

PLANIRANJE OPTIMALNOG POGONA DISTRIBUIRANE PROIZVODNJE HIBRIDNOM METODOM

Vukobratović, Marko

Doctoral thesis / Disertacija

2018

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

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:823236>

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

Download date / Datum preuzimanja: **2024-11-23**

Repository / Repozitorij:

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



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

Marko Vukobratović

**PLANIRANJE OPTIMALNOG POGONA DISTRIBUIRANE
PROIZVODNJE HIBRIDNOM METODOM**

Doktorska disertacija

Osijek, 2018.

Doktorska disertacija izrađena je na Zavodu za elektroenergetiku Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Mentor: prof.dr.sc. Srete Nikolovski

Doktorska disertacija ima 202 stranice.

Disertacija br.: 64

Povjerenstvo za ocjenu doktorske disertacije:

1. prof.dr.sc. *Damir Šljivac*, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, predsjednik Povjerenstva
2. prof.dr.sc. *Srete Nikolovski*, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, mentor
3. doc.dr.sc. *Marinko Barukčić*, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, sumentor
4. prof.dr.sc. *Ivica Pavić*, Fakultet elektrotehnike i računarstva Zagreb, član
5. doc.dr.sc. *Krešimir Fekete*, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, član

Povjerenstvo za obranu doktorske disertacije:

1. prof.dr.sc. *Damir Šljivac*, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, predsjednik Povjerenstva
2. prof.dr.sc. *Srete Nikolovski*, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, mentor
3. doc.dr.sc. *Marinko Barukčić*, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, sumentor
4. prof.dr.sc. *Ivica Pavić*, Fakultet elektrotehnike i računarstva Zagreb, član
5. doc.dr.sc. *Krešimir Fekete*, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, član

Datum obrane doktorske disertacije: 16. travnja 2018.

Hvala mojim najmilijima, supruzi i djeci, na beskonačnoj potpori i razumijevanju...

Sadržaj

1.	Uvod.....	1
1.1.	Opis problema	2
1.2.	Motivacija za istraživanje	3
1.3.	Cilj disertacije	4
1.4.	Hipoteza	4
1.5.	Organizacija i struktura disertacije	5
2.	Pregled literature i područja istraživanja	7
2.1.	Utjecaj distribuirane proizvodnje na distributivnu mrežu.....	9
2.2.	Optimalno planiranje distribuirane proizvodnje u distributivnoj mreži.....	13
2.3.	Optimiziranje pogona distribuirane proizvodnje u aktivnoj distributivnoj mreži.....	30
2.4.	Predviđanje proizvodnje i potrošnje električne energije	40
2.4.1.	Predviđanje proizvodnje električne energije iz sunčanih elektrana	41
2.4.2.	Predviđanje potrošnje električne energije	43
3.	Modeliranje elemenata mreže i proračun tokova snaga.....	47
3.1.	<i>MATPOWER</i> ® simulacijski paket	50
3.2.	Modeliranje elektroenergetskog sustava	52
3.2.1.	Modeliranje vodova i transformatora	53
3.2.2.	Modeliranje potrošača	54
3.2.3.	Modeliranje proizvodnje	55
3.3.	Proračun tokova snaga	57
4.	Računalna inteligencija i primjena u elektroenergetici.....	60
4.1.	Uvodna razmatranja	62
4.2.	Umjetne neuronske mreže.....	64
4.2.1.	Neuron umjetne neuronske mreže.....	65
4.2.2.	Adaptivni linearni model neurona.....	66
4.2.3.	Povratna veza i učenje neurona.....	68
4.2.4.	Ustrojstvo umjetnih neuronskih mreža	69
4.2.5.	Povratna veza i učenje umjetne neuronske mreže.....	72
4.3.	Sustavi neizrazite logike	75
4.3.1.	Funkcije pripadnosti	77
4.4.	Evolucijsko programiranje	79
4.4.1.	Genetski algoritam	83

4.5.	Inteligencija roja čestica.....	87
4.5.1.	Model djelovanja.....	91
4.6.	Hibridne metode.....	96
5.	Algoritam kratkoročnog planiranja pogona distribuiranih izvora	99
5.1.	Planiranje proizvodnje sunčanih elektrana	101
5.2.	Hibridna metoda za planiranje optimalnog pogona distribuiranih izvora.....	105
5.2.1.	Posebnost predloženog postupka i načelo izolacije	111
5.2.2.	Promjene parametara čestica.....	113
5.2.3.	Funkcije cilja i model njihove integracije	114
5.2.4.	Ograničenja i kriterij završetka optimizacijske metode	115
5.2.5.	Prikaz predložene optimizacijske metode	117
5.3.	Rasuđivanje prilikom planiranja optimalnog pogona,	119
5.3.1.	Kriteriji pripadnosti	120
6.	Rezultati određivanja optimalnog pogona distribuiranih izvora razvijenom hibridnom metodom	124
6.1.	Primjeri ispitnih sustava korištenih u simulacijama	126
6.1.1.	Ispitni sustav zasnovan na <i>IEEE</i> ispitnom sustavu od 30 čvorova	126
6.1.2.	<i>IEEE</i> ispitni sustav od 57 čvorova	129
6.1.3.	Radikalni <i>IEEE</i> ispitni sustav od 33 čvora.....	131
6.2.	Određivanje parametara optimizacije	133
6.3.	Rezultati simulacije i prikaz rješenja	135
6.3.1.	Rezultati za ispitni sustav od 30 čvorova.....	136
6.3.2.	Rezultati za <i>IEEE</i> ispitni sustav od 57 čvorova	143
6.3.3.	Rezultati za radikalni <i>IEEE</i> ispitni sustav od 33 čvora.....	147
6.4.	Rasuđivanje o rješenjima	152
7.	Mogućnosti za buduće istraživanje.....	156
8.	Zaključak	158
	Literatura	159
	Popis slika	193
	Popis tablica	196
	Sažetak	198
	Abstract	199
	Životopis.....	200

1. Uvod

"Ako sam i vidio dalje od drugih, to je zato što sam stajao na ramenima divova."

Isaac Newton, 15. veljače 1676.

Globalni rastući trend potreba za električnom energijom ubrzao je razvoj tehnologija proizvodnje električne energije iz obnovljivih izvora i povećao stupanj primjene manjih proizvodnih jedinica, često geografski gušće distribuiranih i zastupljenijih u elektroenergetskom sustavu. Povećan udio distribuirane proizvodnje i napuštanje ulančanog obrasca elektroenergetskog sustava, *proizvodnja-prijenos-distribucija*, donosi nove izazove koji nisu uvijek prepoznati u svojoj ukupnosti. Konačni ishod kontinuiranog povećanja zastupljenosti distribuirane proizvodnje u elektroenergetskom sustavu biti će nastajanje novog obrasca *proizvodnja-prijenos-distribucija-distribuirana proizvodnja* koji podrazumijeva u potpunosti aktivnu distribucijsku mrežu. Zbog procesa *aktivacije* distribucijske mreže pojavljuju se brojni tehnički, ekonomski i regulativni izazovi koji su predmet proučavanja struke i znanosti. Istraživanja koja danas ponude odgovore na izazove budućnosti postaviti će okvire i smjer razvoja novih rješenja čija primjena se ima očekivati.

U potpunosti aktivna distribucijska mreža podrazumijeva iznimno velik broj jedinica distribuirane proizvodnje, različitih snaga, tehnologija, ograničenja i načela primjene, zbog čega je ispravno djelovanje takve elektroenergetske mreže visoko složen proces kojeg je potrebno kontinuirano optimirati. Pojedine tehnologije proizvodnje električne energije iz obnovljivih izvora sadrže nepredvidivu vremensku promjenjivost parametara proizvodnje, što predstavlja dodatni izazov ispravnom djelovanju elektroenergetskog sustava. Znanstveni radovi čiji je pregled dan u ovoj doktorskoj disertaciji proučavaju probleme prepoznate u procesu promjene obrasca djelovanja elektroenergetskog sustava te se s tehničkog, ekonomskog i regulativnog motrišta osvrću na trenutni trend razvoja elektroenergetike.

Znanstveno istraživanje predstavljeno ovom doktorskom disertacijom obuhvaća teorijska razmatranja usmjerena u etapu razvoja nakon procesa *aktivacije* distribucijske mreže te izučava okolnosti prilikom potpune promjene obrasca djelovanja elektroenergetskog sustava. Prema znanjima dostupnih autoru, a koja su predstavljena u disertaciji, izazovi potpuno aktivnih distributivnih mreža sa različitim tehnologijama distribuirane proizvodnje trenutno nisu u središtu razmatranja znanstvenika iz zajedničke interesne sfere i znanstvenog područja. Prepoznati izazov

koji je do sada neprepoznat u znanstvenom području začetak je spoznajnog procesa znanstveno-istraživačkog rada. Ponuditi odgovarajući model njegova rješavanja najveći je stupanj znanstvene spoznaje, a postavljanje okvira i smjernica modelskog rješenja dio je razvojnih stupnjeva, napretka i nazatka u ciklusu znanstveno-istraživačkog rada.

Ovom doktorskom disertacijom utvrđuje se determinirani problem planiranja optimalnog pogona distribuirane proizvodnje u potpuno aktivnoj distribucijskoj mreži, predstavlja se spoznajni proces postavljanja smjera i okvira za razvoj hibridne optimizacijske metode te se nudi model algoritma kratkoročnog planiranja koji sadrži cjeline predviđanja proizvodnje, optimizacije pogona i ocjene pogonskih uvjeta. Sve cjeline ponuđenog algoritma zasnivane su na metodama računalne inteligencije koje su početkom znanstveno-istraživačkog rada autora prepoznate kao prikladne sa razvoj naprednih rješenja.

1.1. Opis problema

Aktivna distribucijska mreža podrazumijeva integraciju distribuirane proizvodnje koja uzrokuje značajne promjene tehničkih svojstava elektroenergetske mreže. Distribuirana proizvodnja razlikuje se u mogućnostima proizvodnje električne energije vidljive kroz razlike u snazi, upravljivosti, tehnologiji korištenja primarnog energenta, raspoloživosti i dostupnosti energenta te mogućnošću planiranja.

Visoki stupanj primjene distribuirane proizvodnje, često regulativno potican, rezultirati će potpuno aktivnom distributivnom mrežom koja u svakom čvoru posjeduje najmanje jedan izvor električne energije, različitih tehnologija primjene po čvorovima i različitih svojstava proizvodnje. U krajnjoj mjeri, potpuno aktivna distribucijska mreža je složen sustav sa primijenjenim svim tehnologijama distribuirane proizvodnje, različitih snaga i odnosa unutar elektroenergetskog sustava. Iako je trenutno izgledno kako će do sveopće pojave visoko aktivne distribucijske mreže proći, možda, desetljeća, manji ispitni sustavi postoje u razvijenim zemljama svijeta, a mnogi znanstveno-istraživački ili komercijalno-razvojni projekti istražuju to specifično područje.

Znanstveno istraživanje predstavljeno ovom doktorskom disertacijom promatra tek prepoznati izazov optimiranja pogona distribuirane proizvodnje visoko primijenjene u potpuno aktivnoj distribucijskoj mreži. Za potrebe određivanja okvira promatranog izazova izučavaju se dvije tehnologije distribuirane proizvodnje integrirane u istom čvoru: neupravljive sunčane elektrane fotonaponske pretvorbe čija je proizvodnja električne energije vremenski promjenjiva te upravljive elektrane koje električnu energiju proizvode sinkronim generatorom, a kao primarni

energent koriste kruto, tekuće ili plinsko gorivo obnovljivih ili neobnovljivih izvora. Opisanim pristupom smanjuju se nedostaci pojedinih tehnologija, a sinergijsko djelovanje takvog sustava naziva se hibridnim distribuiranim izvorom. U opisanom istraživanju pretpostavlja se kako potpuno aktivna elektroenergetska mreža sadrži navedeni hibridni distribuirani izvor u svakom čvoru. Pogon takvih distribuiranih izvora značajan je izazov jer se istovremeno moraju uvažiti dva cilja: vođenja pogona uz najmanje gubitke, prihvatljive troškove, poštivanje tehničkih i zakonskih ograničenja te cilj visoke integracije distribuirane proizvodnje uz poštivanje vremenske promjenjivosti tehnologije sunčanih elektrana. Sveobuhvatno rješenje navedenog izazova predloženo je algoritmom kratkoročnog planiranja pogona distribuiranih izvora čiji je najznačajniji dio hibridna metoda za planiranje optimalnog pogona distribuiranih izvora. Kako su motrišta na ciljeve promatranog problema suprotstavljena, jer istovremeno zadovoljenje visokog stupnja primjene distribuirane proizvodnje, postizanja najmanjih gubitaka i sve uz prihvatljive pogonske troškove nerijetko nije ostvarivo, tehničkom stanovištu pružena je prednost u razmatranjima i optimiranju te je glavni cilj hibridne optimizacijske metode predstavljene ovom doktorskom disertacijom smanjenje tehničkih gubitaka radne snage. Unutar tehničkog stajališta prilikom promatranja prikazanog problema integrirani su regulativni ciljevi o visokom stupnju primjene distribuirane proizvodnje jer je u širim strukovnim razmatranjima takva primjena tehnički opravdana. Tek pošto su tehnički gubici radne snage značajno smanjeni, pristupa se troškovnom rasuđivanju o planiranim pogonskim uvjetima.

1.2. Motivacija za istraživanje

Intuitivno razmišljanje o svrhovitosti istraživanja potvrđuje se izučavanjem obilježja iz područja istraživanja u trenutnim europskim i svjetskim istraživačkim aktivnostima. Radna grupa za napredne elektroenergetske mreže Europske komisije (engl. *Smart Grids Task Force*) od 2009. godine kontinuirano izdaje smjernice za razvoj suvremenih elektroenergetskih sustava [1]. Napredni elektroenergetski sustavi podrazumijevaju određeni stupanj *aktivacije* distribuiranom proizvodnjom, ali i primjenu tehnologija za nadzor, upravljanje, regulaciju proizvodnje i potrošnje primjenom informacijskih tehnologija koje nisu predmet prikazanog znanstvenog istraživanja. Zajednički istraživački centar za napredne elektroenergetske sustave i međusobno djelovanje (engl. *Joint Research Centre - Smart Electricity Systems and Interoperability*) predvodi regulativna, tehnička i ekonomska istraživanja na razini zemalja Europske Unije. Prema matrici odnosa (engl. *relationship matrix*) [2] Zajedničkog istraživačkog centra zemlje koje najviše sudjeluju u istraživanjima naprednih elektroenergetskih sustava su Španjolska, Francuska, Italija, Njemačka, Ujedinjeno Kraljevstvo, Belgija i Nizozemska.

Postojanje radne skupine na tako visokoj institucionalnoj razini značajna je potvrda intuitivnog razmišljanja prilikom usmjeravanja vlastitog znanstveno-istraživačkog rada.

Uvidom u pregled identificiranih trendova Zajedničkog istraživačkog centra [3] i osvrtu europskih operatora distribucijskih sustava [4] jednostavno je zaključiti kako inovativna znanstvena istraživanja trebaju dati odgovore na izazove osmotrene u navedenoj literaturi.

Potpuno je razumljivo kako individualno znanstveno istraživanje ne može doseći visoku razinu implementacije kao istraživanja koja nadilaze institucionalne okvire te svrha i cilj predstavljenog znanstveno-istraživačkog rada nije ponuditi gotov proizvod, već modelski način rješavanja izazova kojima dolazi vrijeme aktualnosti.

1.3. Cilj disertacije

Cilj disertacije je sustavnim i jasnim prikazom spoznajnog procesa znanstveno-istraživačkog rada autora obrazložiti na koji način su ostvareni sljedeći znanstveni doprinosi:

- Hibridna metoda za planiranje optimalnog pogona distribuiranih izvora temeljena na metodi roja čestica i neizrazitoj logici.
- Algoritam kratkoročnog planiranja pogona distribuiranih izvora koji uzima u obzir samodostatnost mreže i minimizaciju gubitaka.
- Validacija predložene hibridne metode za planiranje optimalnog pogona distribuiranih izvora u odnosu na metode temeljene na genetskom algoritmu.

U nastavku doktorske disertacije detaljno se opisuju ispunjenja navedenih znanstvenih doprinosa i opisuju se načela planiranja optimalnog pogona distribuirane proizvodnje hibridnom metodom zasnovanom na metodama računalne inteligencije. Iscrpnim prikazom mogućnosti korištenih metoda računalne inteligencije uvodi se tvrdnja o upotrebljivosti pojedinih pristupa prilikom promatranja specifičnog problema.

1.4. Hipoteza

Prethodnim potpoglavljima iskazala se bitnost proučavanog područja i postavio se prepoznati novi izazov čijem rješavanju se pristupa u predstavljenom znanstvenom istraživanju. Temeljna zamisao na kojoj se zasniva prikazano znanstveno istraživanje je kako se rješenje za planiranje optimalnog pogona distribuiranih izvora u potpuno aktivnoj distributivnoj mreži može u određenoj mjeri zasnivati na rješenjima ponuđenih u znanstvenima radovima koji proučavaju postupni razvoj aktivne distributivne mreže. Postupni razvoj aktivne distributivne mreže

podrazumijeva prvobitni korak prelaska iz uobičajenog obrasca djelovanja elektroenergetskog sustava u novi obrazac, što uključuje pojavu distribuirane proizvodnje. Rješenja predstavljena sljedećim poglavljima uspješno koriste metode računalne inteligencije kako bi odredila optimalan čvor za primjenu optimalne snage distribuirane proizvodnje. U novijim znanstvenim radovima, također prikazanim u sljedećim poglavljima, određuje se veći broj optimalnih čvorova i snaga za različite tehnologije distribuirane proizvodnje.

Detaljnije pojašnjenje osnovne ideje predstavljenog znanstveno-istraživačkog rada je kako se proučavanju optimalnog pogona mnoštva hibridnih distribuiranih izvora, u potpuno aktivnoj distributivnoj mreži, može pristupiti prema sličnim načelima kao određivanju čvora i snage jedne distribuirane proizvodnje. Određivanje spomenutih načela pristupilo se početkom znanstveno-istraživačkog rada ove doktorske disertacije, a upotrijebljena i uokvirena načela potvrđena su objavom tri znanstvena rada u časopisima i jednog u zborniku *IEEE* konferencije iz područja određivanja optimalne snage i čvora za integraciju distribuirane proizvodnje. Nastavkom istraživanja su tako definirana načela u većoj ili manjoj mjeri izmijenjena, dopunjena i detaljnije profilirana. Konačni ishod postavljenih načela je jedinstvena hibridna optimizacijska metoda i hibridni algoritam kratkoročnog planiranja pogona distribuiranih izvora.

U najkraćem obliku, postavljena hipoteza glasila bi: „planiranje optimalnog pogona visokog broja distribuirane proizvodnje u potpuno aktivnoj distributivnoj mreži moguće je ostvariti primjenom metoda računalne inteligencije.“

1.5. Organizacija i struktura disertacije

Doktorska disertacija izrađena na temelju rezultata znanstveno-istraživačkog rada opisanog prethodnim potpoglavljima podijeljena je u osam poglavlja:

1. poglavlje donosi opis uočenog izazova čije rješavanje predlaže znanstveno-istraživački rad opisan ovom doktorskom disertacijom. Jezgrovitim prikazom iznose se temeljne znanstvene ideje autora u području istraživanja, obrazlaže se postavljena hipoteze i iznose se činitelji neposredne motivacije koji su utjecali na znanstveno istraživanje prikazano ovom doktorskom disertacijom.

2. poglavlje predstavlja iscrpan pregled područja istraživanja kroz osvrt na dostupne znanstvene članke objavljene u časopisima i zbornicima konferencija, znanstvene i stručne knjige, doktorske disertacije i druge vrste radova iz kategorija stručne i znanstvene literature. Navedeni

pregled prožet je autorskim mišljenjem o predstavljenoj literaturi s ciljem proširenog pojašnjenja osnovne hipoteze predstavljenog znanstveno-istraživačkog rada.

3. poglavlje donosi prikaz korištene metodologije modeliranja elektroenergetskih mreža korištenih za primjenu predložene hibridne optimizacijske metode i algoritma kratkoročnog planiranja. Naglasak ovog poglavlja stavljen je na simulacijski paketi *MATPOWER* koji se koristi za integraciju proračunskog postupka u optimizacijsku metodu te njime zadane okvire i pravila modeliranja.

4. poglavlje obrađuje temeljene činjenice o računalnoj inteligenciji i navodi razloge usmjeravanja predstavljenog znanstveno-istraživačkog rada u jedinstveni smjer područja. Ovim poglavljem iznose se komparativne prednosti i nedostaci metoda računalne inteligencije korištenih za potrebe znanstveno-istraživačkog rada opisanog ovom doktorskom disertacijom i predstavlja se spoznajni proces izrade predložene optimizacijske metode i algoritma. Dodatno, u ovom poglavlju iznose se razlozi zbog kojih je predložena hibridna optimizacijska metoda zasnovana na metodi roja čestica i razlozi zbog kojih takva metoda poboljšava kvalitetu rješenja u odnosu na rješenja dobivena metodama korištenih u prethodnim znanstvenim istraživanjima autora.

5. poglavlje sadrži opis predloženog algoritma kratkoročnog planiranja pogona distribuiranih izvora i u njemu sadržane cjeline. Jedna od cjelina sadržanih u spomenutom algoritmu je predložena hibridna metoda za planiranje optimalnog pogona distribuiranih izvora, a preostale dvije cjeline su sustav predviđanja proizvodnje sunčanih elektrana i sustav zaključivanja o rezultatima optimizacije, odnosno, sustav za donošenja konačne odluke o rješenju, povezan postupkom *hibridizacije* sa cjelinom optimizacije.

6. poglavlje se sastoji od četiri djela. Prvi dio prikazuje modele ispitnih elektroenergetskih sustava i mreža korištenih za postupak utvrđivanja teorijske i praktične valjanosti predložene metode. Drugi dio naglašava posebitost predloženog optimizacijskog postupka i parametre korištene prilikom postupaka optimizacije. Treći dio sadrži rezultate optimizacijskih postupaka predloženom hibridnom metodom za sve modele opisane u prvom djelu. Četvrti dio donosi rezultate razvijenog sustava rasuđivanja o predloženim rješenjima.

7. poglavlje pruža introspektivan pristup dosadašnjem znanstveno-istraživačkom radu autora i iznosi mogućnosti dodatnog razvoja značajnih cjelina predloženog algoritma.


8. poglavlje daje zaključna razmatranja o znanstveno-istraživačkom radu prikazanog u doktorskoj disertaciji i pruža jezgrovit opis jedinstvenog pristupa rješavanju izdvojenog izazova.

2. Pregled literature i područja istraživanja


Svrha ovog poglavlja je kritičkim osvrtom i izlaganjem recentne literature te znanstvenih radova analizirati znanstvenu opravdanost istraživanja područja primjene metoda računalne inteligencije u elektroenergetici s ciljem određivanja optimalnog pogona distribuiranih izvora potpuno aktivne distributivne mreže unutar okvira kratkoročnog planiranja. Ciljevi razmotreni kroz analizu znanstvenih radova u ovom poglavlju obuhvaćaju smanjenje gubitaka, uravnoteženje energije proizvodnje i potrošnje unutar promatranih sustava, povećanje pouzdanosti i općeniti trend razvoja naprednih mreža implementacijom upravljivih distribuiranih izvora čiju je proizvodnju moguće i potrebno planirati.

Analizom broja znanstvenih radova u priznatim bazama *ScienceDirect*, *IEEE*, *Web of Science* i *Scopus* moguće je zaključiti kako znanstvena razmatranja o zajedničkom djelovanju računalne inteligencije i postupaka matematičkog modeliranja elektroenergetskog sustava značajno postaju zastupljena u proteklih sedam do osam godina. Detaljnim pregledom znanstvenih radova jasno je kako se većina radova bavi optimalnim smještajem distribuirane proizvodnje u elektroenergetskoj mreži prilagođavajući neku od poznatih metoda računalne inteligencije specifičnom problemu. Uvažavajući usku specijaliziranost promatranog područja planiranja optimalnog pogona značajnog broja distribuiranih izvora razumno je ne očekivati iznimno velik broj znanstvenih radova koji se izričito bave navedenom tematikom, ali je iz radova bliskih traženom području moguće naslutiti smjer razvoja i istraživanja. Naime, znanstveni radovi koji određenim postupkom računalne inteligencije rješavaju specifičan problem optimalnog smještaja distribuirane proizvodnje u distributivnoj mreži mogu poslužiti kao temelj razvoja novog postupka za kratkoročno planiranje pogona većeg broja distribuiranih izvora potpuno aktivne distributivne mreže uvažavajući već spomenute ciljeve. Značajni pregledni znanstveni članci iz čijih se redova može naslutiti budući trend uporabe računalne inteligencije u elektroenergetici su rad autora Theo et al. [5], Pesaran et al. [6] i autora Ruiz-Romero et al. [7]. Broj radova objavljenih u znanstvenoj bazi *ScienceDirect* iz polja elektrotehnike i smjera elektroenergetike koji uspješno implementiraju neku od metoda računalne inteligencije s ciljem rješavanja složenih inženjerskih problema prikaza je slikom 2.1., a broj takvih radova objavljenih u bazi *Scopus* prikazan je slikom 2.2. Sa slika 2.1. i 2.2. razvidan je porast broja radova u zadnjih pet godina, međutim složenost mnogobrojnih problema naprednih distributivnih mreža sa velikim brojem distribuiranih izvora različitih karakteristika uzrokovala je značajan porast broja radova u bazi *ScienceDirect* i blagi pad broja radova u bazi *Scopus*. Naime, *Scopus* baza obuhvaća sve časopise indeksirane u navedenoj bazi,

dok *ScienceDirect* baza obuhvaća samo časopise nakladnika *Elsevier*. Uzevši u obzir kategorizaciju znanstvenih baza u Republici Hrvatskoj moguće je zaključiti kako kvaliteta novih objavljenih radova i složenost promatranih problema postaje sve veća.



Slika 2.1. Broj radova iz promatranog područja objavljenih u bazi ScienceDirect



Slika 2.2. Broj radova iz promatranog područja objavljenih u bazi Scopus

Ovo poglavlje sastoji se od četiri cjeline: u potpoglavlju 2.1. iznose se kvalitetni radovi kojima se definira distribuirana proizvodnja i njen utjecaj na distributivnu mrežu; u potpoglavlju

2.2. prikazani su značajni radovi koji rješavaju identificirane probleme optimalnog planiranja distribuirane proizvodnje, najčešće sa stajališta optimalnog smještaja i snage elektrane, koristeći ili razvijajući pri tome neku od metoda računalne inteligencije; potpoglavljem 2.3. opisani su trenutno dostupni radovi koji pretpostavljaju zakonitosti optimizacije cjelokupnog pogona aktivne distributivne mreže sa velikim brojem distribuirane proizvodnje; svrhoviti radovi koji obrađuju temu planiranja potrošnje i proizvodnje nekom od metoda računalne inteligencije prikazani su u potpoglavlju 2.4..

2.1. Utjecaj distribuirane proizvodnje na distributivnu mrežu

Distribuirana proizvodnja je poznati koncept i načelna svojstva poznata su gotovo stotinu godina [8]. Porast energetske potrebe u svijetu, popraćen porastom cijena energenata, ubrzale su razvoj tehnologije za korištenje obnovljivih i neobnovljivih izvora energije te učinile mogućim porast zastupljenosti distribuirane proizvodnje u elektroenergetskom sustavu. Jednoznačna definicija distribuirane proizvodnje na međunarodnoj razini ne postoji, čak se i nazivlje istog poznatog pojma zna mijenjati ovisno o kontekstu i podnebljima te je moguće naići na pojmove *ugrađene proizvodnje*, *raspršene proizvodnje*, *distribuiranih izvora energije*, *decentralizirane proizvodnje* itd. Međutim, priključak elektrane na distributivnu mrežu se može istaknuti kao zajedničko svojstvo svih definicija. Iz rada autora Ackermann et al. [9] moguće je generalno definirati distribuiranu proizvodnju kao izvor električne energije priključen na distributivnu elektroenergetsku mrežu, po mogućnosti u blizini potrošača, bez jasno naznačenog ograničenja u instaliranoj snazi, bez strogog definiranja pogonskog energenta, bez ograničenja prostornog utjecaja i bez zahtjeva po pitanju načina rada. Autori međutim navode više izvora koji zasebno definiraju distribuiranu proizvodnju prema instaliranoj snazi, a koja se generalno može definirati intervalom od nekoliko kilovata do stotinu megavata. Dodatno, distribuirana proizvodnja prema autorima [9] može u posljednje vrijeme koristiti neobnovljive ili obnovljive izvore energije, posjedovati mogućnost upravljanja, sudjelovati u tržištu električne energije i pozitivno utjecati na okoliš.

Prema hrvatskom zakonodavnom okviru elektrane distribuirane proizvodnje koje podrazumijevaju priključak na distributivnu mrežu se mogu prema instaliranoj električnoj snazi podijeliti u kategorije mikro-elektrana (do 50 kW), malih (do 1 MW) i srednjih elektrana (do 35 MW) [10]. Elektrane čija instalirana snaga prelazi instaliranu električnu snagu od 35 MW se u pravilu priključuju na prijenosnu mrežu. Podjela distribuirane proizvodnje prema instaliranoj snazi koja će se koristiti u ovom radu preuzeta je iz preglednog članka autora Viral et al. [11] u kojem se navodi slična podjela: mikro-distribuirana proizvodnja do 5 kW, mala distribuirana proizvodnja

do 5 MW, srednja distribuirana proizvodnja do 50 MW i velika distribuirana proizvodnja od 50 MW do 300 MW. Isti autori izričito navode namjenu distribuirane proizvodnje u osiguranju temeljna snage u sustavu, pokrivanju vršnih opterećenja i pružanju pomoćnih usluga distributivnoj mreži uz jasno pojašnjenje prednosti i izazova koje uzrokuje primjena distribuirane proizvodnje. Kao tehničke prednosti autori [11]–[17] navode rasterećenje vodova i smanjenje gubitaka, poboljšanje naponskog profila i naponske stabilnosti, povećanje energetske učinkovitosti cjelokupnog elektroenergetskog sustava, povećanje pouzdanosti elektroenergetskog sustava, unaprjeđenje pokazatelja kvalitete električne energije i smanjenje zagušenja u prijenosnom i distributivnom sustavu. Detaljniji opis utjecaja distribuirane proizvodnje na naponske propade obrađen je u radu autora Ipinnimo et al. [18] koji ukazuje posebitost utjecaja distribuirane proizvodnje na broj naponskih propada i potrebu za međusobnom koordinacijom većeg broja proizvodnih jedinica kako bi se osiguralo smanjenje broja naponskih propada.

Osim tehničkih prednosti autori [11] iznose i dodatne, posredno ekonomske, prednosti iskazane kroz mogućnost odgode ulaganja u elemente elektroenergetskog sustava i smanjenja različitih troškova vođenja elektroenergetskog sustava. Izazovi koje autori spomenutih radova [11]–[17] navode su mogući povratni tok snage prema nadređenoj elektroenergetskoj mreži, nemogućnost pojedinih tehnologija proizvodnje električne energije koje se koriste u distribuiranoj proizvodnji za proizvodnjom reaktivne snage, moguće prekomjerno povećanje naponskih razina u pripadajućoj distributivnoj mreži, nužne promjene u načinu zaštite elektroenergetskog sustava uslijed dvosmjernog toka snage i mogućeg otočnog pogona, pojava viših harmonika u elektroenergetskom sustavu specifična za pojedine tehnologije proizvodnje električne energije, utjecaj na stabilnost elektroenergetskog sustava, povećanje struja prilikom kvarova u mreži i visoki investicijski troškovi pojedinih tehnologija. Povećanje proizvodnih jedinica distribuirane proizvodnje i moguća samodostatnost distributivne mreže može prema autorima Bollen et al. [19] rezultirati slabljenjem prijenosnog sustava uzrokovanog smanjenjem potrebe za centraliziranim velikim proizvodnim jedinicama.

Viral et al. [11] definiraju dvije vrste distribuirane proizvodnje s obzirom na obuhvaćeno geografsko područje i potrošače koje opskrbljuju električnom energijom – lokalnu i krajnju distribuiranu proizvodnju. Lokalna distribuirana proizvodnja prema spomenutim autorima opskrbljuje potrošače šireg područja i sa gledišta dijela distributivne mreže obavlja ulogu centralne proizvodnje ograničenog dosega. Krajnju proizvodnju autori definiraju kao proizvodnju namijenjenu izravnoj potrošnji bliskog potrošača koji je u pravilu i odgovoran za primjenu takve proizvodnje. Distribuirana proizvodnja u cjelini sa pripadajućim potrošačima čini mikro-mrežu, a

više mikro-mreža čine aktivnu distributivnu mrežu [20] iz čega se može zaključiti kako distribuirana proizvodnja promjenom tehničkih svojstava mreže u koju se priključuje čini distributivnu mrežu aktivnom [21]. Aktivna distributivna mreža predstavlja preduvjet za razvoj naprednih distributivnih mreža (engl. *Smart Grid*), a podrazumijeva promjenu svrhe distributivne mreže iz uloge preuzimanja energije iz nadređene prijenosne mreže i opskrbu potrošača u ulogu mreže koja istovremeno može preuzimati energiju iz nadređene mreže i distribuirane proizvodnje te opskrbljivati potrošače i pri tome optimalno i ispravno djelovati [22].

Tehnologije distribuirane proizvodnje električne energije ne razlikuju se kod primjene krajnje ili lokalne distribuirane proizvodnje te mogu biti zasnivane na korištenju obnovljivih ili neobnovljivih izvora energije. Obnovljivi izvori energije podrazumijevaju elektrane na vjetar, sunčane elektrane, sunčane termalne elektrane, elektrane na biomasu ili bioplin, male hidroelektrane, elektrane koje koriste geotermalnu energiju, elektrane koje koriste energiju valova ili morskih mijena i baterijski spremnici energije, a tehnologije distribuirane proizvodnje električne energije koje koriste neobnovljive izvore energije su turbinske ili motorne elektrane na zemni plin ili tekuća goriva dobivena frakcijskom destilacijom nafte, mikro-turbine na prirodni plin, hibridne ili male gorive ćelije pogonjene prirodnim plinom ili etanolom i mikro-kogeneracije na kruta fosilna goriva, zemni plin ili tekuća goriva dobivena frakcijskom destilacijom nafte [11]. Bitna svojstva pojedinih tehnologija distribuirane proizvodnje prikazana su usporedno u radu [11] čiji sažetak je prikazan tablicom 2.1. Sa stanovišta vođenja elektroenergetskog sustava distribuirana proizvodnja zasnivana na tehnologijama neovisnim o trenutnoj dostupnosti energetske izvora smatra se temeljnom proizvodnjom u sustavu, dok se distribuirana proizvodnja zasnivana na tehnologijama ovisnim o trenutnoj dostupnosti energenta, poput sunčanih elektrana ili elektrana na vjetar, ne može smatrati temeljnom proizvodnjom [23]–[26]. Podaci o upravljivosti distribuirane proizvodnje i sudjelovanju u smanjenju vršnih opterećenja prikazani u tablici 2.1 djelomično su suprotstavljeni podacima koji se mogu pronaći u drugim znanstvenim radovima [13], [27], ali i u skladu sa radovima [28], [29] na osnovu čega je moguće zaključiti kako se tehnologije distribuirane proizvodnje koje posjeduju mogućnosti regulacije izlazne snage i pohranjivanja osnovnog energenta, mogu smatrati upravljivom distribuiranom proizvodnjom, a tehnologije distribuirane proizvodnje koje ne posjeduju takvu mogućnost, poput sunčanih elektrana ili elektrana na vjetar, ne mogu smatrati upravljivim distribuiranim izvorima. U svrhu ovog rada sunčane elektrane se smatraju neupravljivim distribuiranim izvorima, a elektrane koje za pogonski stroj posjeduju turbinu ili motor sa unutrašnjim izgaranjem se smatraju upravljivim distribuiranim izvorima, neovisno o vrsti energenta kojeg mogu koristiti.

