



UNIVERZITET U NIŠU
MAŠINSKI FAKULTET



Miloš B. Simonović

**PRIMENA VEŠTAČKIH NEURONSKIH
MREŽA ZA KRATKOROČNO PREDVIĐANJE
I ANALIZU SISTEMA DALJINSKOG
GREJANJA**

DOKTORSKA DISERTACIJA

Niš, 2016.



UNIVERSITY OF NIŠ
FACULTY OF MECHANICAL ENGINEERING



Miloš B. Simonović

**ARTIFICIAL NEURAL NETWORK
APPLICATION FOR SHORT-TERM
PREDICTION AND ANALYSIS OF DISTRICT
HEATING SYSTEMS**

DOCTORAL DISSERTATION

Niš, 2016.

UNIVERZITET U NIŠU
PODACI O AUTORU ODBRANJENE DOKTORSKE DISERTACIJE

Ime, srednje slovo i prezime autora disertacije	Miloš B. Simonović
Datum, mesto i država rođenja autora	31.05.1973, Niš, Srbija
Važeća kućna adresa autora	Generala Bože Jankovića 21/22, 18 000 Niš
Broj mobilnog ili fiksnog telefona autora	066 6 444 637
Adresa elektronske pošte autora	milos.simonovic@masfak.ni.ac.rs
Naziv završenog fakulteta autora i godina diplomiranja	Mašinski fakultet
Datum odbrane magistarskog rada	31.05.2005
Akadska titula koju je autor stekao odbranom magistarskog rada	magistar mašinskih nauka
Akadska titula koju je autor stekao odbranom doktorske disertacije	doktor tehničkih nauka
Naziv fakulteta na kome je doktorska disertacija odbranjena	Mašinski fakultet
Naziv doktorske disertacije i datum odbrane	Primena veštačkih neuronskih mreža za kratkoročno predviđanje i analizu sistema daljinskog grejanja 13.07.2016
Naučna oblast disertacije prema CERIF šiframiku	T125 Automatizacija, robotika, kontrolni inženjering
Imena mentora i članova komisije za odbranu doktorske disertacije	1) Prof. dr Vlastimir Nikolić, Univerzitet u Nišu, Mašinski fakultet, mentor 2) Prof. dr, Dragan Antić, Univerzitet u Nišu, Elektronski fakultet 3) Prof. dr Žarko Čojbašić, Univerzitet u Nišu, Mašinski fakultet 4) Prof. dr Mihajlo Stojčić, Univerzitet u Banja Luci, Mašinski fakultet 5) Prof. dr Dejan Mitrović, Univerzitet u Nišu, Mašinski fakultet
Redni broj iz evidencije fakulteta o odbranjenoj doktorskoj disertaciji	612-276-3/2016

Mesto i datum:

Pečat:

Prof.dr Nenad T. Pavlović, dekan

Nadici i Danici

Podaci o doktorskoj disertaciji

Mentor:

dr Vlastimir Nikolić, redovni profesor, Univerzitet u Nišu, Mašinski fakultet

Naslov:

Primena veštačkih neuronskih mreža za kratkoročno predviđanje i analizu sistema daljinskog grejanja

Rezime:

Predmet istraživanja disertacije odnosi se na razvoj i primenu algoritama za kratkoročno predviđanje karakteristika sistema daljinskog grejanja pomoću veštačkih neuronskih mreža.

U užem smislu, istraživanja su usmerena na razvoj algoritama za izbor standardnih feedforward i rekurentnih neuronskih mreža i njihove arhitekture, izbor i podešavanje njihovih parametara, izbor i definisanje adekvatnih ulaza, modifikaciju date arhitekture mreža i njeno prilagođavanje ispunjavanju zahteva koje nameće primena veštačkih neuronskih mreža za kratkoročno predviđanje toplotnog opterećenja odnosno snage za sisteme daljinskog grejanja, kao osnovne karakteristike. Posebna pažnja biće posvećena komparativnoj analizi predloženih i usvojenih veštačkih neuronskih mreža sa svojim različitim arhitekturama sa ciljem dobijanja što optimalnijih algoritama.

Adekvatno predviđanje toplotnog opterećenja i toplotne snage, i zadovoljavanje potreba potrošača odgovarajućom isporučenom toplotnom energijom u cilju upravljanja sistemom i uštedom energije i očuvanju životne sredine, predstavlja veoma važan preduslov za optimalno podešavanje sistema daljinskog grejanja. Poboljšanje kvaliteta predviđanja, što je jedan od ciljeva ove teme, kako simulacije pokazuju ima pozitivan uticaj na upravljanje celog sistema daljinskog grejanja.

Osnovni fokus je upravo na adekvatnom izboru ulaznog vektora, broja ulaznih promenljivih i drugih parametara za standardne tipove mreža, za razliku od nekih rešenja koja se mogu naći u literaturi gde autori pribegavaju kreiranju potpuno novih jedinstvenih mreža za rešavanje svog problema. Time se praktično gubi mogućnost

generalizovanja njihove upotrebe a jedan od ciljeva ove disertacije je upravo i takva vrsta generalizacije.

Posebna pažnja u disertaciji je posvećena problemu prelaznih režima grejanja kod kojih se, za razliku od standardnog režima, grejanje ne odvija u kontinuitetu za u toku dana i utvrđenog perioda grejanja. Zato je jako važno postići kvalitetno predviđanje za kratak period kako bi se smanjila potrošnja toplotne energije i povećao koeficijent eksploatacije opreme. Ovo dobija na značaju još više zbog činjenice da su sistemi daljinskog grejanja u Srbiji po definiciji prekidni tj. grejanje se ne realizuje u kontinuitetu već se uključuje ujutru a isključuje u večernjim časovima.

Kratkoročno predviđanje se odnosi na predviđanje odabranih parametara i karakteristika sistema daljinskog grejanja za period od jednog, tri i sedam dana.

Dobijene modifikovane feedforward i rekurentne neuronske mreže zadovoljavaju potreban kvalitet predviđanja za sisteme daljinskog grejanja, adekvatno predviđaju vršna opterećenja u prelaznim režimima grejanja i kroz realizaciju neuronskih mreža iste arhitekture na 4 različita toplotna izvora pokazuju mogućnost generalizacije na određenom nivou.

Naučna oblast:	Mašinsko inženjerstvo
Naučna disciplina:	Automatsko upravljanje i robotika
Ključne reči:	veštačke neuronske mreže, kratkoročno predviđanje, daljinsko grejanje, toplotno opterećenje
UDK:	004.8:519.7:[681.5:697.34(043.3)
CERIFklasi fikacija:	T125 Automatizacija, robotika, kontrolni inženjering
Tip licenceKreativne zajednice:	CC BY-NC

Data on Doctoral Dissertation

Doctoral
Supervisor:

Dr Vlastimir Nikolić, Full professor, University of Niš Faculty of Mechanical Engineering

Title:

Artificial neural network application for short-term prediction and analysis of district heating systems

Abstract:

The subject of the research relates to the development and implementation of algorithms for short-term prediction of the district heating system characteristics using artificial neural networks. The research is aimed at developing algorithms for the selection of standard feedforward and recurrent artificial neural networks and their architectures, choice and adjustment their parameters, choice and definition of adequate inputs, modification of network architecture and its adaptation to meet the demands imposed by the application of artificial neural networks for short-term prediction of heat load as main characteristic of district heating system. Special attention will be devoted to a comparative analysis of proposed and adopted artificial neural networks with their different architectures to obtain optimal algorithms.

An adequate heat load prediction and satisfying consumer demands with delivered heat energy in sense of control system, energy saving and environment protection, are very important preconditions for optimal adjusting of district heating system

Improving quality of prediction, as one of the dissertation objective, has positive impact to control of district heating system, in general.

The main focus is on adequate choice of input vector, number of input nodes and other parameters for standard types of neural networks, contrary to solutions of some authors from literature, where they are creating totally new and unique networks for solving specific problem. On that way, they are losing possibility of generalization which is opposite to one of the dissertation objective.

Specific attention is given to problem of transient regime of heating, where there are no continuation in heating during a day and defined

heating period.

Achieving qualitative prediction for short period is very important for decrease heat consumption and increase the coefficient of equipment exploitation. This is more important due the fact that district heating systems in Serbia are intermitted by definition which means that heating is not realized in continuation but with turning on and off in the morning and evening hours. Short term prediction is realized for prediction of selected parameters and district heating system characteristics for period of one, three and seven days.

Deigned modified feedforward and recurrent neural networks satisfy needed quality of prediction for district heating systems, adequately predict peak loads in transient heating regimes and through the realization of neural networks of the same architecture on four different data heat sources, they are showing possibility of generalization on specific level.

Scientific Field:

Mechanical Engineering

Scientific Discipline:

Automatic control and robotics

Key Words:

artificial neural networks, short-term prediction, district heating, heat load

UDC:

004.8:519.7:[681.5:697.34(043.3)

CERIF Classification:

T125 Automation, robotics, control engineering

Creative Commons License Type:

CC BY-NC

SADRŽAJ

1.	UVOD	1
1.1.	Uvod	1
1.2.	Pregled dosadašnjih saznanja	4
1.3.	Ciljevi disertacije, očekivani rezultati i naučni doprinos	7
1.4.	Metodologija rada.....	8
1.5.	Pregled sadržaja disertacije	9
2.	VEŠTAČKE NEURONSKE MREŽE	12
2.1	Osnove veštačkih neuronskih mreža	12
2.2.	Razvoj veštačkih neuronskih mreža.....	15
2.3.	Osnovne komponente neuronskih mreža	16
2.4.	Način rada veštačke neuronske mreže	20
2.5.	Realizacija veštačkih neuronskih mreža	24
2.6.	Klasifikacija veštačkih neuronskih mreža.....	26
2.7	Osnovni tipovi neuronskih mreža	30
2.7.1	Feedforward neuronske mreže	30
2.7.2	RBF Neuronske mreže sa radijalnom funkcijom	34
2.7.2	Rekurentne neuronske mreže	35
2.7.3	SOM samoorganizirajuće mape	42
2.8	Veštačke neuronske mreže i evolutivni algoritmi	45
2.8.1	Opšta razmatranja.....	45
2.8.2	Metod optimizacije rojevima čestica (PSO – Particle Swarm Optimization).....	45
2.8.3	Genetski algoritmi (GA).....	47
3.	VEŠTAČKE NEURONSKE MREŽE ZA PREDVIĐANJE.....	50
3.1.	Uvodna razmatranja	50

3.2. Predviđanje vremenskih serija	52
3.3 Primena neuronskih mreža za predviđanje.....	54
3.4. Metodologija	56
3.5 Osnove modeliranja veštačke neuronske mreže za predviđanje	58
3.5.1 Arhitektura mreže.....	60
3.5.2 Aktivaciona funkcija	65
3.5.3 Algoritam za obučavanje.....	66
3.5.4 Normalizacija podataka.....	68
3.5.5 Uzorak za obuku i testiranje.....	70
3.5.6 Mere performansi	71
3. 6 Kratkoročno predviđanje kod sistema daljinskog grejanja	73
3.6.1 Opšta razmatranja.....	73
3.6.2 Pregled literature i aktuelni pravci istraživanja.....	75
4. SISTEMI DALJINSKOG GREJANJA	80
4.1. Sistemi daljinskog grejanja	80
4.2. Osnovne karakteristike sistema daljinskog grejanja	84
4.2.1 Toplotno opterećenje.....	84
4.2.2 Temperature	86
4.3. Toplotni izvori.....	90
4.3.1. Opšta razmatranja.....	90
4.3.2 Toplana Krivi vir.....	93
4.3.3 Toplana Konjarnik.....	97
4.3.4 Kotlarnica KC Niš.....	102
4.3.5. Toplana Mašinski fakultet.....	103
4.4 Pregled i analiza vremenskih perioda koji se koriste za testiranje predviđanja	107
5. VEŠTAČKE NEURONSKE MREŽE ZA KRATKOROČNO PREDVIĐANJE SISTEMA DALJINSKOG GREJANJA	115
5.1. Kratkoročno predviđanje kod sistema daljinskog grejanja	116

5.2. Opšta postavka problema	116
5.3. Primenjene veštačke neuronske mreže.....	119
5.3.1 Feedforward neuronska mreža	119
5.3.2 Elman rekurentna neuronska mreža	125
5.3.3 Pregled dobijenih simulacionih rezultata	134
6. KOMPARATIVNA ANALIZA PREDLOŽENIH MREŽA ZA PREDVIĐANJE ..	144
7. ZAKLJUČAK	150
LITERATURA.....	152
BIOGRAFIJA.....	

Listu slika

Slika 2-1 Mozak čoveka (http://humannhealth.com).....	17
Slika 2-2 Grafička interpretacija izgleda a) jednog neurona.....	17
Slika 2-3 Grafička interpretacija izgleda međusobne povezanosti neurona (www.3dscience.com).....	17
Slika 2-4 Struktura biološkog neurona.....	18
Slika 2-5 Model veštačkog neurona.....	19
Slika 2-6 Prikaz slojevite arhitekture veštačke neuronske mreže.	21
Slika 2-7 Grafički prikaz aktivacione funkcije odskočnog tipa	22
Slika 2-8 Grafički prikaz logičke aktivacione funkcije sa pragom.	22
Slika 2-9 Grafički prikaz aktivacione funkcije sigmoidalnog tipa.....	23
Slika 2-10 Grafički prikaz sigmoidalne funkcije za različite vrednosti parametra α	23
Slika 2-11 Grafički prikaz lestvičaste jednodimenzionalne mreže.	27
Slika 2-12 Grafički prikaz 2-dimenzionalne celularne neuronske mreže.	27
Slika 2-13 Grafički prikaz rekurentnih mreža.....	28
Slika 2-14 Struktura Hopfield-ove neuronske mreže sa četiri neurona i njihovim stanjima.	36
Slika 2-15 Osnovna arhitektura Hopfield-ove neuronske mreže.	37
Slika 2-16 Strukturna šema Hopfield-ove neuronske mreže pogodna za hardversku realizaciju.	38
Slika 2-17 Shematski prikaz Elman-ove neuronske mreže.....	39
Slika 2-18 Ilustrativna shema SOM-a samoorganizujuće mape	43
Slika 2-19 Primeri topologija Kohonenovih mreža a) jednodimenzionalna, b) dvodimenzionalna, c) trodimenzionalna	44
Slika 2-20 Pomeranje čestica na novu poziciju.....	46
Slika 2-21 Opšti algoritam optimizacije rojevima čestica	47
Slika 2-22 Osnovna varijanta genetskog algoritma.....	48
Slika 3-1 Osnovne karakteristike neuronskih mreža za predviđanje	51
Slika 3-2 Dijagram uticaja i značajnosti izbora parametara neuronske mreže za kratkoročno predviđanje.....	79
Slika 4-1 Proces daljinskog grejanja	81
Slika 4-2 Udeo korišćenja goriva u sistemima daljinskog grejanja u Srbiji	82
Slika 4-3 Ilustracija cene prirodnog gasa – drugo polugodište 2012 [160]	83

Slika 4-4 Prednosti predviđanja toplotnog opterećenja na strani potrošača.....	85
Slika 4-5 Toplana „Krivi vir“	94
Slika 4-6 Proizvedena snaga na TI Krivi vir 2012/2013	94
Slika 4-7 Zavisnost temperature napojne i povratne vode od spoljne temperature	95
Slika 4-8 Zavisnost protoka od spoljne temperature TI Krivi vir	95
Slika 4-9 Toplana „Konjarnik“	97
Slika 4-10 Ukupna snaga na TI Konjarnik 2013/2014.....	99
Slika 4-11 Zavisnost temperature napojne i povratne vode od spoljne temperature	99
Slika 4-12 Osnovne karakteristike i međusobne zavisnosti za grejnu sezonu 2013/2014TI „Konjarnik“ [m^3/h].....	100
Slika 4-13 TI „KC Niš“	102
Slika 4-14 Shematski prikaz TI „KC Niš“	102
Slika 4-15 Proizvedena snaga na TI Mašinski fakultet 2014/2015 za stambeno naselje “Nikola Tesla”.....	105
Slika 4-16 Zavisnost temperature napojne i povratne vode od spoljne temperature TI MF	105
Slika 4-17 Osnovne karakteristike I perioda TI Krivivir za 1, 3 i 7 dana predviđanja	110
Slika 4-18 Osnovne karakteristike II perioda TI Krivivir za 1, 3 i 7 dana predviđanja	110
Slika 4-19 Osnovne karakteristike I perioda TI Konjarnik za 1, 3 i 7 dana predviđanja	111
Slika 4-20 Osnovne karakteristike II perioda TI Konjarnik za 1, 3 i 7 dana predviđanja.....	111
Slika 4-21 Osnovne karakteristike I perioda TI MF za 1, 3 i 7 dana predviđanja	112
Slika 4-22 Osnovne karakteristike II perioda TI MF za 1, 3 i 7 dana predviđanja	112
Slika 4-23 Raspon toplotne snage u različitim danima pri istoj spoljnoj temperaturi $T_{sp} = -3^{\circ}C$	113
Slika 4-24 Raspon spoljnih temperatura kada je toplotno opterećenje nula TI Krivi vir.....	114
Slika 5-1 Koncept ANN modela za predviđanje 1,3 i 7 dana unapred	118
Slika 5-2 Feedforward neuronska mreža sa 1 skrivenim slojem koja se koristi za predviđanje 1,3 i 7 dana unapred	120
Slika 5-3 Mera performansi FF ANN za TI Konjarnik – Ulaz 1	121
Slika 5-4 Karakteristike obučavanja FF TI Konjarnik Ulaz 1	122
Slika 5-5 Stanje izlaza kod učenja mreže FF TI Konjarnik Ulaz 1	122
Slika 5-6 Mera performansi FF ANN za TI Konjarnik – Ulaz 2	122
Slika 5-7 Karakteristike obučavanja FF TI Konjarnik Ulaz 2	123
Slika 5-8 Stanje izlaza kod učenja mreže FF TI Konjarnik Ulaz 2	123
Slika 5-9 Mera performansi FF ANN za TI Konjarnik – Ulaz 3	123

Slika 5-10 Karakteristike obučavanja FF TI Konjarnik Ulaz 3	124
Slika 5-11 Stanje izlaza kod učenja mreže FF TI Konjarnik Ulaz 3.....	124
Slika 5-12 Mera performansi FF ANN za TI Krivi vir – Ulaz 3.....	124
Slika 5-13 Mera performansi FF ANN za TI Mašinski fakultet – Ulaz 3.....	125
Slika 5-14 Elman rekurentna mreža sa 10 ulaza	126
Slika 5-15 Mera performansi ELM RNN za TI Konjarnik – Ulaz 3.....	126
Slika 5-16 Karakteristike obučavanja FF TI Konjarnik Ulaz 3	127
Slika 5-17 Mera performansi ELM RNN za TI Krivi vir – Ulaz 3.....	127
Slika 5-18 Primenjeni algoritam za optimizaciju težinskih koeficijenata.....	129
Slika 5-19 Primenjeni PSO razvojni ciklus.....	130
5-20 Mera performansi za modifikovanu FF ANN TI Krivi vir za ulaz UM1	131
5-21 Karakteristike obučavanja TI Krivi vir UM3.....	131
5-22 Obuka TI Krivi vir UM3.....	132
Slika 5-23 Mera performansi za modifikovanu FF ANN TI Krivi vir za ulaz UM3	132
Slika 5-24 Mera performansi za modifikovanu FF ANN (2 skrivena sloja) TI Krivi vir za ulaz UM3.....	132
Slika 5-25 Mera performansi za modifikovanu ELM ANN TI Krivi vir za ulaz UM3	132
Slika 5-26 Simulacija TI Konjarnik za predviđanje 1, 3 i 7 dana unapred FF ANN - Ulaz 1 - Period I [MW]	135
Slika 5-27 Simulacija TI Konjarnik za predviđanje 1, 3 i 7 dana unapred FF ANN - Ulaz 2 - Period I [MW]	136
Slika 5-28 Simulacija TI Konjarnik za predviđanje 1, 3 i 7 dana unapred FF ANN - Ulaz 3 - Period I [MW]	136
Slika 5-29 Simulacija TI Konjarnik za predviđanje 3 dana unapred FF ANN - Ulaz 2 - Period II [MW].....	137
Slika 5-30 Simulacija TI Konjarnik za predviđanje 7 dana unapred FF ANN - Ulaz 3 - Period II [MW].....	137
Slika 5-31 Simulacija TI Mašinski fakultet za predviđanje 1 dan unapred FF ANN - Ulaz 3 - Period II [MW].....	138
Slika 5-32 Simulacija TI Mašinski fakultet za predviđanje 7 dana unapred FF ANN - Ulaz 3 - Period II [MW]	138
Slika 5-33 Simulacija TI Konjarnik za predviđanje 1 dan unapred ELM RNN - Ulaz 1 - Period II [MW].....	138

Slika 5-34 Simulacija TI Konjarnik za predviđanje 3 dana unapred ELM RNN - Ulaz 1 - Period II [MW].....	139
Slika 5-35 Simulacija TI Konjarnik za predviđanje 7 dana unapred ELM RNN - Ulaz 1 - Period II [MW].....	139
Slika 5-36 Simulacija TI Mašinski fakultet za predviđanje 1 dan unapred - Ulaz 3 - Period II - Modifikovana FF ANN [MW].....	140
Slika 5-37 Simulacija TI Mašinski fakultet za predviđanje 7 dan unapred - Ulaz 3 - Period II - Modifikovana FF ANN [MW].....	140
Slika 5-38 Simulacija TI Krivi vir za predviđanje 7 dana unapred - Ulaz 1 - Period II - Modifikovana ELM RNN [MW]	141
Slika 5-39 Simulacija TI Konjarnik za predviđanje 1 dan unapred - Ulaz 1 - Period II - Modifikovana ELM RNN	141
Slika 5-40 Simulacija TI Konjarnik FF ANN – predviđanje temperature napojne vode 7 dana unapred.....	142
Slika 5-41 Simulacija TI Konjarnik FF ANN – predviđanje temperature povratne vode 7 dana unapred	142
Slika 5-42 Simulacija TI MF FF ANN – predviđanje potrošnje toplotne energije 7 dana unapred.....	143
Slika 6-1 Algoritam primene veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja	149

Lista tabela

Tabela 2-1 Mozak naspram kompjutera, poređenje karakteristika	14
Tabela 3-1 Pregled izbora arhitekture i parametara kod različitih istraživača [160]	59
Tabela 3-2 Pregled tipova ulaznih promenljivih kao osnovnih faktora koji utiču na predviđanje kod sistema daljinskog grejanja	63
Tabela 4-1 Osnovne karakteristike posmatranih toplotnih izvora	90
Tabela 4-2 Prikaz osnovnih karakteristika za sezonu 2012/2013 TI Krivi vir.....	96
Tabela 4-3 Prikaz osnovnih karakteristika za sezonu 2013/2014 TI Konjarnik	100
Tabela 4-4 Prikaz osnovnih karakteristika za sezonu 2014/2015 TI „Mašinski fakultet“ ...	106
Tabela 4-5 Uporedni prikaz perioda za testiranje na toplotnim izvorima.....	108
Tabela 5-1 Pregled obima i strukture neuronske mreže za obučavanje	120
Tabela 5-2 Pregled vrednosti MSE za različite ulazne vektore	121
Tabela 5-3 Osnovni parametri PSO optimizacije težinskih koeficijenata FF ANN	128
Tabela 5-4 Pregled mera performansi za TI KC Niš.....	133
Tabela 6-1 Uporedni pregled prosečne greške predviđanja za TI Krivi vir.....	144
Tabela 6-2 Uporedni pregled prosečne greške predviđanja za TI Konjarnik	144
Tabela 6-3 Uporedni pregled prosečne greške predviđanja za TI Mašinski fakultet.....	145
Tabela 6-4 Pregled smanjenja greške predviđanja za pikove TI MF Period II.....	146
Tabela 6-5 Pregled smanjenja greške predviđanja za pikove TI Krivi vir.....	146

Lista skraćenica

ACF	Autokorelaciona funkcija
ADALINE	ADaptive LINear Element
AIC	Akaike informativni kriterijum
ANN	artificial neural network - veštačka neuronska mreža
ARCH	Autoregressive conditional heteroscedastic model
ARIMA	Autoregressive integrated moving average model
ARMA	Autoregressive moving average model
ASHRAE	American Society of Heating, Refrigerating and Air Conditioning Engineers
BP	Backpropagation
BPTT	Backpropagation Through Time
CI	Computer Intelligence
DG	Daljinsko grejanje
ESACF	Proširena autokorelaciona funkcija
ELM ANN	Elmanova neuronska mreža
FF ANN	Feedforward neuronska mreža
FL	Fazi logika
GA	Genetski algoritmi
ICT	Information Computer Technology
KO	Kotao
LM	Levenberg-Marquardt
LMA	Levenberg-Marquardt Algoritam
MAD	Mean Absolute Deviation – srednja apsolutna devijacija
MAPE	Mean Average percentage Error – srednja procentualna prosečna greška
ML	Machine Learning – mašinsko učenje

MLP	MultiLayer Perceptron – višeslojni perceptron
MSE	Mean Square Error – srednja kvadratna greška
NWP	Neural Weather Prediction
PACF	Parcijalna autokorelaciona funkcija
PLS	Partial Least Squares - metod najmanjih parcijalnih kvadrata
PSO	Particle Swarm Optimization - Optimizacija rojevima čestica
RBF	Radial Basis Function
RMSE	Root Mean Square Error – koren srednje kvadratne greške
RTRL	Real-Time Recurrent Learning
SARIMA	Seasonal Autoregressive Integrated Moving Average model
SC	Soft Computing
SOM	Self Organizing Map – samoorganizujuća mapa
SRN	Simple recurrent network – prosta rekurentna neuronska mreža
SSE	Srednja kvadratna greška
STLF	Short Term Load Forecasting – kratkoročno predviđanje opterećenja
SVM	support vector machine
SVR	support vector regression metod regresije potpornih vektora
TAR	Treshold AutoRegressive model
TETO	Termoelektrana Toplana
TI	Toplotni izvor
TO	Toplana
TOE	Toplana elektrana
TPS	Toplotna podstanica
TPTT	Truncated Backpropagation Through Time

1. UVOD

1.1.Uvod

Poslednje godine donele su, u okviru burnog razvoja teorije i prakse automatskog upravljanja, saznanje da realizacija fleksibilnijih upravljačkih sistema podrazumeva, pored primene uglavnom algoritamskih pristupa iz domena klasične teorije upravljanja, uključivanje i drugih elemenata, kao što su logika, zaključivanje i heuristika, a takvi sistemi upravljanja poznati su pod nazivom inteligentni sistemi upravljanja. Motivacija za projektovanje inteligentnih sistema upravljanja jeste potreba da se obezbedi željeno ponašanje i performanse zatvorenog sistema kao i njegov integritet u širokom opsegu radnih uslova, što podrazumeva i podražavanje ljudskih sposobnosti, kao što su planiranje, učenje i adaptacija.

Karakteristike upravljačkog sistema takođe moraju odgovarati kompleksnosti procesa, uključujući nelinearnost i vremensku promenljivost, dimenzionalnost i multivarijabilnost, složenost željenih upravljačkih ciljeva, nesavršenost i nepouzdanost merenja, kao i potrebu da se reaguje u slučaju otkaza komponenti sistema. Konvencionalna matematička teorija sistema se u poslednjih nekoliko decenija razvila u naučnu disciplinu izvanrednih mogućnosti i široke primenljivosti. Uspešna primena je kod problema modeliranja i upravljanja linearnih stacionarnih sistema a značajni su rezultati i u oblasti adaptivne identifikacije i upravljanja linearnih vremenski invarijantnih sistema sa nepoznatim parametrima. Teorija nelinearnih sistema je takođe pokazala svoju snagu u tretiranju specijalnih klasa takvih sistema.

Mnogi složeni sistemi ostaju izvan domašaja klasične matematičke teorije sistema jer konvencionalna teorija upravljanja zahteva mnogo apriornih informacija. Stalna potreba za povećanje zahteva pri projektovanju efikasnih upravljačkih sistema je, uz povećanu kompleksnost modela dinamičkih sistema, uslovlila evoluciju metoda upravljanja ka novim sofisticiranim tehnikama upravljanja. Nove karakteristike oblasti inteligentnog upravljanja ostvaruje obuhvatanjem raznorodnih metodologija zasnovanih na fiziološkim metaforama, kao što su fazi logika, neuronske mreže, genetski i evolucionarni algoritmi, veštačka inteligencija i razne tehnike pretraživanja i optimizacije, koje se označavaju terminom meki račun, "soft computing" (SC) i koje su nastale na osnovu Zadeove (Zadeh) vizije o modeliranju mehanizama ljudskog razmišljanja lingvističkim fazi vrednostima. Ove metodologije danas se obuhvataju i terminom računarska inteligencija (CI), koju čini konzorcijum navedenih i drugih tehnika koje igraju važnu ulogu u koncepciji, projektovanju i korišćenju informacionih/inteligentnih sistema.

Meki račun je usmeren na nalaženje približnih rešenja za precizno definisane probleme ili još tipičnije približnih rešenja za neprecizno definisane probleme. U samoj suštini, to je razvoj ka

novim tipovima sistema kod kojih tehnike obučavanja, veštačka inteligencija i klasične metode postaju značajno međusobno kompatibilne. Meki račun razlikuje se od konvencionalnih metoda prvenstveno po tome što je tolerantan ka nepreciznosti, nesigurnosti i delimičnoj istinitosti. U suštini, uzor za meki račun je ljudski mozak, kako u pogledu strukture (npr. neuro mreže) tako i u funkcionalnom smislu (npr. fazi logika).

Osnovni rukovodeći princip kod mekog računa je: ***iskoristiti pomenutu toleranciju ka nepreciznosti, nesigurnosti i delimičnoj istinitosti u cilju ostvarenja lakoće implementacije, robustnosti i niske cene rešenja.***

Jedna od čestih primena mekog računa koja će biti analizirana u ovoj disertaciji je predviđanje vremenskih serija. Samo predviđanje može biti: kratkoročno, srednjeročno i dugoročno. Predmet razmatranja ove disertacije je kratkoročno predviđanje i više o ovoj metodi inteligentnog upravljanja biće reči u narednim poglavljima.

Postoji više različitih metoda kartkoročnog predviđanja. Važno je istaknuti sledeće:

- *Pristup "sličnog" dana (eng. similiar day approach)*

Pristup koji se temelji na traženju istorijskih podataka za dane unutar jedne, dve ili tri godine unazad sličnih karakteristika sa danom čiju potrošnju energije predviđamo. Umesto jednog "sličnog" dana može se koristiti linearna kombinacija više "sličnih" dana.

- *Regresijske metode.*

Regresija je jedna od najšire korišćenih statističkih metoda. Pri predviđanju potrošnje energije, regresijske metode koriste se pri modeliranju odnosa između potrošnje energije i drugih činioca poput vremena, skupa potrošača i vrste dana. Mnogi modeli koriste determinističke uticaje poput praznika, statističke uticaje poput prosečne potrošnje energije i spoljnih uticaja poput temperature.

- *Neuronske mreže.*

Upotreba veštačkih neuronskih mreža kao metode predviđanja potrošnje energije proučavana je još od 1990. godine [2]. Najpopularnije veštačke neuronske mreže za predviđanje opterećenja su mreže sa propagacijom unazad. Neuronske mreže sa propagacijom unazad koriste kontinuirane funkcije i nadzirano učenje. Kod tih mreža se podešavanjem unutrašnjih parametara aproksimira funkcija potrošnje energije. Podešavanje unutrašnjih parametara odvija se pri učenju neuronske mreže pomoću algoritama učenja koji zahtevaju ulazne i izlazne podatke. Najčešće se

kao ulazni podaci koriste vremenski podaci, podaci vezani za godišnja doba, ili istorijska merenja potrošnje energije, dok se kao izlazni podaci koriste stvarne vrednosti potrošnje energije.

Predmet ove disertacije je primena veštačkih neuronskih mreža za kratkoročno predviđanje toplotnog opterećenja i drugih karakteristika sistema daljinskog grejanja.

• *Ekspertski sistemi.*

Predviđanje temeljeno na pravilima koristi pravila, često heuristička u svojoj prirodi kako bi dalo tačna predviđanja. Ekspertski sistemi koriste pravila i procedure korišćene od strane stručnjaka u interesnom području koje se zatim uklapaju u programe sposobne da čine predviđanja bez ljudske pomoći. Upotreba ekspertskih sistema započela je 1960-ih godina u primenama za geološka ležišta i računarsko projektovanje. Ekspertski sistemi daju najbolje rezultate kada stručnjaci iz datog područja saraduju sa programskim inženjerima uklapajući za to vreme stručno znanje u upravljački program. Isto tako, stručno znanje mora biti prikladno za ugradnju u programska pravila (tj. stručnjak mora biti u stanju da objasni svoj proces odlučivanja programeru). Ekspertski sistemi mogu ugraditi stotine ili hiljade proizvodnih pravila.

• *Fazi logika*

Fazi logika je uopštenje uobičajene Booleove logike korišćene za projektovanje digitalnih krugova. U Booleovoj logici ulazne vrednosti mogu imati dve vrednosti, "0" i "1". U neizrazitoj logici ulazne vrednosti poprimaju vrednosti u kvalitativnim rasponima. Tako na primer transformatorsko opterećenje može poprimiti "nisku", "srednju" i "visoku" vrednost [2]. Neizrazita logika omogućuje logičko zaključivanje izlaza temeljeno na neizrazitim ulazima. Među prednostima fazi logike ističe se nedostatak potrebe za matematičkim modelom mapiranja ulaza u izlaze i nedostatak potrebe za preciznim ulazima. Sa takvim generičkim uređenjem pravila, ispravno projektovan sistem fazi logike može biti veoma robustan kada se koristi za predviđanje opterećenja. Naravno, u mnogim je situacijama potreban egzaktni izlaz. Nakon logičke obrade fazi ulaza, proces defazifikacije se može koristiti za predviđanje takvih preciznih izlaza.

• *Metoda potpornih vektora. (eng. support vector machine)*

Ova metoda predstavlja novije napredne tehnike za rešavanje klasifikacijskih i regresijskih problema. Za razliku od neuronskih mreža, koje pokušavaju definisati složene funkcije u prostoru ulaza, metode potpornih vektora obavljaju nelinearno mapiranje (pomoću tzv. *kernel* funkcije) podataka u višedimenzionalni prostor. Zatim se koriste jednostavne linearne funkcije za stvaranje

linearnih granica u novom prostoru. Problem odabira strukture za neuronske mreže ovde zamenjuje problem izbora odgovarajuće *kernel* funkcije.

1.2.Pregled dosadašnjih saznanja

Predmet istraživanja disertacije odnosi se na razvoj i primenu algoritama za kratkoročno predviđanje korišćenjem veštačkih neuronskih mreža kod sistema daljinskog grejanja.

U užem smislu, istraživanja su usmerena na razvoj algoritama za izbor veštačkih neuronskih mreža i njihove arhitekture, izbor i podešavanje njihovih parametara, izbor i definisanje adekvatnih ulaza i njihovo predprocesiranje, modifikaciju date arhitekture mreža i njeno prilagođavanje ispunjavanju zahteva koje nameće primena veštačkih neuronskih mreža za kratkoročno predviđanje. Posebna pažnja biće posvećena komparativnoj analizi predloženih i usvojenih veštačkih neuronskih mreža sa svojim različitim arhitekturama sa ciljem dobijanja optimalnih algoritama za kratkoročno predviđanje kod sistema daljinskog grejanja .

Adekvatno predviđanje toplotnog opterećenja i toplotne snage, i zadovoljavanje potreba potrošača odgovarajućom isporučenom toplotnom energijom u cilju upravljanja sistemom i uštedom energije i očuvanju životne sredine, predstavlja veoma važan preduslov za optimalno podešavanje sistema daljinskog grejanja, te direktno ima uticaj na efikasnost celog sistema, uštedu energije i zaštitu životne sredine. Poboljšanje kvaliteta predviđanja, što je jedan od ciljeva ove teme, kako simulacije pokazuju ima pozitivan uticaj na upravljanje celog sistema daljinskog grejanja.

Većina istraživanja primene veštačkih neuronskih mreža za kratkoročno predviđanje opterećenja (SLTF – short-term load forecasting) se odnosi na električno opterećenje dok je mnogo manji broj radova i istraživanja koji se bave kratkoročnim predviđanjem toplotnog opterećenja kod sistema daljinskog grejanja. Ovi radovi pokazuju da spoljna temperatura, zajedno sa socijalnom komponentom koja opisuje potrebe i ponašanje potrošača, ima najveći uticaj na toplotni izlaz od strane potrošača odnosno potrebe za toplotnom energijom koja treba da bude isporučena od strane toplotnog izvora.

Iako su mnoge metode predviđanja veštačkim neuronskim mrežama primenjene, nijedna od njih nije se dokazala kao metoda koja može biti generalizovana. Razlog leži u činjenici da uslovi i zahtevi svake pojedinačne situacije ili problema imaju jako značajan uticaj na izbor odgovarajućeg modela. Zato se inženjeri u praksi ali i sami istraživači nalaze u problemu kada je u pitanju osnovni izbor tipa neuronske mreže ali i eventualnih njenih modifikacija radi zadovoljavanja projektnih zahteva. Zbog toga je potreban sistemski pristup odabiru tipa neuronske mreže, njene arhitekture i kvaliteta podataka u saglasnosti sa prirodom problema koji se rešava.

Veštačke neuronske mreže su sposobne da uče karakteristike toplotnog opterećenja koje moraju da budu detaljno analizirane. Problem se javlja zbog nedostatka komparacije rezultata varijacija na različitim modelima. Zato je neophodna komparativna analiza karakteristika različitih modela kako bi se metode primenile u realnom vremenu.

U ovoj disertaciji su korišćene feedforward neuronske mreže i rekurentne neuronske mreže jer one čine zajedno preko 95% svih korišćenih neuronskih mreža, što stvara dobre preduslove za potencijalnu generalizaciju. Biće korišćeni i njihovi podtipovi i modifikacije odnosno poboljšanja i urađena adekvatna komparativna analiza koja će rezultirati kreiranjem algoritma za primenu veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja.

U ovoj disertaciji, osnovni fokus je upravo na osnovnim tipovima neuronskih mreža i njihovog prilagođavanja kroz modifikaciju i kombinovanje različitog broja ulaza i drugih parametara za razliku od velikog broja rešenja koja se mogu naći u literaturi gde autori pribegavaju kreiranju potpuno novih jedinstvenih mreža za upotrebu kod rešavanja svog problema. Time se praktično gubi mogućnost generalizovanja njihove upotrebe a jedan od ciljeva ove disertacije je upravo i ta vrsta generalizacije.

U ovoj temi predmet istraživanja je kratkoročno predviđanje potrošnje toplotne energije kroz predviđanje toplotnog opterećenja, toplotne snage na toplotnom izvoru i temperature napojne vode na ulazu potrošača. Ovo predviđanje je naročito značajno za prelazne režime grejanja kod kojih se za razliku od standardnog režima grejanje ne odvija u kontinuitetu za sve vreme utvrđenog perioda grejanja. Zato je jako važno postići kvalitetno predviđanje za kratak period kako bi se smanjila potrošnja toplotne energije i povećao koeficijent eksploatacije opreme. Ovo dobija na značaju još više zbog činjenice da su sistemi daljinskog grejanja u Srbiji po definiciji prekidni tj. grejanje se ne realizuje u kontinuitetu već se uključuje ujutru a isključuje u večernjim časovima.

Kratkoročno predviđanje se odnosi na predviđanje odabranih parametara i karakteristika sistema daljinskog grejanja za period od jednog, tri i sedam dana, za razliku od kratkoročnog predviđanja kod električnog opterećenja gde je jako važno i predviđanje za sat unapred.

Ispitaće se i uticaj kvaliteta stvarnih podataka za obradu na izbor veštačke neuronske mreže i kvalitet samog predviđanja. To je i jedan od razloga postojanja više različitih primera toplotnih izvora sa stvarnim podacima koji su predmet obrade ove teme.

Nakon krize sedamdesetih godina, energija je postala jedna od glavnih tema u agendi razvijenih i zemalja u razvoju koji svoje energetske potrebe obezbeđuju od drugih. Globalna finansijska kriza 2008. i 2009. godine dodatno je povećala potrebu za većim uštedama energije i nalaženju novih načina obezbeđivanja dovoljno energije za sopstvene potrebe, posebno se

oslanjajući na obnovljive izvore energije sa jedne strane i dodatnim postavljanjem fokusa na energetske efikasnost i ekonomsku efektivnost u eksploataciji postojećih energetskih resursa.

I danas, najveći deo potrošnje energije ide na grejanje. Kako je najveća gustina naseljenosti upravo u najvećim gradovima to je i najveća potrošnja energije upravo u njima. Kako svi veći gradovi uglavnom baziraju grejanje na sistemu daljinskog grejanja onda se neizostavno kao rastuća potreba nameće racionalno i efikasno upravljanje sistemima daljinskog grejanja. Optimalno upravljanje savremenim sistemima daljinskog grejanja se može okarakterisati sa tri cilja: redukcijom potrošnje energije, povećanjem energetske efikasnosti i smanjenjem zagađenja životne sredine.

Preduzeća za proizvodnju i distribuciju toplotne energije su odgovorna za isporuku toplotne energije proizvedene u centralnom postrojenju do potrošača preko toplovodnog sistema. Istovremeno, od njih se očekuje da održe cenu proizvedene i isporučene toplotne energije što je moguće nižom. Zato je rastuća potreba za optimizacijom proizvodnje toplotne energije kroz bolje predviđanje i upravljanje potrebama potrošača. Savremena preduzeća za proizvodnju i distribuciju toplotne energije suočavaju se i sa novim izazovima. Mnogi potrošači odlučuju da se isključuju sa sistema daljinskog grejanja i menjaju ga decentralizovanim ili individualnim sistemom grejanja. Preduzeća moraju da poboljšaju usluge i minimiziraju cenu u isto vreme.

Treba istaći da je najznačajniji deo cene daljinskog grejanja cena proizvodnje toplotne energije. Optimizovanjem proizvodnje toplotne energije može se redukovati cena. Međutim, ovaj cilj nije moguće ispuniti bez detaljne analize profila korisničkih zahteva. Cilj je odrediti skup tipičnih profila toplotnih zahteva koja će odgovarati tipičnoj grupi potrošača. Dobijanjem takvog profila zahteva na godišnjem nivou, može se ostvariti dugoročna optimizacija snabdevanja toplotnom energijom. Takođe, potreban je i dnevni profil zahteva zbog kratkoročne optimizacije.

Kako bi se poboljšala ekonomska efikasnost u radu sistema daljinskog grejanja, potrebno je prvo realizovati predviđanje potrošnje toplotne energije. Ekonomsko upravljanje potrošnje sistema za daljinsko grejanje i planiranje je duboko zavisno od tačnog predviđanja.

U cilju teorijske i eksperimentalne verifikacije koncepta kratkoročnog predviđanja kod sistema daljinskog grejanja pomoću veštačkih neuronskih mreža, odabrane su sledeće polazne hipoteze planiranih istraživanja:

- Primenom savremenih metoda i algoritama iz domena veštačke inteligencije, odnosno veštačkih neuronskih mreža moguće je kreirati opštiji algoritam zadovoljavajuće pouzdanosti za kratkoročno predviđanje kod sistema daljinskog grejanja;

- Implementacijom više tehnika veštačkih neuronskih mreža, u proces kratkoročnog predviđanja kod sistema daljinskog grejanja moguće je obezbediti pouzdano predviđanje i upravljanje povećane efikasnosti i efektivnosti sistema daljinskog grejanja;

1.3. Ciljevi disertacije, očekivani rezultati i naučni doprinos

Ključni naučni cilj disertacije je analiza i razvoj algoritama za rešavanje problema kratkoročnog predviđanja kod sistema daljinskog grejanja radi dobijanja racionalnijeg sistema daljinskog grejanja sa aspekta načela ekonomske i energetske efikasnosti i efektivnosti.

Osnovni ciljevi istraživanja su:

- Primena veštačkih neuronskih mreža za kratkoročno predviđanje i analizu sistema daljinskog grejanja
- Predlog metodologije za izbor tipa i parametara veštačke neuronske mreže za kratkoročno predviđanje sistema daljinskog grejanja
- Povećanje kvaliteta kratkoročnog predviđanja korišćenjem predložene metodologije
- Analiza i dalji razvoj algoritama za rešavanje problema kratkoročnog predviđanja kod sistema daljinskog grejanja ;
- Razvoj novih algoritama za kratkoročno predviđanje kod sistema daljinskog grejanja;
- Primena novih algoritama na konkretnim sistemima daljinskog grejanja i stvarnim podacima dobijenih u različitim eksploatacionim uslovima;
- Primena novih algoritama na konkretnim kombinovanim sistemima daljinskog grejanja;
- Dobijanje racionalnijeg sistema daljinskog grejanja sa aspekta načela ekonomske i energetske efikasnosti;

I pored određenog broja publikovanih metoda za kratkoročno predviđanje koje su uspešno testirane i dokazane, nijedna od njih nije se dokazala kao metoda koja može biti generalno primenjena. Razlog leži u činjenici da uslovi i zahtevi svake pojedinačne situacije ili problema imaju jako značajan uticaj na izbor odgovarajućeg modela. Često je i teško uporediti primenjene metode. Zato je jedan od ciljeva ove teme bio i kreiranje algoritma koji će dati doprinos uspostavljanju opštije procedure za primenu veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja.

Rezultati predloženih naučnih istraživanja treba da omoguće implementaciju novog algoritma za kratkoročno predviđanje kod sistema daljinskog grejanja u realnom vremenu pomoću veštačkih neuronskih mreža i time omoguće kao očekivane rezultate:

- Novi algoritam i metodu za primenu veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja;
- Novi algoritam i metodu za izbor uticajnih parametara veštačke neuronske mreže za kratkoročno predviđanje i njihovu komparativnu analizu ;
- Nove smernice primene adekvatnih veštačkih neuronskih mreža kod sistema za daljinsko grejanje;
- Novi algoritam komparacije za primenu veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja i kod elektroenergetskih sistema;
- Novi celoviti algoritam pravila i procedura izbora, projektovanja i implementacije veštačke neuronske mreže za kratkoročno predviđanje kod sistema daljinskog grejanja.

Ovi naučni rezultati, koji bi predstavljali proširenje postojećih saznanja, od praktičnog su značaja za dalji razvoj, kao i sveobuhvatno korišćenje veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja, posebno u prelaznim režimima. Dobijeni rezultati omogućiće bolju autonomiju i pouzdanost sistema daljinskog grejanja sa aspekta efikasnosti i efektivnostui, što predstavlja značajan naučni doprinos unapređenju multidisciplinarnog pristupa pri rešavanju ovakvih kompleksnih problema.

1.4. Metodologija rada

S obzirom na izrazito multidisciplinarni karakter naučnoistraživačke oblasti predloženih istraživanja koja podrazumeva značajan uticaj matematičkih, termo-energetskih i softverskih aspekata, naučne metode istraživanja koje će se primeniti u predmetnoj doktorskoj disertaciji su:

- analitički pristup za rešavanje problema kratkoročnog predviđanja kod sistema daljinskog grejanja
- eksperimentalni metod pomoću koga će, adekvatne veštačke neuronske mreže, biti obučene stvarnim i eksperimentalnim podacima kako bi se vršilo kratkoročno predviđanje kod sistema daljinskog grejanja

Za potrebe izrade doktorske disertacije korišćeni su podaci sa toplotnog izvora "Krivi vir" instalisane snage 128 MW, energetskog subjekta JKP Toplana Niš, podaci dobijeni očitavanjem sa kotlarnice Aleksandra Medvedeva 14, instalisane snage energetskog subjekta Mašinskog fakulteta u

Nišu, toplotnog izvora "Konjarnik" instalisane snage 232 MW, energetskog subjekta Beogradske elektrane i njegovih podstanica kao i podaci dobijeni sa toplotnog izvora "Klinički centar Niš". Pored stvarnih podataka sa gore navedenih toplotnih izvora, korišćeni su i određeni eksperimentalni podaci kako bi se izvršile odgovarajuće komparativne analize predloženih modela. Na Mašinskom fakultetu u Nišu u okviru disertacije izvršena je analiza postojećih i razvoj novih algoritama korišćenjem programskih paketa za simulaciju i razvoj sistema upravljanja i primenu tehnika veštačke inteligencije.

Jedan od osnovnih razloga upotrebe četiri različita skupa podataka sa četiri različita toplotna izvora i različitim performansama samih toplotnih izvora ali i potreba potrošača je pokušaj stvaranja osnove za generalizovanje i definisanje opštih smernica za rešavanje opšteg problema kod sistema daljinskog grejanja.

1.5. Pregled sadržaja disertacije

Disertacija se sastoji od uvoda, pet poglavlja, zaključnih razmatranja, spiska korišćene literature i priloga. Sadržaj teksta disertacije izložen je kroz sledeća poglavlja:

1. Uvod
2. Veštačke neuronske mreže
3. Veštačke neuronske mreže za predviđanje
4. Sistemi daljinskog grejanja
5. Veštačke neuronske mreže za kratkoročno predviđanje sistema daljinskog grejanja
6. Komparativna analiza predloženih mreža za predviđanje
7. Zaključak

U uvodnom delu date su uvodne napomene o predmetu istraživanja i dat je kratak prikaz istraživanja sprovedenih u okviru disertacije.

U okviru drugog poglavlja dati su osnovni pojmovi o veštačkim neuronskim mrežama, njihova podela po različitim kriterijumima i oblasti primene. Detaljnije su opisane arhitekture najčešće zastupljenih neuronskih mreža feedforward mreža, višeslojnih perceptrona, RBF neuronskih mreža, rekurentnih neuronskih mreža Elman i Hopfield. Takođe je dat detaljniji opis algoritama za učenje gore navedenih neuronskih mreža, respektivno. Posebno su istaknute karakteristike neuronskih mreža i prikazane jednačine ponašanja.

U okviru trećeg poglavlja dat je pregled veštačkih neuronskih mreža za predviđanje. Najpre je dat detaljan opis predviđanja vremenskih serija a zatim poseban osvrt na karakteristike veštačkih neuronskih mreža koje ih preporučuju upravo za predviđanje. U posebnom delu ovog poglavlja su

detaljno opisane osnovne karakteristike i način izbora istih veštačkih neuronskih mreža: arhitektura, broj ulaznih čvorova, izbor aktivacione funkcije, obrada ulaznih podataka, određivanje broja neurona u skrivenim slojevima itd. Pored toga dat je istorijski prikaz korišćenja veštačkih neuronskih mreža za predviđanje sa adekvatnom uporednom analizom. U poslednjem delu ovog poglavlja obrađene su veštačke neuronske mreže za kratkoročno predviđanje sa posebnim osvrtom na pregled mreža za kratkoročno predviđanje toplotnog opterećenja kod sistema daljinskog grejanja.

U okviru četvrtog poglavlja dat je opšti opis sistema daljinskog grejanja. Prikazan je poseban osvrt na osnovne karakteristike sistema daljinskog grejanja toplotno opterećenje i temperature. Posebno su opisani toplotni izvori. U ovoj disertaciji koriste se stvarni podaci preuzeti sa četiri toplotna izvora: Toplana “Krivi vir”, Niš, Toplana “Mašinski fakultet”, Niš, Toplana “Klinički centar”, Niš i Toplana “Konjarnik”, Beograd. Reč je o četiri toplotna izvora različitih kapaciteta i različitih potreba potrošača. Zajedničko je da su pribavljeni podaci za po jednu grejnu sezonu kako bi kasnija komparativna analiza bila adekvatna. U ovom delu je data analiza karakteristika sistema daljinskog grejanja za 3 toplotna izvora pojedinačno, počev od minimalne, maksimalne i srednje dnevne spoljne temperature, toplotnog opterećenja odnosno snage za svaki sat dnevno i njihovih međusobnih zavisnosti što predstavlja osnovu za sledeće poglavlje i primenu odgovarajućih metoda na tako uređene podatke. Dat je tabelarni prikaz za tri toplotna izvora 6 karakteristika koje su važne za izradu modela veštačke neuronske mreže za kratkoročno predviđanje, dok je četvrti toplotni izvor iskorišćen kao kontrolni.

U petom poglavlju je dat prikaz primenjenih veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja. Iskorišćene su višeslojna feedforward neuronska mreža i Elman rekurentna neuronska mreža, kao standardni tipovi neuronskih mreža. One su primenjene na svaki od četiri skupa podataka dobijenih sa toplotnih izvora. Data je analiza ulaznih promenljivih kao najvažniji deo algoritma za kratkoročno predviđanje, zbog svoje nelinearnosti jer pored temperaturne sadrži i socijalnu komponentu. Pri tome je svaka od mreža realizovana sa tri različita ulazna vektora. Na taj način su dobijeni simulacioni rezultati za 36 neuronskih mreža. Predviđanje je rađeno za 1, 3 i 7 dana unapred. Radi poboljšanja tačnosti predviđanja opterećenja u pikovima u danima gde se prekida isporuka toplotne energije zbog velikih temperaturnih razlika a na osnovu analize urađene u prethodnom poglavlju uvedeni su novi ulazi koji obuhvataju minimalnu dnevnu temperaturu. Takođe, pomoću PSO algoritma vrši se optimizacija težinskih koeficijenata a pomoću GA broj neurona u skrivenom sloju. Nove modifikovane, poboljšane neuronske mreže se ponovo realizuju na podacima sva četiri toplotna izvora i dobijaju odgovarajući rezultati simulacija.

U šestom poglavlju je izvršena komparativna analiza dobijenih simulacionih rezultata i uspostavljen algoritam za oba tipa predloženih neuronskih mreža. Poseban osvrt je dat uporednoj analizi između rezultata predviđanja dobijenih sa prva tri ulazna vektora i nakon uvođenja novog ulaza radi poboljšanja karakteristika u prelaznim režimima grejanja.

U sedmom poglavlju su data zaključna razmatranja i sumiranje rezultata istraživanja, ističe se naučni doprinos doktorske disertacije i predlažu pravci daljeg istraživanja.

Na kraju je dat spisak korišćene literature.

