, J Adams, and E Dawson, "Load Forecast Bibliography Phase I," *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-99, pp. 53-58, 1980.
- [17] M S Sachdev, R Billinton, and C A Peterson, "Representative bibliography on load forecasting," *IEEE Transactions on Power Apparatus and Systems*, vol. 96, pp. 697-700, 1977.
- [18] A A Mahmoud, T H Ortmeyer, and R E Reardon, "Load Forecasting Bibliography Phase II," *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-100, pp. 3217-3220, 1981.
- [19] M A Abu-El-Magd and N K Sinha, "Short-Term Load Demand Modeling and Forecasting: A Review," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 12, pp. 370-382, 1982.
- [20] G Gross and F D Galiana, "Short-term load forecasting," *Proceedings of the IEEE*, vol. 75, pp. 1558-1573, 1987.
- [21] K Metaxiotis, A Kagiannas, D Askounis, and J Psarras, "Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher," *Energy Conversion and Management*, vol. 44, pp. 1525-1534, 2003.
- [22] K Liu et al., "Comparison of very short-term load forecasting techniques," *IEEE Transactions on Power Systems*, vol. 11, pp. 877-882, 1996.
- [23] I Moghram and S Rahman, "Analysis and evaluation of five short-term load forecasting techniques," *IEEE Transactions on Power Systems*, vol. 4, pp. 1484-1491, 1989.
- [24] J W Taylor and P E McSharry, "Short-Term Load Forecasting Methods: An Evaluation Based on European Data," *IEEE Transactions on Power Systems*, vol. 22, pp. 2213-2219, 2007.
- [25] T Haida and S Muto, "Regression based peak load forecasting using a transformation technique," *IEEE Transactions on Power Systems*, vol. 9, pp. 1788-1794, 1994.

- [26] O Hyde and P F Hodnett, "An adaptable automated procedure for short-term electricity load forecasting," *IEEE Transactions on Power Systems*, vol. 12, pp. 84-94, 1997.
- [27] Slobodan Ružić, A Vučković, and N Nikolić, "Weather sensitive method for short term load forecasting in Electric Power Utility of Serbia," *IEEE Transactions on Power Systems*, vol. 18, pp. 1581-1586, 2003.
- [28] W Charytoniuk, M S Chen, and P Van Olinda, "Nonparametric regression based short-term load forecasting," *IEEE Transactions on Power Systems*, vol. 13, pp. 725-730, 1998.
- [29] W Charytoniuk, M S Chen, P Kotas, and P Van Olinda, "Demand forecasting in power distribution systems using nonparametric probability density estimation," *IEEE Transactions on Power Systems*, vol. 14, pp. 1200-1206, 1999.
- [30] B Korgh, E S de Llinas, and D Lesser, "Design and Implementation of An on-Line Load Forecasting Algorithm," *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-101, pp. 3284-3289, 1982.
- [31] Nima Amjady, "Short-term hourly load forecasting using time-series modeling with peak load estimation capability," *IEEE Transactions on Power Systems*, vol. 16, pp. 798-805, 2001.
- [32] S R Huang, "Short-term load forecasting using threshold autoregressive models," *IEE Proceedings-Generation, Transmission and Distribution*, vol. 144, pp. 477-481, 1997.
- [33] S R Huang and K R Shih, "Short-term load forecasting via ARMA model identification including non-Gaussian process considerations," *IEEE Transactions on Power Systems*, vol. 18, pp. 673-679, 2003.
- [34] J F Chen, W M Wang, and C M Huang, "Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting," *Electric Power Systems Research*, vol. 34, pp. 187-196, 1995.
- [35] M Espinoza, C Joye, R Belmans, and B DeMoor, "Short-Term Load Forecasting, Profile Identification, and Customer Segmentation: A Methodology Based on Periodic Time Series," *IEEE Transactions on Power Systems*, vol. 20, pp. 1622-1630, 2005.
- [36] C M Huang, C J Huang, and M L Wang, "A particle swarm optimization to identifying the ARMAX model for short-term load forecasting," *IEEE Transactions on Power Systems*, vol. 20, pp. 1126-1133, 2005.
- [37] D C Park, M A El-Sharkawi, R J Marks, L E Atlas, and M J Damborg, "Electric load forecasting using an artificial neural network," *IEEE Transactions on Power Systems*,

vol. 6, pp. 442-449, 1991.