Tablica 2.1 Pregled bitnih svojstava tehnologija distribuirane proizvodnje [11]

Vrsta tehnologije	Energent	Moguća instalirana snaga [kW]	Učinkovitost proizvodnje električne energije [%]	Ukupna učinkovitost [%]	Iznos investicije [\$/kW]	Smanjenje vršnih opterećenja	Povećanje pouzdanosti sustava	Pozitivan učinak na pokazatelje kvalitete električne energije
Motor s unutrašnjim izgaranjem	Dizelsko ili benzinsko gorivo, prirodni plin	3 – 6000+	30 - 43	~ 80 - 85	600 - 1200	Da	Da	Da
Plinska turbina s izgaranjem	Plin ili dizelsko gorivo	0,5 – 30 000	21 - 40	~ 80 - 90	400 - 900	Da	Da	Da
Mikro-turbina	Bioplin, prirodni plin	30 - 1000	14 - 30	~ 80 - 85	1200 - 1700	Da	Da	Da
Sunčane elektrane	Energija sunčevog zračenja	0,02 – 1000+	-	~ 40 - 45	4500 - 6000	Ne	Ne	Ne
Elektrane na biomasu	Biomasa	100 – 20 000	15 - 25	~ 60 - 75	1500 - 3000	Ne	Ne	Ne
Male hidro-elektrane	Energija vode	5 – 100 000	-	~ 90 - 98	10 000 – 13 000	Ne	Da	Da

2.2. Optimalno planiranje distribuirane proizvodnje u distributivnoj mreži

Planiranje optimalnog pogona distribuiranih izvora podrazumijeva postojanje aktivne distributivne mreže, a da bi distributivna mreža postala aktivna potrebna je integracija najmanje jedne distribuirane proizvodnje. Optimalna integracija jedne distribuirane proizvodnje podrazumijeva izazov određivanja snage i lokacije priključka elektrane u promatranoj distributivnoj mreži pri kojima će utjecaj distribuirane proizvodnje biti najpovoljniji, tzv. izazov optimalne raspodjele (engl. *optimal allocation*). Izazov optimalne raspodjele elektrane u distributivnu mrežu obuhvaćen je značajnim brojem radova predstavljenih u pregledu znanstvenih baza u uvodnom dijelu ovog poglavlja iz kojih je moguće zaključiti kako metode računalne inteligencije dokazano rješavaju takav izazov ispunjavajući pri tome različite ciljeve. Pojedina dokazana rješenja optimalne raspodjele jedne distribuirane proizvodnje mogu poslužiti kao osnovna zamisao oko koje nastaje rješenje optimalnog pogona većeg broja distribuiranih izvora u promatranoj distributivnoj mreži, pri čemu valja uvažiti mogućnosti i ograničenja svakog promatranog rješenja raspodjele. Iz značajnog broja znanstvenih radova potrebno je izdvojiti i objasniti radove čija rješenja svojim načelima omogućavaju razvoj nove metode za planiranje pogona distributivnih izvora u aktivnoj distributivnoj mreži. Metode prikazane u narednim radovima zahtijevaju složen pristup prilikom oblikovanja programskog rješenja za izvršavanje potrebnih simulacija i proračuna te je iznimno bitno detaljno razlučiti u literaturi načine i procedure koje je moguće nadgraditi.

Prilikom rješavanja problema optimalne raspodjele distribuirane proizvodnje potrebno je razmotriti prednosti i nedostatke mogućeg utjecaja elektrane na distributivnu mrežu. Nerijetko se u početku formiranja aktivne distributivne mreže lokacija i snaga elektrane ne određuju postupkom optimizacije, već mreža postane aktivna gotovo nasumičnom pojavom distribuirane proizvodnje u nekom čvoru promatrane mreže određenom nekim drugim kriterijem, interesom ili zahtjevom drugog čimbenika poput investitora u određenu tehnologiju, značajnog potrošača itd. Porastom broja distribuirane proizvodnje temeljene na različitim tehnologijama zajednički utjecaj svih elektrana biva veći u promatranom sustavu što uzrokuje promjenu u načelima integracije novih elektrana i potrebu za optimalnom raspodjelom. Tijekom razvoja neaktivne distributivne mreže u aktivnu moguće je unaprijed odrediti optimalnu raspodjelu željene distribuirane proizvodnje, a u potpuno aktivnoj distribuiranoj mreži potrebno je planirati pogon mnoštva distribuiranih izvora u realnom ili kvazi-realnom vremenu uvažavajući tehničke odrednice optimalnog pogona koje mogu biti zahtjevi potrošača, zahtjevi za naponskim razinama, dostupnost energenata, mogućnost opskrbe iz nadređene mreže, tehnička ograničenja opreme itd.

Optimalno planiranje rada distribuiranih izvora u potpuno aktivnoj distributivnoj mreži predstavlja suvremeni izazov za operatora distributivnog sustava čija distributivna mreža nije nužno predviđena za prihvaćanje velikog broja elektrana različitih tehnologija niti za nove pogonske uvjete [11], [13], [30]. Optimizacijska rješenja za planiranje pogona moraju biti u skladu sa zahtjevima stvarnih tehničkih zahtjeva i uvjeta proizvodnje iz postojećih kapaciteta [11], [13].

Promatrana literatura razlikuje pet kategorija optimizacijskih metoda, međutim podjela prema kategorijama nije stroga te se određeni postupci mogu uvrstiti u dvije ili više kategorija istovremeno. Najrazumljivije kategorije podjela optimizacijskih metoda su [11], [31]:

- I. Analitičke metode
- II. Meta-heurističke metode
- III. Metode zasnovane na umjetnoj inteligenciji
- IV. Metode zasnovane na evolucijskim načelima
- V. Ostale metode

Analitičke metode zahtijevaju poznavanje algebarskih izraza koji se mogu analizirati prilikom postupka optimizacije, a takav pristup rješavanju optimizacijskog problema podrazumijeva razvijen matematički model promatranih veličina što može predstavljati značajan problem prilikom promatranja složenijih sustava [11], [14]. Prednost analitičkog pristupa očituje se prilikom korištenja modela u sprezi sa mjernim veličinama i vanjskim ulaznim podacima.

Meta-heurističke metode su optimizacijske metode i podrazumijevaju iterativni proces navođenog optimiranja koji djeluje kao vodič za podređene heurističke postupke zasnovane na iskustvenim, intuitivnim, zdravorazumskim ili biološkim načelima [32] koji mogu pružiti kvalitetnu procjenu rješenja uvažavajući složenost određenog problema i pružajući odgovarajuće rezultate unutar poželjnog načina izvođenja [33], [34]. Heuristički postupak koristan je prilikom rješavanja optimizacijskih problema u slučajevima kada precizno i točno rješenje nije jedinstveno, već kada postoji skup prihvatljivih rješenja, te kada preciznost svih rješenja ne mora nužno biti apsolutna, već je dovoljno da bude pragmatično zadovoljavajuća. Heuristički algoritmi mogu biti specifično razvijeni za rješavanje određenog problema ili univerzalno primjenjivi sa zajedničkom značajkom pretrage određenog skupa mogućih rješenja s ciljem odgonetavanja najboljeg rješenja u skupu. Meta-heurističke metode predstavljaju napredne postupke u kojima se heuristički postupak dodatno usavršava pri svakoj iteraciji i prilikom pretrage svakog skupa, a najčešće primjenjuju univerzalno primjenjive heurističke postupke [35]. Način na koji se heuristički postupak usavršava sa svakom iteracijom se može definirati kao zasebna heuristika te se zbog toga

takve složene metode nazivaju meta-heuristikom. Ukoliko se meta-heuristički postupci optimizacije u svom izvođenju dopune egzaktnim rezultatima proračuna pojedinih rješenja tada je moguće ustvrditi kako su općenite strategije specifično primjenjive, a rezultati precizni i točni. Za većinu meta-heurističkih metoda je potrebno pravilno reprezentirati problem, procedure i operatore unutar zakonitosti izvođenja heuristike te djelomično ograničiti prostor rješenja kako bi pretraga bila učinkovita što podrazumijeva zahtjevan istraživački problem prilikom kodiranja specifičnih varijabli [34]. Meta-heurističke metode koje su značajno dokazane i primjenjive u rješavanju različitih problema su lokalna pretraga, tabu pretraživanje, simulirano kaljenje, genetski algoritam i algoritam kolonije mrava [11], [31], [33]–[36].

Pristup računalne inteligencije podrazumijeva namjenske alata i inteligentne postupke za rješavanja određene vrste problema koji ne moraju nužno biti optimizacijski problemi. Najpoznatiji primjeri metoda računalne inteligencije su umjetne neuronske mreže, sustavi neizrazite logike, teorija grubih setova, ekspertni sustavi i vjerojatnosni agenti [37], a primjena navedenih metoda nerijetko je za potrebe donošenja odluka o pojedinim vrijednostima, svrstavanju, sortiranju i označavanju brojevnih veličina prema određenim pravilima. Širi pojam računalne inteligencije obuhvaća sve heurističke i meta-heurističke optimizacijske postupke i procedure te je granica pripadanja određenog pristupa nekoj kategoriji često nejasna. Štoviše, radovi objavljeni unutar *IEEE društva za računalnu inteligenciju* (engl. *IEEE Computational Intelligence Society*), sastavnice međunarodne neprofitne stručne udruga *Instituta inženjera elektrotehnike i elektronike* (engl. *IEEE - Institute of Electrical and Electronics Engineers, Inc.*), obuhvaćaju sve heurističke i meta-heurističke optimizacijske postupke i metode, metode zasnovane na evolucijskim načelima i hibridne metode.

Metode zasnovane na evolucijskim načelima su moćni optimizacijski postupci najčešće korišteni kod optimizacijskih problema prilikom kojih je potrebno razmotriti ispunjenje dva ili više cilja. Zajedničko obilježje optimizacijskih metoda zasnovanih prema evolucijskim načelima jest postojanje jednog ili više postupka donošenja vrijednosnog suda o rješenju, tzv. ocjenjivanje prema kriteriju dobrote [38]. Iterativnim postupkom optimizacije zasnovanim na ovim metodama moguće je prilikom svake sljedeće iteracije usmjeriti pretragu za rješenjima prema području u kojem je prethodna iteracija postigla najbolje rješenje. Razmatrajući navedeni princip djelovanja moguće je zaključiti kako su ove metode slične meta-heurističkim postupcima što dodatno potvrđuje nejasnu granicu i složenost kategorizacije pojedinih metoda.

Izvedenice iz pojedinih optimizacijskih postupaka i metode koje povezuju dva ili više postupka u jedinstveni proces optimizacije pripadaju ostalim metodama, često nazvanim i hibridnim metodama. Najčešće hibridne metode spoj su optimizacijskog postupka i postupka računalne inteligencije za donošenje odluka o skupu rješenja dobivenih optimizacijom [37].

Sve optimizacijske metode mogu naići na određene poteškoće prilikom izvedbe ukoliko nisu pravilno primijenjene i prilagođene promatranom problemu, a najčešće poteškoće su pronalaženje globalno najboljeg rješenja, slaba konvergencija i dugačko vrijeme izvođenja [11].

Wang et al. [39] prikazuju mogućnost da se analitičkim postupkom proračuna padova napona i gubitaka snage nadomjesti iterativna procedura proračuna tokova snaga i na taj način odredi čvor u radijalnoj ili prstenastoj mreži u kojem će integracija distribuirane proizvodnje rezultirati najmanjim gubicama radne snage u sustavu uz zadovoljavajući naponski profil. Analitički pristup opisan u radu promatra dva cilja, lokaciju distribuirane proizvodnje u kojoj će gubici biti najmanji i ispunjenje cilja naponskih razina duž promatranog izvoda, a ukoliko drugi cilj nije ispunjen rješenje lokacije se mijenja u blizini prvotnog rješenja dok se ne ispune oba cilja. Snagu distribuirane proizvodnje autori ograničavaju uvjetom injektirane struje iz elektrane u mrežu te ista ne smije biti veća od struje potrebne potrošačima koji se nalaze od mjesta priključka elektrane do kraja radijalnog izvoda. Pretpostavka koja omogućava izvođenje predložene metode je raspored potrošača u promatranom mreži koji treba biti uniforman duž cijelog izvoda, centralno raspoređen sa najvećim potrošačima na sredini izvoda ili se prilikom snaga potrošača treba povećavati prema kraju izvoda. Prilikom rješavanja istog problema u prstenastim ili zamkastim mrežama autori pomoću matrice admitancija i minimizacije funkcije cilja (2-1) [39] pronalaze optimalnu lokaciju distribuirane proizvodnje. Za lokaciju distribuirane proizvodnje u čvoru j traži se najmanja vrijednost gubitaka koja je u funkciji ekvivalentnog otpora između prvog i i -tog čvora. Dodatno, autori su istražili i mogućnost prikaza promjenjivosti proizvodnje elektrane na obnovljive izvore energije pomoću niza podataka različitih vrijednosti. S obzirom da autori ne koriste iterativne postupke ne postoji problem konvergencije predložene metode.

$$f_j = \sum_{i=1}^{j-1} R_{1i}(j) |S_{Li}|^2 + \sum_{i=j+1}^N R_{1i}(j) |S_{Li}|^2, \quad j = 2, \dots, N \quad (2-1)$$

Acharya et al. [15] među prvima spominju korištenje genetskog algoritma za optimizaciju problema smještaja distribuirane proizvodnje, ali napuštaju takvu ideju zbog mnogobrojnih iterativnih proračuna tokova snaga, čiji rezultati su zapravo ocjena dobrote jedinice, što značajno utječe na vrijeme optimizacije. U svom radu koriste teorem o kompleksnoj snazi koji im

predstavlja okosnicu za određivanje najosjetljivijeg čvora u kojem će distribuirana proizvodnja postići najmanje gubitke u sustavu. Predloženo rješenje prema izrazu (2-2) [15] rezultirati će optimalnom snagom distribuirane proizvodnje za svaki čvor, a pomoću teorema o kompleksnoj snazi pronalazi se utjecaj svake pojedine distribuirane proizvodnje na gubitke u sustavu. Čvor i u kojem su gubici najmanji nakon implementacije distribuirane proizvodnje predstavlja optimalnu lokaciju distribuirane proizvodnje uvažavajući snagu potrošača u tom čvoru P_{Di} .

$$P_{DGi} = P_{Di} + \frac{1}{\alpha_{ii}} \left[\beta_{ii} Q_i - \sum_{j=1, j \neq i}^N (\alpha_{ij} P_j - \beta_{ik} Q_j) \right] \quad (2-2)$$

Newton – Raphsonovu metodu autori [15] koriste za proračun tokova snaga na početku i na kraju procesa određivanja optimalnog rješenja. Značajan doprinos autora jest definiranje tablice za pretragu najboljeg rješenja i grafički prikaz uzrokovanih gubitaka po različitim snagama distribuirane proizvodnje za sve čvorove u promatranoj mreži.

Gözel et al. [14] uspoređuju metode koje su razvili Acharya et al. [15] sa svojom metodom koja polazi od sličnih pretpostavki, ali se razvija u smjeru postavljanja zasebnih matrica kojima opisuju utjecaj injektirane snage na gubitke i naponske razine [40]. Značajan doprinos njihovog rada proizlazi iz definiranja međusobnog utjecaja čvora sa distribuiranom proizvodnjom na ostale čvorove u distribucijskoj mreži i ovisnost osjetljivosti pojedinih čvorova o susjednim elektranama čija je snaga uvijek veća od snage potrošača u pripadajućem čvoru. Rezultati njihovih proračuna također uzimaju proračun gubitaka kao mjerodavan i jasan pokazatelj pozitivnog utjecaja distribuirane proizvodnje. Usporedbom računalne zahtjevnosti autori [14] zaključuju kako je njihova metoda vremenski i računalno manje zahtjevna od pristupa autora [15].

Aman et al. [41] predstavljaju novi pokazatelj stabilnosti snage (engl. *Power Stability Indeks - PSI*), prikazan izrazom (2-3) [41], kojeg koriste za pronalaženje čvora u mreži u kojem će distributivna proizvodnja imati najpovoljniji utjecaj na naponski profil i smanjenje gubitaka na način da se navedeni pokazatelj računa za svaku granu sustava, a dobiveni rezultati se razvrstavaju od najveće do najmanje vrijednosti. Čvorovi koji pripadaju granama sa *PSI* pokazateljem najveće vrijednosti predstavljaju optimalne čvorove za integraciju distribuirane proizvodnje. Predloženu metodu je moguće koristiti prilikom rješavanja problema optimalne raspodjele više distribuiranih izvora ukoliko se prilikom svake pojedinačne integracije iznova računa *PSI* pokazatelj.

$$PSI = \frac{4r_{ij}(P_L - P_G)}{[|V_i| \cos(\theta - \delta)]^2} \leq 1 \quad (2-3)$$

Nakon određivanja najpovoljnijeg čvora za integraciju distribuirane proizvodnje predloženim postupkom se slijedno povećava snaga distribuirane proizvodnje u zadanom čvoru iterativnim postupkom prilikom kojeg autori opažaju prvotno smanjenje gubitaka nakon kojeg slijedi povećanje ukupnih gubitaka u sustavu. Snaga elektrane u iteraciji prilikom koje su gubici najmanji uzima se kao optimalna snaga distribuirane proizvodnje u promatranoj radijalnoj distributivnoj mreži.

Injeti et al. [16] koriste optimizacijsku metodu simuliranog kaljenja za određivanje raspodjele distribuirane proizvodnje i uspoređuju rezultate dobivene genetskim algoritmom i metodom roja čestica. Autori se bave problemom raspodjele jedne ili više distribuiranih proizvodnja u manjim i većim radijalnim mrežama vremenski nepromjenjive potrošnje koristeći proračuna prikazane u [15]. U radu autora Injeti et al. [16] jasno se navode odredbe koje je potrebno uvažiti prilikom korištenja naprednih optimizacijskih metoda računalne inteligencije poput simulacijskih ograničenja i proračunskih zahtjeva. Uspješna implementacija jedne metode računalne inteligencije i prikaz drugih metoda koje se koriste za raspodjelu distribuirane proizvodnje jasan su pokazatelj smjera razvoja budućih istraživanja, što se potvrđuje novijim radom istog autora Injeti [42] u kojem se također razmatra isključivo radijalna distributivna mreža i vremenski nepromjenjivi potrošači.

Najveći broj znanstvenih radova koji koriste meta-heurističke metode optimizacije za rješavanje problema raspodjele distributivne proizvodnje koriste metodu genetskog algoritma ili metodu roja čestica, a pojavljuje se i radovi koji koriste hibridnu metodu nastalu kao spoj tih dvaju procedura. Singh et al. [43] koriste genetski algoritam određen funkcijom cilja (2-4) [43] u svrhu rješavanja posebno oblikovanog problema više-ciljne optimizacije prilikom koje se osim ciljeva smanjenja gubitaka snage i pozitivne promjene naponskog profila razmatra i cilj ekonomskog učinka integracije distribuirane proizvodnje na cijenu radne snage λ . Optimizacijska procedura predloženu u radu zadržana je u tehnički ispravnim granicama korištenjem naponskih ograničenja. Autori koriste znanja prikazana u radu [44] prilikom pretpostavljanja utjecaja distribuirane proizvodnje na cijenu električne energije $C_i(DG)$ u ovisnosti o snazi potrošača P_{Di} i snazi distribuirane proizvodnje P_{DGi} .

$$\begin{aligned} \text{Max } P_{elect}^{DG} = & \sum_{i=1}^n [\{C_i^a(DG) \times (P_{Di} - P_{DGi}) \times \Delta t + C_i^r(DG) \times (Q_{Di} - Q_{DGi}) \times \Delta t\} \\ & + \{C(DG) \times P_{DGi} \times \Delta t\} + \lambda \times P_L(DG) \times \Delta t] \end{aligned} \quad (2-4)$$

Svoja razmatranja autori [43] uspješno potvrđuju simulacijama na modelu radijalne distributivne mreže prilikom kojih dokazuju korisnost predložene metode za rješavanja problema raspodjele jedne ili više distribuiranih proizvodnja u radijalnim distributivnim mrežama.

Abou El-Ela et al. [45] koriste metodu zasnovanu na genetskom algoritmu prilikom rješavanja problema raspodjele jedne distribuirane proizvodnje, a predloženu metodu provjeravaju postupkom linearnog programiranja pri čemu zaključuju kako nema značajnog odstupanja rezultata što potvrđuje korisnost metoda računalne inteligencije. Za potrebe vlastitog istraživanja autori definiraju jasne pokazatelje i ciljeve za poboljšanje naponskog profila izvoda (*VPI*, engl. *Voltage profile improvement*) prema izrazu (2-5), povećanje rotirajuće rezerve sustava (*SRI*, engl. *Spinning reserve increasing*) prema izrazu (2-6), smanjenja tokova snaga među granama (*PFR*, engl. *Power flow reduction*) prema izrazu (2-7) i smanjenje gubitaka snage u granama (*LLR*, engl. *Total line-loss reduction*) prema izrazu (2-8) [45]. Razvijeni algoritam uspješno testiraju na modelu radijalne mreže u Egiptu.

$$\text{Max } VPI\% = \frac{VP_{w/DG} - VP_{wo/DG}}{VP_{wo/DG}} \times 100 \quad (2-5)$$

$$\text{Max } SRI\% = \frac{SR_{w/DG} - SR_{wo/DG}}{SR_{wo/DG}} \times 100 \quad (2-6)$$

$$\text{Max } PFR\% = \frac{PF_{k,wo/DG} - PF_{k,w/DG}}{PF_{k,wo/DG}} \times 100 \quad (2-7)$$

$$\text{Max } LLR\% = \frac{LL_{wo/DG} - LL_{w/DG}}{LL_{wo/DG}} \times 100 \quad (2-8)$$

Ocjenu dobrote distribuirane proizvodnje autori u radu računaju prema izrazu (2-9) [45] definirajući pokazatelj (*MBDG*, engl. *maximal composite benefits of DG*).

$$MBDG = w_1 VPI\% + w_2 SRI\% + w_3 PFR\% + w_4 LLR\% \quad (2-9)$$

Za ograničenja postupka optimizacije metodom računalne inteligencije autori navode ograničenja dopuštenog broja jedinica distribuirane proizvodnje, ali u svom radu analiziraju raspodjelu jedne distribuirane proizvodnje u distributivnoj mreži te zaključuju kako snaga elektrane značajnije utječe na pokazatelje određene izrazima (2-5) – (2-8) od čvora integracije elektrane. Energetsku ravnotežu promatranog sustava autori predstavljaju kao ograničenje optimizacijske procedure te određuju uvjet prema kojem snaga ukupne proizvodnje u promatranom mreži mora biti jednaka zbroju svih vremenski nepromjenjivih potrošača i gubitaka radne snage.

Pristup u kojem se jedan od ciljeva definira kao ograničenje algoritma omogućava izvođenje predložene metode prilikom kojeg je moguće pretpostaviti kako se radi o više-ciljnoj optimizaciji.

Genetski algoritam koriste i autori Biswas et al. [46] prilikom određivanja optimalne raspodjele većeg broja jedinica distribuirane proizvodnje u složenoj distributivnoj mreži s ciljem smanjenja broja naponskih propada. Izloženi problem autori promatraju kroz funkciju cilja smanjenja gubitaka radne snage (2-10), funkciju cilja smanjenja broja potrošača na koji naponski propadi u promatranom vremenu N_F mogu utjecati (2-11) i funkciju cilja smanjenja troška integracije distribuirane proizvodnje (2-12) određenu u novčanim jedinicama po kilovatu instalirane snage K_C i promatranu kao cilj određivanja najmanje snage distribuirane proizvodnje koja će zadovoljiti prethodna dva cilja [46]. Ograničenja potrebna za provedbu algoritma autori definiraju slično prethodnim autorima kao ograničenja snage kroz pojedine grane, naponska ograničenja i ograničenja broja jedinica distribuirane proizvodnje.

$$RPL = \sum_{i=1}^{N_b} \sum_{j=1}^{N_b} A_{ij}(P_i P_j + Q_i Q_j) + B_{ij}(Q_i P_j - P_i Q_j) \quad (2-10)$$

$$\text{Min } S_{DIST} = \sum_{i=1}^{N_F} L_{DIST_i} \quad (2-11)$$

$$\text{Min } C_{DG} = K_C \sum_{i=1}^{N_F} P_{DG_i} \quad (2-12)$$

Posebitost predložene procedure zasnovane na metodi genetskog algoritma ističe su u integriranom korištenju proračuna tokova snaga prilikom ocjenjivanja dobrote najboljih rješenja u svakoj iteraciji. Nakon ocjene dobrote pojedinih rješenja koja se zasniva na rezultatima proračuna tokova snaga, izvodi se dodatni algoritam analize naponskih propada prilikom kojeg se ocjenjuje utjecaj predloženih rješenja na broj vremenski nepromjenjivih potrošača obuhvaćenih naponskim propadima. Navedenim pristupom definiran je inovativan pristup optimizaciji prilikom kojeg se razmatranje više ciljeva odvija u više zasebnih optimizacijskih procedura. Način na koji autori grafički trodimenzionalnom plohom prikazuju rezultate više iteracija kasnije će biti viđen u drugim radovima.

Ograničenost metoda zasnovanih na genetskom algoritmu za rješavanje složenijih optimizacijskih problema pojašnjena je u radu autora Yang et al. [47] u kojem se koristi hibridna metoda dvaju genetskih algoritama s ciljem određivanja najveće snage distribuirane proizvodnje

uvažavajući naponska i tehnička ograničenja elemenata distributivne mreže. Prvim genetskim algoritmom, određenog funkcijom cilja (2-13), određuje se najmanja snaga distribuirane proizvodnje ograničena snagom kratkog spoja na primarnoj strani nadležnog transformatora, naponskom razinom i tehničkim karakteristikama opreme u sustavu. Drugim genetskim algoritmom, prema funkciji cilja (2-14), određuje se snaga distribuirane proizvodnje koja će udovoljiti zahtjevima potrošača promatranog izvoda, a pri tome uvažavajući rješenja prvog genetskog algoritma.

$$\text{Min } f_{1,i} = w_1 \left(\sqrt{\sum_{j=1}^k (P_i(S_{MVA_j}))^2} \right)^{-1} + w_2 \left(\sqrt{\sum_{j=1}^k (P_i(S_{MVA_j}))^2} \right) \quad (2-13)$$

$$\text{Min } f_{2,i} = w_1 \left(P_i(S_{MVA_j}) \right)^{-1} + w_2 P_i(S_{MVA_j}) \quad (2-14)$$

Ovakvim hibridnim pristupom i korištenjem dvaju genetskih algoritama autori su odredili moguće intervale snage distribuirane proizvodnje u ovisnosti o snazi kratkog spoja na sabirnicama nadređene mreže.

Metode zasnivane na genetskom algoritmu kojima se rješavaju optimizacijski problemi proizvodnje jalove energije s ciljem smanjenja gubitaka u promatranim sustavima posebno su prikazane u radovima [48], [49], a potrebno je dodatno istaknuti i rad autora López-Lezama [50] u kojem se određuje optimalna raspodjela distribuirane proizvodnje prema kriteriju zahtjeva proizvođača u relaciji sa cijenom električne energije. U radu [50] ističe se prednost koju distribuirana proizvodnja postiže s obzirom na malu udaljenost od potrošača kroz mogućnost postizanja veće cijene za proizvedenu električnu energiju od tržišne cijene u nekom trenutku jer uzrokuje manje gubitke u sustavu. Autori istog rada naglašavaju kako je više ponovljenih postupaka optimizacije sa nasumičnim početnim postavkama predložene procedure rezultiralo gotovo istovjetnim rješenjima te time potvrđuju upotrebljivost predložene metode.

Prethodno izdvojeni radovi ukazuju na djelotvornost i ograničenja metoda zasnivanih na genetskom algoritmu kojima se rješava problem raspodjele jedne ili više jedinica distribuirane proizvodnje iz različitih stajališta.

Drugačiji pristup rješavanju problema raspodjele više jedinica distribuirane proizvodnje predlažu autori Alrashidi et al. [17] koji iznose algoritam inteligencije roja čestica kao okosnicu svoje metode. Predloženu metodu potvrđuju na modelu distributivne mreže sa više radijalnih

izvoda i ukupno 10 čvorova u kojem kroz više scenarija određuju optimalnu raspodjelu s ciljem smanjenja gubitaka prema izrazu (2-15).

$$\min P_{Losses} = \frac{1}{2} \sum_{i=1}^{NB} \sum_{j=1}^{NB} \Re\{y_{ij}\} [|V_i|^2 + |V_j|^2 - 2|V_i||V_j|\cos\delta_{ij}] \quad (2-15)$$

Autori [17] definiraju ograničenja korištenog algoritma kroz ograničenja promatranog problema, razvidna u naponskim ograničenjima, ograničenjima prividne snage u granama, ograničenjima snage pripadajućih transformatora i ograničenjima najvećeg dopuštenog broja jedinica distribuirane proizvodnje. Autori posebno naglašavaju kako njihova metoda uvjetuje razmatranje isključivo jedne distribuirane proizvodnje po čvoru, a kako se u navedenom radu razmatraju isključivo vremenski nepromjenjiva proizvodnja i nepromjenjivi potrošači, takvo ograničenje je razumljivo.

Navedeni rad, zajedno sa radom [51], predstavlja okosnicu razvoja nove metode zasnovane na algoritmu inteligencije roja čestica kojom će se riješiti problem više jedinica distribuirane proizvodnje po čvoru uz uvažavanje vremenske promjenjivosti potrošača i pojedinih elektrana. El-Zonkoly [51] definira algebarske pokazatelje pomoću kojih dolazi do funkcije cilja za rješavanje optimizacijskog više-ciljnog problema, poput pokazatelja utjecaja distribuirane proizvodnje na radnu (*ILP*) i jalovu snagu (*ILQ*) u sustavu, pokazatelja utjecaja distribuirane proizvodnje na naponske prilike (*IVD*), pokazatelja mogućnosti prihvaćanja snage u ovisnosti o lokaciji elektrane i potrošača (*IC*) te pokazatelja utjecaja distribuirane proizvodnje na struje kratkog spoja u promatranom sustavu (*ISC*). Svakom definiranom pokazatelju autor dodjeljuje težinski faktor važnosti σ čijom promjenom iznosa je moguće orijentirati skup rješenja prema onima rješenjima koja su prilagođena vođenju sustava ili prema onima rješenjima koja mogu biti mjerodavna prilikom planiranja razvoja sustava [51]. Funkcija više ciljeva (*MOF*, engl. *multi-objective function*) tako postaje suma umnožaka pokazatelja i pripadajućih težinskih faktora prema izrazu (2-16) [51]. Takav pristup je čest u znanstvenoj literaturi, a predstavlja združivanje više pojedinih funkcija u jednu funkciju cilja pa se takvo modelirana optimizacija može smatrati istovremeno i jednociljnom i višeciljnom optimizacijom. Stvarna višeciljna optimizacija podrazumijeva vektor funkcija i postojanje suprotstavljenih rješenja .

$$MOF = (\sigma_1 \cdot ILP + \sigma_2 \cdot ILQ + \sigma_3 \cdot IC + \sigma_4 \cdot IVD + \sigma_5 \cdot ISC) + MVA_{sys(pu)} \quad (2-16)$$

Ograničenja promatranog problema integrirana su u predloženoj metodi i definirana kao naponska ograničenja, ograničenja prividne snage kroz grane u sustavu te ograničenje svih snaga

u sustavu koje proizlazi iz nastojanja da promatrani sustav posjeduje mogućnost samostalnog rada neovisno o nadređenoj mreži. Iako autori promatraju isključivo naponski profil i predložena metoda se koristi za održavanje naponskih razina kod različitih vrsta potrošača iz pretpostavki ovog rada moguće je stvoriti predodžbu o inovativnom rješenju za planiranje optimalnog pogona distribuiranih izvora u potpuno aktivnim distributivnim mrežama.

U drugom radu istog autora [52] rješava se problem pokrivanja vršnih opterećenja pomoću optimalne raspodjele distribuirane proizvodnje korištenjem metode zasnovane na algoritmu umjetne kolonije pčela. Predloženi algoritam rješava problem raspodjele uvažavajući kriterij prema kojem su najzahtjevniji potrošači određeni kao primarni za razmatranje integracije distribuirane proizvodnje. U navedenom radu autor ne razmatra potpuno aktivnu distributivnu mrežu u kojoj je u svakom čvoru integrirano više distribuiranih izvora različitih tehnologija, već tri jedinice distribuirane proizvodnje u sustavu od 45 čvorova, odnosno, tri jedinice distribuirane proizvodnje u sustavu od 33 čvora čija ukupna snaga po čvoru ne prelazi 30% snage potrošača u sustavu. Značajna prednost ovog rada je razmatranje dvije vrste tehnologija distribuirane proizvodnje, jedne vremenski promjenjive i neupravljive te druge upravljive distribuirane proizvodnje, a osim distribuirane proizvodnje autor predviđa korištenje sustava za pohranu električne energije kako bi smanjio potrebni angažman upravljive distribuirane proizvodnje.

Integraciju proračuna tokova snaga i algoritma temeljenog na inteligenciji roja čestica s ciljem određivanja optimalne raspodjele više jedinica distribuirane proizvodnje predstavljaju autori Gomez-Gonzalez et al. [53] koji u svojem radu koriste algoritam žabljeg skakanja određen funkcijom (2-17). Prikazani algoritam pripada skupini algoritama inteligencije roja, ali zbog svojih specifičnosti prilikom kodiranja čestica bolje je prilagođen za optimizaciju diskretnih veličina [53]

$$P_{\omega}^t = p_{\omega,max} - \frac{(t-1) \cdot (p_{\omega,max} - p_{\omega,min})}{(t_{max} - 1)} \quad t = 1, 2, \dots, t_{max} \quad (2-17)$$

Značajan doprinos ovog rada je određivanje optimalnog broja jedinica distribuirane proizvodnje koje moraju rezultirati mogućnošću samodostatnosti promatranog sustava, što ga razlikuje od prethodnih radova u kojima se razmatrao smještaj i snaga jedne proizvodne jedinice. Autori izričito navode uspješno korištenje MATLAB programskog okruženja za modeliranje optimizacijske metode koju koriste u suradnji sa *MATPOWER* paketom za izračun tokova snaga.

Povezivanje dvije metode s ciljem razvoja nove hibridne metode predstavljaju autori Moradi et al. [54] koji u svom radu koriste najbolja svojstva križanja jedinstvena za genetski algoritam i svojstvo usmjerenosti prema najboljim rješenjima specifično za algoritam inteligencije roja

čestica. Predloženu metodu autori koriste s ciljem određivanja optimalne raspodjele više jedinica distribuirane proizvodnje uz zadovoljenje tehničkih uvjeta viđena u prethodnim radovima na način da se genetski algoritam koristi s ciljem određivanja optimalne lokacije elektrane, a algoritam inteligencije roja čestica se koristi za određivanje snage elektrane. Prema iskustvu autora, za cjelobrojne optimizacijske probleme genetski algoritam je u mogućnosti brzo i učinkovito pružiti optimalno rješenje, a za probleme predstavljene aritmetikom plutajućih zareza algoritam inteligencije roja čestica posjeduje mogućnost brzog određivanja prostora pretrage. Zadovoljenje tehničkih uvjeta definirano je ograničenjima optimizacijskog problema koja su u ovom slučaju integrirana u zajedničku funkciju cilju prema izrazu (2-18) [54] u kojem funkcija f_1 predstavlja cilj smanjenja gubitaka radne snage, funkcija f_2 predstavlja cilj poboljšanja naponskog profila izvoda, a funkcija f_3 predstavlja pokazatelj naponske stabilnosti određen radijalnog izvoda preuzet iz drugih radova. Koeficijenti k_1 , k_2 , β_1 i β_2 predstavljaju penalizirajuće koeficijente pripadajućih izraza koji odgovaraju težinskih koeficijentima viđenim u prijašnjim radovima. Predstavljena funkcija cilja uzima u obzir vrijednosti napona V_{ni} i iznos prividne snage S_{ni} na sabirnicama radijalnog izvoda.

$$f = \text{Min} \left(\begin{aligned} & (f_1 + k_1 f_2 + k_2 f_3) \\ & + \beta_1 \sum_{i \in N_{DG}} [\max(V_{ni} - V_{ni}^{max}, 0) + \max(V_{ni}^{min} - V_{ni}, 0)] \\ & + \beta_2 \sum_{i \in N} \max(|S_{ni}| - |S_{ni}^{max}|, 0) \end{aligned} \right) \quad (2-18)$$

Prema riječima autora, predložena metoda ukazuje na značajno povećanje preciznosti i ponovljivosti rezultata, ali autori zaključuju kako je potrebno više vremena za provedbu optimizacije u usporedbi sa korištenjem jedne od metoda zasebno.