2. VEŠTAČKE NEURONSKE MREŽE

1.1 Osnove veštačkih neuronskih mreža

Veštačke neuronske mreže predstavljaju alternativni pristup rešavanju logičkih problema u odnosu na konvencionalne računarske logike [1], [2], [3]. Sama reč „veštačke“ sugerise da je inspiracija za strukturu i logiku rada ovih mreža nastala pokušajem imitacije rada prirodnih neuronskih veza i sistema. Povod za intenzivan razvoj veštačkih neuronskih mreža može se naći u sofisticiranosti rada ljudskog mozga, i stalne želje čoveka da ovako kompleksan i inteligentan sistem kreira i podredi svojim potrebama [4].

Neurologija, kao nauka koja se bavi proučavanjem nervnog sistema čoveka, još uvek nema odgovore na sva pitanja u vezi rada mozga. Međutim, za realizaciju prvih veštačkih neuronskih mreža dovoljne su bile, u tom trenutku, poznata anatomska građa i fiziološke funkcije mozga, koje nude informacije o strukturi, načinu prenosa impulsa i memorisanju željenih događaja [5].

Veštačke neuronske mreže su samo jedan od tehničkih alata kojima se nauka i tehnologija služe da bi brzo i kvalitetno rešile složene probleme [1], [6]. Postoji veliki skup tehnika i rešenja koja koriste mehanizme koje nalazimo kod živih bića i koja su inspiracija za nova naučna dostignuća [1],[7],[8],[9], [10].

Početak istraživanja i razvoja veštačkih neuronskih mreža bio je vezan za McCulloch-a i Pits-a koji su predstavili matematički model biološkog neurona [11], [4]. Tada veliki broj istraživača aktivno prihvata novu disciplinu i sve više razvija način rada i nove strukture mreža. Samim tim i sve veći broj problema nalazi svoje rešenje primenom ovih mreža. Međutim, pojavljuju se i poteškoće koje u datom trenutku ne nalaze rešenja primenom veštačkih neuronskih mreža, od kojih je najpoznatiji problem realizacije *XOR* funkcije [2]. Paralelno sa tim javlja se i sve veći broj kritičara ovakvog rada. Međutim, privreda ulaže sve više novca u razvoj i implementaciju ovih mreža, čime se entuzijazam istraživača dodatno povećava. Nažalost, posle desetak godina od prvih koraka, sve više se odustajalo od implementacija neuronskih mreža, pa se i interesovanje za njih polako smanjuje. Na sreću, određen broj naučnika i dalje radi na poboljšanju performansi i rešavanju problema koji se paralelno procesiraju pomoću računara.

Razvoj veštačke inteligencije danas sagledavamo kroz međusobnu interdisciplinarnost matematike, fizike, neurologije, anatomije, teoriju obrade signala i sličnih naučnih disciplina. Cilj razvoja veštačke neuronske mreže je pokušaj da se razume i simulira rad ljudskog mozga, u smislu detekcije signala, njegovog prenosa, postupka donošenja odluka i načina pamćenja tj. zaboravljanja. U osnovi, primenom veštačkih neuronskih mreža pokušava se napraviti veštački sistem sposoban da

uči i donosi inteligentne odluke kao čovek [1], [12]. Ovo je posebno bitno kada se radi o velikoj količini podataka i kratkom vremenu potrebnom za njegovo procesiranje. Elektronska kola, koja se koriste u hardverskoj realizaciji, rade brže nego pojedinačni neuron (nervni signali su spori), ali je mozak zbog velike povezanosti neurona i paralelnog procesiranja, brži od veštačkih neuronskih mreža. Sa druge strane, pogodnosti koje nudi veštačka neuronska mreža su mogućnosti distribuiranja problema na više nivoa i više odvojenih faza, realizacije više paralelnih mreža i u krajnjem slučaju zamenljivost [2],[13], [14], [3], što su karakteristike koje nedostaju mozgu. Takođe, kada se jednom napravi logika rada i nađe adekvatan način za rešavanje problema [1], svaka naredna mreža se može napraviti vrlo brzo, dok obuka novog biološkog mozga da reši probleme nekog prethodnog (uz skup svih potrebnih znanja) traje godinama.

Ljudski mozak je veoma složen i kompleksan, pa su njegov rad i zakoni obrade informacija još uvek neistražena oblast [5]. Prosečan ljudski mozak sadrži oko 10^{11} neuronskih ćelija sa izuzetno velikim brojem veza između njih. U ljudskom nervnom sistemu su, pored inicijalnih impulsa, za rešavanje određenog problema bitne i hemijske relacije koje nisu u potpunosti upravljive. Iz tog razloga pokušaj kompletne simulacije i detaljno praćenje procesa rada predstavlja vrlo kompleksan, težak i nemoguć problem.

Na sreću, pokazalo se da za pojedine grupe problema može da se pronađe rešenje koje je zadovoljavajuće, pa vrlo često i bolje, ili brže, u odnosu na primenu algoritamske logike računara. Danas veštačke neuronske mreže imaju veliku primenu u rešavanju optimizacionih problema, kontrole tokova signala, upravljanja, prepoznavanja slike i glasa i drugih vrlo sofisticiranih problema [15], [16],[3],[17], [18], [19], [5], [20].

Imajući u vidu da je veštačka neuronska mreža pokušaj kopije biološkog nervnog sistema, proces rada se ne može smatrati jednoznačnim, unapred predvidivim i u potpunosti upravljivim. Ovako složen sistem odluke donosi na bazi određene logike, ali i iskustva koje je dobijeno u različitim fazama učenja [2], [13], [14], [3]. U fazama učenja neuronska mreža koristi karakteristiku mozga da memoriše određene podatke od interesa i da u konkretnoj situaciji, na bazi tog znanja, i određenih pravila, donese konačnu odluku [18]. To je razlog što se veštačke neuronske mrežene kreiraju za rešavanje jednog, striktno definisanog zadatka, ali se nakon obuke mogu primeniti na čitavu lepezu sličnih ulaznih podataka i dati odgovarajuće rešenje [4], [2].

Sa druge strane kompjuter može da reši probleme samo ako imaju unapred definisanu metodologiju, što u mnogome ograničava sposobnost rešavanja problema. To implicira da se algoritam kreira fiksno, za tačno definisani problem i sa tačno definisanim postupcima u svakoj od iteracija.

U proseku neuron u mozgu radi brzinom od 100 Hz, što je relativno sporo u poređenju sa kompjuterom koji u sekundi izvrši nekoliko miliona instrukcija. Zajedničko paralelno procesiranje svih prirodnih neurona u mogućnosti je da realizuje bilo koji proces neuporedivo brže od najbržih super računara, iako je brzina rada bioloških neurona reda milisekundi, u poređenju sa brzinama tranzistora koje su čak i ispod reda nanosekundi.

Uprkos toj maloj brzini u poređenju sa kompjuterom, biološka neuronska mreža može da izvede neke zadatke kao što je prepoznavanje, planiranje i upravljanje sa neobičnom lakoćom u odnosu na kompjuter. Razlog leži u velikoj međusobnoj povezanosti neurona i paralelnom procesiranju signala. Ova prednost donosi još jednu veliku razliku između kompjutera i biološkog nervnog sistema. Naime, većina kompjutera ne može biti korisna ako je samo jedna od komponenti oštećena dok je neuronska mreža u mogućnosti da dobro funkcioniše iako postoji značajno oštećenje delova mozga [21],[2].

Osnovni rival veštačkim neuronskim mrežama je klasični računarski program. Razlike između ova dva sistema su izuzetno velike. Konvencionalni računari rade na logičkoj osnovi, sekvencijalno, deterministički ili sa vrlo niskim stepenom paralelizma. Ovi programi zahtevaju promenu svaki put kada se tip problema ili okruženja minimalno promeni. Promene su skupe, i u zavisnosti od problema i dugotrajne. Ako se naprave uporedne karakteristike pojedinih veličina [21], [22], tada se dobijaju podaci prikazani u Tabeli 2.1.

Kompjuter može biti pogodniji za rešavanje algoritamski opisanih problema dok su biološke neuronske mreže pogodnije za nealgoritamske probleme kao što je klasifikacija, prepoznavanje i odlučivanje. U tom smislu su i veštačke neuronske mreže dobri kandidati za rešavanje istih, s obzirom da se pojavljuju kao „naslednici“ bioloških sistema.

Tabela 2-1 Mozak naspram kompjutera, poređenje karakteristika

	Element	Veličina [m]	Brzina [Hz]	Arhitektura	Tolerancija greške	Sposobnost učenja	Energija u toku jedne iteracije [J/s]
Mozak	10^{11} neurona	10^{-6}	100	Paralelna, distribuirana	Da	Da	10^{-6}
Kompjuter	10^8 tranzistora	10^{-7}	10^9	Serijska, centralizovana	Ne	Mala	10^{-6}

Pored neuronskih mreža, postoje još neki napredni sistemi koji imaju svojstvo da rešavaju probleme na osnovu nedovoljno čvrsto postavljenih pravila. Najpoznatiji su genetski algoritmi, fazi

logike, adaptivne memorije, asocijativne memorije i slično, ali su se neuronske mreže do sada pokazale najprihvatljivijim i najadaptivnijim [23],[12], [7], [13].

Neke od karakteristika veštačkih neuronskih mreža mogu se klasifikovati kao [2], [13], [14], [3]:

1) Neuronske mreže se koriste sa ciljem paralelnog (asinhronog ili sinhronog) distribuiranog procesiranja.

2) Mreža je fleksibilna i relativno malo osetljiva na ispad izvesnog broja neurona.

3) Sama se prilagođava promenama i stanjima koje uči i vrlo je imuna na najveći od problema savremenih sistema - šum.

4) Kao što je slučaj i u biološkim mrežama, svaki memorijski element je delokalizovan – raspodeljen je po celoj mreži, što dodatno povećava sposobnost rada mreže u slučaju prekida nekih veza među neuronima ili prestankom rada neurona. Iz tog razloga u neuronskim mrežama ne postoji klasično adresiranje, čime se sve manje nameću stroga pravila upotrebe klasičnih programskih paketa.

5) Svakako treba istaći da se u realizacijama veštačkih neuronskih mreža ne mogu postići brzine bioloških, jer je kompleksnost ovih mreža još uvek veliki tehnološki problem. Činjenica je međutim da je u složenim postupcima i obradama velikog broja podataka, neuronska mreža brža od konvencionalnih računarskih sistema, i da poseduje osobinu bolje stabilnosti u toku rada.

Brzina mreža svakako predstavlja važan segment, naročito kada se govori o mrežama koje zamenjuju uticaj čoveka. S obzirom da veštačke mreže mogu obraditi mnogo više informacija nego biološke, jer se mogu multiplicirati, eventualna sporost naspram bioloških bi se ovim načinom bar delimično izbegla.

2.2. Razvoj veštačkih neuronskih mreža

Prvi koraci u razvoju modela neurona realizovani su i opisani u [11]. Nakon istraživanja Hebb-a o zakonima ponašanja, dolazi do korenite promene u logici povezivanja veštačkih neurona, jer se uviđa da je logika rada neurona podjednako bitna kao i veze između njih. Kasnije je zaključeno da ove veze imaju različite efekte, i da nisu sve iste. Naime, ove veze zavise od vrste i jačine pobude, čime se uviđa jedan od koraka memorisanja i zaboravljanja informacija. Savremena neurologija je pokazala da se i među biološkom neuronima, veze stvaraju, pojačavaju-slabe i nestaju u zavisnosti od intenziteta i učestalosti kojom one prenose informacije od značaja. Na taj način, priroda je i u mozgu napravila selekciju među „boljim“ i „lošijim“ vezama, unoseći dinamiku u njihovo nastajanje ili nestajanje. Hebb-ova hipoteza tvrdi da promena sinaptičkih težina, u

procesu učenja, ima glavnu ulogu u mehanizmu skladištenja informacija u biološkim neuronskim mrežama što je i kasnije pokazano [14].

Oko 1950. godine Frank Rosenblatt pronalazi jednoslojnu neuronsku mrežu poznatu pod nazivom *perceptron* [24]. Perceptron je bio dvoslojna mreža sa sposobnošću učenja određenih vrsta klasifikacije, podešavanjem težinskih vrednosti koje su bile dodeljene vezama neurona. Veliko ograničenje unosi to što model perceptrona nije bio u mogućnosti da implementira *XOR* funkciju s obzirom da nije imao sposobnost da klasifikuje nelinearne razdvojive modele (elemente). Međutim, nedostaci ovog modela su prevaziđeni već 1958. godine kada su Frank Rosenblatt i Charles Wightman razvili prvi pravi neuroračunar. U tom periodu i Bernard Widrow razrađuje novi tip neurona poznat kao *ADALINE (ADaptive LINear Element)*, sa prenosnom funkcijom $f(x)=x$, ali i odgovarajući zakon učenja [14].

U sedamdesetim godinama, pojavljuje se novi talas istraživača koji su dali veliki doprinos ovoj oblasti. Među njima su i Kohonen, Fukushima, Grossberg, Amari, Bryson, Ho, Werbos, Parker i drugi. Tada se pojavljuju samoorganizujuće mreže, njihove poboljšane verzije, dodatni slojevi za perceptron i slično. Početkom 80-ih, američka vojna agencija DARPA (*Defense Advanced Research Projects Agency*) postaje vrlo zainteresovana za neuronske mreže i ponovo se započinje intenzivno finansiranje istih [25]. Osamdesetih godina John Hopfield pravi veliki doprinos povezujući neuronske mreže sa fizičkim sistemima i veličinama, čime ih čini potencijalnim kandidatima za realne probleme. Devedesetih godina Bart Kosko dokazuje da neuronske mreže i fazi logika definišu istu grupu problema čime se započinje intenzivna primena ove logike u računarskim sistemima. Početkom devedesetih svi veći američki univerziteti uvode izučavanje neuronskih mreža u klasični nastavni program čime njihovo istraživanje počinje da biva sve masovnije. Danas skoro da nema oblasti gde se primenjuje veštačka inteligencija, a da nije analizirana primena veštačkih neuronskih mreža [26], [9], [27]. Shodno tome, može se zaključiti da se ova problematika ipak svrstava u red vrlo mladih i samim tim punim novih neistraženih mogućnosti koje nas očekuju.

2.3. Osnovne komponente neuronskih mreža

Kao što je već rečeno, postoje dve kategorije neuronskih mreža: biološke i veštačke neuronske mreže. Biološke neuronske mreže su nervni sistemi živih bića koja imaju složeniji neurološki profil. Biološki nervni sistem čoveka, sa posebnim akcentom na mozak, najčešći je uzor za realizaciju veštačkih neuronskih mreža. Kao najsvesnije biće, i sa najvećim stepenom razvoja, ljudski mozak predstavlja najviši evolutivni stepen razvoja, i kao takav je nedovoljno istražen i upraviv, Slika 2.1. I pored toga, bazična znanja o strukturi i načinu rada ljudskog mozga su bili dovoljni da se na osnovu njih kreiraju modeli i realizuje veštački neuron [3], [4].



Slika 2-1 Mozak čoveka (<http://humannhealth.com>)

Poznavanje strukture mozga je od izuzetnog značaja, jer se ista pokušava realizovati u veštačkim mrežama. Model biološkog neurona sadrži uvek istu grupu elemenata kojima se povezuje za ostale neurone ili koje su njegov individualni deo. Ova vizuelizovana struktura prikazana je na slikama 2.2 i 2.3.




Slika 2-2 Grafička interpretacija izgleda a) jednog neurona



Slika 2-3 Grafička interpretacija izgleda međusobne povezanosti neurona (www.3dscience.com).

Neuron je osnovni element neuronske mreže [5],[14]. Neuron ima svoje ulaze i svoj izlaz. Ulazi neurona su dendriti. Prirodni neuroni imaju po nekoliko stotina dendrita. Dendrit se sa neuronom spaja preko sinapse. Neuronski izlaz naziva se akson, koji se dalje grana na aksonske ogranke i završne tačke, kojima informaciju iz neurona prosleđuje novim dendritima. Struktura biološkog neurona prikazana je na slici 2.4. [28]. Na ovaj način lako se uočava pojava slojevite organizacije jer izlazi jedne grupe neurona (sloja) predstavljaju ulaze nove grupe [14].



Slika 2-4 Struktura biološkog neurona

Veštačke neuronske mreže su po strukturi, funkciji i obradi informacija slične biološkim neuronskim mrežama, ali se radi o veštačkim tvorevinama [2]. One su napravljene po uzoru na biološke, a direktno ih kreira i proizvodi čovek. Shodno tome biološki i veštački neuroni imaju skoro isti konceptijski sastav, samo se načini realizacije pojedinih funkcija razlikuju. Iz tog razloga, razvoj neuronskih mreža, u smislu njihove realizacije, biće sve kvalitetniji jer direktno zavisi od razvoja tehnologije. Ne treba isključiti mogućnost da će se u nekom trenutku kroz realizacije veštačkih neuronskih mreža možda prevazići i neki od problema u biološkim mrežama, na koje se nimalo ili vrlo malo može uticati. Sa druge strane, dalji naučni pomaci u razvoju i otkrivanju tajni bioloških mreža i mozga, u smislu načina rada i memorisanja podataka, omogućiće brži razvoj i implementaciju veštačkih neuronskih mreža u naučne i inženjerske svrhe.

Shodno strukturi bioloških neurona, može se kreirati model, a zatim i fizička realizacija veštačkog neurona. Shodno strukturi na slici 2.4. može se napraviti „grub“ model veštačkog neurona prikazan na slici 2.5. Na slici 2.5. simbolom φ predstavljena je težinska suma i aktivaciona funkcija primenjena na težinsku sumu. Polazeći od ovog modela može se kreirati i razviti oblik koji uključuje sve potrebne parametre za simulaciju rada biološkog neurona. Ovakav model prikazan je na Slici 2.5.

gde su:

x_i – ulazni podaci dendrita (ulazi veštačkog neurona),


w_j – težinski koeficijenti dendrita,

$\varphi(v_j)$ – aktivaciona funkcija,

y_j (akson i njegovi ogranci) – izlazi neurona i

v_j - težinska suma ulaza x_i .

Kao i biološki neuron, i veštački ima dendrite, sinapse i aksone. Sada se uticaj bioloških veza menja uticajem pojedinih konstanti na rad neurona. Ovo se najviše odnosi na promene i opis rada sinapsi kroz sinaptičke težine.



Slika 2-5 Model veštačkog neurona

Preko svakog od dendrita stiže neka informacija koja se prosleđuje neuronu. Fizički posmatrano nisu sve informacije od dendrita podjednako bitne. Pojedini dendriti nose različite informacije, ali na izlazu treba da se pojave uticaji onih koji su, za dati proces, validni. Ova osobina simbolično se kontroliše sinaptičkim težinama, koje su brojne vrednosti, i kojima se množi informacija sa dendrita. Nakon sinapsi sve skalirane veličine od dendrita stižu se u neuron gde se zbirno posmatraju. Ako ova suma ima vrednost koja je iznad praga posmatranog neurona, neuron će biti efikasan, i pomenuti signal modifikovati svojom funkcijom φ . Funkcija φ simboliše inteligentnu funkciju mozga. Kao takva ova funkcija prenosa φ mora biti ograničena i neopadajuća [14].

Generalno posmatrano, kreiranje namenske veštačke neuronske mreže za rešavanje konkretnog problema zahteva izbor funkcije kojom će se menjati sinaptičke težine i funkcije samih neurona [29]. U zavisnosti od tipa problema, mreže mogu da omoguće dva pristupa u rešavanju: princip razvrstavanja (*Classification*) i princip pridruživanja (*Association*) [30].

Princip razvrstavanja koristi karakteristike ulaznih podataka da bi pronašao sličnosti među njima i na taj način ih grupisao u manje grupe. Na ovaj način svi podaci na ulazu se dele u određen broj grupa, čime se mreža obučava na postojanje konačnog broja celina. Svaki novi podatak koji se pojavi na ulazu biće dodeljen nekoj od ranije formiranih grupa i na taj način klasifikovan u odnosu na prethodno naučene karakteristike te grupe.

Princip pridruživanja, sa druge strane, daje mogućnost rekonstrukcije ulaznog signala ili podatka koji je oštećen u prenosu ili degradiran šumom. Na ovaj način prepoznaje se i pretpostavlja deo koji nedostaje. Ovakav vid pridruživanja poznat je kao auto-pridruživanje. Sa druge strane, ulazni podatak može biti promenjen u samoj mreži i kao takav dodeljen nekoj grupi na izlazu mreže. Ovaj način pridruživanja naziva se hetero-pridruživanje. Bez obzira koji princip se koristi, ovaj vid rada mreža iskazuje upotrebu funkcija prenosa kao uvod u rešavanje problema memorisanja informacija u mozgu.

2.4. Način rada veštačke neuronske mreže

Haykin je opisao nekoliko važnih svojstava veštačkih neuronskih mreža (ANN *Artificial Neural Network*) [14], [3]:


1. ANN mogu biti linearne i nelinearne. Mnoge pojave u prirodi su nelinearne i važne su.
2. ANN uči tako što stvara relacije između ulaznih i izlaznih podataka.
3. ANN ima sposobnost da prilagođava težinske koeficijente sa promenama stanja na mreži.
4. Svaki neuron u mreži je pobuđen aktivnošću drugih neurona.
5. ANN ima sposobnost da se samoorganizuje, sačuva i distribuira informacije koje je primila tokom procesa učenja.
6. Paralelna priroda ANN čini je pogodnom za implementaciju u moderne elektronske komponente (VLSI), i kao takvom vrlo otpornom na greške.

U poglavlju 2.3. je objašnjeno kako se biološki neuron može modelirati i realizovati pomoću neurona veštačke neuronske mreže. Da bi mreža činila celinu pored jednog neurona mora postojati način da se kreira i poveže proizvoljan broj novih, koji treba da zadovolje navedena svojstva sa ciljem da kreiraju sredstvo koje može da donosi neke zaključke.

Ono što predstoji je da se definišu međusobni odnosi neurona, aktivacione funkcije neurona i definiše način učenja kome će se mreža podvrgnuti. U tom smislu, model veštačke neuronske mreže može se raščlaniti na tri segmenta [14]:

1. Arhitektura mreže,
2. Aktivaciona funkcija neurona i
3. Zakoni učenja.

Arhitektura mreže podrazumeva način vezivanja pojedinih neurona u celoj mreži. Zbog neophodne sistematizacije velikog broja neurona, svaka mreža je organizovana u slojeve [31]. Svaki sloj je celina za sebe i neuroni unutar jednog sloja obavljaju tačno određenu funkciju. Svi slojevi su međusobno povezani, pri čemu su izlazi jednog sloja ulazi sledećeg, i tako dalje. Generalno gledano, mreže se klasifikuju u tri sloja: ulazni, izlazni i skriveni [32], [2]. Označavanje ovih slojeva najčešće je prvim slovom engleskih reči. Tako su neuroni ulaznog sloja označeni sa *i* (*input*), skrivenog sa *h* (*hidden*) i izlaznog sa *o* (*output*). Ulazni i izlazni sloj su oni slojevi kojima se podaci uvode ili uzimaju iz mreže dok je skriveni sloj međusloj kojim se tražena funkcija realizuje.



Slika 2-6 Prikaz slojevite arhitekture veštačke neuronske mreže.


Skriveni sloj može imati proizvoljan broj podslojeva u zavisnosti od potreba i kompleksnosti date mreže. Broj slojeva unutar skrivenog sloja (h_i) direktno se odražava na mogućnost rešavanja problema. Naime, kod postavljanja veštačke neuronske mreže jedan od prvih koraka predstavlja i definisanje broja slojeva potrebnih da dati problem reši. Tek nakon toga, definišu se međusobne veze i matematičke funkcije koje ih opisuju. Najčešće se u reprezentaciji mreže skriveni sloj crta kao jedinstven sloj, jer se time smanjuje kompleksnost crteža. Na slici 2.6. prikazana je struktura jedne veštačke neuronske mreže, kod koje je skriveni sloj predstavljen sa dva sloja, dok su ulazni i izlazni sloj predstavljeni sa različitim brojem ulaznih, odnosno izlaznih (neurona) signala. Broj ulaznih (i_i) i izlaznih (o_i) signala može, ali i ne mora, biti isti. U zavisnosti od problema koji se rešava, i strukture mreže koja je izabrana, ove dve veličine se izračunavaju ili su definisane početnim problemom [29].

Aktivaciona funkcija neurona – predstavlja matematičku funkciju kojom neuron, ukoliko reaguje na prispelu informaciju, menja ulazni signal, i kao takav ga predaje ostalim neuronima. Definiše se na ulazu u mrežu i direktno zavisi od problema koji se rešava i dinamike signala koji se obrađuje. U savremenim veštačkim neuronskim mrežama, kao matematička interpretacija, funkcija prenosa najčešće se koristi u obliku [14], [32]:

1. Odskočne (Hevisajdove) funkcije,
2. Logičke funkcije sa pragom i
3. Sigmoidalne (logaritamske, *arctan*-ne ili Gausove) funkcije.


Odskočna (Hevisajdova) funkcija je funkcija čija se vrednost u trenutku t promeni sa vrednosti 0 na 1. Promena se posmatra kao trenutna. Kao takva, ne može se u potpunosti realizovati realnim sistemima, ali je njena blaga aproksimacija realno izvodljiva u brzim sistemima. Stanjima 0 i 1 simbolično se označava stanje neurona kao neaktivno, tj. aktivno. Ovakav model se pojavio 1943. godine od strane neurofiziologa McCulloch-a i Pitts-a. Oni su stanje neurona posmatrali kao isključiva stanja u smislu nadražaja. Ako nadražaj postoji neuron je pobuđen i treba da obavi neku svoju funkciju, i suprotno. Pokazalo se da ovaj model predstavlja skromno ali za neke probleme

efikasno rešenje, naročito ako se ima u vidu pojednostavljenje matematičkog modela upotrebom odskočne funkcije. Na slici 2.7. prikazana je odskočna funkcija gde promenljiva v predstavlja ulazni signal.



Slika 2-7 Grafički prikaz aktivacione funkcije odskočnog tipa


Logička funkcija sa pragom je slična odskočnoj, ali postoji vremenski deo u kome se dešava pomenuta promena. Ovim se predstavlja promena stanja u realnim vremenskim sistemima, što odgovara krajnjim implementacijama. Na ovaj način možese definisati prag nakon koga se tumači promena stanja, iako ona fizički ne dostiže vrednost 1. Opseg vrednosti prelaznog dela se definiše shodno potrebama u konkretnom slučaju, ali najčešće se uzima simetrični opseg $-x$ do x , dok su -1 i 1 krajnje granice intervala od interesa. Ova funkcija je često korišćena i iz razloga što predstavlja aproksimaciju nelinearnog pojačavača, koji se inače i koristi u praktičnoj realizaciji aktivacione tj. funkcije prenosa. Na slici 2.8. prikazana je funkcija sa pragom koja ima granične vrednosti 0 i 1.



Slika 2-8 Grafički prikaz logičke aktivacione funkcije sa pragom.


Sigmoidalna funkcija, Slika 2.9, obuhvata veći broj dobro poznatih funkcija. Ove funkcije se najčešće primenjuju kao aktivacione funkcije zahvaljujući svojoj početnoj nelinearnosti koja odgovara funkcijama električnih komponenti potrebnih za realizaciju. Međutim, najvažnija karakteristika je da se, promenom jednog parametra ovih funkcija, nagibi krivih menjaju. Na taj

način promena parametra direktno utiče na nagib krive čime se izlazni signal direktno modifikuje. Time se aktivacija jednog neurona čini dinamičkom, a samim tim i sposobnom da, u različitim početnim uslovima, kreira različite izlazne signale.



Slika 2-9 Grafički prikaz aktivacione funkcije sigmoidalnog tipa.

Na slici 2.10. prikazana je sigmoidalna funkcija sa različitim parametrima. Parametar α određuje nagib funkcije. Za veće vrednosti parametra a sigmoidalna funkcija sve više teži odskočnoj. Ova funkcija može biti realizovana i na neki drugi način, kao što je tangens hiperbolički, ali uvek zadržava osobine diferencijabilnosti na celom domenu što je važno za mnoge primene u analognim veštačkim neuronskim mrežama [14].



Slika 2-10 Grafički prikaz sigmoidalne funkcije za različite vrednosti parametra α .

Funkcije prenosa neurona ili aktivacione funkcije su neophodne da bi mreža mogla da nauči nelinearne funkcije. Ako toga ne bi bilo sve mreže bi bile na nivou perceptrona koji ima jedan ulaz i jedan izlaz. Drugi razlog za upotrebu nelinearnih funkcija je i pojava da se od kombinovanja ulaznih linearnih funkcija na izlazu svakako, kao posledica, dobija nelinearna.

Zakoni učenja - Učenje u neuronskim mrežama predstavlja ključni proces kojim se one razlikuju od klasičnih računarskih pristupa [7]. Samo učenje mreže podrazumeva proces podešavanja i korekcije vrednosti težinskih koeficijenata na sinapsama [18]. Ukoliko se nekim dendritom šalje više informacija neuronu, težinski koeficijent sinaptičke veze tog dendrita je sve

veći, i obrnuto (što odgovara biološkim neuronskim mrežama i Hebb-ovom učenju). Na ovaj način neuron uči sa koje strane se pojavljuju informacije od značaja i koji „put ih donosi“. Ukoliko se nekim putem skoro nikada ne šalju informacije on polako „iščezava“, čime se njegov značaj smanjuje i sve je manja verovatnoća da će pojava neke informacije u njemu moći da promeni konačnu odluku. Eksitacijom ili inhibicijom nekih veza među neuronima pravi se razlika između manje-više bitnih informacija, dobro ili pogrešno naučenih i slično. Čovek svoje iskustvo i znanje stiče celog života, i na taj način sve više učvršćuje veze koje definišu informacije od interesa, dok proces zaboravljanja podrazumeva slabljenje ili uništenje neuronskih veza za slabo korišćene podatke. Kod veštačkih neuronskih mreža obučavanje se vrši skupom ulaznih parametara u zavisnosti od problema koji se rešava [33], [34]. Ovaj skup treba da bude što je veći moguć, da bi mreža imala više prilike da pronađene zakonitosti, i sličnosti ojača sinaptičkim težinama. Iz tog razloga ovaj skup se često naziva trening skupom, i trebalo bi da sadrži sve reprezentativne uzorke za koje se mreža želi obučiti. Izostavljanje nekog uzorka može proizvesti da mreža nije u stanju da na odgovarajući ulazni signal odreaguje kako treba, ili da se delimično prilagodi i pokuša da „razume“ šta se od nje zapravo traži. Zbog realne pretpostavke da se nikada ne može napraviti takav trening skup koji bi sadržao sve moguće kombinacije, a naročito za složene probleme koji se rešavaju, procedura učenja, odabir trening skupa i način kontrole rezultata u toku rada, ima veliku ulogu u radu mreže. Kako se svi ovi koraci podvode pod fazu učenja, direktno se nameće stav o važnosti i sofisticiranosti ove faze u kreiranju veštačke neuronske mreže [4].

Obučavanje se najčešće deli na tri kategorije: nadgledano (*supervised*), nenadgledano ili samoorganizujuće (*selforganizing*) i delimično nadgledano [23]. Postoje i druge podele [14], [2] u kojima se ističu i hibridne varijante navedenih kategorija. S obzirom na problem koji se u ovom radu istražuje zadržaćemo se na osnovnoj podeli na tri navedene kategorije.

2.5. Realizacija veštačkih neuronskih mreža

Svaka neuronska mreža može se realizovati hardverski i softverski. Hardverski realizovane veštačke neuronske mreže su analogne, pa se svaki problem pomoću njih rešava u paralelnom procesiranju. Sam rad tih mreža može biti taktovan.

Najvažnije karakteristike veštačkih neuronskih mreža su:

1. Nema striktno definisanog algoritma, već se mreža obučava na osnovu trening skupa,
2. Raspodeljena memorija i
3. Paralelno procesiranje.

Softverska realizacija podrazumeva realizaciju na postojećim računarima pri čemu su neuroni i veze među njima virtuelni. S obzirom da se hardverskim neuronskim mrežama razvijaju postupci različiti od metoda zasnovanih na računarima, svaka softverska implementacija predstavlja relativno loše rešenje. Ova rešenja pokušavaju da objedine dve bazično suprotne metode, što često daje lošije rezultate nego što bi se dobilo hardverskom realizacijom. Isto tako, softverska implementacija zavisi od brzine rada i tehničkih karakteristika računara. Kako se veštačke neuronske mreže koriste za rešavanje kompleksnih problema, vreme potrebno za obradu na klasičnim računarima često je nerealno dugo, čime i rešenje gubi na smislu. Iz tog razloga softverska realizacija se koristi kao test faza, dok se za konkretne realizacije u praksi koristi hardverska. Sa druge strane, hardverska realizacija podrazumeva složen i često skup postupak, koji je za probne ili interne potrebe neisplativ. Zato se nakon svih probnih faza u softverskoj realizaciji prelazi na hardversku, pa se često ne može ni govoriti o podeli nego integraciji ove dve vrste realizacije. Bez obzira da li se hardverska realizacija izvodi za masovnu ili individualnu potrebu, organizacija veštačke mreže i njena izrada su uvek iste. U tom smislu postoji tačno definisan postupak izrade i delova koji se kasnije povezuju [30]. Osnovni delovi hardvera koji opslužuje veštačku neuronsku mrežu su:

- Interfejs,
- Sinapse,
- Neuroni,
- Veze među neuronima i
- Proces učenja.

Interfejs treba da omogući dovođenje spoljašnjih signala u veštačku neuronsku mrežu, i omogući njihovo odvođenje kao krajnjeg rezultata. U zavisnosti od problema koji se rešava, interfejs se mora prilagoditi ne samo vrsti signala nego i broju ulaznih neurona, koji nekada može biti relativno veliki, čime se realizacija usložnjava.

Sinapse treba da omoguće unutrašnju promenu signala koja je zasnovana na uticaju ostalih neurona mreže, skaliranih težinskim koeficijentima.

Neuroni treba da omoguće sumiranje svih signala koji se u njega stiču, njihovu modifikaciju i uslove za njegovo aktiviranje posredstvom praga odlučivanja.

Veze među neuronima treba da omoguće prenos signala, uz minimalnu degradaciju, nezavisno jedan od drugih. Ovo spada u veoma komplikovane probleme u realizaciji imajući u vidu da u opštem modulu svaki neuron treba da bude spojen sa svim ostalima u mreži [3], [18], [34].

Na kraju, učenje predstavlja proces adaptivnog menjanja sinaptičkih težina shodno trening skupu ulaznih signala. Više detalja o realizaciji mreža, koja nije predmet istraživanja ove teze, može se naći u literaturi [30].

2.6. Klasifikacija veštačkih neuronskih mreža

Veštačke neuronske mreže mogu se klasifikovati u mnogo kategorija shodno parametru po kome se klasifikacija vrši. Neki od parametara koji fundamentalno utiču na organizaciju i rad mreže su [27],[13], [14], [18], [4]:

1. Broj slojeva,
2. Vrsta veza između neurona,
3. Vrsta obučavanja neuronskih mreža,
4. Smer prostiranja informacija,
5. Vrsta podataka koja se obrađuje.


Shodno ovim parametrima, svaka mreža može se klasifikovati u neku od grupa koje povezuju slične parametre. Teško je govoriti o standardizovanoj podeli, jer se mreže neprestano razvijaju. U literaturi postoji veliki broj autora koji su dali svoje viđenje klasifikacije, a u ovom radu biće izložena podela koja se pojavljuje kao zajednička kod većine autora.

1. *Prema broju slojeva* mreže mogu biti jednoslojne i višeslojne. Jednoslojne mreže mogu se dalje deliti u zavisnosti od broja neurona, što odgovara mrežama realizovanim za rešavanje prostijih problema, dok se za veliki broj međuslojeva koristi termin višeslojne.

2. *Prema vrsti veza* između neurona mogu se izdvojiti sledeće grupe: slojevite, potpuno povezane, lestvičaste i celularne. Moguće su i kombinacije nekih od navedenih grupa.


Slojevite mreže organizovane su u slojeve, tako da su izlazi jednog sloja ulazi sledećeg. Ovo je primenjeno kod realizacije ranije opisanog *backpropagation* algoritma. Na ovaj način tok signala kroz mrežu može se posmatrati sekvencijalno, dok je mreža pored logičke i strukturalno lako kontrolisana u postupku nadgledanja.

Potpuno povezane mreže su one mreže gde izlaz jednog neurona vodi ka ulazima ostalih u mreži. U ovom slučaju organizacija mreže se usložnjava, pogotovo imajući u vidu da se i neuroni izlaznog sloja povezuju sa neuronima ulaznog. Na ovaj način formira se petlja, i signali se teže nadgledaju. Ovakav tip neuronskih veza primenjen je i u realizaciji Hopfield-ovih mreža.



Slika 2-11 Grafički prikaz lestvičaste jednodimenzione mreže.

Kod lestvičastih mreža postoje jednodimenzione, dvodimenzione i višedimenzione grupe polja neurona. Svaki od ulaza spojen je na sve ulaze neurona u tom polju. Izlaz iz polja može biti izlazni sloj, ili predstavljati ulaz novom polju neurona. U tom slučaju govori se o višedimenzionalnim grupama polja. Za razliku od potpuno povezanih mreža, ova mreža je bez povratne sprege, gde su neuroni raspoređeni u polja koja čine neku logičku celinu, slika 2.11.



Slika 2-12 Grafički prikaz 2-dimenzionalne celularne neuronske mreže.


Kod celularnih veza povezani su samo susedni čvorovi. Susednost čvorova definisana je logičkim vezama, dok se u nekim slučajevima može govoriti i o fizičkim blizinama. Ovakav tip veza među neuronima primenjen je kod celularnih neuronskih mreža (CNN), slika 2.12. Na svaku ćeliju utiče ograničen broj ćelija iz njenog okruženja. I upravo ta lokalizovanost veza između jedinica predstavlja glavnu razliku između celularnih neuronskih mreža i drugih neuronskih mreža.

3. *Prema vrsti obučavanja* veštačke neuronske mreže se mogu podeliti na:

1. Nadgledano obučavanje - *Supervised training*,
2. Delimično nadgledano obučavanje i
3. Nenadgledano obučavanje - *Unsupervised training*.

U poglavlju 2.4. je objašnjen značaj i problem obučavanja veštačkih neuronskih mreža.

4. Prema smeru prostiranja informacije u mreži mogu biti sa prostiranjem unapred (*feedforward*), kod kojih viši slojevi ne vraćaju informaciju u niže slojeve, ili sa prostiranjem unazad (*backward*), gde viši slojevi vraćaju informacije nazad u niže slojeve. U literaturi se mreže sa prostiranjem unapred mogu naći i pod nazivom nerekurzivne, nerekurentne ili nepovratne, dok se mreže sa prostiranjem unazad mogu naći kao rekurzivne, rekurentne ili povratne [14], [4], [34]. U mrežama sa prostiranjem unapred, najvažniju ulogu igraju prioriteti slojeva. Kako se tačno zna, koji sloj predaje kom sloju informacije, tačno se zna i tok signala. Ovakvom organizacijom postiže se velika stabilnost i brzina rada mreže.



Slika 2-13 Grafički prikaz rekurentnih mreža.

Kod mreža sa povratnom spregom (*feedback*) postoji izražena upotreba povratnih veza. Uvođenjem rekurzije direktno se utiče na stabilnost rada mreža. Iz tog razloga kod ovih mreža u samom početku treba očekivati pojave stabilnih i nestabilnih stanja. Sa druge strane, baš ovakva struktura mreža pokazuje se vrlo dobro u implementacijama koje zahtevaju primenu asocijativne memorije i rešavanje problema optimizacije, jer u iteracijama mogu same sebe dovesti u stanje koje obezbeđuje kvalitetno rešenje. Uvođenje povratne reakcije direktno dovodi i do povećanja efikasnosti mreže, jer se stanja koja nisu validna u svakoj sledećoj iteraciji brišu.

Najpoznatije mreže sa povratnom spregom su Hopfield-ova neuronska mreža, Jordan-ova neuronska mreža i Elman-ova neuronska mreža, čije su strukture prikazane na slici 2.13.

5. Prema vrsti podataka mreže mogu biti analogne i digitalne. Ova podela je direktno uslovljena prirodom signala koji se koriste. Interesantno je istaći da, za razliku od savremenih primena digitalne tehnike, i sve većeg potiskivanja analogne, analogne mreže mogu dati čak i bolje rezultate. Ovo je posebno važno kod specifičnih signala kojima konverzija u digitalni može degradirati originalnu strukturu signala.

Neuronska mreža se razlikuje od tradicionalnih računara (PC računara, radnih stanica, i mainframe računara) u formi i funkcionisanju. Dok neuronska mreža koristi veliki broj jednostavnih procesora da bi obavila njene kalkulacije, tradicionalni računari koriste jedan ili, u ređim slučajevima, svega nekoliko veoma kompleksnih procesorskih jedinica. Neuronska mreža ne poseduje centralno lokalizovanu memoriju, niti se programira sekvencama instrukcija, kao svi tradicionalni računari.

Klasični računari koji rade na binarnoj logičkoj osnovi, koriste algoritamski način obrade podataka (sekvencijalni) sa veoma niskim stepenom paralelizacije. U algoritamskom načinu obrade podataka računar obrađuje jednu po jednu informaciju ili u boljem slučaju obrađuje manji broj informacija u isto vreme. Za razliku od ovog pristupa obrade podataka, neuronska mreža procesira istovremeno više informacija, tj. najbolja varijanta za neuronsku mrežu je da je svaki neuron po jedan procesor. Razvoj neuronskih mreža je doveo do novih arhitektura računara koji se u mnogome razlikuju od računara kakvi su danas rasprostranjeni. Ako bismo posmatrali primer prepoznavanja slova, algoritamsko rešenje bi zahtevalo da se zadato slovo uporedi sa svim slovima u bazi, slovo po slovo, dok neuronska mreža može da uporedi zadato slovo istovremeno sa svim slovima, a rešenje je slovo sa najvećom verovatnoćom. Ovo je moguće jer se memoriji pristupa uz pomoć sadržaja, a ne adrese.

Kod klasičnih računara su elementi obrade informacija i elementi memorisanja informacija potpuno odvojene komponente. Kod neuronske mreže memorisanje i obrada predstavljaju jednu kompaktnu celinu. Podaci koji su vezani za rad neuronske mreže nemaju nikakav smisao bez jedinica obrade.

Neuronska mreža se razlikuje od tradicionalnih računara po načinu na koji se "programira". Umesto programa napisanih kao serije instrukcija, kao što to rade klasični računari, može se upotrebiti obučena neuronska mreža, gde arhitektura i težinski koeficijenti određuju njenu funkciju. Koeficijenti se podešavaju tokom obučavanja na ograničenom skupu karakterističnih primera. Kada se mreža obuči do zadovoljavajuće granice, vrednosti veza se mogu memorisati i koristiti u kasnijem radu.

Kod klasičnih računara softver mora biti gotovo savršen da bi radio. Razvoj softvera zahteva iscrpan dizajn, testiranje i postepeno usavršavanje čine ga dugim i skupim procesom. Neuronske mreže omogućavaju evolutivni razvoj softvera, tj. neuronska mreža se može naknadno adaptirati realnim i novo nastalim uslovima. Neuronske mreže imaju sposobnost da menjaju svoju strukturu i funkciju, za razliku od klasičnih algoritama koji nemaju toliku fleksibilnost.

Decentralizovana obrada i memorisanje omogućavaju mreži da nastavi funkcionisanje i u uslovima kada se deo mreže ošteti (jedan deo neurona prestane da funkcioniše ili se neke veze

prekinu). Oštećena mreža će i dalje biti u stanju da funkcioniše ali sa smanjenom tačnošću. Mreža je takođe tolerantna i na prisustvo šuma u ulaznom signalu. Svaki memorisani uzorak je delokalizovan, tj. smešten je u celu mrežu. Ova osobina je još jedna veoma važna osobina neuronskih mreža.

2.7 Osnovni tipovi neuronskih mreža

Kao što je već rečeno, jedna od podela veštačkih neuronskih mreža je prema smeru prostiranja informacija. Ova podela je danas najprisutnija i određuje vrlo često oblast primene i način korišćenja veštačke neuronske mreže. Dakle, prema smeru prostiranja informacija, veštačke neuronske mreže mogu biti: sa smerom prostiranja unapred – feedforward neuronske mreže i sa smerom prostiranja unazad, tj. povratne odnosno rekurentne neuronske mreže.

Upravo će u ovoj disertaciji za potrebe realizacije kratkoročnog predviđanja kod sistema daljinskog grejanja biti korišćene i feedforward i rekurentne neuronske mreže. Zato su u ovom poglavlju date osnovne karakteristike i jedne i druge neuronske mreže.

Posebno su opisani najčešće korišćeni tipovi feedforward i rekurentnih neuronskih mreža.

2.7.1 Feedforward neuronske mreže

Feedforward neuronske mreže su podskup veštačkih neuronskih mreža čiji čvorovi formiraju aciklični graf gde se informacije kreću samo u jednom smeru, od ulaza ka izlazu.

Višeslojni perceptron (MLP) je klasa feedforward neuronskih mreža koji se sastoji od tri ili više slojeva neurona. Sloj je grupa neurona (jedinica) koja prima veze od istih jedinica. Jedinice unutar sloja nisu međusobno povezane.

MLP se sastoji od tri tipa slojeva: ulaznog sloja, jednog ili više skrivenih slojeva i izlaznog sloja. Ulazni sloj je prvi sloj mreže i ne prima bilo kakve veze od drugih jedinica već umesto toga drži ulazni vektor mreže kao aktivaciju samih jedinica. Ulazni sloj je potpuno povezan sa prvim skrivenim slojem. Skriveni sloj i je potpuno povezan sa skrivenim slojem $i+1$. Poslednji skriveni sloj je potpuno povezan sa izlaznim slojem. Aktivacija izlaznih jedinica predstavlja izlaz neuronske mreže.

Izlaz neuronske mreže se izračunava u procesu koji se naziva prosec propagacije ili prostiranja unapred (forward propagation) i odvija se u tri koraka:

1. Ulaz mreže se kopira u aktivaciju ulaznih jedinica
2. Skriveni slojevi izračunavaju svoje aktivacije topološkim redom
3. Izlazni sloj izračunava svoju aktivaciju i kopira je u izlaz mreže

MLP je najčešće korišćena statička mreža u kojoj su dati ulazi mreže sa željenim izlazom i gde se težine podešavaju tako da mreža proizvede željeni izlaz. Neuron izračunava svoj izlaz zasnovan na težinskoj sumi svih svojih ulaza saglasno svojoj aktivacijskoj funkciji. Podaci se kreću, kao što je veće rečeno, u jednom smeru. Mreža se obučava podešavanjem težina koje povezuju neuron korišćenjem procedure prostiranja greške unazad „error backpropagation“. Postoji više različitih algoritama za učenje a najpopularniji je back-propagation algoritam koji uključuje gradijentne metode sa i bez momentuma koje su isuviše spore za rešavanje praktičnih problema. Algoritmi kao što su konjugovano gradijentni algoritam, kvazi Newton-ov algoritam, Levenberg–Marquardt (LM) algoritam itd. se razmatraju kao brži algoritmi i svi se koriste kao standardne tehnike numeričke optimizacije.

2.7.1.1 “Backpropagation” algoritam za obučavanje sa prostiranjem unazad

Kako bi se realizovalo kvalitetno predviđanje, neuronska mreža mora biti obučavana na odgovarajućoj seriji podataka. Primeri u formi parova (**ulaz, izlaz**) se izvlače iz serije podataka, gde su **ulazi** i **izlazi** vektori po veličini jednaki broju ulaza i izlaza mreže, respektivno. Tada se za svaki primer “*backpropagation*” obučavanje sastoji iz tri koraka:

1. Unošenje ulaznog vektora na ulaze mreže i pokretanje mreže: izračunavaju se aktivacione funkcije sekvencijalno unapred od prvog skrivenog sloja do izlaznog sloja.
2. Izračunavanje razlike između željenog izlaza za taj primer, i stvarnog trenutnog izlaza mreže. Zatim se greška sekvencijalno prostire unazad od izlaznog sloja do prvog skrivenog sloja.
3. Za svaku vezu se menjaju težine i to tako što se modifikuju proporcionalno sa greškom.

Kada se sva tri koraka realizuju za svaki primer iz serije podataka, javlja se jedna epoha. Obučavanje uobičajeno traje hiljadu epoha, eventualno do dostizanja unapred određenog maksimalnog broja epoha ili do trenutka kada greška izlaza padne ispod prihvatljive granice. Obučavanje može biti vremenski ograničeno u zavisnosti od veličine mreže, broja primera, limita epoha ili limita greške.

Svaki od tri koraka će biti detaljnije opisani. U prvom koraku, ulazni vektor se unosi na ulaze mreže, zatim počinje računanje izlaza aktivacione funkcije svake jedinice za svaki sloj počev od prvog skrivenog sloja i svake jedinice tog sloja. Jednačina (2.1) predstavlja aktivacionu funkciju jedinice skrivenog sloja a jednačina (2.2) aktivacionu funkciju jedinice izlaznog sloja:

$$I_c = h_{skriven}(\sum_{p=1}^P i_{c,p} w_{c,p} + b_c), h_{skriven}(x) = \frac{1}{1+e^{-x}} \quad (2.1)$$

$$I_c = h_{Izlaz}(\sum_{p=1}^P i_{c,p} w_{c,p} + b_c), h_{Izlaz}(x) = x \quad (2.2)$$

Eventualno, mreža će prostirati vrednosti kroz sve jedinice do izlaza mreže.

U drugom koraku, za svaki sloj počev od izlaznog sloja i za svaku jedinicu u tom sloju izračunava se izraz greške. Za svaku jedinicu u izlaznom sloju, izraz greške u jednačini (2.3) se izračunava.

$$\delta\delta_c = h'_{I_{zlaz}}(x)(D_c - I_c) \quad (2.3)$$

gde je D_c željeni izlaz mreže (iz vektora izlaza) koji odgovara trenutnoj jedinici izlaznog sloja, I_c je trenutni izlaz mreže koji odgovara trenutnoj jedinici izlaza, a $h'_{I_{zlaz}}(x)$ je izvod linearne aktivacione funkcije izlazne jedinice, tj. 1. Za svaku jedinicu u skrivenim slojevima izračunava se greška u jednačini (2.4):

$$\delta_c = h'_{skriven}(x) \sum_{n=1}^N \delta_n w_{n,c} \quad (2.4)$$

N je broj jedinica u sledećem sloju, δ_n je izraz greške za jedinicu u sledećem sloju a $w_{n,c}$ je težina koja modifikuje vezu od jedinice c do jedinice n . Izvod sigmoidne aktivacione funkcije skrivene jedinice $h'_{I_{zlaz}}(x)$ je $I_h(1 - I_h)$.

U trećem koraku, za svaku vezu se izračunava jednačina (2.5) koja predstavlja promenu u težini koja modifikuje vezu od jedinice p ili ulaza mreže p do jedinice c :

$$\Delta w_{c,p} = \alpha \delta_c I_p \quad (2.5)$$

$w_{c,p}$ je težina kojom se modifikuje veza jedinice p ili ulaza mreže p do jedinice c , α je faktor učenja, a I_p je izlaz jedinice p ili ulaz mreže p . zato nakon trećeg koraka, većina težina ima različite vrednosti. Promena težina nakon svakog primera se naziva on-line obučavanje. Druga mogućnost je "batch" obučavanje gde se promene akumuliraju i primenjuju nakon što mreža prođe sve primere.

Cilj obučavanja sa prostiranjem unazad je konvergiranje do najbližeg optimalnog rešenja zasnovanog na ukupnoj kvadratnoj grešci proračunatoj u jednačini (2.6).

$$E_c = \frac{1}{2} \sum_{c=1}^C (D_c - I_c)^2 \quad (2.6)$$

C je broj jedinica u izlaznom sloju, D_c je željeni izlaz mreže (iz vektora izlaza) koji odgovara trenutnoj jedinici izlaznog sloja a I_c je aktuelni izlaz mreže koji odgovara jedinici trenutnog izlaznog sloja. Konstanta $\frac{1}{2}$ se koristi za prostiranje unazad i može ili ne biti uključen u proračunu ukupne kvadratne greške. Faktor učenja upravlja koliko brzo i dobro će mreža konvergirati ka partikularnom rešenju. Vrednosti za faktor učenja se može kretati od 0.01 do 0.3.

Danas u primeni nalazimo mnoge modifikacije prethodno opisanog osnovnog algoritma *povratnog prostiranja greške*. Međusobno se ti algoritmi razlikuju prema brzini konvergencije prilikom traženja rešenja, a razlike mogu biti čak do nekoliko stotina puta. Prema [9] razlikujemo dve grupe algoritama kod unapređenih statičkih *BP* mreža. Tzv. *spore* i *brze* algoritme. U *spore* algoritme npr. spadaju:

- *BP*-algoritam sa konstantnim koeficijentom brzine učenja (engl. *learning rate*) - α ,
- *BP*-algoritam sa konstantnim koeficijentom momentuma (engl. *momentum*)

U brze npr.spadaju:

- *BP*-algoritam sa varijabilnim ili adaptivnim (engl. *adaptive*) koeficijentom brzine učenja,
- *Levenberg-Marquardt* algoritam

Kod *brzih* algoritma primenjuju se tzv. heurističke tehnike koje su proizišle iz analize uspešnosti učenja standardnih ‘*steepest descent*’ algoritama. Kod *Levenberg-Marquardt* algoritma primjenjuju se klasične metode numeričke optimizacije i on je nešto detaljnije u nastavku opisan.

2.7.1.2 Levenberg-Marquardt-ov algoritam učenja

Levenberg-Marquardt (LMA) [9] algoritam slovi kao napredan i najbrži algoritam za nelinearnu optimizaciju. Za razliku od *Quasi-Newton* algoritma [9], kod *LMA* nije potrebno izračunavati *Hessianovu* matricu. S obzirom da se kod *LMA* kao funkcija greške primenjuje suma kvadrata greške tada se *Hessian-ov*matrica aproksimira kako sledi:

$$H = J^T J \quad (2.7)$$

Gradijent se izračunava kao:

$$G = J^T E \quad (2.8)$$

Ovdje je J^T – transponovana *Jacobian-ova* matrica koja sadrži prve izvode greške mreže, a E –vektor greške mreže. U tom se slučaju *Jacobian-ova* matrica izračunava standardnim *BP*-algoritmom što je značajno jednostavnije nego izračunavanje *Hessian-ove* matrice.