- [38] A D Papalexopoulos, H Shangyou, and P Tie-Mao, "An implementation of a neural network based load forecasting model for the EMS," *IEEE Transactions on Power Systems*, vol. 9, pp. 1956-1962, 1994.
- [39] D K Ranaweera, N F Hubele, and A D Papalexopoulos, "Application of radial basis function neural network model for short-term load forecasting," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 142, pp. 45-50, 1995.
- [40] A Khotanazad, H Rey-Chue, A Abaye, and D Maratukulam, "An adaptive modular artificial neural network hourly load forecaster and its implementation at electric utilities," *IEEE Transactions on Power Systems*, vol. 10, pp. 1716-1722, 1995.
- [41] B F Hobbs et al., "Analysis of the value for unit commitment of improved load forecasts," *IEEE Transactions on Power Systems*, vol. 14, pp. 1342-1348, 1999.
- [42] M H Choueiki, C A Mount-Campbell, and S C Ahalt, "Implementing a weighted least squares procedure in training a neural network to solve the short-term load forecasting problem," *IEEE Transactions on Power Systems*, vol. 12, pp. 1689-1694, 1997.
- [43] A G Bakirtzis, V Petridis, S J Kiartzis, M C Alexiadis, and A H Maissis, "A neural network short term load forecasting model for the Greek power system," *IEEE Transactions on Power Systems*, vol. 11, pp. 858-863, 1996.
- [44] S J Kiartzis, C E Zoumas, J B Theocharis, A G Bakirtzis, and V Petridis, "Short-term load forecasting in an autonomous power system using artificial neural networks," *IEEE Transactions on Power Systems*, vol. 12, pp. 1591-1596, 1997.
- [45] K L Ho, Y Y Hsu, and C C Yang, "Short term load forecasting using a multilayer neural network with an adaptive learning algorithm," *IEEE Transactions on Power Systems*, vol. 7, pp. 141-149, 1992.
- [46] Y Y Hsu and C C Yang, "Design of artificial neural networks for short-term load forecasting. Part 2: Multilayer feedforward networks for peak load and valley load forecasting," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 138, pp. 414-418, 1991.
- [47] Y Y Hsu and C C Yang, "Design of artificial neural networks for short-term load forecasting. Part 1: Self-organising feature maps for day type identification," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 138, pp. 407-413, 1991.
- [48] P K Dash, A C Liew, and G Ramakrishna, "Power-demand forecasting using a neural network with an adaptive learning algorithm," *IEE Proceedings - Generation,*

Transmission and Distribution, vol. 142, pp. 560-568, 1995.