Inovativan pristup optimizaciji nude autori Saif et al. [55] koji umjesto postupka optimizacije ograničenog jednakostima ili nejednakostima definiraju simulacijsko-optimizacijski postupak prilikom kojeg se tehnička ispravnost optimizacije ocjenjuje simulacijskom provjerom. Razvijena metoda, koju autori nazivaju dvoslojna simulacijska optimizacija jer se izvodi simultano u programskom okruženju MATLAB i programskom alatu GAMS, koristi proračun tokova snaga za sve simulacijske slučajeve i metodu roja čestica za određivanje raspodjele različitih tipova neupravljivih elektrana na obnovljive izvore energije s ciljem povećanja pouzdanosti opskrbe

sustava i smanjenja pogonskih i investicijskih troškova. Razvijenu metodu uspješno primjenjuju na dijelu stvarnog elektroenergetskog sustava prilikom čega iznenađuje podatak kako među optimalnim rješenjima raspodjele nisu uvrštene sunčane elektrane i sustavi za pohranu električne energije, već isključivo elektrane na vjetar što autori pripisuju dostupnosti primarnog energenta na promatranom području. Zaključak njihova rada jest zadovoljenje energetske potrebe promatrane mreže sa više radijalnih izvoda korištenjem neupravljive distribuirane proizvodnje čime se stvaraju preduvjeti za otočni pogon buduće napredne mreže.

Dva rada autora Aman et al. [56], [57] opisuju uporabu algoritma inteligencije roja čestica s ciljem raspodjele više jedinica distribuirane proizvodnje kroz uvođenje novih kriterija opisivanja utjecaja distribuirane proizvodnje na elektroenergetsku mrežu poput kriterija mogućeg povećanja potrošača u sustavu i pokazatelja stabilnosti izvoda. S obzirom da uvedeni kriteriji promatraju tehničke veličine svojstvene području elektroenergetike oblik uvedenih kriterija približno je jednak već viđenim pokazateljima kod drugih autora. Dodatnim provjerama i usporedbom predložene metode sa analitičkom metodom i algoritmom pretrage autori potvrđuju ispravnost korištenja algoritma inteligencije roja čestica za rješavanje problema raspodjele s ciljem smanjenja gubitaka i postizanja najvećeg korisnog utjecaja distribuirane proizvodnje [57].

Usporedba metoda razvijenih na temelju algoritma inteligencije roja čestica i analitičkog pristupa optimizaciji predočena je u radu autora Kansal et al. [58] u kojem se rješava problem raspodjele različitih tehnologija distribuirane proizvodnje s ciljem smanjenja gubitaka prema izrazu (2-19).

$$\text{Min } P_L = \sum_{i=1}^N \sum_{j=1}^N [\alpha_{ij}(P_i P_j + Q_i Q_j) + \beta_{ij}(Q_i P_j - P_i Q_j)] \quad (2-19)$$

Autori definiraju četiri vrste distribuirane proizvodnje s obzirom na mogućnost proizvodnje radne i jalove snage i predlažu integraciju jednu od njih s obzirom na rezultate simulacije. Rezultati dobiveni različitim optimizacijskim pristupom su identični prilikom analize optimalne lokacije za integraciju distribuirane proizvodnje, dok se prilikom određivanja optimalne snage elektrane rezultati razlikuju do 5%.

U vodećim znanstvenim bazama postoji i određen broj znanstvenih radova koji koriste i druge biološki inspirirani optimizacijske algoritme, a značajniji radovi su oni autora Niknam et al. [59]–[61] u kojima se koristi algoritam razmnožavanja pčela kako bi se riješio više-ciljni problem raspodjele distribuirane proizvodnje u distributivnoj mreži [59] ili problem promjene topologije

distributivne mreže [60], [61]. U radovima autora Niknam se, po principu određivanja matice među pčelama, pronalazi najbolji kandidat za opstanak populacije koja u elektroenergetici predstavlja distribuiranu proizvodnju ili topologiju mreže. Poseban oblik navedenog algoritma kojeg autor predlaže se prilikom usporedbe sa genetskim algoritmom i algoritmom inteligencije roja čestica iskazao kao algoritam sa najmanjim vremenom izvođenja uz jednako kvalitetne rezultate.

Korisnost i upotrebljivost algoritma inteligencije roja čestica dodatno se pojašnjava u radovima [62]–[69] u kojima se navedeni algoritam koristi za rješavanje optimizacijskih problema ili problema predviđanja te se uspoređuju algoritmi evolucijske strategije sa ovim algoritmom. Autori Kumari et al. [62] uspoređuju genetski algoritam, unaprijeđeni genetski algoritam i algoritam roja čestica prilikom optimizacije statističkih VAR kompenzatora u mreži s ciljem smanjenja gubitaka i postizanja optimalnih tokova snaga u mreži. Unaprijeđeni genetski algoritam kojeg predlažu autori ističe se implementacijom pet dodatnih operatora križanja gena, uz tri uobičajena, te prema njihovim rezultatima pruža najbolje rezultate optimizacije. Autori Yin et al. [63] koriste algoritam inteligencije roja čestica za optimizaciju dodijele računalnih procesa raspodijeljenim procesorima, a navedeni rad, iako iz područja računarstva, temeljito pojašnjava primjenu korištenog algoritma. Hibridnom metodom nastalom sjedinjenjem algoritma inteligencije roja čestica i sustava neizrazite logike autori Zhang et al. [64] rješavaju problem optimalnih tokova jalove snage s ciljem održavanja napona u prijenosnim mrežama. Najbolja rješenja svake iteracije algoritma inteligencije roja čestica u navedenom radu služe kao mjerilo karakterističnih parametara sljedeće iteracije algoritma. Prilagođeni algoritam inteligencije roja čestica kojim se rješava problem optimalne raspodjele distribuirane proizvodnje s ciljem smanjenja gubitaka u promatranom sustavu predstavljaju autori Ashari et al. [65], dok uobičajeni pristup algoritmom inteligencije roja čestica za rješavanje istog problema koriste autori Bhumkittipich et al. [66]. Cjeloviti pregled svih izvedenica algoritma inteligencije roja čestica poznatih autorima Zhang et al. [67], uključujući i algoritam prikazan u radu [68] koji može rezultirati većim brojem najboljih rješenja, uz prikaz hibridnih pristupa, ukazuje na prikladnost navedenog algoritma za rješavanja mnogih optimizacijskih problema.

Izražena sličnost algoritma u radovima različitih autora [68] i [54] ukazuje kako je moguće izuzetno malim izmjenama načela izvođenja postići drugačiji pristup i pri tome razviti ponešto drugačiji algoritam, na što upozoravaju i autori rada [32] koji se zalažu za drugačiji proces razvoja meta-heurističkih metoda.

Odnosom čimbenika rizika nepredviđenih događaja u distributivnoj mreži koji se pojavljuje uslijed integracije distribuirane proizvodnje i povećanja broja elektrana u distributivnoj mreži bave se autori Ganguly et al. [69] koji hibridnom metodom inteligencije roja čestica i sustava neizrazite logike dolaze do ne-dominiranih (engl. *Pareto*) rješenja.

Opsežan i kvalitetan pregled optimizacijskih postupaka korištenih pri matematičkom modeliranju proučavanjem 360 znanstvenih radova pružili su autori Theo et al. [5] koji bez posebne podjele i grupiranja postupaka navode prednosti i nedostatke svakog pristupa uz osvrt na znanja kojima su navedeni pristupi rezultirali. Za genetski algoritam autori navode kako je prikladan za rješavanje problema koji mogu imati više povoljnih rješenja, načelno ga je jednostavno integrirati u postojeći simulacijski okvir, tolerantan je prema funkcijama cilja kaotičnih atributa te je prikladnim za topološku i kategorijsku promjenjivu optimizaciju. Međutim, kao nedostatke genetskog algoritma autori iznose mogućnost konvergencije prema lokalno najboljem rješenju umjesto prema globalno najboljem, dugo vrijeme potrebno za konvergenciju i složen pristup utvrđivanja kriterija prestanka postupka optimizacije. Prilikom osvrta na algoritam inteligencije roja čestica autori iznose prednosti brzog izvođenja uz prilagodljivost i otvorenost algoritma hibridizaciji s drugim postupcima mekog računarstva, ali upozoravaju kako je za rješavanje problema ovim postupkom potrebno definirati koordinatni sustav gibanja i pravilan broj čestica jer u suprotnom algoritam može rezultirati lokalno najboljim rješenjima.

Sveobuhvatan pregled optimizacijskih metoda kojima je moguće pridonijeti učinkovitijoj integraciji distribuirane proizvodnje u elektroenergetski sustav iznose autori Colmenar-Santos et al. [70] u svom radu iz 2016. godine, a detaljnom analizom njihovog izlaganja moguće je stvoriti predodžbu koji su pristupi dovoljno robusni za korištenje prilikom planiranja pogona distribuirane proizvodnje u potpuno aktivnoj distributivnoj mreži. Autori rada [70] navode kako problem više-ciljne optimizacije planiranja pogona distribuirane proizvodnje različitih tehnologija u potpuno razvijenoj aktivnoj mreži još nije u cijelosti riješen te iznose detalje razvoja ideje o robusnom sustavu za upravljanje distribuiranom proizvodnjom kojeg nazivaju *AMN* (engl. *Active Management Network*) čija uloga je upravljanje u realnom vremenu distribuiranom proizvodnjom i drugim uređajima u distributivnim mrežama [70]. Analizirajući optimizacijske metode i podjele videne u literaturi autori navedenog rada navode podjelu optimizacijskih pristupa u tri cjeline:

- I. Konvencionalni pristupi
- II. Pristupi zasnovani na umjetnoj inteligenciji
- III. Hibridne pristupi zasnovani na više metoda umjetne inteligencije

Prema [70] cjelini konvencionalnih pristupa pripadaju analitičke metode, proračuni tokova snaga, metode nelinearnog programiranja i pravilo 2/3, a pristupima zasnovanim na umjetnoj, odnosno računalnoj, inteligenciji pripadaju evolucijski algoritmi, algoritam simuliranog kaljenja, algoritam diferencijalne evolucije, algoritam roja čestica, sustavi neizrazite logike, algoritam kolonije mrava, algoritam tabu pretrage, algoritam umjetne kolonije pčela, algoritam krijesnica, dok hibridnim pristupima pripadaju metode nastale sjedinjenjem genetskog algoritma i sustava neizrazite logike, genetskog algoritma i tabu pretrage, genetskog algoritma i algoritma roja čestica, genetskog algoritma i proračuna tokova snaga, algoritma roja čestica i proračuna tokova snaga te tabu pretrage i sustava neizrazite logike.

Pregledom svih metoda autori iznose kako su rješenja koje počivaju na algoritmu inteligencije roja zahtjevnija prilikom razvoja ukoliko se traži pouzdano pružanje globalno najboljih rješenja, a sustavi neizrazite logike i hibridni sustavi nisu dovoljno zastupljeni u literaturi. Za metode zasnovane na evolucijskim načelima autori navode kako su preuranjene konvergencije iznimno izražene ukoliko se rješavanju problema ne pristupi dovoljno detaljno, dok je za ostale značajne metode poput algoritma simuliranog kaljenja i algoritma kolonije mrava potrebno značajno vrijeme izvođenja, što ih isključuje iz moguće upotrebe s ciljem kratkoročnog planiranja.

Slična podjela optimizacijskih algoritama koji se koriste prilikom rješavanja problema raspodjele distribuiranih izvora iznosi se u radu već spomenutom u uvodnom dijelu ovog poglavlja autora Pesaran et al. [6] koji definiraju pet cjelina podjele:

- I. Klasični pristup
- II. Metode pretrage
- III. Algoritmi inspirirani fizikalnim ili sociološkim zakonitostima
- IV. Pristupi inspirirani prirodnim procesima
- V. Hibridni inteligentni algoritmi

Prema [6] cjelini klasičnog pristupa pripadaju analitički algoritmi, metode linearnog programiranja, metode mješovitog cjelobrojnog linearnog programiranja, metode nelinearnog programiranja, metode mješovitog cjelobrojnog nelinearnog programiranja i metode dinamičkog programiranja. Nadalje, metodama pretrage prema istim autorima pripadaju metode iscrpne pretrage, proračuni tokova snaga, proračuni kontinuiranih tokova snaga i postupak koncentracije opterećenja. Algoritmima inspiriranim fizikalnim ili sociološkim zakonitostima prema navedenim autorima pripadaju algoritam simuliranog kaljenja, pretraga harmonije glazbenog sastava, tabu pretraga i algoritmi zasnovani na sustavima neizrazite logike. Pod pristupima inspiriranih

prirodnim procesima se prema autorima [6] podrazumijevaju evolucijski algoritmi, algoritam roja čestica, algoritam kolonije mrava, algoritam umjetne kolonije pčela i algoritam krijesnica. Konačno, spomenuti autori pod hibridnim inteligentnim algoritmima podrazumijevaju sjedinjenja više navedenih metoda, poput genetskog algoritma i tabu pretrage, genetskog algoritma i algoritma simuliranog kaljenja, genetskog algoritma i algoritma roja čestica, genetskog algoritma i proračuna tokova snaga, algoritma roja čestica i proračuna tokova snaga te kombinacije bilo kojeg navedenog optimizacijskog postupka sa sustavima neizrazite logike.

U radu [6] navode se prednosti klasičnog pristupa poput jednostavnosti implementacije optimizacijskih postupaka i visoke razina preciznosti, ali i nedostaci koji se očituju u složenosti računalnog procesa, nemogućnosti razmatranja više ciljeva i sporoj konvergenciji. Algoritmi računalne inteligencije odlikuju se učinkovitijom primjenom uz manje iterativnih postupaka, značajnom zastupljenošću u literaturi i mogućnošću razmatranja složenih problema, ali se u radu navodi kako mogu dovesti do krivih rješenja uslijed preuranjene konvergencije, mogu posjedovati manjak sljedivosti rezultata te je postupak modeliranja takvih algoritama složeniji nego kod klasičnog pristupa. Hibridni pristup se prema riječima istih autora odlikuje brzom konvergencijom i učinkovitom primjenom, ali se smatra iznimno složenim za proces modeliranja uz veoma malo primjera u dostupnoj literaturi. Znanstvenim radovima [5], [6], [70], [71] upotpunjuju se znanstvena razmatranja korištenja metoda mekog računarstva u elektroenergetici

Hibridni pristup za rješavanje problema raspodjele s ciljem smanjenja gubitaka i održavanja naponskog profila složene distributivne mreže, zasnovan na sjedinjenju genetskog algoritma i umjetnih neuronskih mreža, odnosno genetskom algoritmu i proračuna tokova snaga, prikazan je u radu [72]. U navedenom radu se genetskim algoritmom određuje optimalna raspodjela jedne distribuirane proizvodnje u distributivnoj mreži čiji se utjecaj na gubitke određuje umjetnom neuronskom mrežom integriranom u genetski algoritam. Za rješavanje problema raspodjele u prstenastim distributivnim mrežama opisani pristup nije rezultirao valjanim rješenjima te je razvijen novi hibridni pristup nastao sjedinjenjem genetskog algoritma i proračuna tokova snaga. U radu [72] je prikazan i hibridni algoritam nastao sjedinjenjem dvaju umjetnih neuronskih mreža koji se odvija prema načelima algoritma pretrage, međutim autori ukazuju na nedostatke takvog pristupa.

Prikazani znanstveni radovi jasan su pokazatelj smjera razvoja robusnih inteligentnih rješenja kojima je moguće riješiti određeni skup složenih problema u elektroenergetici, ali se pristupi zasnovani na metodama mekog računarstva ne bi smjeli bez kritike i oprezne

implementacije prihvaćati kao opće svojstvena rješenja za apsolutno sve slučajeve [73]. Međutim, složenost promatranog problema opravdava korištenje složenog pristupa kojem se nastoji doći do rješenja, a upravo takav problem jest i planiranje optimalnog pogona velikog broja jedinica distribuirane proizvodnje različitih tehnologija u razvijenoj aktivnoj distributivnoj mreži.

2.3. Optimiziranje pogona distribuirane proizvodnje u aktivnoj distributivnoj mreži

Radovi prikazani u prethodnom poglavlju uspješno rješavaju problem raspodjele jedne ili više jedinica distribuirane proizvodnje u distributivnoj mreži te se postupci korišteni u navedenim radovima, prema mišljenju autora ovog rada, mogu proširiti, doraditi i prilagoditi za rješavanja optimizacijskih problema pogona distribuirane proizvodnje u potpuno aktivnim distributivnim mrežama. Dodatno, radovi u kojima se proučava problem optimiranja više različitih tehnologija elektrana u sustavima mikro-mreža mogu poslužiti kao primjer više-ciljnih optimizacijskih procedura čija je načela moguće u manjoj ili većoj mjeri uvažiti prilikom razvoja nove metode planiranja pogona distribuiranih izvora u distributivnim mrežama. Naime, poštujući podjelu distribuirane proizvodnje autora [11] spomenutu u prvom dijelu ovog poglavlja, na krajnju i lokalnu proizvodnju, moguće je sa gledišta distributivne mreže sustav mikro-mreže shvatiti kao krajnju proizvodnju, a veće jedinice distribuiranih izvora kao lokalnu proizvodnju. Nadalje, sustav mikro-mreže posjeduje određene zajedničke značajke sa elektroenergetskim sustavom aktivne distributivne mreže, poput karakteristika pojedinih tehnologija elektrana u sustavu mikro-mreže koje odgovaraju tehnologijama elektranama distribuiranih izvora u distributivnoj mreži.

Kako je već spomenuto, u radu autora Colmenar-Santos et al. [70] iznose se izazovi koje uzrokuje povećana integracija distribuirane proizvodnje u distributivnoj mreži i pojašnjavaju različiti optimizacijskih postupci metoda računalne inteligencije kojima se takvi izazovi mogu riješiti pri čemu autori naglašavaju potencijal hibridnih metoda. Smjer razvoja distributivnih mreža prema naprednim distributivnim mrežama odvija se putem razvoja aktivnih distributivnih mreža [22] [74], [75] integracijom distribuirane proizvodnje [76], a kako cjeloviti pojam naprednih distributivnih mreža podrazumijeva jezgrovitu primjenu informacijskih tehnologija [77], [78], što predstavlja složen namjenski proces, promatranje elektroenergetskog problema optimalnog planiranja pogona distribuiranih izvora u aktivnoj distributivnoj mreži predstavlja temelj budućeg istraživanja i razvoja [19].

Poveznica sustava mikro-mreža i aktivne distributivne mreže pojašnjena je u radu [22] u kojem se sustav mikro-mreže objašnjava kao druga etapa razvoja naprednih mreža, a pojavom

mikro-mreže u distributivnoj mreži uzrokuje se prelazak u aktivnu distributivnu mrežu čime se potvrđuje potreba za pregledom radova koji rješavaju optimizacijske izazove u mikro-mrežama. Integracijom sustava mikro-mreža u distributivne mreže definiraju se cjeline distribuirane proizvodnje s mogućnošću sudjelovanja u pomoćnim uslugama elektroenergetskog sustava što omogućava razvoj dodatnih standarda poput virtualnih elektrana, sustava za pohranu energije i sustava za upravljanje potrošnjom, a sve navedeno u konačnici, primjenom komunikacijskih i informacijskih tehnologija, dovodi do razvoja naprednih mreža [22].

Predodžba optimalnog pogona više distribuiranih izvora nerazdvojiva je od pojma aktivnih distributivnih mreža te je iz navedenih razmatranja opravdano iznijeti znanstvene radove iz područja optimizacije mikro-mreža uvažavajući razumne poveznice između spomenutih pojmova.

Iako za modeliranje optimalnog sustava mikro-mreže postoje komercijalna i dokazana rješenja, poput programskog paketa HOMER (engl. *Hybrid Optimization Model for Multiple Energy Resources*) [79], planiranje optimalnog pogona mikro-mreže u realnom ili kvazi-realnom vremenu uz promjenjivu dostupnost pojedinih energenata predstavlja složen izdvojeni problem specifičnih izazova i ograničenja. Navedena izvedenica osnovnog problema optimiranja sustava mikro-mreže od interesa je mnogim znanstvenicima te je iznimne radove potrebno posebno istaknuti.

Optimalnim vođenjem mikro-mreže koja se sastoji od neupravljivih sunčanih elektrana i elektrana na vjetar te upravljivih dizel agregata uz primjenu baterijskih sustava za pohranu energije bave se autori Shi et al. [28] koji u svom radu razmatraju i mogućnost prekida opskrbe električnom energijom pojedinim kupcima, odnosno, preraspodjelu opterećenja u sustavu. Autori navedenog rada iznose izrazito složen matematički aparat zasnovan na dekompoziciji u blizini minimuma konveksne funkcije kojim dolaze do intervalnih rješenja optimalnih tokova snaga u mikro-mreži prilikom otočnog i mrežnog režima rada, poštujući tehnička ograničenja i zahtjeve sustava. Predloženu matematičku metodu autori nazivaju strategijom upravljanja energijom (engl. *Energy management strategy*) te ističu potrebu za navedenim rješenjem u razvijenim distributivnim mrežama, mikro-mrežama i naprednim distributivnim mrežama. Iako navedeni rad ne koristi metode mekog računarstva za rješavanje opisanog problema, prikazanim matematičkim aparatom moguće je dobiti uvid u zahtjevnost promatranog problema i pretpostaviti hermetičnost analitičkog pristupa planiranju optimalnog pogona više distribuiranih izvora u aktivnoj distributivnoj mreži.

Sustav za upravljanje energijom u mikro-mreži koja se sastoji od sunčanih elektrana, elektrana na vjetar i sustava za pohranu energije uz mogućnost preuzimanja energije iz

distributivne mreže razvijaju autori Umeozor et al. [80] koristeći metodu mješovito-cjelobrojnog linearnog programiranja. Posebitost rada [80] ističe se kroz dobivanje više optimalnih rješenja s obzirom na tehno-ekonomske uvjete u nadređenoj distributivnoj mreži te donošenju najbolje odluke s obzirom na stanje proizvodnje u mikro-mreži i zahtjeva potrošača.

Optimalnim upravljanjem energijom u distributivnoj mreži koja se sastoji od 123 čvora, 7 sustava mikro-mreža i 9 distribuiranih izvora bave se autori rada [20] koji predstavljaju hibridnu metodu nastalu sjedinjenjem sortirajućeg genetskog algoritma bez dominantnih rješenja i teorije grubih setova. Autori predlažu interaktivnu matricu teorije igara opisanu kroz 10 matematičkih izraza za rješavanje interakcije između različitih izvora promatranih kroz točku priključka (engl. *Point of common coupling – PCC*) prilikom operativnog vođenja mikro-mreže i više sustava mikro-mreža unutar distributivne mreže sa L brojem čvorova. Interaktivna matrica optimizira se minimizacijom 3 funkcije cilja (2-20) – (2-22) prilagođenim hijerarhijski uređenim genetskim algoritmom, a predloženu metodu autori ispituju na IEEE testnoj mreži od 33 čvora u koju integriraju 3 sustava mikro-mreže.

$$\min G_1 = \sum_{t=1}^T \sqrt{\sum_{l \in L} (U_{l,t} - 1)^2 / L} \quad (2-20)$$

$$\min G_2 = \sum_{t=1}^T \sqrt{\sum_{l \in L} (P_{l,t}^{PCC} - \theta)^2 / T} \quad (2-21)$$

$$\min G_3 = \sum_{t=1}^T P_t^{LOSS} \quad (2-22)$$

Uspoređujući rezultate dobivene optimizacijom pomoću metoda mekog računarstva sa rezultatima dobivenim klasičnim pristupom upravljanja stvarnom mrežom autori zaključuju kako predloženi pristup ostvaruje bolje rezultate prilikom optimizacije složenijih sustava sa više distribuiranih izvora. Posebno ostvarenje navedenog rada naglašava se, prema riječima autora, u dokazu uspješnog pristupa rješavanju složenih optimizacijskih problema pomoću računalne inteligencije prilikom čega autori iznose kako se dodatne procedure i druga hibridna rješenja tek trebaju istražiti.

Planiranje pogona 34 sustava gorivih ćelija u distributivnoj mreži koja se sastoji od 83 čvora autori Niknam et al. [81] rješavaju pomoću metode inteligencije roja čestica i sustava neizrazite logike kojeg koriste za promjene parametara čestica kako bi osigurali dodatne iteracije i osigurali

globalna najbolja rješenja promatrajući dva cilja zasebno. Za potrebe dnevnog planiranja autori izvršavaju 24 zasebne simulacije, a prilikom svake simulacije uzimaju u obzir moguće promjene u konfiguraciji distributivne mreže. Posebna odlika predložene metode ističe se prilikom uvažavanja prethodno ostvarenim najboljih rješenja u narednim iteracijama što skraćuje vrijeme potrebno za pronalazak novih rješenja ukoliko su odstupanja među iteracijama minimalna. Upravo sustavom neizrazite logike kojom se mijenjaju parametri čestica autori uz minimalne računalne napore osiguravaju široko pokrivanje prostora pretrage.

Načela sekundarne regulacije u prijenosnom sustavu autori Battistelli et al. [82] primjenjuju za automatizirano optimalno vođenje aktivne distributivne mreže raspodijeljenu na virtualne proizvodne jedinice koje se sastoje od mikro-mreže, potrošača i čvora za priključak električnih vozila. Električna vozila se u radu autora smatraju prilagodljivim teretima s mogućnošću predaje električne energije ukoliko je to potrebno. Virtualnu proizvodnu jedinicu autori nazivaju pametnom korisničkom mrežom (engl. *Smart user grid*) koja je u stalnom međudjelovanju sa aktivnom distributivnom mrežom i koja se vodi prema smjernicama nadređene mreže uz poštivanje cilja samodostatnosti mikro-mreže prema izrazu (2-23). Prema izrazu (2-23) autori nastoje voditi mikro-mrežu na način da proizvodnja iz sunčane elektrane (P_{PV}), biomase (P_{BM}) i snaga preuzeta iz nadređene mreže (P_{GRID}) zadovoljavaju upravljive potrošače unutar mikro-mreže (L_{CLR1}), zahtjeve za punjenje električnih vozila (L_{EVS}), upravljive potrošače koji nisu dio mikro-mreže (L_{CLR2}) i kritične neupravljive potrošače (L_{CR}). Načela planiranja izvora u mikro-mreži prikazana u ovom radu izvrstan su pokazatelj na koji način je potrebno pristupiti planiranju distribuiranih izvora u distributivnoj mreži.

$$P_{PV} + P_{BM} + P_{GRID} = L_{CLR1} + L_{EVS} + L_{CLR2} + L_{CR} \quad (2-23)$$

Distributivna mreža je u ovom slučaju agregator koji upravlja sa više čvorova korisničkih mreža različitih značajki i sa više potrošačkih čvorova. Korištenjem CPLEX programskog alata autori izvode 24 zasebne simulacije za potrebe stvarne mreže koja se sastoji od 4 izvoda te definiraju nužne komunikacijske kriterije za implementaciju predložene metode automatiziranog vođenja aktivne distributivne mreže koja se sastoji od više sustava mikro-mreža.

Primjenjivost rješenja predloženog u [82] za potrebe stvarne mreže opravdava nedostatak naprednog optimizacijskog pristupa pomoću metoda računalne inteligencije čime autori ukazuju kako prinudna sklonost složenim rješenjima nije uvijek nužna te kako su svrsishodna rješenja moguća bez povećanja složenosti procesa pronalaska rješenja. Obrazac dolaska do rješenja najmanje složenom metodom razvidan je u radu autora Jun et al. [83] koji metodom cjelobrojnog

programiranja rješavaju optimizaciju upravljanja energijom u mikro-mreži koja se sastoji od više čimbenika proizvodnje i potrošnje pristupajući problemu na već spomenuti način podjele dnevnog intervala u 24 zasebna proračuna. Prilagodбом višeagentnog sustava autori određuju interakciju među čimbenicima mikro-mreže te dolaze do optimalnog rješenja modelirajući sustav u Java Agent Development programskom okruženju. Modeliranje agenata višeagentnog sustava u tri sloja autorima omogućava obuhvaćanje promjenjive karakteristike proizvodnje pojedinih izvora električne energije, a definiranje ukupno pet agenata prema autorima je dovoljno kako bi se modelirali svi čimbenici mikro-mreže. Pristup korištenja višeagentnog sustava prikazan je i u radu [84] u kojem autori spomenutom metodom sa stajališta distributivne rješavaju problem optimalnog pogona više sustava mikro-mreža promatrajući cilj smanjenja cijene električne energije.

Promjenjiva karakteristika proizvodnje pojedinih izvora u mikro-mreži u kojoj je osim proizvodnje električne energije potrebno planirati i upravljati grijanjem i hlađenjem predmet je promatranja autora Gu et al. [85] koji navode kako različiti analitički pristupi i pristupi računalnom inteligencijom rezultiraju sličnim rješenjima, ali kako ne postoji univerzalno rješenje.

Sustav neizrazite logike koriste autori Momahed et al. [86] koji rješenja dobivena matematičkim predviđanjem proizvodnje sunčanih elektrana i elektrana na vjetar kategoriziraju predloženim sustavom, a na temelju rezultata kategorizacije moguće proizvodnje električne energije, određuju raspodjelu energije u mikro-mreži. Predviđanje proizvodnje električne energije iz dvije vrste malih elektrana i predviđanje potrošnje u radu [86] se zasniva na prethodnim stvarnim pokazateljima i povijesnim podacima proizvodnje i potrošnje koje autori analiziraju nelinearnom regresijom i statističkim uglađivanjem. Glavni cilj navedenog rada je voditi sustav mikro-mreže na način da se iz nadređene distributivne mreže preuzima što manje električne energije te da se zahtjevi potrošača u mikro-mreži u što većoj mjeri snabdjevaju iz dvije vrste malih elektrana i sustava za pohranu električne energije.

Radovi koji proučavaju problematiku mikro-mreža odlikuju se detaljnim prikazom promjenjivosti proizvodnje električne energije iz pojedinih tehnologija elektrana na obnovljive izvore energije koje se koriste u promatranim sustavima, uvažavajući pri tome iznimnu osjetljivost mikro-mreže na male promjene u karakteristikama proizvodnje i potrošnje. Pregled ključnih radova koji obrađuju tematiku planiranja proizvodnje u sustavima mikro-mreža omogućava stvaranje predodžbe o kriterijima po kojima je potrebno razmatrati znanstvene radove koji obrađuju problematiku planiranja i upravljanja energijom iz distribuiranih izvora istih tehnologija u distributivnoj mreži.

Autori Hung et al. [13], [87] iznose svoja razmatranja o optimalnoj raspodjeli dvaju tehnologija distribuirane proizvodnje u promjenjivim uvjetima proizvodnje jedne od njih. U radu [13] se analitičkim pristupom i iterativnim proračunima, za svaki čvor zasebno, promatra elektrana na biomasu, kao upravljivi izvor, i elektrana na vjetar, kao neupravljivi izvor električne energije, ovisan o meteorološkim uvjetima. Analitički pristup utjecaja distribuirane proizvodnje u navedenom radu [13] se zasniva na izrazu (2-24), dok se snaga i pogonski uvjeti upravljive distribuirane proizvodnje određuju prema izrazima (2-25) i (2-26).

$$P_{loss} = \sum_{i=1}^N \sum_{j=1}^N \left[\alpha_{ij}((P_{DG_i} - P_{D_i})P_j + (a_i P_{DG_i} - Q_{D_i})Q_j) + \beta_{ij}((a_i P_{DG_i} - Q_{D_i})P_j + (P_{DG_i} - P_{D_i})Q_j) \right] \quad (2-24)$$

$$P_{DG_i} = P_{d_i} - \frac{X_i}{\alpha_{ii}} \quad (2-25)$$

$$pf_{DG_i} = \cos \left(\tan^{-1} \left(\frac{\alpha_{ii} Q_{D_i} - Y_i}{\alpha_{ii} P_{D_i} - X_i} \right) \right) \quad (2-26)$$

Autori opravdavaju korištenje analitičkog pristupa vremenskom promjenjivošću proizvodnje elektrana na vjetar te navode kako se prema njihovim saznanjima heurističke metode i meta-heuristički pristupi ne mogu nositi sa takvim promjenjivim uvjetima. U svom pristupu autori izvršavaju potreban broj simulacija koji odgovara broju promatranih sati i za svaki sat donose optimalno rješenje raspodjele prema četiri scenarija: bez distribuirane proizvodnje, sa jednom elektranom na biomasu, sa jednom elektranom na vjetar te sa kombinacijom elektrane na biomasu i elektrane na vjetar. U posljednjem scenariju autori elektranu na biomasu koriste samo u trenucima kada elektrana na vjetar nije u mogućnosti snabdjeti zahtjeve potrošača. Za promatrani period od 96 sati autori izvode 96 iterativnih postupaka optimizacije raspodjele jedne elektrane, promatrajući svaki čvor zasebno, a poštivanje tehničkih ograničenja svakog dobivenog rješenja provjeravaju zasebnim proračunom tokova snaga.

Analitički pristup istih autora prilikom raspodjela više hibridnih sustava neupravljivih sunčanih elektrana *PV* (engl. *Photovoltaic*) i upravljivih spremnika za pohranu električne energije *BES* (engl. *Battery Energy Storage*) u distributivnoj mreži opisan je u radu [87] u kojem se pomoću novo-definiranog pokazatelja *IMO* (engl. *Multi-Objective Index*) određuje utjecaj jednog hibridnog sustava na mrežu. Nakon određivanja *IMO* pokazatelja prema izrazu (2-27) za svaki čvor u mreži zasebno, autori predlažu novu proceduru koja će uzeti u obzir najbolje rješenje prve iteracije, integrirati ga u mrežu, te iznova iterativno odrediti *IMO* pokazatelj za ostale čvorove u

mreži. Ponavljanjem navedene procedure s ciljem smanjenja IMO pokazatelja autori dolaze do optimalnog broja hibridnih sustava za promatranu mrežu koje odgovara iteraciji prilikom koje je promjena IMO pokazatelja jednaka nuli.


$$IMO(P_k, a_k) = \frac{\sigma_1}{P_L} P_{L(PV+BES)} + \frac{\sigma_2}{Q_L} Q_{L(PV+BES)} \quad (2-27)$$

Autori ispituju predloženu proceduru na sustavu od 33 čvora kroz dva promatrana scenarija: scenarij prilagodljivih pogonskih uvjeta hibridnog sustava i scenarij sukladan pogonskim uvjetima prema standardu IEEE 1547. Dodatno, uslijed zahtjevnog iterativnog postupka predloženog analitičkog pristupa autori ograničavaju optimizaciju nakon određivanja tri optimalna čvora za integraciju hibridnog sustava, odnosno, nakon izvršena tri seta iteracija proračuna za svaki čvor zasebno i za razdoblje od 24 sata. Autori se kritički osvrću na standard IEEE 1547 te ukazuju na značajno smanjenje gubitaka i odražavanja stabilnog naponskog profila izvoda optimizacijom pogonskih uvjeta hibridnog sustava.

U radu istog autora [88] iznosi se zapažanje kako vremenska promjenjivost proizvodnje i potrošnje otežava mogućnost korištenja naprednih tehnika računalne inteligencije te kako se u navedenim okolnostima, prema saznanjima autora, predočeni problemi mogu riješiti isključivo analitičkim pristupom. Isti IMO pokazatelj autori demonstriraju prilikom promatranja utjecaja različitih pogonskih uvjeta elektrane na biomasu na gubitke u distributivnoj mreži [89]. Autori zaključuju kako je već spomenutim analitičkim pristupom i promjenom težinskih faktora σ_1 i σ_2 moguće doći do optimalnog rješenja pogonskih uvjeta upravljive distribuirane proizvodnje.

Sličan pristup predstavljaju autori Xing et al. [90] koji definiraju pojmove aktivne distributivne mreže i aktivnog upravljanja mrežom (engl. *Active Management*) što prema autorima zahtjeva složenu razinu komunikacije između čimbenika aktivne distributivne mreže. Autori iznose ideju o sustavu upravljanja distributivnom mrežom (engl. *Distribution Management System – DMS*) u kojoj se nalaze elektrana na vjetar (VE), mala elektrana (mE) i sunčana elektrana (FNE) prema slici 2.3.

Prema autorima navedenog rada, integracija elektrana promjenjivih i neupravljivih karakteristika proizvodnje je moguća isključivo uz dovoljan broj upravljivih i nepromjenjivih elektrana ili sustava za pohranu električne energije. Korištenjem genetskog algoritma za optimizaciju i metode unutrašnje točke umjesto proračuna tokova snaga autori na IEEE 123 modelu mreže nastoje maksimizirati proizvodnju iz promjenjivih elektrana uvažavajući kriterij o zastupljenosti takvih izvora što rezultira integracijom od ukupno šest elektrana.