Upotrebljavajući takvu aproksimaciju *Hessian-ove* matrice izraz za *LMA* je:

$$x_{k+1} = x_k - [J^T J + \alpha I]^{-1} J^T E \quad (2.9)$$

Kada je $\alpha=0$ gornji izraz postaje *Quasi-Newton* algoritam uz aproksimaciju *Hessian-ove* matrice. U slučaju da je α veliki on time zapravo postaje ‘*gradient descent*’ malog koraka. S obzirom da *Newtonova* metoda postaje brža i preciznija u blizini minimuma funkcije greške, cilj je zapravo težiti k njoj što je pre moguće. α se smanjuje nakon svakog uspešnog koraka iteracije (smanjenje greške), a povećava se kada probna ili testna iteracija nastoji povećati grešku, te se na taj način funkcija greške ponovo vraća u pređašnje stanje kakvo je bilo u $i-1$ koraku iteracije. Nedostatak *LMA* je taj što zahteva puno memorije za proračun *Jacobian-ove* matrice. Neke modifikacije *LMA* u tom slučaju dele *Jacobian* matricu na dva dela, dobijajući tako za proračun aproksimaciju *Hessian-ove* matrice. Međutim tačnost proračuna po kojoj je *LMA* poznat se tada smanjuje.

2.7.2 RBF Neuronske mreže sa radijalnom funkcijom

RBF neuronske mreže su dvoslojne statičke neuronske mreže. Nulti (ulazni) sloj najčešće samo prosleđuje ulaze u mrežu na ulaz prvog sloja sastavljenog od neurona sa aktivacijskim funkcijama s kružnom osnovom i predstavlja njeno tzv. receptivno polje. Drugi sloj mreže, ujedno i izlazni sloj, sastoji se od perceptrona s linearnom aktivacijskom funkcijom najčešće jediničnog aktivacijskog pojačanja. Matematički se RBF neuronska mreža može opisati sledećim izrazima:

$$\mathbf{x}_1 = \mathbf{y}_0 = \mathbf{x} \quad (2.10)$$

pri čemu je $\mathbf{x} = [x_1, x_2, \dots, x_{n(x)}]^T$ vektor ulaza u mrežu (nulti sloj mreže), odnosno y_0 izlaz iz nultog sloja neuronske mreže a $\mathbf{x}_1 = [x_{1,1}, x_{1,2}, \dots, x_{1,n(0)}]^T$ vektor ulaza u prvi sloj mreže dimenzije $n(x)$,

$$v_{1,i} = \|\mathbf{x}_1 \times \mathbf{w}_{s,i} - \mathbf{w}_{c,i}\| = \sqrt{\sum_{k=1}^{n(0)} (x_{1,k} w_{s,i,k} - w_{c,i,k})^2}, \quad i = 1, \dots, n(1) \quad (2.11)$$

Navedena jednakost predstavlja operaciju konfluencije, odnosno u slučaju RBF neuronskih mreža euklidsku udaljenost pri čemu je $w_{s,i}$ vektor sinaptičkih težinskih koeficijenata i -tog neurona, te $w_{c,i}$ vektor središta i -tog neurona. Rezultat operacije konfluencije je ulaz u nelinearnu aktivacijsku funkciju, a ukoliko pretpostavljamo Gaussovu funkciju sledi:

$$x_{2,i} = \psi_1(v_{1,i}, \sigma_i) = \exp\left(-\frac{v_{1,i}^2}{2\sigma_i^2}\right), \quad i = 1 \dots n(1) \quad (2.12)$$

gde je σ_i parametar neurona koji predstavlja odstupanje od središta Gaussove funkcije, a ψ_1 je nelinearna aktivacijska funkcija skrivenog sloja. Dalje, ulaz u drugi (izlazni) sloj mreže možemo računati:

$$\mathbf{v}_2 = \mathbf{W}_t \mathbf{x}_2 \quad (2.13)$$

pri čemu je \mathbf{W}_t vektor težinskih koeficijenata na izlazu iz prvog sloja, a \mathbf{x}_2 vektor izlaznih signala iz prvog sloja. Konačno, izlaz iz neuronske mreže računamo prema izrazu:

$$\mathbf{y}_2 = \psi_2(\mathbf{v}_2) \quad (2.14)$$

gdje ψ_2 predstavlja aktivacijsku funkciju linearnog sloja. Najčešće korišćena aktivacijska funkcija izlaznog sloja je *pureline* (linearna funkcija s jediničnim pojačanjem) a osim nje može se koristiti i tzv. *tansig* funkcija, koje su već opisane u prethodnim poglavljima.

RBF mreže imaju sposobnost aproksimacije proizvoljne kontinuirane nelinearne funkcije a njihova aproksimacijska sposobnost određena je položajem središta RBF neurona, varijancom njihovih aktivacijskih funkcija te iznosima težinskih koeficijenata izlaznog sloja mreže. Vrednosti ovih parametara RBF mreže računaju se algoritmima učenja koji su opisani u nastavku. RBF neuronske mreže predstavljaju alternativu MLP mrežama, posebno u slučaju aproksimacije jednostavnih i vremenski malo promenljivih nelinearnosti kada je moguće unapred na odgovarajući

način rasporediti središta i odrediti iznose varijanci RBF neurona, a učenje mreže svesti samo na podešavanje težinskih koeficijenata izlaznog sloja. U tom slučaju vladanje RBF neuronske mreže postaje linearno zavisno od parametara, za razliku od MLP mreža čije je vladanje nelinearno zavisno od parametara. Raspored središta značajno utiče na svojstva RBF mreže. Tradicionalno se RBF funkcije koriste za interpolaciju nelinearnih viševarijabilnih funkcija, pri čemu je broj središta jednak broju podataka (u svaki se ulazni podatak postavlja po jedno središte). Aproksimaciju proizvoljne nelinearne kontinuirane funkcije moguće je također postići i sa manjim brojem dobro raspoređenih središta i to na dva načina: tako da se središta postave u slučajno odabrane ulazne podatke [40] ili jednolikim rasporedom središta u prostoru ulaznih podataka. RBF mreže i sa slučajnim i sa jednolikim rasporedom središta RBF neurona mogu aproksimirati proizvoljnu kontinuiranu nelinearnu funkciju, međutim, potrebni broj RBF neurona može biti jako velik. Smanjenje broja neurona može se postići proširenjem postupka učenja mreže i podešavanjem položaja središta te varijanci RBF neurona. U tom slučaju vladanje RBF mreže postaje nelinearno zavisno od parametara, kao i MLP mreže, ali i s uporedivim aproksimacijskim svojstvima.

2.7.2 Rekurentne neuronske mreže

2.7.2.1 Hopfield-ova neuronska mreža

Hopfield-ova neuronska mreža pripada grupi rekurentnih neuronskih mreža [14], [35]. Kod ovih mreža, izlazni neuroni su povezani sa svim ulaznim neuronima, osim sopstvenog. Na taj način svaki od neurona svojim stanjem direktno utiče na sve ostale u mreži [36]. Na ovaj način svi ostali neuroni uče i prilagođavaju se promeni stanja svakog od njih, što bi u biološkoj interpretaciji bila promena ponašanja jedinke u odnosu na grupu kojoj pripada. Kako su generalno uslovi u kojima grupa deluje slični, to je svaka od promena vrlo bitna jer doprinosi ukupnom rezultatu rada mreže. Na ovaj način se u veštačkim mrežama upotrebom rekurentnih mreža postiže interaktivnost koja postoji i u biološkim strukturama [37], [14].

Kod Hopfield-ove neuronske mreže u povratnim granama najčešće postoje operatori jediničnog kašnjenja, tako da signal sa izlaza prvo bude zakašnjen i potom se vodi na sinapse drugih ulaznih neurona, koji su realizovani tako da svaki od njih rešava neki od segmenata definisanog problema [14].

Uticao povratnih signala može se dodatno ograničiti postavljanjem praga delovanja, čime se neke manje promene eliminišu, i mreža radi sa većim relativnim greškama [36]. Kako je


organizacija ovih mreža slična organizaciji ostalih veštačkih neuronskih mreža, za probleme koji se rešavaju treba definisati sledeće :

1. Nelinearnost neurona unutar mreže,
2. Potrebu za simetričnošću sinaptičkih veza i
3. Broj povratnih veza unutar mreže.

U zavisnosti od toga kakav je izbor parametara mreže, mreže poprimaju relativno različite strukture unutar iste klase rekurentnih mreža. Najpoznatije među ovim mrežama su Hopfield-ova mreža, Boltzmann-ov spoj i Mean-field-theory spoj[38], [14],[22].

Kao jednu od varijanti rekurentne neuronske mreže, J. J. Hopfield je predstavio u radu[36], koja je po njegovom imenu i dobila naziv. Jedan sloj Hopfield-ove neuronske mreže vrši procesiranje signala i na kraju vrši njegovu binarnu klasifikaciju [36],[37]. Vrednosti na izlazu neuronske mreže su 0 ili 1 u zavisnosti da li je vrednost signala bila manja ili veća od praga. Kod nekih implementacija ove vrednosti su -1 i 1.


Matematički posmatrano, izlaz neurona u izlaznom sloju je [14], [36]gde je T_{ij} težinski koeficijent za vezu između neurona i i j , u_j je stanje j -tog neurona a θ_i je definisani prag za i -ti neuron. Ovako definisane vrednosti neurona na njegovom izlazu nazivaju se stanja neurona. Stanjima neurona opisano je i trenutno stanje Hopfield-ove neuronske mreže. U svakom trenutku ova stanja definišu jednu fazu rada, i svaka faza se može analizirati zasebno. U opštem slučaju stanje mreže je opisano vektorom $v = (v_1, v_2, \dots, v_n)$, koji je skup nula i jedinica, čime se opisuju pojedinačna stanja neurona. Na primeru mreže sa četiri neurona i vektorom stanja $v = (1,0,0,1)$ struktura mreže sa njenim stanjima data je na slici 2.14.



Slika 2-14 Struktura Hopfield-ove neuronske mreže sa četiri neurona i njihovim stanjima.

U svakoj iteraciji stanja neurona se menjaju shodno dolaznim signalima u neuron i težinskim koeficijentima na vezama sa ostalim neuronima. Kako je Hopfieldova neuronska mreža potpuno povezana, rekurzivna stanja mreže se mogu samostalno menjati u svakoj od iteracija nakon samo

jednog pobuđivanja mreže. Ukoliko nema drugih spoljašnjih pobuda, rekurzija u mreži doprinosi da u određenoj iteraciji Hopfieldova neuronska mreža dođe u stabilno stanje [36], [14]. Ovo stanje podrazumeva da su promene koje nastaju u svakoj narednoj iteraciji manje od praga i ne mogu promeniti pojedinačna stanja neurona.




Slika 2-15 Osnovna arhitektura Hopfield-ove neuronske mreže.

Veze između neurona u Hopfield-ovoj neuronskoj mreži su ograničene sa dva uslova:

1. $T_{ii} = 0$, za svako i (tj. neuron ne može pobuđivati samog sebe)
2. $T_{ij} = T_{ji}$ za svako $i-j$ (tj. međusobni uticaji dva neurona su istih težina).

Za ovako definisanu arhitekturu Hopfield-ove neuronske mreže može se nacrtati i grafička interpretacija gde u_n predstavlja početno stanje neurona, Slika 2.16.

Imajući u vidu potrebu da se osnovna struktura sa slike fizički realizuje, potrebno je gradivne komponente blok šeme zameniti aktivnim ili pasivnim komponentama električnih kola. Na Slici 2.16. prikazana je osnovna struktura Hopfieldove neuronske mreže u obliku strukturne šeme, pogodne za hardversku realizaciju, gde je sa u_i označena težinska suma ulaznih signala, T_{ij} težinski uticaji sinapsi a sa φ aktivaciona funkcija [36].




Slika 2-16 Strukturna šema Hopfield-ove neuronske mreže pogodna za hardversku realizaciju.

Kao i ostale rekurentne mreže i Hopfield-ova mreža je nelinearna, što joj daje mogućnost rešavanja složenih problema [36], [39], [14]. Ova mreža se zasniva na principu pamćenja informacija u dinamički stabilnim stanjima [36].

Svaka informacija se, u toku jedne iteracije, pamti u lokalnom minimumu energijske funkcije. Tokom rada, mreža teži da svoje izlaze podesi tako da svi konvergiraju ka jednom od grupe pomenutih lokalnih minimuma, i na takav način uđe u stabilno stanje. Taj minimum treba da bude minimum svih ostalih, pa se na taj način i očekuje kvalitetna konvergencija ka globalnom minimumu čime se postiže rešenje optimizacionog problema.

2.7.2.2 Elman-ova neuronska mreža

Elman-ove neuronske mreže [153] su poznate i pod nazivom parcijalne rekurentne neuronske mreže ili proste rekurentne neuronske mreže. Reč je višeslojnim preceptronima proširenim sa jednim ili više kontekst slojeva koji pamte izlazne vrednosti jednog od slojeva koji kasni za jedan korak. Ovi slojevi se koriste za aktivaciju tog ili nekog drugog sloja u sledećem vremenskom koraku.



Slika 2-17 Shematski prikaz Elman-ove neuronske mreže

Povratna veza od skrivenog do kontekst sloja omogućava Elman-ovoj neuronskoj mreži da uči, prepoznaje i generiše privremene uzorke, poznate kao prostrani („spatial“) uzorci. Svaki skriveni neuron se povezuje sa samo jednim neuronima kontekst sloja preko konstantne težine koja iznosi +1. Na taj način, kontekst sloj se konstituise kao neka vrsta kopije stanja skrivenog sloja, na jednoj instanci ranije.

Logično, broj neurona u kontekst sloju je isti broju neurona u skrivenom sloju. Saglasno metodu koji je predložio Sarle [154], ceo skup podataka je podeljen na skup podataka za obučavanje i skup podataka za validaciju. Cela faza obučavanja se prekida kada se dostigne najmanja greška na validacionom skupu podataka.

2.7.2.3 Obučavanje rekurentnih neuronskih mreža

U ovoj disertaciji prikazana su tri tipa obučavanja rekurentnih neuronskih mreža:

- Backpropagation Through Time – propagacija unazad kroz vreme
- Truncated Backpropagation Through Time
- Real-Time Recurrent Learning

1) Backpropagation Through Time – propagacija unazad kroz vreme

Standardni „backpropagation“ algoritam ne odgovara neuronskim mrežama koje imaju unutrašnje cikluse. Srećom, rekurentne neuronske mreže se mogu modifikovati da izgledaju kao feedforward neuronske mreže razvijanjem mreže u vremenu i tada ih obučavati „Backpropagation Through Time“ (BPTT) algoritmom koji su prvi primenili Rumelhart, Hinton and Williams [11]. Proces razvijanja mreže počinje sa prostom rekurentnom neuronskom mrežom u trenutnom vremenu t , označenu kao SRN_t (simple recurrent neural network). Kako je kontekstni sloj SRN samo kopija aktivacije skrivenog sloja iz prethodnog koraka, ciklusi u mreži se mogu izbeći zamenom kontekst sloja sa identičnom kopijom SRN mreže iz prethodnog koraka, SRN_{t-1} . Skriveni sloj SRN_{t-1} se tada povezuje na skriveni sloj SRN_t . Ova procedura se ponavlja dok se nedostigne vremenski korak 0, u kome se ne zamenjuje kontekstni sloj već ostaje podešen na svojim početnim aktivacijama. Broj SRN kopija predstavlja dubinu razvijene mreže i svaka kopija mreže koristi isti skup težina veze.

Jednom kada se SRN razvije u feedforward neuronsku mrežu, može se koristiti backpropagation algoritam. Ovaj algoritam se ponovo sastoji iz tri koraka:

1. Propagacija unapred. Signal se prostire kroz razvijenu mrežu u standardnom obliku od vrha do dna. U ovom slučaju, od najdalje kopije SRN do najskorije kopije.

2. Propagacija unazad. Izraz greške $\Delta_i^{izlaz}(t)$ jedinice izlaznog sloja i kopije SRN u vremenu t se izračunava kao

$$\Delta_i^{izlaz}(t) = (target_i(t) - a_i^{izlaz}(t)) \frac{\partial act(a_i^{izlaz}(t))}{\partial a_i^{izlaz}(t)} \quad (2.15)$$

gde je $target_i(t)$ željeni izlaz jedinice i izlaznog sloja SRN u vremenu t a $a_i^{izlaz}(t)$ je njena aktuelna aktivacija u vremenu t .

Za svaku jedinicu i skrivenog sloja razvijene SRN u vremenu t , neka se uradi j iteracija kod svih jedinica koje primaju veze od jedinice i saglasno razvijenoj mreži i neka Δ_j bude izraz greške iteracije j . Težinska matrica w_{ij}^h sadrži težine veza od jedinice i do jedinice j . Izraz greške skrivene jedinice i označen kao $\Delta_i^{skriven}(t)$ se izračunava kao:

$$\Delta_i^{skriven}(t) = (\sum_j \Delta_j w_{ij}^h) \frac{\partial act(a_i^{skriven}(t))}{\partial a_i^{skriven}(t)} \quad (2.16)$$

3. Osvežavanje težina originalne SRN. Za svaku jedinicu j u skrivenom ili izlaznom sloju l originalne mreže koja prima veze od jedinice i u sloju k , vršimo osvežavanje saglasno:

$$nova w_{ij}^l = w_{ij}^l + \alpha \sum_{\tau=0}^t \Delta_i^k(\tau) a_j^l(\tau) \quad (2.17)$$

gde je w_{ij}^l težinska matrica veza od jedinice i do jedinice j u sloju l , $\Delta_i^k(\tau)$ izraz greške jedinice i u sloju k kopije razvijene mreže u koraku vremena τ , $a_j^l(\tau)$ je aktivacija jedinice j u sloju l kopije razvijene mreže u vremenu τ , a α faktor učenja.

2) Truncated Backpropagation Through Time

Kod BPTT, broj kopija SRN u razvijenoj mreži je jednak vremenskom koraku t , tako da je korišćenje ovog algoritma za on line učenje nepraktično. Zbog toga se koristi on line verzija BPTT algoritma koja se naziva Truncated Backpropagation Through Time (TBTT) i koja je iskorišćena u [14]. TBPTT radi analogno kao BPTT, osim što je maksimalna dubina d razvijene mreže ograničena.

Mreže se razvijaju od vremenskog koraka t do $t-d+1$ kada razvijanje staje. Kontekst sloj kopije SRN mreže u vremenu $t-d-1$ drži aktivaciju skrivenog sloja mreže u vremenu $t-d$.

TBPTT tipično realizuje prolaz unazad u razvijenoj mreži za svakih d vremenskih koraka ili za svaki vremenski korak. Kako se težine veza menjaju svaki vremenski korak, pogodno je sačuvati prošle vrednosti težina ili koristiti trenutne težine ali sa realizacijom propagiranja unapred u razvijenoj mreži.

3) Real-Time Recurrent Learning

Real-Time Recurrent Learning (RTRL) algoritam je gradijentni metod spusta pogodan za on line učenje rekurentnih mreža. [15]. Neka imamo SRN mrežu čija svaka jedinica i u vremenskom koraku t ima potencijal $p_i(t)$ i aktivaciju $a_i(t)$. Radi lakšeg razumevanja neka su sa U i indeksima ul , *skriven* i *izlaz* označeni skupovi indeksa za ulazne, skrivene i izlazne jedinice, respektivno. Težina veze od jedinice i do jedinice j se označava w_{ij} . U vremenskom koraku t , neka je $target_i(t)$ željena aktivacija izlazne jedinice i .

U vremenskom koraku t , trenutna greška $E(t)$ je

$$E(t) = \frac{1}{2} \sum_{i \in U_{izlaz}} (target_i(t) - a_i(t))^2 \quad (2.18)$$

i minimizirana ukupna greška $E_{uk}(t)$ u vremenu t je

$$E_{uk}(t) = \sum_{\tau=1}^t E(\tau) \quad (2.19)$$

Greška se minimizira podešavanjem težina duž negativnog gradijenta greške $-\partial(E_{uk}(t)) / (\partial w_{ij})$. Ova ukupna greška se može sračunati akumulacijom negativnog gradijenta instanci greške u svakom vremenskom koraku:

$$-\frac{\partial E(t)}{\partial w_{ij}} \sum_{i \in U_{izlaz}} (target_i(t) - a_i(t)) \frac{\partial a_i(t)}{\partial w_{ij}} \quad (2.20)$$

Na taj način se kreira dinamički sistem sa promenljivama v_{ij}^k za svaku skrivenu i izlaznu jedinicu. Kako je početno stanje mreže nezavisno od njenih težina, početna vrednost se može podesiti na $v_{ij}^k(0) = 0$. Težine mreže se tada mogu osvežiti duž akumulirane trajektorije


$$nova\ w_{ij} = w_{ij} - \alpha \sum_{k \in U_{izlaz}} (a_k(t) - target_k(t)) v_{ij}^k \quad (2.21)$$

Limit ovog algoritma je njegova upotreba za veoma male mreže.

2.7.3 SOM samoorganizirajuće mape

Samoorganizujuća mapa (SOM) je tip veštačke neuronske mreže čija obuka se vrši nenadgledanim učenjem kako bi se dobila niskodimenzionalna (najčešće dvodimenzionalna), diskretna reprezentacija ulaznih uzoraka. Ovakva diskretna reprezentacija podataka zove se mapa. Samoorganizujuće mape razlikuju se od drugih tipova neuronskih mreža po tome što čuvaju informaciju o topološkim svojstvima ulaza pomoću funkcije susednih neurona. Osobine samoorganizujuće mape omogućuju joj vizualnu predstavu niskodimenzionog pogleda na visokodimenzione podatke, tj. višedimenziono skaliranje. Ovaj model je prvi put kao neuronsku mrežu opisao finski profesor Teuvo Kohonen, početkom 80-tih godina, stoga se ove mreže zovu i Kohonenove mape. Samoorganizujuće mape rade u dve faze: učenje i mapiranje. Učenje izgrađuje mapu pomoću ulaznih uzoraka. Ovaj proces je kompetitivan i naziva se i kvantizacija vektora. Mapiranje vrši klasifikaciju ulaznog vektora. Samoorganizujuća mapa sastoji se iz komponenti koje se nazivaju čvorovi ili neuroni. Svaki neuron ima vektor težina, istih dimenzija kao i vektor ulaznih podataka, i poziciju u prostoru mape. Procedura smeštanja vektora iz prostora podataka u mapu sastoji se iz

- pronalaženja neurona čiji vektor težina ima vrednosti najbliže vektoru iz prostora podataka i
- dodeljivanja koordinata mape ovog neurona vektoru.



Slika 2-18 Ilustrativna shema SOM-a samoorganizujuće mape

Cilj obuke samoorganizujuće mape je izazivanje slične reakcije različitih delova mape na određene šablone sa ulaza. Ovakva reakcija je analogna načinu na koji se obrađuju vizualne, auditorne i ostale čulne informacije u mozgu čoveka. Težine neurona se najčešće inicijalizuju malim, slučajnim vrednostima. Mrežu je potrebno obučiti sa velikim brojem vektora uzoraka koji predstavljaju, što je moguće bliže, vektore koji se očekuju u toku faze mapiranja. Obično se obučavanje sa istim uzorcima vrši više puta, kroz nekoliko iteracija. Kohonenova mapa se obučava kompetitivnim učenjem .

Kompetitivno učenje je proces nenadgledanog učenja veštačkih neuronskih mreža pri kojem se neuroni takmiče za dozvolu da se aktiviraju za određeni skup ulaznih podataka.


Kada se mreži preda uzorak za učenje, računa se njegovo odstojanje od vektora težina svih neurona mreže. Neuron čije su vrednosti vektora težina najbliže ulazu je neuron sa najvećim podudaranjem. Vrednosti ovog neurona i njegovih suseda u SOM rešetki se potom približavaju vrednostima ulaza. Uticaj ulaza na vrednosti vektora težina neurona opada sa vremenom i udaljenošću od neurona sa najvećim podudaranjem. Formula kojom se vrši ažuriranje vrednosti vektora težina neurona $\mathbf{Wv}(t)$ je:

$$\mathbf{Wv}(t + 1) = \mathbf{Wv}(t) + \Theta(v, t) \alpha(t)(\mathbf{D}(t) - \mathbf{Wv}(t)), \quad (2.22)$$

gde je $\alpha(t)$ monotono opadajući koeficijent odnosno faktor učenja, a $\mathbf{D}(t)$ je ulazni vektor. Funkcija susednih neurona $\Theta(v, t)$ zavisi od rastojanja između neurona sa najvećim podudaranjem i neurona v .

Postoje dva načina za ažuriranje vrednosti:

- Najjednostavniji način je ažuriranje sa istom vrednosti svih neurona koji se nalaze dovoljno blizu neurona sa najvećim podudaranjem, dok vrednosti ostalih ostaju nepromenjene.
- Drugi način je ažuriranje suseda upotrebom Gausove funkcije.



Slika 2-19 Primeri topologija Kohonenovih mreža a) jednodimenzionalna, b) dvodimenzionalna, c) trodimenzionalna

Bez obzira koji je način ažuriranja, funkcija susednih neurona smanjuje radijus svog delovanja tokom vremena. To znači da će na početku obuke, kada je široko „susedstvo“, samoorganizacija biti vršena na nivou cele mreže. Vremenom će se „susedstvo“ suziti na samo nekoliko neurona čije težine konvergiraju lokalnim srednjim vrednostima. Ovaj postupak ponavlja se za svaki ulazni vektor isti broj puta. Obično je broj iteracija velik (λ). Na kraju obuke, mreža pravi veze izlaznih neurona sa grupama ili šablonima ulaznih podataka.

Kvantizacija vektora je tehnika kojom se iskorišćava struktura ulaznih vektora u svrhu kompresije podataka. Tačnije, ulazni prostor deli se u određeni broj regiona i za svaki region definiše se rekonstrukcioni vektor. Kada kvantizator dobije novi ulazni vektor, prvo se utvrđuje region kojem on pripada. Dalje se u algoritmu taj ulazni vektor predstavlja reprodukcioni vektorom za dati region. Ovim postupkom, upotrebom kodirane verzije reprodukcionog vektora umesto originalnog ulaza, ostvaruje se značajna ušteda u memorijskom prostoru koji je potreban za čuvanje podatka, na račun tačnosti (kvaliteta) podatka. Kolekcija reprodukcionijskih vektora naziva se „code book“, a njeni članovi „code words“. Kvantizator vektora sa najmanjom deformacijom, tj. gubitkom kvaliteta podataka zove se „Voronoi“ ili „najbliži-sused“ kvantizator. Voronoi ćelije su grupe tačaka ulaznog prostora koje odgovaraju određenom regionu tog prostora primenom pravila „najbliži sused“, prema Euklidskoj matrici. Algoritam SOM-a sadrži približan metod za nenadgledano izračunavanje Voronoi vektora pri čemu se aproksimacija određuje vektorima težina sinapsi neurona.

Danas se SOM koriste za razne aplikacije. Na kraju 2005 godine, Kohonen je dokumentovao 7768 naučnih publikacija, koje analiziraju, razvijaju ili primenjuju samoorganizujuće mape. Kada je u pitanju primena, može se, po Kohonenu, predstaviti više glavnih oblasti primene:

- statističke metode
 - (a) istraživačka analiza podataka
 - (b) statistička analiza i organizacija teksta
- Industrijska analiza, upravljanje i telekomunikacije

- Biomedicinska analiza i primena
- Finansijske aplikacije

Generalno se može reći da ne postoji ograničenje korišćenja SOM-a.

2.8 Veštačke neuronske mreže i evolutivni algoritmi

2.8.1 Opšta razmatranja

Danas su inteligentne metode proračuna u velikom periodu razvoja i kao što je već naznačeno u uvodnom poglavlju one uključuju fazi logiku, neuronske mreže koje su predmet ove disertacije, evolutivne algoritme i druge metode. Sa razvojem kompjuterskih tehnologija rastao je i razvoj i napredak u istraživanju i primeni ovih metoda.

Ono što je zajedničko Evolutivnim algoritmima (EA) i veštačkim neuronskim mrežama je da teorijski proističu iz primene biloških principa na naučna istraživanja. Poslednjih godina, više istraživača pokušava da kombinuje EA sa ANN kako bi na taj način kombinujući prednosti obe metode kreirali još efikasniji metod inteligentnog proračuna. To se uglavnom odnosi na korišćenje EA za optimizaciju arhitekture mreže, predprocesiranje ulaznih podataka mreže, spajanje više mreža, itd.

2.8.2 Metod optimizacije rojevima čestica (PSO – Particle Swarm Optimization)

Optimizacija rojevima čestica (Particle swarm optimization - PSO) predstavlja metodu inspirisanu inteligencijom grupe. Posmatrajući prirodni proces udruživanja jedinki u grupe, može se primetiti da bespomoćne jedinke postaju ozbiljan protivnik kada se udruže. Na taj način akumuliraju inteligenciju stvarajući kolektivnu inteligenciju, pa interakcijom i razmenom znanja između jedinki cela grupa veoma brzo napreduje. U tom posmatranju jata ptica u potrazi za hranom kao skupa čestica uočeno je da svaka čestica tj. ptica koristi nekoliko pravila za prilagođavanje svog leta kao što su:

- izbegavanje sudara,
- prilagođavanje brzine leta,
- pokušaj ostanka u blizini ostalih ptica.

Inspirisani ovim uočenim činjenicama, Eberhart i Kennedy [155] dolaze na ideju kreiranja algoritma za rešavanje optimizacionih problema. U sam algoritam uključuju i sociološku interekciju između čestica u roju, tako da svaka čestica pamti svoje do tada pronađenu najbolju poziciju, ima uvid u najbolje pozicije svojih suseda i kretanje usmerava uzimajući u obzir obe komponente. U PSO metodi svaka čestica odgovara jednom potencijalnom dopustivom rešenju i kreće se u d-

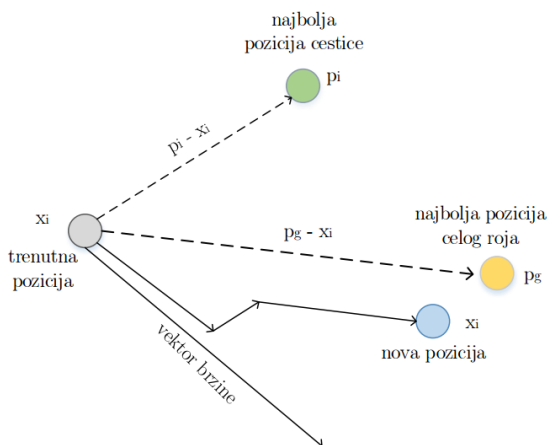
dimenzionom dopustivom prostoru rešenja. Čestice pokušavaju da poprave svoju poziciju koristeći svoje iskustvo iz prethodnih pozicija, ali i iskustva drugih čestica (celog roja ili podskupa-okoline čestice). Poziciju čestice i , $i = 1, 2, \dots, n$ u roju od n čestica karakteriše d dimenzioni vektor položaja $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{id})$ i vektor brzine, odnosno gradijenta (pravca) u kome bi se čestica kretala bez drugih uticaja $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{id})$. Najbolju poziciju čestice i do tekućeg trenutka predstavlja vektor $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{id})$ a najbolju poziciju celog roja vektor $\mathbf{p}_g = (p_{g1}, p_{g2}, \dots, p_{gd})$. Osnovni PSO algoritam se sastoji od dela inicijalizacije gde se generiše roj čestica u pretraživačkom prostoru na slučajnim pozicijama i sa slučajnim pravcima kretanja čestica. U tako generisanom roju potrebno je pronaći i sačuvati najbolju česticu. Zatim sve dok nije ispunjen kriterijum zaustavljanja izvršava se ažuriranje vektora brzine i pomeranje čestica na nove pozicije. U tako dobijenom roju čestica ažuriraju se najbolje pozicije čestica ako je rešenje popravljeno kao i najbolja čestica celog roja ako je došlo do popravljavanja trenutno najboljeg rešenja. U svakoj iteraciji j ažuriranje vektor brzine čestice i se obavlja pomoću sledeće formule:

$$v_{id}^j = w \cdot v_{id}^{j-1} + c_1 \cdot r_1 (p_{id}^j - x_{id}^j) + c_2 \cdot r_2 \cdot (p_{gd}^j - x_{id}^j) \quad (2.23)$$

gde je w parametar inercije koji kontroliše uticaj prethodnih brzina čestice na trenutnu, c_1 faktor kognitivnog učenja (uticaj iskustva čestice), c_2 faktor socijalnog učenja (uticaj iskustva celog roja) i r_1, r_2 slučajne konstante iz izabrane uniformne raspodele $U[0, 1]$. Pomeranje čestice i na novu poziciju \mathbf{x}_i u iteraciji j se vrši po formuli:

$$x_{id}^{j+1} = x_{id}^j + v_{id}^j \quad (2.24)$$

Vrednosti v_{id} se ograničavaju na vrednosti iz unapred zadatog segmenta $[v_{\min}, v_{\max}]$, kako čestica ne bi izašla iz dopustivog prostora pretrage. Odnos između lokalnog i globalnog pretraživanja prostora dopustivih rešenja se može kontrolisati parametar w . Za veće vrednosti w pojačava se globalna pretraga, dok se za manje vrednosti w pojačava lokalna pretraga.



Slika 2-20 Pomeranje čestica na novu poziciju

Opisani koraci se mogu predstaviti algoritmom koji je prikazan na Slici 2.21.

```

slučajno generisi roj čestica;
ponavljaj {
   $f_i = f(x_i)$ ;
  za sve čestice  $i$  {
    za svaku koordinatu  $d$  {

$$v_{id}^j = w \cdot v_{id} + c_1 \cdot r_1 (p_{id} - p_{id}) + c_2 \cdot r_2 \cdot (p_{gd} - x_{id}),$$


$$x_{id} = x_{id} + v_{id}$$

    }
    ako ( $f(x_i) < f(p_i)$ ) onda {
       $p_i = x_i$ ;
    }
    ako ( $f(x_i) < f(p_g)$ ) {  $p_g = x_i$ ; }
  }
} (dok nije zadovoljen kriterijum zaustavljanja)

```

Slika 2-21 Opšti algoritam optimizacije rojevima čestica

2.8.3 Genetski algoritmi (GA)

Genetski algoritmi su heuristička metoda optimizacije koja rešava određene računarske probleme simulirajući mehanizam prirodne evolucije. Pojam genetskog algoritma kao modela predložen je 70-ih godina prošlog veka od strane Džona Holanda [156]. On je u svom radu predložio genetski algoritam kao računarski proces koji imitira evolutivni proces u prirodi. Ovaj algoritam se često naziva prost genetski algoritam ili kanonski genetski algoritam. Više o konceptu genetskih algoritama se može videti u [157],[158], [159].

Prost genetski algoritam koristi binarnu reprezentaciju, prostu selekciju, ukrštanje sa jednom tačkom prekida i prostu mutaciju. Ova varijanta genetskog algoritma može se naći u [156]. Prost genetski algoritam je često bio tema mnogih ranijih studija i jos uvek se koristi kao merilo za novije genetske algoritme. Na žalost, ovaj algoritam ima i puno mana: binarna reprezentacija je suviše restriktivna, mutacija i ukrštanje koje koristi mogu da se primenjuju samo za binarne i celobrojne reprezentacije, selekcija je osetljiva na konvergirajuće populacije sa bliskim vrednostima cilja i konvergencija ka rešenju je jako spora.

Kao sto je već spomenuto, genetski algoritmi simuliraju prirodni evolutivni proces. Za evolutivne procese kao i za genetske algoritme može se ustanoviti da:

- postoji populacija jedinki;

- neke jedinke su bolje prilagođene okolini;
- bolje jedinke imaju veću verovatnoću preživljavanja i reprodukcije;
- osobine jedinki zapisane su pomoću genetskog koda;
- deca nasleđuju osobine roditelja;
- jedinke mogu mutirati.

Kod genetskih algoritama jedinke predstavljaju trenutne aproksimacije rešenja problema koji se rešava. Svaka jedinka se kodira i svakoj jedinki se pridružuje određena mera kvaliteta, koja se određuje pomoću funkcije cilja. Prilikom inicijalizacije generiše se početna populacija. Ona se obično generiše slučajnim izborom rešenja iz domena. Dozvoljeno je da se početno rešenje dobijeno nekom drugom metodom optimizacije doda početnoj populaciji. Zatim, sledi proces koji se ponavlja dok god se ne zadovolji uslov zaustavljanja. Taj proces se sastoji od izvršavanja genetskih operatora selekcije, ukrštanja i mutacije. Osim procene kvaliteta koja se mora obaviti nad jedinkama, sve operacije genetskog algoritma se sprovode nad kodiranim jedinkama. Višestrukom primenom operatora selekcije uglavnom loše jedinke izumiru, a bolje ostaju i u sledećem koraku se ukrštaju. Ukrštanjem se prenose osobine roditelja na decu. Mutacijom se menjaju osobine jedinki slučajnom promenom gena. Jedan ovakav postupak omogućuje da iz generacije u generaciju raste prosečan kvalitet populacije. Osnovni koraci genetskog algoritma prikazani su na sledećoj slici (Slika 2.22).

Od problema koji se rešava obično zavise samo dve komponente genetskog algoritma: kodiranje problema, tj. reprezentacija rešenja i funkcija cilja. U prvoj fazi kreiranja genetskog algoritma donosi se odluka o genetskoj reprezentaciji mogućeg rešenja datog problema.

```

Unošenje_Ulaznih_Podataka();
Generisanje_Početne_Populacije();
While (! Kriterijum_Zaustavljanja_GA())
{
    for (i = 1; i < Npop; i++)
        obj[i] = Funkcija_Cilja(i);
    Funkcija_Prilagođenosti();
    Selekcija();
    Ukrštanje();
    Mutacija();
}
Štampanje_Izlaznih_Podataka();

```

Slika 2-22 Osnovna varijanta genetskog algoritma

Ovo uključuje definisanje jedinki i njihovo pridruživanje mogućim rešenjima. Reprezentacija rešenja može dosta da utiče na efikasnost genetskog algoritma, pa je izbor reprezentacije veoma važan. Međutim, naći "pravu" reprezentaciju za problem koji se rešava jedan je od najtežih delova pravljenja dobrog genetskog algoritma. Uglavnom se polazi od prakse i dobrog poznavanja domena primene.

Takođe, genetski algoritmi, kao i svaka druga metoda optimizacije, zahtevaju neku kvantitativnu meru kvaliteta, tj. ispravnosti predloženog rešenja. Ova mera se zove prilagođenost

(na engl. fitness) i daje je funkcija cilja koja se još u literaturi naziva funkcija sposobnosti ili funkcija ocene kvaliteta. Važno je spomenuti da se sve operacije genetskog algoritma sprovode nad jedinkama osim ocene njihovog kvaliteta, tj. ocene prilagođenosti koja se mora odrediti nad dekodiranim jedinkama – potencijalnim rešenjima. Funkcija cilja je najvažniji deo genetskog algoritma. Ona predstavlja ključ procesa selekcije određujući koje će se jedinke eliminisati, a koje će ostati u populaciji. Na osnovu ove funkcije se određuje koliko je jedinka dobra, tj. računa se njena prilagođenost. Obično, što je prilagođenost jedinke veća, to jedinka ima veću verovatnoću preživljavanja. Znači, jedinke s malom prilagođenošću imaju i malu verovatnoću preživljavanja.

Postoji više načina definisanja funkcije cilja. Ona treba da bude relativno brza jer se primenjuje u svakoj generaciji nad svakim članom populacije. Vredi spomenuti i da je definisanje ove funkcije za zadati problem jedan od najtežih zadataka pravljenja dobrog genetskog algoritma.

3. VEŠTAČKE NEURONSKE MREŽE ZA PREDVIĐANJE

3.1. Uvodna razmatranja

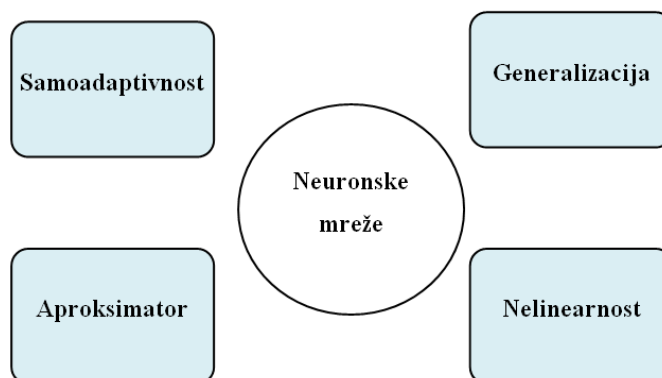
Jedna od osnovnih primena veštačkih neuronskih mreža je predviđanje [41]. Veštačke neuronske mreže obezbeđuju moćan alternativni alat kako za istraživače tako i za praktičare kada je u pitanju predviđanje. Nekoliko bitnih karakteristika čine veštačke neuronske mreže atraktivnim za realizaciju različitih zadataka predviđanja. Najpre, nasuprot tradicionalnim metodama zasnovanim na modelima, veštačke neuronske mreže pripadaju samoadaptivnim metodama zasnovanim na podacima gde postoji samo nekoliko pretpostavki o modelima za probleme koji se proučavaju. Kao što je već rečeno u prethodnom poglavlju, one uče iz primera pokušavajući da uhvate funkcionalne veze između podataka čak i kad su te veze i odnosi nepoznati ili teško opisivi. To znači da su veštačke neuronske mreže jako pogodne za probleme kod kojih rešenja zahtevaju znanja koja je teško specificirati ali za koja postoji dovoljna količina podataka ili observacija. U tom smislu, veštačke neuronske mreže mogu biti posmatrane i tretirane kao multivarijantne nelinearne neparametarske statističke metode (White 1989, Ripley 1993, Cheng Titterington 1994) [42],[43],[44]. Ovakav pristup modeliranju sa sposobnošću da se uči iz iskustva je veoma koristan za mnoge praktične probleme jer je često lakše imati podatke nego dobre teorijske pretpostavke o zakonima kojima se upravlja sistemima iz kojih se generišu ti podaci. Problem kod ovakvog pristupa modeliranja zasnovanog na upravljanju podacima je što pravila nisu uvek očigledna a observacije su zamaskirane šumovima. U svakom slučaju, ovakvi pristupi modeliranju su u pojedinim situacijama jedino izvodljivi za rešavanje problema u realnom svetu.

Druga karakteristika veštačkih neuronskih mreža bitna za predviđanje je sposobnost generalizacije. Nakon učenja iz uzorka odnosno podataka koji su dati, veštačke neuronske mreže korektno reaguju na deo podataka koji nije iskorišćen kao uzorak čak i ako uzorak sadrži šumove odnosno neke defektne informacije. Kako se predviđanje realizuje kao predviđanje budućeg ponašanja na osnovu primera ponašanja iz prošlosti, upravo je predviđanje idealna oblast za primenu neuronskih mreža u načelu.

Treća karakteristika je činjenica su veštačke neuronske mreže univerzalni funkcionalni aproksimatori. Pokazalo se da mreža može da aproksimira bilo koju kontinualnu funkciju na bilo koju željenu tačnost (Irie Miyake 1988, Hornik 1989, Cybenko 1989, Funahashi 1989, Hornik 1991, 1993) [45], [46], [47], [48], [49], [50]. Veštačke neuronske mreže imaju mnogo opštije i fleksibilnije funkcionalne forme u odnosu na tradicionalne statističke metode. Bilo koji model za predviđanje pretpostavlja da postoji određeni odnosi (poznati ili nepoznati) između ulaza (prošle

vrednosti vremenske serije ili drugih relevantnih promenljivih) i izlaza (buduće vrednosti). Najčešće, tradicionalni statistički modeli za predviđanje imaju ograničenja u oceni ove određene funkcije usled kompleksnosti realnog sistema. Veštačke neuronske mreže mogu biti dobar alternativni metod za identifikaciju ove funkcije.

Konačno, veštačke neuronske mreže su nelinearne. Predviđanje je dugo vremena bilo u domenu linearne statistike. Tradicionalni pristupi predviđanju vremenskog niza, kao što su Box – Jenkins ili ARIMA metod (Box 1976, Pankratz 1983) [51], [52] pretpostavljaju da su vremenske serije koje su predmet proučavanja generisani iz linearnih procesa. Linearni modeli imaju prednosti u činjenici da se mogu razumeti i analizirati do najsitnijih detalja ali i zbog lakog razumevanja i implementacije. Međutim, ovi linearni modeli mogu biti u potpunosti nepogodni i neprihvatljivi ako je posmatrani mehanizam nelinearan. Tada je neracionalno unapred pretpostaviti da je određena realizacija vremenske serije generisana linearnim procesom. U stvari, sistemi u realnom svetu su često nelinearni. (Granger Terasvirta 1993) [53]. 80-tih godina 20. veka nekoliko nelinearnih modela vremenske serije su razvijeni kao što su bilinearni model (Granger Anderson, 1978) [54], „threshold autoregressive” model (TAR) (Tong Lim, 1980) [55] kao i (ARCH) „autoregressive conditional heteroscedastic“ model (Engle, 1982) [56]. Međutim, ovi nelinearni modeli su i dalje ograničeni jer se eksplicitan odnos u vremenskoj seriji mora pretpostaviti hipotetički sa malo znanja o određenom zakonu. U stvari, formulacija nelinearnog modela za konkretan skup podataka je veoma težak zadatak jer postoji mnogo mogućih nelinearnih uzoraka i prespecificirani nelinearni model moda neće biti dovoljno opšti da obuhvati sve važne karakteristike. Veštačke neuronske mreže su sposobne da realizuju nelinearno modeliranje bez unapred poznatog znanja o odnosima između ulaznih i izlaznih promenljivih. Upravo zato su veštačke neuronske mreže opštiji i fleksibilniji alat za predviđanje.



Slika 3-1 Osnovne karakteristike neuronskih mreža za predviđanje

Ideja za korišćenje veštačkih neuronskih mreža za predviđanje nije nova. Prva primena datira od 1964. godine. Hu (1964) [57] je u svojoj tezi koristio Widrow-ovu adaptivnu linearnu mrežu za prognoziranje tj. predviđanje vremena. Usled nedostatka algoritma za obučavanje u to vreme, rezultati istraživanja su bili kranje ograničeni. Tek 20-ak godina kasnije, tačnije 1986. godine sa uvođenjem algoritma sa propagacijom unazad – „backpropagation“ algoritma (Rummelhart 1986) [58] načinjen je veliki korak u razvoju veštačkih neuronskih mreža za potrebe predviđanja. Werbos (1974) (1988) [59], [60] prvi formuliše propagaciju unazad i nalazi da veštačke neuronske mreže obučene propagacijom unazad nadmašuju tradicionalne statističke metode kao što su regresija Box-jenkins-ova metoda. Lapedes i Farber (1987) [61] izrađuju studiju u kojoj zaključuju da se veštačke neuronske mreže mogu koristiti za predviđanje nelinearnih vremenskih nizova. Weigend (1990) (1992) [62], [63] Cotrell (1995) [64] daju osnovne karakteristike strukture neuronskih mreža za predviđanje vremenskih nizova u realnom svetu. Tang (1991) [65] Sharda i Patil (1992) [66] i Tang i Fishwick (1993) [67] prikazuju različite izveštaje rezultata komparacije predviđanja između Box-Jenkins i modela veštačke neuronske mreže.

3.2. Predviđanje vremenskih serija

Jedan od najuzbudljivijih izazova kod ljudskog istraživanja je predviđanje budućnosti. Potreba za znanjem o budućnosti ne dolazi samo zbog prirodne ljudska radoznalosti, već i zbog neophodnosti da se poboljša trenutna tehnologija i metode.

Termin predviđanje, koji često menja termin prognoziranje je veoma širok. On sublimira metodologije za prognozu vremena, predviđanje finansijskih podataka, predviđanje bioloških karakteristika, tehnoloških parametara, rezultate konjskih trka, potrošnje energije. Međutim, može se reći da je predviđanje uvek zasnovano na modelu procesa koji se predviđa.

Uopšteno, dva su glavna pristupa moguća za modeliranje – model „bele kutije“ i „model „crne kutije“.

Prvi metod koristi unapred poznato znanje o sistemu koji se previđa. Tipični model „bele kutije“ je matematički model zasnovan na fizičkim i hemijskim zakonima. Model „crne kutije“ je zasnovan na identifikaciji podataka koji dopuštaju osvežavanje početnog prediktora da bi se dobili odgovarajući rezultati. Tipični modeli „crne kutije“ su veštačke neuronske mreže.

Objavljeno je mnogo radova sa primenom veštačkih neuronskih mreža za predviđanje. Izbor odgovarajuće veštačke neuronske mreže i njeno podešavanje obično nisu trivijalna stvar. Postoji mnogo parametara koji utiču na kvalitet predviđanja. Jedan od njih je broj ulaznih neurona – odnosno dužina ulaznog vektora prediktora.

Uopšteno, veličina ulaznog vektora zavisi od frekvencije signala. Neki autori su pomenili „phrase“ memoriju koja se odnosi na predviđanje na n prostornih intervala vremena. Iako, tačna metodologija koja obezbeđuje striktno pravilo za projektovanje nultog sloja posebne veštačke neuronske mreže ne postoji. Motivacija ovog učešća dolazi iz ranijih istraživanja i studija uticaja veličine ulaznog vektora za izabrane strukture veštačkih neuronskih mreža.

Predviđanje se zasniva na informacijama iz prošlosti i na trenutnom stanju.

Svi rešavaju problem predviđanja svakog dana sa različitim stepenom uspeha. Na primer, vreme, potrošnja energije,...

U tehničkom domenu parametri predviđanja sistema se mogu izraziti preko jednačina tj. predviđanje je svedeno na rešavanje tih jednačina. Međutim, u praksi se srećemo sa takvim problemima gde bi takav opis bio jako komplikovan ili čak nemoguć.

Moguće je koristiti različite aproksimacije, na primer regresija (vraćanje na staro) zavisnosti promenljivih koje se predviđaju od drugih događaja što se onda ekstrapolira u budućnosti. Nalaženje takve aproksimacije može takođe biti jako teško. Ovakav pristup uopšteno predstavlja kreiranje modela predviđanja događaja.

Veštačke neuronske mreže se mogu koristiti za predviđanje sa različitim nivoom uspeha. Prednost toga je uključivanje automatskog učenja zavisnosti samo od merenih podataka bez ikakve potrebe za dodavanjem drugih informacija. Neuronska mreža se obučava na osnovu istorijskih podataka sa nadom da će se na taj način otkriti skrivene zavisnosti i da će biti moguće iskoristiti ih za predviđanje budućnosti. Drugim rečima, neuronska mreža nije predstavljena kao eksplicitno dat model. Ona je više kao crna kutija koja je sposobna da uči.

Moguće je predviđati različite tipove podataka. Međutim ovde pričamo o predviđanju vremenskog niza. Pri tome treba imati u vidu da te vrednosti zavise i od drugih faktora sem vremena.

Osnovni kriterijumi za klasifikaciju tipova predviđanja su:

- Podaci koje imamo za učenje predviđanja i za predviđanje
- Šta želimo da predvidimo – vrednost ili trend?

Kada želimo da dobijemo tačnu vrednost (ili više vrednosti) promenljive u budućnosti, tada predviđamo vrednost. Druga mogućnost je predvideti trend promenljive tj. da li vrednost ide gore ili dole bez razmatranja veličine promene – tada predviđamo trend.

Za predviđanje vremenske serije obično imamo vrednosti promenljive u jednakim intervalima – tada pokušavamo da predvidimo razvoj vrednosti zasnovan na istorijskim vrednostima i samom vremenu. U ovom slučaju istorijska vremenska serija treba da bude dovoljno duga i sa dovoljnom gustinom.

Možemo imati dodatne informacije o vremenskoj seriji, kao na primer vrednosti izvoda. Ova informacija se može koristiti za još tačnija predviđanja. Važna informacija može biti dodata korišćenjem interventnih promenljivih (interventni indikatori), koji predstavljaju informaciju o vremenskoj seriji ili informaciju o periodu koji se predviđa. Na primer, kada predviđamo potrošnju energije tada poznavanje informacije da li predviđamo za ponedeljak ili subotu može dramatično da poboljša predviđanje. Ova informacija ne prati eksplicitno vremensku seriju i mora biti dodata. Veoma je od pomoći korišćenje vrednosti interventnih indikatora kada se kreira model koji će se koristiti za predviđanje.

Možemo takođe da imamo informaciju o drugim zavisnim promenljivim, posebno u vremenskoj seriji. Iz istorije zavisne promenljive možemo rezonovati o drugim promenljivim. Odnos se može izraziti na različite načine. Primer je statički zbir (ili spora promena) 2 promenljive. To ne mora da bude izraženo eksplicitno – na primer promena cena akcija na berzi u jednom sektoru je zavisna ali ju je teško izraziti nekim proračunom. Ovakva vrsta informacije se bira u nadi da će biti koherentna sa predviđenom vrednošću ali ne možemo biti sigurni u to.

Prednost upotrebe veštačkih neuronskih mreža za predviđanje je da su one sposobne da uče iz primera i da su nakon završenog učenja sposobne da uhvate skrivene i jako nelinearne zavisnosti, čak i kada ima značajnih nepreciznosti u skupu podataka za učenje.

Nedostatak veštačkih neuronskih mreža je što uče zavisnosti validne samo za određeni period pa se greška predviđanja ne može generalizovano proceniti.

Predviđanje vremenske serije korišćenjem veštačkih neuronskih mreža se sastoji od učenja mreže istorijom promenljivih u izabranom ograničenom vremenu i primenom naučene informacije na budućnost. Podaci iz istorije su obezbeđeni za ulaze neuronske mreže a očekujemo podatke za budućnost iz izlaza mreže.

Više informacija ne znači bolje predviđanje. Uvek je značajno izabrati relevantne informacije.

3.3 Primena neuronskih mreža za predviđanje

Problemi predviđanja postoje u različitim oblastima pa je i literatura o predviđanju pomoću veštačkih neuronskih mreža raznovrsna i zastupljena u najrazličitijim poljima tako da je istraživačima jako teško da sakupe sve radove iz različitih oblasti kada je u pitanju predviđanje pomoću veštačkih neuronskih mreža.

Jedna od prvih uspešnih primena veštačkih neuronskih mreža za predviđanje je saopštena od strane Lapedes i Farber (1987) [61]. Koristeći dva deterministička haotična vremenska niza generisana logičkom mapom i Glass-Mackey –ovom jednačinom, oni su projektovali feedforward

neuronsku mrežu koja može tačno da oponaša i predviđa takve nelinearne dinamičke sisteme. Njihovi rezultati pokazuju da veštačke neuronske mreže mogu da se koriste za modeliranje i predviđanje nelinearnih vremenskih nizova sa veoma visokom tačnošću.