- [49] I Drezga and S Rahman, "Input variable selection for ANN-based short-term load forecasting," *IEEE Transactions on Power Systems*, vol. 13, pp. 1238-1244, 1998.
- [50] I Drezga and S Rahman, "Short-term load forecasting with local ANN predictors," *IEEE Transactions on Power Systems*, vol. 14, pp. 844-850, 1999.
- [51] T M Peng, N F Hubele, and G G Karady, "Advancement in the application of neural networks for short-term load forecasting," *IEEE Transactions on Power Systems*, vol. 7, pp. 250-257, 1992.
- [52] S Fan, L Chen, and W J Lee, "Short-Term Load Forecasting Using Comprehensive Combination Based on Multimeteorological Information," *IEEE Transactions on Industry Applications*, vol. 15, pp. 1460-1466, 2009.
- [53] T Saksornchai, W J Lee, K Methaprayoon, J R Liao, and R J Ross, "Improve the unit commitment scheduling by using the neural-network-based short-term load forecasting," *IEEE Transactions on Industry Applications*, vol. 41, pp. 169-179, 2005.
- [54] B Heshmaty and A Kandel, "Fuzzy Linear Regression and Its Applications to Forecasting in Uncertain Environment," *Fuzzy Sets and Systems*, vol. 15, pp. 159-191, 1985.
- [55] S Rahman and R Bhatnagar, "An expert system based algorithm for short term load forecast," *IEEE Transactions on Power Systems*, vol. 3, pp. 392-399, 1988.
- [56] S Rahman, "Formulation and analysis of a rule-based short-term load forecasting algorithm," *Proceedings of the IEEE*, vol. 78, pp. 805-816, 1990.
- [57] S Rahman and O Hazim, "A generalized knowledge-based short-term load forecasting technique," *IEEE Transactions on Power Systems*, vol. 8, pp. 508-514, 1993.
- [58] K L Ho et al., "Short term load forecasting of Taiwan power system using a knowledge-based expert system," *IEEE Transactions on Power Systems*, vol. 5, pp. 1214-1221, 1990.
- [59] S Chenthur Pandian, K Duraiswamy, C Christofer Asir Rajan, and N Kanagaraj, "Fuzzy approach for short term load forecasting," *Electric Power Systems Research*, vol. 76, pp. 541-548, 2006.
- [60] P A Mastorocostas, J B Theocharis, and A G Bakirtzis, "Fuzzy modeling for short term load forecasting using the orthogonal least squares method," *IEEE Transactions on Power Systems*, vol. 14, pp. 29-36, 1999.
- [61] H Mori and H Kobayashi, "Optimal fuzzy inference for short-term load forecasting,"

- IEEE Transactions on Power Systems*, vol. 11, pp. 390-396, 1996.
- [62] H C Wu and C Lu, "Automatic fuzzy model identification for short-term load forecast," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 146, pp. 477-482, 1999.
- [63] A M Al-Kandari, S A Soliman, and M E El-Hawary, "Fuzzy short-term electric load forecasting," *International Journal of Electrical Power & Energy Systems*, vol. 26, pp. 111-122, 2004.
- [64] K B Song, Y S Baek, D H Hong, and G Jang, "Short-term load forecasting for the holidays using fuzzy linear regression method," *IEEE Transactions on Power Systems*, vol. 20, pp. 96-101, 2005.
- [65] K B Song, S K Ha, J W Park, D J Kweon, and K H Kim, "Hybrid load forecasting method with analysis of temperature sensitivities," *IEEE Transactions on Power Systems*, vol. 21, pp. 869-876, 2006.
- [66] A G Bakirtzis, J B Theoharis, S J Kiartzis, and K J Satsios, "Short term load forecasting using fuzzy neural networks," *IEEE Transactions on Power Systems*, vol. 10, pp. 1518-1524, 1995.
- [67] S E Papadakis, J B Theoharis, S J Kiartzis, and A G Bakirtzis, "A novel approach to short-term load forecasting using fuzzy neural networks," *IEEE Transactions on Power Systems*, vol. 13, pp. 480-492, 1998.
- [68] P K Dash, A C Liew, and S Rahman, "Fuzzy neural network and fuzzy expert system for load forecasting," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 143, pp. 106-114, 1996.
- [69] D Srinivansan, S S Tan, C S Chang, and E K Chan, "Practical implementation of a hybrid fuzzy neural network for one-day-ahead load forecasting," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 145, pp. 687-692, 1998.
- [70] N Sapankevych and R Sankar, "Time Series Prediction Using Support Vector Machines: A Survey," *IEEE Computational Intelligence Magazine*, vol. 4, pp. 24-38, 2009.
- [71] S Fan, K Methaprayoon, and W J Lee, "Multiregion Load Forecasting for System With Large Geographical Area," *IEEE Transactions on Industry Applications*, vol. 45, pp. 1452-1459, 2009.
- [72] P K Dash, H P Satpathy, A C Liew, and S Rahman, "A real-time short-term load forecasting system using functional link network," *IEEE Transactions on Power*

Systems, vol. 12, pp. 675-680, 1997.