Slika 2.3 Sustav upravljanja aktivnom distributivnom mrežom prema [90]

Planiranjem optimalne opskrbe potrošača u okvirima kratkoročnog vremenskog perioda prilikom kojeg se uzima u obzir isprekidanost proizvodnje pojedinih tehnologija bave se autori Soares et al. [91] koji koriste specifičan signalni algoritam inteligencije roja čestica kako bi odgovorili na zahtjeve 208 potrošača stvarne elektroenergetske mreže u kojoj se nalaze i 27 sustava za pohranu električne energije te 99 jedinica distribuirane proizvodnje. Korištenjem funkcije cilja prema izrazu (2-28) autori postižu energetske samodostatnost promatranog sustava na temelju čega navode kako se time postiže preduvjet za razvoj naprednih distributivnih mreža.

$$\begin{aligned}
 & \sum_{W=1}^{N_W} P_{Wind}(W, t) \\
 & + \sum_{Pv=1}^{N_{Pv}} P_{Photovoltaic}(Pv, t) \\
 & + \sum_{Fc=1}^{N_{Fc}} P_{FuelCell}(Fc, t) \\
 & + \sum_{S=1}^{N_S} P_{StorageDischarge}(S, t) + \sum_{LC=1}^{N_{LC}} P_{LoadCurtailment}(LC, t) \\
 & = \sum_{L=1}^{N_L} P_{Load}(L, t) + \sum_{S=1}^{N_S} P_{StorageCharge}(S, t); \quad \forall t \in \{1, \dots, T\}
 \end{aligned} \tag{2-28}$$

Posebitost rada očituje se u dnevnom planiranju proizvodnje iz različitih tehnologija distribuirane proizvodnje koje se ostvaruje podjelom vremenskog okvira planiranja na više zasebnih simulacija. Predložena metoda izvršava se u nekoliko sekundi čime se zadovoljava uvjet kratkoročnog planiranja unutar realnog ili kvazi-realnog vremena.

Značajno postignuće optimalne isporuke električne energije u realnom vremenu opisano je u radu autora Kellerer et al. [92] koji metodom statističkog zaključivanja i grafičkim modelom određuju optimalnu isporuku električne energije u distributivnoj mreži u kojoj 70% potrošačkih čvorova posjeduje nasumično odabranu snagu sunčane elektrane. Autori ograničavaju vrijeme izvođenja matematičkog modela izrađenog u programskom alatu GAMS na 3000 sekundi te uspoređuju dobivene rezultate sa rezultatima dobivenim mješovitim-cjelobrojnim linearnim programiranjem. Razlika u rezultatima je manja od 1% za 75% promatranih simulacija, a najveća razlika između simulacijskih pristupa je 4,2% čime autori dokazuju upotrebljivost predložene matematičke procedure. Bitna značajka predloženog rješenja očituje se u mogućnosti izvođenja bez potpunog poznavanja svih elemenata promatrane mreže ukoliko se uvažavaju unaprijed zadana tehnička ograničenja.

Lamadrid et al. [93] obrađuju problematiku smanjenja CO₂ emisije u promatranom sustavu dajući prednost proizvodnje elektranama na vjetar i pokrivajući vršna opterećenja iz spremnika za pohranu energije. Dodatnu proizvodnju iz konvencionalnih izvora autori penaliziraju kroz tri odvojene etape: kroz CO₂ emisiju prilikom postojeće proizvodnje, kroz CO₂ emisiju prilikom povećanja proizvodnje uslijed praćenja povećane potrošnje i kroz pogonski trošak konvencionalnih elektrana prilikom povećanja proizvodnje električne energije. Autori razvijaju dvoznačni model robusne stohastičke procjene stanja u mreži, uključujući stanje proizvodnje elektrana na vjetar i stanje zahtjeva potrošača koje modeliraju Markovljevim lancima prema izrazu (2-29), a prelazak između stanja definiran je promatranim varijablama navedenog rada, a koje su cijena proizvodnje radne snage C_p^i , cijena CO₂ emisije C_E^i uslijed takve proizvodnje, troškovi proizvodnje prilikom promjene stanja C_{p+}^i i C_{p-}^i , troškovi CO₂ emisije prilikom promjene stanja C_{E+}^i i C_{E-}^i , suma troškova prelaska iz stanja veće vjerojatnosti $C_{\delta+}^i$ i vrijednost očekivane pohranjene energije C_S^T .

$$\begin{aligned}
f(p, p_+, p_-) = & \sum_{k \in K} \psi_{\alpha}^k \sum_{i \in I^k} \left(C_P^i(p^{ik}) + C_E^i(p^{ik}) + C_{P_+}^i(p_+^{ik}) + C_{P_-}^i(p_-^{ik}) + C_{E_+}^i(p_+^{ik}) \right. \\
& \left. + C_{E_-}^i(p_-^{ik}) \right) \\
& + \sum_{i \in I^0} (C_{\delta}^i(p^{i0}) + C_E^i(p^{i0} - \hat{p}^{t-1, i0}) \\
& - (C_{s, inc}^T[\eta_{out}]B_g + C_{s, dec}^T[\eta_{out}]B_h)p)
\end{aligned} \tag{2-29}$$

Opsežnom simulacijom autori dokazuju kako se zahtjevi potrošača mogu u potpunosti snabdjeti odgovarajućim planiranjem pogona elektrana promjenjive i nepromjenjive proizvodnje. Pokazatelji proizvodnje elektrana na vjetar prikazani u ovom radu temelje se na povijesnim podacima i statističkim očekivanjima. Iako autori samokritički navode kako se predloženo rješenje može doraditi u pogledu modeliranja realnijih stanja proizvodnje i promatranjem mnogih drugih veličina u sustavu, postupak opisan u ovom radu na iznimno inovativan način rješava problematiku optimalnih tokova snaga bez potrebe za zahtjevnim proračunima.

Pristup zasnovan na mješovito-cjelobrojnom kvadratnom programiranju opisuju autori Hu et al. [25] koji rješavaju problem raspodjele potrošnje u promatranoj mreži. Navedeni rad kvalitetno obrađuje matematički model raspodjele potrošnje, a načela prikazana se mogu koristiti za razvoj matematičkog modela raspodjele proizvodnje upravljivih elektrana. Autori razmatraju preraspodjelu potrošnje kako bi krivulja potrošnje odgovarala krivuljama proizvodnje sunčanih elektrana i elektrana na vjetar. Primjenom linearnih ograničenja autori uspješno ispituju predloženu proceduru u uvjetima kvazi-realnog vremena modelirajući istu u MATLAB i GAMS programskom okruženju.

Na tragu rješenja prikazanog u radu [81] isti autor Niknam uz druge koautore u radu [94] koristi već opisani sustav neizrazite logike kako bi djelovao na čestice u postupku optimizacije i planiranja pogona gorivih ćelija s ciljem smanjenja gubitaka i smanjenja emisije štetnih plinova. Prikazanom hibridnom metodom autori osiguravaju primjenjivost predloženog rješenja u mrežama sa većim ili manjem brojem čvorova jer se područje pretrage može proširiti tijekom postupka optimizacije, uz nepoželjan utjecaj na brzinu konvergencije, korištenjem sustava neizrazite logike.

Raspodjelom energije u sustavu mikro-mreže bave se autori Elamine et al. [95] koji predviđaju promjenjivost elektrane na vjetar korištenjem umjetnih neuronskih mreža optimiziranih algoritmom inteligencije roja čestica. Postupkom optimizacije umjetne neuronske mreže, koja svoje djelovanje temelji na povijesnim pokazateljima brzine vjetra, autori postižu visoku razinu

preciznosti. U sustavu mikro-mreže autori modeliraju i sustav za pohranu električne energije za kojeg potrebne režime rada određuju sustavom neizrazite logike.

Analitički pristup optimalnog pogona elektrana na vjetar i sunčanih elektrana u mikro-mreži prikazan je radom autora Wang et al. [96] koji modelirani problem rješavaju postupkom mješovitog-cjelobrojnog kvadratnog programiranja. Autori promatraju ukupnu moguću proizvodnju mikro-mreže i kako bi ispunili zahtjeve pripadajućih potrošača.

Modeli prikazani radovima koji proučavaju planiranje pogona u sustavima mikro-mreže opisanim u prvom djelu ovog potpoglavlja posjeduju detaljno razrađena svojstva proizvodnih jedinica koje je moguće utvrditi i kod proizvodnih jedinica u distributivnoj mreži. Zahtjevi autonomnog pogona mikro-mreže, uz pouzdanu opskrbu električnom energijom iz elektrana promjenjivih i neupravljivih te ujednačenih i upravljivih karakteristika proizvodnje, zajednički su zahtjevima aktivnih i naprednih distributivnih mreža. Opisani radovi odlikuju se složenim matematičkim modelima razvijenim posebno za potrebe proučavanja samostalnog djelovanja mikro-mreža ili više mikro-mreža kroz distributivnu mrežu. Iako detaljni, predloženi modeli nisu u cijelosti iskoristivi za promatranje aktivnog distributivnog sustava, ali se određena načela mogu preuzeti i doraditi s ciljem razvoja optimizacijske metode za planiranje optimalnog pogona više jedinica distribuirane proizvodnje, prilikom kojeg je cilj sagledati što više identificiranih izazova opisanih u radu autora Phuangpornpitak et al. [74]. Ključni izazovi opisani u navedenom radu su konceptualni prikaz s tehničkog stajališta, prednosti i nedostaci različitih tehnologija distribuirane proizvodnje, problem raspodjele prilikom planiranja razvoja distributivne mreže, problem nastanka aktivne distributivne mreže integracijom većeg broja jedinica distribuirane proizvodnje, predviđanje proizvodnje i potrošnje s ciljem upravljanja energijom, utjecaj prelaska distributivne mreže u naprednu distributivnu mrežu na cijenu električne energije, smjer razvoja zakonodavnog okvira koji će omogućiti razvoj distributivnih mreža i u konačnici, izazovi upravljanja naprednom distributivnom mrežom [74]. Neizbježan trend razvoja distributivnih mreža i povećanje zastupljenosti distribuirane proizvodnje u ukupno proizvedenoj električnoj energiji rezultirati će značajnom potrebom za robusnim i široko primjenjivim rješenjem koje će zasigurno posjedovati neka načela djelovanja prikazana prethodnim radovima.

2.4. Predviđanje proizvodnje i potrošnje električne energije

Istraživanje autora ovog doktorskog rada u području planiranja optimalnog pogona distribuiranih izvora se razvilo iz područja predviđanja proizvodnje električne energije iz elektrana čija proizvodnja ovisi o meteorološkim uvjetima. Periodička proizvodnja se očekuje u sunčanim

elektranama i elektranama na vjetar [97]–[99], no kako su pojedinačne elektrane na vjetar rijetka pojava u elektroenergetskom sustavu i najčešće su pojedinačne elektrane dio vjetro-parkova većih ukupnih snaga te se gotovo nikada ne priključuju na distributivnu mrežu [100], sunčane elektrane smatraju se distribuiranim izvorom čiju je proizvodnju potrebno precizno predvidjeti s ciljem planiranja pogona jedinica distribuirane proizvodnje koje ne ovise o meteorološkim uvjetima, poput elektrana na bioplin, biomasu, prirodni plin ili dizelska i benzinska goriva. Dodatno, sunčane elektrane fotonaponske pretvorbe predstavljaju izvrstan primjer krajnje distribuirane proizvodnje jer se mogu integrirati kao mikro i male elektrane neposredno uz potrošače [22], najčešće na krovu objekta samog potrošača, a u ponekim slučajevima se dnevna kretanja proizvodnje mogu podudarati sa dnevnim kretanjem potrošnje [101]. Predviđanje proizvodnje električne energije iz sunčanih elektrana je neophodno ukoliko se želi osigurati najveći pozitivni utjecaj distribuirane proizvodnje i pri tome izbjeći bilo kakav negativan učinak na distributivnu mrežu [22], [102], poput iznimnog povećanja naponskih razina [23], povećanog opterećenja elemenata mreže, dinamičkih promjena napona [100], [103], [104], utjecaja na kvalitetu električne energije [103], [105]–[109], smanjenja pouzdanosti sustava [99] ili povećanja gubitaka u sustavu.

Predviđanje potrošnje električne energije predstavlja središnji integralni proces planiranja pogona i razvoja elektroenergetskog sustava [110] te podrazumijeva značajno složen zadatak jer se zahtjevi potrošača mijenjaju pod utjecajem vanjskih, sezonskih, socijalnih i ostalih čimbenika [111], [112]. Periodi predviđanja se mogu podijeliti na dnevne ili tjedne koji se nazivaju kratkoročnim predviđanjem, tjedne do godišnje koji se nazivaju srednje-ročnim, te godišnje ili duže koje se nazivaju dugoročnim planiranjem [110]. Prilikom planiranja pogona optimalnog pogona distribuiranih izvora za određeno vremensko razdoblje potrebno je uzeti u obzir kretanja potrošnje u istom promatranom vremenskom razdoblju kako bi rješenja optimalnog pogona zaista odgovarala trenutnim stanjima u promatranj aktivnoj distributivnoj mreži. Istraživanje autora ovog doktorskog rada promatra kretanje potrošnje u kratkoročnom i srednje-ročnom vremenskom periodu jer je za optimalno planiranje pogona distribuiranih izvora aktivne distributivne mreže u realnom ili kvazi-realnom vremenu potrebno ispuniti uvjet kratkoročnog predviđanja [110].

2.4.1. Predviđanje proizvodnje električne energije iz sunčanih elektrana

Statističkom obradom 35 040 uzoraka proizvodnje sunčane elektrana u periodu jedne godine autori Bacher et al. [113] korištenjem i usporedbom standardnog modela autoregresije i modela autoregresije sa egzogenim varijablama određuju sunčevo zračenje koristeći model vedrog neba, na temelju kojeg predviđaju moguću proizvodnju sunčanih elektrana. Normizacija proizvodnje

sunčane elektrane modelom vedrog neba provodi se statističkim ugađivanjem povijesnih podataka, a autori postupkom normirane srednje kvadratne pogreške ispituju dva neovisna pristupa. Prema riječima autora, model autoregresije bez vanjskih varijabli je u mogućnosti pružiti točna predviđanja za razdoblja do dva sata, ali za duža razdoblja potrebno je implementirati pokazatelje meteoroloških prilika kao vanjske varijable modela.

Primjenom umjetnih neuronskih mreža autori Chen et al. [114] predviđaju proizvodnju električne energije iz sunčanih elektrana koja se zasniva na meteorološkim uvjetima. Povijesne podatke proizvodnje električne energije iz promatranih elektrana zajedno sa podacima o intenzitetu sunčevog zračenja, temperaturi, brzini i smjeru vjetera, naoblaci, tlaku zraka i relativnoj vlažnosti zraka autori klasificiraju prema međusobnoj ovisnosti te za svaki meteorološki pokazatelj iskazuju korelaciju sa proizvodnjom sunčane elektrane. Autori zaključuju kako je korelacija između intenziteta sunčevog zračenja i proizvodnje električne energije iz sunčane elektrane značajna, isto kao i veza temperature zraka i proizvodnje električne energije. Promatrajući relativnu vlažnost zraka i proizvodnju električne energije iz sunčane elektrane autori zaključuju kako se radi o obrnuto proporcionalnim veličinama. Analizom korelacije ulaznih podataka o meteorološkim pokazateljima i podataka o proizvodnji električne energije autori odabiru podatke o intenzitetu sunčevog zračenja, brzini vjetera, temperaturi zraka i relativnoj vlažnosti zraka, uz vremenski slijed i proizvodnju električne energije kao ulazne veličine za učenje umjetne neuronske mreže. Poveznicu između vrijednosti dobivenih neuronima skrivenog sloja a_i i neurona izlaznog sloja y_j autori definiraju izrazom (2-30) koji uzima u obzir težinske koeficijente w_{ij} svake veličine promatranog vektora ulaznih podataka x_t .

$$y_j = \sum_{i=1}^N w_{ij} a_i(x_t) \quad (2-30)$$

Ispitivanjem modelirane umjetne neuronske mreže na skupu podataka poznatih autorima, ali nepoznatih umjetnoj neuronskoj mreži autori dokazuju ispravnost predviđanja predloženim postupkom.

Pedro et al. [115] uspoređuju rezultate predviđanja dobivene metodama auto-regresivnog integriranog srednjeg pomaka, k-najbliži susjeda, umjetnih neuronskih mreža i hibridne umjetnih neuronskih mreža optimiziranih genetskim algoritmom te zaključuju kako umjetna neuronska mreža pokazuje najpreciznije rezultate za period u trajanju od 8 mjeseci. Dodatno autori zaključuju kako je optimizacija neuronske mreže pomoću genetskog algoritma poboljšala preciznost

predviđanja, a najveća poboljšanja preciznosti predviđanja se mogu postići uzimajući u obzir veći set meteoroloških podataka.

Prethodno opisani radovi koriste gotove meteorološke podatke kako bi predvidjeli proizvodnju sunčanih elektrana i izbjegli pogreške modela koje mogu nastati predviđanjem meteoroloških uvjeta, ali autori Fernandez-Jimenez et al. [116] predviđaju meteorološke uvjete numeričkim metoda i umjetnom neuronskom mrežom na kojima se temelji predviđanje proizvodnje sunčanih elektrana ispitano auto-regresivnom metodom, k-najbližim susjedima, umjetnom neuronskom mrežom i adaptivnim sustavom neizrazite logike i umjetnih neuronskih mreža. Autori u svom radu zaključuju kako višeslojna umjetna neuronska mreža pruža najpreciznije rezultate prilikom kratkoročnog predviđanja, a zadovoljavajuće visoku preciznost predviđanja proizvodnje električne energije u realnim uvjetima mogu postići za period do 16 dana.

Pristup zasnovan na umjetnoj neuronskoj mreži prikazan je u radu autora Chow et al. [117] koji iznose metodu predviđanja temeljenu na umjetnim neuronskim mrežama uzimajući u obzir meteorološke pokazatelje. Uspješnim modeliranjem umjetne neuronske mreže, odnosno pravilnim određivanjem broja neurona u skrivenom sloju N_h u odnosu na broj neurona ulaznog sloja N_i , broj neurona izlaznog sloja N_o i broj uzoraka dostupnih za učenje N_p prema izrazu (2-31), autori ostvaraju metodu za predviđanje proizvodnje sunčanih elektrana u realnom 20-minutnom vremenu uz iznimno jaku korelaciju između predviđenih i stvarnih vrijednosti. Izvrsnim rezultatima autori istog rada potvrđuju predloženi znanstveni doprinos i ukazuju na mogućnost primjene prikazanog pristupa u realnom vremenu pri stvarnim uvjetima tržišta električne energije.

$$N_h = \frac{N_i + N_o}{2} + \sqrt{N_p} \quad (2-31)$$

Prema mišljenju autora ovog doktorskog rada predviđanje proizvodnje električne energije iz sunčanih elektrana primjenom umjetnih neuronskih mreža čije se djelovanje zasniva na vanjskim meteorološkim pokazateljima predstavlja rješenje sa najmanjom mogućnosti pogreške predviđanja jer se takvim pristupom izbjegava predviđanje meteoroloških uvjeta, a predviđa se isključivo proizvodnja električne energije uz poznatu korelaciju sa određenim meteorološkim pokazateljima.

2.4.2. Predviđanje potrošnje električne energije

U dostupnoj literaturi se metode za predviđanje potrošnje električne energije mogu podijeliti na skupinu statističkih pristupa i skupinu pristupa računalnom inteligencijom. Skupini statističkih pristupa pripadaju metode eksponencijalnog izgladivanja, metoda auto-regresivnih pomičnih prosjeka (engl. *AutoRegressive-Moving-Average* - *ARMA*) [110], metoda auto-regresivnog

integriranog pomičnog prosjeka (engl. *AutoRegressive Integrated Moving Average - ARIMA*) [118], metoda dinamičke regresije i metoda linearne regresije. Skupini pristupa predviđanju potrošnje računalnom inteligencijom pripadaju sustavi neizrazite logike, umjetne neuronske mreže [119]–[122], metoda kolonije mrava [123] i hibridne metode nastale sjedinjenjem navedenih pristupa [124], [125]. Različiti pristupi predviđanju rezultiraju određenim prednostima, ali i nedostacima te ne postoji univerzalno rješenje koje će za sve prilike pružiti ispravan rezultat [126].

Predviđanje potrošnje električne energije u ovisnosti o temperaturi zraka, primjenom optimalno modelirane umjetne neuronske mreže, prikazuju autori Yokoyama et al. [127]. Autori navedenog rada postižu značajnu preciznost predviđanja provođenjem optimizacije ulaznog skupa podataka i uklanjanjem ponavljajućih podataka za koje autori smatraju kako otežavaju proces učenja umjetne neuronske mreže. U prvom dijelu predloženog modela autori predviđaju temperaturu i vlažnost zraka, na temelju kojih predviđaju kretanje potrošnje. Iako je njihov model korektan, predviđanje potrošnje zasnovano na predviđanjima ulaznih veličina može povećati vjerojatnost pogreške modela i predviđene potrošnje. Primjenjiv sustav trebao bi uzimati preciznije procjene meteoroloških podataka, najčešće iz vanjskih izvora poput meteoroloških prognoza.

Sheikh et al. [112] definiraju nužne pokazatelje koje je potrebno obuhvatiti prilikom kratkoročnog, odnosno srednje-ročnog planiranja primjenom umjetnih neuronskih mreža. Za kratkoročno planiranje autori iznose nužnost uzimanja u obzir tijeka vremena, meteoroloških podataka i vrste potrošača, ali ne definiraju koje meteorološke podatke treba uzeti u obzir. Za srednje-ročno planiranje, koje je prema autorima planiranje za razdoblje od jednog tjedna do jedne godine unaprijed, navode kako je potrebno razmatrati povijesna kretanja potrošnje za isto vremensko razdoblje, broj i vrstu potrošača, meteorološke uvjete, moguće promjene u topologiji mreže te gospodarska i demografska kretanja u promatranom području.

Day et al. [128] uspoređuju pristupe kratkoročnom predviđanju primjenom sustava neizrazite logike, vremenskog slijeda srednjih pomaka i umjetnom neuronskom mrežom te dokazuju kako pristup umjetnim neuronskim mrežama pruža najbolje rezultate ukoliko se prilikom modeliranja umjetne neuronske mreže koriste povijesni podaci potrošnje u zavisnosti o meteorološkim podacima.

Dodatnim razvojem primjene umjetnih neuronskih mreža za kratkoročno predviđanje potrošnje električne energije bave se autori Lauret et al. [129] koji umjetnu neuronsku mrežu doraduju Bayesovim mrežama kako bi odredili statističku kovarijaciju promatranih veličina. Predloženi pristup autori uspoređuju sa uobičajenom umjetnom neuronskom mrežom te sa

hibridnim pristupom umjetne neuronske mreže i Gaussovog postupka eliminacije. Rezultati predviđanja u navedenom radu [129] potvrđuju ispravnost pristupa umjetnim neuronskim mrežama i Bayesovim mrežama.

Podatke o potrošnji električne energije i podatke o meteorološkim pokazateljima autori Bennett et al. [111] koriste za učenje umjetne neuronske mreže korištene za predviđanje potrošnje. Navedene podatke za jednu godinu autori obrađuju metodom auto-regresivnih pomičnih prosjeka sa vanjskim varijablama (engl. *Auto Regressive Integrated Moving Average with Exogeneous Input – ARIMAX*) kako bi identificirali uzorke potrošnje te prilagodili ulazne podatke za učenje umjetne neuronske mreže. Prilikom promatranja iznimno složenog modela tijekom jedne godine autori postižu najveća odstupanja od 11% do 12%.

Autor ovog doktorskog rada je prezentirao na 32. međunarodnog konferenciji *Science in Practice 2014* održanoj na Elektrotehničkom fakultetu u Osijeku, od 15. do 17. listopada 2014. godine, rad iz područja predviđanja potrošnje električne energije korištenjem umjetne neuronske mreže. Navedeni rad rezultat je izučavanja postupaka predviđanja proizvodnje električne energije iz sunčanih elektrana i predviđanja potrošnje električne energije u ovisnosti o meteorološkim uvjetima. Poveznica između neurona ulaznog sloja y i neurona izlaznog sloja X_i dana je izrazom (2-32) [130] koji obuhvaća težinski koeficijent promatrane veličine W_i , broj neurona skrivenog sloja N i prag predaje informacije sljedećem sloju k :

$$y = f \left(\sum_{i=0}^{N-1} W_i X_i(t) - k \right) \quad (2-32)$$

Težinski koeficijenti promatranih veličina određuju utjecaj ulaznih parametara na izlazne vrijednosti umjetne neuronske mreže, a moguće ih je odrediti empirijski ili je moguće pristupiti samo-određivanju veza umjetne neuronske mreže prilikom učenja iz postojećeg skupa podataka koristeći izraz (2-33) kojim obuhvaća stupanj učenja n , vrijednosti ciljanih veličina t_{pj} , vrijednosti proračunatih veličina o_{pj} , vrijednost ulazne veličine i_{pi} te dobivena pogreška δ_{pj} [131]:

$$\Delta_P W_{ji} = n(t_{pj} - o_{pj})i_{pi} = n\delta_{pj}i_{pi} \quad (2-33)$$

Ulazne veličine umjetne neuronske mreže su temperatura zraka, redni broj promatranog dana u godini i potrošnja prethodnog dana preuzetih iz *ISO New England* [132] baze podataka. Nakon 148 epoha učenja umjetne neuronske mreže Levenberg–Marquardt algoritmom rezultati

predviđanja se od stvarnih rezultata razlikuju za prosječno 0,086% na promatranoj godišnjoj razini, a izvadak rezultata predviđanja za jedan nasumično odabrani dan prikazan je tablicom 2.2.

Tablica 2.2 Usporedni prikaz rezultata predviđanja potrošnje električne energije

Sati [h]	Stvarna potrošnja [kVA]	Predviđena potrošnja [kVA]	Sati [h]	Stvarna potrošnja [kVA]	Predviđena potrošnja [kVA]
1	12.930,00	12.050,34	13	16.064,00	15.958,53
2	12.311,00	11.688,92	14	16.053,00	15.797,65
3	11.805,00	11.875,54	15	15.960,00	16.031,60
4	11.629,00	12.151,19	16	16.047,00	17.637,35
5	11.674,00	12.676,43	17	17.033,00	18.803,38
6	11.972,00	13.220,07	18	18.190,00	17.582,55
7	12.433,00	13.340,37	19	17.964,00	16.868,43
8	12.744,00	14.091,85	20	17.450,00	15.956,20
9	13.370,00	14.951,11	21	16.708,00	14.449,21
10	14.246,00	15.577,39	22	15.580,00	12.886,23
11	15.042,00	16.063,97	23	14.186,00	11.984,60
12	15.672,00	16.283,20	24	12.960,00	11.845,00

3. Modeliranje elemenata mreže i proračun tokova snaga

Svrha ovog poglavlja je sažeto i jasno prikazati metodologiju modeliranja ispitnih elektroenergetskih sustava za potrebe istraživanja prikazanog ovom doktorskom disertacijom. Obuhvatiti sve načine modeliranja elektroenergetskog sustava nije moguće jednim doktorskim radom te je u ovom poglavlju naglasak isključivo na modele i razine modela korištene prilikom istraživanja autora. Literatura [133] pruža cjelokupan prikaz modeliranja elemenata elektroenergetskog sustava, načina izvođenja proračuna tokova snaga, mogućnosti prijenosa matematičkih modela u računalne zapisa i načine prikaza rezultata proračuna, dok literatura [134], [135] pruža uvid u jedinstvene matematičke modele hidro-elektrana, elektrana na vjetar, elektrana na plin, planiranja pogona konvencionalnih elektrana, razvoja elektroenergetskog sustava, naprednih proračuna optimalnih tokova snaga, predviđanja cijene električne energije i modele upravljanja rizikom u elektroenergetskom sustavu. Prilikom modeliranja elemenata elektroenergetskog sustava korisno je konzultirati i literaturu [136] koju odlikuje jasan i sažet prikaz nužnih parametara promatranih elemenata. Prilikom izrade programskih postupaka za analizu elektroenergetskog sustava i proračuna tokova snaga nužno je u osnovi konzultirati literaturu autora Saadat [137], Glover et al. [138] i literaturu autora Idema et al. [139] u kojoj su prikazani svi matematički modeli i postupci analize elektroenergetskog sustava. Posebno valja istaknuti literaturu [140] koja jasno i precizno prikazuje matematičke modele elemenata elektroenergetskog sustava i pripadajuće postupke proračuna. Posebitosti izvedbe distributivnih mreža prikazane su u literaturi [141], a zapažanja prikazana u navedenoj literaturi mogu se koristiti kao ograničenja i za provjeru ispravnosti vladanja matematičkog i računalnog modela.

Hibridne metode opisane u drugom i četvrtom poglavlju ove doktorske disertacije nerijetko podrazumijevaju ko-simulaciju različitih programskih rješenja i programskih alata ili ko-simulacijsko djelovanje pojedinih cjelina određenog programskih alata, primjerice upotrebu programskog okruženja *MATLAB* (engl. *MATrix LABORatory*) za razvoj optimizacijske metode i posebnog *OpenDSS* (engl. *Open Distribution System Simulator*) programskog alata za modeliranje i analizu elektroenergetskog sustava [90], [142]–[144] ili pak upotrebu programskog okruženja *MATLAB* za ostvarivanje oba cilja prilikom čega se modeliranje i analiza elektroenergetskog sustava izvodi pomoću alatnog okvira *PSAT* (engl. *Power System Analysis Toolbox*) [145] namijenjenog za korištenje unutar programskog okruženja *MATLAB* [145]–[147]. Izvršni primjeri ko-simulacije unutar programskog okruženja *MATLAB* su radovi [50], [53], [148]–[157] i literatura [134] u kojima se koristi naredbena datoteka (eng. *scripting*) otvorenog koda

MATPOWER [158]. Kvaliteta naredbenog rješenja *MATPOWER* dodatno je potvrđena razvojem zasebnog naredbenog rješenja za programski jezik *Python* na istim načelima djelovanja, a koje se koristi u znanstvenom radu autora Al-Wakeel et al. [159]. Naredbena rješenja se nazivaju i *skriptnim* rješenjima, a podrazumijevaju ispisivanje skupa naredbi koja zajedno čine manji dio neke cjeline, a odlikuju se mogućnošću promjene dijelova napisanog računalnog koda [133]. *MATPOWER* skup naredbenih datoteka naziva se simulacijski paket [160].

Komercijalno dostupna i posebno razvijena programska rješenja za modeliranje i analizu elektroenergetskog sustava najčešće se odlikuju preciznim i točnim modelima, matematički ispravnim procedurama i minimalnom mogućnošću pogreške, no gotovo uvijek su takva programska rješenja zatvoreni sustavi sa unaprijed definiranim ili pojednostavljenim parametrima modela na koje krajnji korisnik nema mogućnost utjecati [133]. U literaturi postoje primjeri kojima se navodi kako je komercijalno dostupnim alatima moguće provjeriti bliskost rezultata dobivenih novim predloženim modelima ili procedurama, najčešće prilikom rješavanja optimizacijskih problema [161], [162], a u radovima [6], [163]–[167] komercijalno dostupni programski alat *DIGSILENT Power Factory* (engl. *DIGital SIMulation of Electrical NeTworks*) se koristi u ko-simulaciji sa *MATLAB* programskim okruženjem. Dodatno, isti komercijalno dostupan programski alat se koristi za znanstveno-istraživačke radove prikazane u [103], [107], [165], [168]–[173], a prema literaturi [174] programski alat *DIGSILENT Power Factory* se odlikuje značajnom bazom provjerenim modela i dokazanom funkcionalnošću.

Upotreba komercijalno dostupnih programskih alata prema autoru Milano [133] nije znanstveno-istraživački opravdana jer zanemaruje razvoj matematičkog modela promatranog sustava i proces implementacije te se nimalo kritički prihvaćaju tuđi, možda neodgovarajući, modeli. Isti autor za znanstveno-istraživačko djelovanje u području elektroenergetike predlaže upotrebu nekog od programskih jezika poput *FORTRAN*, *C*, *Delphi*, *Java*, *Python*, *MATLAB* ili *Octave*. U znanstveno-istraživačkoj zajednici najčešće se koristi *MATLAB* programsko okruženje specijalizirano za rad sa matricama i za kojeg postoje brojni dodaci otvorenog koda i simulacijski paketi za modeliranje i analizu elektroenergetskog sustava koji koriste programski jezik *MATLAB* programskog okruženja poput *EST*, *MatDyn*, *MatEMTP*, *MATPOWER*, *PAT*, *PSAT*, *PST* i *VST* [133].

Odluka o izboru ko-simulacijskog pristupa za modeliranja elemenata i analizu elektroenergetskog sustava uz odabir odgovarajućeg programskog jezika za modeliranje optimizacijskog algoritma mora biti rezultat komparacije značajki pojedinih pristupa uvažavajući

pri tome planirano ostvarenje ciljeva znanstveno-istraživačkog rada. Jedan od ciljeva i znanstvenih doprinosa ove doktorske disertacije je i razvoj algoritma kratkoročnog planiranja pogona distribuiranih izvora čime se nužno određuje uvjet kratkog vremena izvođenja predloženog algoritma. U predloženom algoritmu proračun tokova snaga predstavlja funkciju cilja optimizacijske metode, a obzirom da se funkcija cilja računa za svaku pojedinu česticu svake pojedine populacije modelirane metodom inteligencije roja čestica jasno je kako proračun tokova snaga predstavlja računalno i vremenski najzahtjevniji dio predloženog algoritma.

U tablici 3.1. [133] usporedno su prikazana vremena izvođenja pojedinih dodataka otvorenog koda namijenjenih za najraširenija programska okruženja i programske jezike u znanstvenoj zajednici. Vremena izvođenja rezultat su proračuna tokova snaga za elektroenergetski sustav od 2746 čvorova i 3514 elektroenergetskih vodova izvršenog na osobnom računalu Core 2 Duo tehnologije.

Tablica 3.1. Vrijeme izvođenja pojedinih paketa otvorenog koda prilikom analize elektroenergetskog sustava [133]

Naziv dodatka	Temeljno okruženje dodatka	Ukupno vrijeme izvođenje proračuna [s]	Vrijeme potrebno za faktorizaciju Jakobijeve matrice [s]
<i>UWPLOW</i>	<i>C</i>	1,155	-
<i>InterPSS</i>	<i>Java</i>	15,97	-
<i>MATPOWER</i>	<i>MATLAB</i>	1,464	0,0363
<i>PSAT</i>	<i>Octave</i>	5,221	0,0433
-	<i>Python</i>	1,420	0,0319

Prema tablici 3.1. najkraće vrijeme izvođenja pokazuju programski jezici *C* i *Python*, te programsko okruženje *MATLAB* koje služi kao poligon za izvođenje naredbene datoteke *MATPOWER*.

Drugi korak odluke o izboru ko-simulacijskog pristupa i odabira odgovarajućeg programskog jezika za modeliranje optimizacijske metode podrazumijeva procjenu dostupnosti i prepoznatljivosti pojedinih mogućih programskih rješenja. Radovi prikazani u drugom poglavlju i u uvodu ovog poglavlja većinom koriste *MATLAB* programsko okruženje koje je dostupno i na predmetnoj znanstveno-nastavnoj ustanovi.

Uvažavajući pojašnjene kriterije odabira ko-simulacijskog pristupa i programskog okruženja za modeliranje predložene hibridne metode i simulaciju predloženog algoritma u ovoj doktorskoj disertaciji koristi se *MATLAB* programsko okruženje i dodatak naredbenih datoteka *MATPOWER*. *MATLAB* programsko okruženje upotrebljava se za izradu optimizacijske metode i glavne naredbene datoteka koja koordinira dodatnim naredbenim datotekama i prikuplja rezultate simulacija. Dodatak *MATPOWER* predstavlja dodatne naredbene datoteke otvorenog koda kojima koordinira glavna naredbena datoteka, a cjelokupni paket služi modeliranju elektroenergetskog sustava i izvođenju proračuna uz mogućnost izmjene naredbenih redaka.

3.1. *MATPOWER*® simulacijski paket

MATPOWER simulacijski paket sadrži više desetaka naredbenih datoteka za *MATLAB* programsko okruženje, tzv. *m-file*. Sve naredbene datoteke u potpunosti su otvorenog koda i podliježu licenci za slobodan softver (engl. *GNU GPL*) što omogućava gotovo bezuvjetno rukovanje i promjenu parametara ukoliko je potrebna, a nastao je kao rezultat projekta *PowerWeb* [158], [175]. Naredbene datoteke sadržane u simulacijskom paketu se mogu podijeliti na ulazne ili modelske naredbene datoteke i naredbene datoteke izvođenja proračunskih rutina [160], [175]. Osim sa *MATLAB* programskim okruženjem, *MATPOWER* je u potpunosti kompatibilan i sa *GNU Octave* programskim jezikom namijenjenim znanstvenom-istraživačkom radu. Znanstvena literatura prikazana u ovoj doktorskoj disertaciji iznimno cijeni mogućnosti *MATPOWER* simulacijskog paketa koje se mogu podijeliti u tri cjeline [175]:

- Modeliranje elektroenergetskog sustava i priprema ulaznih podataka proračuna razumljivim naredbenim pristupom,
- Proračuni tokova snaga i optimalnih tokova snaga otvorenog koda,
- Organiziran i jasan pregled rezultata i pristup podacima simulacije,

Modeliranje elektroenergetskog sustava i priprema ulaznih podataka u *MATPOWER* simulacijskom paketu uređena je preko struktura u *MATLAB* programskom okruženju koje poziva varijabla *mpc* (engl. *MATPOWER case*) [175]. Strukture se zapisuju u obliku *m-file* datoteke, a cjelokupni simulacijski paket *MATPOWER* u verziji 4.1 koja se koristi za modeliranje elektroenergetskog sustava u ovoj doktorskoj disertaciji posjeduje značajan broj ispitnih sustava, navedenih u tablici 3.2.[160]. Novije verzije *MATPOWER* simulacijskog paketa dodatno su proširene *PEGASE* i *RTE* ispitnim sustavima zasnovanim na francuskom elektroenergetskom sustavu.