Sledeći Lepedesa i Farbera, veliki broj radova je bio posvećen korišćenju veštačkih neuronskih mreža za analizu i predviđanje determinističkih haotičnih vremenskih nizova sa ili bez šumova. Haotični vremenski nizovi se uglavnom javljaju kod inženjerskih i fizičkih nauka jer većina fizičkih fenomena odnosno pojava se generišu nelinearnim haotičnim sistemima. Kao rezultat, mnogi autori iz oblasti fizike su se bavili ovom temom. Lowe i Webb su (1990) [68] diskutovali odnos između dinamičkih sistema i funkcionalne interpolacije sa veštačkim neuronskim mrežama. Depisch (1991) [69] je predložio hijerarhijski obučen model veštačke neuronske mreže kod koga je napravljen veliki napredak u dostizanju visoke tačnosti za predviđanje dva haotična sistema.

Postoji jako obimna literatura o upotrebi veštačkih neuronskih mreža kod finansijskih aplikacija. (Trippi i Turban, 1993; Gately, 1996) [70], [71]. Veštačke neuronske mreže se koriste za predviđanje bankrotstva i poslovnih gubitaka, (Wilson i Sharda, 1994) [72], kretanje stranih valuta (Weigend, 1992) [63]; cene akcija na berzi (Grudnitski i Osburn, 1993) [73] i druge oblasti kod finansijskih aplikacija.

Druga veoma važna oblast primene veštačkih neuronskih mreža je predviđanje potrošnje električne energije odnosno električnog opterećenja. Predviđenja opterećenja je oblast koja zahteva visoku tačnost jer je snabdevanje strujom direktno zavisno od predviđanja potreba za optrećenjem. Park i Sandberg (1991) [74] su ustanovili da jednostavna neuronska mreža sa temperaturom kao ulaznom informacijom pokazuje mnogo bolje karakteristike nego časovno predviđanje zasnovano na tehnici regresije. Kratkoročno predviđanje električnog opterećenja veoma je slično kratkoročnom predviđanju toplotnog opterećenja kod sistema daljinskog grejanja što je deo teme ove disertacije.

Mnogi istraživači koriste podatke sa dobro poznatog M-takmičenja (Makridakis 1982) [75] za komparaciju performansi modela veštačkih neuronskih mreža sa tradicionalnim statističkim modelima. M – takmičenje je uglavnom usmereno na polje biznisa, ekonomije i finansija. Treba pomenuti nekoliko važnih radova [65], [66], [76] i [77]. Na Santa Fe takmičenju iz predviđanja (Weigend i Gershenfeld, 1993) [78], šest nelinearnih vremenskih nizova iz potpuno različitih disciplina kao što su fizika, psihologija, astrofizika, finansije i muzika su korišćena.

Mnogi drugi problemi predviđanja su rešeni zahvaljujući veštačkim neuronskim mrežama. Na primer, cene smeštaja (Kohzadi 1996) [79], temperatura okoline (Balestrino 1994) [80], opterećenje komponenti helikoptera (Haas 1995)[81], međunarodni putnički vazdušni saobraćaj (Nam i Schaefer 1995) [82], makroekonomske indikacije (Maasoumi 1994) [83], nivo ozona (Ruiz-

Suarez, 1995) [84], inventar personala (Huntley, 1991) [85], padanje kiše (Chang, 1991) [86], rečni tok (Karunanithi, 1994) [87], prosečne ocene studenata (Gorr, 1994) [88], životni vek alata (Ezugwu, 1995) [89], ukupna industrijska proizvodnja (Aiken, 1995) [90], putanje (Payeur, 1995) [91], saobraćaj (Duliba, 1991) [92], potrebe za vodom (Lubero, 1991) [93] profil pritiska vetra (Turkkan i Srivastava, 1995) [94].

3.4. Metodologija

Postoji mnogo različitih načina za konstruisanje i implementaciju veštačkih neuronskih mreža za predviđanje. Većina studija koristi višeslojni perceptron ([65], [66], [67]) dok ostale koriste neke varijacije višeslojnog perceptrona. Pored feedforward neuronskih mreža koje se koriste uglavnom za predviđanje treba ovde pomenuti da i rekurentne neuronske mreže igraju važnu ulogu kod predviđanja. Kod [95] može se videti odnos između rekurentnih mreža i opšteg ARIMA modela. Upotreba rekurentnih neuronskih mreža za predviđanje se može naći kod [96], [95] i [97].

Narendra i Parthasarathy (1990) [98] i Levin i Narendra (1993) [99] diskutuju na temu identifikacije i upravljanja nelinearnim dinamičkim sistemima korišćenjem feedforward i rekurentnih neuronskih mreža. Teorijski i rezultati simulacije iz ovih studija obezbeđuju neophodnu osnovu za tačnu analizu i predviđanje nelinearnih dinamičkih sistema.

Lapedes i Farber (1987) [61] su prvi iskoristili višeslojnu feedforward neuronsku mrežu za potrebe predviđanja. Jones je 1990 proširio [61], korišćenjem efikasnijeg Newton-ovog metoda za obuku mreže umesto standardne propagacije unazad. Zasnivajući se na oba gore navedena rada, Poli i Jones (1994) [100] prave stohastički model višeslojnog perceptrona sa slučajnim (proizvoljnim) vezama između jedinica i funkcijama održivih šumova.

Nalaženje racionalnog modela je veoma izazovan zadatak pri čemu posebno treba voditi računa da ne dođe do pretreniranja mreže odnosno „overfitinga“, što se često događa kod veštačkih neuronskih mreža. Ovi racionalni modeli imaju sposobnost prepoznavanja ali i sposobnost generalizacije. Baum i Hausler (1989) [101] su diskutovali o odnosu između generalizacije mreže i veličine uzorka za obučavanje. Amirikian i Nishimura su našli da odgovarajuća veličina mreže zavisi od specifičnih zadataka učenja.

Neki istraživači su se bavili pitanjem nalaženja mreže odgovarajuće veličine za predviđanje vremenskih nizova u realnom svetu. Lachtermacher i Fuller (1995) [102] su primenili hibridni pristup kombinujući Box-Jenkins model i veštačke neuronske mreže za potrebu minimizacije veličine mreže i zahtevanih podataka za obuku. U eksploatacionoj fazi, Box-Jenkins metod se koristi za nalaženje odgovarajućeg ARIMA modela. U fazi modeliranja, pravi se veštačka

neuronska mreža sa informacijama o komponentama kašnjenja vremenske serije dobijenih u prvom koraku. Kuan i Liu (1995) [97] predlažu proceduru u dva koraka za konstrukciju feedforward i rekurentne neuronske mreže za predviđanje vremenskog niza. U prvom koraku koristi se kriterijum predvidive stohastičke kompleksnosti (Rissanen, 1987) [103] za izbor odgovarajuće strukture mreže a onda je iskorišćen metod nelinearnih najmanjih kvadrata za ocenu parametara mreže. Barker (1990) [104] i Bergerson i Wunsch (1991) [105] su razvili hibridne sisteme kombinujući veštačke neuronske mreže sa ekspertnim sistemom.

Pelikan (1992) [106] predstavio je metod kombinujući nekoliko neuronskih mreža sa maksimalnim ostatkom dekorelacije. Rezultati iz kombinovane mreže pokazuju poboljšanje u odnosu na pojedinačnu mrežu linearnu regresiju. Ginzburg i Horn (1994) [107] takođe koriste kombinovane neuronske mreže za poboljšanje tačnosti predviđanja vremenske serije. Dok je prva mreža klasična za modeliranje stvarne vremenske serije, druga se koristi za modeliranje ostatka iz prve mreže i za predviđanje grešaka prve mreže. Wedding i Cios (1996) [108] opisuju metod kombinujući neuronsku mrežu sa radijalnom funkcijom (RBFN) i Box-Jenkins modele za poboljšanje pouzdanosti predviđanja vremenskih nizova. Donaldson i Kamstra (1996) [109] su predložili predviđanje kombinujući veštačke neuronske mreže sa kombinovanim metodama linearnog predviđanja kako bi prevazišli na taj način nedostatke linearne metode predviđanja.

Zhang i Hutchinson (1993) [110] i Zhang (1994) [111] opisuju metod veštačke neuronske mreže zasnovan na opštem modelu u prostoru stanja. Fokusirajući se na višestruke korake predviđanja, oni izražavaju sumnju da individualna mreža može biti dovoljno moćna da obuhvati sve informacije iz dostupnog skupa podataka pa zato predlažu kaskadni pristup koji koristi nekoliko kaskadnih neuronskih mreža za predviđanje višestrukih budućih vrednosti. Metod je u osnovi iterativan i jedna mreža je potrebna za predviđanje svakog dodatnog koraka. Prva mreža se konstruiše samostalno na osnovu prošlih observacija kao ulaza da proizvede početno jedan korak unapred predviđanje. Tada se druga mreža konstruiše korišćenjem svih prošlih observacija i prethodnih predviđanja kao ulaza za generisanje i jedan korak i dva koraka unapred predviđanja. Ovaj proces se ponavlja dok konačno poslednja mreža ne koristi sve prošle observacije kao sve prethodne vrednosti predviđanja i na taj način dovede do željenog predviđanja u više koraka.

Chackraborty i saradnici (1992) [112] su razmatrali korišćenje veštačkih neuronskih mreža za predviđanje multivarijantnih vremenskih serija. Korišćenjem jednovremene strukture trivarijantne vremenske serije, oni usvajaju kombinovani pristup neuronskih mreža koji proizvodi mnogo bolje rezultate nego mreže posebno za svaku pojedinačnu vremensku seriju. Vishwakama (1994) [113] koristi dvoslojnu neuronsku mrežu za predviđanje višestruke ekonomske vremenske serije zasnovanu na teoriji Kalmanovog filtra modela u prostoru stanja.

Veštačke neuronske mreže se takođe proučavaju kao pomoćni alat za izbor metode predviđanja i identifikaciju ARIMA modela. Chu i Widjaja (1994) [114] predlažu sistem dve neuronske mreže za izbor metode predviđanja. Prva mreža se koristi za prepoznavanje potrebnih uzoraka u podacima a druga mreža se koristi za izbor metode predviđanja između šest modela eksponencijalnog izravnivanja zasnovanim na potrebnim uzorcima iz podataka, horizonta predviđanja i tipa industrije odakle dolaze podaci. Testiranjem simuliranih i stvarnih podataka, njihov sistem ima visok odnos tačne identifikacije potrebnih uzoraka i daju dobru preporuku za adekvatan metod predviđanja.

Jhee i saradnici (1992) [115] predlažu pristup veštačkih neuronskih mreža za identifikaciju modela Box-Jenkins. Dve veštačke neuronske mreže se odvojeno koriste za modeliranje autokorelacione funkcije (ACF) i parcijalne autokorelacione funkcije (PACF) stacionarnih serija i njihovi izlazi određuju red ARIMA modela. U narednom radu, Lee i Jhee (1994) [116] razvijaju sistem veštačke neuronske mreže za automatsku identifikaciju Box-Jenkins modela korišćenjem proširene autokorelacione funkcije (ESACF) kao ekstraktora karakteristika vremenske serije. Viešslojni perceptron sa mrežom predprocesiranja filtriranja šumova se projektuje kako bi identifikovao tačan ARIMA model. Oni nalaze da ovaj sistem daje dobre rezultate za veštački generisane podatke i realne vremenske serije i zaključuju da su performanse ESACF superiornije u odnosu na ACF i PACF u identifikaciji tačnog ARIMA modela.

3.5 Osnove modeliranja veštačke neuronske mreže za predviđanje

Uprkos mnogim zadovoljavajućim karakteristikama veštačkih neuronskih mreža, izrada neuronske mreže za predviđanje za pojedinačni problem predviđanja nije prost zadatak pitanja vezana za modeliranje koja utiču na performanse veštačke neuronske mreže moraju biti pažljivo razmatrana. Prva kritična odluka je određivanje odgovarajuće arhitekture, odnosno broj slojeva, broj neurona u svakom sloju, i broj veza između neurona. Druga odluka obuhvata izbor aktivacionih funkcija skrivenih i izlaznih neurona, algoritma za obuku, transformacije podataka ili metode normalizacije, skupa podataka za obuku i testiranje i mere performansi. U pregledu trenutnih dostignuća u oblasti veštačkih neuronskih mreža za predviđanje Zhang i saradnici [117] daju prikaz primene različitih parametara (ulazni čvorovi, skriveni slojevi, aktivacione funkcije, algoritmi za obučavanje, normalizacija podataka, mere performansi) za različite oblasti predviđanja i deo tog pregleda je dat u Tabeli 3.1.

Tabela 3-1 Pregled izbora arhitekture i parametara kod različitih istraživača [117]

Istraživači	Obučavanje /veličina testa	Ulazni čvorovi	Skriveni sloj:čvor	Izlazni čvorovi	Akt. funkcija skrivena:izlazna	Algoritam za obučavanje	Normalizacija podataka	Mere performansi
Chakraborty et al. (1992)	90/10	8	1:8	1	Sigmoid: sigmoid	BP	Log transform	MSE
Cottrell et al. (1995) [64]	220/ ?	4	1:2-5	1	sigmoid:linearna	Drugog reda	Nema	Promenljivi rezidual i BIC
De Groot and Wurtz (1991)	221/35, 55	4	1:0-4	1	Tanh: tanh	BP, LM,...	Eksterna linearna [0,1]	Promenljivi rezidual
Foster et al. (1992)	N-k/k	5,8	1:3,10	1	ND	ND	ND	MAPE
Ginzburg and Horn (1994)	220/35	2	1:3	1	sigmoid:linearna	BP	Eksterna linearna [0,1]	RMSE
Gorr et al. (1994)	90%/10%	8	1:3	1	sigmoid:linearna	BP	Nema	ME i MAD
Grudnitski and Osburn (1993)	ND	4	2:(24)(8)	1	ND	BP	ND	% tačnosti predviđanja
Kang (1991)	70/24 ili 40/24	4,8,2	1,2:varirajuće	1	sigmoid: sigmoid	GRG2	Eksterna linearna [-1,1] ili [0.1,0.9]	MSE, MAPE, MAD
Kohzadi et al. (1996)	240/25	6	1:5	1	ND	BP	Nema	MSE, AME, MAPE
Kuan and Liu (1995)	1245/varirajuće	varirajuće	1:varirajuće	1	sigmoid:linearna	Newton	ND	RMSE
Lachtermacher and Fuller (1995)	100% sintetički	D	1:ND	1	sigmoid: sigmoid	BP	Eksterna prosta	RMSE
Nam and Schaefer (1995)	3,6,9, godina a/1 godina	2	1:12,15,7	1	sigmoid: sigmoid	BP	ND	MAD
Nelson et al. (1994)	N-18/18	varirajuće	1:varirajuće	1	ND	BP	Nema	MAPE
Schoneburg (1990)	42/56	0	2:(10)(10)	1	sigmoid: sinusna, sigmoid	BP	Eksterna linearna [0.1,0.9]	% tačnosti predviđanja
Sharda and Patil (1992)	N-k/k	2	1:12	1,8	sigmoid: sigmoid	BP	„Across channel“ linearna [0.1,0.9]	MAPE
Srinivasan et al. (1994)	84/21	4	2:(19)(6)	1	sigmoid:linearna	BP	„Along channel“ linearna [0.1,0.9]	MAPE
Tang et al. (1991)	42/56	1,12,24	1=ulazni čvor	1,6,12,24	sigmoid: sigmoid	BP	ND	SSE
Tang and Fishwick (1993)	N-k/k	2. mesec 4:kvartal	1=ulazni čvor	1,6,12	sigmoid: sigmoid	BP	Eksterna linearna [0.2,0.8]	MAPE
Vishwakarma (1994)	300/24	6	2.(2)(2)	1	ND	ND	ND	MAPE
Weigend et al. (1992)	221/59 501/215	2 1	1:8,3 1:5	1	sigmoid:linearna tanh: linearna	BP	Nema „Along channel“ statistička	ARV ARV
Zhang (1994)	100 000/500	1	2:(20)(20)	1-5	sigmoid: sigmoid	BP	Nema	RMSE

3.5.1 Arhitektura mreže

Najzastupljenija veštačka neuronska mreža za predviđanje je feedforward neuronska mreža a kako je već navedeno u prethodnom poglavlju veliku primenu kod rešavanja problema predviđanja imaju i rekurentne neuronske mreže. Kako je najpopularniji tip feedforward neuronske mreže višeslojni perceptron (MLP) a kada je u pitanju osnovna arhitektura i njeno projektovanje na primeru MLP se može u najvećoj meri generalizovati izbor adekvatne arhitekture neuronske mreže. Prilikom projektovanja potrebno je odrediti sledeće promenljive:

- broj ulaznih neurona (čvorova)
- broj skrivenih slojeva i skrivenih neurona (čvorova)
- broj izlaznih neurona (čvorova)

Izbor ovih parametara je suštinski zavisn od problema koji se rešava. Iako postoje mnogi različiti pristupi i algoritmi za nalaženje optimalne arhitekture veštačke neuronske mreže, te metode su prilično kompleksne i teške za implementaciju. Sa druge strane, te metode ne pružaju garanciju za izbor optimalnog rešenja za svaki realni problem predviđanja. To znači da danas ne postoji jednostavan striktan metod za određivanje ovih parametara. Smernice su uglavnom heuristične i odnose se na iskustva dobijena eksperimentalno. Upravo zato se često kaže da je projektovanje veštačkih neuronskih mreža pre umetnost nego nauka.

3.5.1.1 Broj skrivenih slojeva i čvorova

Skriveni sloj i njegovi čvorovi igraju veoma važnu ulogu za uspešnu primenu veštačkih neuronskih mreža. Naime skriveni čvorovi u skrivenom sloju dozvoljavaju odnosno omogućavaju neuronskim mrežama da detektuju karakteristiku, da uhvate uzorak u podacima i da realizuju komplikovano nelinearno mapiranje između ulaznih i izlaznih promenljivih. Veoma je jasno da bez skrivenih čvorova, jednostavni perceptroni sa linearnim izlaznim neuronima su ekvivalentni linearnim statističkim modelima za predviđanje. Pod uticajem teorijskih radova koji pokazuju da je jedan skriveni sloj dovoljan za veštačku neuronsku mrežu da aproksimira bilo koju kompleksnu nelinearnu funkciju sa željenom tačnošću, većina autora koristi samo jedan skriven sloj za potrebe predviđanja. Međutim, jedan skriven sloj mreže može zahtevati veliki broj skrivenih čvorova, što nije poželjno jer će se pogoršati vreme obučavanja i pogoršaće se sposobnost generalizacije mreže.

Dva skrivena sloja neuronske mreže mogu da obezbede više koristi za neki tip problema. Neki autori su prepoznali ovaj problem i u svojim radovima koristili više skrivenih slojeva.

(uglavnom dva skrivena sloja) Srinivasan (1994) [119] je koristio dva skrivena sloja što je doprinelo dobijanju kompaktnije arhitekture sa boljom efikasnošću u procesu obučavanja u poređenju sa mrežom sa jednim skrivenim slojem. Zhang [111] je našao da mreže sa dva skrivena sloja mogu da modeliraju zadatak strukturu podataka i obezbede predviđanje mnogo tačnije od mreža sa jednim skrivenim slojem. On je takođe probao i vršio komparacije sa neuronskim mrežama sa više od dva skrivena sloja ali nije postigao bilo kakvo poboljšanje. [119], [47] i [65] su još tada zaključili da neuronska mreža nikada nema potrebe da ima više od dva skrivena sloja kako bi se koristila za rešavanje problema predviđanja. Međutim, korišćenje dva skrivena sloja može dati bolje rezultate za neke specifične probleme, posebno kada je potrebno da jedan skriveni sloj ima puno skrivenih čvorova da bi se postigao željeni rezultat predviđanja.

Zadatak određivanja optimalnog broja skrivenih čvorova je krucijalan ali i jako komplikovan. Uopšteno, poželjnije su mreže sa malim brojem skrivenih čvorova jer obično njihov manji broj dovodi do bolje sposobnosti generalizacije i manje problema sa „overfittingom“. Međutim, mreže sa malim brojem skrivenih neurona možda nisu u stanju da modeliraju i uče iz podataka. Ne postoje teorijske osnove za izbor ovog parametra iako se mogu naći nekoliko sistematskih pristupa.

Najčešći način za određivanje broja skrivenih čvorova je pomoću eksperimenta ili metodom proba-greška. Takođe, predloženo je nekoliko pravila kao što je pravilo da broj skrivenih čvorova zavisi od broja ulaznih uzoraka i da svaki težinski koeficijent treba da ima najmanje deset ulaznih uzoraka (veličina uzorka). Da bi izbegli problem overfitting-a, neki autori su obezbedili empirijska pravila za ograničenje broja skrivenih čvorova. Lachtermacher i Fuller [102] daje heuristično ograničenje broja skrivenih čvorova. Za slučaj najčešćih neuronskih mreža sa jednim skrivenim slojem, postoji nekoliko praktičnih smernica. One uključuju „ $2n+1$ “ ([119]; [120]), „ $2n$ “ ([121]), „ n “ [67], „ $n/2$ “ ([122]), gde je n broj ulaznih neurona odnosno čvorova. Međutim, nijedan od ovih heurističnih izbora ne radi dobro za sve probleme.

Tang i Fishwick [67] su istraživali uticaj skrivenih čvorova i pronašli da broj skrivenih čvorova utiče na performanse predviđanja ali da taj uticaj nije toliko značajan. Poređenjem nekih studija može se ustanoviti da u nekim slučajevima kada je broj skrivenih čvorova bio jednak broju ulaznih čvorova, dobijeni su bolji rezultati predviđanja [123], [67].

3.5.1.2 Broj ulaznih čvorova

Broj ulaznih čvorova odgovara broju promenljivih u ulaznom vektoru koji se koristi za predviđanje budućih vrednosti. Za kauzalno predviđanje, broj ulaza je obično transparentan i relativno lak za biranje. Kod predviđanja vremenskih serija, broj ulaznih čvorova odgovara broju

zakasnelih observacija koje se koriste za otkrivanje zadatog uzorka u vremenskoj seriji i predviđanje budućih vrednosti. Međutim, trenutno ne postoji sistematski pristup određivanju ovog broja. Izbor ovog parametra treba da bude uključen u proces izrade modela. Idealno, poželjan je mali broj ulaznih čvorova koji opisuju jedinstvene karakteristike iz podataka. Previše ili premalo ulaznih čvorova mogu uticati na sposobnost učenja i predviđanja cele neuronske mreže.

Većina autora je radila eksperimente kako bi pomogla izboru broja ulaznih čvorova dok su neki drugi primenjivali i usvajali neke intuitivne i empirijske ideje. Na primer, [66] i [67] koriste 12 ulaza za mesečne podatke i četiri za kvartalne podatke heuristički. Pregledom literature, ne mogu se ustanoviti konzistentni rezultati za određivanje pitanja ovog važnog parametra. Neki autori su upravo navodili da je veći broj ulaznih čvorova dao bolje rezultate dok su neki drugi utvrdili upravo suprotno. Lachtermachher i Fuller u [102] su ustanovili loš uticaj većeg broja ulaznih čvorova na predviđanje jedan korak unapred a dobar uticaj na predviđanje više koraka unapred. Neki istraživači jednostavno usvajaju broj ulaznih čvorova korišćenjem prethodnih studija dok ostali proizvoljno biraju taj broj za svoju aplikaciju.

Sa aspekta problema predviđanja vremenskih serija, broj ulaznih čvorova je verovatno najkritičnija odluka jer sadrži važnu informaciju o kompleksnoj (linearnoj ili nelinearnoj) autokorelacionoj strukturi u podacima. Većina dostupnih testova i kriterijuma je zavisna od modela pa tako nijedan način nije dovoljno superioran da bi mogao da se primeni u svakoj situaciji. Često korišćen kriterijum za identifikaciju nelinearnog modela je Akaike informativni kriterijum (AIC). Međutim, još uvek postoje kontraverze oko korišćenja ovog kriterijuma. Poslednjih godina, genetski algoritmi su postali popularni za optimalno projektovanje neuronskih mreža. Genetski algoritmi predstavljaju proceduru optimizacije koja može prirodnom selekcijom i biološkom evolucijom da učini efikasnijim proces učenja veštačkih neuronskih mreža.

Kada govorimo o kratkoročnom predviđanju i adekvatnom odabiru ulaznog vektora može se govoriti o više tipova ulaznih promenljivih. U Tabeli 3-2 dat je prikaz tipova ulaznih promenljivih sa karakteristikama.

Za kratkoročna predviđanja kod sistema daljinskog grejanja potrebno je uzeti u obzir vremenske periode, meteorološke prognoze i moguće skupove potrošača. Kod srednjoročnih i dugoročnih predviđanja potrebno je uzeti istorijske podatke o potrošnji i vremenu, podatke o broju potrošača pojedinog skupa, potrošačke aparate na području predviđanja, demografske podatke i mnoge druge. Vremenski podaci uključuju godišnje doba, dan u nedelji te sat u danu. Značajne su razlike u potrošnji među danima u nedelji kao i za vreme praznika kada se razlikuje režim grejanja. Najznačajniji su klimatski uslovi. U obzir ulaze razni klimatski činioci od kojih su temperatura i vlažnost najvažniji.

Tabela 3-2 Pregled tipova ulaznih promenljivih kao osnovnih faktora koji utiču na predviđanje kod sistema daljinskog grejanja

Vremenski faktori	Godišnja doba Doba dana (jutro, večer, noć itd.) Dan u nedelji Praznici (Božić, Nova godina itd.)
Ekonomski i ekološki faktori	Demografske karakteristike potrošača (ruralne sredine, stanovanje, industrija i poslovanje itd.) Ekonomski trendovi (recesija ili ekspanzija) Promena cene toplotne energije i tarifni sistem Industrijski rast
Meteorološki faktori	Temperatura Sunčeva radijacija Vlažnost vazduha Brzina vetra Padavine (kiša, sneg) Oblačnost
Socijalni faktori	Ponašanje potrošača i subjektivni osećaj zadovoljstva

3.5.1.3 Broj izlaznih čvorova

Broj izlaznih čvorova je relativno lako odrediti jer su oni direktno povezani sa problem koji se rešava. Za probleme predviđanja vremenskih serija, broj izlaznih čvorova često korespondira horizontu predviđanja. Postoje dva tipa predviđanja. Jedan korak unapred koji koristi jedan izlazni čvor) i predviđanje više koraka unapred. Mogu se naći najčešće dva načina u literaturi za realizaciju predviđanja više koraka unapred. Prvi način se naziva iterativno predviđanje koje se koristi kod Box-Jenkins modela i kod koga vrednosti predviđanja se iterativno koriste kao ulazi za sledeće predviđanje. U ovom slučaju je potreban samo jedan izlazni čvor. Drugi način je direktni metod kod koga neuronska mreža ima nekoliko izlaznih čvorova za direktno predviđanje svakog koraka u budućnosti. Zhang je u [111] koristio oba ova metoda za predviđanje više koraka unapred. Pokazalo se da je direktan metod mnogo bolji od iterativnog metoda. Međutim, Weigen [63] je saopštio da direktni metod za predviđanje više koraka unapred daje značajno lošije rezultate od iterativnog metoda.

Može se zaključiti da je direktni metod bolji iz dva razloga. Prvi, neuronska mreža može biti napravljena da direktno predviđa vrednosti više koraka unapred. Ovakav pristup ima prednost u odnosu na iterativni metod kao što je Box-jenkins metod gde iterativna metoda konstruiše samo jednu funkciju koja se koristi za predviđanje jedne tačke svaki put a onda vrši iteraciju ove funkcije na sopstvenom izlazu da bi predvideo tačke u budućnosti. Kako se predviđanje pomera napred, nestaju prošle observacije. Umesto njih, koriste se predviđanja za predviđanja budućih tačaka. Tipično je da što je duži horizon predviđanja da je manja tačnost iterativne metode. To objašnjava

zašto Box-Jenkins modeli tradicionalno više odgovaraju kratkoročnom predviđanju. To se može jasno videti iz sledećih jednačina predviđanja k -tog koraka korišćenjem iterativnog metoda kao što je Box-Jenkins:

$$\hat{x}_{t+1} = f(x_t, x_{t-1}, \dots, x_{t-n}), \quad (3.1)$$

$$\hat{x}_{t+2} = f(\hat{x}_{t+1}, x_t, x_{t-1}, \dots, x_{t-n+1}), \quad (3.2)$$

$$\hat{x}_{t+3} = f(\hat{x}_{t+2}, \hat{x}_{t+1}, x_t, x_{t-1}, \dots, x_{t-n+2}), \quad (3.3)$$

.

.

.

$$\hat{x}_{t+k} = f(\hat{x}_{t+k-1}, \hat{x}_{t+k-2}, \dots, \hat{x}_{t+1}, x_t, x_{t-1}, \dots, x_{t-n+k-1}). \quad (3.4)$$

gde x_t observacija u vremenu t , x_t je vrednost predviđanja za vreme t , f je funkcija ocenjena veštačkom neuronskom mrežom. Na drugoj strani, veštačka neuronska mreža sa k izlaznih čvorova može da se koristi za predviđanje tačaka više koraka unapred direktno koristeći sve korisne prošle observacije kao ulaze. Predviđanje k koraka unapred iz veštačke neuronske mreže će biti:

$$\hat{x}_{t+1} = f_1(x_t, x_{t-1}, \dots, x_{t-n}), \quad (3.5)$$

$$\hat{x}_{t+2} = f_2(\hat{x}_{t+1}, x_t, x_{t-1}, \dots, x_{t-n+1}), \quad (3.6)$$

.

.

.

$$\hat{x}_{t+k} = f_k(x_t, x_{t-1}, \dots, x_{t-n}). \quad (3.7)$$

gde su f_1, \dots, f_k funkcije određene mrežom.

Drugi razlog zašto je direktni metod bolji je činjenica da je Box-Jenkins metodologija zasnovana uglavnom na autokorelaciji između podataka s kašnjenjem. Treba ponovo napomenuti da autokorelacija u suštini meri samo linearnu korelaciju između podataka sa kašnjenjem. U stvarnosti, korelacija može biti nelinearna pa Box-jenkins model neće biti u stanju da modelira takve nelinearne odnose. Veštačke neuronske mreže su bolje u hvatanju nelinearnih odnosa u podacima.

3.5.1.4 Interkonekcija čvorova

Arhitektura mreže se takođe karakteriše međusobnim vezama čvorova u slojevima. Veze između čvorova u mreži fundamentalno određuju ponašanje mreže. Za većinu predviđanja kao i za druge primene, mreže su potpuno povezane u slojevima svojim čvorovima sa čvorovima sledećeg

sloja izuzev izlaznog sloja. Međutim, moguće je da imamo različito povezane mreže kao u [124] ili uključene direktne veze ulaznih čvorova sa izlaznim čvorovima [92]. Dodavanje direktnih veza između ulaznog sloja i izlaznog sloja može biti prednost za tačnost u predviđanju jer se mogu koristiti za modeliranje linearne strukture podataka i mogu povećati moć prepoznavanja mreže. Tang i Fishwick [67] su istraživali uticaj direktne veze za predviđanje jedan korak unapred ali nisu došli do nekih generalnih zaključaka.

3.5.2 Aktivaciona funkcija

Aktivaciona funkcija se naziva i prenosna funkcija. Određuje odnos između ulaza i izlaza čvora i mreže. Uopšte, aktivaciona funkcija uvodi stepen nelinearnosti koja je jako značajna za većinu primena veštačkih neuronskih mreža. Chen i Chen [125] su identifikovali opšte uslove za kontinualnu funkciju za njeno kvalifikovanje kao aktivacione funkcije. Svaka diferencijabilna funkcija se teorijski može klasifikovati kao aktivaciona funkcija. U praksi se mali broj aktivacionih funkcija koristi i one su predstavljene u poglavlju 2. Najčešće se koriste:

1. Sigmoidna (logistička funkcija)

$$f(x) = (1 + \exp(-x))^{-1} \quad (3.8)$$

2. Hiperbolička tangentna funkcija

$$f(x) = (\exp(x) - \exp(-x))/(\exp(x) + \exp(-x)) \quad (3.9)$$

3. Sinusna ili kosinusna funkcija

$$f(x) = \sin(x) \quad \text{ili} \quad f(x) = \cos(x) \quad (3.10)$$

4. Linearna funkcija

$$f(x) = x \quad (3.11)$$

Najčešći i najpopularniji izbor kod istraživača i praktičara je logistička prenosna funkcija.

Postoje određena heuristička pravila za izbor aktivacione funkcije. Na primer, Klimasauskas [127] predlaže logističku aktivacionu funkciju za probleme klasifikacije što uključuje učenje prosečnog ponašanja kao i hiperboličku tangentnu funkciju ako problem uključuje učenje o devijacijama od proseka kakav je problem predviđanja. Međutim, nije sasvim jasno da li različite aktivacione funkcije imaju veliki uticaj na performanse mreže.

Generalno, mreža može imati različite aktivacione funkcije za različite čvorove u istom ili različitim slojevima. Međutim, uglavnom sve mreže koriste istu aktivacionu funkciju kod čvorova u istom sloju. Dok većina istraživača koristi logističku aktivacionu funkciju za skrivene čvorove ne postoji konsenzus koja aktivaciona funkcija bi trebala da se koristi za izlazne čvorove. Sledeći konvenciju, većina istraživača koristi logističku aktivacionu funkciju za skrivene i izlazne čvorove. Treba napomenuti da kada se koriste nelinearne squashing funkcije u izlaznom sloju, vrednosti ciljanog izlaza obično treba da se normalizuju kako bi odgovarali opsegu stvarnih izlaza iz mreže dok izlazni čvor sa logističkom ili hiperboličkom tangensnom funkcijom ima tipični opseg [0,1] ili [-1,1] respektivno.

Logistička aktivaciona funkcija se čini veoma pogodnom za izlazne čvorove sa više klasifikacionih problema gde su vrednosti cilja često binarne. Međutim, za problem predviđanja koji uključuje kontinualne vrednosti cilja, racionalno je koristiti linearnu aktivacionu funkciju za izlazne čvorove. Rummelhart [127] heuristički ilustruje adekvatnost korišćenja linearnih izlaznih čvorova za probleme predviđanja sa modelom verovatnoće feedforward neuronske mreže, dajući neke teorijske naznake podršci linearne aktivacione funkcije za izlazne čvorove. Važno je napomenuti da feedforward neuronske mreže sa linearnim izlaznim čvorovima imaju ograničenje da ne mogu modelirati vremenske serije koje sadrže trend [64]. Za ovaj tip neuronske mreže može biti potrebno predferenciranje kako bi se eliminisao efekat trenda. Trenutno istraživači ne istražuju relativne performanse korišćenja linearne i nelinearne aktivacione funkcije za izlazne čvorove i o tome postoje empirijski rezultati.

3.5.3 Algoritam za obučavanje

Obučavanje neuronske mreže je problem neograničene nelinearne optimizacije u kojem težine mreže se iterativno modifikuju kako bi minimizirali ukupnu srednju ili ukupnu kvadratnu grešku između željenih i stvarnih izlaznih vrednostiza sve izlazne čvorove u odnosu na sve ulazne uzorke. Činjenica da postoji veliki broj različitih metoda optimizacije obezbeđuje veliki izbor za obučavanje neuronske mreže. Trenutno ne postoji algoritam koji garantuje globalno optimalno rešenje za opšti problem nelinearne optimizacije u nekom realnom vremenu. Svi algoritmi optimizacije pate u praksi od problema lokalnog optimalnog rešenja i ono što se može uraditi je korišćenje dostupnih metoda optimizacija koji mogu dati najbolje lokalno rešenje ukoliko globalno optimalno rešenje nije dostupno.

Najpopularniji metod za obučavanje je algoritam sa propagacijom unazad („backpropagation“) koji je suštinski metoda najbržeg spusta. Kod ovog algoritma veličina koraka koja se naziva „learning rate“ ili faktor učenja ili koeficijent učenja u literaturi koja obrađuje

veštačke neuronske mreže, mora biti specificirana. Faktor učenja je krucijalan za algoritam učenja propagacijom unazad jer određuje intenzitet promena težinskih koeficijenata. Dobro je poznato da metod najbržeg spusta pati od spore konvergencije, neefikasnosti i nedostatka robustnosti. Štaviše, ova metoda može biti veoma osetljiva na izbor faktora učenja. Niži faktor učenja ima tendenciju da uspori proces učenja dok viši faktor učenja može izazvati oscilacije u težinskom prostoru. Jedan od načina da se poboljša metod najbržeg spusta je uključivanje dodatnih parametara momenta kako bi se dozvolilo viši faktor učenja koji će dovesti do brže konvergencije dok će sa druge strane minimizirati tendenciju oscilacija (Rumelhart 1986). Ideja uvođenja momenta ima za cilj promenu sledećih težina u više ili manje istom pravcu kao prethodni i tako smanji uticaj oscilacija višeg faktora učenja. Yu i saradnici [128] opisuju metodu dinamičke adaptivne optimizacije faktora učenja korišćenjem informacije o izvodu. Oni takođe pokazuju da se moment može uspešno odrediti uspostavljanjem odnosa između propagacije unazad i konjugovane gradijentne metode.

Standardna tehnika propagacije unazad sa momentom je usvojena od strane većine istraživača. Kako postoji nekoliko sistematskih načina izbora faktora učenja i momenta istovremeno, najbolje vrednosti parametara učenja se obično biraju eksperimentalno. Kako faktor učenja i moment mogu imati bilo koju vrednost između 0 i 1, realno je nemoguće uraditi iscrpnu pretragu za nalaženje najboljih kombinacija ovih parametara obučavanja. Samo izabrane vrednosti se razmatraju od strane istraživača. Na primer, Sharda i Patil [66] su probali devet kombinacija tri faktora učenja (0.1, 0.5, 0.9) i tri momenta (0.1, 0.5, 0.9).

Tang i Fishwick [67] zaključuju da parametri obučavanja igraju kritičnu ulogu u performansama veštačke neuronske mreže. Korišćenjem različitih parametara učenja, retestiraju se performanse veštačke neuronske mreže za nekoliko vremenskih serija za koje je prethodno ustanovljeno da su imale lošije rezultate sa veštačkim neuronskim mrežama. Oni su pronašli da za svaku od tih vremenskih serija postoji veštačka neuronska mreža sa adekvatnim parametrima učenja koja se realizuje značajno bolje. Tang i saradnici [65] su takođe izučavali uticaj parametara obučavanja na učenje veštačke neuronske mreže. Oni su ustanovili da je visok faktor učenja dobar za manje kompleksne podatke a da niži faktor učenja sa visokim momentom može da se koristi za kompleksije serije podataka. Međutim, ne postoje konzistentni zaključci o najboljim parametrima učenja verovatno iz razloga neefikasnosti i nerobustnosti algoritma gradijentnog spusta.

U svetlu prikazanih slabosti algoritma sa propagacijom unazad, veliki broj njegovih modifikacija je predložen. Među predloženim modifikacijama najefikasniji metod nelinearne optimizacije su metodi drugog reda (Levenberg-Marquardt i BFGS) i oni se koriste u najvećem broju optimizacionih paketa. Oni imaju bržu konvergenciju, robustnost i sposobnost nalaženja dobrog lokalnog minimuma i to ih čini atraktivnim za obučavanje veštačkih neuronskih mreža.

Drugo veoma važno pitanje obučavanja veštačkih neuronskih mreža je funkcija cilja. Obično se koriste SSE i MSE jer su definisane u odnosu na grešku. Druge funkcije cilja kao što je maksimizacija obrta, profita ili preduzeća mogu biti pogodniji za potrebe finansijskog predviđanja. Refenes [129] je pokazao da izbor funkcije cilja može imati značajan uticaj na performanse predviđanja mreže ako su algoritam učenja (propagacija unazad) i drugi parametri mreže fiksni. Tako je jedan od mogućih načina za rad direktno sa funkcijom cilja je primena algoritma pretrage sa algoritmom sa propagacijom unazad na genetske algoritme ili druge optimizacione metode koji dozvoljavaju traženje preko proizvoljnih funkcija.

3.5.4 Normalizacija podataka

Nelinearne aktivacione funkcije kao što je logička aktivaciona funkcija imaju gomilajuću ulogu u restrikciji ili gomilanje mogućeg izlaza iz čvora unutar (0,1) ili (-1,1). Normalizacija podataka se često realizuje pre nego što počne proces obučavanja. Kada se za izlazne čvorove koristi nelinearna prenosna funkcija, željene izlazne vrednosti se moraju transformisati u opseg stvarnog izlaza mreže. Čak i kada se koristi linearna izlazna prenosna funkcija može biti od koristi uraditi standardizaciju izlaza i ulaza da bi se izbegli problemi u proračunu.

Azoff [130] je sistematizovao četiri metode za normalizaciju ulaza:

1. „Along channel“ normalizacija: Kanal se definiše kao skup elemenata na istoj poziciji preko svih ulaznih vektora u skupu za obučavanje i testiranje. To znači, da svaki kanal može da se posmatra kao „nezavisna“ ulazna promenljiva. Ova normalizacija se realizuje kolona po kolona ako su ulazni vektori stavljeni u matricu. Drugim rečima, normalizuje se svaka ulazna promenljiva pojedinačno.
2. „Across channel“ normalizacija: Ovaj tip normalizacije realizuje svaki ulazni vektor nezavisno.
3. „Mixed channel“ normalizacija: Ova metoda koristi kombinaciju prethodne dve metode normalizacije.
4. Eksterna normalizacija: Svi podaci za obučavanje su normalizovani u određeni opseg.

Izbor jedne od gore navedenih metoda zavisi od kompozicije ulaznog vektora. Za problem predviđanja vremenskih serija, najčešće je eksterna normalizacija najpogodnija procedura normalizacije. Observacije vremenskog kašnjenja iz istog izvora se koriste kao ulazne promenljive i mogu zadržati strukturu između kanala kao stvarne serije. Za probleme kauzalnog predviđanja se koristi „along channel“ normalizacija jer su ulazne promenljive uglavnom nezavisne promenljive koje se koriste za predviđanje zavisnih promenljivih.

za svaki tip normalizacije koriste se najčešće sledeće formule:

- linearna transformacija u [0,1]:

$$x_n = (x_0 - x_{min}) / (x_{max} - x_{nmin}) \quad (3.12)$$

- linearna transformacija u [a,b]:

$$x_n = \frac{(b-a)(x_0 - x_{min})}{x_{max} - x_{nmin}} + a \quad (3.13)$$

- statistička normalizacija

$$x_n = (x_0 - \bar{x}) / s \quad (3.14)$$

- prosta normalizacija

$$x_n = x_0 / x_{max} \quad (3.15)$$

gde x_n i x_0 predstavljaju normalizovane i stvarne podatke; x_{min} , x_{max} , \bar{x} i s su minimum, maksimum srednja vrednost i standardna devijacija duž kolona ili vrsta respektivno.

Ostaje nejasno da li je uopšte potrebno raditi normalizaciju ulaza. Postoji nekoliko studija koje razmatraju uticaj normalizacije podataka na učenje mreže. Shanker i saradnici (1996) je proučavao uticaj metoda linearne i statističke normalizacije na probleme klasifikacije. Oni su zaključili da je normalizacija korisna u kontekstu faktora klasifikacije i srednje kvadratne greške ali da ta prednost nestaje kako se povećava veličina mreže i uzorka. Takođe, normalizacija podataka obično usporava proces obučavanja.

Normalizacija izlaznih vrednosti je obično nezavisna od normalizacije ulaza. Za probleme predviđanja vremenskih serija normalizacija želejnih vrednosti (targeta) se realizuje zajedno sa ulazima. Izbor opsega za normalizaciju ulaza i targeta zavisi od aktivacione funkcije izlaznih čvorova, sa tipično [0,1] za logističku funkciju i [-1,1] za hiperboličku tangensnu funkciju. Pojedini istraživači vrše skaliranje samo na opseg [0.1, 0.9]: [118] ili [0.2, 0.8] [67]: bazirajući to na činjenici da nelinearne aktivacione funkcije obično imaju asimptotska ograničenja.

Treba napomenuti da će kao rezultat normalizovanih vrednosti targeta, posmatrani izlaz mreže korespondirati u normalizovanom opsegu. Kako bi se interpretirali rezultati dobijeni iz mreže mora se uraditi reskaliranje na originalni opseg. Sa stanovišta korisnika, tačnost dobijena kod veštačke neuronske mreže treba da bude zasnovana na reskaliranom skupu podataka. Takođe, mere performansi treba da budu proračunate na osnovu reskaliranih izlaza.

3.5.5 Uzorak za obuku i testiranje

Kao što je ranije pomenuto, potrebno je imati uzorke za obučavanje i testiranje veštačke neuronske mreže. Uzorak za obučavanje se koristi razvoj modela veštačke neuronske mreže a uzorak za testiranje se usvaja za evaluaciju sposobnosti predviđanja modela. Ponekad se pravi i treći skup podataka kao validacioni uzorak da bi se izbegao overfitting problem ili odredile tačke zaustavljanja procesa obučavanja. Uobičajeno je da se koristi isti skup podataka za testiranje za potrebe validacije i testiranja posebno kada su u pitanju mali skupovi podataka. Izbor uzorka za obučavanje i testiranje može uticati na performanse veštačke neuronske mreže.

Prvo pitanje koje se postavlja je kako podeliti celokupan skup podataka na skupove za obučavanje i testiranje. Iako ne postoji opšte rešenje ovog problema, nekoliko faktora treba uzeti u obzir i to pre svega karakteristike samog problema, tip podataka i veličinu dostupnih podataka. To je posebno važno za predviđanje vremenskih serija. Neodgovarajuće odvajanje skupa za obučavanje i skupa za testiranje će uticati na izbor optimalne strukture veštačke neuronske mreže i evaluacije performansi predviđanja veštačke neuronske mreže.

U literaturi se mogu naći male smernice za izbor uzorka za obučavanje i testiranje. Većina autora bira ove skupove na osnovu pravila 90% - 10%, 80% - 20% ili 70%-30%. Neki vrše izbor na osnovu njihovog pojedinačnog problema. Granger [53] je predložio da za model nelinearnog predviđanja najmanje 20% bilo kog uzorka bude ostavljeno po strani za evaluaciju predviđanja.

Drugi veoma bitan faktor je veličina uzorka. Ne postoji definisano pravilo sa zahtevima koji treba da se ispune za dati problem. Količina podataka za obučavanje mreže zavisi od strukture mreže, metode obučavanja i kompleksnosti samog problema ili količine šumova u podacima. Generalno, kao što je to slučaj kod statističkih metoda i pristupa, veličina uzorka je usko povezana sa željenom tačnošću problema. Što je veća veličina uzorka to je tačnost veća i obrnuto.

U realnosti je veličina uzorka ograničena dostupnošću podataka. Tačnost konkretnog problema predviđanja može da bude pod uticajem veličine uzorka koji se koristi u skupu za obučavanje ili skupu za testiranje.

Svaki model ima ograničenja u tačnosti koju može dostići za realne probleme. Na primer, ako razmatramo dva faktora: šumove u podacima i zadatom modelu, tada će granica tačnosti linearnog modela kao što je Box-Jenkins biti određena šumovima u podacima i stepenom do koga je zadata funkcionalna forma nelinearna. Sa više observacija, tačnost modela se ne može poboljšati ukoliko nema nelinearne strukture u podacima. Kod veštačkih neuronskih mreža, šum sam po sebi određuje granicu tačnosti usled sposobnosti aproksimacije opšte funkcije. Sa dovoljno velikim uzorkom veštačka neuronska mreža može modelirati bilo koju kompleksnu strukturu podataka. To

znači da veštačke neuronske mreže mogu bolje iskoristiti veći uzorak od linearnih statističkih modela. Međutim, to ne znači da veštačke neuronske mreže zahtevaju veće uzorke od linearnih statističkih modela kako bi radile dobro. Kang [122] je ustanovio da veštačke neuronske mreže rade veoma dobro predviđanje iako je veličina uzorka manja od 50 dok Box-Jenkins modeli uglavnom zahtevaju minimalno 50 tačaka kako bi predviđanje bilo uspešno.

3.5.6 Mere performansi

Iako mogu postojati razne mere performansi kvaliteta predviđanja veštačkim neuronskim mrežama kao što su vreme modeliranja, vreme obučavanja, najvažnija mera performansi je predviđanje tačnosti koja se može postići pomoću podataka za obučavanje. Međutim, pogodna mera tačnosti za dati problem nije univerzalno prihvaćena od strane naučnika i praktičara. Mera tačnosti se često definiše preko greške predviđanja koja predstavlja razliku između stvarne (željene) i predviđene vrednosti. Postoji više takvih mera tačnosti za predviđanje koje se susreću u literaturi i svaka ima svoje prednosti i ograničenja. Najčešće se koriste:

- Srednja apsolutna devijacija (MAD)

$$MAD = \frac{\sum |e_t|}{N} \quad (3.16)$$

- Zbir kvadrata greške (SSE)

$$SSE = \sum (e_t)^2 \quad (3.17)$$

- Srednja kvadratna greška (MSE)

$$MSE = \frac{\sum (e_t)^2}{N} \quad (3.18)$$

- Koren srednje kvadratne greške (RMSE)

$$RMSE = \sqrt{MSE} \quad (3.19)$$

- Srednja apsolutna procentualna greška (MAPE)

$$MAPE = \frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| (100) \quad (3.20)$$

gde je e_t individualna greška predviđanja; y_t je stvarna vrednost; i N je broj izraza greške.

Kao dodatak gore navedenom, treba reći da se u literaturi mogu naći i druge mere tačnosti u literaturi. Na primer, srednja greška (ME), geometrijska srednja relativna greška (GMRAE), Akaike informacijski kriterijum (AIC) i Bayesian informacijski kriterijum (BIC), itd.

Zbog ograničenja koje ima svaka mera tačnosti pojedinačno, moguće je koristiti višestruku meru performansi. Međutim, ukoliko je jedan metod najbolji duž jedne dimenzije to ne znači da će biti najbolji u odnosu na neku drugu dimenziju.

Važno je napomenuti da prve 4 mere performansi koje su gore navedene su apsolutne mere i ograničenih vrednosti kada se koriste za poređenje različitih vremenskih serija. MSE je najčešće korišćena mera tačnosti u literaturi. Međutim, meritornost ove mere je predmet debate sa stanovišta evaluacije relativne tačnosti metode predviđanja kod različitih skupova podataka. Štaviše, MSE može biti neadekvatna mera za model veštačke neuronske mreže sa uzorkom za obučavanje jer ignoriše važnu informaciju o broju parametara modela koji se ocenjuje. Sa statističke tačke gledišta, kako broj ocenjenih parametara u modelu raste, stepeni slobode celog modela opadaju pa raste mogućnost overfitinga u uzorku za obučavanje. Poboljšana definicija MSE za deo koji se obučava je da je to ukupna suma kvadratnih grešaka podeljena sa stepenima slobode, koji predstavljaju broj observacija minus broj težina i pragova čvorova u modelu veštačke neuronske mreže.

3. 6 Kratkoročno predviđanje kod sistema daljinskog grejanja

3.6.1 Opšta razmatranja

Kako je već rečeno, veštačke neuronske mreže se koriste u ovoj disertaciji za kratkoročno predviđanje i analizu sistema daljinskog grejanja. Osnovna karakteristika koja se razmatra i čije se kratkoročno predviđanje realizuje je toplotno opterećenje i snaga na toplotnom izvoru. Zato je posebna pažnja posvećena upravo ovoj karakteristici i sve razvijene i analizirane veštačke neuronske mreže su realizovane sa aspekta kratkoročnog predviđanja toplotnog opterećenja odnosno toplone snage na toplotnom izvoru.

Pored ove karakteristike, razvijene i analizirane metode predviđanja zasnovane na veštačkim neuronskim mrežama se koriste i za predviđanje adekvatne temperature napojne vode kao važne karakteristike sistema daljinskog grejanja čijom minimizacijom se doprinosi snižavanju troškova proizvodnje toplotne energije u celini. Takođe, opisuje se uticaj temperature povratne vode na efikasnost i efektivnost celokupnog sistema daljinskog grejanja pa shodno tome se vrši ocena i analiza i ove karakteristike primenom veštačkih neuronskih mreža.

Treba istaći da se analizira upravo mogućnost primene razvijenih metoda veštačkih neuronskih mreža za kratkoročno predviđanje toplotnog opterećenja na kratkoročno predviđanje temperature napojne vode i temperature povratne vode.

Dakle, osnova kratkoročnog predviđanja je toplotno opterećenje odnosno snaga na toplotnom izvoru a tako razvijene metode se primenjuju kasnije i na kratkoročno predviđanje temperatura napojne vode i temperature povratne vode.

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

- Podaci koji se koriste za projektovanje STLF modela uglavnom potiču iz javno komunalnih 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 omogućće 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. Ono što je karakteristično je da većina takvih istraživanja i organizovanih takmičenja konkretno vezana za elektrenergetska preduzeća i kratkoročno predviđanje električnog opterećenja i potrošnje električne energije .

Kako je već rečeno u uvodnom poglavlju 1, većina tehnika kratkoročnog predviđanja opterećenja odnosi se na električno opterećenje. Upravo zato je i u ovoj disertaciji prilikom pregleda ranijih istraživanja i aktuelnih istraživanja iz ove oblasti pralelelno sa pregledom istraživanja koja se odnose na kratkoročno predviđanje toplotnog opterećenja dat poseban osvrt na kratkoročno predviđanje električnog opterećenja gde se koriste veštačke neuronske mreže. Posebno iz razloga što su danas sve prisutnija moderna kombinovana postrojenja koja istovremeno proizvode i isporučuju i toplotnu energiju i struju. Sa druge strane, potrošač koji je u centru pažnje ima za cilj da njegova potrošnja energije (bilo električne bilo toplotne) bude što manja a potrošačke potrebe zadovoljene pa je u tom smislu razumljiva težnja ka efikasnim i efektivnim sistemima.

Upravo zbog toga je i rastuća potreba predviđanja kako bi se obezbedili energetski i ekonomski efikasni i efektivni sistemi.