- [73] C M Huang and H T Yang, "Evolving wavelet-based networks for short-term load forecasting," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 148, pp. 222-228, 2001.
- [74] S H Ling, F H F Leung, H K Lam, and P K S Tam, "Short-term electric load forecasting based on a neural fuzzy network," *IEEE Transactions on Industrial Electronics*, vol. 50, pp. 1305-1316, 2003.
- [75] H T Yang, C M Huang, and C L Huang, "Identification of ARMAX model for short term load forecasting: an evolutionary programming approach," *IEEE Transactions on Power Systems*, vol. 11, pp. 403-408, 1996.
- [76] H T Yang and C M Huang, "A new short-term load forecasting approach using self-organizing fuzzy ARMAX models," *IEEE Transactions on Power Systems*, vol. 13, pp. 217-225, 1998.
- [77] R H Liang and C C Cheng, "Combined regression-fuzzy approach for short-term load forecasting," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 147, pp. 261-266, 2000.
- [78] K H Kim, J K Park, K J Hwang, and S H Kim, "Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems," *IEEE Transactions on Power Systems*, vol. 10, pp. 1534-1539, 1995.
- [79] K H Kim, H S Youn, and Y C Kang, "Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method," *IEEE Transactions on Power Systems*, vol. 15, pp. 559-565, 2000.
- [80] Y Zhang et al., "RBF Neural Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment," *IEEE Transactions on Power Systems*, vol. 23, pp. 853-858, 2008.
- [81] M Daneshdoost, M Lotfalian, G Bumroongit, and J P Ngoy, "Neural network with fuzzy set-based classification for short-term load forecasting," *IEEE Transactions on Power Systems*, vol. 13, pp. 1386-1391, 1998.
- [82] S Fan and L Chen, "Short-term load forecasting based on an adaptive hybrid method," *IEEE Transactions on Power Systems*, vol. 21, pp. 392-401, 2006.
- [83] N F Hubele and C S Cheng, "Identification of seasonal short-term load forecasting models using statistical decision functions," *IEEE Transactions on Power Systems*, vol. 5, pp. 40-45, 1990.

- [84] H Mori and A Yuihara, "Deterministic annealing clustering for ANN-based short-term load forecasting," *IEEE Transactions on Power Systems*, vol. 16, pp. 545-551, 2001.
- [85] A Khotanazad et al., "ANNSTLF-a neural-network-based electric load forecasting system," *IEEE Transactions on Neural Networks*, vol. 8, pp. 835-846, 1997.
- [86] Y Y Hsu and K L Ho, "Fuzzy expert systems: an application to short-term load forecasting," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 139, pp. 471-477, 1992.
- [87] J. Neter, W. Wasserman, and M. H. Kutner, *Applied linear statistical models*. Chicago: Irwin, 1996, vol. 4.
- [88] Vojislav Kecman, *Learning and Soft Computing; Support Vector Machines, Neural Networks and Fuzzy Logic Models*. Cambridge, Massachusetts: MIT Press, 2001.
- [89] Tao Hong, Pu Wang, and H. Lee Willis, "A Naïve Multiple Linear Regression Benchmark for Short Term Load Forecasting," in *Power and Energy Society General Meeting, 2011 IEEE*, Raleigh, NC, USA, 24-29 July 2011, pp. 1-6.
- [90] Marin Matijaš, Johan A.K. Suykens, and Slavko Krajcar, "Load forecasting using a multivariate meta-learning system," *Expert Systems with Applications*, vol. 40, no. 1, pp. 4427-4437, September 2013.
- [91] Juan J. Cárdenas, Luis Romeral, Antonio Garcia, and Fabio Andrade, "Load forecasting framework of electricity consumptions for an Intelligent Energy Management System in the user-side," *Expert Systems with Applications*, vol. 39, no. 5, pp. 5557-5565, April 2012.
- [92] M. López, S. Valero, C. Senabre, J. Aparicio, and A. Gabaldon, "Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study," *Electric Power Systems Research*, vol. 91, pp. 18-27, October 2012.
- [93] S Ilić, A Erdeljan, F Kulić, and S Vukmirović, "Hybrid artificial neural network system for short-term load forecasting," *Thermal Science*, vol. 16, no. 1, pp. 215-224, 2012.
- [94] Hong-Ze Li, Sen Guo, Chun-Jie Li, and Jing-Qi Sun, "A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm," *Knowledge-Based Systems*, vol. 37, pp. 378-387, January 2013.
- [95] Xiao Zhi, Shi-Jie Ye, Zhong Bo, and Sun Cai-Xin, "BP neural network with rough set for short term load forecasting," *Expert Systems with Applications*, vol. 36, no. 1, pp. 273-279, January 2009.