Tablica 3.2. Ispitni sustavi sadržani u simulacijskom paketu *MATPOWER* 4.1 [160]

Naziv	Opis
case_ieee30	<i>IEEE</i> ispitni sustav od 30 čvorova
case24_ieee_rts	<i>IEEE</i> RTS ispitni sustav od 24 čvora
case4gs	<i>Grainger & Stevenson</i> ispitni sustav od 4 čvora
case6ww	<i>Wood & Wollenberg</i> ispitni sustav od 6 čvorova
case9	<i>Chow</i> ispitni sustav od 9 čvorova
case9Q	Ispitni sustav od 9 čvorova sa troškovima reaktivne snage
case14	<i>IEEE</i> ispitni sustav od 14 sabirnica
case30	Ispitni sustav od 30 čvorova zasnivan na <i>IEEE</i> ispitnom sustavu
case30pwl	Ispitni sustav od 30 čvorova linearnih troškova
case39	ispitni sustav <i>New England</i> od 39 čvorova
case57	<i>IEEE</i> ispitni sustav od 57 čvorova
case118	<i>IEEE</i> ispitni sustav od 118 čvorova
case300	<i>IEEE</i> ispitni sustav od 300 čvorova
case2383wp	Poljski elektroenergetski sustav sa iz 1999.-2000. sa vršnim opterećenjem
case2736sp	Poljski elektroenergetski sustav sa iz 2004. sa vršnim ljetnim opterećenjem
case2737sop	Poljski elektroenergetski sustav sa iz 2004. bez vršnih opterećenja
case2746wop	Poljski elektroenergetski sustav sa iz 2003.-2004. bez vršnih opterećenja
case2746wp	Poljski elektroenergetski sustav sa iz 2003.-2004. sa vršnim opterećenjem
case3012wp	Poljski elektroenergetski sustav sa iz 2007.-2008. sa vršnim opterećenjem
case3120sp	Poljski elektroenergetski sustav sa iz 2008. sa vršnim ljetnim opterećenjem
case3375wp	Prošireni poljski elektroenergetski sustav sa iz 2007.-2008. sa vršnim opterećenjem

Literatura prikazana u drugom poglavlju najčešće koristi *IEEE* ispitne sustave za provjeru ispravnosti predloženih metoda te se navedeni pristup koristi i u ovoj doktorskoj disertaciji kako bi se na univerzalno prihvatljivim i provjerenim primjerima ispitala ispravnost predložene metode i algoritma.

U naredbenim datotekama ispitnih sustava definirani su parametri modeliranih elemenata u matričnom obliku razdvojeni razmakom (engl. *tab-delimited*), a u tablici 3.3. prikazan je primjer za oblik zapisa parametara čvorova ispitnog sustava od četiri čvora *case4gs* u kojoj su nazivi tehničkih veličina istovjetni nazivima *MATPOWER* varijabli prema kojima *Pd* predstavlja radnu

snagu potrošača nekog čvora, Qd predstavlja jalovu snagu potrošača, Gs predstavlja vodljivost porečene grane elementa, Bs predstavlja susceptanciju poprečne grane, $Area$ predstavlja logičko područje kojem element pripada, Vm predstavlja iznos napona iskazan po jedinici (p.u., engl. *per-unit*), Va predstavlja kut napona u stupnjevima, $baseKV$ predstavlja nazivni napon elementa mreže, $zone$ predstavlja područje gubitaka (engl. *loss zone*), $Vmax$ predstavlja najveći dopušteni napon iskazan po jedinici i $Vmin$ predstavlja najmanji dopušteni iznos napona iskazan po jedinici. Varijabla $type$ odnosi se na vrstu čvora te joj vrijednost može biti 1 za potrošački čvor, 2 za čvor sa regulacijom napona, 3 za referentni čvor te 4 za izdvojeni čvor (engl. *out of service*) [160]. U istoj naredbenoj datoteci nalaze se i matični zapisi o parametrima proizvodnih jedinica i parametrima vodova promatranog sustava.

Tablica 3.3. Primjer modeliranih parametara za čvorove ispitnog sustava *case4gs* simulacijskog paketa *MATPOWER*

Podaci za čvorove definirani unutar varijable [mpc.bus]												
<i>bus_i</i>	<i>type</i>	<i>Pd</i>	<i>Qd</i>	<i>Gs</i>	<i>Bs</i>	<i>Area</i>	<i>Vm</i>	<i>Va</i>	<i>baseKV</i>	<i>zone</i>	<i>Vmax</i>	<i>Vmin</i>
1	3	50	30,99	0	0	1	1	0	230	1	1,1	0,9
2	1	170	105,35	0	0	1	1	0	230	1	1,1	0,9
3	1	200	123,94	0	0	1	1	0	230	1	1,1	0,9
4	2	80	49,58	0	0	1	1	0	230	1	1,1	0,9

Cjelokupna lista varijabli korištenih u naredbenim datotekama ispitnih sustava nalazi se u prilogu B literature [160], [175] i u potpunosti je sukladna sa *IEEE* i *PTI* načinima zapisa.

3.2. Modeliranje elektroenergetskog sustava


U potpoglavlju 3.1. opisan je način djelovanja simulacijskog paketa *MATPOWER* putem naredbenih datoteka razvijenih za modeliranje ispitnih elektroenergetskih sustava te će se u ovom potpoglavlju detaljnije opisati modeliranje pojedinih elemenata elektroenergetskog sustava, a prikazani matematički izrazi preuzeti su iz literature navedene u uvodu ovog poglavlja te iz priručnika simulacijskog paketa *MATPOWER*.

Svrha ovog potpoglavlja nije teorijski uvod u analizu elektroenergetskog sustava, prikaz razvoja fizikalnih i matematičkih modela elemenata elektroenergetskog sustava ili algebarskih postupaka sa matricama incidencija kojima je opisana topologija promatranih elektroenergetskih mreža, već sažeto i jasno prikazati u kojoj mjeri i koliko složeno su razvijeni modeli simulacijskog paketa *MATPOWER* koji se koristi prilikom znanstveno-istraživačkog rada prikazanog ovog doktorskom disertacijom i koji je sjedinjen sa optimizacijskom metodom inteligencije roja čestica

u zasebnu hibridnu metodu. Literaturom [133], [137], [138], [140], [176] prikazane su teorijske pretpostavke koje obuhvaća i simulacijski paket *MATPOWER* na način prikazan znanstvenim radom autora Zimmerman et al. [158].

3.2.1. Modeliranje vodova i transformatora

Vodovi u simulacijskom paketu *MATPOWER* se modeliraju prema π shemi s koncentriranim parametrima uz pripadajući model elektroenergetskog transformatora prijenosnog omjera τ i zakreta kuta napona θ , kako je prikazano slikom 3.1. i za koje se matrica admitancija cijele takve grane Y_{gr} zapisuje izrazom (3-1) [160].



Slika 3.1. Prikaz modela grane sadržane od modela voda i transformatora u simulacijskom paketu *MATPOWER* [160]

$$\underline{Y}_{gr} = \begin{bmatrix} \left(\underline{y}_u + j \frac{b_p}{2} \right) \frac{1}{\tau^2} & -\underline{y}_u \frac{1}{\tau e^{-j\theta}} \\ -\underline{y}_u \frac{1}{\tau e^{j\theta}} & \underline{y}_u + j \frac{b_p}{2} \end{bmatrix} \quad (3-1)$$

Uzdužna komponenta grane opisana je izrazom (3-2), odnosno fizikalnim veličinama reaktancijom i djelatnim otporom voda koje je potrebno poznavati prilikom zapisivanja naredbene datoteke.

$$\underline{Y}_u = \frac{1}{r_u + jx_u} = \frac{1}{\underline{z}_u} \quad (3-2)$$

Za modeliranje grane u naredbenoj datoteci modela elektroenergetskog sustava nužno je poznavati od kojeg do kojeg čvora je spojena promatrana grana, reaktanciju, djelatni otpor i susceptanciju voda iskazane po jedinici (*p.u.*), trajno dopuštenu snagu, kratkotrajno dopuštenu snagu i snagu dopuštenu u nuždi iskazane u mega-voltamperima (*MVA*), prijenosni omjer transformatora i promjenu kuta na transformatoru promatrane grane ukoliko između dva

promatrana čvora postoji transformacija, a u suprotnom za obje varijable postaviti vrijednost 0. Za grane je moguće odrediti pogonsko stanje prilikom kojeg se vrijednost varijable *status* postavlja na vrijednost 1 ukoliko je grana u pogonu ili na vrijednost 0 ukoliko grana nije u pogonu. Konačno, za svaku granu je moguće odrediti najmanju i najveću vrijednost razlike kuta napona na početku i na kraju voda $\theta_f - \theta_t$.

3.2.2. Modeliranje potrošača

Potrošači se u simulacijskom paketu *MATPOWER* modeliraju kompleksnom snagom u dijelu naredbene datoteke u kojem se definiraju čvorovi u mreži pomoću izraza (3-3) za *i*-ti čvor [160].

$$\underline{s}_d^i = p_d^i + jq_d^i \quad (3-3)$$

U simulacijsku naredbenu datoteku unose se podaci o radnoj snazi u mega-vatima (*MW*) i jalovoj snazi u mega-voltamperima reaktivnim (*Mvar*), a odabir vrste čvora prema varijabli *type* opisane u potpoglavlju 3.1 ne uvjetuje postojanje ili ne postojanje potrošača na nekom čvoru, što je prikazano izvatkom iz podataka o čvorovima *IEEE* ispitnog sustava od 118 čvorova u tablici 3.4. koristeći varijable opisane za tablicu 3.3. Uz zadane parametre potrošača proračunom tokova snaga izračunavaju se iznos i kut napona na pripadajućem čvoru [138].

Tablica 3.4. Primjer modeliranih parametara za čvorove *IEEE* ispitnog sustava od 118 čvorova simulacijskog paketa *MATPOWER*

<i>bus_i</i>	<i>type</i>	<i>Pd</i>	<i>Qd</i>	<i>Gs</i>	<i>Bs</i>	<i>Area</i>	<i>Vm</i>	<i>Va</i>	<i>baseKV</i>	<i>zone</i>	<i>Vmax</i>	<i>Vmin</i>
1	2	51	27	0	0	1	0,955	10,67	138	1	1,06	0,94
2	1	20	9	0	0	1	0,971	11,22	138	1	1,06	0,94
3	1	39	10	0	0	1	0,968	11,56	138	1	1,06	0,94
4	2	39	12	0	0	1	0,998	15,28	138	1	1,06	0,94

U simulacijskom paketu *MATPOWER* potrošače nije moguće modelirati konstantnom strujom ili impedancijom, a upravljive potrošače je potrebno modelirati kao proizvodne jedinice negativne snage [160].

Promjenjivost potrošnje potrebno je modelirati varijablama uvažavajući zahtjeve za formom naredbene datoteke simulacijskog paketa *MATPOWER*. Prilikom modeliranja vremenski promjenjivih potrošača potrebno je promatrani vremenski period podijeliti na zasebne simulacijske procedure u onolikom broju koliko vremenskih jedinica se promatra unutar određenog vremenskog perioda. U istraživanju prikazanim ovom doktorskom disertacijom promatra se

vremenski period od jednoga dana, podijeljen na 24 zasebne simulacijske cjeline od kojih svaka predstavlja jedan sat u danu. Za sve potrošače u obrađenim simulacijama koriste se istovjetne krivulje potrošnje određene izrazima (3-4) i (3-5) u kojima p_p predstavlja radnu snagu, a q_p predstavlja jalovu snagu potrošača nekog čvora.

$$p_{p,min} \leq p_p(t) \leq p_{p,max} \quad \forall t \in \mathcal{T} \quad (3-4)$$

$$q_{p,min} \leq q_p(t) \leq q_{p,max} \quad \forall t \in \mathcal{T} \quad (3-5)$$

3.2.3. Modeliranje proizvodnje

Jedinice distribuirane proizvodnje koje se sastoje od upravljivih i neupravljivih tehnologija elektrana na istom čvoru nazivaju se hibridnim sustavima [71], a najčešće se hibridni sustavi promatraju kroz istraživanje mikro-mreža [177]. U simulacijskom paketu *MATPOWER* se podaci o proizvodnim jedinicama zapisuju unutar simulacijske naredbene datoteke za svaki čvor u ispitnom sustavu, a uvjet modeliranja je ograničenje o jednoj proizvodnoj jedinici po čvoru. Zbog navedenog ograničenja se snage sunčanih elektrana pretpostavljene predviđanjem umjetnom neuronskom mrežom moraju zbrojiti sa snagom upravljivih distribuiranih izvora ukoliko optimizacijski proces ukaže na potrebu definiranja hibridnog sustava na nekom čvoru.

Prema [160] proizvodne jedinice se modeliraju prema izrazu (3-6) unosom mega-vata i mega-voltampera reaktivnih u simulacijsku naredbenu datoteku, u kojem s_g^i predstavlja kompleksnu snagu proizvodne jedinice (engl. *generator*), p_a^i predstavlja radnu snagu, a q_a^i predstavlja jalovu snagu proizvodne jedinice.

$$\underline{s}_g^i = p_a^i + jq_a^i \quad (3-6)$$

Za broj proizvodnih jedinica n_g formira se vektor $\underline{S}_g = P_g + jQ_g$ dimenzija $n_g \times 1$, a u simulacijskoj naredbenoj datoteci se, osim radne i jalove snage proizvodne jedinice, u odjeljku *gen* unose podaci o najvećoj i najmanjoj mogućoj jalovoj snazi proizvodne jedinice u mega-voltamperima reaktivnim (*Mvar*), zadani iznos napona iskazana po jedinici (*p.u.*), nazivna snaga proizvodne jedinice iskazana u mega-voltamperima (*MVA*), vrijednost varijable pogonskog stanja istovjetno kako se unosi za grane, najveći i najmanji iznos radne snage iskazani u mega-vatima (*MW*) prema pogonskoj karti proizvodne jedinice kao i pripadajući podaci o proizvodnji jalove snage prema pogonskoj karti iskazani u mega-voltamperima reaktivnim (*Mvar*), razina povećanja snaga iskazana u mega-vatima po minuti (*MW/min*), razina deseto-minutne rezerve i razina

trideseto-minutne rezerve iskazane u mega-vatima (MW) i koeficijent predviđanja zahtjeva obuhvaćenog područja opskrbe.

Proizvodne jedinice, neupravljive sunčane elektrane i upravljivi sinkroni generatori, modelirane su isključivo radnom snagom uvažavajući trenutni zakonodavni okvir u Republici Hrvatskoj [178] i smjernice literature [179]. Odabir tehnologije pogonskog stroja za proizvodnje električne energije korištenjem sinkronog generatora u modelu prikazanim ovim znanstvenim istraživanjem ne utječe na rezultate dobivene postupkom optimizacije koji obuhvaća sve tehnologije kod kojih postoji dovoljna zaliha primarnog energenta. Uvažavajući tablicu 2.1, tehnologije obuhvaćene prikazanim znanstvenim istraživanjem podrazumijevaju pogonske strojeve motora sa unutrašnjim izgaranjem i mikro-turbine koje kao primarni energent koriste dizelsko ili benzinsko gorivo, prirodni plin, bioplin ili biomasu. Izraz (3-7) opisuje dostupni interval snage svakog promatranog sinkronog generatora u kojem predloženi optimizacijski postupak pronalazi optimalno rješenje. Interval je ograničen najvećom dopuštenom snagom sinkronog generatora $p_{g,max}$ i najmanjom mogućom snagom sinkronog generatora $p_{g,min}$.

$$p_{g,min} \leq p_g(t) \leq p_{g,max} \quad \forall t \in \mathcal{T} \quad (3-7)$$

U izrazu (3-7) $p_{g,max}$ predstavlja najveću snagu koju razmatra predloženi optimizacijski postupak, a $p_{g,min}$ je u predloženoj metodi moguće postaviti na vrijednost nula. Vremenska promjenjivost proizvodnje se, kao i kod modeliranja potrošača, promatra podjelom promatranog vremenskog perioda u zasebne simulacijske cjeline.

Dodatno ograničenje u predloženom modelu predstavlja izraz (3-8) prema kojem ukupna instalirana snaga proizvodnih jedinica u nekom čvoru ne smije biti više od dvostruke ukupne instalirane snage potrošača u istom čvoru, a što je implementirano u ograničenja simulacije. Proizvodne jedinice promatrane u ovom istraživanju su sunčane elektrane $p_{g,SE}$ i prethodno opisani upravljivi sinkroni generatori $p_{g,SG}$.

$$p_{g,SE}(t) + p_{g,SG}(t) \leq 2 \left(\sum p_p(t) \right) \quad \forall t \in \mathcal{T} \quad (3-8)$$

Detaljan matematički i programski model sinkronog generatora, koji značajno nadilazi zahtjeve ovog znanstvenog istraživanja, je moguće pronaći u petnaestom poglavlju literature [133].

U simulacijsku naredbenu datoteku simulacijskog paketa *MATPOWER* za modeliranje proizvodnih jedinica se unose podaci o radnoj snazi u mega-vatima (MW) i jalovoj snazi u mega-

voltamperima reaktivnim ($Mvar$), najvećoj i najmanjoj dopuštenoj jalovoj snazi u megavoltamperima reaktivnim ($Mvar$), razina napona koju proizvodna jedinica održava iskazana po jedinici ($p.u.$), nazivna prividna snaga proizvodne jedinice u megavoltamperima (MVA), pogonski pokazatelj proizvodne jedinice koji za vrijednost manju ili jednaku nuli smatra kako proizvodna jedinica nije u pogonu, a za vrijednost veću od nule smatra kako proizvodna jedinica je u pogonu. Za proizvodne jedinice u simulacijskoj naredbenoj datoteci simulacijskog paketa *MATPOWER* potrebno je još definirati i najveću i najmanju dopuštenu radnu snagu u megavattima (MW), a moguće je definirati gornju i donju granicu radne snage pogonske krivulje generatora te pripadajuće najmanje i najveće vrijednosti jalove snage, sposobnost praćenja promjene tereta zadanu u megavattima po minuti (MW/min), sposobnost 10-minutne rezerve radne snage i 30-minutne rezerve radne snage te sposobnost promjene jalove snage zadane u megavoltamperima reaktivnom po minuti (MVA/min). Primjer modeliranih parametara generatora prikazan je izvatkom iz *IEEE* ispitnog sustava od 30 čvorova u tablici 3.5. Preostali navedeni parametri u spomenutoj naredbenoj datoteci posjeduju vrijednost nula.

Tablica 3.5. Primjer modeliranih parametara za čvorove *IEEE* ispitnog sustava od 30 čvorova simulacijskog paketa *MATPOWER*

<i>bus</i>	<i>Pg</i>	<i>Qg</i>	<i>Qmax</i>	<i>Qmin</i>	<i>Vg</i>	<i>mBase</i>	<i>status</i>	<i>Pmax</i>	<i>Pmin</i>
1	23,54	0	150	-20	1	100	1	80	0
2	60,97	0	60	-20	1	100	1	80	0

Detaljno pojašnjenje svih modeliranih veličina za proizvodne jedinice razvidno je u priručniku simulacijskog paketa *MATPOWER* [160], [175].

3.3. Proračun tokova snaga

Proračunom tokova snaga određuju se struje kroz grane i naponi u čvorovima [133], a u simulacijskom paketu *MATPOWER* proračun je sadržan u naredbenoj datoteci koja se zadano zasniva na iterativnom postupku Newton-Raphson metode uz mogućnost promjene u postupak Gauss-Seidel metode [158], [160]. U svakoj iteraciji Newton-Raphson metode simulacijski paket *MATPOWER* formira cjelokupnu Jakobijevu matricu. Proračun tokova snaga izvodi se za stacionarno stanje elektroenergetskog sustava u kojem su potrošači definirani radnom i jalovom snagom, a izvori električne energije radnom snagom i iznosom napona [133]. Referenti čvor u mreži je potrebno definirati zbog matematičkog postupka te zbog fizikalnih karakteristika modeliranih elemenata mreže koji utječu na pojavu gubitaka u elektroenergetskom sustavu [133].

Za n_{ξ} broj čvorova formira se matrica admitancija Y_{ξ} dimenzija $n_{\xi} \times n_{\xi}$ koja povezuje vektor injektirane struje I_{ξ} i napone u čvorovima V prema izrazu (3-9)

$$I_{\xi} = Y_{\xi} V \quad (3-9)$$

Za broj grana n_g formiraju se matrice Y_{pr} i Y_{od} dimenzija $n_g \times n_{\xi}$ koje povezuju napone u čvorovima V sa strujama I_{pr} i I_{od} u kojima indeks pr podrazumijeva smjer *prema čvoru*, a indeks od podrazumijeva smjer struje *od* čvora. Vektori struja I_{pr} i I_{od} zapisuju se izrazima (3-10) i (3-11).

$$I_{pr} = Y_{pr} V \quad (3-10)$$

$$I_{od} = Y_{od} V \quad (3-11)$$

Na temelju izraza (3-9) - (3-11) računaju se komplekse snage u funkciji kompleksnog napona i uspoređuje se sa snagama potrošača i proizvodnih jedinica korištenjem matrica identiteta C_{od} i C_{pr} prema izrazima (3-12) - (3-14) [160], [175].

$$Y_{pr} = [Y_{pr,od}]C_{od} + [Y_{pr,pr}]C_{pr} \quad (3-12)$$

$$Y_{od} = [Y_{od,od}]C_{od} + [Y_{od,pr}]C_{pr} \quad (3-13)$$

$$Y_{\xi} = C_{od}^T Y_{od} + C_{pr}^T Y_{pr} + Y_{sh} \quad (3-14)$$

U izrazu matrica Y_{sh} predstavlja poprečnu granu prema izrazu $Y_{sh} = G_{sh} + jB_{sh}$. Konačno, kompleksne snage se računaju prema izrazima (3-15) - (3-17) u ovisnosti o kompleksnoj vrijednosti napona [160], [175].

$$\underline{S}_{\xi}(V) = [V]I_{\xi}^* = [V]Y_{\xi}^*V^* \quad (3-15)$$

$$\underline{S}_{od}(V) = [C_{od}V]I_{od}^* = [C_{od}V]Y_{od}^*V^* \quad (3-16)$$

$$\underline{S}_{pr}(V) = [C_{pr}V]I_{pr}^* = [C_{pr}V]Y_{pr}^*V^* \quad (3-17)$$

Prilikom izvođenja proračuna tokova snaga u simulacijskom paketu *MATPOWER* jedan generatorski čvor odabire se kao referenti čvor koji održava kut i vrijednost napona [133], [160] te u teoriji raspolaže beskonačnom radnom snagom [133]. Preostali generatorski čvorovi definirani su varijablom *type* sa vrijednosti 2 kao PV čvorovi. Ukoliko čvoru nije definiran tip pretpostavlja se kako se radi o potrošačkom, PQ, čvoru sa vrijednostima potrošačke radne i jalove snage iz

podataka o čvorovima. Izraz (3-18) predstavlja ravnotežu snage u promatranom sustavu i za potrebe proračuna tokova snaga se razdvaja na izraz (3-19) za radnu komponentu i izraz (3-20) za jalovu komponentu snage [158], [160], [175].

$$g_s(V, S_g) = \underline{S}_{\tilde{c}}(V) + \underline{S}_d - C_g \underline{S}_g = 0 \quad (3-18)$$

$$g_p(\theta, V_m, P_g) = P_{\tilde{c}}(\theta, V_m) + P_d - C_g P_g = 0 \quad (3-19)$$

$$g_Q(\theta, V_m, Q_g) = Q_{\tilde{c}}(\theta, V_m) + Q_d - C_g Q_g = 0 \quad (3-20)$$

U izrazima (3-19) i (3-20) varijabla θ predstavlja kut napona, a varijabla V_m predstavlja iznos napona (engl. *magnitude*). Skup jednadžbi $g(x) = 0$ koje se rješavaju simulacijskim paketom *MATPOWER* formiraju se prema izrazima (3-19) i (3-20) u funkciji nepoznate vrijednosti napona prema izrazu (3-21) u kojem su J_{PV} i J_{PQ} pokazatelji prema vrsti čvora. Vektor x sadrži sve nepoznate vrijednosti napona, kutove za PV čvorove i iznose i kutove za PQ čvorove.

$$g(x) = \begin{cases} g_p^{(i)}(\theta, V_m, P_g) & \forall i \in J_{PV} \cup J_{PQ} \\ g_Q(\theta, V_m, Q_g) & \forall j \in J_{PQ} \end{cases} \quad (3-21)$$

Broj jednadžbi koje se rješavaju proračunom tokova snaga je zbroj broja PV čvorova i dvostrukog iznosa broja PQ čvorova prema izrazu $n_{jed} = n_{PV} + 2n_{PQ}$. Nakon izračuna svih vrijednosti napona računa se potrebna snaga referentnog čvora prema izrazu $n_{PV} + 1$. Iterativnim postupkom proračuna smanjuje se pogreška vektora x u odnosu na osjetljivost Jakobijeve matrice.

Način formiranja Jakobijeve matrice detaljnije je prikazan u četvrtom poglavlju literature [139], šestom poglavlju literature [138], petom poglavlju literature [176] i četvrtom poglavlju literature [133].

Detaljan prikaz iterativnog postupka proračuna tokova snaga Newton-Raphson ili Gauss-Seidel metodom za jednostavnije primjere elektroenergetskih mreža moguće je pronaći u šestim poglavljima literature [137] i [138], sedmom poglavlju literature [139] i u petom poglavlju literature [176].

U simulacijskom paketu *MATPOWER* proračun tokova snaga se izvodi aktivacijom naredbene datoteke *runpf* koja rezultira strukturom rezultata (engl. *results*). Spomenuta struktura rezultata sadrži jedanaest zasebnih struktura o tehničkim i logičkim veličinama proračuna.

4. Računalna inteligencija i primjena u elektroenergetici

Računalna inteligencija se smatra sljedbenikom umjetne inteligencije, a podrazumijeva napredne obrasce i pravila svojstvena visokom stadiju razvoja i primjene obuhvaćenih metoda. Kako je spomenuto u drugom poglavlju, autor Rutkowski [37], pojmom računalne inteligencije obuhvaća korištenje umjetnih neuronskih mreža, sustava neizrazite logike, evolucijske algoritme, ekspertne sustave, teorije grubih setova i vjerojatnosne metode. Osim navedenih postupaka, prošireni pojam računalne inteligencije obuhvaća i inteligenciju roja, fraktale, teoriju kaosa, umjetni imunološki sustav, teoriju valića (engl. *Wavelet*) i genetske algoritme [180].

Često upotrjebljeni prošireni pojam za set metoda i postupaka računalne inteligencije je *meko računarstvo* (engl. *soft computing*) koji podrazumijeva izvodljive postupke računalnog modeliranja kojima je moguće uspješno riješiti određeni problem [35], [73], [181]. Meko računarstvo podrazumijeva i hibridne pristupe nastale sjedinjenjem više metoda računalne inteligencije, a odlikuje se uspješnom primjenom za kontinuirane vrijednosti, mogućnošću samo-evaluacije i promjene načina izvođenja, stohastičkim pristupom, paralelizmom prilikom izvođenja te sposobnošću generiranja približnih ili polu-rješenja [182].

Postupci i metode sadržane u računalnoj inteligenciji nerijetko svoja načela djelovanja temelje na biološkim principima ili prirodnim procesima [183], [184], a primjenjuju se prilikom rješavanja problema za koje ne postoje učinkoviti ili specijalizirani postupci [185]. Nedostatak posebnih postupaka za određene probleme može biti uzrokovan složenošću koja ne omogućava učinkovito modeliranje ili nemogućnošću da se određeni problemi i svi promatrani čimbenici objasne ili modeliraju [181].

U elektroenergetici računalna inteligencija može biti upotrjebljena za optimizaciju pogona, proračun optimalnih tokova snaga [62], [186], [187] modeliranje sustava i nadzor naprednih distributivnih mreža korištenjem sustava neizrazite logike, evolucijskih algoritama i umjetnih neuronskih mreža, a postupci umjetne inteligencije mogu biti iskoristivi prilikom analize podataka i događaja te dijagnostike naprednih distributivnih mreža upotrebom kvalitativnog zaključivanja, metoda za planiranje i hibridnih postupaka [188]. Dodatno, računalna inteligencija se uspješno koristi za rješavanje problema projektiranja stabilizatora elektromehaničkih oscilacija, određivanje uzroka i sortiranje kvarova u prijenosnoj mreži, procjenu pouzdanosti, predviđanje potrošnje, koordinaciju zaštite elektroenergetskog sustava, procjenu kvalitete električne energije, ekonomsku isporuku električne energije, optimizaciju jalove snage i određivanje optimalnih tokova snaga [189].

Usporedbu metoda klasičnog, egzaktnog, pristupa i heurističkih metoda prilikom predviđanja potrošnje nekog objekta iznose autori Wang et al. [190] prema kojima pristup heurističkim metodama ne zahtjeva detaljno modeliranje fizikalnih svojstava promatranog objekta te je precizna rješenja predviđanja moguće ostvariti iznimno brzo temeljem povijesnih podataka. Međutim, autori navode kako razvijeni heuristički model, s obzirom da ne uzima u obzir fizikalna svojstva objekta, nije u mogućnosti predviđati potrošnju bez povijesnih podataka te zbog toga nije iskoristiv za planiranje novih objekata, no ipak predlažu dodatni razvoj modela putem računalne inteligencije kako bi se temeljem postojeće heuristike izradio široko primjenjiv postupak.

Pregledni znanstveni članak autora Jha et al. [191] opisuje na koje načine se trenutno koriste postupci umjetne inteligencije u suvremenim elektroenergetskim sustavima u kojima prevladavaju elektrane na obnovljive izvore energije. U području elektrana na vjetar autori opisuju doprinose u 30 znanstvenih članaka koji rješavaju problem predviđanja brzine vjetra i proizvodnje elektrana na vjetar, a prema riječima autora, postupci predviđanja zasnovani na načelima umjetnih neuronskih mreža su najviše zastupljeni. Osim postupaka predviđanja u području elektrana na vjetar, zasnovanim na umjetnim neuronskim mrežama, autori [191] opisuju i korištenje genetskog algoritma, metode inteligencije roja čestica i metode kolonije mrava. U području sunčanih elektrana autori istog rada navode kako su najviše zastupljeni postupci zasnovani na umjetnim neuronskim mrežama koje se u 40 članaka opisanih u radu [191] koriste za predviđanje sunčevog zračenja, proizvodnje sunčanih elektrana, planiranje rasporeda fotonaponskih modula sunčanih elektrana, planiranje pasivnih objekata korištenjem optimalno dimenzioniranih sunčanih elektrana i za projektiranje sustava praćenja Sunca. Kroz 15 znanstvenih radova se u istom preglednom radu opisuju korištenje umjetnih neuronskih mreža i hibridnih metoda koje koriste umjetne neuronske mreže za primjenu u planiranju proizvodnje hidro-elektrana, predviđanju vodostaja i toka te predviđanju potreba za održavanjem hidro-elektrana. Za potrebe rješavanja identificiranih problema u području hidro-elektrana se osim umjetnih neuronskih mreža koriste i meta-heurističke metode opisane u drugom poglavlju ovog doktorskog rada.

Za optimalno planiranje opskrbe elektrane na biomasu primarnim energentom se, prema autorima preglednog znanstvenog članka [191], uspješno koristi metoda inteligencije roja čestica, a za rješavanje problema predviđanja udjela metana u bioplina, klasifikacije kvalitete bio-dizela, predviđanje cijene drvene biomase, predviđanje učinkovitosti kogeneracije i predviđanje cetanskog broja bio-dizela koriste metode zasnovane na umjetnim neuronskim mrežama. Hibridna metode nastala sjedinjenjem umjetne neuronske mreže i genetskog algoritma se, prema navodima istih autora, uspješno primjenjuje u povećanju učinkovitosti proizvodnje bioplina.

Za hibridne proizvodne sustave, opisane u prethodnom poglavlju, autori preglednog znanstvenog članka [191] iznose 10 znanstvenih radova koji primjenom umjetnih neuronskih mreža, metode inteligencije roja čestica, genetskog algoritma ili hibridnih meta-heurističkih metoda rješavaju probleme predviđanja proizvodnje, upravljanja energijom, planiranja optimalne snage hibridnog sustava i planiranje raspodjele hibridnog sustava u distributivnoj mreži.

U zaključku svog rada, autori [191] iznose kako je dosadašnja široka primjenjivost metoda računalne inteligencije pokazatelj potencijalnog značajnijeg razvoja i primjene mekog računarstva u elektroenergetici.

Ovo poglavlje sastoji se od šest cjelina: u potpoglavlju 4.1. objašnjen je spoznajni proces znanstveno-istraživačkog rada te kriterij odabira odgovarajuće optimizacijske metode; u potpoglavlju 4.2. ističu se osnovne zakonitosti modeliranja umjetnih neuronskih mreža; potpoglavljem 4.3. opisuju se osnovni principi djelovanja sustava neizrazite logike; načela evolucijskog programiranja koje obuhvaća i genetski algoritam prikazana su potpoglavljem 4.4; inteligencija roja čestica i zakonitosti modeliranja upotrijebljeni u ovom radu pojašnjeni su u potpoglavlju 4.5, dok se postupak hibridizacije odabranih postupaka objašnjava u potpoglavlju 4.6

4.1. Uvodna razmatranja

Prema pregledu znanstvenih radova opisanih u drugom poglavlju ove doktorske disertacije i sukladno iznesenom u uvodu ovog poglavlja, moguće je stvoriti predodžbu o učinkovitosti i primjenjivosti pojedinih postupaka i metoda meta-heuristike. U radu [72] iz drugog poglavlja ove doktorske disertacije opisan je problem raspodjele jedne distribuirane proizvodnje i predloženo rješenje zasnovano na genetskom algoritmu. Postupak optimizacije putem genetskog algoritma razvijenog za potrebe navedenog rada prvotno je poslužio kao predložak optimizacijskog postupka planiranja pogona distribuiranih izvora u potpuno aktivnoj distributivnoj mreži. Obzirom da je cilj algoritma kratkoročnog planiranja pogona distribuiranih izvora izvođenje u realnom ili kvazi-realnom vremenu, potrebno je zadovoljiti uvjet o trajanju izvođenja optimizacijskog postupka. Vrijeme izvođenja postupka zasnovanog na hibridizaciji uz genetski algoritam korišten za problem iz rada [72] zadovoljavalo je uvjet realnog ili kvazi-realnog vremena te je za pretpostaviti bilo kako će isti postupak moći, uz manje izmjene, biti iskorišten za planiranje optimalnog pogona više proizvodnih jedinica potpuno aktivne distributivne mreže.