Jedan od najvećih problema kod sistema daljinskog grejanja je kašnjenje između odluke na toplotnom izvoru do stvarnog uticaja koji se oseti na strani potrošača. Da bi bili u stanju da predvidimo koliko energije je sistemu potrebno u n ciklusa moramo da sortiramo predviđanje. Stari klasični način predviđanja se zasnivao na statistici i iskustvu operatera. Predviđanje se pravi sa centralizovane tačke gledišta i ne uzima u obzir lokalno stanje potrošača tj. lokalne temperaturne varijacije. Ukoliko predviđanje baziramo na lokalnim informacijama, umesto centralizovano, možemo koristiti puno više podataka pa će predviđanje biti potpunije.

Izazov sa kojim se susreću kompanije za distribuciju toplotne energije je kako odgovarajuće reagovati na promene u potrebama za toplotnom energijom potrošača odnosno promenama u toplotnim zahtevima. Značajan period vremena je potreban da se toplotna energija distribuirana od toplotnog izvora do krajnjih potrošača, u nekim slučajevima i tri časa. Za to vreme, zahtev za toplotnom energijom se opet može promeniti kao što i inače dostiže svoje pikove u jutarnjim i večernjim satima. Zato je radi osiguranja adekvatne isporuke toplotne energije potrebno imati dobro predviđanje potreba potrošača izraženo kroz toplotne zahteve. (heat demand). Međutim, ovaj zahtev se menja u zavisnosti od potrošača jer ni potrebe svih potrošača nisu iste. Primera radi, toplotni zahtev banke može zavisiti samo od spoljne temperature dok potrebe hotela su ograničene značajnim povećanjima u vršnim satima svakog dana.

3.6.2 Pregled literature i aktuelni pravci istraživanja

Predviđanje toplotnog opterećenja kod sistema daljinskog grejanja je dobilo na pažnji poslednjih 15-ak godina. Postoji nekoliko predloženih pristupa koji uglavnom uključuju statističke metode i metode mašinskog učenja (ML).

Većina statističkih modela sažima temperatutno zavisnu komponentu i socijalnu komponentu, koja je direktno vezana za socijalno ponašanje potrošača. Dotzauer (2002) [131] je predložio jednostavan model u kome se temperaturno zavisna komponenta predstavlja kao linearna funkcija, dok je socijalna komponenta jednaka konstantnoj vrednosti za svaki dan u nedelji. Nielsen i Madsen (2006) [132] su upotrebili metod sive kutije koji kombinuje fizičko znanje sa statističkim modeliranjem. Fizičko znanje obezbeđuje opštu strukturu modela, razmatrajući i uzimajući u obzir prelaz toplote kroz zidove, prelaz toplote kroz prozore, ventilaciju kao i socijalno ponašanje potrošača. Proces statističkog modeliranja se tada koristi za proračunavanje aktuelnih koeficijenata modela. Chramcov (2010) [133] je upotrebio polinomnu funkciju za temperaturno zavisnu komponentu i metodologiju Box-jenkins za socijalnu komponentu. Metodologija Box-Jenkins primenjuje ARMA model. Grosswinhager, Voigt i Kozek (2011) [134] su objavili studiju u kojoj nestacionarno ponašanje toplotnog opterećenja obuhvataju SARIMA modelom koji je ubačen u prostor stanja. Vrednosti predviđanja se izračunavaju korišćenjem klasične Kalmanove rekurzije. Uticaj spoljne temperature se opisuje linearnom funkcijom.

Algoritmi mašinskog učenja su sposobni da se bave kako linearnim tako i nelinearnim delom toplotnog opterećenja. Najzastupljeniji pristup ML algoritama za predviđanje toplotnog opterećenja su upravo neuronske mreže.

Grzenda i Macukow (2006) [135] su u svom radu diskutovali o načinu kako samoorganizujuće mape (SOM) i višeslojni perceptron i mogu biti upotrebljeni za razvoj dvostepenog algoritma za autonomnu konstrukciju modela predviđanja. Problem je iskorišćen kao studija slučaja za predviđanje toplotnog zahteva u jednoj kompaniji za daljinsko grejanje. Dodatno, zbog nestandardne evaluacije modela predviđanja, primenjena je realizacija višeslojnih perceptrona pomoću evolutivnih algoritama.

Zbog toga je bilo potrebno izraditi posebne modele predviđanja za različite grupe potrošača koji su definisani uz pomoć SOM mreža. U njihovom radu u cilju konstruisanja modela za predviđanje toplotne energije, primenjeni su višeslojni perceptroni. Za svaku grupu potrošača koja nije prazna, konstruisana je jedna MLP mreža. Za obuku neuronske mreže, primenjeni su evolutivni algoritmi.

U ovom slučaju, iskorišćeni su za predviđanje toplotnih zahteva izabranih potrošača određene grupe. Detaljna serija podataka dostupna za izabranu grupu potrošača je upotrebljena za definisanje i skupa za učenje i skupa za testiranje. Skupovi sadrže potrošnju toplotne energije na svakih sat vremena za izabrani mesec kombinovano sa prosečnom spoljnom temperaturom za taj sat. Osnovni cilj je obučavanje višeslojnog perceptrona za predviđanje toplotnog zahteva na svaki sat u zavisnosti od spoljne temperature, vremena u toku dana i dana u nedelji. Dodatno su izabrani sati označeni kao pik sati sa zahtevima za toplu vodu.

Kato, Sakawa i saradnici (2010) [136] su u svom radu u cilju poboljšanja tačnosti predviđanja toplotnog opterećenja dodali novi ulazni podatak za predviđanje toplotnog opterećenja i usvojili rekurentnu neuronsku mrežu kao mrežu za predviđanje koja može da obuhvati dinamičke varijacije toplotnog opterećenja razmatranjem karakteristika podataka za toplotno opterećenje.

U ovoj novoj metodi za predviđanje usvojena je rekurentna neuronska mreža sa 33 ulaza i 24 izlaza. Od tako definisane rekurentne neuronske mreže se očekuje da uhvati trend toplotnog opterećenja jer može da snimi i sačuva podatke o toplotnom opterećenju za prethodni dan.

U [137] Sakawa i saradnici, kao osnovu za analizu koriste već korišćenu feedforward troslojnu neuronsku mrežu i definišu njen nedostatak u smislu da postaje manje tačna u periodima kada je toplotno opterećenje nestacionarno. U ovom istraživanju, oni pokušavaju da poboljšaju predviđanje uvođenjem rekurentne neuronske mreže korišćenjem PSO (Particle Swarm Optimization) za adaptaciju dinamičkih varijacija toplotnog opterećenja zajedno sa unošenjem novog ulaznog podatka u mrežu.

Park, Kim i saradnici (2010) [138] u svom radu o kratkoročnom predviđanju potrošnje toplotne energije vrše validaciju tri metoda predviđanja: metod parcijalnih najmanjih kvadrata (PLS), metod veštačkih neuronskih mreža (ANN), i metod regresije potpornih vektora (SVR). Na osnovu rezultata kratkoročnog predviđanja, realizovano je kratkoročno predviđanje za jednu nedelju unapred za Suseo sistem daljinskog grejanja. Podaci o spoljnoj temperaturi i potrošnji toplotne energije su uzeti za zimsku sezonu 2007/2008. Potrošnja toplotne energije koja je dobijena predviđanjem je upoređena sa stvarnom iz tog perioda radi validacije modela predviđanja.

Wojduga (2014) [139] je usvojio 4 različite neuronske mreže za reliazaciju i testiranje. Pri tome je za potrebe obuke uzet period od 5 grejnih sezona. Za potrebe predviđanja je uzet model neuronske mreže sa prostiranjem greške unazad sa jednim skrivenim slojem. Broj ulaza, broj neurona u skrivenom sloju i broj izlaza mreže se za svaku od varijanti menja i predstavljaju dobijeni rezultati. Ulazni vektor pokriva 14 tipova podataka a u skrivenom sloju ima 18 neurona.

Yang et al. (2015) [140] su u svom radu primenili Numerical Weather Prediction (NWP) za potrebe predviđanja toplotnog opterećenja. NWP je primenjen za dobijanje korelacijskih parametara

vremena toplotnog opterećenja a onda se adekvatno strukturirana veštačka neuronska mreža projektuje u cilju realizacije predviđanja. Zadovoljavajući eksperimentalni rezultati su dobijeni korišćenjem stvarnih podataka toplotnog opterećenja iz severne Kine. Eksperimentalni rezultati su pokazali predloženi NWP metod može precizno da predviđa toplotno opterećenje. Poređenjem tracionalnog metoda koji se zasniva na prognozi vremena predložena metoda može da efektivno poboljša tačnost predviđanja

Kako bi se predvidela potrošnja od strane potrošača moraju se znati relacije između različitih parametara. Prvi korak je nalaženje i određivanje tih parametara. Drugi korak je određivanje koji algoritam treba da se upotrebi za fazu učenja i treći i poslednji korak je razvoj algoritma koji koristi algoritam za mašinsko učenje.

U [141] su neuronske mreže iskorišćene za bolje predviđanje meteorološkog predviđanja. Taj pristup je jako centralizovan, ne uzima u obzir socijalnu komponentu i njen zaključak je da neuronske mreže ne daju bolje predviđanje od statističkih metoda.

Drugi pristup je dat u [142] gde se pokušava predviđanje potrošnje celog sistema tokom određenog perioda vremena. I ovaj pristup je strogo centralizovan i ne uzima u obzir socijalno ponašanje lokalnog vremena. Rezultati su pozitivni i model se koristi trenutno u nekim toplanama u Velikoj Britaniji.

Upotreba veštačkih neuronskih mreža za potrebe predviđanja je dodatno dobila na značaju i zamahu nakon dva otvorena takmičenja realizovana od strane Američkog društva termičkih inženjera (American Society of Heating, Refrigerating and Air Conditioning Engineers (ASHRAE)). Cilj ovih takmičenja je bio da obezbede analizu zgrada i energetske zajednice u celini, sa jasno definisanim testiranjem različitih metoda za predviđanje energije zgrada sat unapred i rezultati su pokazali da su ANN dale najtačniji model.

Danas su jako zastupljene i tzv. hibridne metode kratkoročnog predviđanja koje kombinuju veštačke neuronske mreže sa još nekom tehnikom veštačke inteligencije ili statističkom tehnikom.

Tako je, na primer, za klasifikaciju velikog ulaznog skupa podataka i predviđanja potrebnog opterećenja, razvijen model veštačke neuronske mreže sa fazi logikom. U [143] Kuihe Yang i saradnici su predložili metod za pojednostavljenje strukture sistema i poboljšanje preciznosti predviđanja. U [144] Lingling Zao i saradnici prikazali funkciju članstva izrađenu na karakteristikama kratkoročnog opterećenja i za poboljšanje rezultata predviđanja. Takođe, u radu [145] je takođe iskorišćena fazi logika u kombinaciji sa ANN za metod predviđanja tipa „slični dan“. Gore navedeni radovi su pokazali da je fazi logika odlična tehnika za rešavanje različitih neodređenosti i poboljšanje tačnosti predviđanja.

Genetski algoritmi su heuristička tehnika koja se široko koristi za nalaženje optimalnog rešenja. Kada se GA koristi hibridizovano sa ANN, upravo se koristi za globalnu optimizaciju broja ulaznih neurona i broja neurona u skrivenom sloju neuronske mreže. Takođe, GA optimizuje težine između neurona veštačke neuronske mreže. Chaturvedi i saradnici [146] su pokazali kako obučiti neuronsku mrežu korišćenjem poboljšanog GA. Genetski algoritam u kombinaciji sa PSO, FL i dr. smanjuje grešku predviđanja opterećenja [147-149].

PSO algoritam optimizacije se uspešno može primeniti neke optimizacione probleme u realnom vremenu. Tian Shu i saradnici [150] su razvili novi metod obučavanja RBF neuronskih mreža zasnovan na PSO. Ning i saradnici su predložili RBF model veštačke neuronske mreže zasnovan na PSO za predviđanje opterećenja. [151] Yang Shang Dong i saradnici su predložili novi PSO algoritam sa adaptivnim težinskim faktorima inercije [152].

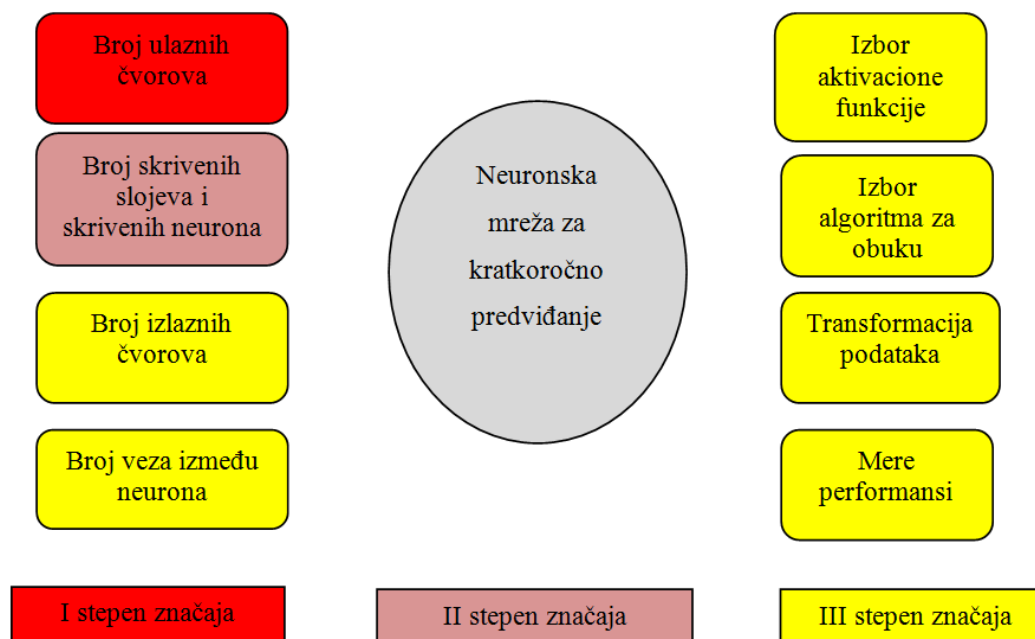
Tokom proteklih nekoliko decenija, veliki broj različitih STLF tehnika je predstavljen u literaturi, dok su mnoge od njih primenjene u praksi. Pregled literature predstavljen u ovom poglavlju pokriva veliki broj radova koji zastupaju upotrebu različitih tehnika za potrebe rešavanja STLF problematike, 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.

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. 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, 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.

Na osnovu datih razmatranja o kratkoročnom predviđanju, pregleda postojećih istraživanja i problema koji je postavljen kao zadatak za rešavanje (kratkoročno predviđanje kod sistema za daljinsko grejanje) može se napraviti dijagram uticaja i značajnosti za izbor odgovarajuće neuronske mreže koja će odgovoriti postavljenim zahtevima. Dijagram je prikazan na Slici 3-2.



Slika 3-2 Dijagram uticaja i značajnosti izbora parametara neuronske mreže za kratkoročno predviđanje

Kao što se može videti sa dijagrama I stepen značaja ima upravo izbor ulaznih čvorova te je zato osnovna postavka kvalitetnog kratkoročnog predviđanja u ovoj disertaciji usmerena na izboru adekvatnog ulaznog vektora sa odgovarajućim brojem ulaznih promenljivih.

4. SISTEMI DALJINSKOG GREJANJA

Energetske potrebe u gradovima se povećavaju u kontinuitetu shodno rastu gradske populacije. Evropska unija je postavila određene opšte ciljeve u pogledu energetske potrebe i zahteva za smanjenje emisije ugljen dioksida do 2020. godine. Ovi ciljevi se mogu definisati kroz tri specifična cilja:

- Postići smanjenje od 20% emisije štetnih gasova u odnosu na emisiju iz 1990. godine
- Povećati udeo obnovljivih izvora energije na 20% u ukupnoj proizvodnji energije u EU
- Poboljšati energetske efikasnost za 20%

Na zgrade odlazi 40% ukupne potrošnje energije i 36% ukupne emisije CO₂. Zbog toga smanjenje potrošnje energije u zgradama može dovesti do značajnog smanjenja emisije CO₂. Upotreba obnovljivih izvora energije u zgradama i redukovana potrošnja energije mogu obezbediti dugoročnu sigurnost u snabdevanju energijom.

Tehnološki napredak u ICT sektoru obezbeđuje potencijal za smanjenje emisije CO₂ iz zgrada za 15%. Daljinski energetske sistemi nude prednosti ponovne upotrebe iskorišćene energije preko kombinovanih energetske sistema koji proizvode struju i toplotnu energiju i tako dovode do smanjene emisije CO₂. Ovi kombinovani sistemi obezbeđuju struju kako poslovnim tako i stambenim zgradama. Iskorišćena toplotna energija iz procesa generisanja struje se koristi kao toplotna energija za stambene i poslovne zgrade transportom tople vode kroz mrežu sistema daljinskog grejanja. Procenjeno je na globalnom nivou da daljinsko grejanje smanjuje postojeću emisiju CO₂ za 3-4%. EU je ustanovila da nije u potpunosti iskorišćen sav potencijal kogeneracije za uštedu energije.

4.1. Sistemi daljinskog grejanja

Terminom daljinsko grejanje (DG) označavamo centralizovano snabdevanje toplotnom energijom većeg broja potrošača. Potrošači toplote u sistemu daljinskog grejanja mogu biti: postrojenja centralnog grejanja, provetranja, klimatizacije, postrojenja za pripremu tople sanitarne vode, kao i različiti uređaji u industriji koji koriste toplotu.

Podela sistema DG prema nameni:

- komunalni sistemi (stambene, poslovne, javne zgrade)

– industrijski sistemi (razne fabrike – potrebe grejanja i tehnološki procesi)

Podela prema nosiocu toplote:

- vodeni sistemi,
- parni sistemi.

Slično kao i kod sistema centralnog grejanja, kod daljinskog grejanja postoje tri osnovna elementa sistema:

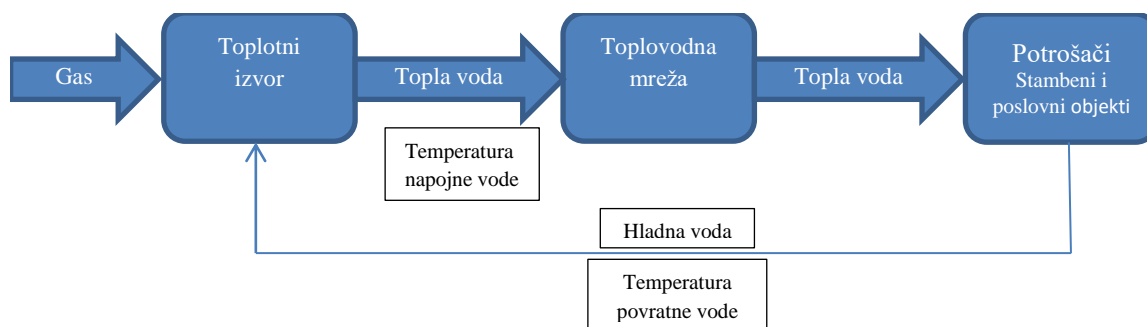
1. element za proizvodnju toplote (toplotni izvor – toplana, kotlovi);
2. element za transport nosioca toplote (cevna mreža – toplovod);
3. element za predaju toplote potrošačima (priključna stanica, predajna stanica, toplotna podstanica ili samo podstanica)

Izvor toplote su obično parni ili vrelovodni kotlovi na čvrsto, tečno ili gasovito gorivo.

Za transport nosioca toplote (radnog fluida) koristi se posebna cevna mreža – toplovod (ili parovod), koja se najčešće izvodi kao podzemna.

Cevi toplovoda ili parovoda moraju biti dobro termički izolovane kako bi se sprečili (sveli na najmanju meru) gubici toplote od izvora do potrošača.

Toplotna podstanica je element sistema u kome se vrši primopredaja toplote između sistema daljinskog grejanja i kućne instalacije.



Slika 4-1 Proces daljinskog grejanja


Prema evropskom udruženju nacionalnih udruženja za daljinsko grejanje, Euroheat&Power, daljinsko grejanje je pogodan način za grejanje prostora i pripremu tople vode. U mnogim procesima, na primer kod procesa proizvodnje električne energije ili pri sagorevanju otpada, velike količine energije se oslobađaju u obliku otpadne toplote. Osnovna ideja vodilja za moderne sisteme daljinskog grejanja je iskorišćavanje ove toplote koja bi inače bila izgubljena iz proizvodnje električne energije, iz procesa rafinacije goriva i biogoriva kao i iz drugih industrijskih procesa. Daljinsko grejanje takođe omogućava korišćenje obnovljivih izvora energije kao što su: biomasa, geotermalna ili sunčeva energija. Daljinsko grejanje u Srbiji se ne zasniva na ovoj jednostavnoj

ideji vodilji. U Srbiji se radi „proizvodnje“ toplote spaljuju komercijalna goriva –prirodni gas, mazut, ugalj.

Kada se govori o obimu DG u Srbiji mogu se definisati sledeće karakteristike:

- sistemom DG greje se približno 800,000 stanovau više od 55 gradova i opština (što je 25% ukupnog stambenog fonda)
- prosečna specifična potrošnja energije za grejanje: 130-180 KWh/m² год.
- troškovi goriva supreko 400 miliona evra godišnje
- postoji više od 6,700 MW kapaciteta u kotlovima koji proizvode samo toplotu
- postoji više od 1,200 km distributivnih mreža
- postoji preko 15,000 podstanica

Preko 90% proizvodnje toplotne energije u sistemima daljinskog grejanja u Srbiji zasnovano je na direktnom korišćenju fosilnih goriva. To je proces u kome se energija dobijena sagorevanjem fosilnih goriva preda velikoj masi vode koja prenosi toplotnu energiju do korisnika sistema bez istovremene proizvodnje električne energije ili industrijske pare. Direktno korišćenje fosilnih goriva zaslužno je za svega 15% proizvodnje toplotne energije u sistemima daljinskog grejanja u 27 zemalja Evropske unije.




Slika 4-2 Udeo korišćenja goriva u sistemima daljinskog grejanja u Srbiji

Neoptimizovana distribucija i isporuka toplote u Srbiji je jedan od problema koji utiču na neefikasnost distribucije i isporuke toplotne energije. Potrebna je modernizacija podstanica u sistemima daljinskog grejanja u Srbiji kako bi se omogućilo uvođenje regulacije putem promenljivog protoka, odnosno kvantitativne regulacije. Ovakva vrsta regulacije bi omogućila značajne uštede koje mogu dosegnuti i do 15% ukupno potrebne energije za optimalno grejanje konzuma.

Gubici u distribuciji toplotne energije postoje i usled lošeg stanja distributivnih mreža sa velikim curenjima vode i nedovoljnom izolacijom. Sistemi daljinskog grejanja u Finskoj se dopunjuju vodom u proseku jednom u toku sezone. Sistemi daljinskog grejanja u Srbiji se dopunjuju od nekoliko puta godišnje do nekoliko desetina puta godišnje. Samo nekoliko sistema daljinskog grejanja u Srbiji ima curenje koje je na nivou najboljih evropskih standarda.

Mere koje treba preduzeti u cilju smanjenja gubitaka u distributivnoj mreži i u celom sistemu daljinskog grejanja su:

- Rehabilitacija primarnih i sekundarnih mreža (sprečavanje curenja)
- Revitalizacija primarnih i sekundarnih mreža (poboljšanje izolacije i sprečavanje korozije)
- Optimizacija distribucije toplote (daljinski nadzor i praćenje)
- Uvođenje kvantitativne regulacije sa promenljivim protokom i uvođenje režima promenljivog protoka u sekundarnim mrežama
- Napredno upravljanje isporukom toplote (permanentno dispečiranje)
- Korišćenje skladišta toplote



Slika 4-3 Ilustracija cene prirodnog gasa – drugo polugodište 2012 [160]

4.2. Osnovne karakteristike sistema daljinskog grejanja

4.2.1 Toplotno opterećenje

Toplotno opterećenje kod sistema daljinskog grejanja je suma toplotnog opterećenja sa strane potrošača i gubitaka toplote tokom distribucije. Zbog toga procenjena potražnja odnosno potreba za toplotnim opterećenjem na strani proizvodnje odnosno toplotnog izvora mora uzimati u obzir i fazu distribucije toplotne energije. Ovaj odnos se može prikazati jednačinom:

$$Q_{proizvodnja} = Q_{gubici} + \sum_1^C Q_{potrošnja} \quad (4.1)$$

Ovde je $Q_{proizvodnja}$ ukupno toplotno opterećenje proizvedeno na toplotnom izvoru. Q_{gubici} je gubitak toplote tokom distribucije zagrejane vode a $Q_{potrošnja}$ je toplotno opterećenje sa strane potrošača. $Q_{potrošnja}$ konstantno varira i zavisi od vremenskih uslova i vremena u toku dana. Distribucija toplotne energije u mreži sistema daljinskog grejanja odnosno toplovodu zavisi od hidrauličkih i termodinamičkih karakteristika sistema.


$Q_{proizvodnja}$ zavisi od 4 nezavisna faktora:

1. Ventili na radiatorima kao grejnim telima.
2. Ventili u podstanicama kojima se upravlja protokom. Oni održavaju konstantnu temperaturu tople vode i temperaturu napojne vode u zavisnosti od spoljne temperature.
3. Upravljanje diferencijalnim pritiskom na strani toplotnog izvora.
4. Temperatura napojne vode na strani toplotnog izvora. Temperatura napojne vode zavisi od spoljne temperature.

Lako se može zaključiti da su prva dva faktora visoko zavisna od potrošnje toplotne energije sa strane potrošača. Zato varijacija toplotnog opterećenja sa strane potrošača rezultira varijacijom toplotnog opterećenja na strani toplotnog izvora. U cilju optimizacije sistema daljinskog grejanja, potrebno je fokusirati se na optimizaciju obe strane kao potrošačke tako i proizvodne. Tačno predviđanje toplotnog opterećenja sa strane potrošača obezbeđuje vrednu informaciju o potrebi toplotnog opterećenja na strani toplotnog izvora. U tom slučaju, toplotni izvor ne bi imao potrebu da proizvodi višak toplotne energije. Na taj način dolazimo do uštede energije i primene načela energetske efikasnosti.

Takvim ponašanjem se smanjuju gubici toplote u mreži i snižava temperatura povratne vode i sveukupno se podiže efikasnost mreže sistema daljinskog grejanja. Zato predviđanje toplotnog opterećenja sa strane potrošača postaje neizbežno za procenu potrebe toplotnog opterećenja na

strani toplotnog izvora i za postizanje adekvatne optimizacije mreže sistema daljinskog grejanja. Na Slici 4-4 su opisane prednosti predviđanja toplotnog opterećenja preko dijagrama.



Slika 4-4 Prednosti predviđanja toplotnog opterećenja na strani potrošača

Potrošači mogu da promene potražnju za toplotnom energijom na dva načina:

1. Konstatna temperaturna razlika i varijabilan protok: Temperaturna razlika je razlika između temperature napojne vode i temperature povratne vode. Potrošač može da poveća potražnju za toplotnom energijom povećanjem protoka. U tom slučaju, povećanje potražnje za toplotnom energijom se prenosi na stranu toplotnog izvora velikom brzinom, oko 1000 m/s.
2. Varijabilna temperatura i konstantan protok: U ovom slučaju, potrošač može da poveća ili smanji razliku u temperaturi kako bi promenio potražnju za toplotnom energijom. Promena u potražnji za toplotnom energijom stiže do toplotnog izvora brzinom jednakom protoku vode u sistemu daljinskog grejanja, oko 1-3 m/s.

U prvom slučaju, samo nekoliko sekundi prođe za prenos od promene potražnje za toplotnom energijom do toplotnog izvora. U drugom slučaju, potrebni su sati da se ta promena u potražnji prenese do toplotnog izvora posebno kod velikih sistema daljinskog grejanja. Tada toplotni izvor menja toplotno opterećenje saglasno promeni potražnje i novo toplotno opterećenje se ponovo prenosi brzinom protoka do strane potrošača. Ovo objašnjava kašnjenje od 4-6 sati u upravljačkoj petlji sistema daljinskog grejanja.

Osnovna razlika između opterećenja kod sistema daljinskog grejanja i elektroenergetskih sistema je u vremenskom kašnjenju koje može biti značajno u mreži sistema daljinskog grejanja dok se kod elektroenergetskih mreža kašnjenje ne pojavljuje. Međutim, sličnosti između ova dva tipa problema ukazuju da je moguće koristiti relativno slične tipove algoritama za predviđanje opterećenja.

4.2.2 Temperature

Izbor projektne temperature je i kompleksan i veoma važan korak u projektovanju mreže sistema daljinskog grejanja. Radne temperature u mreži utiču na kapacitet isporuke toplote i toplotne gubitke. Zato je od samih početaka postojanja sistema daljinskog grejanja optimizacija temperatura daljinskog grejanja stalni izazov.

Postoje dve različite temperature temperatura napojne vode i temperatura povratne vode (napojna i povratna temperatura).

Napojna temperatura je temperatura tople vode koja iz toplotnog izvora ide do potrošačkih podstanica. Ova temperatura je određena toplotnim izvorom. Povratna temperatura je temperatura vode nakon podstanice i zato je to niža temperatura. Povratna temperatura nije radni parametar već je rezultat efektivnog rada u praksi pa na nju utiču sami potrošači i sama topologija mreže.

Kod mreža sistema daljinskog grejanja, postoje dva parametra za upravljanje toplotnom energijom koja se isporučuje potrošačima.

Toplota koju prima potrošač u svojoj postanici zavisi od razlike u temperaturi između zagrejane napojne i ohlađene povratne vode, protoka i konačno od specifičnog toplotnog kapaciteta.

$$P = \dot{m}C_p\Delta T \quad (4.2)$$

$$\Delta T = T_n - T_p \quad (4.3)$$

C_p je karakteristika koja zavisi od vrste fluida (za vodu C_p iznosi 4.18 KJ/kgK u standardnim uslovima ali varira sa temperaturom), i zato nije parametar koji može da se koristi za promenu količine toplotne energije koja se dostavlja potrošačima.

Kako povratna temperatura nije određena od strane toplotnog izvora, to znači da samo temperatura napojne vode i protok mogu da se menjaju od strane snabdevača, odnosno toplotnog izvora kao proizvodne jedinice. Ova dva parametra predstavljaju mehanizam toplotnog izvora za podešavanje proizvodnje shodno zahtevima potrošača u svakom trenutku. Moguće je vršiti podešavanje samo jednog od ova dva parametra. Na primer, moguće je podešavanje samo protoka ali je to problematično sa druge strane jer nije dobro za uređaje kao što su pumpe na mreži da imaju širok radni opseg protoka.

Kako se u gornjim jednačinama vidi, svako smanjenje napojne temperature ili svako povećanje povratne temperature ima smanjenje uticaja na ukupnu toplotnu energiju koja se prenosi.

Efikasna mreža sistema daljinskog grejanja ima dve karakteristike:

- nisku napojnu temperaturu i
- visoku temperaturnu razliku između napojne i povratne temperature

Niska temperatura napojne vode povećava efikasnost proizvodnje i smanjuje transportne gubitke toplote. Na jednoj strani, visoka ΔT dovodi do redukcije protoka tj. do energetske uštede na pumpama. Na drugoj strani, postoji potreba za smanjenjem napojne temperature i povećanjem ΔT . Kako je energija koja se prenosi proporcionalna sa ΔT , efikasna mreža treba da ima nisku povratnu temperaturu.

Ranije je već rečeno da povratna temperatura nije radni parametar jer zavisi od potrošačkog dela mreže. Bez obzira na to, današnji napor za dobijanje što efikasnijih mreža vode do poboljšanja potrošačkih podstanica, redukcije grešaka u radu podstanica i njihovog povezivanja sa mrežom.

Niske temperature napojne i povratne vode imaju pozitivan uticaj na proizvodnju. Sistemi koji imaju samo kotlove za grejanje kao proizvodne jedinice (kakav je najčešći slučaj u Srbiji) nemaju veliku zavisnost svojih performansi od ovih temperatura. Uglavnom, samo srednji toplotni kapacitet može biti pod uticajem ovih parametara. Na drugoj strani, kod toplotnih pumpi ili kogenerativnih postrojenja, nivo temperature ima veliki uticaj na proizvodnju.

Kod toplotnih izvora kao što su toplotne pumpe (tipičan slučaj – Švedska), performanse proizvodnje toplotne energije COP (koeficijent performansi - Coefficient Of Performance – odnos promena u toplotnoj energiji na izlazu) je vezan sa temperaturama. Niska povratna temperatura povećava COP što dovodi do uštede u struji kod proizvodnje toplotne energije.

Kod kogenerativnih postrojenja povratna temperatura igra veoma važnu ulogu. Njeno smanjenje može dovesti do ekonomskog profita kada je u pitanju proizvodnja toplotne energije. Što je niža ova temperatura, to se može generisati više toplotne energije. Ovaj uticaj je posebno značajan kod kombinovanih kogenerativnih postrojenja koja koriste drvo ili otpad kao gorivo.

Rad pumpe predstavlja energiju potrebnu da transportuje toplu vodu od toplotnog izvora do potrošača i nazad. Iz ovog razloga se pumpe instaliraju duž mreže pri čemu se većina njih postavlja na toplotnom izvoru. Pad pritiska se meri dovoljno daleko od izvora i ako pritisak nije dovoljno visok, pumpa obezbeđuje pritisak koji je potreban. Ove pumpe moraju da obezbede pritisak koji se gubi duž dovodnih i odvodnih toplotovodnih cevi zbog trenja odnosno otpora koji se javlja između same vode i cevi. Ovi otpori nemaju linearnu relaciju sa protokom ali su grubo proporcionalni sa trećinom energije protoka. To znači da smanjenje protoka vode imaju jako veliki uticaj na potrošnju energije koja se koristi za pumpe. Ako ponovo pogledamo odnose u jednačini 4.2 možemo zaključiti da povećanje u temperaturnoj razlici dovodi do smanjenog protoka i posledično, do redukcije rada pumpi i troškova.

To znači da možemo zaključiti da povećanje temperaturne razlike ima veoma pozitivni uticaj na energetske uštede, u ovom slučaju, električne energije.

Toplotni gubici na mreži su proporcionalni temperaturnoj razlici između spoljne temperature temperature vode u cevima.

Kako spoljna temperatura nije operativni parametar, toplotni gubici zavise od temperature napojne i povratne vode i njihovog odnosa sa protokom. Za postojeću mrežu daljinskog grejanja, samo temperaturni nivoi i protok mogu da se menjaju sa ciljem smanjenja toplotnih gubitaka u distribuciji.

Sledeća jednakost pokazuje energiju kojom se snabevaju potrošači:

$$\dot{Q}_i + \dot{W}_p = \dot{Q}_g + \dot{Q}_p \quad (4.4)$$

gde je \dot{Q}_i toplotna energija proizvedena na toplotnom izvoru, \dot{W}_p rad koji se prenosi pumpnim stanicama, \dot{Q}_g toplotni gubici duž mreže i \dot{Q}_p toplotna energija koja se isporučuje potrošačima odnosno njihovim podstanicama.

Saglasno modelu koji se može definisati preko 2 cevi – dovodne i odvodne ili povratne koje su smeštene u podzemnom kanalu, toplotni gubici u mreži, po jedinici dužine, se mogu izraziti na sledeći način:

$$\dot{Q}_g = 2 \cdot \left[\frac{(T_c - T_s)}{(R_i + R_o + R_k + R_z)} \right] \quad (4.5)$$

gde je T_c srednja temperatura dve cevi:

$$T_c = \frac{T_n - T_p}{2} \quad (4.6)$$

a R_i, R_o, R_k i R_z , respektivno termički koeficijenti otpora izolacije cevi, otvora kanala, samog kanala i zemljišta, koji se izračunavaju u zavisnosti od materijala i oblika uzimajući u obzir protok.

Iz ovog razloga, stvarno je važno uzeti u razmatranje toplotne gubitke kada se određuju optimalne projektne temperature u sistemu daljinskog grejanja. Potrebno je znati da su normalne vrednosti toplotnih gubitaka u mreži sistema daljinskog grejanja više od 10% energije koja se dovodi.

Može se pomisliti da je optimizacija toplotnih gubitaka laka ukoliko se i napojna i povratna temperatura smanje na minimum. Naravno da će takva mera dovesti do smanjenja toplotnih gubitaka. Međutim, druge okolnosti se moraju uzeti u obzir, kao što je činjenica da će smanjenje temperaturne razlike rezultirati većim protokom a onda posledično višim padom pritiska i većom potrošnjom energije za pumpe.

Takođe, napojnu temperaturu nije moguće smanjiti ispod zahteva koji su postavljeni od strane potrošača.

Efikasnost mreže sistema DG je primarno zavisna od nivoa temperatura. To znači da je od važnosti optimizovati i napojnu i povratnu temperaturu. Ovakva optimizacija dovodi do manje potrošnje energije i predstavlja dobro poznati cilj kod savremnih sistema.

Odgovarajuća optimizacija mora uzeti u obzir sve uticaje koji su gore opisani kao i njihovu interakciju. Mora se imati u vidu da ponekad poboljšanja jednog uticaja dovodi do pogoršanja ostalih i obrnuto. Iz tog razloga, optimizacija cele mreže treba da obuhvati: proizvodnju, transport odnosno prenos toplote kroz mrežu i potrošačke podstanice.

Optimizacija temperatura napojne i povratne vode zavisi od ograničavajućih uslova. Svaka mreža ima svoje sopstvene vrednosti za optimalna rešenja pa obično najbolje rešenje za jednu mrežu ne može direktno ekstrapolirati na druge mreže.

Potrošač ima važnu ulogu u optimizaciji mreže daljinskog grejanja. U cilju minimiziranja potrošnje struje koju koriste pumpe u mreži, temperaturna razlika između napojne i povratne temperature mora biti maksimizirana. Kao što je ranije pomenuto, napojna temperatura je parametar u proizvodnji toplotne energije na toplotnom izvoru dok povratna temperatura to nije. Povratna temperatura zavisi od potrošača. Željena niska povratna temperatura je jedino moguća ako su potrošačke podstanice adekvatno projektovane i ako ispravno rade. Kod sistema daljinskog grejanja, slično drugim mrežama kao što je elektroenergetska, potrošač ima veliki uticaj na mrežu. Kod elektroenergetskih mreža, operator električne energije mora da uzima u obzir reaktivnu snagu, potencijalnu razliku, intenzitet itd.

Kod sistema daljinskog grejanja, temperature i protoci su parametri. Primarna mreža, tj. cevi između toplotnog izvora i potrošačkih podstanica, se projektuje saglasno ugovorenoj snazi potrošača i nivoa temperatura. Ali kada jedan potrošač ne održava visoku temperaturnu razliku u sekundarnoj mreži, potreban je veći protok u primarnoj mreži da bi preneo istu toplotnu snagu. Iz ovog razloga, kada potrošač vrati vodu na visoku temperaturu, podstanica mora da poveća protok, što rezultuje povećanim obimom rada pumpe i rizikom da drugi potrošači ne prime ugovorenu snagu.

Temperaturna razlika mora da bude maksimizirana u cilju da može da radi sa minimalnim zahtevanim protokom. Ova činjenica mora da bude uzeta u obzir i kod primarne i kod sekundarne mreže.

U primarnoj mreži protok vode se reguliše saglasno zahtevu za toplotnim potrebama. U toku zime, sa visokim zahtevom za toplotnim potrebama, protok je viši. Varijabilni protok u mreži je način da se optimizuju troškovi distribucije.

U sekundarnoj mreži, ista razmatranja moraju biti uzeta u obzir.

4.3. Toplotni izvori

U ovoj disertaciji su korišćeni podaci sa 4 toplotna izvora: TI Krivi vir, TI Konjarnik, TI Mašinski fakultet i TI Klinički centar Niš. Raspolagalo se sa podacima za više različitih grejnih sezona.

Izvršeno je ujednačavanje podataka tako da je za svaki toplotni izvor posmatrana samo po jedna grejna sezona.

Očitavanja su bila različita: TI Krivi vir i TI Mašinski fakultet su imali časovno očitavanje a TI Konjarnik i TI Klinički centar očitavanje na 15 minuta.

Izvršeno je ujednačavanje očitavanja na sat vremena.

Grejanje je po definiciji u Srbiji sa prekidima u toku noći i traje od 5 do 21 čas. Međutim, nekim danima u toku grejne sezone dolazi do grejanja u toku noći zbog niske temperature ili zbog praznika.

Ujednačeni su podaci sa TI samo za period grejanja od 5 do 21 čas.

U pojedinim danima tokom posmatranih grejnih sezona dolazilo je do prekida isporuke toplotne energije tokom celog dana ili u toku dana zbog kvarova na TI ili toplovodnoj mreži.

Ujednačeni su podaci sa TI za periode kada je iz gore navedenih razloga dolazilo do obustavljanja toplotne energije.

Sva ova ujednačavanja su urađena kako bi se obezbedili reprezentativni skupovi podataka za obučavanje neuronskih mreža a sve u cilju adekvatnog kratkoročnog predviđanja.

Tabela 4-1 Osnovne karakteristike posmatranih toplotnih izvora

Toplotni izvor	Tip	Potrebe	Grejna sezona	Očitavanje	Period
Krivi vir	gas/grejanje	stanovanje, poslovanje	1	časovno	5-21 čas
Konjarnik	gas/grejanje, sanitarna voda	stanovanje, poslovanje	1	časovno	5-21 čas
Klinički centar	gas/grejanje, para	poslovanje	1	časovno	5-21 čas
Mašinski fakultet	gas/grejanje	stanovanje	1	časovno	5-21 čas

4.3.1. Opšta razmatranja

Kada se govori o stanju toplotnih izvora u Srbiji, treba istaći da mali broj velikih jedinica služi da isporuči optimalnu količinu toplote najdaljem potrošaču u najhladnijem danu ali da ne postoji dovoljno toplotnih skladišta i vršnih kapaciteta.

Spoljne projektne temperature u nacionalnim standardima ne odgovaraju stvarnim klimatskim uslovima – odnosno postoji inherentna precenjenost potrebne instalisane snage grejnih tela.

Takođe, ostavljena je rezerva kapaciteta zarad očekivanog povećanja konzuma.

Voda je danas osnovni nosilac toplote u sistemima DG gde se uglavnom primenjuju vrelovodni sistemi ($\theta_r > 110\text{ C}$).

- Toplota koju voda prenosi je direktno proporcionalna masenom protoku i razlici temperatura napojne i povratne vode.

- Izbor temperatura napojne i povratne vode je od velikog značaja. Da bi toplovod bio jeftiniji (manjih prečnika) i da bi snaga pumpe i utrošeni rad bili manji, potrebno je da maseni protok bude manji, a to znači da razlika temperatura napojne i povratne vode treba da bude što veća. Ovo je naročito važno kada su u pitanju veće dužine transporta.

Sa porastom temperature napojne vode raste i njen pritisak (kako bi se sprečilo ključanje). Prema tome, potrebno je optimizirati vrednost temperature napojne vode zajedno sa toplotnim izvorom i načinom regulisanja toplotnog konzuma (kvantitativno, kvalitativno ili kombinovano). Projektni parametri treba da daju najbolje rezultate za celogodišnji rad sistema DG. Sa druge strane, svakako treba težiti da temperatura povratne q_p vode bude što niža, ali je ona ograničena temperaturom povratne vode u kućnoj instalaciji.

U našoj zemlji se u sistemima DG uglavnom koriste toplane za proizvodnju toplote i koriste se sledeći temperaturni režimi:

- 110/70°C; 130/70°C; 140/70°C i 150/70°C za direktne sisteme i
- 110/75°C; 130/75°C; 140/75°C i 150/75°C za indirektno sisteme.

Podela mreža daljinskog grejanja može se izvršiti na nekoliko načina:

- Prema konfiguraciji postoje:
 - zrakaste i
 - prstenaste mreže.
- Prema broju cevi:
 - jednocevne (za transport pare bez povratka kondenzata - neekonomično);
 - dvocevne (najčešće primenjivane);
 - trocevne (dve razvodne sa različitim q_r i jedna povratna).
- Prema načinu polaganja cevi:
 - nadzemne (jeftinije, primenjuje se u industrijskim kompleksima) i
 - podzemne (cevi u kanalima ili beskanalno polaganje u zemlju).

Kod manjih sistema daljinskog grejanja proizvodnja toplote odvija se u kotlarnicama (KO) ili toplanama (TO). U toplanama se, pored kotlova za proizvodnju toplote, nalazi i ostala prateća oprema i uređaji. Kotlovi u toplani mogu biti na čvrsto, tečno ili gasovito gorivo. U novije vreme primenjuju se i kotlovi za sagorevanje biomase (u vidu briketa ili peleta), koji zamenjuju ugljeve i time dovodi do smanjene emisije štetnih gasova u okolinu. Kotlovi u toplanama mogu biti vrelovodni ili parni.

Proizvodnja toplote u većim sistemima često se odvija spregnuto sa proizvodnjom električne energije. Takva proizvodnja toplote naziva se kombinovana proizvodnja, i odvija se u posebnim postrojenjima. Ukoliko je primarna proizvodnja toplote onda se takva postrojenja nazivaju toplane - elektrane (TOE), a ako je primarna proizvodnja električne energije onda jereč o termoelektranama - toplanama (TETO). Pri kombinovanoj proizvodnji toplote i električne energije stepen korisnosti iskorišćenja primarne energije je veći nego pri odvojenoj proizvodnji, čak i do dva puta. Kombinovana proizvodnja je idealno rešenje kada se sagorevaju niskokalorični ugljevi u blizini velikih urbanih sredina. Za kombinovanu proizvodnju mogu se koristiti:

- parno-turbinska postrojenja (najčešće primenjivana),
- gasno-turbinska postrojenja i
- kombinovana parno-gasna turbinska postorjenja.

U sistemima daljinskog grejanja veoma je važna raspodela pritiska u mreži. Pritisak u mreži se razlikuje u stanju mirovanja radnog fluida (statički) i u radu sistema. Nikada i nigde u sistemu se ne sme dozvoliti:

- da pritisak poraste iznad pritiska zasićenja, kako ne bi došlo do isparavanja vode i
- da pritisak padne ispod atmosferskog, kako ne bi došlo do usisavanja vazduha.

Sa druge strane maksimalni pritisak vode u grejnim telima je 6 bar, pa se zbog toga na brežuljastim terenima obavezno primenjuje indirektni sistem (kada se hidraulički razdvajaju primarni i sekundarni cirkulacioni krug).

Maksimalni pritisak u primarnom delu mreže je 25 bar.

Održavanje pritiska se može rešiti na nekoliko načina i to obično u kombinaciji sa rešavanjem problema ekspanzije vode prilikom zagrevanja. Neki od načina su:

- Ekspanzioni sud sa parnim prostorom,
- Ekspanzioni sud sa gasnim jastukom,
- Diktir sistem (pomoću posebnih cirkulacionih pumpi - diktir pumpi).

Postoje dva osnovne tipa toplotnih podstanica:

- sa direktnim priključkom i
- sa indirektnim priključkom.

Kod sistema sa direktnim priključkom sistem daljinskog grejanja i kućna instalacija predstavljaju jedinstven hidraulički (cirkulacioni) krug. Ovo rešenje je jednostavnije, jeftinije i ekonomičnije. U ovom sistemu je temperatura povratne vode primara niža i jednaka je temperaturi povratne vode u sekundaru (kućnoj instalaciji). Međutim, ovakav sistem nije uvek primenljiv, zbog pritiska koji je potrebno održavati u mreži daljinskog grejanja. Nepovoljnost predstavlja i jedinstven cirkulacioni krug, pa se nečistoće iz kućne instalacije prenose u instalaciju daljinskog grejanja..

Indirektan priključak podrazumeva postojanje razmenjivača toplote, koji služi za razmenu toplote između vode primara i sekundara i on hidraulički razdvaja cirkulacione krugove sistema DG i kućne instalacije. Prednost ovakve podstanice je što je pritisak u kućnoj instalaciji nezavisan od pritiska u toplovodu. Osim toga, nema mešanja vode iz kućne instalacije sa vodom iz sistema DG.

4.3.2 Toplana Krivi vir

Snabdevanje toplotnom energijom teritorije grada Niša, vrši se centralnim sistemom toplifikacije grada, lokalnim kotlarnicama i individualnim ložištima.


Pored toplifikacije, stvoreni su uslovi da se gasovodnom mrežom niskog pritiska do potrošača kao energent dovede i prirodni gas. Centralni sistem toplifikacije grada čine izvori toplotne energije u sklopu JKP „Gradska toplana“ i mreža magistralnih toplovoda. Ukupni instalisani kotlovski kapaciteti u jedinstvenom sistemu toplifikacije grada u 13 objekata, kojima gazduje JKP „Gradska toplana Niš“, iznose 236,80 [MW]. Glavne izvore toplotne energije čine dve toplane: toplana „Krivi Vir“ i toplana „Jug“ sa instalisanim kapacitetima kotlova od 195,00 [MW] i još 11 lokalnih kotlarnica sa instalisanim kotlovskim kapacitetima od 48,00 [MW]. Od navedenih toplotnih izvora kojima gazduje JKP „Gradska toplana Niš“ samo toplana „Krivi Vir“, toplana „Jug“ i toplana „Majakovski“ kao osnovni energent, koriste prirodni gas.

Distribucija toplotne energije do potrošača vrši se mrežom magistralnih toplovoda u dužini od oko 67,00 [km] i u 1140 podstanica. U najvećem delu obuhvata centralno gradsko jezgro na levoj obali Nišave. Prosečna godišnja proizvodnja toplotne energije u toplanama i kotlarnicama u okviru JKP "Gradska toplana" Niš je oko 235.000MWh. Ovim sistemom trenutno je pokriveno 29.098 stambenih i 2.104 poslovnih korisnika.




Slika 4-5 Toplana „Krivi vir“

Za potrebe ove disertacije posmatrana je zimska grejna sezona 2012/2013. Prosečna spoljna temperatura 6.2 °C za period 15.10.2012 do 24.03.2013. godine, pri čemu je minimalna temperatura bila -11°C a maksimalna temperatura 23°C. Prosečna temperatura napojne vode u istom periodu je bila 67.9 °C a prosečna temperatura povratne vode 48.8 °C. Tako se lako može izračunati da je prosečna temperaturna razlika između napojne i povratne vode 19.1 °C. Prosečan protok u sezoni 2012/2013 je bio 2730 m³/h. Po pravilu sa porastom temperature trebalo bi da opada protok. Kao što se može videti analizom dijagrama sa Slike 4.8 postoji zavisnost protoka od spoljne temperature ali promena protoka sa porastom temperature nije adekvatna promeni koja se može konstatovati kod sistema daljinskog grejanja sa regulisanim protokom. Tako se može konstatovati da postoji puno prostora za uregulisanjem protoka kod konkretnog sistema daljinskog grejanja.




Slika 4-6 Proizvedena snaga na TI Krivi vir 2012/2013



Slika 4-7 Zavisnost temperature napojne i povratne vode od spoljne temperature

TI Krivi vir



Slika 4-8 Zavisnost protoka od spoljne temperature TI Krivi vir

Treba imati u vidu da je reč o prekidnom sistemu grejanja gde se toplotna energija isporučuje potrošačima u periodu od 5 časova ujutru pa do 21 sat. Međutim, ono što otežava upravljanje i adekvatno predviđanje potrebne količine toplotne energije koja treba da se proizvede je da dolazi do prekida isporuke toplotne energije i u toku radnog režima (od 5 č. do 21 č.) u slučajevima kada je spoljna temperatura veća od 12 °C. Takav režim nazivamo tzv. „prelaznim režimom“. Prelazni režimi se uglavnom javljaju na početku i na kraju grejne sezone. Ono što nije dobro kod ovih režima je potreba da više puta dnevno uključujete i sključujete kotlolove za grejanje odnosno sam toplotni izvor što povećava troškove eksploatacije ali smanjuje vek trajanja samog toplotnog izvora i opreme koja se nalazi na izvoru.

Tabela 4-2 Prikaz osnovnih karakteristika za sezonu 2012/2013 TI Krivi vir

Spoljna temperatura [°C]	Broj sati [-]	Temperatura napojne vode [°C]	Temperatura povratne vode [°C]	Protok [m ³ /h]	Snaga [MW]
-11	4	83.00	54.75	2787.00	91.57
-10	5	83.00	56.80	2790.60	85.04
-9	3	81.60	55.30	293.30	85.54
-8	5	81.00	52.80	2788.20	91.42
-7	3	85.60	56.30	2778.30	94.83
-6	9	86.11	57.78	2783.89	91.74
-5	13	81.46	53.62	2775.31	89.85
-4	23	82.43	54.70	2779.04	89.69
-3	59	82.90	55.44	2771.86	88.52
-2	48	80.83	53.42	2773.31	88.44
-1	59	78.90	53.00	2764.46	83.28
0	116	77.66	52.44	2757.84	80.93
1	160	76.46	52.79	2755.31	75.88
2	130	74.20	51.72	2754.35	72.03
3	181	72.25	50.91	2743.97	68.09
4	161	69.67	50.00	2725.93	62.40
5	138	67.04	49.57	2731.84	55.61
6	160	66.14	48.33	2727.50	56.55
7	194	63.48	46.79	2719.89	52.85
8	184	61.63	45.73	2720.58	50.35
9	123	59.20	45.01	2718.01	44.92
10	124	57.86	44.32	2714.31	42.49
11	95	56.61	43.89	2691.60	39.70
12	50	55.46	42.20	2699.06	41.53
13	39	55.23	42.21	2666.10	40.51
14	23	55.35	40.35	2640.57	46.04
15	6	54.83	40.67	2647.83	43.95
16	3	54.33	40.33	2373.67	37.51
Prosečna vrednost:		70.87	49.68	2638.34	67.54

Za posmatranu grejnu sezonu 2012/2013 postoji 536 sati kada nije vršena isporuka toplotne energije u okviru radnog režima toplotnog izvora. Kako je ukupan broj sati u grejnoj sezoni bio 2737, to se dobija da je za 19.5% potencijalnih radnih sati bilo prekida u isporuci toplotne energije. Takođe, važno je istaći da je 25 radnih dana dolazilo do uključivanja i isključivanja toplotnog izvora sa isporuke toplotne energije u toku grejne sezone. Kako je cela grejna sezona efektivno

trajala 160 dana to znači da je 15.6% dana bilo sa uključivanjima i isključivanjima toplotnog izvora sa isporukom toplotne energije.