- [96] S-T. Chen, David C. Yu, and Alireza R. Moghaddamjo, "Weather sensitive short-term load forecasting using nonfully connected artificial neural network," *IEEE Transactions on Power Systems*, vol. 7, no. 3, pp. 1098-1105, 1992.
- [97] C-N. Lu, H-T. Wu, and S. Vemuri, "Neural network based short term load forecasting," *IEEE Transactins on Power Systems*, vol. 8, no. 1, pp. 336-342, 1993.
- [98] A. Piras, A. Germond, B. Buchenel, K. Imhof, and Y Jaccard, "Heterogeneous artificial neural network for short term electrical load forecasting," *IEEE Transactions on Power Systems*, vol. 11, no. 1, pp. 397-402, 1996.
- [99] O. Mohammed et al., "Practical experiences with an adaptive neural network short-term load forecasting system," *IEEE Transactions on Power Systems*, vol. 10, no. 1, pp. 254-265, 1995.
- [100] TM Peng, NF Hubele, and GG Karady, "Conceptual approach to the application of neural network for short-term load forecasting," in *IEEE Int Symp on Circuits and Systems*, New Orleans, LA, 1990.
- [101] K.B. Song, S.K. Ha, J.W. Park, D.J. Kweon, and K.H. Kim, "Hybrid load forecasting method with analysis of temperature sensitivities," *Power Systems, IEEE Transactions on*, vol. 21, no. 2, pp. 869-876, 2006.
- [102] T.M. Peng, N.F. Hubele, and G.G. Karady, "Conceptual approach to the application of neural network for short-term load forecasting," in *IEEE Int Symp on Circuits and Systems*, New Orleans, LA, 1990.
- [103] Rahmat-Allah Hooshmand, Habib Amooshahi, and Moein Parastegari, "A hybrid intelligent algorithm based short-term load forecasting approach," *International Journal of Electrical Power & Energy Systems*, vol. 45, no. 1, pp. 313-324, February 2013.
- [104] M. Amina, V.S. Kodogiannis, I. Petrounias, and D. Tomtsis, "A hybrid intelligent approach for the prediction of electricity consumption," *International Journal of Electrical Power & Energy Systems*, vol. 43, no. 1, pp. 99-108, December 2012.
- [105] Jianzhou Wang, Xiaolong Ma, Jie Wu, and Yao Dong, "Optimization models based on GM (1, 1) and seasonal fluctuation for electricity demand forecasting," *International Journal of Electrical Power & Energy Systems*, vol. 43, no. 1, pp. 109-117, December 2012.
- [106] A. Khotanzad, R. C. Hwang, A. Abaye, and D. & Maratukulam, "An adaptive modular artificial neural network hourly load forecaster and its implementation at electric utilities," *IEEE Transactions on Power Systems*, vol. 10, no. 3, pp. 1716-1722, 1995.