Posebitost kodiranja promatranog problema prema zahtjevima genetskog algoritma uvjetovala je ograničeno izvođenje postojećeg postupka. Naime, prema zahtjevima optimizacije

pomoću genetskog algoritma, tehničke veličine je potrebno svesti na genetski zapis jedinke unutar populacije više jedinki, a u radu [72] snaga pojedinačne elektrane je definirana promjenom unutar genetskog zapisa svake jedinke, a broj čvorova mreže jednak je broju jedinki unutar populacije čime se dodatno osigurava pronalazak globalnog rješenja. Za svaku jedinku računa se funkcija dobrote, koja je promatranjem navedenog problema zapravo bila proračun tokova snaga i brojčani iznos utjecaja svake jedinke na gubitke radne snage u sustavu. Za svaku generaciju pojavljuje se jedinka koja ima najbolji genetski zapis, odnosno koje je prema funkciji dobrote najbolje ocjenjena. Promjena genetskog zapisa jedinke, snage elektrane, se u početku izvođenja algoritma odvija nasumično, a nakon određenog broja iteracija se snage mijenjaju ciljano prema snagama najboljih jedinki. Promatranje sustava sa više preostalih jedinki jedne generacije tipično je za genetski algoritam koji je zamišljen na način da nasumičnim odabirom najboljih jedinki jedne generacije definira početne genetske zapise sljedeće generacije. Međutim, u slučaju kada najbolje jedinke jedne generacije trebaju ostati aktivne prilikom pojave druge i svake sljedeće generacije, uvjeti promatranog problema se mijenjaju te je izgledna pojava n -te generacije koja može najbolja rješenja tražiti u prostoru već otkrivenih rješenja jer je tako uvjetovano nasljeđivanjem genetskog zapisa. Dodatno, svaka aktivna generacija jedinki definira novi distributivni sustav za sljedeću generaciju što uvjetuje dodatna kodiranja genetskog zapisa. Upotrebu genetskog algoritma sa više aktivnih populacija predlažu autori Alshraideh et al. [192] međutim predloženo rješenje nije iskoristivo za specifičan problem planiranja optimalnog pogona potpuno aktivne distributivne mreže. Povećanjem složenosti rješenja povećava se i računalna zahtjevnost postupka optimizacije te je nemoguće ispuniti uvjet realnog ili kvazi-realnog vremena izvođenja. Tijekom znanstveno-istraživačkog rada koji je prethodio izradi ove doktorske disertacije autor napušta razvoj hibridne metode zasnovane na genetskom algoritmu i 2015. godine preusmjerava istraživanje ka razvoju metode zasnovane na inteligenciji roja čestica čija načela djelovanja i dodatni argumenti za odabir su prikazani u potpoglavlju 4.5.

Sličan zaključak o upotrebljivosti genetskog algoritma za promatranje više-dimenzionalnih problema iznose autori Zahraee et al. [193] koji u svom preglednom članku opisuju metode računalne inteligencije upotrijebljene za rješavanje optimizacijskih problema prilikom planiranja pojedinačnih hibridnih proizvodnih sustava. Autori predviđaju hibridizaciju više meta-heurističkih metoda s ciljem razvoja široko primjenjivih postupaka optimizacije, a metodu inteligencije roja čestica smatraju superiornu genetskom algoritmu. Dodatnu prednost diskretne metode inteligencije roja čestica u usporedni sa genetskim algoritmom iznose autori [53], dok se u radu [67] poneka pozitivna svojstva genetskog algoritma koriste prilikom izrade nove hibridne metode

zasnivane na inteligenciji roja čestica. Prednost metode inteligencije roja čestica prilikom pronalaska optimalne promjene topologije distributivne mreže razvidna je u radu Abdelaziz et al. [194], a mogućnosti hibridizacije zasnivane na inteligenciji roja čestica prilikom optimiranja tehnološkog postupka proizvodnje prikazane su u radu Garcia Nieto et al. [195].

4.2. Umjetne neuronske mreže

U drugom poglavlju i u uvodu ovog poglavlja istaknuta je korisnost i upotrebljivost umjetnih neuronskih mreža (engl. *Artificial Neural Network – ANN*) prilikom rješavanja različitih inženjerskih problema, najviše probleme predviđanja potrošnje i proizvodnje iz različitih vrsta elektrana. Dodatna korisnost umjetnih neuronskih mreža razvidna je u znanstvenim radovima iz područja kvalitete električne energije [196]–[200], procjene stanja elektroenergetskog sustava [167], [201] i analize kvarova u elektroenergetskom sustavu [202]–[208]. Umjetne neuronske mreže načela djelovanja temelje na biološkom modelu mozga proizašlog iz istraživanja neurofizioloških osobina živih bića, detaljno opisanog u literaturi [209].


Prilikom modeliranja umjetnih neuronskih mreža potrebno je zadovoljiti smjernice modeliranja [210] na koje se mogu svesti svi modeli umjetnih neuronskih mreža u poznatoj literaturi:

- Vladanje pojedinih neurona modelira se prijenosnim funkcijama po načelu *sve-ili-ništa* [211] prilikom kojeg neuron procesira ulazne veličine na svojstven način koji uvjetuje oblik i vrijednost izlazne veličine. Za svaku ulaznu veličinu je potrebno precizno odrediti razinu pobude pojedinog neurona.
- Veze između neurona, koji odgovaraju sinapsama u biološkom modelu, je potrebno modelirati u dovoljnom broju kako bi neuroni mogli međusobno djelovati.
- Slijed informacija između neurona treba biti učinkovit, poznatog smjera i namjene, a skup ulaznih informacija neurona modelira se kao algebarska suma [212]
- Vladanje umjetne neuronske mreže modelirano učenjem poznatih podataka ovisi o vezama između neurona te je kroz pojedine umjetne sinapse potrebno onemogućiti kretanje informacija. Navedeni postupak izvodi se postavljanjem težinskih koeficijenata u pojedinim vezama koji odgovaraju međusobnoj zavisnosti promatranih informacija. Težinske koeficijente može umjetna neuronska mreža odrediti samostalno postavljanjem pravila učenja (engl. *Learning rule*) [213] modeliranjem adaptivnih linearnih neurona (engl. *Adaline*) [214].

- Integriranju umjetne neuronske mreže u postupak promatranja složenih procesa treba postupiti konzervativno s obzirom na oblik ulaznih informacija u umjetnu neuronsku mrežu i na željeni oblik izlaznih informacija nakon obrade.

4.2.1. Neuron umjetne neuronske mreže

Osnovni činitelj umjetne neuronske mreže koji odgovara smjernicama modeliranja je neuron sa pripadajućim vezama i prijenosnom funkcijom, prikazan slikom 4.1.a, odnosno samo neuron sa objedinjenim dijelovima prema slici 4.1.b, a koji je ujedno i prikaz najčešće korišten u znanstvenim radovima. Na slici 4.1.a [212] i na slici 4.1.b [210] simboli $x_1, x_2, x_3, \dots, x_n$ predstavljaju ulazne veličine, $w_{k1}, w_{k2}, w_{k3}, \dots, w_{kn}$ predstavljaju težinske koeficijente komunikacijskih veza pripadajućih ulaznih veličina, prag b_k predstavlja regulacijsku funkciju skoka čime neuron postaje procesna jedinica [215], u_k je težinska suma na temelju ulaznih veličina, $G(u_k)$ je prijenosna funkcija koja oblikuje izlaznu veličinu y_k . Dodatno, u modelu autora Pfeifer et al. [210], dio neurona označen sa h_k podrazumijeva blok kreiranja težinske sume, a dio označen sa a_k podrazumijeva prijenosnu funkciju.



Slika 4.1 Model neurona umjetne neuronske mreže prema literaturi: a) Haykin [212]; b) Pfeifer et al. [210]

Matematički se neki k -ti neuron opisuje izrazima (4-1) i (4-2) u kojima oznake odgovaraju oznakama na slici 4.1. [212]:

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (4-1)$$


$$y_k = G(u_k + b_k) \quad (4-2)$$

Prijenosne funkcije mogu biti funkcija praga (4-3), linearna funkcija (4-4) ili sigmoidna funkcija (4-5) [212], prikazane slikom 4.2..

$$G(u_k) = \begin{cases} 1, & u_k \geq 0 \\ 0, & u_k < 0 \end{cases} \quad (4-3)$$

$$G(u_k) = \begin{cases} 1, & u_k \geq \frac{1}{2} \\ u_k, & \frac{1}{2} > u_k > -\frac{1}{2} \\ 0, & u_k \leq -\frac{1}{2} \end{cases} \quad (4-4)$$

$$G(u_k) = \frac{1}{1 + \exp^{-au_k}} \quad (4-5)$$



Slika 4.2. Prijenosne funkcije neurona: a) prag; b) linearna; c) sigmoidna


Smanjenjem koeficijenta a u nazivniku sigmoidne funkcije utječe se na nagib funkcije kako je to prikazano crvenom crtkanom linijom na slici 4.2.c., a beskonačnim povećanjem koeficijenta a sigmoidna funkcija postala bi funkcija praga. Najčešće korišteni oblik prijenosne funkcije je upravo sigmoidna funkcija jer predstavlja određeni kompromis između linearnih i nelinearnih prijenosnih funkcija [212]

4.2.2. Adaptivni linearni model neurona

Adaptivni linearni model neurona (engl. *ADaptive LINear Element – ADALINE*) nužan je za modeliranje umjetne neuronske mreže koja ima sposobnost učenja potrebnog djelovanja iz skupa poznatih podataka. Usporedba izlaznih vrijednosti neurona i ciljanih vrijednosti promatranih veličina korištenjem metode najmanjih kvadarata pogreške u adaptivnom linearnom modelu neurona odvija se uporabom Delta pravila (engl. *Delta rule*), odnosno, minimizacijom sume kvadarata pogrešaka ili Widrow-Hoffovim pravilom [210], [216] za ciljane vrijednosti ζ , izlazne vrijednosti neurona O prema izrazu (4-6), za m uzoraka. Model adaptivnog linearnog neurona prikazuje se slikom 4.3, na kojoj se ističe blok zbrajanja pogreške $\Delta\Sigma$ i povratna veza [213].

$$\min \Delta = \frac{1}{m} \sum_{k=1}^m (\zeta(k) - O(k))^2 \quad (4-6)$$

Minimizacija se u izrazu (4-6) izvodi iterativnim postupkom gradijentnog spusta. Obzirom da svaki neuron posjeduje više ulaznih veza potrebno je odrediti koje komunikacijske veze najviše utječu na pogrešku izlazne vrijednosti u odnosu na ciljanu vrijednost. Delta pravilo integrira se u vrijednost izlazne veličine y_k matematičkim zapisom adaptivno linearnog neurona, prema izrazu (4-7). Veličinu ξ je u izrazu (4-7) potrebno svesti na vrijednost O podešavanjem težinskih koeficijenata ulaznih komunikacijskih veza. Indeks μ je jednake vrijednosti za cijeli set ulaznih veličina, a η je pozitivna konstanta koja utječe na dinamiku učenja [210].



Slika 4.3 Model adaptivnog linearnog neurona

$$\Delta y_{ik} = \eta (\zeta_i^\mu - O_i^\eta) \xi_k^\mu \quad (4-7)$$

Promjena težinskih koeficijenata na ulaznim komunikacijskim vezama neurona mijenja se prema izrazu (4-8) [212], [216], u kojem Δw_{kn} predstavlja promjenu težinskog faktora w_{kn} ulazne komunikacijske veze $x_n(t)$ izdvojene iz vektora $x(t)$ u trenutku t , za k -ti neuron:

$$\Delta w_{kj}(t) = \eta e_k(n) x_n(t) \quad (4-8)$$

gdje je $e_k(n)$ razlika između ciljane vrijednosti ζ i izlazne vrijednosti O i u neuronu se računa Delta pravilom prema izrazu (4-9) [209], [212]:

$$\mathfrak{E} = \frac{1}{2} e_k^2(n) \quad (4-9)$$

Nakon što se izračuna potrebna promjena težinskog koeficijenta $\Delta w_{kj}(t)$ potrebno je promijeniti vrijednost koeficijenta prema izrazu (4-10) [212]:

$$w_{kj}(t+1) = w_{kj}(t) + \Delta w_{kj}(t) \quad (4-10)$$

4.2.3. Povratna veza i učenje neurona

Povratna veza neurona presudna je za modeliranje dinamičkih neurona, a time i umjetne neuronske mreže koja je u stanju fino podešavati svoje ustrojstvo promjenom koeficijenata dodijeljenih stupnjevima slobode. Neka je definiran komunikacijski put \mathcal{A} koji se kreće od vrijednosti neke komunikacijske veze $x_n(t)$, preko stvaranja unutrašnje vrijednosti neurona u_k , koja u vremenu t oblikuje izlaznu vrijednost y_k , sukladno slici 4.3. Tada je komunikacijski put \mathcal{B} povratna veza između u_k i sumacijskog bloka Σ preko komparatora $\Delta\Sigma$. Izlazna veličina se tada može zapisati izrazima (4-11) i (4-12) [212]:

$$y_k(t) = \mathcal{A}[u_k(t)] \quad (4-11)$$

$$u_k(t) = x_n(t) + \mathcal{B}[y_k(t)] \quad (4-12)$$

Ukoliko se unutrašnji signal neurona izostavi iz promatranja tada se može definirati odnos izlazne vrijednosti (4-13) i zatvorene povratne veze (4-14) uz uvjet nekomutativne operacije $\mathcal{B}\mathcal{A} \neq \mathcal{A}\mathcal{B}$ [212].

$$y_k(t) = \frac{\mathcal{A}}{1 - \mathcal{A}\mathcal{B}}[x_n(t)] \quad (4-13)$$

$$\frac{\mathcal{A}}{1 - \mathcal{A}\mathcal{B}} \quad (4-14)$$

Za pojašnjenje utjecaja povratne veze na određivanje vrijednosti težinskih koeficijenata potrebno je razmotriti vladanje neurona sa povratnom vezom ukoliko je na ulazu vrijednost težinskog koeficijenta, a povratna veza uzrokuje kašnjenje t^{-1} . Izlazni signal koji nastaje kao rezultat zatvorene povratne veze (4-15) je tada u funkciji težinskog koeficijenta i ulazne vrijednosti (4-16) za l ciklusa kašnjenja.

$$\frac{\mathcal{A}}{1 - \mathcal{A}\mathcal{B}} = \frac{w}{1 - wt^{-1}} = w \sum_{l=0}^{\infty} w^l t^{-l} \quad (4-15)$$

$$y_k(t) = w \sum_{l=0}^{\infty} w^l t^{-l} [x_n(t)] \quad (4-16)$$

Navedeni izrazi ukazuju na upravljanje dinamičkim vladanjem neurona pomoću težinskih koeficijenata iz čega proizlazi zaključak o tri moguća vladanja:

- Uz uvjet $|w| < 1$ neuron će imati konvergentno eksponencijalno vladanje
- Uz uvjet $|w| > 1$ neuron će imati divergentno eksponencijalno vladanje
- Uz uvjet $|w| = 1$ neuron će imati divergentno linearno vladanje

Prilikom promatranja proizvodnje električne energije iz sunčanih elektrana s obzirom na temperaturu zraka, vlagu u zraku, intenzitet sunčevog zračenja i brzinu vjetra potrebno je koristiti umrežene adaptivne modele neurona što rezultira *MADLINE* (engl. *Multiple ADELIN*). modelom umjetne neuronske mreže Osnovno načelo modeliranja *MADLINE* umjetne neuronske mreže je povezivanje više adaptivnih neurona u zajedničko ustrojstvo u kojem se zbirne informacije kreću u smjeru \mathcal{A} cijele umjetne neuronske mreže [214]. Nakon učenja takve neuronske mreže i samo-određivanja težinskih koeficijenata mreža posjeduje svojstvo rješavanja negacijskih problema kakvi su međusobne ovisnosti promatranih veličina [211]. Prilikom modeliranja *MADLINE* modela umjetne neuronske mreže nužno je modelirati unutrašnji sloj neurona koji se u literaturi naziva skriveni sloj [209]–[213].

4.2.4. Ustrojstvo umjetnih neuronskih mreža

Način na koji su adaptivni neuroni međusobno organizirani i način njihova međusobna povezivanja unutar umjetne neuronske mreže utječe na mogućost učenja umjetne neuronske mreže. Najčešće ustrojstvo umjetne neuronske mreže je organiziranija po slojevima, a osnovna organizacija umjetne neuronske mreže je jedan sloj koji se sastoji od dva ili više adaptivna neurona od kojih svaki neuron dobiva ulaznu informaciju o svakoj promatranoj veličini. Zbog samo jednog sloja takva umjetna neuronska mreža se naziva jednoslojna (engl. *Single-layer*), a jedini modelirani sloj izvršava zadaću prikupljanja podataka, rad sa podacima i generiranje izlaznih vrijednosti. Jednoslojna umjetna neuronska mreža nužno posjeduje isti broj ulaznih i izlaznih podataka koliko i neurona [212].

Višeslojna umjetna neuronska mreža posjeduje zaseban sloj neurona koji služe za prikupljanje ulaznih podataka, a na svaki neuron ulaznog sloja može biti spojeno više veza sa ulaznim podacima pa čak i veze svih podataka. Takva umjetna neuronska mreža je najčešće korišteni oblik u obrađenoj literaturi, a nerijetko se takvo ustrojstvo umjetne neuronske mreže

modelira u tri sloja definiranjem ulaznog sloja neurona, skrivenog sloja neurona i izlaznog sloja neurona. Na taj način ulazni sloj priprema podatke i unutrašnje vrijednosti umjetne neuronske mreže koji služe kao ulazni podaci skrivenog sloja neurona. Skriveni sloj neurona služi kao logička i matematička veza između ulaznog sloja i vrijednosti izlaznih podataka obrađenih u izlaznom sloju neurona [212]. Broj neurona ulaznog i izlaznog sloja se kod višeslojnih umjetnih neuronskih mreža može razlikovati te je modeliranjem višeslojne umjetne neuronske mreže omogućeno djelovanje prilikom kojeg broj izlaznih veličina ne ovisi o broju ulaznih veličina.

Najvažniji sloj kod višeslojne umjetne neuronske mreže je skriveni sloj jer se njime određuje stupanj slobode i gornja ograničenja mogućnosti umjetne neuronske mreže prilikom učenja. Višeslojna umjetna neuronska mreža može posjedovati jedan ili više skrivenih slojeva neurona, a više skrivenih slojeva podrazumijeva i učenje o funkcijama višeg reda [212]. Dodatno, višeslojna umjetna neuronska mreža se može koristiti i s ciljem povećanja točnosti djelovanja [217].

Kod višeslojnih umjetnih neuronskih mreža koje posjeduje jedan sloj skrivenih neurona presudno je definirati broj skrivenih neurona kako bi modelirana umjetna neuronska mreža posjedovala potreban stupanj slobode za ponovljivo djelovanje, ali i kako ne bi stvarala šum slobodnih parametara [184], [210]. Suvišni neuroni skrivenog sloja uzrokuju izobličenje promatranih podataka i njihove međuovisnosti, dok umjetna neuronska mreža sa brojem neurona u skrivenom sloju manjim od potrebnog neće posjedovati mogućnost obuhvaćanja promatranih međuovisnosti [184]. Stupanj slobode podrazumijeva prilagodljivost umjetne neuronske mreže nasumičnoj pojavi šuma u ulaznim podacima. Vladanje prilikom kojeg je modelirana umjetna neuronska mreža u mogućnosti pružiti rezultat unatoč nasumičnoj pojavi šuma je poželjno vladanje i podrazumijeva kvalitetan model umjetne neuronske mreže [184].

U literaturi se mogu pronaći različiti primjeri određivanja optimalnog broja neurona u skrivenom sloju, a zajedničko mišljenje svih promatranih autora je kako ne postoji točno određen postupak primjenjiv prilikom promatranja svih vrsta problema. Literatura [218] ukazuje kako najmanji broj neurona skrivenog sloja mora biti veći od broja neurona ulaznog sloja, ali ne više od dvostruko veći, što upozorava i literatura [217], [219]. U [217] iznosi se i kako broj neurona skrivenog sloja treba biti između broja neurona ulaznog sloja i broja neurona izlaznog sloja, ili prema izrazu (4-17) u kojem n_s predstavlja broj neurona skrivenog sloja, n_u predstavlja broj neurona ulaznog sloja, a n_i predstavlja broj neurona izlaznog sloja.

$$n_s = \frac{2}{3}n_u + n_i \quad (4-17)$$

Broj neurona skrivenog sloja je moguće odrediti optimizacijskim postupkom nekom od metoda računalne inteligencije promatrajući pogrešku između očekivane izlazne vrijednosti umjetne neuronske mreže i vrijednosti dobivene djelovanjem izrađenog modela [95], [115], [120], [127], [217], [220], [221]. Pristup određivanju broja skrivenih neurona na temelju broj neurona ulaznog sloja nalazi se u literaturi [222] gdje se definira kako broj neurona skrivenog sloja mora biti polovina od broja neurona ulaznog sloja. U znanstvenom radu [223] predstavljeni su izrazi (4-18) i (4-19) po kojem se može izračunati potreban broj neurona prvog skrivenog sloja i potreban broj neurona drugog skrivenog sloja korištenjem novog parametra r (4-20).

$$n_{s1} = r^2 n_i \quad (4-18)$$

$$n_{s2} = r n_i \quad (4-19)$$

$$r = \sqrt[3]{\frac{n_u}{n_i}} \quad (4-20)$$

Literatura [184] ukazuje kako je moguće broj neurona odrediti pomoću izraza (4-21), ali i kako je optimalan broj neurona skrivenog sloja najbolje odrediti empirijskim postupkom.

$$n_s = \frac{n_u + n_i}{2} \quad (4-21)$$

Empirijski postupak opisan u literaturi [184] primjenjiv je prilikom proučavanja svih problema, ali zahtjeva dugotrajno i ponovljivo traganje za najboljim rješenjem. Autori [184] predlažu da se prilikom modeliranja umjetne neuronske mreže koja je sposobna učiti, skup podataka pripremljen za učenje raspodjeli na dva, približno jednaka dijela. Prvi podskup poznatih ulaznih i izlaznih veličina se u predloženom postupku iskoristi za učenje umjetne neuronske mreže, a iz drugog podskupa poznatih veličina se odstrane vrijednosti izlaznih veličina koji bi trebali biti rezultat djelovanja umjetne neuronske mreže. Nakon procesa učenja više umjetnih neuronskih mreža, sa različitim brojem neurona skrivenog sloja, na istom podskupu poznatih podataka, svakoj modeliranoj mreži se na ulazni sloj dovedu ulazni podaci drugog podskupa te se promatraju vrijednosti izlaznih veličina. Umjetna neuronska mreža koja svojim djelovanjem pruži izlaznu vrijednost sa najmanjom pogreškom u odnosu na traženu i poznatu vrijednost predstavlja optimalno modeliranu umjetnu neuronsku mrežu. Navedeni postupak je potrebno ponoviti za više različitih podjela osnovnog skupa na podskupove kako bi se provjerila ispravnost vladanja optimalne ili optimalnih umjetnih neuronskih mreža. Konačno, proces učenja je potrebno ponoviti

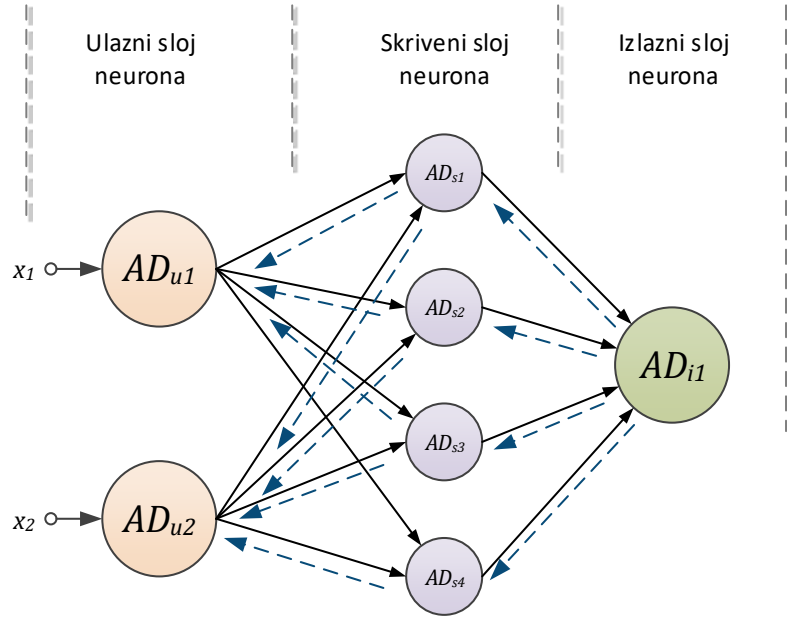
za cijeli skupo poznatih podataka na umjetnoj neuronskoj mreži koja ukaže na najbolje vladanje. Opisani postupak koriste i autori Buhari et al. [224].

4.2.5. Povratna veza i učenje umjetne neuronske mreže

Model djelovanja neurona prilikom postojanja povratne veze s ciljem učenja o vladanju prijenosne funkcije se uspješno primjenjuje prilikom modeliranja umjetne neuronske mreže s ciljem učenja o međusobnoj ovisnosti promatranih veličina. Mogućnost učenja se načelno odnosi na višeslojne umjetne neuronske mreže sa najmanje jednim skrivenim slojem neurona [212]. Kao što se u modelu neurona sa povratnom vezom računa pogreška između ciljane i dobivene vrijednosti za jednu veličinu, tako se na razini umjetne neuronske mreže sagledava odstupanje izlazne vrijednosti od ciljane vrijednosti u međuovisnosti o više ulaznih veličina korištenjem unatražnog rasprostiranja (engl. *back-propagation*) informacije o pogrešci. Algoritam unatražnog rasprostiranja informacije o pogrešci djeluje po istom načelu kao usporedba najmanjih kvadrata pogreške kod modela jednog adaptivnog neurona [212]. Učenje umjetne neuronske mreže algoritmom unatražnog rasprostiranja nužno podrazumijeva povremeni tijek informacija suprotan od smjera definiranog u modelu umjetne neuronske mreže, prikazano plavim iscrtanima linijama na primjeru prikazanog slikom 4.4.. Na istom primjeru definirana je višeslojna umjetna neuronska mreža koja se sastoji od dva *ADELIN*E modela neurona ulaznog sloja nazvanih AD_{u1} i AD_{u2} , četiri *ADELIN*E neurona skrivenog sloja nazvanih AD_{s1} , AD_{s2} , AD_{s3} i AD_{s4} te jednog *ADELIN*E neurona izlaznog sloja nazvanog AD_{i1} . Crnim linijama naznačen je tijek informacija prema *naprijed* (engl. *feed-forward*) od ulaznog sloja prema izlaznom sloju neurona, a plavim iscrtanima linijama tijek informacije o pogrešci dobivene izlazne vrijednosti u odnosu na ciljane izlazne vrijednosti prilikom učenja. Povratni put unatražnog rasprostiranja utječe na vrijednosti sigmoidnih prijenosnih funkcija i na vrijednosti težinskih koeficijenata pojedinih neurona.

Za modeliranje umjetne neuronske mreže koja posjeduje mogućnost učenja potrebno je modelirati skrivene adaptivne neurone sigmoidnih funkcija [213] međusobno spojene sa svim ulaznim i izlaznim neuronima [214], a ukoliko višeslojna umjetna neuronske mreže posjeduje više skrivenih slojeva, potrebno je međusobno spojiti sve neurone skrivenih slojeva [210], [212].

Za neurone skrivenog sloja AD_{s1} , AD_{s2} , AD_{s3} i AD_{s4} u ovoj vrsti umjetne neuronske mreže ne postoji unaprijed određeni odziv na ulazne vrijednosti te se odnos nekog neurona skrivenog sloja AD_{sj} prema ulaznim vrijednostima određuje iterativnim postupkom određivanja lokalnog gradijenta prema izrazu (4-22) za n -tu iteraciju.



Slika 4.4. Unatražno rasprostiranje informacije o pogrešci izlazne veličine kod višeslojne umjetne neuronske mreže

$$\delta_{AD_{sj}} = -\frac{\partial \mathfrak{E}(n)}{\partial y_{AD_{sj}}} G'_{AD_{sj}}(v_{AD_{sj}}(n)) \quad (4-22)$$

U izrazu (4-22) $v_{AD_{sj}}(n)$ predstavlja težinski sumu svih ulaznih veličina koje pobuđuju prijenosnu funkciju neurona [212], a pogreška \mathfrak{E} se odnosi na razliku vrijednosti izlaznog neurona AD_{i1} u odnosu na ciljanu vrijednost. Za više izlaznih neurona AD_{ik} se računa prema izrazu (4-23).

$$\mathfrak{E}(n) = \frac{1}{2} \sum_k e_k^2(n) \quad (4-23)$$

Izrazom (4-24) se izlazna vrijednost neurona ulaznog sloja promatra kao ulazna vrijednost neurona skrivenog sloja.

$$\frac{\partial \mathfrak{E}(n)}{\partial y_{AD_{sj}}} = \sum_{AD_{ik}} e_k(n) \frac{\partial e_{AD_{ik}}(n)}{\partial v_{AD_{ik}}(n)} \frac{\partial v_{AD_{ik}}(n)}{\partial y_{AD_{sj}}} \quad (4-24)$$

Ukoliko se pogreška izlaznog neurona shvati kao razlika ciljane vrijednosti $c_{AD_{ik}}$ i dobivene vrijednosti $y_{AD_{ik}}$ prema izrazu (4-25) tada se prijenosna funkcija G može zapisati izrazom (4-26).

$$e_{AD_{ik}}(n) = c_{AD_{ik}} - y_{AD_{ik}} \quad (4-25)$$

$$G'_{AD_{ik}}(v_{AD_{ik}}(n)) = -\frac{\partial e_{AD_{ik}}(n)}{\partial v_{AD_{ik}}(n)} \quad (4-26)$$

U okruženju promatranog izlaznog neurona postoji izlazna težinskih suma svih vrijednosti skrivenog sloja $v_{AD_{ik}}(n)$ koja odgovara težinskim koeficijentima pripadajućih z komunikacijskih veza i ulaznim vrijednostima izlaznog sloja $y_{AD_{sj}}$, a koja se računa prema izrazu (4-27).

$$v_{AD_{ik}}(n) = \sum_{j=0}^z w_{kj}(n)y_{AD_{sj}}(n) \quad (4-27)$$

Parcijalnim deriviranjem izraza (4-27) po $y_{AD_{sj}}$ dobije se izraz (4-28) koji predstavlja izraz za težinski koeficijent između j -tog neurona skrivenog sloja i k -tog neurona izlaznog sloja, a kombinacijom izraza (4-28) i (4-26) u izrazu (4-24) dobije se izraz (4-29) kojim se obuhvaća promjena težinskog koeficijenta prema pogrešci n -te iteracije [212].

$$w_{kj}(n) = \frac{\partial v_{AD_{ik}}(n)}{\partial y_{AD_{sj}}(n)} \quad (4-28)$$

$$\frac{\partial \mathcal{E}(n)}{\partial y_{AD_{sj}}(n)} = - \sum_k \delta_{AD_{ik}}(n)w_{kj}(n) \quad (4-29)$$

Konačno, uvrštavanjem izraza (4-29) u izraz (4-22) dobije se izraz (4-30) koji predstavlja izraz za unatražno rasprostiranje neurona skrivenog sloja promatranjem prijenosne funkcije neurona skrivenog sloja $G'_{AD_{sj}}$, težinskih faktora oko neurona skrivenog sloja $v_{AD_{sj}}$, potrebnog gradijenta $\delta_{AD_{ik}}$ težinskog koeficijenta veze između j -tog neurona skrivenog sloja i k -tog neurona izlaznog sloja.

$$\delta_{AD_{sj}} = G'_{AD_{sj}}(v_{AD_{sj}}(n)) \sum_k \delta_{AD_{ik}}(n)w_{kj}(n) \quad (4-30)$$

Primjena algoritma unatražnog rasprostiranja podrazumijeva izračun pogreške na neuronu ili neuronima izlaznog sloja te slanje informacije o pogrešci kroz cijelu mrežu u smjeru od izlaznog sloja prema ulaznom sloju kako bi se promijenili težinski koeficijenti prema uporabom Delta pravila (4-31) za cijelu umjetnu neuronsku mrežu.

$$\Delta w_{kj}(n) = \eta \cdot \delta_{AD_{ik}}(n) \cdot y_{AD_{sj}}(n) \quad (4-31)$$

Pogreška izlazne vrijednosti izlaznog neurona posljedica je izlaznih vrijednost skrivenog sloja te se izraz (4-31) mora primijeniti za sve ulazne komunikacijske veze izlaznog neurona. Također, izrazi (4-30) i (4-31) se primjenjuju na svim slojevima i za sve pripadajuće komunikacijske veze, ne samo na izlaznom sloju, te se time postiže mogućnost finog ugađanja

vladanja umjetne neuronske mreže. Prema literaturi [213], algoritam unatražnog rasprostiranja treba primijeniti na sve modelirane slojeve neurona, uključujući i na komunikacijske veze između ulaznog i skrivenog sloja neurona.

Težinska suma svih ulaznih vrijednosti nekog neurona $v_j(n)$ predstavlja pobudu sigmoidne prijenosne funkcije (4-5) te je istu moguće zapisati izrazom (4-32) [212]

$$G_j'(v_j(n)) = \frac{1}{1 + \exp^{-av_j(n)}} = \frac{a \exp^{-av_j(n)}}{(1 + \exp^{-av_j(n)})^2} \quad (4-32)$$

A kako je izlazna vrijednost rezultat prijenosne funkcije i težinske sume svih ulaznih vrijednosti prva derivacija prijenosne funkcije je tada izraz (4-33).

$$G_j'(v_j(n)) = ay_j(n)[1 - y_j(n)] \quad (4-33)$$

Prema tome, gradijent neurona skrivenog sloja koji posjeduje sigmoidnu prijenosnu funkciju se računa prema izrazu (4-34).

$$\delta_{ADs_j}(n) = ay_j(n)[1 - y_j(n)] \sum_k \delta_{ADik}(n)w_{kj}(n) \quad (4-34)$$

Uvažavajući izraz (4-33) moguće je zaključiti kako stupanj promjene težinskih koeficijenata odgovara derivaciji prijenosne funkcije te će najveća promjena nastupiti za vrijednosti koje nisu u ekstremima 0 ili 1, točnije, za one promatrane veličine koje nemaju izričito jaku ili izričito slabu međusobnu ovisnost, odnosno fizikalnu povezanost.

Navedeno svojstvo unatražnog rasprostiranja omogućava promatranje više ili manje povezanih fizikalnih veličina nekog problema kao što je predviđanje proizvodnje električne energije iz sunčanih elektrana u ovisnosti o intenzitetu sunčevog zračenja, temperaturi zraka, relativnoj vlažnosti zraka i brzini vjetra, a prema [212] izraz (4-33) osigurava stabilno i precizno provođenje učenja o promatranim veličinama i njihovim međusobnim ovisnostima.

4.3. Sustavi neizrazite logike

U drugom poglavlju ovog doktorskog rada opisani su postupci primjene sustava neizrazite logike (engl. *Fuzzy Logic*), najčešće s ciljem razvoja hibridnih metoda, prilikom modeliranja rješenja za različite inženjerske probleme. Uz navedene radove, sustavi neizrazite logike uspješno se koriste i prilikom izrade postupaka odlučivanja o prihvatljivom rješenju [149], [225]–[234], grupiranja rješenja ili događaja [60], [235]–[238], sustava analize uzroka kvarova u elektroenergetskom sustavu [202], [206], [208], [239] i elektranama [240], postupaka predviđanja

proizvodnje električne energije iz elektrana na vjetar [241], postupaka predviđanja potrošnje električne energije [242], postupaka upravljanja potrošnjom [243], analize kvalitete električne energije [244]–[249], procjene kretanja cijena električne energije [250], [251], planova razvoja aktivne distributivne mreže [226], [227], procjene stanja elektroenergetskog sustava [252] i prilikom određivanja raspodjele distribuirane proizvodnje u distributivnoj mreži [253].

Za razliku od klasične, izrazite, logike u kojoj postoje dvije razine odlučivanja o nečemu, ili nešto jest ili nešto nije, neizrazita logika dozvoljava treće stanje, odnosno mogućnost da nešto istovremeno i jest i nije, ovisno o ocjeni više vrijednosti, vjerojatnosti pojave, izračunu neizrazitih pravila i izračunu neizrazitih količnika [180]. Neizraziti skupovi i sustavi neizrazite logike ne podrazumijevaju nužno neprecizne i nepouzdana podatke ili vrijednosti, već temeljem brojčanih vrijednosti i zadanih pravila upućuju na opisne, često lingvističke neodređenosti jezičnih struktura kakvima se, temeljem bogatog iskustva, koriste poznavaoци određenog problema ili predmeta [254]–[256].

Posebna cjelina primjene sustava neizrazite logike su ekspertni sustavi (engl. *Expert Systems*) kojima se temeljem specifičnih znanja pohranjenih u određenom repozitoriju, modeliraju opažanja, iskustva, strukturirano prikazivanje podataka i donošenje zaključaka svojstveno ljudskom stručnjaku [257]. Ekspertni sustavi su u mogućnosti ubrzati proces odlučivanja promatranjem određenih kvalitativnih ili kvantitativnih informacija uspoređujući trenutne informacije sa podacima dostupnim u repozitoriju znanja. Promatranje znanja u sustavima neizrazite logike može biti globalno ili lokalno. Globalno promatranje znanja podrazumijeva promatranja cijelog repozitorija, a lokalnim promatranjem uzimaju se u obzir samo znanja koja su povezana sa promatranim veličinama [254]. Usporedbe trenutnih i postojećih informacija se obrađuju procesom zaključivanja prema zadanim pravilima koja se opisuju funkcijama pripadnosti [257], a cjelokupni proces koji se sastoji od uspoređivanja sa repozitorijem znanja, zaključivanja prema zadanim pravilima i izvršavanja prioriternih radnji naziva se mehanizam za zaključivanje (engl. *inference engine*) [256].