TI Krivi vir snadbeva toplotnom energijom različite tipove potrošača pa se može zaključiti da će korišćenjem karakteristika ovog TI biti omogućena analiza kratkoročnog predviđanja za kombinovani i mešoviti tip potrošača stanovanje i poslovanje.

4.3.3 Toplana Konjarnik

Sistem daljinskog grejanja „Beogradskih elektrana“ je jedinstven tehničko – tehnološki sistem međusobno povezanih energetske objekata koji služi za proizvodnju, prenos i isporuku toplotne energije. Sistem čine proizvodni izvori, toplovodna mreža i predajne stanice.

Toplana „Konjarnik“ je puštena u rad 1976. godine. Tada su izgrađena dva kotla instalisane snage po 58 MW, a kasnije još jedan od 116 MW. Ukupna instalisana snaga Toplane „Konjarnik“ je 232 MW. Kotlovi kao primarno gorivo koriste prirodni gas, a alternativno mazut. Za sopstvene potrebe ugrađeni su i parni kotlovi kapaciteta 2 x 10 t/h pare.

30.12.2015 pušten je u rad novi vrelovodni kotao kapaciteta 70 MW čime je povećan kapacitet toplane “Konjarnik” na 302 MW. Konstrukcija kotla je vertikalni membranski sa gorionikom na prirodni gas, koji je ugrađen na plafonu kotla. Gorionik je snage 70 megavata, najmodernije konstrukcije sa Low NOx, tako da ispunjava sve zahteve i standarde zaštite čovekove okoline. Kotao je povezan u sistem preko razmenjivača toplote voda/voda snage 70 megavata, koji je prvi put izgrađen u Srbiji.



Slika 4-9 Toplana „Konjarnik“

Prosečna spoljna temperatura 9.37 °C za period 12.10.2013 do 31.03.2014. godine, pri čemu je minimalna temperatura bila -6.5°C a maksimalna temperatura 26°C. Prosečna temperatura napojne vode u istom periodu je bila 58.37 °C a prosečna temperatura povratne vode 39.37 °C. Tako se lako može izračunati da je prosečna temperaturna razlika između napojne i povratne vode 19 °C. Prosečan protok u sezoni 203/2014 je bio 3482.80 m³/h. Analizom dijagrama protok-spoljna temperatura sa Slike 4.12 može se ustanoviti razlika između radnog režima TI Konjarnik i TI Krivi vir, objašnjenog u prethodnom poglavlju. Naime, opseg kretanja intenziteta protoka je kod TI Konjarnik mnogo širi iz dva razloga:


- zbog postojanja sanitarne vode i potrebe njenog zagrevanja
- zbog činjenice da je sistem uregulisanja kod TI Krivi vir zasnovan na praćenju temperature odlazne vode i njenim povećavanjem srazmerno snižavanju spoljne temperature – zato je opseg protoka jako uzan i može se govoriti o konstantnom protoku.

Ova dva sistema daljinskog grejanja (TI Konjarnik i TI Krivi vir) se razlikuju i u načinu aktiviranja samih sistema.

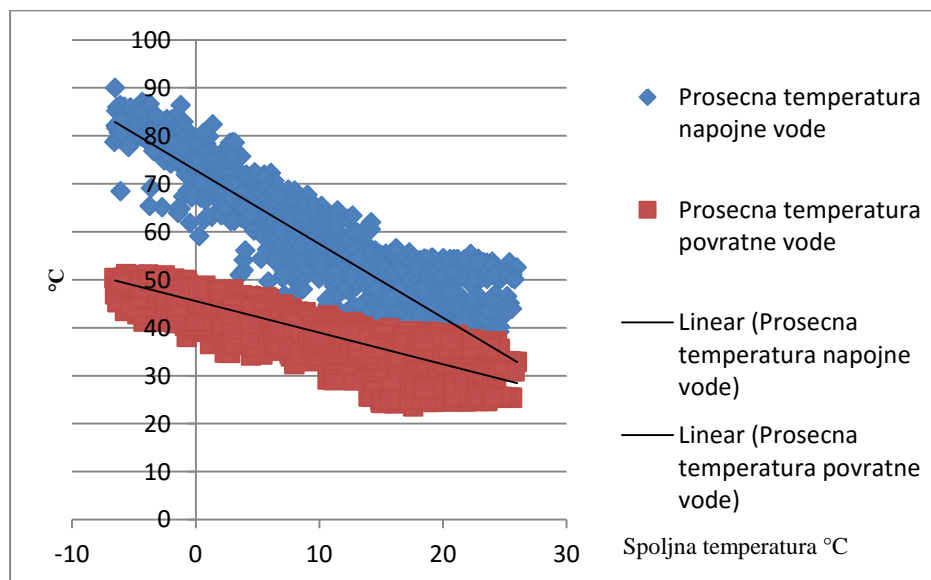
Kod TI Krivi vir toplotne podstanice se uključuju kako koja dostigne zadate parametre temperature napojne vode što znači da će se prve uključiti one koje su najbliže samom TI a da će se tek posle određenog broja sati uključiti one koje su najudaljenije u toplovodnoj mreži od TI.

Kod TI Konjarnik se vrši zagrevanje vode u celoj mreži pre uključivanja podstanica da bi u određenom trenutku se uključile sve pumpe koje aktiviraju podstanice i na taj način počinje zagrevanje potrošača.


Sa aspekta potrošača, razlika u aktiviranju sistema dovodi do toga da na TI Konjarnik svi potrošači istovremeno dobijaju grejanje dok kod TI Krivi vir najudaljeniji potrošači dobijaju grejanje sa kašnjenjem.



Slika 4-10 Ukupna snaga na TI Konjarnik 2013/2014



Slika 4-11 Zavisnost temperature napojne i povratne vode od spoljne temperature



Slika 4-12 Osnovne karakteristike i međusobne zavisnosti za grejnu sezonu 2013/2014 TI „Konjarnik“ [m³/h]

Sledeća razlika koja se može konstatovati poređenjem dijagrama temperatura povratne i napojne vode TI Krivi vir i TI Konjarnik je da su prosečne temperature napojne i povratne vode kod TI Konjarnik prosečno niže za oko 9°C, dok je temperaturna razlika gotovo identična. Ova razlika nema osnovu ni zbog činjenice da je kod TI Konjarnik potrebna uvek određena viša temperatura zbog zagrevanja sanitarne vode. Međutim, razlog u ovoj razlici leži u činjenici da je prosečna spoljna temperatura za posmatrani period kod TI Krivi vir za preko 3°C niža, što neminovno dovodi do povećanja temperatura napojne i povratne vode.

Tabela 4-3 Prikaz osnovnih karakteristika za sezonu 2013/2014 TI Konjarnik

Spoljna temperatura [°C]	Broj sati [-]	Temperatura napojne vode [°C]	Temperatura povratne vode [°C]	Protok [m ³ /h]	Snaga [MW]
-7	1	78.73	50.38	4832	154
-6	19	82.35	48.60	4759	179
-5	12	82.32	42.83	4743	179
-4	26	80.95	48.71	4608	164
-3	28	79.62	47.06	4688	171
-2	31	79.22	46.56	4588	167
-1	70	76.55	46.51	4649	156
0	85	75.04	46.11	4598	149
1	124	73.81	45.65	4547	143
2	102	71.68	44.72	4559	138
3	115	69.75	43.72	4593	134
4	99	66.63	42.82	4544	122
5	81	65.24	41.63	4473	121

6	101	63.31	41.37	4435	111
7	164	60.75	41.02	4411	99
8	211	59.27	39.97	4431	97
9	228	57.39	39.06	4395	92
10	197	56.21	38.76	4268	85
11	180	53.87	38.17	3971	72
12	142	53.09	37.85	4035	71
13	127	52.21	37.57	3098	65
14	107	49.32	36.19	3098	55
15	114	46.79	35.61	2044	35
16	95	46.49	34.51	1295	20
Prosečna vrednost:		65.86	42.31	4152	115.79

Treba imati u vidu da je reč o prekidnom sistemu grejanja gde se toplotna energija isporučuje potrošačima u periodu od 5 časova ujutru pa do 21 sat. Međutim, ono što otežava upravljanje i adekvatno predviđanje potrebne količine toplotne energije koja treba da se proizvede je da dolazi do prekida isporuke toplotne energije i u toku radnog režima (od 5 č. do 21 č.) u slučajevima kada je spoljna temperatura veća od 12 °C. Za posmatranu grejnu sezonu 2013/2014 postoji 589 sati kada nije vršena isporuka toplotne energije u okviru radnog režima toplotnog izvora. Kako je ukupan broj sati u posmatranom periodu grejne sezone bio 2891, to se dobija da je za 20.3% potencijalnih radnih sati bilo prekida u isporuci toplotne energije. Takođe, važno je istaći da je 17 radnih dana dolazilo do uključivanja i isključivanja toplotnog izvora sa isporuke toplotne energije u toku grejne sezone. Kako je cela grejna sezona efektivno trajala 170 dana to znači da je 10% dana bilo sa uključivanjima i isključivanjima toplotnog izvora sa isporukom toplotne energije.

TI Konjarnik snadbeva toplotnom energijom i sanitarnom vodom različite tipove potrošača pa se može zaključiti da će korišćenjem karakteristika ovog TI biti omogućena analiza kratkoročnog predviđanja za kombinovani i mešoviti tip potrošača stanovanje i poslovanje.

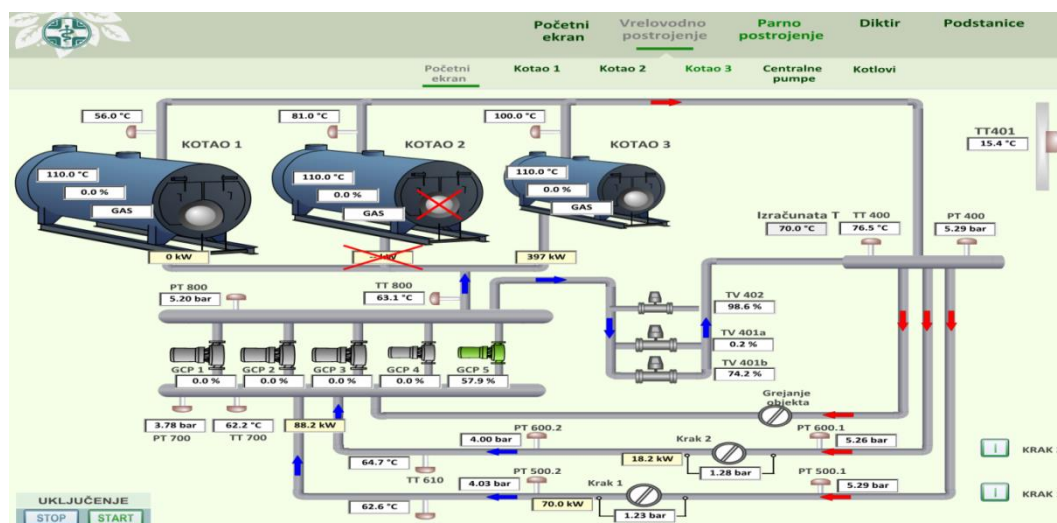
4.3.4 Kotlarnica KC Niš

Kao prioritet u daljem razvoju sistema toplifikacije izvršena je rekonstrukcija kotlarnice KC Niš, koja umesto uglja koristi prirodni gas. Kapacitet kotlarnice je 30 MW. Kotlarnica primarno snabdeva toplotnom energijom Klinički centar Niš, Medicinski i Stomatološki fakultet, Hitnu pomoć, Institut za zaštitu zdravlja i Zavod za transfuziju. Deo kapaciteta ove kotlarnice (6MW) namenjen je potrebama Grada, kao zamena za gašenje kotlarnice „Čair“, koja je u neposrednoj blizini, a koja kao energent koristi mazut.

Vrednost radova, koji su trajali nekoliko godina, je 4,5 miliona evra, a kotlarnica je puštena u rad za grejnu sezonu 2012/2013. Novac je obezbeđen iz kredita Svetske banke za koji je garanciju dala Vlada Republike Srbije. Nekadašnja kotlarnica na ugalj niškog Kliničkog centra bila je jedan od najvećih zagađivača šireg centra grada. Osim zaštite životne sredine nova gasna kotlarnica snage 30 MW smanjuje utrošak energije za 30 do 50 odsto.



Slika 4-13 TI „KC Niš“



Slika 4-14 Shematski prikaz TI „KC Niš“

Kako TI Klinički centar Niš obezbeđuje toplotnu energiju za grejanje Kliničkog centra i drugih medicinskih ustanova, na taj način se omogućava analiza predloženih algoritama za kratkoročno predviđanje za specifičan tip potrošača za poslovanje i medicinu.

Međutim, u ovoj disertaciji podaci za TI KC Niš služe kao kontrolni kako bi se izvršila verifikacija dobijenih rezultata. To znači da se ne vrši posebna analiza karakteristika ovog TI niti se raspolaže dovoljnim skupom podataka za neku drugačiju analizu.

Na osnovu podataka o toplotnom opterećenju koje je časovno očitano i u zavisnosti od spoljne temperature, realizovani su skupovi podataka koji su iskorišćeni za testiranje veštačkih neuronskih mreža koje su projektovane i modifikovane na ostala tri toplotna izvora.

Reč je o drugoj grejnoj sezoni nakon puštanja u rad ovog TI, grejnoj sezoni 2013/2014.

Prosečna spoljna temperatura u grejnoj sezoni 2013/2014 je bila 9.77°C za period 15.10.2013 do 31.03.2014. godine, pri čemu je minimalna temperatura bila -7°C a maksimalna temperatura 26°C .

4.3.5. Toplana Mašinski fakultet

U kotlarnici su instalirana tri vrelovodna kotla temperaturnog režima $130/70^{\circ}\text{C}$, od kojih su dva kotla tip: TE-110 V proizvođača „MINEL-Kotlogradnja“ snage $Q=8700\text{kW}$, a treći, naknadno ugrađeni kotao tip: UT-H 8200 proizvođača „LOOS“ snage $Q=8200\text{kW}$.

Za sagorevanje goriva u kotlovima broj 2 i 3 koriste se kombinovani gorionici gas/mazut proizvođača „SAACKE“ tip: SKVG-A 102-30, povezani sa dovodom gasa preko sopstvenih gasnih rampi sa potrebnom regulacionom, mernom i sigurnosnom opremom.

Kotao broj 1 poseduje gorionik za sagorevanje samo mazuta. Kao alternativno gorivo koristi se mazut.

Za zaštitu hladnog kraja kotlova koriste se tri pumpe povezane u zajednički recirkulacioni sistem.

Distribucija toplotne energije se vrši preko četiri grane i to grane za Mašinski fakultet, za Elektronski fakultet i Studentski centar, za Tehničke škole i za naselje „Nikola tesla“. Cirkulacija vode do potrošača postiže se ugrađenim cirkulacionim pumpama koje su posebne za svaku od četiri grane. Regulacija temperature vode vrši se preko dva trokraka elektromotorna ventila u zavisnosti od spoljašnje temperature.

Na Toplifikacioni sistem Mašinskog fakulteta priključeno je ukupno 12 toplotnih podstanica, i to:

- Stambeno naselje "Nikola Tesla": 5 TPS (2 x 1500kW i 3 x 800kW)

- Studentski centar, Paviljon 4: 1 TPS
- Studentski centar, Restoran "INDEX": 1 TPS
- Elektronski fakultet: 2 TPS
- Mašinski i Građevinsko – arhitektonski fakultet: 1TPS
- Srednje tehničke škole: 2 TPS

Sve toplotne podstanice su indirektnog tipa, projektovane za temperaturske režime 130/80°C (primar) i 90/70°C (sekundar), pri čemu samo podstanice u stambenom naselju "Nikola Tesla" imaju ugrađene pločaste razmenjivače toplote. Ostale podstanice su starije generacije sa dobošastim razmenjivačima toplote. Frekventna regulacija cirkulacionih pumpi nije urađena ni u jednoj toplotnoj podstanici.

Podstanice u naselju "Nikola Tesla" opremljene su meračima utroška toplotne energije na primarnoj strani i balasnim ventilima sekundarnog kruga. Cirkulacija kroz sekundarni krug obezbeđuje se radnim cirkulacionim pumpama. Pored radnih na svakoj grani cirkulacionog kruga ugrađene su i rezervne pumpe. Regulacija u ovim podstanicama vrši se prolaznim kombi ventilom na primarnoj strani, kojim rukovodi upravljačka jedinica, a na osnovu informacija sa spoljnog temperaturskog senzora.

Regulacijom se obezbeđuje poštovanje kliznog dijagrama u napojnom vodu sekundarnog kruga. Toplotna podstanica u objektu Studentski centar – Paviljon 4, opremljena je radnim i rezervnim pumpama za obezbeđenje cirkulacije u sekundarnom krugu.

Poštovanje kliznog dijagrama u napojnom vodu sekundarnog kruga obezbeđuje se sa dva trokraka motorna regulaciona ventila preko zajedničke upravljačke jedinice. Ova toplotna podstanica raspolaže meračem utroška toplotne energije.


Toplotne podstanice u objektima Studentski centar – Restoran "INDEX", Mašinski i Građevinsko-arhitektonski fakultet, opremljene su radnim i rezervnim pumpama za obezbeđenje cirkulacije u sekundarnom krugu. Toplotne podstanice u pomenutim objektima raspolažu meračima utroška toplotne energije i regulacionom opremom.

Toplotne podstanice u objektu Elektronski fakultet opremljene su meračima utroška toplotne energije na primarnoj strani instalacije i balasnim ventilima sekundarnog kruga. Cirkulacija kroz sekundarni krug obezbeđuje se radnim cirkulacionim pumpama. Pored radnih na svakoj grani cirkulacionog kruga ugrađene su i rezervne pumpe. Toplotna podstanica raspolaže sistemom za hemijsku pripremu vode u sekundarnoj instalaciji, ali ne i sistemom regulacije.

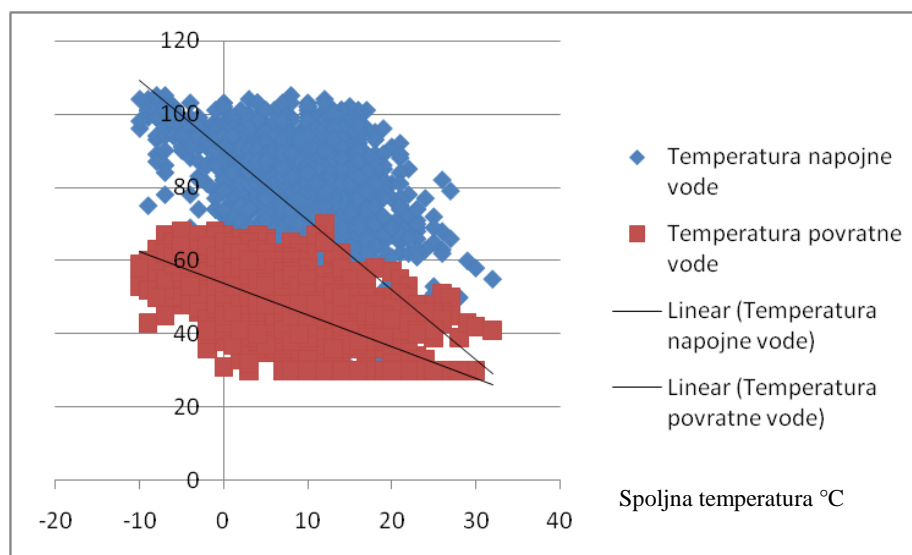
Toplotna podstanica u objektu Srednje tehničke škole opremljena je meračem utroška toplotne energije na primarnoj strani i balasnim ventilima sekundarnog kruga.

Cirkulacija kroz sekundarni krug obezbeđuje se radnim cirkulacionim pumpama. Pored radnih, na svakoj grani cirkulacionog kruga ugrađene su i rezervne pumpe. Regulacija u podstanici vrši se prolaznim kombi ventilom na primarnoj strani, kojim rukovodi upravljačka jedinica, a na osnovu informacija sa spoljnog temperaturnog senzora. Regulacijom se obezbeđuje poštovanje kliznog dijagrama u napojnom vodu sekundarnog kruga.

Prosečna spoljna temperatura 9 °C za period 01.10.2014 do 30.04.2015. godine, pri čemu je minimalna temperatura bila -10°C a maksimalna temperatura 32°C. Prosečna temperatura napojne vode u istom periodu je bila 73 °C a prosečna temperatura povratne vode 46 °C. Tako se lako može izračunati da je prosečna temperaturna razlika između napojne i povratne vode 27 °C.



Slika 4-15 Proizvedena snaga na TI Mašinski fakultet 2014/2015 za stambeno naselje “Nikola Tesla”



Slika 4-16 Zavisnost temperature napojne i povratne vode od spoljne temperature TI MF

Tabela 4-4 Prikaz osnovnih karakteristika za sezonu 2014/2015 TI „Mašinski fakultet“

Spoljna temperatura [°C]	Broj sati [-]	Temperatura napojne vode [°C]	Temperatura povratne vode [°C]	Snaga [MW]
-10	3	99.00	57.00	2.538
-9	8	98.00	55.00	2.203
-8	12	98.00	56.00	1.748
-7	16	96.00	56.00	1.921
-6	11	99.00	57.00	1.617
-5	11	96.00	59.00	1.759
-4	19	93.00	58.00	1.646
-3	37	93.00	59.00	1.512
-2	36	86.00	56.00	1.440
-1	48	86.00	57.00	1.344
0	123	86.00	54.00	1.414
1	103	83.00	51.00	1.259
2	121	84.00	51.00	1.200
3	191	84.00	51.00	1.286
4	180	83.00	50.00	1.183
5	281	82.00	50.00	1.177
6	189	82.00	50.00	1.124
7	268	79.00	48.00	1.043
8	259	78.00	47.00	1.003
9	157	77.00	47.00	1.005
10	227	74.00	46.00	0.857
11	120	71.00	45.00	0.781
12	197	68.00	43.00	0.583
13	137	67.00	43.00	0.583
14	159	60.00	40.00	0.264
15	78	63.00	40.00	0.204
16	139	60.00	40.00	0.113
17	91	54.00	37.00	0.054
18	79	50.00	37.00	0.043
19	50	53.00	37.00	0.005
Prosečna vrednost:		79.40	49.23	1.096

Za potrebe disertacije posmatra se samo grana toplovoda koji iz toplotnog izvora snadbeva stambeno naselje “Nikola Tesla”. Razlog leži u potrebi da se algoritmi kratkoročnog predviđanja pomoću veštačkih neuronskih mreža realizuju na različitim toplotnim izvorima. Na ovaj način se obezbeđuje toplotni izvor koji snadbeva pretežno stambeno naselje i na taj način odgovara potrebama specifične grupe potrošača, odnosno tipu potrošača za stanovanje.

Treba imati u vidu da je reč o prekidnom sistemu grejanja gde se toplotna energija isporučuje potrošačima u periodu od 5 časova ujutru pa do 21 sat. Međutim, ono što otežava upravljanje i adekvatno predviđanje potrebne količine toplotne energije koja treba da se proizvede je da dolazi do prekida isporuke toplotne energije i u toku radnog režima (od 5 č. do 21 č.) u slučajevima kada je spoljna temperatura veća od 12 °C. Takav režim nazivamo tzv. „prelaznim režimom“. Prelazni režimi se uglavnom javljaju na početku i na kraju grejne sezone. Ono što nije dobro kod ovih režim je potreba da više puta dnevno uključujete i isključujete kotlove za grejanje odnosno sam toplotni izvor što povećava troškove eksploatacije ali smanjuje vek trajanja samog toplotnog izvora i opreme koja se nalazi na izvoru.

Za posmatranu grejnu sezonu 2014/2015 postoji 536 sati kada nije vršena isporuka toplotne energije u okviru radnog režima toplotnog izvora. Kako je ukupan broj sati u grejnoj sezoni bio 2737, to se dobija da je za 19.5% potencijalnih radnih sati bilo prekida u isporuci toplotne energije. Takođe, važno je istaći da je 25 radnih dana dolazilo do uključivanja i isključivanja toplotnog izvora sa isporuke toplotne energije u toku grejne sezone. Kako je cela grejna sezona efektivno trajala 160 dana to znači da je 15.6% dana bilo sa uključivanjima i isključivanjima toplotnog izvora sa isporukom toplotne energije.

4.4 Pregled i analiza vremenskih perioda koji se koriste za testiranje predviđanja

Za potrebe disertacije i analize i potvrde kvaliteta i tačnosti predviđanja koriste se periodi od 1, 3 i 7 dana u posmatranim periodima grejnih sezona gde postoje dostupni podaci.

Definisana su po dva različita perioda od 7 dana za svaki TI i to tako da:

- prvi period nema prekida u isporuci toplotne energije tokom dana – kontinuirana isporuka toplotne energije od 5 do 21
- drugi period kada ima prekida u isporuci toplotne energije u toku dana – nema kontinuirane isporuke toplotne energije od 5 do 21

U Tabeli 4.4 dat je uporedni prikaz izabranih perioda za testiranje.

Posebna pažnja treba da se obrati na vrednosti maksimalne i minimalne temperature kada se posmatra II period za testiranje. I to iz razloga nalaženja adekvatnog odgovora za predviđanje toplotnog opterećenja u uslovima prekida isporuke toplotne energije. Kao što se može videti iz Tabele 4.4, minimalna temperatura je dosta niža od granične (12°C) a maksimalna je dosta viša od granične temperature.

Tabela 4-5 Uporedni prikaz perioda za testiranje na toplotnim izvorima

Toplotni izvor	Period za testiranje	Prosečna spoljna temperatura	Minimalna spoljna temperatura	Maksimalna spoljna temperatura	Broj sati prekida
I PERIOD					
Krivi vir	08.- 14.02.2013	3.74	0	8	nema
Konjarnik	01.- 07.12.2013	2	-3	5	nema
Klinički centar Niš	01.- 07.12.2013	3	-3	6	nema
Mašinski fakultet Niš	08.- 14.02.2015	3.74	0	8	nema
II PERIOD					
Krivi vir	18.- 24.03.2013	7.43	1	17	20 sati
Konjarnik	24.- 30.03.2014	12	6	22	28 sati
Klinički centar Niš	24.- 30.03.2014	12	5	23	26 sati
Mašinski fakultet Niš	23.- 29.03.2015	12	6	22	29 sati

Kako se kratkoročno predviđanje realizuje za 1, 3 i 7 dana unapred, to su, respektivno date osnovne karakteristike za 1, 3 i 7 dana izabranih perioda za svaki toplotni izvor. Odgovarajući dijagrami su prikazani na slikama 4.17 – 4.22. Analizom dijagrama mogu se postaviti određene generalizacije:


- I period za TI Krivi vir ima velike pikove na početku svakog dana (5 sati ujutru), približno 25% veći od prosečnih vrednosti i relativno male oscilacije u temperaturi napojne vode tokom perioda. Razlika između maksimalne i minimalne spoljne temperature je 8 stepeni.
- II period za TI Krivi vir ima velike pikove na početku svakog dana ali i više manjih pikova (lokalnih maksimuma) tokom dana. Takođe, postoje periodi u toku dana kada postoji prekid u isporuci toplotne energije. II period za TI Krivi vir ima veće oscilacije u temperaturi napojne vode ali i veće oscilacije u spoljnoj temperaturi. Razlika između maksimalne i minimalne spoljne temperature je 16 stepeni
- I period za TI Konjarnik ima velike pikove na početku svakog dana (5 sati ujutru), ali su oni približno čak i preko 50% veći od prosečnih vrednosti i jako male oscilacije u temperaturi napojne vode tokom perioda (mnogo manje nego TI Krivi vir). Za razliku od TI Krivi vir, postoje i manji pikovi

(lokalni maksimumi) tokom dana. Razlika između maksimalne i minimalne spoljne temperature je 8 stepeni.


- II period za TI Konjarnik ima velike pikove na početku svakog dana ali i više manjih pikova (lokalnih maksimuma) tokom dana. Takođe, postoje periodi u toku dana kada postoji prekid u isporuci toplotne energije. II period za TI Konjarnik nema većih oscilacija u temperaturi napojne vode ali ima veće oscilacije u spoljnoj temperaturi. Razlika između maksimalne i minimalne spoljne temperature je 16 stepeni
- I period za TI Mašinski fakultet ima velike pikove na početku svakog dana (5 sati ujutru), ali su oni približno čak i preko 50% veći od prosečnih vrednosti i jako male oscilacije u temperaturi napojne vode tokom perioda (mnogo manje nego TI Krivi vir). Za razliku od TI Krivi vir, postoje i manji pikovi (lokalni maksimumi) tokom dana. Razlika između maksimalne i minimalne spoljne temperature je 8 stepeni.
- II period za TI Mašinski fakultet ima velike pikove na početku svakog dana ali i više manjih pikova (lokalnih maksimuma) tokom dana. Takođe, postoje periodi u toku dana kada postoji prekid u isporuci toplotne energije. II period za TI Mašinski fakultet nema većih oscilacija u temperaturi napojne vode ali ima veće oscilacije u spoljnoj temperaturi. Razlika između maksimalne i minimalne spoljne temperature je 16 stepeni
- Kao što se može primetiti, razlika u maksimalnoj i minimalnoj temperaturi kod svih posmatranih toplotnih izvora je ista, i iznosi 8 stepeni za I period i 16 stepeni za II period. Logično se nameće jedan od zaključaka da veća razlika u dnevnoj temperaturi ili tokom jednog perioda povećava verovatnoću potrebe za prekidima u isporuci toplotne energije.




Slika 4-17 Osnovne karakteristike I perioda TI Krivivir za 1, 3 i 7 dana predviđanja




Slika 4-18 Osnovne karakteristike II perioda TI Krivivir za 1, 3 i 7 dana predviđanja




Slika 4-19 Osnovne karakteristike I perioda TI Konjarnik za 1, 3 i 7 dana predviđanja



Slika 4-20 Osnovne karakteristike II perioda TI Konjarnik za 1, 3 i 7 dana predviđanja



Slika 4-21 Osnovne karakteristike I perioda TI MF za 1, 3 i 7 dana predviđanja



Slika 4-22 Osnovne karakteristike II perioda TI MF za 1, 3 i 7 dana predviđanja

Pored osnovnih karakteristika posmatranih perioda predviđanja potrebno je sagledati i druge karakteristike i trendove posmatranih sistema daljinskog grejanja i napraviti komparativnu analizu.


To se posebno odnosi na:

- raspon proizvedene toplotne snage u različitim danima pri istoj spoljnoj temperaturi
- raspon spoljnih temperatura kada je proizvedena snaga nula odnosno kada nema isporuke toplotne energije.


Analiza ovih karakteristika i trendova je od izuzetnog značaja za mogućnost kasnije generalizacije projektovanih neuronskih mreža za kratkoročno predviđanje. Upravo ove dve karakteristike presudno utiču na kvalitet obučavanja neuronskih mreža i definišu specifični cilj koji se ogleda u traženju načina da se tako izražena nelinearnost adekvatno obuhvati u procesu obučavanja neuronskih mreža.

Na slici 4-23 i 4-24 predstavljeni su primeri raspona snage i temperatura za TI Krivi vir, respektivno za istu spoljnu temperaturu i nulto toplotno opterećenje. Ovaj toplotni izvor je izabran jer je uporedna analiza pokazala da su kod TI Krivi vir rasponi veći u odnosu na ostale posmatrane toplotne izvore.

Proces učenja i simulacije test perioda u sledećem poglavlju će pokazati da je kvalitet dobijenog predviđanja najslabiji kod ovog toplotnog izvora a kao jedan od ključnih razloga treba razmatrati ovu činjenicu.



Slika 4-23 Raspon toplotne snage u različitim danima pri istoj spoljnoj temperaturi $T_{sp} = -3^{\circ}\text{C}$



Slika 4-24 Raspon spoljnih temperatura kada je toplotno opterećenje nula TI Krivi vir

Analizom gore navedenih karakteristika sistema daljinskog grejanja, sa aspekta kratkoročnog predviđanja, može se zaključiti:

- da je toplotno opterećenje odnosno snaga osnovna karakteristika koja se menja i koja je predmet predviđanja
- da je spoljna temperatura osnovni parametar koji utiče na toplotno opterećenje
- da su mali rasponi promena temperature napojne i povratne vode
- da su velike nelinearnosti prisutne i da se ogledaju kroz velike raspone u toplotnom opterećenju za istu spoljnu temperaturu i kroz prekid isporuke toplotne energije prilikom velikih temperaturnih razlika i da je potrebno uvođenje interventnog indikatora za poboljšanje predviđanja
- da je očitavanje karakteristika časovno i da postoje razlike u očitavanju sa SCADA-e i ručno.

5. VEŠTAČKE NEURONSKE MREŽE ZA KRATKOROČNO PREDVIĐANJE SISTEMA DALJINSKOG GREJANJA

Po statistici, grejanje prostora učestvuje sa 68% u ukupnoj potrošnji energije u kući. Ukupna potrošnja toplotne energije (uključuje grejanje prostora i vode) učestvuje sa 80 % ukupne potrošnje energije u kućama. Upravo je to razlog zašto je fokus na smanjenju i optimizaciji potrošnje toplotne energije u zgradama kako bi se do 2020. godine dostigli postavljeni ciljevi od strane EU. Visoki operativni troškovi za rad i održavanje energetskog objekta čini neophodnim optimizaciju proizvodnje i distribucije energije. Postoji potreba za predviđanjem energetskih potreba i zahteva kako bi se optimizovao proces proizvodnje energije. Predviđanje energije obezbeđuje ocenu budućih energetskih potreba i zahteva. Zahtev za toplotnim opterećenjem varira tokom dana. Predviđanje zahteva za energijom obezbeđuje informaciju o energetskim resursima potrebnim da zadovolje energetske potrebe u bliskoj budućnosti. Pouzdano predviđanje toplotnog opterećenja vodi do ušteda u energiji. To dovodi do sprečavanja toplotnih gubitaka i poboljšava efikasnost jedinice za proizvodnju toplotne energije.

Predviđanje toplotnog opterećenja takođe obezbeđuje informaciju o satima kada je potreba za toplotnom energijom najveća. Takva informacija daje mogućnost isporučiocu energije da bude spreman za one sate kada je potrebno potrošačima isporučiti najviše toplotne energije. Kako bi upravljali vršnim toplotnim opterećenjem mogu postojati tzv. termalna skladišta. Za vreme kada je zahtev za toplotnim opterećenjem nizak, višak proizvedene toplotne energije iz kogenerativnog postrojenja može se skladištiti u termalnom skladištu kao neka vrsta akumulatora toplotne energije. Skladištena toplotna energija se može distribuirati u periodima vršnog zahteva za toplotnim opterećenjem. Ovaj proces optimizuje rad kogenerativnog postrojenja i zadovoljava zahtev za vršnim toplotnim opterećenjem.

Sistem za predviđanje toplotnog opterećenja obezbeđuje informaciju o niskim i visokim potrebama za toplotnim opterećenjem koja omogućava toplotnom postrojenju proizvodnju adekvatne toplotne energije saglasno zahtevu. Ovakav pristup smanjuje višak proizvedene toplotne energije i dovodi do dalje optimizacije toplotnog postrojenja.

Jedan od važnih zadataka je kašnjenje u obezbeđivanju toplotne energije u stambenim i poslovnim zgradama. Proizvodnja i isporuka toplotne energije može trajati nekoliko sati. Zbog toga može doći do situacije da je dovedena toplotna energija nedovoljna ili suvišna, usled brze varijacije spoljne temperature. Ovaj problem takođe može biti rešen preciznim predviđanjem potreba za toplotnim opterećenjem.

Faktore koji utiču na potrošnju toplotne energije i opterećenja se mogu klasifikovati u dve klase: interne i eksterne. Eksterni faktori uključuju spoljnu temperaturu, solarnu radijaciju, brzinu vetra, pravac vetra, itd. Interni faktori se odnose na sam sistem daljinskog grejanja i uključuju pritisak napojne i povratne vode, temperaturu napojne i povratne vode, razliku između ulazne i povratne temperature i protoka. Prisustvo velikog broja faktora čini predviđanje toplotnog opterećenja jako zahtevnim istraživačkim izazovom.

Zato je potrebno identifikovati parametre koji imaju najveći uticaj na predviđanje toplotnog opterećenja. Takođe je važno za istraživanja izvršiti generalizaciju sakupljenih podataka i primeniti kod modela za predviđanje sa ciljem da se sa što manje podataka posebno od samih zgrada i ostalih objekata koji se greju sistemom daljinskog grejanja dobiju zadovoljavajući rezultati. Na taj način se smanjuju troškovi instaliranja odgovarajuće opreme na većem broju zgrada i drugih objekata koje se greju. U ovom radu se upravo zbog toga koriste sakupljeni podaci sa toplotnih izvora čime se smanjuje ukupna cena troškova istraživanja i samog predviđanja, što i jeste jedan od ciljeva samog predviđanja toplotnog opterećenja i drugih karakteristika kod sistema daljinskog grejanja.

5.1. Kratkoročno predviđanje kod sistema daljinskog grejanja

Kako bi se sistemom daljinskog grejanja upravljalo što je moguće efikasnije, neophodno je donositi izvršne odluke u cilju da te odluke obezbede dobro predviđanje potreba za grejanjem za nastupajuću grejnu sezonu. Sa visokim kvalitetom predviđanja potreba za zalihama energenata i rizik od prevelike proizvodnje se smanjuje. Cilj korišćenja veštačkih neuronskih mreža za predviđanje je obezbeđivanje jednostavnog i moćnog alata koji može da obezbedi tačnu prognozu odnosno predviđanje na osnovu postojećih podataka iz proizvodnje bez potrebe za izradom nekog složenijeg modela.

5.2. Opšta postavka problema

Problem koji se nastoji rešiti u ovoj disertaciji se ogleda u sledećem: potrebno je realizovati adekvatno kratkoročno predviđanje za 1, 3 i 7 dana za dva perioda u zimskoj grejnoj sezoni, jedan kada nema prekida u isporuci toplotne energije tokom dana (standardan zimski dan) i drugi kada ima jedan ili više prekida isporuke u toku jednog dana ili više dana u posmatranom periodu koji se predviđa. Ova dva perioda su izdvojena kao karakteristični periodi tokom zimske grejne sezone.

Realizacija predviđanja se ostvaruje preko dva osnovna tipa neuronske mreže: višeslojne feedforward mreže i Elman rekurentne neuronske mreže.

Ova dva tipa neuronske mreže se uzimaju za realizaciju predviđanja kao tipovi neuronskih mreža koji se najčešće koriste za predviđanje i kao neuronske mreže koje su najdostupnije i najviše analizirane. Cilj korišćenja standardnih neuronskih mreža je preusmeravanje fokusa istraživanja i analize na druge karakteristike i parametre neuronskih mreža (a ne na sam tip mreže) od kojih suštinski zavisi kvalitet i tačnost predviđanja.

To se pre svega odnosi na izbor i uticaj ulaznog vektora odnosno ulaznih čvorova u neuronsku mrežu, izbor aktivacione funkcije, optimalne vrednosti težinskih koeficijenata i broja neurona u skrivenom sloju. Upravo, analiza koja je data u 3. poglavlju pokazuje da su ovi parametri od uticaja za kvalitet i tačnost predviđanja.

Analizirajući predložena rešenja za ulazne vektore, imajući u vidu raspoloživost podataka i vodeći računa da ne dođe do overfitinga, ove mreže su primenjene na tri različita ulazna vektora:

- Prvi ulazni vektor ima tri ulaza: vreme (h), toplotna snaga za prethodni dan, spoljna temperatura za dan koji se predviđa (U1)
- Drugi ulazni vektor ima 6 ulaza: vreme (h), toplotna snaga za prethodna tri dana, spoljna temperatura za prethodni i dan koji se predviđa (U2)
- Treći ulazni vektor ima 10 ulaza: vreme (h), toplotna snaga za prethodnih pet dana, spoljna temperatura za prethodna 3 dana i dan koji se predviđa (U3)

Pri tome treba imati u vidu da se cela analiza ulaznog vektora svodi na dve izdvojene pretpostavke:

- Spoljna temperatura je najuticajniji parametar vremena potreban za kvalitetno predviđanje, ostali vremenski uticaju su malo uticajni (vetar, vlažnost,..)
- Ne uzima se u obzir socijalna komponenta kao ulazni parametar. Ona je nelinearna, zavisi od ponašanja potrošača i pokušava se upravo uhvatiti ta nelinearnost pravilnim odabirom ulaznog vektora i obuhvatanjem nelinearnih odnosa između temperature i toplotne snage


U literaturi postoji niz primera gde se može videti da je upravo spoljna temperatura najvažniji faktor od koga zavisi toplotno opterećenje kod sistema daljinskog grejanja.

Da bi se realizovale izabrane neuronske mreže potrebno je izvršiti preuređenje skupova ulaznih podataka za sva četiri toplotna izvora. Potrebno je sirove podatke preuzete sa SCADA sistema, očistiti ih od grešaka, skratiti ih na časovni period očitavanja, proveriti i eliminisati neregularnosti u skupovima koji mogu da utiču na kvalitet predviđanja.

Važno je napomenuti da po ugledu na neka prethodna istraživanja, predstavljena u poglavlju 3., se odlučilo da se ne radi normalizacija postojećih podataka odnosno njihovo svođenje na opseg [0,1].

Mreže se realizuju za dva perioda vremena koji su izabrani:

- Prvi, gde nema prekida u isporuci toplotne energije u toku dana i u celom posmatranom periodu od 7 dana za predviđanje
- Drugi, gde ima prekida u isporuci toplotnom energijom u toku dana, tzv. prelazni režimi



Slika 5-1 Koncept ANN modela za predviđanje 1,3 i 7 dana unapred

Nakon realizacije gore navedenih neuronskih mreža sa tri ulazna vektora pristupa se sagledavanju i analizi kvaliteta predviđanja. To se postiže uporednom analizom meri performansi i prosečne greške predviđanja. Posebno se izdvajaju i upoređuju rezultati u pikovima za drugi posmatrani period za predviđanje.

Na ovaj način se realizuje 36 neuronskih mreža za svaki period koji se predviđa.

Uporedna analiza dobijenog predviđanja pokazuje da su velike vrednosti greške u drugom izabranom periodu posebno kada su pikovi i da je jako izražena nestacionarnost.

Da bi se popravilo predviđanje u prelaznim režimima pristupa se sledećem:

- Uvodi se algoritam PSO za optimizaciju težinskih koeficijenata kako bi se dobile optimalne vrednosti koeficijenata
- Uvodi se algoritam GA za optimizaciju broja neurona u skrivenom sloju
- Uvodi se nova ulazna promenljiva i na taj način proširuje ulazni vektor. Nova ulazna promenljiva je minimalna dnevna temperatura T_{spmin} . Cilj uvođenja ove ulazne promenljive ima za cilj da uhvati na bolji način trend pikova u prelaznim režimima grejanja.

Na taj način se formiraju nove modifikovane i poboljšane neuronske mreže i vrši se njihova realizacija na datim skupovima podataka datih toplotnih izvora za dva odabrana perioda predviđanja. Dobija se novih 36 neuronskih mreža za svaki odabrani period. Vršiti se njihova uporedna analiza.

Pri tome, treba imati u vidu da uvođenje nove ulazne promenljive dovodi do promene dimenzija ulaznih vektora:

- UM1 – modifikovani ulazni vektor U1 sa 4 ulaznih promenljivih
- UM2 – modifikovani ulazni vektor U2 sa 7 ulaznih promenljivih
- UM3 – modifikovani ulazni vektor U3 sa 11 ulaznih promenljivih

Zbog toga je potrebno prilagoditi i skupove podataka za obučavanje mreža.

Nakon toga, definisane veštačke neuronske mreže se koriste za predviđanje drugih karakteristika sistema daljinskog grejanja: temperature napojne vode i temperature povratne vode. Sada se ne vrši modifikacija mreža već se postojeće mreže koriste za kratkoročno predviđanje gore navedenih temperatura.

Na taj način se doprinosi opštosti postupka kratkoročnog predviđanja i kreiranja smernica i algoritma preporuka koji može biti univerzalan kada je u pitanju ovaj konkretan skup srodnih problema.

5.3. Primenjene veštačke neuronske mreže

5.3.1 Feedforward neuronska mreža

Prva primenjena veštačka neuronska mreža je višeslojna feedforward neuronska mreža sa 1 skrivenim slojem.

Skriveni sloj ima 20 neurona. Do ovog početnog broja neurona u skrivenom sloju se došlo korišćenjem preporuka datih u trećem poglavlju disertacije, pri čemu se uzima u obzir da je ulazni vektor sa najviše 10 ulaza. Tada se može primeniti preporuka da je broj neurona u skrivenom sloju jednak $2n$, gde je n broj neurona na ulazu.

Što se tiče broja skrivenih slojeva, odlučeno je da mreža ima 1 skriveni sloj nakon komparacije sa mrežom sa dva skrivena sloja. Mreža sa dva skrivena sloja je davala bolje rezultate po pitanju mera performansi ali je brzina bila mnogo manja pa bi i kvalitet predviđanja bio lošiji.


Broj skrivenih slojeva: 1

Broj neurona u skrivenom sloju: 20

U drugom delu ovog poglavlja za potrebe nalaženja optimalnog broja neurona u skrivenom sloju koriste se genetski algoritmi i kao krajnji broj neurona u skrivenom sloju predložen je broj 22.

Aktivacione funkcije su hiperboličke tangensne sigmoidne funkcije (tansig) u oba sloja, skrivenom i izlaznom.

Ovde treba imati u vidu da se do ove aktivacione funkcije došlo komparativnom analizom svih kombinacija koje se mogu napraviti kada se posmatraju osnovne aktivacione funkcije koje su opisane u prethodnim poglavljima. (logsig, tanh, purelin). Menjanjem aktivacione funkcije u slojevima došlo se do zaključka da kada je u pitanju brzina konvergencije i pre svega mera performansi (korišćena MSE) najbolje rezultate pokazuje kombinacija (tansig, tansig) za skriveni i izlazni sloj.



Slika 5-2 Feedforward neuronska mreža sa 1 skrivenim slojem koja se koristi za predviđanje 1,3 i 7 dana unapred

Izabrana feedforward neuronska mreža ima karakteristike obučavanja za svaki izabrani ulazni vektor date na slikama 5-4 do 5-9, Ulazni vektor 1, Ulazni vektor 2 i Ulazni vektor 3, respektivno. Formirani su posebni skupovi podataka za obučavanje u zavisnosti od tipa ulaznog vektora. U Tabeli 5-1 dati su podaci o obimu i strukturi podataka za obučavanje.

Tabela 5-1 Pregled obima i strukture neuronske mreže za obučavanje

Tip mreže	Veličina uzorka	Normalizacija podataka	Broj ulaza	Algoritam učenja	Broj skrivenih slojeva	Broj neurona u skrivenom sloju	Aktivaciona funkcija	Mera performansi
FF ANN Krivi vir	2533	Nema	3,6,10	LMA	1	20	tanh;tanh	MSE
FF ANN Konjanrik	2669	Nema	3,6,10	LMA	1	20	tanh;tanh	MSE
FF ANN Mašinski	2839	Nema	3,6,10	LMA	1	20	tanh;tanh	MSE

Preporučeni algoritam za obučavanje je Levenberg-Marqdt-ov algoritam koji je dovoljno brz i pouzdan za učenje. Ovaj algoritam je detaljnije opisan u 2. Poglavlju.

Obučavanje je vršeno redom na skupovima podataka za Konjanrik, Mašinski fakultet i Krivi vir. U Tabeli 5-2 su prikazane vrednosti izabrane mere performansi (MSE) za ova tri toplotna izvora i za različite ulazne vektore.


Tabela 5-2 Pregled vrednosti MSE za različite ulazne vektore

Toplotni izvor	Ulazni vektor	Mera performansi (MSE)
Konjarnik	U1 (3 ulaza)	0,585
Konjarnik	U2 (6 ulaza)	0,234
Konjarnik	U3 (10 ulaza)	0,239
Mašinski fakultet	U1 (3 ulaza)	0,496
Mašinski fakultet	U2 (6 ulaza)	0,235
Mašinski fakultet	U3 (10 ulaza)	0,188
Krivi vir	U1 (3 ulaza)	38,235
Krivi vir	U2 (6 ulaza)	36,652
Krivi vir	U3 (10 ulaza)	35,855


Kao što se može videti iz priložene tabele mera performansi je jako zadovoljavajuća kod TI Konjarnik i TI MF, dok je najslabija kod TI Krivi vir. Više je razloga slabijih rezultata obučavanja mreže za podatke sa TI Krivi vir. Ovde su navedeni sledeći:

- Čitanje sirovih podataka je iz kotlovske knjige (operater očitava i unosi podatke na svakih sat vremena u kotlovsku knjigu)
- Najviše šumova, nepreciznih podataka i nedostajućih podataka je bilo upravo za skup podataka sa TI Krivi vir
- Najveće razlike u proizvedenoj snazi u odnosu na spoljnu temperaturu su kod TI Krivi vir
- Najviše intervencija na prilagođavanju sirovih podataka je bilo za TI Krivi vir

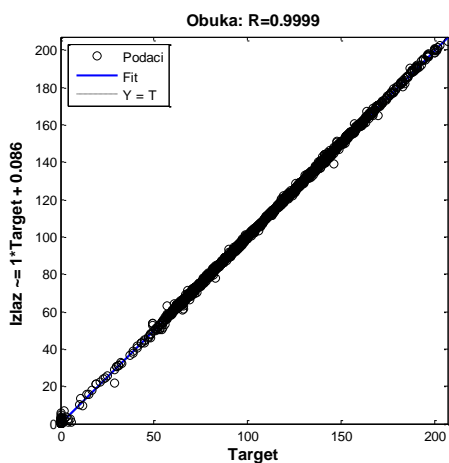
Iz gore navedenog se može zaključiti da kvalitet sirovih podataka, procenat šumova, nedostajućih podataka jako utiče na kvalitet obučavanja neuronske mreže.




Slika 5-3 Mera performansi FF ANN za TI Konjarnik – Ulaz 1




Slika 5-4 Karakteristike obučavanja FF TI Konjarnik Ulaz 1



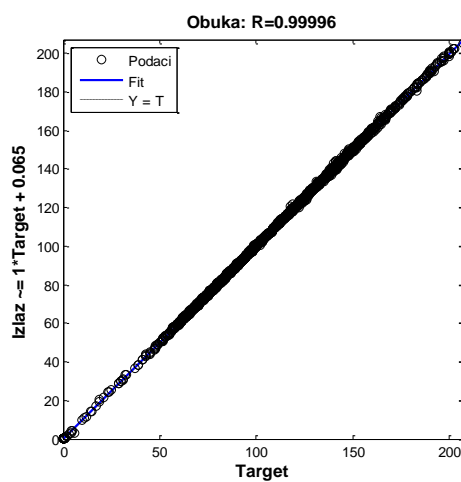
Slika 5-5 Stanje izlaza kod učenja mreže FF TI Konjarnik Ulaz 1



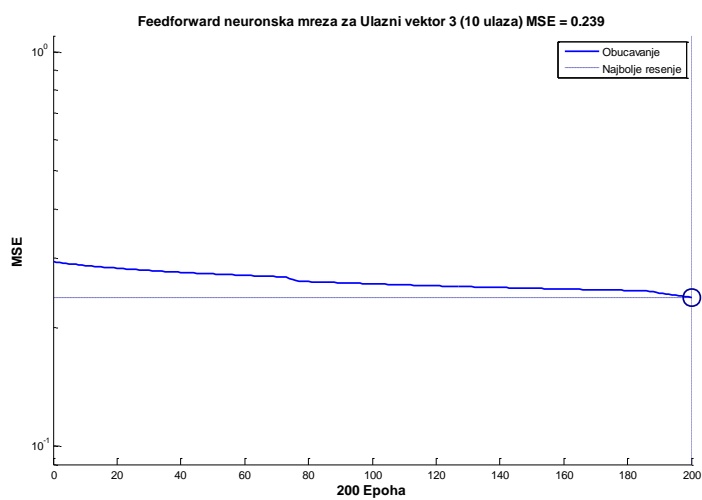
Slika 5-6 Mera performansi FF ANN za TI Konjarnik – Ulaz 2




Slika 5-7 Karakteristike obučavanja FF TI Konjarnik Ulaz 2




Slika 5-8 Stanje izlaza kod učenja mreže FF TI Konjarnik Ulaz 2




Slika 5-9 Mera performansi FF ANN za TI Konjarnik – Ulaz 3




Slika 5-10 Karakteristike obučavanja FF TI Konjarnik Ulaz 3



Slika 5-11 Stanje izlaza kod učenja mreže FF TI Konjarnik Ulaz 3



Slika 5-12 Mera performansi FF ANN za TI Krivi vir – Ulaz 3



Slika 5-13 Mera performansi FF ANN za TI Mašinski fakultet – Ulaz 3

5.3.2 Elman rekurentna neuronska mreža

Predložena Elman rekurentna neuronska mreža ima jedan skriven sloj i povratni kontekst sloj. Aktivacione funkcije za skriveni i izlazni sloj su hiperbolički tangens. Zadržan je isti algoritam učenja kao kod feedforward neuronskih mreža LMA. U skrivenom sloju je nakon više iteracija ustanovljeno 20 neurona.

Na slici je prikazana arhitektura Elman rekurentne neuronske mreže za slučaj kada na ulazu imamo vektor sa 10 ulaza. Kao što je već rečeno, pored ovog izabranog slučaja, imamo slučaj sa 3 i 6 ulaza.

Skriveni sloj ima 20 neurona. Do ovog početnog broja neurona u skrivenom sloju se došlo korišćenjem preporuka datih u trećem poglavlju disertacije, pri čemu se uzima u obzir da je ulazni vektor sa najviše 10 ulaza. Tada se može primeniti preporuka da je broj neurona u skrivenom sloju jednak $2n$, gde je n broj neurona na ulazu.


Što se tiče broja skrivenih slojeva, odlučeno je da mreža ima 1 skriveni sloj nakon komparacije sa mrežom sa dva skrivena sloja, kao i uslučaju feedforward neuronske mreže.

Broj skrivenih slojeva: 1


Broj neurona u skrivenom sloju: 20

U drugom delu ovog poglavlja za potrebe nalaženja optimalnog broja neurona u skrivenom sloju koriste se genetski algoritmi i kao krajnji broj neurona u skrivenom sloju predložen je broj 22.


Aktivacione funkcije su hiperbolički tangensi u oba sloja, skrivenom i izlaznom, kao što je i u slučaju feedforward neuronske mreže.