Određivanje prioriternih radnji predstavlja okosnicu sustava za odlučivanje zasnovanog na sustavu neizrazite logike, a postoje četiri moguća pristupa kojima se promatraju dvije veličine x i y [258]. Iako isprva različiti, svi pristupi promatranju i uspoređivanju dvaju veličina x i y zasnivaju se na usporedbi vrijednosti funkcija pripadnosti μ svake pojedine veličine, za što je nužno da promatrane veličine budu dio istog skupa X . Tri su moguća ishoda promatranja funkcija pripadnosti dvaju veličina x i y , prikazani izrazom (4-35)

$$\begin{aligned}
x &\Rightarrow \mu(x, y) > 0,5 \\
y &\Rightarrow \mu(x, y) < 0,5 \\
x, y &\Rightarrow \mu(x, y) = 0,5
\end{aligned}
\tag{4-35}$$

Dakako, da bi izrazi prema (4-35) bili mogući, potrebno je ispuniti uvjet prema (4-36), odnosno, modelirati sustav neizrazite logike na način da funkcija pripadnosti može poprimiti bilo koju realnu vrijednost u intervalu $[0,1]$.

$$\forall x, y \in X, \mu(x, y) + \mu(y, x) = 1 \tag{4-36}$$

Sustavi neizrazite logike osim neizrazitih skupova mogu obrađivati i izrazite podatke ukoliko se takvi podaci obrade postupkom neizrazite pretvorbe (engl. *fuzzification*) [259] koji podrazumijeva zapis izrazite vrijednosti pomoću funkcije pripadnosti, nakon čega se nekoj vrijednosti dodjeljuje određeno obilježje [180]. Postupak koji omogućava izvršavanje prioritete radnje podrazumijeva pretvorbu neizrazitih vrijednosti, zapisanih pomoću funkcije pripadnosti i obilježja veličine, u izrazite vrijednosti s obzirom na najveću vrijednost funkcije pripadnosti (engl. *defuzzification*).

Prošireni pojam mehanizma za zaključivanje podrazumijeva postupak neizrazite pretvorbe, određivanje vrijednosti svih funkcija pripadnosti, usporedbu dobivenih vrijednosti i pretvorbu u izrazitu ili lingvističku vrijednost [180].

4.3.1. Funkcije pripadnosti

Neizraziti skupovi S razlikuju se od izrazitih skupova nepreciznom granicom između pripadanja nekom skupu U i mogućnošću djelomičnog pripadanja u dva skupa istovremeno [259], a određeni su funkcijom pripadnosti μ neke varijable x skupu U , prema izrazu (4-37) [222], [257]. Funkcija pripadnosti može poprimiti bilo koju vrijednost u intervalu $[0,1]$.


$$S = \{x, \mu_S(x) | x \in U\} \tag{4-37}$$

Ključnima u područja neizrazite logike smatraju se radovi autora Zadeh et al. [257], [260], kojima se definiraju nelinearne i linearne funkcije pripadnosti [261].

Najčešće korištena funkcija pripadnosti je trokutasta (engl. *Triangular*), često nazivana i lambda, opisana izrazom (4-38) [180] i slikom 4.5.a. Trokutasta funkcija je linearna po dijelovima, ne mora nužno biti simetrična [261], a njeno glavno obilježje je postizanje najveće vrijednosti u jednoj točki što ju čini idealnom za modeliranje srednjih vrijednosti.

$$A(x) = \begin{cases} 0 & , x \leq a \\ \frac{x-a}{m-a} & , x \in [a, m] \\ \frac{b-x}{b-m} & , x \in [m, b] \\ 0 & , x \geq b \end{cases} \quad (4-38)$$

Sljedeća često korištena funkcija je jednočlana (engl. *singleton*), opisana izrazom (4-39) i slikom 4.5.b. koja se koristi za opisivanje veličina koje mogu poprimiti samo jednu vrijednost.




Slika 4.5. Oblik funkcija pripadnosti: a) trokutasta; b) jednočlana; c) L-funkcija

$$A(x) = \begin{cases} 0 & , x \neq m \\ 1 & , x = m \end{cases} \quad (4-39)$$

Izrazom (4-40) i slikom 4.5.c. opisana je L funkcija koja se koristi za opisivanje lingvistički niskih vrijednosti u kojem je neizrazitost naglašena u području $[a, b]$.

$$A(x) = \begin{cases} 1 & , x \leq a \\ \frac{b-x}{b-a} & , a < x \leq b \\ 0 & , x > b \end{cases} \quad (4-40)$$

Na slici 4.6. prikazane su gamma funkcija pripadnosti, trapezoidna funkcija pripadnosti i S-funkcija pripadnosti [262]. Gamma funkcija pripadnosti prikazana slikom 4.6.a [180] koristi se za opisivanje lingvistički visokih vrijednosti kojima se opisuju veličine čija vrijednost raste u području $[a, b]$. Prema izrazu (4-41), koeficijent k određuje nagib linearnog neizrazitog djela.



Slika 4.6. Oblik funkcija pripadnosti: a) gamma; b) trapezoidna; c) S-funkcija

$$A(x) = \begin{cases} 0 & , x \leq a \\ \frac{k(x-a)^2}{1+k(x-a)^2} & , x > a \end{cases} \quad (4-41)$$

Trapezoidna funkcija pripadnosti, opisana izrazom (4-42) [180] i slikom 4.6.b izvedenica je trokutaste funkcije i koristi se za opisivanje lingvistički srednjih vrijednosti nekog intervala $[b, c]$.

$$A(x) = \begin{cases} 0 & , (x \leq a) \circ (x \geq d) \\ \frac{x-a}{b-a} & , x \in (a, b] \\ 1 & , x \in (b, c) \\ \frac{d-x}{d-c} & , x \in (b, d) \end{cases} \quad (4-42)$$

Prva glatka funkcija koju je moguće jednostavno derivirati je S- funkcija, opisana izrazom (4-43) i slikom 4.6.c. Nužan uvjet ove funkcije dan je izrazom (4-44), a područje primjene jednako je kao i kod gamma funkcije.

$$A(x) = \begin{cases} 0 & , x \leq a \\ 2 \left(\frac{x-a}{m-a} \right)^2 & , x \in (a, m] \\ 1 - 2 \left(\frac{b-x}{b-m} \right)^2 & , x \in (m, b) \\ 1 & , x \geq b \end{cases} \quad (4-43)$$

$$m = \frac{a+b}{2} \quad (4-44)$$

Opisanim funkcijama pripadnosti moguće je opisati većinu promatranih veličina nekog tehničkog sustava [73], [94], [179], [185], [222], [251], [252], [263]–[268]. Složeniji sustavi neizrazite logike izrađuju se kombiniranjima najčešće korištenih funkcija pripadnosti s ciljem oblikovanja složenijih krivulja pri čemu se za svaku funkciju pripadnosti određuje udio u ukupnoj vrijednosti [259].

4.4. Evolucijsko programiranje

Uz zapažanja o znanstvenim radovima, prikazanim u drugom poglavlju ove doktorske disertacije, koji se bave upotrebljivošću metoda evolucijskog programiranja, bitno je istaknuti radove koji korištenjem metoda iz širokog raspona evolucijskog programiranja uspješno rješavaju dodatne inženjerske probleme. Autori Stepien et al. [269] složenim i prilagođenim postupkom evolucijskog algoritma rješavaju problem promjene topologije distributivne mreže s ciljem bržeg i sigurnijeg izlaženja iz stanja kvara. Istu problematiku proučavaju autori Mendes et al. [270] koji

evolucijskim algoritmom dolaze do optimalnog rješenja za uklopna stanja distributivne mreže nakon kvara. Promjenom topologije distributivne mreže bave se i autori Venkatesh et al. [271] koji evolucijskog programiranje sjedinjuju sa sustavom neizrazite logike te takvim hibridnim rješenjem pronalaze topologiju mreže koja će rezultirati najmanjim gubicima. Problem topologije distributivne mreže proučavaju i autori Carrano et al. [272], ali sa stajališta optimalnog planiranja sustava s ciljem najveće pouzdanosti i najmanjeg troška. *Monte-Carlo* simulacijom autori [272] modeliraju porast broja potrošača, a genetski algoritam sjedinjuju sa četiri analitička izračuna koja odražavaju četiri nepovezana stajališta na isti problem. Evolucijsko programiranje se uspješno koristi i u procjeni stanja elektroenergetskog sustava [146], [273], analizi kvalitete električne energije [274], [275], upravljanju potrošnjom [276] i određivanju optimalne proizvodnje jalove snage [277]. Postupci evolucijskog programiranja uspješno dokazuju svoju upotrebljivost prilikom promatranja diskontinuiranih, nerazlučivih i više-dimenzionalnih prostora pretrage, a prilikom rješavanja linearnih, kvadratnih, konveksnih i jedno-dimenzionalnih problema učinkovitost postupaka evolucijskog programiranja nije značajna [278].

Evolucijsko programiranje (engl. *Evolutionary Computation*) obuhvaća sve iterativne postupke optimizacije čija se načela djelovanja i izvođenja zasnivaju na biološkim principima [180] Darwinove teorije evolucije i opstanka najsposobnijih [279], [280], a najizraženiji primjeri evolucijskih metoda su genetski algoritmi, evolucijske strategije i evolucijski algoritmi [278]. Terminologija korištena prilikom opisivanja metoda evolucijskog programiranja preuzeta je iz biologije te se prilikom modeliranja pojedinih postupaka evolucijskog programiranja koriste izrazi za *kromosom*, *gen*, *jedinku* i *populaciju* [180]. Svaki postupak evolucijskog programiranja zasniva se na stvaranju početne populacije jedinki, odnosno skupa kromosoma, čija se dobrota određuje funkcijom cilja, a najbolje jedinke jedne populacije odabiru se za stvaranje primjeraka jedinki sljedeće populacije. Dodatno, pojedini postupci evolucijskog programiranja uvode procese križanja jedinki i nasumične mutacije jedinke kojom se povećava raznolikost populacije [32]. Procesi križanja i nasumične mutacije utječu na zbirku gena unutar kromosoma, bilo vrijednostima ili lokacijom u kromosomu. Pojedina populacija jedinki odnosi se na pojedinu iteraciju optimizacijskog procesa, pojedina jedinka podrazumijeva predloženo rješenje zapisano binarnim oblikom, ocjena dobrote je brojčana vrijednost određena proračunom funkcije cilja, a procesi križanja i nasumične mutacije djeluju na binarne zapise jedinki [35]. Neka populaciju μ će u iteraciji n ovisno o procesu križanja s i procesu nasumične mutacije v stvoriti preduvjete za novu populaciju $\lambda(n + 1)$, prema izrazu (4-45) [180].

$$\lambda(n + 1) = s(v(\mu(n))) \quad (4-45)$$

Jedinke populacije $\lambda(n + 1)$ odlikuju se svojstvima najboljih jedinki populacije $\mu(n)$, a uz dovoljan broj iteracija dolazi se do ukupno najboljeg rješenja prema funkciji cilja. Oblik funkcije cilja i vrijednost ocjene dobrote se određuje s obzirom na promatrani problem te ne mora nužno biti jedna funkcija, već može biti rezultat simulacije ili mjerenja [180].

Osnovna struktura izvođenja svih metoda evolucijskog programiranja prikazana je pseudokodom u tablici 4.1. [180], [278]

Tablica 4.1. Prikaz osnovne strukture izvođenja metoda evolucijskog programiranja

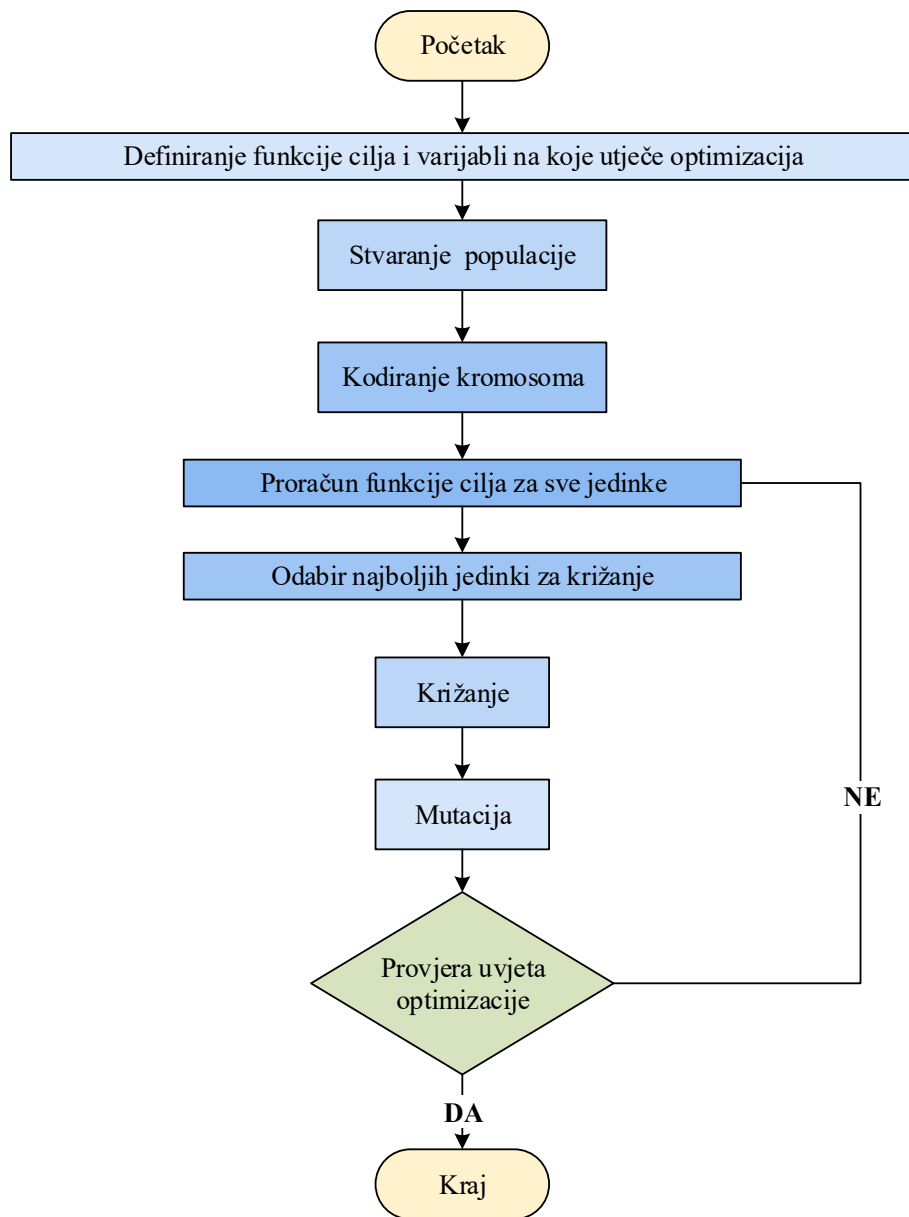
1	Početak algoritma;
2	Zadaju se početni uvjeti: $\mu, f(x), P'(n) \in I^\mu$
3	Prije prve iteracije, u trenutku n , skup rješenja $P'(n)$ je prazan skup
4	Ocjenjuju se jedinke populacije μ korištenjem funkcije cilja $f(x)$
5	Za $i = 1$ do μ ili dok se ne ispuni uvjet optimizacije
6	Popunjava se skup rješenja $P'(n) = \{a'_1, a'_2, \dots, a'_\mu\}$
7	Prema ocjeni dobrote se odabiru jedinke za stvaranje novih jedinki
8	Računaju se $a'_i(n)$ prema funkcijama $s(\mu(n))$ i $v(\mu(n))$
9	Popunjava se skup rješenja $P''(n) = \{a''_1, a''_2, \dots, a''_\mu\}$

Načelno se funkcija cilja može zapisati izrazom (4-46) u kojem vrijedi $h: X \rightarrow \mathbb{R}$, težinski koeficijent w_0 se odnosi na hijerarhijski odnos vrijednosti funkcije cilja neke jedinke u odnosu na druge jedinke, koeficijent c_j ukazuje u kolikoj je mjeri neko ograničenje j funkcije cilja narušeno, a težinski koeficijent w_j se odnosi na hijerarhijski odnos koeficijenta c_j u odnosu na isti koeficijent kod drugih jedinki [73]. Navedeni načelni pristup nije pragmatično iskoristiv jer može uzrokovati odbacivanje rješenja koja najviše ispunjavaju funkciju cilja, ali imaju značajnu vrijednost koeficijenta c_j , odnosno, mogu se nametnuti rješenja koja imaju manju vrijednost koeficijenta c_j , ali i manje zadovoljenje funkcije cilja.

$$f(x) = w_0 h(x) - \sum_{j=1}^k w_j c_j(x) \quad (4-46)$$


Genetski algoritam je najznačajniji predstavnik evolucijskih metoda koji koristi procese križanja i nasumične mutacije kako bi rezultirao najboljim rješenjem prema načelima prirodne

evolucije, a osim za rješavanje optimizacijskih problema koristi se i za klasifikacijske probleme [262]. Osnovna izvedba genetskog algoritma je prikazana na slici 4.7. [281].



Slika 4.7. Dijagram toka osnovne izvedbe genetskog algoritma

Evolucijski algoritmi su po načelima djelovanja slični genetskom algoritmu, ali nerijetko ne koriste proces križanja kako bi osigurali opstanak najbolje ocjenjene jedinke, već isključivo proces mutacije [262]. Grafički prikaz osnovne strukture evolucijskog algoritma prikazan je slikom 4.8. [282].



Slika 4.8. Dijagram toka osnovne izvedbe evolucijskog algoritma

Evolucijska strategije je zaseban postupak evolucijskog programiranja koji uvodi proces rekombinacije genetskog zapisa jedinki, a koristi se i prilagođenim procesom mutacije [262].

4.4.1. Genetski algoritam

Literatura [185] iznosi smjernice koje je potrebno zadovoljiti prilikom primjene genetskog algoritma. U istoj literaturi se navodi kako je potrebno moguća rješenja u prostoru pretrage nekog problema prikazati kao kromosome, najčešće binarnim zapisom. Dodatno, potrebno je pravilno odrediti veličinu populacije kako bi broj jedinki bio dovoljan da se osigura kretanje ka globalnom rješenju, uz postizanje najmanje zahtjevnog računalnog procesa. Ocjena dobrote pojedine jedinke je zaseban izazov koji se može riješiti integriranim izračunom ili razvojem hibridne metode u kojoj će se ocjena dobrote provoditi zasebnim postupkom. Posebna pozornost je u navedenoj literaturi usmjerena ka metodologiji po kojoj se izvršava odabir najboljih jedinki s ciljem reprodukcije, odnosno stvaranja nove populacije, uvažavajući pri tome mogućnost da pojedina rješenja budu krivo odbačena.

Izvođenje genetskog algoritma podrazumijeva cjelobrojne iteracije kojima se uzrokuju promjene u populacijama jedinki uvažavanjem svojstava najboljih jedinki svake generacije. Dva su načina na koji je moguće modelirati izvođenje genetskog algoritma, generacijski pristup (engl. *generational method*) i stacionarni pristup (engl. *steady-state method*) [73]. Generacijski pristup odgovara postupku opisanom do sada u ovom potpoglavlju, pri kojem najbolje ocjenjene jedinke predstavljaju predložak za izradu svih jedinki nove populacije. Generacijskim pristupom neka populacija μ rezultira potomcima λ , uz uvjet $\lambda \geq \mu$, a ukoliko je populacija λ veća od populacije μ smatra se da je pronalaženje globalno optimalnog rješenja izgledno [73].

Stacionarni pristup se razlikuje po tome što se dvije najbolje ocjenjene jedinke neke populacije μ koriste za izradu jedne nove jedinke ($\mu + 1$) koja zatim zauzima mjesto neke lošije ocjenjene jedinke u populaciji ili jedinke nasumično odabrane za zamjenu. Ukoliko se populacija novih jedinki označi sa λ , tada se stacionarni pristup modeliranju genetskog algoritma opisuje kao ($\mu + \lambda$). Odabir jedinke za zamjenu, odnosno odabir jedinke koja će ustupiti svoje mjesto novoj u

populaciji novoj jedinki, posebna je problematika modeliranja, detaljno obrađena u potpoglavlju 42.3 literature [73]. U oba pristupa modeliranju genetskog algoritma se koriste proces križanja za preuzimanje najboljih svojstava pojedinih jedinki i proces nasumične mutacije za stvaranje novih varijanti jedinki te proces reprodukcije najbolje ocjenjenih jedinki [283].

Stacionarni pristup modeliranju genetskog algoritma u kojem se najlošije ocjenjena čestica zamjenjuje najbolje ocjenjenom česticom nužno podrazumijeva i očuvanje najboljih jedinki, odnosno njihovu izolaciju u zaseban skup koji nije podložan izmjenama ili zamjenama. Takav pristup izolacije najboljih jedinke se u literaturi naziva načelom *elitizma* [38], [73], [180], [278], [282], [284], [285]. Elitne jedinke jedne iteracije izuzimaju se iz procesa mutacije, a moguće je izuzeti ih iz budućih križanja sa jedinkama potomcima koje su nastale kao rezultat prvog križanja te tako izbjeći načelno kloniranje rješenja [185], [285]. Prema literaturi, modeliranjem elitizma se pozitivno utječe na uspješno izvođenje genetskog algoritma [282], [284]. Kod genetskog algoritma se modeliranjem elitizma najbolje jedinke jedne generacije pojavljuju i u sljedećoj generaciji [35].

Modeliranje odnosa među jedinkama, točnije, njihovo određivanje po dobroti i način na koji se jedinke međusobno natječu za dominaciju unutar populacije, detaljno je opisano u potpoglavlju 42.2 literature [73], u potpoglavlju 2.1 literature [38], u potpoglavlju 5.6 literature [185] i u potpoglavlju 17.3 literature [279]. Odnos među jedinkama može biti modeliran nasumičnom selekcijom, razmjernom selekcijom, slučajnim općim uzorkovanjem, metodom skaliranja, poretkom jedinki, odabirom putem natjecanjem ili odabirom putem skraćivanja [73].

Nasumična selekcija (engl. *Radnom Selection*) je najjednostavniji pristup modeliranju odnosa među jedinkama prilikom koje se dvije nasumično odabrane jedinke koriste za izradu nove jedinke [73]. Razmjerna selekcija (engl. *Proportional Selection*) se u literaturi naziva i selekcija odabira ruletom (engl. *Roulette-wheel selection*), a podrazumijeva određivanje vjerojatnosti p_i za određenu jedinku prema kojoj će biti odabrana kao jedinka koja daje novu generaciju na temelju određivanja odnosa ocjene dobrote te jedinke $f_i(x)$ prema zbroju svih ocjena dobrote $f_i(y)$ neke populacije, prema izrazu (4-47) [279].

$$p_i = \frac{f_i(x)}{\sum_y f_i(y)} \quad (4-47)$$

Slučajno opće uzorkovanje (engl. *Stochastic Universal Sampling*) se koristi kod generacijskog pristupa genetskom algoritmu jer se tako smanjuje obično dugotrajno vrijeme izvođenja genetskog algoritma [73].

Poredak prema ocjeni dobrote (engl. *Rank Selection*) podrazumijeva rangiranje jedinki od najbolje ocjenjene jedinke $\mu - 1$ u populaciji μ do jedinke sa najmanjom ocjene dobrote, obično vrijednosti 0 [278], a uvođenjem parametra α za broj potomaka koje može stvoriti najbolja jedinka i parametra β za broj potomaka koje može stvoriti najlošije ocjenjena jedinka, vjerojatnost da neka jedinka i bude izabrana za stvaranje nove jedinke se računa prema izrazu (4-48) [278].

$$p_i = \frac{\beta + \left(\frac{i}{\mu - 1}\right)(\alpha - \beta)}{\mu} \quad (4-48)$$

Ukupan zbroj vjerojatnosti za sve jedinke se računa prema izrazu (4-49) [278] iz kojeg vrijedi kako broj potomaka najbolje jedinke može biti najviše dvostruko veći od prosječno dopuštenog broja potomaka pripadajuće populacije, čime se izbjegava prijevremena konvergencija postupka optimizacije.

$$\sum_{i=0}^{\mu-1} \frac{\beta + \left(\frac{i}{\mu - 1}\right)(\alpha - \beta)}{\mu} = \frac{1}{2}(\alpha + \beta) \quad (4-49)$$

Rangiranje jedinki po ocjenama dobrote najrazumljiviji je način modeliranja odnosa među jedinkama jer se identičan pristup koristi kod uzgoja životinja prilikom odabira jedinki sa poželjnim svojstvima koje je cilj prenijeti na potomke [279].

Odabir jedinki koje će dati potomke putem natjecanja (engl. *Tournament Selection*) zahtjeva definiranje podskupa jedinki ϑ koji može sadržavati dvije ili više jedinke koje se izdvajaju kako bi se određenim svojstvima natjecale za dominantu poziciju podskupa ϑ . Izdvajanje može biti nasumično ili određeno poretkom jedinki. Jedinka koja postigne dominantnu poziciju unutar podskupa ϑ postaje jedinka nove populacije λ , a postupak natjecanja se ponavlja definiranjem novog podskupa ($\vartheta + 1$) koji će dati sljedeću jedinku populacije λ [278].

Struktura izvođenja genetskog algoritma koji koristi razmjernu selekciju jedinki prikazana je pseudo-kodom u tablici 4.1. [72], [130], [281]. U slučaju modeliranja natjecanja među jedinkama, najčešće prilikom rješavanja problema više-ciljne optimizacije, dio pseudo-koda od linije 11 do linije 23 se zamjenjuje iterativnim postupkom koji definira novi podskup ϑ iz kojeg se odabiru jedinke za ostatak postupka. Dodatno, novi iterativni postupak uvodi skup elitnih jedinki koji služi kao predložak skupa λ [281], a u samom početku izvođenja je potrebno definirati dvije suprotstavljene početne populacije.

Tablica 4.2 Prikaz strukture izvođenja optimizacije genetskim algoritmom uz razmjernu selekciju jedinki

1	Početak algoritma;
2	Postavljanje funkcije cilja $f(x)$ i definiranje broja varijabli n_v koje se optimiziraju i intervala vrijednosti $[max, min]$ za svaku varijablu
3	Definiranje kriterija zaustavljanja najvećim dopuštenim brojem iteracija ili pomoću $f(x)$
4	Određivanje broja jedinki populacije μ
5	Određivanje koliko mutacija obuhvaća kromosom u intervalu $[0, 1]$, najčešće je proizvoljna vrijednost uz uvjet $m_r < 0,5$
6	Određivanje koliko jedinki populacije μ ostaje u populaciji λ , $k = m_r \cdot \mu$
7	Definiranje nužnog uvjeta $N_t = n_v$ za korištenje genetskog algoritma za racionalne brojeve
8	Izračun broja mutacija $n_m = (\mu - 1) \cdot N_t \cdot m_r$
9	Izračun broja parova jedinki za potomstvo $n_{pot} = \frac{\mu - k}{2}$
10	Postavljanje brojača iteracije $i = 0$
11	Stvaranje početne populacije nasumičnim postavljenjem vrijednosti za svaku n_v unutar intervala dopuštenih vrijednosti, $(max - min) \cdot rand(\mu, n_v) + min$
12	Proračun $f(x)$ i zapis vrijednosti parametra optimizacije $f(i) \rightarrow p_{opt}$
13	Rangiranje jedinki od najmanje vrijednosti p_{opt} do najveće.
14	Određivanje jedinke koja posjeduje najmanji p_{opt}
15	Izračun srednje vrijednosti p_{opt} za populaciju i
16	Postavljanje brojača iteracije $i = i + 1$
17	Reprodukcija jedinki; Određivanje vjerojatnosti p_i za svaku jedinku da bude odabrana za potomstvo prema (4-47)
18	Određivanje dvije jedinke sa najvećom vjerojatnošću odabira, p_1 i p_2 , iz skupa potencijalnih jedinki $(p_1, p_2, \dots, p_{n_{pot}})$
19	Križanje, postavljanje brojača križanja $i_c = 1$ i uvjeta $i_c \leq n_{pot}$ i $i_d = 2$ do $k + 1$
20	Odabir jedinki za križanje pretragom kromosoma
21	Ako $p_1(i_c) \leq p_i(i_d)$ i ako $p_1(i_c) > p_i(i_d - 1)$ tada vrijedi $m(i_c) = i_d - 1$
22	Ako $p_2(i_c) \leq p_i(i_d)$ i ako $p_2(i_c) > p_i(i_d - 1)$ tada vrijedi $z(i_c) = i_d - 1$
23	Postavljanje brojača $i_c = i_c + 1$
24	Određivanje koji dio kromosoma se križa, $xp = rand(1, n_{pot}) \cdot N_t$
25	Križanje m i z , $m(i_c), xp(i_c) - z(i_c), xp(i_c)$
26	Nastanak prvog potomka koji ima vrijednosti $m(i_c)$
27	Nastanak drugog potomka koji ima vrijednost $z(i_c)$

28	Stvaranje nasumičnih mutacija na jedinkama do dopuštenog broja mutacija n_m , $(max - min) \cdot rand + min$
29	Proračun $f(x)$ za potomke i jedinke mutacije
30	Rangiranje jedinki od najmanje vrijednosti p'_{opt} do najveće.
31	Određivanje jedinke koja posjeduje najmanji p'_{opt}
32	Izračun srednje vrijednosti p'_{opt} za populaciju $i + 1$
33	Provjera uvjeta optimizacije prema najvećem dopuštenom broju iteracija ili prema ispunjenu vrijednosti p'_{opt}


Zbog procesa reprodukcije, križanja i mutacija genetski algoritam je nerijetko računalno zahtjevan, a set problema koji se mogu riješiti genetskim algoritmom može biti ograničen.

4.5. Inteligencija roja čestica

Inteligencija roja čestica (engl. *Swarm Intelligence* – SI) se prema nekim izvorima smatra zasebnom cjelinom računalne inteligencije [180], [182], [280], [286], a prema određenoj literaturi je dio evolucijskih algoritama [189], [262], [287]. Neizražena razgraničenja u principima djelovanja određenih metoda i međusobna bliskost određenih pravila odvijanja nerijetko stvaraju nejasnu predodžbu o razlikama između pojedinih pristupa [32], a time uzrokuju i višeznačnu podjelu među metodama. Ključnom literaturom u području inteligencije roja čestica prema navodima u mnoštvu znanstvenih radova smatraju se djela autora Kennedy [182] u kojem se detaljno opisuje nastanak navedene metode i poveznica sa evolucijskim algoritmima.

Princip djelovanje metoda inteligencija roja se najbolje objašnjava stohastičkim biološkim principima djelovanja jata ptica ili riba, roja pčela ili mrava [182], [189], [265], [280], [286], [287], a pojam *čestice* kod svih navedenih bioloških principa djelovanja se odnosi na jedinku unutar koherentne skupine. Tim pristupom se i let ptica definira kao *roj čestica* u kojem se pojam *čestice* odnosi na predmet *ptice*, a pod pojmom *roja* se podrazumijeva predmet *jato* [182]. Temeljni pojam inteligencije roja čestica podrazumijeva sve algoritme koji svoje djelovanje zasnivaju na međusobnoj suradnji pojedinih čimbenika skupine i težnji svih jedinki u praćenju najbolje jedinke pri čemu se pojedinci ne natječu za prevlast i dominaciju nad drugim pripadnicima skupine [189], [280], što je slučaj u evolucijskim pristupima. Zajednička obilježja metoda inteligencije roja i evolucijskih metoda su princip stohastičkog nastanka početne populacije jedinki, ocjena dobrote jedinki prema funkciji dobrote ili pripadajućem proračunu, promjena populacije na temelju individualnih pokazatelja dobrote i iterativno ponavljanje dok se kriteriji ne ispune. Sličnost metode inteligencije roja čestica i genetskog algoritma očituje se u nasumičnom generiranju

početne generacije jedinki, ocjeni pojedinih jedinki prema funkciji dobrote i nasumičnoj promjeni određenih svojstva jedinke kako bi se izbjeglo *zapunjanje* u lokalnim rješenjima. Kod metoda inteligencije roja najčešće promijenjeno svojstvo jedinke je brzina kretanja kroz višedimenzionalni prostor pretrage. Osnovna izvedba optimizacijske metode inteligencije roja čestica prikazana je dijagramom toka na slici 4.9. [282], [288].



Slika 4.9. Dijagram toka osnovne izvedbe optimizacijske metode inteligencije roja čestica

Metodama inteligencije roja čestica pripadaju optimizacijski algoritmi kolonije mrava (engl. *ant colony optimization*), algoritmi umjetne kolonije pčela (engl. *artificial bee colony*), višeciljni šišmiš algoritmi (engl. *multiobjective bat algorithm*), algoritam krijesnica (engl. *firefly algorithm*), algoritam traženja ptica kukavica (engl. *Cuckoo search algorithm*), algoritam oprašivanja cvijeća (engl. *Flower Pollination Algorithm*), algoritam umjetnog imunološkog sustava (engl. *artificial*

immune system), algoritam vučjeg čopora (engl. *wolf search algorithm*) [289], algoritam hranjenja bakterija (engl. *Bacterial Foraging*) i algoritam čopora mačaka (engl. *Cat Swarm Optimization*) [288].

U teorijskim razmatranjima, inteligencija roja se opisuje kao kretanje čestica kroz višedimenzionalni prostor problema po principu praćenja čestice *vode*, odnosno najbolje čestice u nekom trenutku kretanja, ili skupa određenih pravila umjesto *vode*, s ciljem ostvarenja boljitka za cijeli roj [180]. Čestice se kreću u roju kroz višedimenzionalni prostor problema sve dok promjena kretanja ne bude beznačajno mala što ukazuje na pronalazak globalno najboljeg rješenja. Ponašanje svake čestice je u algoritmima inteligencije roja definirano kroz dva gledišta: društveni model i kognitivni model. Društveni model čestice oblikuje njeno ponašanje isključivo kroz praćenje najbolje jedinke te ne uzima u obzir individualnu spoznaju jedinke. Osim prema najboljoj jedinki, čestice se mogu formirati da apsolutno vjeruju susjednim jedinkama i pri tome zanemaruju individualna iskustva te svoje djelovanje formiraju isključivo prema iskustvima drugih. Suprotan pristup je kognitivni model čestice prilikom kojeg se svaka čestica smatra zasebnom jedinkom i kretanje kroz višedimenzionalni prostor pretrage se odvija isključivo prema vlastitom iskustvu i vlastitim spoznajama [182], [280], [287]. Prilikom modeliranja metode inteligencije roja čestica moguće je precizno ugoditi vladanje čestica prema navedena dva modela te se time ostvaruje virtualno beskonačno mnogo mogućnosti za kreiranje specifičnih algoritama *po mjeri* promatranih rješenja. Čestice koje pamte vlastite najbolje položaje u višedimenzionalnom prostoru pretrage mogu u većoj ili manjoj mjeri uspoređivati svoja iskustva sa ostalim česticama te pri tome biti određene brzinom kretanja, snagom privlačenja prema prethodnim iskustvima ili prema iskustvima susjednih čestica.

Metoda inteligencija roja čestica koju predlaže Kennedy [182] ne posjeduje genetske operatore mutacije ili križanja, niti genetski zapis čestica te je prema tome postupak manje zahtjevan za modeliranje. Čestice se međusobno ne zamjenjuju, već bivaju privučene u prostor pretrage u blizini najbolje ocjenjene čestice, a brzinu kojom se kreću prema zajedničkom prostoru mogu same određivati. Svaka čestica pamti individualna najbolja rješenja u prostoru pretrage, a kako postoji samo jedna najbolja čestica koja dijeli informaciju sa svima, ne mora nužno postojati interakcija između svih jedinki, što je nužan i računalno zahtjevan preduvjet za pravilno izvođenje genetskog algoritma [189].

Obzirom da se metoda inteligencije roja čestica može modelirati na način da čestice posjeduju vlastitu informaciju, ali i informaciju čitavog roja, moguće je koordinacijom informacija

utjecati na ponašanje cijelog roja. Naime, kako je opisano u uvodnim razmatranjima ovog poglavlja, pokušaj optimizacije pogona više distribuiranih izvora u potpuno aktivnoj distributivnoj mreži korištenjem genetskog algoritma ili hibridne metode zasnovane na genetskom algoritmu složen je postupak koji prema iskustvu autora ove doktorske disertacije nije ponudio odgovarajuće rješenje. Najbolja rješenje prve iteracije, odnosno najbolja jedinka prve generacije genetskog algoritma, mora postati rješenje pogona prve elektrane, ali genetski algoritam zahtjeva od najbolje jedinke informaciju o genetskom zapisu kako bi poslužila kao predložak formiranja novih jedinki. U tom slučaju nova generacija započinje sa genetskim zapisom koji je već određen u mreži i kojeg ne treba promatrati u budućim rješenjima te je nastala potpuno kriva selekcija nove generacije koja optimalna rješenja traži u području koje je prethodnom generacijom već riješeno.