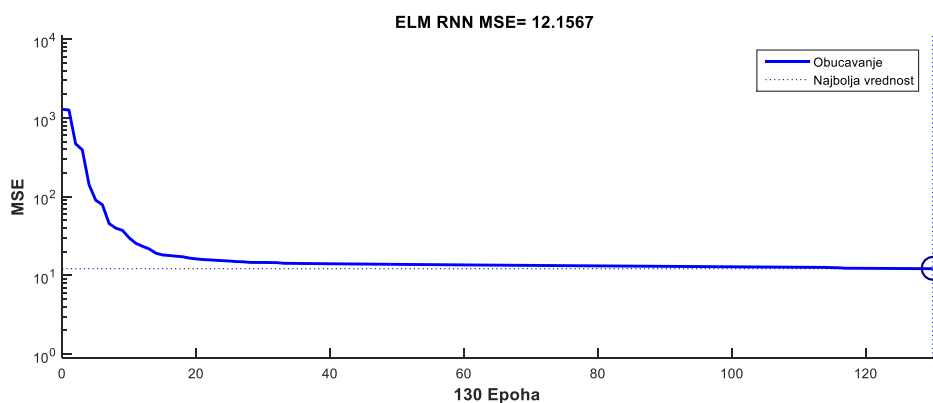
Slika 5-14 Elman rekurentna mreža sa 10 ulaza



Slika 5-15 Mera performansi ELM RNN za TI Konjarnik – Ulaz 3



Slika 5-16 Karakteristike obučavanja FF TI Konjarnik Ulaz 3



Slika 5-17 Mera performansi ELM RNN za TI Krivi vir – Ulaz 3

5.3.3 Modifikovane neuronske mreže

Kao što je već rečeno, nakon analize rezultata simulacija dobijenih standardnim neuronskim mrežama opisanim u poglavljima 5.3.1 i 5.3.2 pristupa se korigovanju neuronskih mreža kako bi se popravili rezultati predviđanja.

Kako se teži generalizaciji predloženih algoritama neuronskih mreža potrebno je modifikacijom postojećih primenjenih standardnih neuronskih mreža ispuniti sledeća 3 cilja:

- poboljšati kvalitet obučavanja neuronskih mreža za skup podataka TI Krivi vir koji su bili sa najlošijim performansama (MSE)
- smanjiti grešku predviđanja kod perioda II
- smanjiti grešku predviđanja u danima gde postoje pikovi u toplotnoj snazi odnosno u prelaznim režimima gde se prekida isporuka toplotne energije tokom dana

Modifikovane FF ANN i ELM RNN imaju sledeće karakteristike:

- optimizovani broj neurona u skrivenom sloju primenom GA (Poglavlje 2.8.3) gde se kao optimalni broj dobija $n_h=22$ za minimalnu MSE
- optimizovane težinske koeficijente dobijene primenom PSO algoritma (Poglavlje 2.8.2) sa konkretnim parametrima datim u Tabeli 5.1
- i najvažnije, uvođenje nove ulazne promenljive T_{spmin} – minimalne dnevne temperature kao interventnog indikatora kako bi se uhvatila velika odstupanja u spoljnoj temperaturi koja za posledicu imaju “prelazni režim” grejanja

GA algoritam (Poglavlje 2.8.4) se primenjuje za izbor optimalnog broja neurona u skrivenom sloju. Inicijalna vrednost je 20, po preporukama i realizaciji koja je već urađena a funkcija cilja je MSE kao mera performansi neuronske mreže koja određuje kvalitet učenja dok je opseg broja neurona od n_{min} do $2n_{max}+1$. (4 – 24). Kao optimalan broj neurona u skrivenom sloju određen je broj 22.

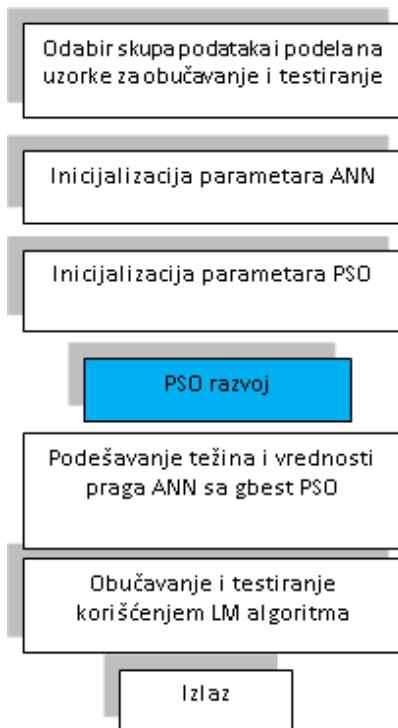
Tabela 5-3 Osnovni parametri PSO optimizacije težinskih koeficijenata FF ANN

Osnovni parametri	Vrednosti
Ulazni vektor	11,7,4
Toplotna snaga za prethodnih 5,3,1 dan	
Spoljna temperatura za prethodna 3,1 dan	
Spoljna temperatura za dan predviđanja	
Minimalna spoljna temperatura za dan predviđanja	
Sati	
Broj skrivenih neurona	20
Broj epoha u ANN	200
Početna vrednost težine	0.9
Konačna vrednost težine	0.4
akceleracioni koeficijent c_1	2
akceleracioni koeficijent c_2	1.9
fitness funkcija	MSE

PSO algoritam je primenjen za optimizaciju težinskih koeficijenata gde je kao mera performansi i fitness funkcija cilja uzeta MSE. Cilj optimizacije težinskih koeficijenata sa PSO je dostizanje višeg nivoa obučavanja odnosno smanjenje MSE kao mere performansi kod učenja mreže. Principijelno isti algoritam PSO se primenjuje i kod FF ANN i kod ELM RNN.

Problem predstavlja činjenica što imamo više skupova podataka i što se optimizacija težinskih koeficijenata vrši za tri nova ulazna vektora (UM1, UM2, UM3) sa 4,7,11 ulaznih neurona.

Maksimalan broj težinskih koeficijenata koji se optimizuje je $(11+1)*22+(22+1)*1=507$ paramatera za PSO, za UM3. Na sledećim slikama 5.18 i 5.19 su prikazani algoritmi PSO za optimizaciju težinskih koeficijenata.

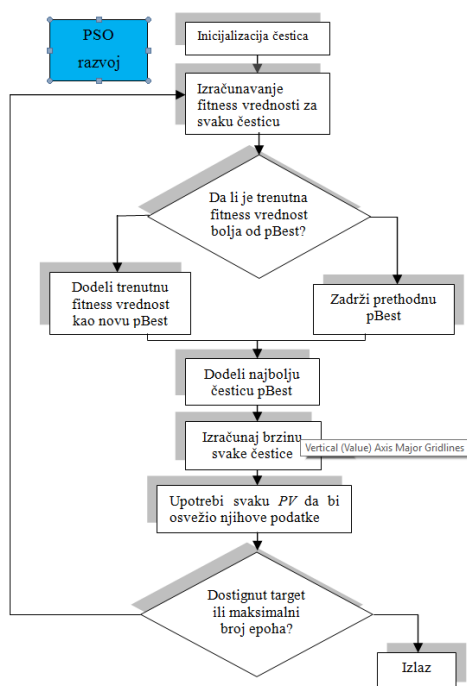


Slika 5-18 Primenjeni algoritam za optimizaciju težinskih koeficijenata

Metoda optimizacije PSO je poslužila za nalaženje globalnog minimuma pa bi to trebalo da doprinese boljoj meri performanse posebno za TI Krivi vir.

Cilj korišćenja GA i PSO metoda kod modifikovanih neuronskih mreža je da se poboljšaju performanse učenja neuronske mreže.

Broj neurona u skrivenom sloju i vrednosti težinskih koeficijenata neuronske mreže su u skladu sa preporukama iz Poglavlja 3. uticajni parametri za kvalitet i grešku predviđanja. To je i osnovni razlog zašto se kod modifikacije neuronskih mreža pristupa korekciji tih parametara.



Slika 5-19 Primenjeni PSO razvojni ciklus

Međutim, sigurno najvažniji deo modifikacije je uvođenje dodatne ulazne promenljive, koja dovodi do povećanja dimenzija ulaznih vektora za jedan. Ova nova ulazna promenljiva se može posmatrati i kao neka vrsta interventnog indikatora koja treba da usaglasi određene nepravilnosti koje smetaju dobrom obučavanju mreže a koje su predstavljene u 4. poglavlju. To se pre svega odnosi na:

- velike dnevne temperaturne razlike koje dovode prekida isporuke toplotne energije jednom ili više puta tokom istog dana (izabrani periodi II)
- velike razlike u toplotnom opterećenju odnosno toplotnoj snazi za istu spoljnu temperaturu u različitim danima (posebno se odnosi na TI Krivi vir gde je to najizraženije)

Uvođenje minimalne spoljne dnevne temperature kao nove ulazne promenljive upravo ima za cilj da adekvatnije obuhvati nelinearnosti koje slede iz gore navedenih specifičnih karakteristika i da bi se na taj način ostvarila bolja generalizacija.


Tako modifikovana feedforward i rekurentna neuronska mreža se obučavaju novim skupom podataka (koji ima za po jedan veću dimenziju ulaznih vektora) i dobijaju se mnogo bolje karakteristike učenja.

Na slikama 5-20 do 5-25 prikazane su karakteristike učenja za modifikovani ulazni vektor 3 sa 11 ulaznih promenljivih koji pokazuje mnogo bolje rezultate što će se pokazati i prilikom simulacija ulaznim vektorima za period II za TI Krivi vir.


Mera performansi za TI Krivi vir nije i dalje na zadovoljavajućem nivou u poređenju sa ostalim toplotnim izvorima te se uvodi nova modifikacija:

- saglasno preporukama i analizi koja je data u polavlju 3. povećava se broj skrivenih slojeva sa 1 na 2 a broj neurona u skrivenim slojevima se zadržava na nivou dobijenim porešavanjem GA (22 za 1. skriveni sloj i 22 za 2. skriveni sloj).


Tako dobijena modifikovana neuronska mreža koja sada ima veći broj neurona i veći broj težinskih koeficijenata se nakon optimizacije težinskih koeficijenata na isti način kao i prethodne mreže realizuje nad podacima za TI Krivi vir i dobija relativno zadovoljavajuća mera performansi MSE.




5-20 Mera performansi za modifikovanu FF ANN TI Krivi vir za ulaz UM1



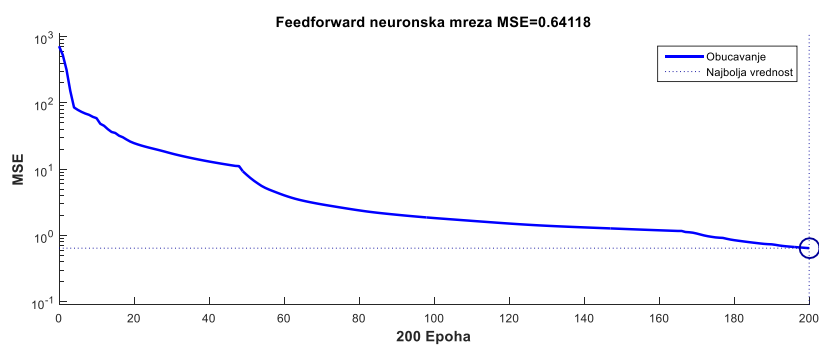
5-21 Karakteristike obučavanja TI Krivi vir UM3




5-22 Obuka TI Krivi vir UM3



Slika 5-23 Mera performansi za modifikovanu FF ANN TI Krivi vir za ulaz UM3



Slika 5-24 Mera performansi za modifikovanu FF ANN (2 skrivena sloja) TI Krivi vir za ulaz UM3



Slika 5-25 Mera performansi za modifikovanu ELM ANN TI Krivi vir za ulaz UM3

Kako bi se izvršila kontrola dobijenih rezultata obučavanja projektovanih neuronskih mreža i na taj način potvrdila ispravnost modifikacije ali i mogućnost generalizacije samog postupka primene ovih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja, dobijene neuronske mreže su realizovane nad skupom podataka za TI Klinički centar.

Rezultati mera performansi su prikazani u Tabeli 5-4.

Tabela 5-4 Pregled mera performansi za TI KC Niš

Toplotni izvor	Ulazni vektor	Mera performansi (MSE)
FF ANN KC Niš	U1 (3 ulaza)	0,685
FF ANN KC Niš	U2 (6 ulaza)	0,434
FF ANN KC Niš	U3 (10 ulaza)	0,339
ELM RNN KC Niš	U1 (3 ulaza)	0,596
ELM RNN KC Niš	U2 (6 ulaza)	0,422
ELM RNN KC Niš	U3 (10 ulaza)	0,232
Modifikovana FF ANN KC Niš	UM1 (4 ulaza)	0,234
Modifikovana FF ANN KC Niš	UM2 (7 ulaza)	0,182
Modifikovana FF ANN KC Niš	UM3 (11 ulaza)	0,166
Modifikovana ELM RNN KC Niš	UM1 (4 ulaza)	0,443
Modifikovana ELM RNN KC Niš	UM2 (7 ulaza)	0,222
Modifikovana ELM RNN KC Niš	UM3 (11 ulaza)	0,122

Dobijeni rezultati pokazuju dobar kvalitet obučavanja za potrebe kratkoročnog predviđanja sistema daljinskog grejanja. To govori o tome da su mreže dobro obučene i da mogu da se koriste za simulacije kratkoročnog predviđanja za 1, 3 i 7 dana za posmatrane periode.

5.3.3 Pregled dobijenih simulacionih rezultata

5.3.3.1 Standardne neuronske mreže – feedforward i rekurentne

Ovde je dat jedan deo simulacionih rezultata. Kao što je već više puta rečeno, testiranje se realizuje na dva perioda predviđanja za svaki toplotni izvor, period I i period II kako je objašnjeno u 4. poglavlju.

Za svaki period predviđanja i svaki ulazni vektor formiraju se ulazni test vektori i vrši simulacija na obučenim i naučenim neuronskim mrežama.

Za period I se dobijaju rezultati simulacija sa sledećim karakteristikama:

za FF ANN:

- prosečna greška predviđanja je jako zadovoljavajuća za TI Konjarnik i TI Mašinski fakultet – nisu potrebne bilo kakve posebne korekcije
- prosečna greška predviđanja za TI Krivi vir je ~7% što je dobar rezultat ali je cilj spustiti grešku predviđanja u raspon 3-5%
- brzina obučavanja nije velika ali to ne proizvodi negativne posledice po ciljeve predviđanja

za ELM RNN:

- prosečna greška predviđanja je jako zadovoljavajuća za TI Konjarnik i TI Mašinski fakultet – nisu potrebne bilo kakve posebne korekcije
- prosečna greška predviđanja za TI Krivi vir je ~5% što je dobar rezultat
- brzina obučavanja je velika

Za period II se dobijaju rezultati simulacija sa sledećim karakteristikama:

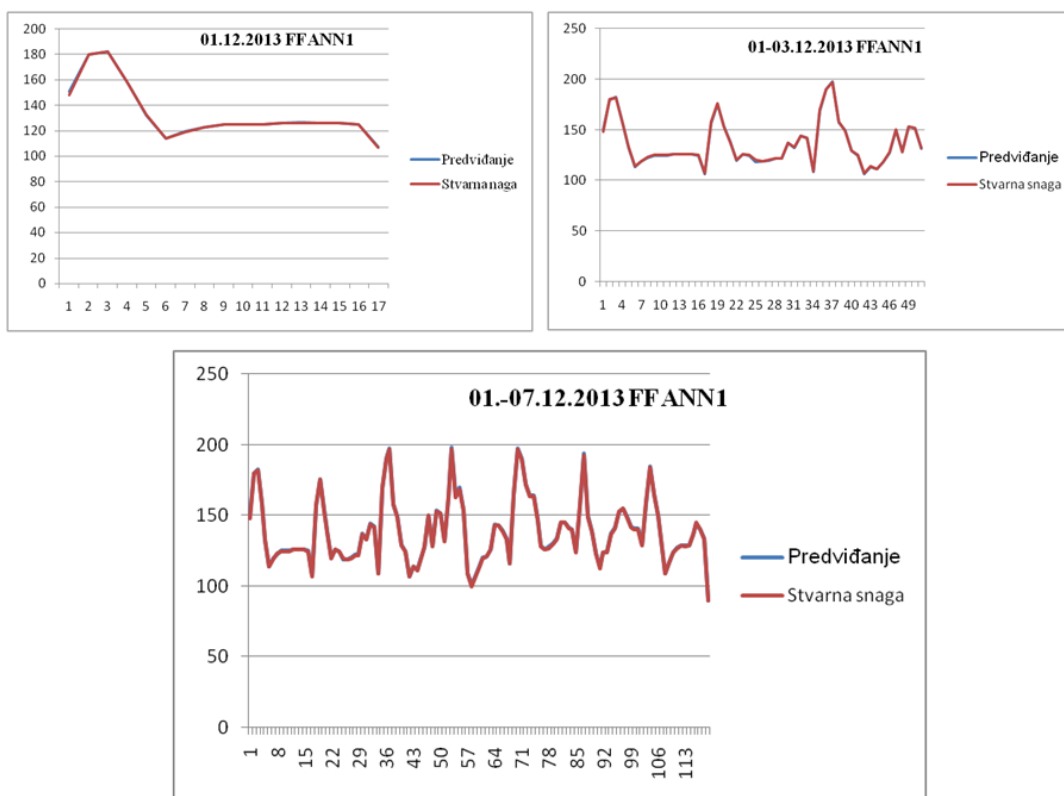
za FF ANN:

- prosečna greška predviđanja je zadovoljavajuća za TI Konjarnik i TI Mašinski fakultet – veća nego u periodu I
- prosečna greška predviđanja za TI Krivi vir je ~10% što nije zadovoljavajuće jer je cilj spustiti grešku predviđanja u raspon 3-5%
- velike su greške predviđanja za pikove u toku dana gde se prekida isporuka toplotne energije i cilj je smanjiti grešku predviđanja za pikove


- brzina obučavanja nije velika ali to ne proizvodi negativne posledice po ciljeve predviđanja

za ELM RNN:


- prosečna greška predviđanja zadovoljavajuća za TI Konjarnik i TI Mašinski fakultet – veća nego u periodu I
- prosečna greška predviđanja za TI Krivi vir je ~9% što nije zadovoljavajuće
- velike su greške predviđanja za pikove u toku dana gde se prekida isporuka toplotne energije i cilj je smanjiti grešku predviđanja za pikove
- brzina obučavanja je velika




Slika 5-26 Simulacija TI Konjarnik za predviđanje 1, 3 i 7 dana unapred FF ANN - Ulaz 1 - Period I [MW]




Slika 5-27 Simulacija TI Konjarnik za predviđanje 1, 3 i 7 dana unapred FF ANN - Ulaz 2 - Period I [MW]




Slika 5-28 Simulacija TI Konjarnik za predviđanje 1, 3 i 7 dana unapred FF ANN - Ulaz 3 - Period I [MW]




Slika 5-29 Simulacija TI Konjarnik za predviđanje 3 dana unapred FF ANN - Ulaz 2 - Period II [MW]




Slika 5-30 Simulacija TI Konjarnik za predviđanje 7 dana unapred FF ANN - Ulaz 3 - Period II [MW]




Slika 5-31 Simulacija TI Mašinski fakultet za predviđanje 1 dan unapred FF ANN - Ulaz 3 - Period II [MW]



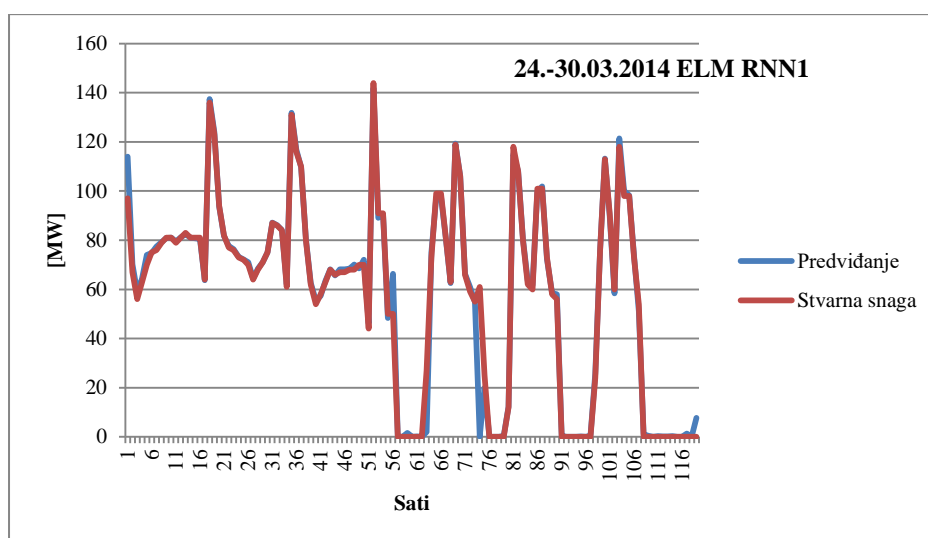
Slika 5-32 Simulacija TI Mašinski fakultet za predviđanje 7 dana unapred FF ANN - Ulaz 3 - Period II [MW]



Slika 5-33 Simulacija TI Konjarnik za predviđanje 1 dan unapred ELM RNN - Ulaz 1 - Period II [MW]



Slika 5-34 Simulacija TI Konjarnik za predviđanje 3 dana unapred ELM RNN - Ulaz 1 - Period II [MW]



Slika 5-35 Simulacija TI Konjarnik za predviđanje 7 dana unapred ELM RNN - Ulaz 1 - Period II [MW]


5.3.3.2 Modifikovane neuronske mreže – feedforward i rekurentne

Kako je ustanovljeno u prethodnom poglavlju, najveći nedostatak i greška predviđanja je upravo za period II gde se nalaze dani kada dolazi do prekida isporuke toplotne energije odnosno kada sistem daljinskog grejanja radi u tzv. prelaznom režimu.


Zato se projektuju i implemintiraju modifikovane neuronske mreže sa tri nivo poboljšanja kako je to objašnjeno u prethodnim poglavljima (optimizovanje težinskih koeficijenata, optimizovanje broja neurona u skrivenom sloju i uvođenje dodatnog ulaza).

Cilj modifikovanih neuronskih mreža je upravo smanjivanje greške predviđanja kod velikih pikova koji se javljaju kod toplotnog opterećenja kada se obustavlja i ponovo uspostavlja isporuka toplotne energije.


Nakon testiranja modifikovanih neuronskih mreža za kritične dane, simulacioni rezultati su predstavljeni na slikama 5-36, 5-37, 5-38 i 5-39.




Slika 5-36 Simulacija TI Mašinski fakultet za predviđanje 1 dan unapred - Ulaz 3 - Period II - Modifikovana FF ANN [MW]



Slika 5-37 Simulacija TI Mašinski fakultet za predviđanje 7 dan unapred - Ulaz 3 - Period II - Modifikovana FF ANN [MW]




Slika 5-38 Simulacija TI Krivi vir za predviđanje 7 dana unapred - Ulaz 1 - Period II - Modifikovana ELM RNN [MW]




Slika 5-39 Simulacija TI Konjarnik za predviđanje 1 dan unapred - Ulaz 1 - Period II - Modifikovana ELM RNN

Posebno treba imati u vidu da ovako realizovane neuronske mreže mogu da se iskoriste za predviđanje i analizu drugih karakteristika sistema daljinskog grejanja opisanih u prethodnim poglavljima. To se pre svega odnosi na temperaturu napojne i temperaturu povratne vode. Zato su i primenjene dobijene neuronske mreže na predviđanje temperature napojne i temperaturu povratne vode.




Slika 5-40 Simulacija TI Konjarnik FF ANN – predviđanje temperature napojne vode 7 dana unapred

Činjenica da je raspon temperatura napojne i povratne vode mali i da je temperatura relativno ujednačena tokom procesa grejanja, dovodi do toga je prosečna greška predviđanja jako dobra kao što se vidi na simulacijama. (Slika 5-40 i 5-41)



Slika 5-41 Simulacija TI Konjarnik FF ANN – predviđanje temperature povratne vode 7 dana unapred

Na identičan način, moguće je primeniti projektovane neuronske mreže za kratkoročno predviđanje potrošnje toplotne energije i takvo predviđanje je prikazano na primeru TI Mašinski fakultet. (Slika 5-42)



Slika 5-42 Simulacija TI MF FF ANN – predviđanje potrošnje toplotne energije 7 dana unapred

Dobijeni rezultati su jako zadovoljavajući, što dovodi do zaključka da postoji mogućnost izvesne generalizacije kada su u pitanju standardne neuronske mreže i njihova primena na kratkoročno predviđanje različitih karakteristika sistema daljinskog grejanja.

6. KOMPARATIVNA ANALIZA PREDLOŽENIH MREŽA ZA PREDVIĐANJE

U ovom poglavlju je izvršena komparativna analiza dobijenih simulacionih rezultata i uspostavljen algoritam za predložene neuronske mreže.

Pažnja je posvećena uspostavljanju opštijih procedura i algoritama i izbora parametara kako bi se podigao nivo generalizacije za kratkoročno predviđanje kod sistema daljinskog grejanja kao izabranog specifičnog problema.

Poseban osvrt je dat uporednoj analizi između rezultata predviđanja dobijenih sa prva tri ulazna vektora i nakon uvođenja nove ulazne promenljive radi poboljšanja karakteristika u prelaznim režimima grejanja.

Tabela 6-1 Uporedni pregled prosečne greške predviđanja za TI Krivi vir

TI Krivi vir						
Tip ulaznog vektora	FF ANN			ELMAN		
I period predviđanja						
Ulazni vektor 1	8.254	11.294	12.281	8.244	9.315	9.295
Ulazni vektor 2	8.165	9.286	9.278	8.24	9.280	9.217
Ulazni vektor 3	8.252	9.234	9.166	8.232	8.772	9.107
II period predviđanja						
Ulazni vektor 1	9.540	10.344	10.891	9.72	9.98	.87
Ulazni vektor 2	9.429	9.679	10.891	9.22	9.911	10.45
Ulazni vektor 3	9.618	10.478	10.962	9.02	9.725	10.206

Tabela 6-2 Uporedni pregled prosečne greške predviđanja za TI Konjarnik

TI Konjarnik						
Tip ulaznog vektora	FF ANN			ELMAN		
I period predviđanja						
Ulazni vektor 1	.254	.294	.281	.244	.315	.295
Ulazni vektor 2	.25	.286	.278	.24	.280	.287
Ulazni vektor 3	.252	.284	.276	.232	.272	.277
II period predviđanja						
Ulazni vektor 1	.550	.474	.891	.72	.98	.87
Ulazni vektor 2	.529	.439	.891	.1	.01	.35
Ulazni vektor 3	.618	.478	.962	.02	.725	.206

Tabela 6-3 Usporedni pregled prosečne greške predviđanja za TI Mašinski fakultet

TI Mašinski fakultet						
Tip ulaznog vektora	FF ANN			ELMAN		
I period predviđanja						
Ulazni vektor 1	.254	.294	.281	.244	.315	.295
Ulazni vektor 2	.25	.286	.278	.24	.280	.287
Ulazni vektor 3	.252	.284	.276	.232	.272	.277
II period predviđanja						
Ulazni vektor 1	.589	.489	.998	.82	.92	.87
Ulazni vektor 2	.560	.445	.998	.15	.2	.45
Ulazni vektor 3	.626	.487	1.042	.05	.715	.215

Iz tabelarne analize treba istaći sledeće:

- Veći deo dobijenih rezultata je adekvatan sa aspekta prihvatljivosti prosečne greške predviđanja osim TI Krivi vir
- Najveće greške predviđanja su za Ulazni vektor 1
- Najbolji rezultati predviđanja su dobijeni za Ulazni vektor 3
- Prosečne greške predviđanja za prvi posmatrani period su niže u odnosu na drugi period predviđanja
- Prosečne greške predviđanja su ujednačenije za prvi posmatrani period predviđanja
- Prosečne greške predviđanja kod rekurentne neuronske mreže su po pravilu niže i dostižu se manjim brojem iteracija

Na osnovu ove analize se može zaključiti da je potrebna modifikacija i uvođenje novih algoritama i poboljšanih mreža da bi se postigli bolji rezultati, pre svega tačnost predviđanja kod drugog perioda predviđanja.

Analizom dobijenih rezultata nakon uvođenja novih promenljivih i uvođenjem algoritma PSO za optimalno podešavanje težinskih koeficijenata zaključuje se sledeće:

- Novi algoritmi modela neuronskih mreža daju bolje rezultate predviđanja za prelazne režime (u ovom slučaju drugi period predviđanja)
- Smanjena je prosečna greška predviđanja u odnosu na standardne tipove mreži
- Smanjene su greške u pikovima pre i posle prekida isporuke toplotne energije u toku dana

- Moguće je podešavanje parametara mreže na skupu podataka sa jednog TI i naknadna implementacija na skupovima podataka drugih TI
- Postignuta dobra tačnost predviđanja kod svih skupova podataka (4 TI) što daje dobre osnove za generalizaciju modela za kratkoročno predviđanje toplotnog opterećenja kod sistema daljinskog grejanja
- Pokazana razlika u kvalitetu predviđanja u zavisnosti od kvaliteta i načina obrade i metodologije sakupljanja podataka sa različitih TI (Ogledni primer TI Krivi vir)
- Pokazana mogućnost korišćenja iste arhitekture neuronske mreže za kratkoročno predviđanje povezanih karakteristika sistema daljinskog grejanja (temperatura napojne i povratne vode, potrošnja toplotne energije)

Komparativna analiza rezultata predviđanja za najveće pikove u drugom posmatranom periodu je data u Tabeli 6-4 i Tabeli 6-5.

Tabela 6-4 Pregled smanjenja greške predviđanja za pikove TI MF Period II

Period II 24.03.2013 TI Krivi vir			
	Stvarna snaga	Predviđena snaga	%
FF ANN	97	134,99	39%
Modifikovana FF ANN	97	114,1	17%
FF ANN	70	78,21	11,7%
Modifikovana ANN	70	73,89	5,5%

Tabela 6-5 Pregled smanjenja greške predviđanja za pikove TI Krivi vir

Period II 23.03.2015 TI Mašinski fakultet			
	Stvarna snaga	Predviđena snaga	% greške
FF ANN	3,3	0	100%
Modifikovana FF ANN	3,3	3,01	8,8%
FF ANN	2,422	0	100%
Modifikovana ANN	2,422	2,02	16,9%
FF ANN	2,302	1,05	54,4%
Modifikovana ANN	2,302	2,10	8,8%

Kao što se može videti iz tabela, realizacijom modifikovanih neuronskih mreža na test podacima za Period II gde postoji tzv. prelazni režim grejanja dobijaju se mnogo bolji rezultati.

Greška predviđanja kod pikova za period II – 24.03.2013 TI Krivi vir se primenom modifikovane FF ANN mreže smanjuje preko 50%.

Greška predviđanja kod pikova za period II – 23.03.2015 TI Mašinski fakultet se primenom modifikovane FF ANN smanjuje oko 80%.

U oba gore navedena slučaja dobijaju se odlični rezultati pa se može zaključiti da je cilj realizacije modifikovanih neuronskih mreža uvođenjem novog ulaza i odgovarajućom optimizacijom, ispunjen.

Razlika u manjem smanjenju greške predviđanja kod pikova za TI Krivi vir leži u činjenici da su karakteristike obučavanja mreže za taj skup podataka slabije kao što je već pojašnjeno u prethodnim poglavljima.

Primena istih veštačkih neuronskih mreža na kratkoročno predviđanje povezanih karakteristika sistema daljinskog grejanja (temperature napojne vode, temperature povratne vode i potrošnje toplotne energije) pokazuje odličnu kompatibilnost i nešto manje greške predviđanja u odnosu na predviđenu toplotnu snagu.

Ova činjenica potvrđuje ispravnost izbora toplotne snage odnosno opterećenja kao glavne karakteristike za analizu i simulaciju jer prilagođavanje njenim karakteristikama i promenama u ponašanju obuhvata i većinu varijacija ostalih karakteristika i podiže nivo opštosti i generalizacije što je i jedan od ciljeva.

Komparativna analiza, primenjene preporuke iz poglavlja 3. i dobijene simulacije iz poglavlja 5. za stvarne skupove podataka mogu da se sublimiraju kroz određene preporuke kada je u pitanju primena veštačkih neuronskih mreža za kratkoročno predviđanje karaktersitika kod sistema daljinskog grejanja:

- preporuka je korišćenje standardnih feedforward i rekurentnih neuronskih mreža
- preporuka je korišćenje kombinacije aktivacionih funkcija (tansig, tansig) za skriveni i izlazni sloj u odnosu na druge aktivacione funkcije jer je obuka brža a mera performansi MSE niža
- preporuka je da se što više vremena posveti analizi postojećeg problema kroz analizu datog skupa podataka i međusobnih zavisnosti različitih karakteristika
- preporuka je da ulazni vektor ne treba da bude sa previše ulaznih promenljivih (misli se na minimum 10 puta manji broj ulaznih promenljivih od broja primera uzorka)
- preporuka je da problem sa obučavanjem mreže treba rešavati kroz dodatnu analizu skupa podataka i eventualno uvođenje novih ulaznih promenljivih a ne promenom tipa mreže
- preporuka je da se koriste feedforward neuronske mreže jer su lakše za implementaciju od rekurentnih neuronskih mreža bez obzira na manju grešku predviđanja i manji broj iteracija kod rekurentnih
- preporuka je da ne treba raditi normalizaciju podataka već više vremena posvetiti analizi međusobne korelacije podataka
- preporuka je koristiti LM algoritam zbog brzine i simulacije
- preporuka je da se dosta vremena posveti uređenju uzorka odnosno skupa podataka kroz otklanjanje nedostajućih podataka, šumova, grešaka u čitanju,..

- preporuka je da se za karakteristike obučavanja mreže koristi kao mera performansi MSE a za samo predviđanje prosečna greška predviđanja ili MAPE.
- preporuka je da se broj skrivenih slojeva poveća sa 1 na 2 ukoliko se ne dobiju dobri rezultati za obučavanje.
- preporuka je da se za periode testiranja biraju periodi koji obuhvataju određene specifične karakteristike kao što je ovde slučaj sa prekidima u grejanju
- preporuka je da se ista arhitektura neuronske mreže koristi za kratkoročno predviđanje drugih povezanih karakteristika sistema daljinskog grejanja kao što su temperatura napojne i povratne vode i potrošnja toplotne energije.

Na kraju ove komparativne analize može se ustanoviti izgled algoritma za kratkoročno predviđanje kod sistema daljinskog grejanja zadovoljavajuće tačnosti korišćenjem standardnih veštačkih neuronskih mreža. (Slika 6-1).

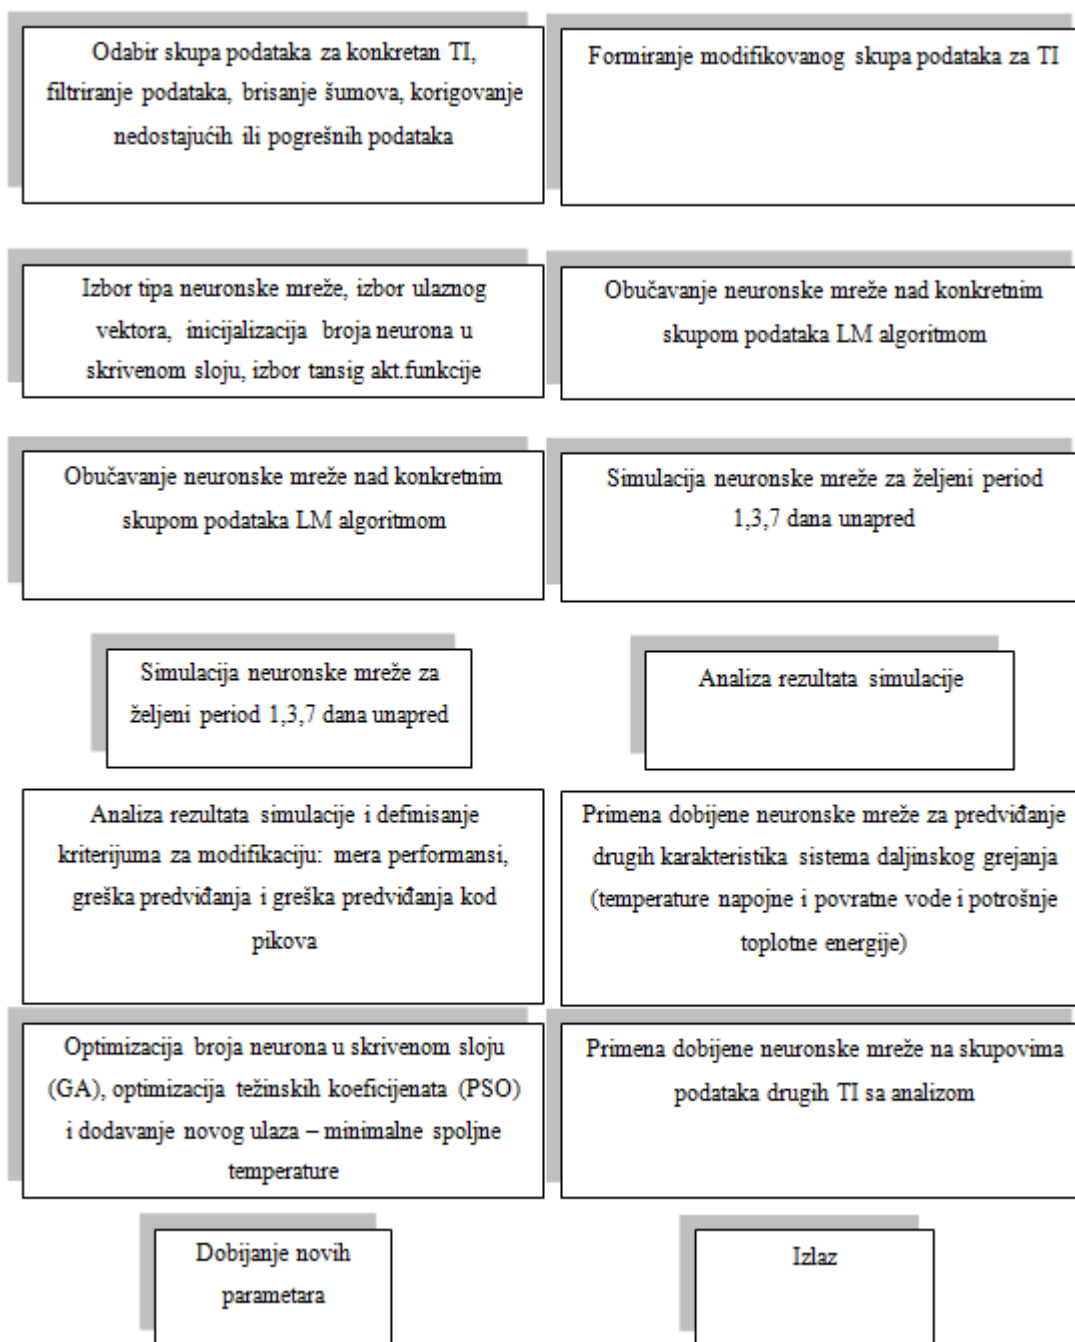
Pri tome treba napomenuti da je konačna analiza kratkoročnog predviđanja obihvatila projektovanje, obučavanje i simulaciju 2 standardna tipa neuronskih mreža na na 6 (3+3) različitih ulaznih vektora i 4 različita toplotna izvora (4 skupa podataka za obučavanje) za po dva posmatrana perioda predviđanja i da su prikazane simulacije za 1, 3 i 7 dana predviđanja unapred. To znači da je izvršena analiza i simulacija ukupno 288 neuronskih mreža.

Kada se govori o praktičnom uticaju i značaju kratkoročnog predviđanja sistema daljinskog grejanja treba izdvojiti dva aspekta:

- industrijski i
- društveni

Sa industrijskog aspekta, predviđanje toplotnog opterećenja pomaže u efektivnom planiranju i upravljanju sistemima daljinskog grejanja. Na taj način se mogu smanjiti operativni troškovi proizvodnje toplotne energije.

Sa društvenog aspekta, predviđanje toplotnog opterećenja kod sistema daljinskog grejanja može dovesti do velike koristi kada je životna sredina u pitanju. Kvalitativno poboljšanje upravljanja sistemima daljinskog upravljanja neminovno za posledicu ima smanjenje rizika za ugrožavanje životne sredine a kvantitativno utiče pozitivno na ostvarenje cilja postavljenog od strane EU o smanjenju emisije štetnih gasova za 20% do 2020. godine u odnosu na nivo iz 1990.



Slika 6-1 Algoritam primene veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja

7. ZAKLJUČAK

Ključni naučni cilj disertacije je analiza i razvoj algoritama za rešavanje problema kratkoročnog predviđanja kod sistema daljinskog grejanja radi dobijanja racionalnijeg sistema daljinskog grejanja sa aspekta načela ekonomske i energetske efikasnosti.

Izložena istraživanja sprovedena u toku izrade ove disertacije po sadržaju obuhvataju primenu više tehnika veštačke inteligencije za realizaciju kratkoročnog predviđanja toplotnog opterećenja i drugih karakteristika kod sistema daljinskog grejanja. Primarno su izložena istraživanja koje se odnose na primenu veštačkih neuronskih mreža za kratkoročno predviđanje ali i primene savremenih metoda optimizacije GA i PSO.

Primenom savremenih metoda i algoritama iz domena veštačke inteligencije moguće je razviti odgovarajuće modele neuronskih mreža za predviđanje koji predstavljaju dobar preduslov za implementaciju istih kod konkretnih toplotnih izvora i dobijanje efikasnijih i efektivnijih sistema daljinskog grejanja sa energetskog i ekonomskog aspekta.

Rezultati naučnih istraživanja omogućavaju implementaciju novog algoritma za kratkoročno predviđanje kod sistema daljinskog grejanja u realnom vremenu pomoću veštačkih neuronskih mreža i pružaju mogućnost izvesne standardizacije i generalizacije u meri koliko je to uopšte moguće kod primene metode veštačkih neuronskih mreža.

Kako bi se izvršila odgovarajuća generalizacija i uspostavio nivo opštosti, istraživanja su primenjena na različitim toplotnim izvorima.

Dobijeni rezultati su jako zadovoljavajući i vode zaključku da se uz pridržavanje adekvatnih preporuka mogu primeniti i na druge toplotne izvore sa dovoljno tačnosti i pouzdanosti u predviđanju.

U okviru teze predstavljeni su sledeći doprinosi:

- Novi algoritam i metoda za primenu standardnih veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja;
- Novi algoritam i metodu za izbor uticajnih parametara veštačke neuronske mreže za kratkoročno predviđanje i njihovu komparativnu analizu ;
- Nove smernice primene adekvatnih veštačkih neuronskih mreža kod sistema za daljinsko grejanje;
- Novi celoviti algoritam pravila i procedura izbora, projektovanja i implementacije veštačke neuronske mreže za kratkoročno predviđanje kod sistema daljinskog grejanja.

Ovi naučni rezultati, koji predstavljaju proširenje postojećih saznanja, od praktičnog su značaja za dalji razvoj, kao i sveobuhvatno korišćenje veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja, posebno u prelaznim režimima.

Dobijeni rezultati omogućavaju bolju autonomiju i pouzdanost sistema daljinskog grejanja sa aspekta efikasnosti i efektivnosti, što predstavlja značajan naučni doprinos unapređenju multidisciplinarnog pristupa pri rešavanju ovakvih kompleksnih problema.

I pored određenog broja publikovanih metoda za kratkoročno predviđanje koje su uspešno testirane i dokazane, nijedna od njih nije se dokazala kao metoda koja može biti generalno primenjena. Razlog leži u činjenici da uslovi i zahtevi svake pojedinačne situacije ili problema imaju jako značajan uticaj na izbor odgovarajućeg modela. Često je i teško uporediti primenjene metode. Zato je jedan od ciljeva ove disertacije i bio kreiranje algoritma koji će dati doprinos uspostavljanju opštije procedure za primenu veštačkih neuronskih mreža za kratkoročno predviđanje kod sistema daljinskog grejanja. Pri tome, posebno imajući u vidu da su podaci uzeti sa toplotnih izvora sa različitim eksploatacionim uslovima i drugim karakteristikama.

Pravci daljih istraživanja podrazumevaju dodatnu optimizaciju optimizaciju algoritama i sistematizaciju predloženih rešenja. To se posebno odnosi na uključivanje dodatnih podataka za analizu samog problema sistema daljinskog grejanja i to pre svega socijalnu komponentu kao parametra a sa strane predviđanja dalju razradu uticaja ulaznog vektora i drugih parametara na kvalitet predviđanja. Sa stanovišta korišćenja veštačkih neuronskih mreža, jedan od pravaca istraživanja će biti usmeren na korišćenje drugih standardnih neuronskih mreža i adekvatnu komparaciju ali i njihovo korišćenje za klasifikaciju ulaznih promenljivih koja je neminovna sa daljom detaljnom analizom. Time će se pokazati upotrebna vrednost veštačkih neuronskih mreža na još jednoj konkretnoj pojavi pored predviđanja a to je klasifikacija.

Takođe, jedan pravac istraživanja će se zasnivati na pokušaju primene ovakvog pristupa rešavanju multidisciplinarnog problema pomoću veštačkih neuronskih mreža na rešavanje drugih problema kratkoročnog predviđanja.

LITERATURA

- [1] E. Alpaydin, *Introduction to Machine Learning*, The MIT Press Cambridge, Massachusetts London, England, 2004.
- [2] R. Rojas, J. Feldman, *Neural Networks: A Systematic Introduction*, Springer, 1996.
- [3] I. Aleksander, H. Morton, *An Introduction to Neural Computing*, Intl Thomson Computer Pr, 1995.
- [4] L. Fausett, *Fundamentals of Neural Networks-Architectures, Algorithms and Applications*, Prentice Hall, 1993.
- [5] M. Brown, C. J. Harris, *Neurofuzzy adaptive modelling and control*, Prentice Hall, 1994.
- [6] J. S. Jang, C. T. Sun, E. Mizutani, *Neuro-Fuzzy and Soft Computing: Acomputational approach to learning and machine intelligence*, Prentice-Hall, Upper Saddle River, NJ 07458, 1997.
- [7] S. J. Russel, P. Norvig, *Artificial Intelligence – A Modern Approach*, Prentice Hall, Englewood Cliffs, New Jersey, 1995.
- [8] G. Chakraborty, “Genetic Algorithm Approaches to Solve Various Steiner Tree Problems“, *Steiner Trees in Industries*, Kluwer Academic, pp. 71-100, 2001.
- [9] C. T. Lin, G. Lee, *Neural Fuzzy Systems: A Neural-Fuzzy Synergism to Intelligent Systems*, Prentice-Hall Inc., NJ, 1996.
- [10] M. Dorigo, G. Di Caro, “Ant colony optimization: a new meta-heuristic”, *Proceedings of the 1999 Congress on Evolutionary Computation*, 1999. Vol. 2, Washington, DC, USA.
- [11] W.S. McCulloch, W. Pitts, “A logical calculus of the ideas immanent innervousactivity”, *Bulletin of mathematical biophysics* 5, pp. 115-133, 1943
- [12] G. F. Luger, *Artificial Intelligence-Structures and Strategies for Complex Problem Solving*, Addison-Wesley, 2005.
- [13] P. Simpson, *Artificial neural system*, Pergamon, Elmsford, NY, 1990.
- [14] S. Haykin, *Neural networks - a comprehensive foundation*, MacMillan collage Publishing Company, Inc., 1994.
- [15] L. X Wang, *A Course in Fuzzy Systems and Control*, Prentice Hall, NJ, 1997.
- [16] H. L. Tsoukalas, E. R. Uhrig, *Fuzzy and neural approaches in engineering*, John Wiley & Sons, Inc., 1997.

- [17] F. Araujo, B. Ribeiro, L. Rodrigues, “A neural network for shortest path computation“, *IEEE Trans. Neural Networks*, No. 5(12), pp. 1067–1073, 2001.
- [18] R. Beale, T. Jackson, *Neural Computing – An Introduction*, Institute of Physics Publishing, 1990.
- [19] T. X. Brown, “Neural network design for switching network control”, Caltech Ph. D. Thesis, 1991.
- [20] A.Cichocki, R. Unbehauen, *Neural Network for Optimazation and Signal Processing*, Wiley, 1993.
- [21] H.Simon, *Neural Networks: A comprehensive Foundation*, 2nd Edition, Pearson Education, 1998.
- [22] D. J. Amit, H. Gutfreund, H. Sompolinsky, “Information storage in neural networks with low levels of activity“, *Physical Review A*, Vol. 35, No. 6, pp.2293-2303, 1987.
- [23] B. Kosko, *Neural Networks and Fuzzy Systems*, Prentice Hall, NJ, 1992.
- [24] A. Borst, M. Egelhaaf, H. S. Seung, “Two-dimensional motion perception in flies”, *Neural Computation* 5, pp. 856-868, 1993.
- [25] DARPA (Defense Advanced Research Project Agency), “DARPA neural network study”, *AFCEA International Press*, Fairfax, VA, 1988.
- [26] H. Fahmy, G. Develekos, C. Douligeris, “Application of neural networks and machine learning in network design”, *IEEE J. on Selected areas in Comm.*, Vol.15, No.2, pp. 226-237, February 1997.
- [27] B. Muller, J. Reinhardt, *Neural Networks: an introduction*, Springer-Verlag, 1990.
- [28] A. C. Guyton, J.E. Hall, *Textbook of medical physiology*, W. B. Saunders, 1996.
- [29] A. I. Galushkin, *Neural Networks Theory*, Springer-Verlag, Berlin, 2007.
- [30] M. P. Craven, “Inter-chip communication in an analogue neural networkutilising frequency division multiplexing”, Ph.D. Thesis, University of Nottingham, 1993.
- [31] C. T. Leondes, *Algorithms and Architectures*, Academic Press, 1998.
- [32] A. Blais, “An introduction to neural networks”, IBM Developer works, <http://www.128.ibm.com/developerworks/linux/library/l-neural/>, july 2001.
- [33] S. I. Gallant, *Neural Network Learning and Expert Systems*, MIT Press, 1993.
- [34] G.A. Carpenter, M.A.Cohen, S.Grossberg, Technical comments, “Computingwith neural networks”, *Science* 235, pp. 1226-1227, 1987.
- [35] J. J. Hopfield, D. W. Tank, “Neural’ computations of decision in optimization problems”, *Biol. Cybern.*, No. 52, pp. 141–152, 1985.

- [36] J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities,” *Proc. Nat. Acad. Sci.*, Vol. 79, pp. 2554–2558, 1982.
- [37] D. Graupe, “Principles of artificial neural network”, Advanced series on circuits and systems – Vol.6, World Scientific Publishing, 2007.
- [38] C. Molter, U. Salihoglu, H. Bersini, “Storing static and cyclic patterns in an Hopfield neural network”, Technical report, Laboratory of artificial intelligence (IRIDIA-ULB), February 2005.
- [39] J. J. Hopfield, “Neurons with graded response have collective computational properties like those of two-state neurons”, *Proc. Natl. Acad. Sci.*, USA 81, pp. 3088–3092, 1984.
- [40] D.S. Broomhead and D. Lowe. Multivariable functional interpolation and adaptive networks. *Complex Systems*, 2:321–355, 1988.
- [41] Sharda, R., 1994. Neural networks for the MS/OR analyst: An application bibliography. *Interfaces* 24 (2), 116–130.
- [42] White, H., 1989. Learning in artificial neural networks: A statistical perspective. *Neural Computation* 1, 425–464.
- [43] Ripley, B.D., 1993. Statistical aspects of neural networks. In: Barndorff-Nielsen, O.E., Jensen, J.L., Kendall, W.S. (Eds.), *Networks and Chaos-Statistical and Probabilistic Aspects*. Chapman and Hall, London, pp. 40–123.
- [44] Cheng, B., Titterton, D.M., 1994. Neural networks: A review from a statistical perspective. *Statistical Science* 9 (1), 2–54.
- [45] Irie, B., Miyake, S., 1988. Capabilities of three-layered perceptrons. In: *Proceedings of the IEEE International Conference on neural networks: Neural Networks, I*, pp. 641–648.
- [46] Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks* 2, 359–366.
- [47] Cybenko, G., 1989. Approximation by superpositions of a sigmoidal function. *Mathematical Control Signals Systems* 2, 303–314.
- [48] Funahashi, K., 1989. On the approximate realization of continuous mappings by neural networks. *Neural Networks* 2, 183–192.
- [49] Hornik, K., 1991. Approximation capabilities of multilayer feedforward networks. *Neural Networks* 4, 251–257.
- [50] Hornik, K., 1993. Some new results on neural network approximation. *Neural Networks* 6, 1069–1072.

- [51] Box, G.E.P., Jenkins, G.M., 1976. *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco, CA.
- [52] Pankratz, A., 1983. *Forecasting with Univariate Box-Jenkins Models: Concepts and Cases*. John Wiley, New York.
- [53] Granger, C.W.J., Terasvirta, T., 1993. *Modelling Nonlinear Economic Relationships*. Oxford University Press, Oxford.
- [54] Granger, C.W.J., Anderson, A.P., 1978. *An Introduction to Bilinear Time Series Models*. Vandenhoeck and Ruprecht, Göttingen.
- [55] Tong, H., Lim, K.S., 1980. Threshold autoregressive, limit cycles and cyclical data. *Journal of the Royal Statistical Society Series B* 42 (3), 245–292.
- [56] Engle, R.F., 1982. Autoregressive conditional heteroskedasticity with estimates of the variance of UK inflation. *Econometrica* 50, 987–1008.
- [57] Hu, M.J.C., 1964. Application of the adaline system to weather forecasting. Master Thesis, Technical Report 6775-1, Stanford Electronic Laboratories, Stanford, CA, June.
- [58] Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1986. representations by backpropagating errors. *Nature* 323 (6188), 533–536.
- [59] Werbos, P.J., 1974. Beyond regression: new tools for prediction and analysis in the behavioral sciences. Ph.D. thesis, Harvard University.
- [60] Werbos, P.J., 1988. Generalization of backpropagation with application to a recurrent gas market model. *Neural Networks* 1, 339–356.
- [61] Lapedes, A., Farber, R., 1987. Nonlinear signal processing using neural networks: prediction and system modeling. Technical Report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM.
- [62] Weigend, A.S., Huberman, B.A., Rumelhart, D.E., 1990. Predicting the future: A connectionist approach. *International Journal of Neural Systems* 1, 193–209.
- [63] Weigend, A.S., Huberman, B.A., Rumelhart, D.E., 1992. Predicting sunspots and exchange rates with connectionist networks. In: *Nonlinear Modeling and Forecasting*. Addison-Wesley, Redwood City, CA, pp. 395–432.
- [64] Cottrell, M., Girard, B., Girard, Y., Mangeas, M., Muller, C., 1995. Neural modeling for time series: a statistical stepwise method for weight elimination. *IEEE Transactions on Neural Networks* 6 (6), 1355–1364.
- [65] Tang, Z., Almeida, C., Fishwick, P.A., 1991. Time series forecasting using neural networks vs Box-Jenkins methodology. *Simulation* 57 (5), 303–310.

- [66] Sharda, R., Patil, R.B., 1992. Connectionist approach to timeseries prediction: An empirical test. *Journal of Intelligent Manufacturing* 3, 317–323.
- [67] Tang, Z., Fishwick, P.A., 1993. Feedforward neural nets as models for time series forecasting. *ORSA Journal on Computing* 5 (4), 374–385.
- [68] Lowe, D., Webb, A.R., 1990. Time series prediction by networks: A dynamical systems perspective. *IEE proceedings-F* 138 (1), 17–24
- [69] Deppisch, J., Bauer, H.-U., Geisel, T., 1991. Hierarchical training of neural networks and prediction of chaotic time series. *Physics Letters* 158, 57–62.
- [70] Trippi, R.R., Turban, E., 1993. *Neural Networks in Finance and Investment: Using Artificial Intelligence to Improve Real-world Performance*. Probus, Chicago.
- [71] Gately, E., 1996. *Neural Networks for Financial Forecasting*. John Wiley, New York.
- [72] Wilson, R., Sharda, R., 1992. Neural networks. *OR/MS Today*, August, 36–42.
- [73] Grudnitski, G., Osburn, L., 1993. Forecasting S and P and gold futures prices: An application of neural networks. *The Journal of Futures Markets* 13 (6), 631–643.
- [74] Park, J., Sandberg, I.W., 1991. Universal approximation using radial basis function networks. *Neural Computation* 3, 246–257.
- [75] Makridakis, S., Anderson, A., Carbone, R., Fildes, R., Hibdon, The accuracy of extrapolation, (time series) methods: Results of a forecasting competition. *Journal of Forecasting* 1 (2), 111–153.
- [76] Hill, T., Marquez, L., O'Connor, M., Remus, W., 1994. Artificial neural networks for forecasting and decision making. *International Journal of Forecasting* 10, 5–15.
- [77] Hill, T., O'Connor, M., Remus, W., 1996. Neural network models for time series forecasts. *Management Sciences* 42 (7), 1082–1092.
- [78] Weigend, A.S., Gershenfeld, N.A., 1993. *Time Series Prediction: Forecasting the Future and Understanding the Past*. AddisonWesley, Reading, MA.
- [79] Kohzadi, N., Boyd, M.S., Kermanshahi, B., Kaastra, I., 1996. A comparison of artificial neural network and time series models for forecasting commodity prices. *Neurocomputing* 10, 169–181.
- [80] Balestrino, A., Bini Verona, F., Santanche, M., 1994. Time series analysis by neural networks: Environmental temperature forecasting. *Automazione e Strumentazione* 42 (12), 81–87.
- [81] Haas, D.J., Milano, J., Flitter, L., 1995. Prediction of helicopter component loads using neural networks. *Journal of the American Helicopter Society* 40 (1), 72–82.

- [82] Nam, K., Schaefer, T., 1995. Forecasting international airline passenger traffic using neural networks. *Logistics and Transportation* 31 (3), 239–251.
- [83] Maasoumi, E., Khotanzad, A., Abaye, A., 1994. Artificial neural networks for some macroeconomic series: A first report. *Econometric Reviews* 13 (1), 105–122.
- [84] Ruiz-Suarez, J.C., Mayora-Ibarra, O.A., Torres-Jimenez, J., Ruiz- Suarez L.G., 1995. Short-term ozone forecasting by artificial neural networks. *Advances in Engineering Software* 23, 143– 149.
- [85] Huntley, D.G., 1991. Neural nets: An approach to the forecasting of time series. *Social Science Computer Review* 9 (1), 27–38.
- [86] Chang, I., Rapiraju, S., Whiteside, M., Hwang, G., 1991. A neural network to time series forecasting. In: *Proceedings of Decision Science Institute.*, 3, pp. 1716–1718.
- [87] Karunanithi, N., Grenney, W.J., Whitley, D., Bovee, K., 1994. Neural networks for river flow prediction. *Journal of Computing in Civil Engineering* 8 (2), 201–220.
- [88] Gorr, L., 1994. Research prospective on neural network forecasting. *International Journal of Forecasting* 10, 1–4.
- [89] Ezugwu, E.O., Arthur, S.J., Hins, E.L., 1995. Too-wear prediction using artificial neural networks. *Journal of Materials Processing Technology* 49, 255–264.
- [90] Aiken, M., Krosch, J., Vanjani, M., Govindarajulu, C., Sexton, R., 1995. A neural network for predicting total industrial production. *Journal of End User Computing* 7 (2), 19–23.
- [91] Payeur, P., Le-Huy, H., Gosselin, C.M., 1995. Trajectory prediction for moving objects using artificial neural networks. *IEEE Transactions on Industrial Electronic* 42 (2), 147–158.
- [92] Duliba, K.A., Contrasting neural nets with regression in predicting performance in the transportation industry. In: *Proceedings of the Annual IEEE International Conference on Systems Sciences.*, 25, pp. 163–170.
- [93] Lubero, R.G., 1991. Neural networks for water demand time series forecasting. In: *Proceedings of the International Workshop on Artificial Neural Networks*, pp. 453–460.
- [94] Turkkan, N., Srivastava, N.K., 1995. Prediction of wind load distribution for air-supported structures using neural networks. *Canadian Journal of Civil Engineering* 22 (3), 453–461.
- [95] Connor, J.T., Martin, R.D., Atlas, L.E., 1994. Recurrent neural networks and robust time series prediction. *IEEE Transactionon Neural Networks* 51 (2), 240–254.

- [96] Gent, C.R., Sheppard, C.P., 1992. Predicting time series by a fully connected neural network trained by back propagation. *Computing and Control Engineering Journal* 3 (3), May, 109–112
- [97] Kuan, C.-M., Liu, T., 1995. Forecasting exchange rates using feedforward and recurrent neural networks. *Journal of Applied Econometrics* 10, 347–364.
- [98] Narendra, K.S., Parthasarathy, K., 1990. Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks* 1 (1), 4–27.
- [99] Levin, A.U., Narendra, K.S., 1993. Control of nonlinear dynamical systems using neural networks: Controllability and Stabilization. *IEEE Transactions on Neural Networks* 4 (2), 192–206
- [100] Poli, I., Jones, R.D., 1994. A neural net model for prediction. *Journal of American Statistical Association* 89 (425), 117–121.
- [101] Baum, E.B., Haussler, D., 1989. What size net gives valid generalization?. *Neural Computation* 1, 151–160.
- [102] Lachtermacher, G., Fuller, J.D., 1995. Backpropagation in timeseries forecasting. *Journal of Forecasting* 14, 381–393.
- [103] Rissanen, J., 1987. Stochastic complexity (with discussion). *Journal of the Royal Statistical Society, B*, 49, 223–239 and 252–265.
- [104] Barker, D., 1990. Analyzing financial health: Integrating neural networks and expert systems. *PC AI* 4 (3), 24–27.
- [105] Bergerson, K., Wunsch, D.C., 1991. A commodity trading model based on a neural network–expert system hybrid. In: *Proceedings of the IEEE International Conference on Neural Networks*, Seattle, WA, pp. 1289–1293.
- [106] Pelikan, E., de Groot, C., Wurtz, D., 1992. Power consumption West-Bohemia: Improved forecasts with decorrelating connectionist networks. *Neural Network World* 2 (6), 701–712.
- [107] Ginzburg, I., Horn, D., 1994. Combined neural networks for timeseries analysis. *Advances in Neural Information Processing Systems* 6, 224–231.
- [108] Wedding II, D.K., Cios, K.J., 1996. Time series forecasting by combining RBF networks, certainty factors, and the Box Jenkins model. *Neurocomputing* 10, 149–168
- [109] Donaldson, R.G., Kamstra, M., 1996. Forecasting combining with neural networks. *Journal of Forecasting* 15, 49–61.

- [110] Zhang, X., Hutchinson, J., 1993. Simple architectures on fastmachines: Practical issues in nonlinear time series prediction. In: Weigend, A.S., Gershenfeld, N.A. (Eds.), Time Series forecasting. Prediction: Forecasting the Future and Understanding the Past. Addison-Wesley, Reading, MA.
- [111] Zhang, X., 1994. Time series analysis and prediction by neural networks. Optimization Methods and Software 4, 151–170
- [112] Chakraborty, K., Mehrotra, K., Mohan, C.K., Ranka, S., 1992. Forecasting the behavior of multivariate time series using neural networks. Neural Networks 5, 961–970.
- [113] Vishwakarma, K.P., 1994. A neural network to predict multiple time series. In: Proceedings of the IEEE International Conference on Neural Networks, 6, pp. 3674–3679.
- [114] Chu, C.H., Widjaja, D., 1994. Neural network system for forecasting method selection. Decision Support Systems 12, 13–24.
- [115] Jhee,W.C., Lee, K.C., Lee, J.K., 1992. A neural network approach for the identification of the Box-Jenkins model. Network: Computation in Neural Systems 3, 323–339.
- [116] Lee, J.K., Jhee,W.C., 1994. A two-stage neural network approach for ARMA model identification with ESACF. Decision Support Systems 11, 461–479.
- [117] Zhang Guoqiang, B. Eddy Patuwo, Michael Y. Hu, Forecasting with artificial neural networks: the state of the art, International Journal of Forecasting 14 (1998), pp 35-62
- [118] Srinivasan, D., Liew, A.C., Chang, C.S., 1994. A neural network short-term load forecaster. Electric Power Systems Research, 28, 227–234.
- [119] Lippmann, R.P., 1987. An introduction to computing with neural nets, IEEE ASSP Magazine, April, 4–22.
- [120] Hecht-Nielsen, R., 1990. Neurocomputing. Addison-Wesley, Menlo Park, CA.
- [121] Wong, F.S., 1991. Time series forecasting using backpropagation neural networks. Neurocomputing 2, 147–159.
- [122] Kang, S., 1991. An Investigation of the Use of Feedforward Neural Networks for Forecasting. Ph.D. Thesis, Kent State University.
- [123] De Groot, C., Wurtz, D., 1991. Analysis of univariate time serieswith connectionist nets: a case study of two classical examples. Neurocomputing 3, 177–192.

- [124] Chen, S.T., Yu, D.C., Moghaddamjo, A.R., 1991. Weather sensitive short-term load forecasting using nonfully connected artificial neural network. In: Proceedings of the IEEE/Power Engineering Society Summer Meeting, 91 SM 449–8 PWRS.
- [125] Chen, T., Chen, H., 1995. Universal approximation to nonlinear operators by neural networks with arbitrary activation functions and its application to dynamical systems. *IEEE Transactions on Neural Networks* 6 (4), 911–917.
- [126] Klimasauskas, C.C., 1991. Applying neural networks. Part 3: Training a neural network, *PC-AI*, May/ June, 20–24.
- [127] Rumelhart, D.E., Durbin, R., Golden, R., Chauvin, Y., 1995. Backpropagation: the basic theory. In: Chauvin, Y., Rumelhart, D.E. (Eds.), *Backpropagation: Theory, Architectures, and Applications*. Lawrence Erlbaum Associates, New Jersey, pp. 1–34.
- [128] Yu, X.H., Chen, G.A., Cheng, S.X., 1995. Dynamic learning rate optimization of the backpropagation algorithm. *IEEE Transactions on Neural Networks* 6 (3), 669–677.
- [129] Refenes, A.N., 1995. *Neural Networks in the Capital Markets*. IEEE Transactions on Neural John Wiley, Chichester.
- [130] Azoff, E.M., 1994. *Neural Network Time Series Forecasting of Financial Markets*. John Wiley and Sons, Chichester.
- [131] Dotzauer, E. (2002). Simple model for prediction of loads in district-heating systems. *Applied Energy*, 73 (3), 277- 284.
- [132] Nielsen, H. A., & Madsen, H. (2006). Modelling the heat consumption in district heating systems using a grey-box approach. *Energy and Buildings* , 38 (1),63-71.
- [133] Chramcov, B. (2010). Heat demand forecasting for concrete district heating system. *International Journal of Mathematical Models and Methods in Applied Sciences*, 4 (4), 231-239.
- [134] Grosswindhagera, S., Voigtb, A., & Kozeka, M. (2011). Online short-term forecast of system heat load in district heating networks. *Proceedings of the 31st International Symposium on Forecasting* .
- [135] Grzenda, M., & Macukow, B. (2006). Demand prediction with multi-stage neural processing. *Advances in Natural Computation and Data Mining* , 131-141.
- [136] Kato, K., Sakawa, M., Ishimaru, K., Ushiro, S., & Shibano, T. (2008). Heat load prediction through recurrent neural network in district heating and cooling systems. *IEEE International Conference on Systems, Man and Cybernetics*, 1401-1406.

- [137] M. Sakawa, H. Katagiri, T. Matsui, K. Ishimaru and S. Ushiro (2010). Heat load prediction in district heating and cooling systems through a recurrent neural network with data characteristics, *Scientiae Mathematicae Japonicae Online*, e-2010, 449–464
- [138] Park, T. C., Kim, U. S., Kim, L.-H., Jo, B. W., & Yeo, Y. K. (2010). Heat consumption forecasting using partial least squares, artificial neural network and support vector regression techniques in district heating systems. *Korean Journal of Chemical Engineering* , 27 (4), 1063-1071.
- [139] Krzysztof Wojdyga. Predicting heat demand for a district heating systems, *International Journal of Energy and Power Engineering* 2014; 3(5): 237-244
- [140] Yang Hongying, a, Jin Shuanglong, Feng Shuanglei, Wang bo, Zhang fei, Che Jianfeng. (2015) Heat Load Forecasting of District Heating System Based on Numerical Weather Prediction Model, 2nd International Forum on Electrical Engineering and Automation (IFEEA 2015)
- [141] Malmström, B., Ernfors, P., Nilsson, D. and Vallgren, H., 1996, Short-term forecasts of district heating load and outdoor temperature by use of on-line-connected computers. *Värmeforsk*, Stockholm, Sweden
- [142] Canu, S., Duran, M. and Ding, X., District Heating Forecast using Artificial Neural Networks, *International Journal of Engineering*, Vol 2. (1994)
- [143] Kuihe Yang; Lingling Zhao, Application of Mamdani Fuzzy System Amendment on Load Forecasting Model, *Symposium on Photonics and Optoelectronics*; 14-16 Aug. 2009. vol.4, no., p. 1-4.
- [144] Lingling Zhao et. al. Load forecasting based on amendment of Mamdani Fuzzy System, *Wireless communications, networking & mobile computing*; 26-28 Sep. 2009. p. 1-4,
- [145] Jain, A; Srinivas, E.; Rauta, R.. Short term load forecasting using Fuzzy adaptive inference and similarity, *World Congress on Nature & Biologically Inspired Computing*; 9-11 Dec. 2009, p.1743-1748.
- [146] Chaturvedi, D.K., Kumar, R., Mohan, M., Kalra, P.K.: Artificial Neural Network learning using improved Genetic algorithm .*J. IE (I)*, EL 82(2001).
- [147] EI Desouky, A, Aggarwal, R., Elkateb, M., Li, F., Advanced hybrid Genetic algorithm for short-term generation scheduling. *IEEE Proceedings Generation, Transmission and Distribution* 2001. 148 (6), p. 511-517.

- [148] Liao, G.-c., Tsao, I.-P., Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting. *IEEE Transactions on Evolutionary Computation* 2006. (3), p.330-340.
- [149] Heng, E.T.H.; Srinivasan, D.; Liew, A.C.;, Short term load forecasting using genetic algorithm and neural networks, *Energy Management and Power Delivery*, 1998. Proceedings of EMPD '98. 1998 International Conference on, 3-5 Mar 1998. Vol. 2, no., p. 576-581.
- [150] Tian Shu, Liu Tuanjie. Short Term Load Forecasting Based on RBFNN and QPSO, *Power and Energy Conference*, 27-31 March 2009. p. 1-4.
- [151] Ning Lu; Jianzhong Zhou;, Particle Swarm Optimization-Based RBF Neural Network Load Forecasting Model, *Power and Energy Engineering Conference, APPEEC 2009*, 27-31 March 2009. Asia-Pacific, p. 1-4.
- [152] Yang ShangDong and Li Xiang. A new ANN optimized by improved PSO algorithm combined with chaos and its application in short-term load forecasting. In *Computational Intelligence and Security*, 2006 International Conference. p. 945 – 948.
- [153] Elman, J L. (1991). Distributed representations, simple recurrent networks, and grammatical structure, *Mach Learn* , 7, (2-3), pp 95-126
- [154] Sarle WS. (1995) Stopped training and other remedies for overfitting. In: *Proceedings of the 27th Symposium on the Interface of Computing Science and Statistics*. Convention Center and Vista Hotel, Pittsburgh, PA; vol. 27, p. 352-360
- [155] Russ C Eberhart and James Kennedy. A new optimizer using particle swarm theory. In *Proceedings of the sixth international symposium on micro machine and human science*, volume 1, pages 39–43. New York, NY, 1995.
- [156] Holland J.H., "Adaptation in Natural and Artificial Systems", The University of Michigan Press, Ann Arbor (1975).
- [157] Bäck T., Fogel D. B., Michalewicz Z., "Basic Algorithms and Operators", in: *Evolutionary Computation 1*, Institute of Physics Publishing, Bristol-Philadelphia (2000).
- [158] Beasley D., Bull D.R., Martin R.R., "An Overview of Genetic Algorithms, Part 1, Fundamentals", *University Computing*, Vol. 15, No. 2, pp.58-69 (1993)
ftp://ralph.cs.cf.ac.uk/pub/papers/GAs/ga_overview1.ps

- [159] Goldberg D.E., "Genetic Algorithms in Search, Optimization and Machine Learning", Addison-Wesley Publ. Comp., Reading, Mass., (1989).
- [160] <http://www.aers.rs>, Agencija za energetiku Republike Srbije

BIOGRAFIJA

Kandidat Miloš Simonović rođen je 31.05.1973. godine u Nišu. Oženjen je i otac dve kćeri, Nadice i Danice. Završio je osnovnu školu "Vožd Karađorđe" u Nišu i srednju školu prirodno-matematičke struke "Bora Stanković" u Nišu, zanimanje – programersko-matematički saradnik, obe kao nosilac diplome "Vuk Karadžić".

Diplomirao je na Mašinskom fakultetu Univerziteta u Nišu na Katedri za Precizno mašinstvo i automatiku, sa prosečnom ocenom 9,40 u toku studija i ocenom 10 (deset) na diplomskom radu iz predmeta Multivarijabilni sistemi automatskog upravljanja, pod naslovom "Robustno upravljanje multivarijabilnih sistema automatskog upravljanja sa primenom".

Poslediplomske studije na Mašinskom fakultetu u Nišu iz oblasti automatsko upravljanje upisao je školske 1998. godine. Položio je sve ispite predviđene planom i programom fakulteta sa prosečnom ocenom 10 (deset). Magistarski rad pod naslovom: "Primena neuronskih mreža za upravljanje i adaptaciju sistema upravljanja u prostoru stanja" odbranio je 31. maja 2005. godine na Mašinskom fakultetu u Nišu i stekao akademski naziv magistar mašinskih nauka.

Naučno-nastanom veću Mašinskog fakulteta Univerziteta u Nišu, prijavio je izradu doktorske disertacije pod nazivom "Primena veštačkih neuronskih mreža za kratkoročno predviđanje i analizu sistema daljinskog grejanja" 03.06.2015. godine.

Od novembra 1999. godine je zaposlen na Mašinskom fakultetu kao saradnik.

Od decembra 2001. godine kandidat je zaposlen na Mašinskom fakultetu u Nišu kao istraživač-pripravnik. Od 2000. godine je uključen u izvođenje vežbi iz predmeta Automatsko upravljanje, Sistemi upravljanja u mehatronici, Diskretni sistemi automatskog upravljanja, Numeričke mašine i roboti, Informacione tehnologije u mašinstvu. Od 2007. godine je zaposlen na Mašinskom fakultetu sa zvanjem asistent.

Od 29.07.2008 do 12.07.2012. godine, obavljao je funkciju Gradonačelnika grada Niša i u tom četvorogodišnjem periodu je njegov radni odnos bio u statusu mirovanja na Mašinskom fakultetu, shodno Zakonu.

Trenutno je angažovan u izvođenju vežbi iz sledećih predmeta:

- Upravljanje sistemima
- Sistemi upravljanja u mehatronici
- Hidraulički i pneumatski sistemi upravljanja
- Modeliranje i identifikacija sistema i procesa
- Industrijska automatika
- Računarski podržana analiza i projektovanje sistema upravljanja

- Odabrana poglavlja iz oblasti mehatronike i upravljanja
- Neuro i fazi modeliranje i upravljanje
- Inteligentno upravljanje
- Napredni sistemi upravljanja

Autor je i koautor više naučnih i stručnih radova i jednog pomoćnog univerzitetskog udžbenika.

Učestvovao je u realizaciji više naučno-istraživačkih projekta.

Učestvovao je u projektovanju i uvođenju više različitih informacionih sistema.

Učestvovao je u izradi više stručnih studija.

Učestvovao je u izradi više komercijalnih elaborata i studija na Mašinskom fakultetu.

Završio je više različitih seminara i kurseva i stekao sertifikate iz oblasti automatskog upravljanja, informacionih tehnologija i energetske efikasnosti.

- Manchester Business School, Poslovna škola Mančester, Engleska, 2005. godine
- Finansijski inženjering u oblasti energetske efikasnosti, Vlada Kraljevine Norveške, 2004
- Informacione tehnologije, Stainbase fondacija

U toku osnovnih studija bio je nosilac stipendije Ministarstva za nauku i tehnologiju Republike Srbije.

IZJAVA O AUTORSTVU

Izjavljujem da je doktorska disertacija, pod naslovom

PRIMENA VEŠTAČKIH NEURONSKIH MREŽA ZA KRATKOROČNO PREDVIĐANJE I ANALIZU SISTEMA DALJINSKOG GREJANJA

koja je odbranjena na Mašinskom fakultetu Univerziteta u Nišu:

- rezultat sopstvenog istraživačkog rada;
- da ovu disertaciju, ni u celini, niti u delovima, nisam prijavljivao/la na drugim fakultetima niti univerzitetima;
- da nisam povredio/la autorska prava, niti zloupotrebio/la intelektualnu svojinu drugih lica.

Dozvoljavam da se objave moji lični podaci, koji su u vezi autorstva i dobijanja akademskog zvanja doktora nauka, kao što su ime i prezime, godina i mesto rođenja, i datum odbrane rada, i to u katalogu Biblioteke, Digitalnom repozitorijumu Univerziteta u Nišu, kao i u publikacijama Univerziteta u Nišu.

U Nišu, _____.

Potpis autora disertacije:



Dr Miloš B. Simonović

**IZJAVA O ISTOVETNOSTI ŠTAMPANOG I ELEKTRONSKOG OBLIKA
DOKTORSKE DISERTACIJE**

Naslov disertacije:

**PRIMENA VEŠTAČKIH NEURONSKIH MREŽA ZA KRATKOROČNO
PREDVIĐANJE I ANALIZU SISTEMA DALJINSKOG GREJANJA**

Izjavljujem da je elektronski oblik moje doktorske disertacije, koju sam predao/la za unošenje u **Digitalni repozitorijum Univerziteta u Nišu**, istovetan štampanom obliku.

U Nišu, _____.

Potpis autora disertacije:



Dr Miloš B. Simonović

IZJAVA O KORIŠĆENJU

Ovlašćujem Univerzitetsku biblioteku „Nikola Tesla“ da u Digitalni repozitorijum Univerziteta u Nišu unese moju doktorsku disertaciju, pod naslovom:

PRIMENA VEŠTAČKIH NEURONSKIH MREŽA ZA KRATKOROČNO PREDVIĐANJE I ANALIZU SISTEMA DALJINSKOG GREJANJA

Disertaciju sa svim prilogima predao sam u elektronskom obliku, pogodnom za trajno arhiviranje.

Moju doktorsku disertaciju, unetu u Digitalni repozitorijum Univerziteta u Nišu, mogu koristiti svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (Creative Commons), za koju sam se odlučio.

1. Autorstvo (CC BY)

2. Autorstvo – nekomercijalno (CC BY-NC)

3. Autorstvo – nekomercijalno – bez prerade (CC BY-NC-ND)

4. Autorstvo – nekomercijalno – deliti pod istim uslovima (CC BY-NC-SA)

5. Autorstvo – bez prerade (CC BY-ND)

6. Autorstvo – deliti pod istim uslovima (CC BY-SA)

U Nišu, _____.

Potpis autora disertacije:



Dr Miloš B. Simonović

ИЗВЕШТАЈ О ОЦЕНИ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

ПОДАЦИ О КАНДИДАТУ

Презиме, име једног родитеља и име	Симоновић Бојан Милош
Датум и место рођења	31.05.1973, Ниш, Србија

Основне студије

Универзитет	Универзитет у Нишу
Факултет	Машински факултет
Студијски програм	Аутоматско управљање
Звање	Дипломирани инжењер машинства
Година уписа	1992
Година завршетка	1998
Просечна оцена	9,40

Мајстер студије, магистарске студије

Универзитет	Универзитет у Нишу
Факултет	Машински факултет
Студијски програм	Аутоматско управљање
Звање	Магистар машинских наука
Година уписа	1998
Година завршетка	2005
Просечна оцена	10,00
Научна област	Аутоматско управљање и роботика
Наслов завршног рада	Примена неуронских мрежа за управљање и адаптацију система управљања у простору стања

Докторске студије

Универзитет	-
Факултет	-
Студијски програм	-
Година уписа	-
Остварен број ЕСПБ бодова	-
Просечна оцена	-

НАСЛОВ ТЕМЕ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Наслов теме докторске дисертације	Примена вештачких неуронских мрежа за краткорочно предвиђање и анализу система даљинског грејања
Име и презиме ментора, звање	др Властимир Николић, редовни професор
Број и датум добијања сагласности за тему докторске дисертације	НСВ 8/20-01-008/15-025 16.09.2015.године

ПРЕГЛЕД ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Број страна	163
Број поглавља	7
Број слика (шема, графика)	91
Број табела	17
Број прилога	-

МАШИНСКИ ФАКУЛТЕТ У НИШУ

Примљено: 20. 5. 2016.			
Орг.јед.	Број	Прилог	Вредности
	612-343/2016		

**ПРИКАЗ НАУЧНИХ И СТРУЧНИХ РАДОВА КАНДИДАТА
који садрже резултате истраживања у оквиру докторске дисертације**

Р. бр.	Аутор-и, наслов, часопис, година, број волумена, странице	Категорија
1	<p><u>Милош Симоновић</u>, Властимир Николић, Емина Петровић: Short-term Heat load Forecasting of Small District heating System Using Artificial Neural Networks,, Facta Universitatis, Series: Automatic Control and Robotics, Accepted</p> <p><i>Кратак опис садржине (до 100 речи)</i></p> <p>У раду су коришћени стварни историјски подаци за зимски период 2014-2015 са топлотног извора топлане Машински факултет Ниш, при чему је посматрано краткорочно предвиђање топлотног оптерећења за период 1 до 7 дана са аспекта коришћења различитих улазних вектора за исти модел вештачке неуронске мреже. Наиме, одговарајући избор улазних података је од највеће важности за обучавање неуронске мреже и добијање задовољавајућих резултата. Коришћена је feed forward неуронска мрежа са два различита улазна вектора за два различита периода предвиђања и извршена адекватна компарација која је показала боље резултате за улазни вектор који је садржао више података о систему и претходним вредностима температуре и оптерећења.</p>	M24
2	<p><u>Милош Симоновић</u>, Властимир Николић, Иван Ћирић, Емина Петровић: Recurrent Neural Network Short-term Prediction of District Heating System in Transient Regimes, ACTA TECHNICA CORVINIENSIS – Bulletin of Engineering, ISSN: 2067-3809, Fascicule 1/2016 pp.133 -137</p> <p><i>Кратак опис садржине (до 100 речи)</i></p> <p>У раду се показује да предузећа за производњу и дистрибуцију топлотне енергије имају растућу потребу да побољшају економску и енергетску ефикасност. Зато је јако важно оптимизовати производњу топлотне енергије коришћењем бољег предвиђања и управљања потребама потрошача. У овом раду, је фокус на краткорочном предвиђању где се користе стварни историјски подаци са топлотног извора Криви вир, инсталисане снаге 128 MW, енергетског субјекта ЈКП Топлана Ниш. Ово предвиђање је нарочито значајно за грејање у прелазним режимима када немамо континуирану испоруку топлотне енергије за време посматраног периода грејања. Примењена је рекурентна вештачка неуронска мрежа како би се обезбедило квалитетно краткорочно предвиђање услед варијација спољне температуре и добијени су задовољавајући резултати.</p>	M51
3	<p>Ivan R. Pavlovic, Ivan Ciric, Ratko Pavlovic, <u>Milos Simonovic</u>, Vlastimir Nikolic : Viscoelastic Double beam System Stability Analysis using Artificial neural Networks, Facta Universitatis, Series: Automatic Control and Robotics, Vol.14, N^o 1, 2015, pp.11-17</p> <p><i>Кратак опис садржине (до 100 речи)</i></p> <p>У раду су представљене предности примене неуронских мрежа у оцени и анализи нумеричких резултата добијених на основу анализе стабилности система вискоеластичних двоструких греда под дејством стохастичког оптерећења. Анализирани су нумерички подаци где су границе скоро сигурне стабилности двоструких греда одређене методом функционала Љапунова. Нумерички резултати добијени из анализе стабилности овог система су даље коришћени за обучавање вештачке неуронске мреже. Једна од предности примене неуронских мрежа је знатно мање време срачунавања, док је највећа предност оцена и приказ резултата који се не могу одредити конвенционалном нумеричком методом.</p>	M24
4	<p><u>Милош Симоновић</u>, Властимир Николић, Иван Ћирић, Емина Петровић, Софија Павловић: Heat Consumption Prediction of Small District Heating System Using Artificial Neural Networks, The 17th Symposium on Thermal Science and Engineering of Serbia, Sokobanja, Proceedings, ISBN 978-86-6055-076-9, pp. 741-748, Srbija, 2015.</p> <p><i>Кратак опис садржине (до 100 речи)</i></p> <p>У раду су коришћени стварни историјски подаци за зимски период 2014-2015 са топлотног извора топлане Машински факултет Ниш, при чему је употребљен побољшани модел неуронске мреже за предвиђање потрошње 1 до 7 дана унапред.</p>	M33

	<p>Искоришћена је метода „particle swarm” оптимизације (PSO) за подешавање тежинских коефицијената неуронске мреже и извршена компарација са регуларном feed forward неуронском мрежом. Добијени резултати са побољшаниом неуронском мрежом су бољи са аспекта предвиђања.</p>	
5	<p>Милош Симоновић, Властимир Николић, Емина Петровић: Short-term Heat load Forecasting of Small District heating System Using Artificial Neural Networks, The 3rd International Conference Mechanical Engineering in XXI century, September 17-18, 2015, Proceedings, ISBN 978-86-6055-072-1, pp. 291-294, Србија, 2015</p> <p><i>Кратак опис садржине (до 100 речи)</i></p> <p>У раду су коришћени стварни историјски подаци за зимски период 2014-2015 са топлотног извора топлане Машински факултет Ниш, при чему је посматрано краткорочно предвиђање топлотног оптерећења за период 1 до 7 дана са аспекта коришћења различитих улазних вектора за исти модел вештачке неуронске мреже. Наиме, одговарајући избор улазних података је од највеће важности за обучавање неуронске мреже и добијање задовољавајућих резултата. Коришћена је feed forward неуронска мрежа са два различита улазна вектора и извршена адекватна компарација која је показала боље резултате за улазни вектор који је садржао више података о систему и претходним вредностима температуре и оптерећења.</p>	M33
6	<p>Милош Симоновић, Милан Огризовић: Application of Neural Networks for Control DHS in Transient Regimes, 45th Congress HVAC&R, 3-5 December 2014, Belgrade, Serbia</p> <p><i>Кратак опис садржине (до 100 речи)</i></p> <p>За потребе овог рада искоришћени су стварно измерени подаци за период од 1. фебруара 2013. године до 31.03.2013. године, на топлотном извору Криви вир, град Ниш, регион југоисточне Србије, инсталисане снаге 128 MW, који може да користи природни гас и мазут. Укупно је употребљено 1020 података. Подаци се односе на прекидни режим грејања од 5 сати ујутру до 21 сат увече. За период предвиђања је изабран период од једне недеље од 25.марта до 31.марта. Проблем код адекватног предвиђања представља и чињеница да се због високих спољних температура у току дана прекида грејање у појединим интервалима. Предвиђање је реализовано за 1, 3 и 7 дана унапред. Бољи резултати су добијени за краће предвиђање.</p>	M33
7	<p>Милош Симоновић, Милан Огризовић: Short term prediction using neural networks for improving efficiency of district heating systems, International Conference on District Energy 2015, Engineering tomorrow through Innovative solutions, 22-24. March 2015, Portorož, Slovenia</p> <p><i>Кратак опис садржине (до 100 речи)</i></p> <p>У раду је као један од могућих начина за побољшање карактеристика система даљинског грејања приказана је употреба стварних историјских података са топлотног извора за предвиђање производње топлотне енергије и снаге. У овом раду су коришћени стварни историјски подаци са топлотног извора Коњарник, за зимски период 2013-2014. Примењена је feedforward неуронска мрежа са backpropagation алгоритмом и добијени су задовољавајући резултати. Просечна грешка предвиђања је веома задовољавајућа и упоредива са подацима добијеним са SCADA система. Приказан је и преглед предвиђања температуре напојне воде на радијаторима коришћењем података са једне топлотне подстанице као дела система даљинског грејања топлотног извора Коњарник. Овакво предвиђање температуре напојне воде представља добру основу за уштеду енергије и води до економски и енергетски ефикасног система даљинског грејања оријентисаног ка потрошачу.</p>	M34
8	<p>Емина Петровић, Властимир Николић, Дејан Митровић, Милош Симоновић: Optimal Design of Combined Heat and Power Production Plant Using Particle Swarm Optimization, The 17th Symposium on Thermal Science and Engineering of Serbia, Sokobanja, Proceedings, ISBN 978-86-6055-076-9, pp. 677-685, Србија, 2015.</p> <p><i>Кратак опис садржине (до 100 речи)</i></p> <p>У раду 2.2.10 приказана је примена „particle swarm” оптимизација (PSO) за оптимално пројектовање параметара комбинованог когенеративног постројења. Функција циља је</p>	M33

дефинисана као укупна сума цене коштања постројења, што је у релацији са трошковима горива и капиталним трошковима. Минимизацијом тако изабране функције добијају се оптимално пројектовани параметри.

Ćirić Ivan, Žarko Ćojbašić, Vlastimir Nikolić, Milica Ćirić, Mladen Tomić, Emina Petrović, Miloš Simonović, (2015) "Neural Network Prediction of Person Position for Human Following Mobile Robot Platform", 12th International Conference on Accomplishments in Electrical and Mechanical Engineering and Information Technology DEMI 2015, Banjaluka, BiH

Кратак опис садржине (до 100 речи)

- 9 Мобилна роботска платформа која прати људе задатке праћења може да оствари много успешније уколико у сваком тренутку предвиђа наредну позицију човека. На овај начин се заправо смањује област претраге слике наредног фрејма у коме ће се наћи човек, што значајно убрзава извршење самог алгорита препознавања и праћења људи стерео камером. Како се проблем своди на предвиђање временских серија, у овом раду је предложено решење засновано на имплементацији неуронске мреже за ово предвиђање.

M33

НАПОМЕНА: уколико је кандидат објавио више од 3 рада, додати нове редове у овај део документа

ИСПУЊЕНОСТ УСЛОВА ЗА ОДБРАНУ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Кандидат испуњава услове за оцену и одбрану докторске дисертације који су предвиђени Законом о високом образовању, Статутом Универзитета и Статутом Факултета.

ДА

НЕ

Образложење

Кандидат је магистар техничких наука, има одобрену тему докторске дисертације, објавио је већи број научних и стручних радова и поднео докторску дисертацију одговарајуће садржине, обима и квалитета, у складу са одобреном темом докторске дисертације.

ВРЕДНОВАЊЕ ПОЈЕДИНИХ ДЕЛОВА ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Кратак опис појединих делова дисертације (до 500 речи)

Разматрана теза састоји се из 7 поглавља. Претходе им резиме на српском и енглеском језику, садржај и листе табела и слика. На крају се налази списак 160 референци и биографија аутора.

У уводном делу дате су уводне напомене о предмету истраживања и дат је кратак приказ истраживања спроведених у оквиру дисертације.

У оквиру другог поглавља дати су основни појмови о вештачким неуронским мрежама, њихова подела по различитим критеријумима и области примене. Детаљније су описане архитектуре најчешће заступљених неуронских мрежа feedforward мрежа, вишеслојних перцептрона, RBF неуронских мрежа, рекурентних неуронских мрежа Elman и Hopfield. Такође је дат детаљнији опис алгоритама за учење горе наведених неуронских мрежа, респективно. Посебно су истакнуте карактеристике неуронских мрежа и приказане једначине понашања.

У оквиру трећег поглавља дат је преглед вештачких неуронских мрежа за предвиђање. Најпре је дат детаљан опис предвиђања временских серија а затим посебан осврт на карактеристике вештачких неуронских мрежа које их препоручују управо за предвиђање. У посебном делу овог поглавља су детаљно описане основне карактеристике и начин избора истих вештачких неуронских мрежа: архитектура, број улазних чворова, избор активационе функције, обрада улазних података, одређивање броја неурона у скривеним слојевима итд. Поред тога дат је историјски приказ коришћења вештачких неуронских мрежа за предвиђање са адекватном упоредном анализом. У последњем делу овог поглавља обрађене су вештачке неуронске мреже за краткорочно предвиђање са посебним освртом на преглед мрежа за краткорочно предвиђање топлотног оптерећења код система даљинског грејања.

У оквиру четвртог поглавља дат је општи опис система даљинског грејања. Приказане су основне карактеристике система даљинског грејања као што су топлотно оптерећење и температуре. Посебно су описани топлотни извори. У овој дисертацији користе се стварни подаци преузети са четири топлотна извора: Топлана "Криви вир", Ниш, Топлана "Машински факултет", Ниш, Топлана "Клинички центар", Ниш и Топлана "Коњарник", Београд. Реч је о четири топлотна извора различитих капацитета и различитих потреба потрошача. Заједничко је да су прибављени подаци за по једну грејну сезону како би каснија компаративна анализа била адекватна. У овом делу је дата анализа карактеристика система даљинског грејања за топлотне изворе појединачно, почев од минималне, максималне и средње дневне спољне температуре. топлотног оптерећења односно снаге за сваки сат дневно и њихових међусобних

зависности што представља основу за следеће поглавље и примену одговарајућих метода на тако уређене податке. Дат је табеларни приказ за 6 карактеристика које су важне за израду модела вештачке неуронске мреже за краткорочно предвиђање.

У петом поглављу је дат приказ примењених вештачких неуронских мрежа за краткорочно предвиђање код система даљинског грејања. Искоришћене су вишеслојна феедфорвард неуронска мрежа и Елман рекурентна неуронска мрежа, као стандардни типови неуронских мрежа. Оне су примењене на сваки од четири скупа података добијених са топлотних извора. Дата је анализа улазних променљивих као најважнији део алгорита за краткорочно предвиђање, због своје нелинеарности јер поред температурне садржи и социјалну компоненту. При томе је свака од мрежа реализована са три различита улазна вектора за два различита тест периода предвиђања. На тај начин су добијени симулациони резултати за 72 неуронске мреже по топлотном извору. Предвиђање је рађено за 1, 3 и 7 дана унапред. Ради побољшања тачности предвиђања оптерећења у пиковима у данима где се прекида испорука топлотне енергије због великих температурних разлика а на основу анализе урађене у претходном поглављу уведен је нови улаз у виду минималне дневне температуре. Такође, помоћу PSO алгорита извршена је оптимизација тежинских коефицијената а користећи GA извршена оптимизација броја неурона у скривеном слоју. Нове модификоване, побољшане неуронске мреже се поново реализују на подацима са топлотних извора и добијају одговарајући резултати симулација.

У шестом поглављу је извршена компаративна анализа добијених симулационих резултата и успостављен алгоритам за предложене неуронске мреже. Посебан осврт је дат упоредној анализи између резултата предвиђања добијених са прва три улазна вектора и након увођења новог улаза ради побољшања карактеристика у прелазним режимима грејања.

У седмом поглављу су дата закључна разматрања и сумирање резултата истраживања, истиче се научни допринос докторске дисертације и предлажу правци даљег истраживања.

На крају је дат списак коришћене литературе и биографија кандидата.

ВРЕДНОВАЊЕ РЕЗУЛТАТА ДОКТОРСKE ДИСЕРТАЦИЈЕ

Ниво остваривања постављених циљева из пријаве докторске дисертације (до 200 речи)

Циљеви постављени у пријави докторске дисертације су остварени, уз поштовање предложеног оквирног садржаја дисертације.

Представљена истраживања су по садржају обухватала више актуелних научноистраживачких праваца од вештачких неуронских мрежа, методе PSO и генетских алгоритама до филтрирања података, и коришћења сазнања о самој природи проблема даљинског грејања. Резултати истраживања представљени у разматраној тези потврђују да је применом савремених метода и алгоритама из домена вештачке интелигенције могуће реализовати краткорочно предвиђање временских серија код система даљинског грејања и то пре свега топлотног оптерећења и снаге на топлотном извору али и значајних температура.

Вредновање значаја и научног доприноса резултата дисертације (до 200 речи)

Обрађивана тема докторске дисертације је веома значајна и актуелна, како у научном смислу, тако и смислу практичне применљивости. Поднета докторска дисертација представља оригиналан и вредан научни и стручни допринос кандидата. Научни допринос разматраног рукописа и објављених радова се пре свега огледа у следећем:

- Дефинисана је методологија примене вештачких неуронских мрежа за предвиђање топлотног оптерећења која у фокус ставља избор адекватног улазног вектора ;
- Представљена је методологија избора модификованих улазних вектора на основу анализе карактеристика самих система даљинског грејања;
- Нови алгоритам компарације за примену вештачких неуронских мрежа за краткорочно предвиђање код система даљинског грејања
- Нови целовити алгоритам правила и процедура избора, пројектовања и имплементације вештачке неуронске мреже за краткорочно предвиђање код система даљинског грејања
- Добијени резултати омогућују бољу аутономију и поузданост система даљинског грејања са аспекта ефикасности и ефективности

Оцена самосталности научног рада кандидата (до 100 речи)

Кандидат мр Милош Симоновић показао је значајно теоријско и практично знање, као и висок ниво самосталности, систематичности и креативности у бављењу научно-истраживачким радом. Кандидат је приказао детаљну, свеобухватну и квалитетну анализу постојеће научне литературе из области теме докторске дисертације. Познавање литературе и стечена знања из више области је искористио да на креативан начин осмисли, формулише и примени научни приступ примене вештачких неуронских мрежа за краткорочно предвиђање временских серија. Креирао је одговарајуће улазне векторе и алгоритме који омогућавају примену предложених методологија.

Неки од научних резултата представљених у разматраној тези презентирани су у оквиру већег броја научних радова који су штампани у часописима и представљени на међународним и домаћим конференцијама, те штампани у зборницима радова.

ЗАКЉУЧАК (до 100 речи)

На основу прегледа поднете радне верзије докторске дисертације и увидом у публиковане научне радове кандидата, чланови Комисије за оцену и одбрану докторске дисертације закључују следеће:

- Поднети рукопис одговара теми докторске дисертације одобреној од стране Наставно научног већа Машинског факултета у Нишу и Научно стручног већа Универзитета у Нишу.
- Докторска дисертација представља оригиналан и вредан научни и стручни допринос веома актуелној и значајној проблематици примене вештачких неуронских мрежа за краткорочно предвиђање код система даљинског грејања
- Научни допринос и оригиналност дисертације показани су објављивањем већег броја радова.
- Докторска дисертација је адекватно конципирана и технички квалитетно урађена.
- Резултати приказаног научног рада имају висок степен општости и применљивости.
- Кандидат поседује висок ниво теоријских и практичних знања из више области потребних за решавање комплексних проблема примене вештачких неуронских мрежа за предвиђање а и добро је упознат са досадашњим научним достигнућима.
- Кандидат је показао висок ниво самосталности и систематичности у бављењу научно-истраживачким радом, као и креативан приступ формулацији и решавању разматраних проблема.



Имајући у виду напред наведено, Комисија предлаже Наставно научног већу Машинског факултета у Нишу да се поднети рукопис кандидата **мр Милоша Симоновића**, дипломираног инжењера машинства, под називом:

„ПРИМЕНА ВЕШТАЧКИХ НЕУРОНСКИХ МРЕЖА ЗА КРАТКОРОЧНО ПРЕДВИЂАЊЕ И АНАЛИЗУ СИСТЕМА ДАЉИНСКОГ ГРЕЈАЊА“

прихвати као докторска дисертација, а кандидат позове на усмену јавну одбрану.

КОМИСИЈА

Број одлуке ННВ о именовану Комисије		НСВ 8/20-01-003/16-030	
Датум именовања Комисије		18.04.2016. године	
Р. бр.	Име и презиме, звање		Потпис
1.	др Властимир Николић, редовни професор		председник, ментор
	Аутоматско управљање и роботика (Научна област)	Универзитет у Нишу, Машински факултет (Установа у којој је запослен)	
2.	др Драган Антић, редовни професор		члан
	Аутоматика (Научна област)	Универзитет у Нишу, Електронски факултет (Установа у којој је запослен)	
3.	др Жарко Ђојбашић, редовни професор		члан
	Аутоматско управљање и роботика (Научна област)	Универзитет у Нишу, Машински факултет (Установа у којој је запослен)	

	др Михајло Стојчић, ванредни професор	члан	
4.	Мехатроника и роботика (Научна област)	Универзитет у Бања Луци, Машински факултет (Установа у којој је запослен)	
	др Дејан Митровић, ванредни професор	члан	
5.	Термотехника, термоенергетика и процесна техника (Научна област)	Универзитет у Нишу, Машински факултет (Установа у којој је запослен)	

Датум и место:
У Нишу, мај 2016

ЗАПИСНИК

са усмене одбране докторске дисертације мр Милоша Симоновића, дипломираног инжењера машинства, одржане 13. јула 2016. године на Машинском факултету у Нишу.

Одбрана докторске дисертације почела је у 12⁰⁰ часова уводним излагањем Председника Комисије, који је саопштио основне биографске податке о кандидату, ток поступка израде докторске дисертације као и Извештај Комисије за оцену и одбрану докторске дисертације.

Кандидат је пристунио излагању докторске дисертације, изнесећи методологију рада и постигнуте резултате до којих је дошао.

После завршеног усменог излагања кандидата, чланови Комисије су поставили више питања на које је кандидат дао одговоре.

Одбрана је завршена у 14 часова.

На основу усмене одбране, одговора кандидата на постављена питања чланова Комисије и на основу Одлуке о усвајању Извештаја Наставно-научног већа Факултета и Научно-стручног већа за техничко-технолошке науке Универзитета у Нишу, чланови Комисије су једногласно донели

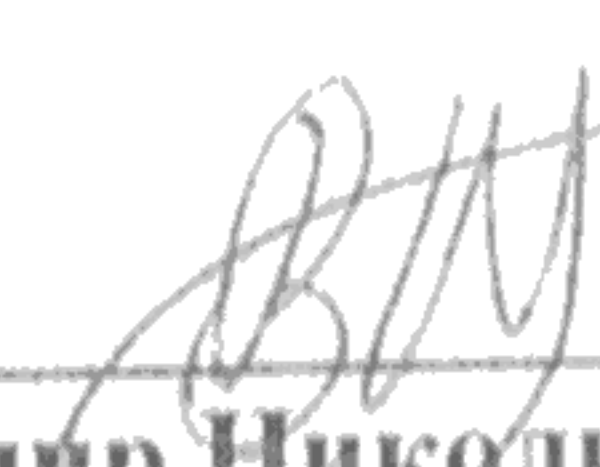
О Д Л У К У


мр Милош Симоновић, дипломирани инжењер машинства, одбранио је докторску дисертацију под називом:

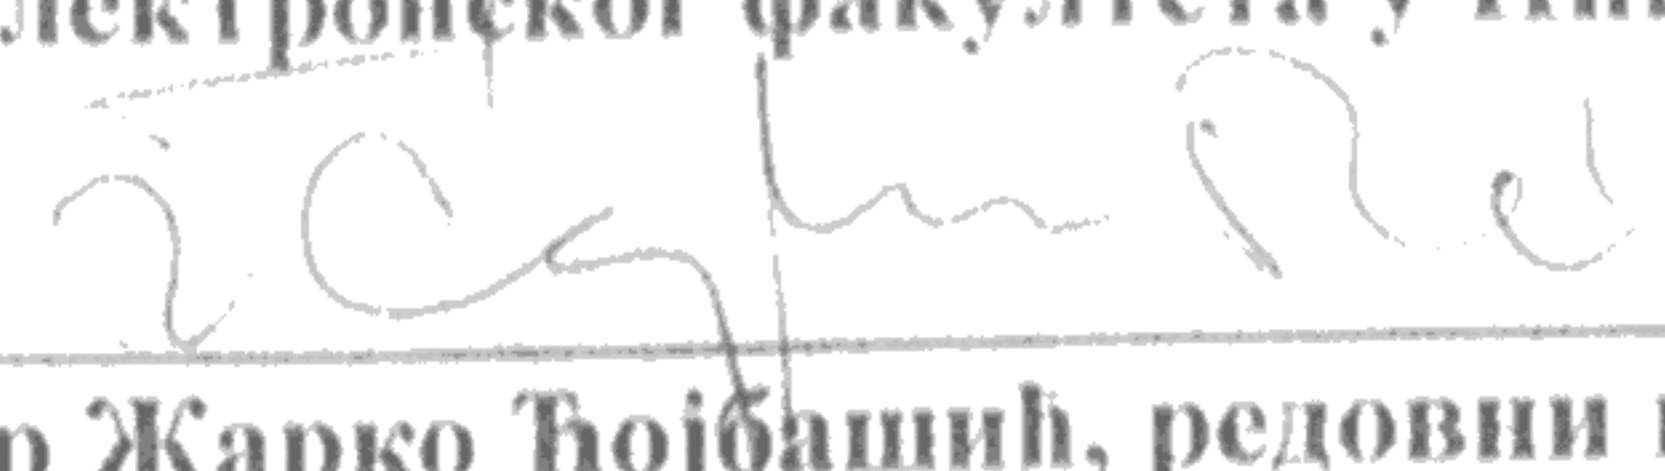
„ПРИМЕНА ВЕШТАЧКИХ НЕУРОНСКИХ МРЕЖА ЗА КРАТКОРОЧНО ПРЕДВИЂАЊЕ И АНАЛИЗУ СИСТЕМА ДАЉИНСКОГ ГРЕЈАЊА“

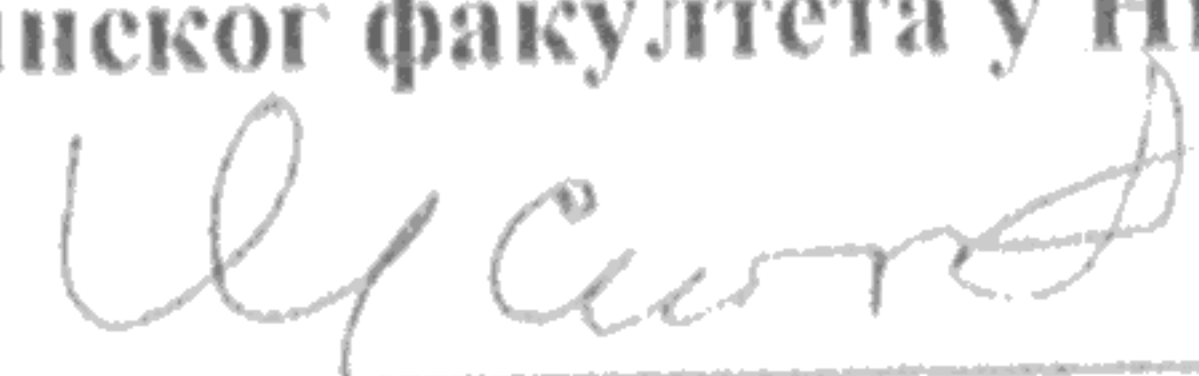
и стекао право да буде промовисан у научни степен

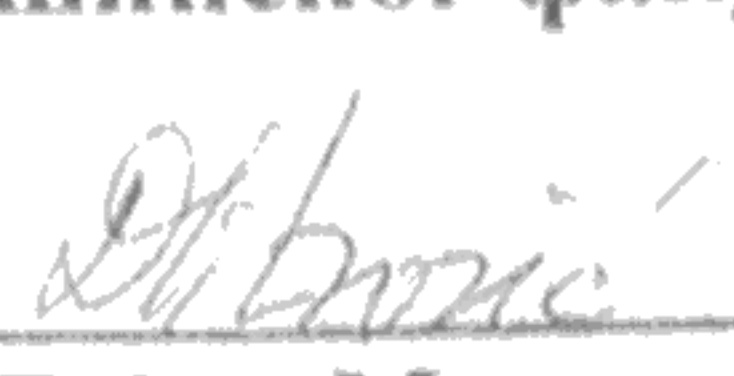
ДОКТОР ТЕХНИЧКИХ НАУКА


др Властимир Николић, редовни професор
Машинског факултета у Нишу


др Драган Антић, редовни професор
Електронског факултета у Нишу


др Жарко Ђојбашић, редовни професор
Машинског факултета у Нишу


др Михајло Стојчић, ванредни професор
Машинског факултета у Бања Луци


др Дејан Митровић, ванредни професор
Машинског факултета у Нишу