Prirodno vladanje inteligencije roja čestica, odnosno biološko ponašanje jata ptica, riba ili roja pčela ili mrava, omogućava razvoj drugačijeg pristupa za rješavanje promatranog problema. U metodi inteligencije roja čestica roj se kreće homogeno kroz prostor pretrage, a svaka čestica prilikom kretanja posjeduje mogućnost korištenja individualnih i grupnih informacija. Način na koji se modelira metoda inteligencije roja čestica i postupak kojim se identificira optimalno rješenje se ponekad razlikuju u navedenoj literaturi. U ovoj doktorskoj disertaciji koristi se iskustvo modeliranja genetskog algoritma i nužni princip elitizma. Ipak, metoda predložena ovom doktorskom disertacijom ne sjedinjuje dvije meta-heurističke metode, genetski algoritam i inteligenciju roja čestica, već isključivo koristi načelo elitizma genetskog algoritma kako bi se najbolja rješenja inteligencije roja čestica izolirala u skup rješenja i na taj način formirali informaciju o optimalnom pogonu više elektrana u sustavu.

Čestica *vođe*, odnosno čestica sa najboljim rješenjem u prvoj iteraciji postaje integrirana u distributivni sustav, tj. daje informaciju o potrebnom pogonu distribuirane elektrane u nekom čvoru. Preostale čestice i roj u cjelini se u trenutku *gubitka vođe* modeliraju tako da promijene svoje kretanje prema prostoru sljedeće najbolje informacije gdje se postupak selekcije *vođe* ponavlja. Tim načinom osigurano je skupno kretanje čitavog roja od najboljeg dijela prostora pretrage prema sljedećem malo manje najboljem, zatim sljedećem itd., te je jedna generacija čestica dovoljna za sva rješenja. Ovakvim prilagođenim ponašanjem inteligencije roja u potpunosti je moguće izbjeći iterativno kreiranje novih generacije i iscrpne proračuna za svaku kreiranu generaciju što znatno utječe na računalnu zahtjevnost algoritma.

Svaka informacija o planu pogona distribuirane proizvodnje u nekom čvoru je zapravo informacija o čestici u tom dijelu prostora pretrage, a broj aktiviranih elektrana odgovara broju

izgubljenih vođa. Poštivanjem tehničkih uvjeta promatranog distributivnog sustava i ograničenja simulacije te hibridizacijom postupka integriranjem proračuna tokova snaga osigurano je iterativno kretanje od jednog dijela prostora do drugog dijela prostora, do trećeg dijela, itd. Svaka čestica koja izolacijom po kriteriju elitizma postane dio ukupnog rješenja pridonosi boljitku ukupnog rješenja te upotpunjuje korisnost i upotrebljivost predložene metode. Čestice prestaju biti dio integriranog rješenja kada roj više ne može poštivati ograničenja optimizacije ili kada se funkcija cilja ne može dodatno zadovoljiti.

Posebno izrađen i prilagođen model inteligencije roja čestica korišten za rješavanje optimizacijskog problema planiranja pogona distribuiranih izvora u potpuno aktivnoj distributivnoj mreži razlikuje se od uobičajenog modela upravo po selekciji elitnih čestica. U osnovnom modelu inteligencije roja, najslabije čestice iščezavaju i time roj postaje skalarno kvalitetniji razgradnjom najlošijih čestica [180], dok u predloženom pristupu elitne čestice napuštaju roj te se integriraju u dio ukupnog rješenja kako bi roj mogao nastaviti kretanje prema drugom dijelu prostora rješenja. Upravo načelo izolacije elitnih čestica odgovara načelu izolacije elitnih jedinki kod genetskog algoritma, ali je kod predloženog postupka u ovom radu riječ o drugačijem gledištu izolacije, odnosno, iterativnom izdvajanju najboljih čestica iz roja, umjesto o selekciji najboljih jedinki. Izolacija elitnih jedinki obilježje je genetskog algoritma, a u predloženom pristupu uspješno je integrirana u metodu inteligencije roja na inovativan način izolacije elitnih čestica. Čestice se u predloženoj metodi prema roju vladaju samostalno poštujući zadana pravila brzine i inercije, ali se uz samostalno vladanje promatra vladanje susjedne čestice pa time i kretanje cijelog roja.

4.5.1. Model djelovanja

Prikaz modela djelovanja metode inteligencije roja čestica u ovom dijelu potpoglavlja 4.5 odnosi se na inercijski algoritam inteligencije roja čestica (engl. *weighted PSO*) koji se od uobičajenog algoritma razlikuje po modeliranju inercije čestice. Inercija čestice se modelira kako bi se brzina čestice smanjivala sa porastom broja iteracija [288] te tako postepeno približilo globalno najboljem rješenju uz smanjenje rizika od promašaja najboljeg rješenja. Kretanje roja čestica kroz višedimenzionalni prostor pretrage određeno je brzinom *i-te* čestice b_i , inercijom čestice w , položajem čestice u roju p_i i ocjenom dobrote svake čestice koja se u predloženom postupku računa proračunom tokova snaga opisanog u prethodnom poglavlju. Za k optimiziranih veličina, prilikom *i-te* iteracije kretanja, neka *j-ta* čestica se zapisuje kao vektor $X_j(i) = [x_{j,1}(i); x_{j,2}(i); \dots; x_{j,k}(i); \dots; x_{j,d}(i)]$ u kojem je svaki x veličina koja se optimizira, a d

predstavlja broj kontrolnih varijabli [290]. Roj se sastoji od n čestica i zapisuje se vektorom $roj(i) = [X_1(i), X_2(i), \dots, X_n(i)]$ [290]. Nakon svake iteracije kretanja roja najbolje rješenje se pohranjuje u vektor rješenja, a brzine i položaji preostalih čestica se mijenjaju prema izrazu (4-50) i (4-51) [180], [182], [189], [217], [221], [265], [280], [287], [288], [290]:

$$b_{ij,nova} = w \times b_{ij,trenutno} + c_1 r_1 (pbest_{ij,trenutno} - p_{ij,trenutno}) + c_2 r_2 (gbest_{ij,trenutno} - p_{ij,trenutno}) \quad (4-50)$$

$$p_{ij,nova} = p_{ij,trenutno} + b_{ij,nova} \quad (4-51)$$

gdje su r_1 i r_2 nasumično odabrani brojevi u intervalu $[0,1]$, c_1 je konstanta uvažavanja individualnog iskustva i prikupljenih informacija, a c_2 je konstanta uvažavanja informacija susjednih čestica i iskustva roja.

Vrijednosti konstanti c_1 i c_2 su proizvoljne, no u literaturi se spominju pravila prema kojima ih je najbolje odrediti poput:

- $c_1 = c_2 = 2$ [35], [61], [288], [291], [292],
- $c_1 = c_2 = 0,25$ [290],
- $c_1 = 3; c_2 = 1$ [280],
- $c_1 = c_2 = 2,1$ [293],
- $c_1 = c_2 = 1,49618$ [294],
- $c_1 = 1,3; c_2 = 2$ [295],
- $c_1 = 0,5; c_2 = 2$ [295],
- $c_1 = 1,8; c_2 = 2$ [295];
- $c_1 = c_2 = 1,5$ [296],
- $c_1 = c_2 = 2,05$ [62],
- $c_1 = c_2 = 1,49455$ [297]
- $[c_1, c_2] = [0, 2]$ [298]

Vrijednosti konstanti c_1 i c_2 je moguće odrediti naprednim modeliranjem metode roje čestica prilikom kojeg konstante postaju dio kontrolnih varijabli te se time optimiziraju i njihove vrijednosti [32], [94], a moguće ih je u svakoj iteraciji nasumično mijenjati [299]. Ukoliko je cilj naglasiti djelovanje jednog iskustva čestice na štetu uvažavanja drugog iskustva tada je, u pravilu, potrebno poštivati uvjet $c_1 + c_2 = 4$ [180].

Prema izrazu (4-50) čestica određuje svoje kretanje u višedimenzionalnom prostoru pretrage $[-s, s]$ na temelju vlastitog najboljeg iskustva p_{best} (engl. *personal best*) i na temelju iskustva najbolje čestice u roju g_{best} (engl. *global best*) [180], [189], [217], [221], [280].

Brzinu čestice potrebno je ograničiti kako čestica ne bi napustila prostor pretrage zbog prevelike brzine i nemogućnosti praćenja roja. Štoviše, ukoliko se dogodi da tijekom kretanja po prostoru pretrage upravo najbolje ocjenjena čestica naglo poveća brzinu, moguće je napuštanje prostora pretrage cijelog roja. Prilikom promatranja problema više distribuiranih izvora u potpuno aktivnoj distributivnoj mreži broj čestica u roju odgovara broju promatranih upravljivih elektrana te se brzina čestice ograničava veličinom roja u prostoru pretrage prema izrazima (4-52) i (4-53).

$$v_{max} = \delta(p_{max,j} - p_{min,j}) \quad (4-52)$$

$$v_{min} = \delta(p_{min,j} - p_{max,j}) \quad (4-53)$$

U izrazima (4-52) i (4-53) p_{max} i p_{min} se odnose na krajnje položaje čestica u roju, a δ je konstanta koju se empirijski određuje kako čestice ne bi težile rubnim područjima pretrage [217].

Dodatni postupak ograničenja brzine čestice se ostvaruje promjenom inercije čestice gdje se veća vrijednost inercije koristi u početku kretanja roja i za osiguranje globalne pretrage rješenja, a manja vrijednost inercije se koristi pri kraju optimizacije za pojednostavljeno kretanje oko najboljeg rješenja [182]. Za određivanje odgovarajućeg iznosa inercije čestice koristi se izraz (4-54) u kojem se uvodi novi parametar $\varphi = c_1 + c_2$ [288], odnosno izraz (4-55) koji uzima u obzir broj iteracija optimizacije te gornje ograničenje inercije w_{max} i donje ograničenje inercije w_{min} [287]:

$$w = \frac{2}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|} \quad (4-54)$$

$$w = w_{max} - \frac{(w_{max} - w_{min})}{\text{najveći broj iteracija}} \times \text{broj iteracije} \quad (4-55)$$

Optimizacijska metoda inteligencije roja čestica (engl. *Particle Swarm Optimization – PSO*) svojim načelima djelovanja podrazumijeva usporedno optimiranje svih čestica što znatno utječe na računalnu zahtjevnost izvođenja, a kako je za ispravno izvođenje načelno potrebno modelirati samo funkcije (4-50) i (4-51) broj modeliranih parametara je znatno manji nego kod genetskog algoritma što povoljno utječe na vrijeme izvođenja optimizacije. U predloženom postupku koriste

se izrazi (4-50) - (4-53) i (4-55), a optimizacijski model je i u tom obliku manje računalno zahtjevan od modela zasnovanog na genetskom algoritmu.

Ocjena dobrote pojedine čestice u predloženoj metodi rezultat je proračuna tokova snaga integriranog u proceduru optimizacije metodom roja čestica. Sjedinjenjem iterativnog proračuna tokova snaga i stohastičkih načela metode inteligencije roja čestica osigurano je obuhvaćanje većeg prostora pretrage uz precizne i točne rezultate optimizacije.

Istovremenim uvažavanjem individualnih informacija svake čestice pohranjenih u vektoru individualnih rješenja X_j^{ind} i informacija roja pohranjenih u vektoru X^{roj} omogućena je elastičnost pretrage i uspješno se izbjegavaju kriva rješenja lokalnog optimuma. Vektori individualnih rješenja i rješenja roja se definiraju izrazima (4-56) i (4-57):

$$X_j^{ind}(i) = [x_{j,1}^{ind}(i), x_{j,2}^{ind}(i), \dots, x_{j,d}^{ind}] \quad (4-56)$$

$$X^{roj} = [X_{i,j}^{roj}, X_{i+1,j+1}^{roj}, \dots, X_{i+n,j+n}^{roj}] \quad (4-57)$$

Čestica koja posjeduje najbolje individualno rješenje prve iteracije biva u postupku predloženom u ovoj doktorskoj disertaciji izolirana u skup rješenja roja te se kretanje ostatka roja nastavlja prema sljedećoj informaciji o najboljem rješenju, uz izuzimanje prostora već postojećeg rješenja.

Uvedeni postupak eliminacije elitnih čestica prvotno je zamišljen kao procedura kojom će se popunjavati skup rješenja, ali je ubrzo zabilježena dodatna kvaliteta predloženog postupka razvidna u izbjegavanju prerane konvergencije postupka i povećanju prostora pretraživanja. Konačno, u istraživanju koje za rezultat ima ovaj doktorski rad, broj čestica početne populacije roja odgovara broju promatranih upravljivih elektrana pa time stohastička priroda metode inteligencije roja čestica ne utječe negativno na konvergenciju globalno najboljih rješenja jer se već u nultoj iteraciji razmatraju svi čvorovi u distributivnoj mreži. Podatak o proizvodnji upravljive elektrane postaje sastavni dio opisa promatranog distributivnog sustava, te se dobrote preostalih čestica računaju sa novim podacima.

Osnovna struktura izvođenja optimizacije metodom roja čestica prikaza je pseudo-kodom u tablici 4.3:

Tablica 4.3 Prikaz osnovne strukture izvođenja optimizacije metodom roja čestica

1	Početak algoritma;
2	Postavljanje brojača iteracije $i = 0$ i stvaranje n čestica na nasumično odabranim položajima u prostoru pretrage;
3	Definiranje roja $\{X_j(0), j = 1, 2, \dots, n\}$;
4	Svaka čestica se smatra potencijalnim rješenjem: $X_j(0) = [x_{i,1}(0); x_{i,2}(0); \dots, x_{i,k}(0)]$; Svaka kontrolna varijabla je definirana u intervalu $[x_{min}, x_{max}]$;
5	Provjera dobrote svake čestice zasebno i postavljanje $pbest$ i $gbest$. Ukoliko sve čestice zadovoljavaju ograničenja slijedi korak 6. U protivnom se postupak ponavlja od koraka 2;
6	Povećanje brojača iteracije za 1: $i = i + 1$;
7	Promjena brzine čestica prema izrazu (4-50);
8	Promjena položaja čestice prema izrazu (4-51);
9	Provjera dobrote čestice za nove položaje i brzine;
10	Pretraga za najboljim rješenjima funkcijama min ili max , ovisno o cilju optimizacije;
11	Kriterij zaustavljanja Ukoliko su kriteriji zaustavljanja zadovoljeni optimizacijski postupak se zaustavlja Ukoliko kriteriji zaustavljanja nisu zadovoljeni postupak se ponavlja od koraka 6;

Kriterij zaustavljanja može biti postizanje dopuštenog broja iteracija ili konvergencija rješenja prilikom koje pogreška između rezultata funkcije i cilja i ocjena dobrote postigne određenu vrijednost.

Prilikom proučavanja čestica u prostoru pretrage koji je definiran topologijom distributivne mreže položaji čestica su predodređeni brojem čvorova u mreži i mogu se odrediti cjelobrojnim postupkom opisanim u radovima [53], [61], [300]–[303], no određivanje optimalne snage distribuiranog izvora nije cjelobrojni problem, već je problem zapisan decimalnim brojevima te je vezivanje dva različita brojeva cilja poseban izazov [17]. Radovi u kojima se proučava problematika promjene topologije elektroenergetske mreže uspješno prikazuju upotrebu cjelobrojno modelirane metode inteligencije roja čestica jer su uklopna stanja također cjelobrojni problem [60], [194]. Metoda predložena u ovoj doktorskoj disertaciji koristi prednosti predodređenog cjelobrojnog prostora pretrage smatrajući pri tome određivanje optimalne snage distribuiranog izvora kao određivanje decimalnog broja pomoću hibridizacije proračuna tokova snaga i inteligencije roja čestica integriranjem proračuna u samu metodu. Navedeni pristup cjelobrojnog prostora pretrage je poznat u računalnim znanostima kao diskretna optimizacija

metodom roja čestica (engl. *Discrete Particle Swarm Optimization*) [290], [301]–[303]. Sličan pristup razvidan je u radovima autora Gómez-González. [53], [300] koji koriste algoritam žabljeg skakanja i proračun optimalnih tokova snaga te u radovima koji koriste algoritam kolonije pčela [288]. Razmatranje problema čije rješenje mora biti spoj decimalnog i cjelobrojnog broja predmet je interesa i autora radova [304]–[307]. Drugi način istovremenog promatranja cjelobrojnih i decimalnih veličina je primjenom zasebne hibridne metode inteligencije roja čestica koju predlaže Kennedy [182], ali je navedeni pristup ograničen na binarne diskretne vrijednosti.

4.6. Hibridne metode

Heurističke i meta-heurističke metode razvijene su s ciljem naprednog i učinkovitog pretraživanja prostora rješenja, a brojnost različitih metoda ukazuje na mogućnost prilagodbe pristupa računalom inteligencijom svakom problemu [73]. Međutim, iako postoje mnogi primjeri uspješne primjene metoda računalne inteligencije prilikom rješavanja inženjerskih problema, od kojih su radovi značajni za područje elektroenergetike i vezani uz područje istraživanja ove doktorske disertacije navedeni u prethodnim poglavljima, u literaturi se navodi kako ne postoji univerzalno primjenjiva metoda ili ne postoji jednoznačan dokaz o sveobuhvatnoj superiornosti jedne metode u odnosu na ostale, a teorem koji opisuje navedeno načelo se naziva *Nema-besplatnog-ručka teorem* (engl. *No-Free-Lunch Theorem*) [73], [218], [288], [308]–[312]. Navedeni teorem ukazuje kako su svi pristupi računalne inteligencije jednaki u ocjeni primjenjivosti i učinkovitosti ukoliko se njihovo djelovanje ispita na svim promatranim problemima [289], odnosno kako za svaku uspješnu primjenu jedne metode računalne inteligencije postoji jedan neuspješan primjer primjene iste metode [218]. Za postupak računalne inteligencije \mathcal{A} i za postupak računalne inteligencije \mathcal{B} uz istu funkciju cilja f vrijedi jednakost prema izrazu (4-58) u kojoj se oznaka e odnosi na računalnu zahtjevnost, a P vjerojatnost uz koju promatrani postupak rezultira optimalnim rješenjem x .

$$\sum_f P(x | f, \mathcal{A}, e) = \sum_f P(x | f, \mathcal{B}, e) \quad (4-58)$$

Teorem *Nema-besplatnog-ručka* je moguće protumačiti i kao nužni kriterij odabira metode računalne inteligencije za primjenu prilikom rješavanja određenog problem jer promatrani problem određuje *alat* idealan za rješavanje [289], točnije, u konačnom prostoru mogućih rješenja \mathcal{X} traži se rješenje prema ocjeni dobrote \mathcal{Y} za sve promatrane probleme \mathcal{F} korištenjem funkcije cilja $f: \mathcal{X} \rightarrow \mathcal{Y}$ [288]. Bez poznavanja granica prostora mogućih rješenja i bez poznavanja djelovanja funkcije cilja na pretragu rješenja nije moguće primijeniti metode računalne

inteligencije jer se svaka pojedina metoda mora prilagoditi promatranom problemu [73], [282]. Način na koji znanstvena zajednica nastoji postići univerzalnu primjenjivost metoda računalne inteligencije naziva se *hibridizacija*, a podrazumijeva postupak sjedinjenja općenitih heurističkih pravila i strogo specijaliziranih postupaka primjenjivih za promatrani problem [73], [313]. Metode računalne inteligencije odlikuju se mogućnošću međusobne hibridizacije kojom se postiže dodatno učenje, pretraživanje ili upravljanje podređenim metodama s ciljem razvoja robusnih i kvalitetnih postupaka za rješavanje složenih problema, a hibridne metode nastale sjedinjenjem dvaju ili više postupaka računalne inteligencije uspješno ispravljaju nedostatke pojedinih postupaka. Hibridne metode i zakonitosti njihova modeliranja prikazani su i u drugom poglavlju kroz pregled općenitih pravila i principa trenutnih znanstvenih istraživanja.

Česti postupci hibridizacije su sjedinjenje metode simuliranog kaljenja i tabu pretrage, genetskog algoritma i tabu pretrage, genetskog algoritma, tabu pretrage i metode simuliranog kaljenja zajedno [287], sustava neizrazite logike i umjetnih neuronskih mreža, genetskog algoritma i lokalne pretrage [180], [272], [313], genetskog algoritma i *Monte-Carlo* simulacija [314], [315], metode inteligencije roja čestica i metode auto-regresivnog integriranog pomičnog prosjeka [316], algoritma krijesnica i postupka traženja uzoraka [317], metode inteligencije roja čestica i kolonije mrava [318], diskretne metode inteligencije roja čestica i algoritama razmnožavanja pčela [61], metode inteligencije roja čestica i genetskog algoritma [54] te preostalih hibridnih metoda opisanih u prethodnim poglavljima ovog rada.

Sjedinjenje dva heuristička ili meta-heuristička pristupa je moguće ostvariti na pet različitih razina međusobne implementacije [280]:

- Samostalnim korištenjem više metoda koje se često koristi prilikom sagledavanja istog problema različitim procedurama rješavanja. Iako se u ovom slučaju zapravo ne radi o sjedinjenju, rješavanje istog problema na više načina različitim postupcima može se opisati kao hibridizacija.
- Transformacijom promatranih podataka ili veličina pomoću jedne metode kako bi odgovarala nužnom obliku ulaznih informacija druge metode. Najčešći oblik ovakve hibridizacije je kaskadno korištenje umjetnih neuronskih mreža i sustava neizrazite logike.
- Nejakom spregom više metoda koje koriste zajedničke meta-podatke prilikom djelovanja, poput sjedinjenja umjetnih neuronskih mreža i metode potpornih vektora.

- Jakom spregom prilikom koje jedna metoda direktno utječe na parametre druge metode poput promijene parametara sustava neizrazite logike umjetnim neuronskim mrežama.
- Potpunom integracijom prilikom koje iz dvije metode nastaje nova metoda sa obilježjima obje metode, poput modeliranja neurona skrivenog sloja umjetne neuronske mreže sustavima neizrazite logike, a što rezultira određenim intervalom vrijednosti izlaznih veličina skrivenog sloja.

Kako je opisano u drugom poglavlju ove doktorske disertacije, autori Pesaran [6] i Colmenar-Santos [70] u svojim preglednim radovima sažeto, jasno i precizno tumače hibridne metode i hibridizaciju, uključujući integraciju različitih proračunskih postupaka u meta-heurističke pristupe. Hibridizaciju optimizacijskih procedura literatura [319] definira kao sjedinjenje stohastičkih i determinističkih postupaka kojima se postiže značajno smanjenje prostora pretrage uz učinkovitu konvergenciju prema rješenju, a pristup u kojem se genetskom algoritmu integriraju klasične proračunske metode razvidan je u literaturi [313].

Podjelom postupaka korištenih prilikom planiranja distribuirane proizvodnje iz rada autora Tan et al. [31] definirane su hibridne metode koje mogu biti sjedinjenja genetskog algoritma i sustava neizrazite logike, genetskog algoritma i tabu pretrage, genetskog algoritma i inteligencije roja čestica, genetskog algoritma i proračuna optimalnih tokova snaga, inteligencije roja čestica i proračuna optimalnih tokova snaga te tabu pretrage i sustava neizrazite logike.

Metoda inteligencije roja čestica se najčešće sjedinjuje sa drugim meta-heurističkim metodama [67], [94], [227], [295], [320], [321] ili sa proračunskim procedurama integriranim u postupak optimizacije [300]. Proračun tokova snaga uspješno je integriran u postupak genetskog algoritma u radovima [72], [152], [156], [322] i u postupak inteligencije roja čestica u radu [55].

Autor Jung [323] navodi kako se metoda inteligencije roja čestica uspješno koristi za optimalno modeliranje različitih hibridnih sustava računalne inteligencije koji se koriste za predviđanje brzine vjetera i proizvodnje električne energije iz elektrana na vjetar. Takav primjer upotrebe jedne metode računalne inteligencije kao kontrolnim alatom nad drugom ili nad više drugih metoda računalne inteligencije smatra se izvrsnim meta-heurističkim pristupom.

5. Algoritam kratkoročnog planiranja pogona distribuiranih izvora

U drugom poglavlju ove doktorske disertacije prikazani su znanstveni radovi i postignuća koji metodama računalne inteligencije rješavaju različite izazove identificirane u naprednim distributivnim mrežama, najčešće izazov raspodjele jedne ili više jedinica distribuirane proizvodnje različitih tehnologija. Prema mišljenju autora ove doktorske disertacije, prikazani postupci i načini modeliranja odabranih optimizacijskih metoda omogućavaju dodatni razvoj i prilagodbu s ciljem određivanja optimalnog pogona više distribuiranih izvora u potpuno aktivnoj distributivnoj mreži. Potpoglavljem 2.2 opisana je nužnost sjedinjenja više meta-heurističkih metoda ili meta-heurističkih metoda sa računalnim postupcima, tzv. *hibridizacija*. Postupak *hibridizacije* optimizacijskih i proračunskih postupaka se u posljednjoj literaturi naziva *ko-simulacija* te je predmet istraživanja znanstveno-istraživačkog projekta iz programa Horizon 2020 br. 654113 [324]–[328]. Postojanje europskog istraživačkog projekta u području razvoja hibridnih ko-simulacijskih postupaka, kojeg čini konzorcij od osamnaest tehničkih sveučilišta i fakulteta u Europi, ukazuje na ispravnost odabranog smjera razvoja znanstveno-istraživačkog rada prikazanog ovom doktorskom disertacijom.

Trećim poglavljem opisan je simulacijski paket *MATPOWER* koji se koristi za modeliranje elektroenergetskog sustava i proračun tokova snaga, a koji je moguće u potpunosti implementirati u meta-heurističku metodu modeliranu programskim okruženjem *MATLAB*. Implementacija simulacijskog paketa *MATPOWER* u jedinstveno modeliranu optimizacijsku metodu računalne inteligencije rezultira hibridnom ko-simulacijskom metodom za planiranje optimalnog pogona distribuiranih izvora u potpuno aktivnoj distributivnoj mreži.


Četvrto poglavlje iscrpno prikazuje metode računalne inteligencije upotrijebljene prilikom znanstveno-istraživačkog rada koji je prethodio izradi ove doktorske disertacije. U istom poglavlju pružen je uvid u osnovne postavke svake obrađene metode računalne inteligencije sa pojašnjenjem nužnih zahtjeva modeliranja te je naglašena posebitost metode opisane u ovom poglavlju, preciznije, posebitost optimizacijske metode inteligencije roja čestica preinačene načelom *elitizma* i djelovanjem prepoznatim u genetskom algoritmu.

Algoritam kratkoročnog planiranja pogona distribuiranih izvora koji sadrži hibridnu metodu za planiranje optimalnog pogona distribuiranih izvora predstavljenu u ovom doktorskom radu sadrži tri cjeline računalne inteligencije, sjedinjene različitim razinama međusobne implementacije, opisanih poglavljem 4.6. Prva cjelina predstavlja predviđanje proizvodnje

sunčanih elektrana fotonaponske pretvorbe, a modelirana je umjetnom neuronskom mrežom i opisana potpoglavljem 5.1.

Razinom implementacije *transformacijom podataka* prema [280] se prva cjelina nastavlja na drugu cjelinu predloženog algoritma. Druga cjelina sastoji se od hibridne optimizacijske metode modelirane predloženom jedinstvenom metodom inteligencije roja čestica s kojom je *totalnom integracijom* [280] sjedinjen simulacijski paket *MATPOWER*, odnosno modelski i računski postupak opisan trećim poglavljem. Takva razina implementacije predstavlja sjedinjenje stohastičkih i determinističkih postupaka, točnije, čvrstu *hibridizaciju* ili *ko-simulaciju*.

Konačno, treća cjelina predloženog hibridnog algoritma za kratkoročno planiranje optimalnog pogona distribuiranih izvora predstavljenog ovim radom podrazumijeva postupak zaključivanja o pogonu distribuiranih izvora, modeliran sustavom neizrazite logike i povezan sa drugom cjelinom *nejakom spregom* [280]. Sve tri cjeline sistematično su prikazane slikom 5.1.




Slika 5.1. Cjeline predloženog algoritma

U literaturi [329] argumentirano je obrazložen pristup koji se sastoji od cjelina planiranja i optimizacije u tržišnim uvjetima, a primjeri koji se opisuju navedenom literaturom zasnivaju se na genetskom algoritmu. Uvažavajući razmatranja navedena u potpoglavlju 4.1. i iskustva prikazana prethodno prikazanim znanstvenim člancima opravdano je zaključiti kako je optimizacijsku metodu potrebno zasnivati na načelima metode inteligencije roja čestica te kako genetski algoritam nije u mogućnosti zadovoljiti uvjet kratkoročnog planiranja distribuirane proizvodnje.

Glavna naredbena datoteka zapisana u programskom okruženju *MATLAB* sadrži jedinstvenu optimizacijsku metodu u koju je u potpunosti implementiran simulacijski paket *MATPOWER*. Cjeline predviđanja o proizvodnji sunčanih elektrana i odlučivanja o rješenjima su zasebne naredbene datoteke koje predviđenim algoritmom pružaju, odnosno obrađuju simulacijske podatke.

5.1. Planiranje proizvodnje sunčanih elektrana

U znanstveno-istraživačkom radu predstavljenog ovom doktorskom disertacijom se problemu predviđanja proizvodnje sunčanih elektrana promatranjem podataka o temperaturi zraka, relativnoj vlažnosti zraka, intenzitetu sunčevog zračenja i brzini vjetra, pristupa modeliranjem višeslojne *MADLINE* umjetne neuronske mreže i programskom okruženju *MATLAB*, prikazane slikom 5.2., koja je ustrojena u tri sloja. Zadaća modelirane umjetne neuronske mreže je promatrati zadane ulazne veličine kao dijelove zajedničke funkcije, a parametri takve funkcije opisane umjetnom neuronskom mrežom procjenjuju se procesom učenja. Razumljivo, međusobno ovisnost promatranih ulaznih veličina te postojanje korelacije među veličinama značajno utječe na mogućnosti umjetne neuronske mreže.



Slika 5.2. Umjetna neuronska mreža za predviđanje proizvodnje sunčanih elektrana

Prvi sloj je sloj ulaznih neurona koji služi za obradu ulaznih vrijednosti i dovođenje brojčanih zapisa u uniformno stanje, smanjenje šuma i izolaciju neodgovarajućih podataka. Broj ulaznih parametara modelirane umjetne neuronske mreže odgovara broju neurona u ulaznom sloju.

Izlazni sloj sadrži jedan neuron koji daje podatak o iznosu proizvodnje sunčane elektrane s obzirom na ulazne podatke umjetne neuronske mreže i na modelirane prijenosne funkcije neurona skrivenog sloja.

Međusobna veza između slojeva umjetne neuronske mreže je dvosmjerna te se koristi načelo unatražnog rasprostiranja, detaljno opisano u potpoglavlju 4.2.5. U modeliranoj umjetnoj neuronskoj mreži, vrijednost izlazne veličine i -tog predviđanja y_i u funkciji je težinskih koeficijenata w cjelokupne modelirane mreže, zapisanih vektorom težinskih koeficijenata W . Pogreška predviđene vrijednosti \mathcal{E} u odnosu na poznatu vrijednost $y_{p,i}$ prilikom učenja umjetne neuronske mreže također je u funkciji vektora težinskih koeficijenata W prema izrazu (5-1)

$$\mathcal{E}(W) = \sum [y_{p,i} - y_i(W)]^2 \quad (5-1)$$

Korištenjem funkcije *net* u programskom okruženju *MATLAB* poziva se umjetna neuronska mreža za koju je potrebno definirati broj ulaznih veličina, broj slojeva, kašnjenja, težinske koeficijente, broj izlaznih veličina i preostale funkcijske parametre.

Parametrom *net.divideFcn = 'dividerand'* za modeliranu umjetnu neuronsku mrežu određena je nasumična podjela poznatog skupa podataka na dio za učenje i dio za provjeru vladanja umjetne neuronske mreže. Pod provjerom vladanja umjetne neuronske mreže podrazumijeva se uspoređivanje izlaznih veličina sa ciljanim vrijednostima (engl. *validation*) i ispitivanje korisnosti modelirane umjetne neuronske mreže (engl. *testing*) prilikom predviđanja proizvodnje sunčanih elektrana temeljem podataka o temperaturi zraka, relativnoj vlažnosti zraka, intenzitetu sunčevog zračenja i brzini vjetra. Za potrebe učenja umjetne neuronske mreže koristi se 70% uzoraka poznatog skupa podataka, a preostali uzorci se koriste u jednakim omjerima za uspoređivanje veličina i ispitivanje vladanja modelirane umjetne neuronske mreže, što se definira parametrima *net.divideParam.trainRatio*, *net.divideParam.valRatio* i *net.divideParam.testRatio*. Odabrani algoritam učenja modelirane umjetne neuronske mreže je *Levenberg-Marquardt* algoritam učenja, detaljno opisan u [37] i [330], a kriterij odabira upravo *Levenberg-Marquardt* algoritma umjesto *Fletcher-Reeves*, *Polak-Ribière* ili *Powell-Beale* algoritma je najmanje vrijeme potrebno za konvergenciju i najmanji zahtjevi za računalnom memorijom [216]. Navedeni algoritam učenja se u *MATLAB* programskom okruženju naredbene datoteke definira parametrom *net.trainFcn = 'trainlm'*, a odnos izlaznih veličina i poznatih vrijednosti promatra se srednjom kvadratnom pogreškom, što se definira parametrom *net.performFcn = 'mse'*.

Korištenjem skupa ulaznih podataka (engl. *inputs*) i skupa ciljanih, poznatih vrijednosti (engl. *targets*) moguće je, uz definirane navedene parametre, pristupiti učenju umjetne neuronske mreže korištenjem naredbe *train(net, inputs, targets)* koja će pokrenuti model definiran vrstom umjetne neuronske mreže i brojem skrivenih neurona. Vrsta umjetne neuronske mreže odgovara

zadaći namijenjenoj promatranoj umjetnoj neuronskoj mreži, a u ovom slučaju radi se o formiranju nove zajedničke prijenosne funkcije pa se umjetna neuronska mreža formira naredbom $net = fitnet(hiddenLayerSize)$. Varijabla o broju neurona skrivenog sloja $hiddenLayerSize$ mora sadržavati cjelobrojnu vrijednost. Ispitivanjem korisnosti modelirane umjetne neuronske mreže stvaraju se prve izlazne veličine na način da modelirana umjetna neuronska mreža obradi skup ulaznih podataka i rezultira skupom izlaznih podataka korištenjem naredbenog retka $outputs = net(inputs)$. Pogreške nastale ispitivanjem umjetne neuronske mreže obrađuju se za cijele skupove ciljanih i izlaznih veličina korištenjem naredbe $gsubtract$.


Ispravno modeliranu umjetnu neuronsku mrežu potrebno je snimiti pod drugim imenom naredbenim redcima $novamreza = net$ i $save novamreza$ te ju je tada moguće ponovno upotrijebiti na novom skupu ulaznih podataka, $noviinput$, što rezultira novim skupom izlaznih podataka, $novioutput$, a jednakim postupkom kao u prethodnom koraku, odnosno, korištenjem naredbenog retka $novioutput = novamreza(noviinput)$ moguće je za 24 ulazna uzorka dobiti 24 predviđene vrijednosti proizvodnje sunčane elektrane, što odgovara vremenskom periodu jednog dana, prikazane tablicom 5.1. Vrijednosti o proizvodnji sunčanih elektrana su u konačnici definirane postocima kako bi se u drugoj cjelini predloženog algoritma mogle iskoristiti definiranjem vektora neovisnog o promatranoj snazi elektrana. Nužno je napomenuti kako vrijednosti u postocima nisu izlazne vrijednosti modelirane umjetne neuronske mreže jer nisu takvi bili ni ulazni podaci za učenje o proizvodnji sunčane elektrane. Postotne vrijednosti dobivene su zasebnom procedurom skupnog dijeljenja predviđenih snaga sa nazivnom snagom sunčane elektrane i formiranjem novog vektora integriranog u optimizacijsku metodu. Literatura [331] navodi kako za specifične slučajeve modeliranja umjetnih neuronskih mreža nije potrebno modelirati proces učenja, što ovisi o promatranom procesu.

Tablica 5.1. Vrijednosti proizvodnje sunčane elektrane dobivene modeliranom umjetnom neuronskom mrežom za vremenski period od jednog dana

sati	0	1	2	3	4	5	6	7	8	9	10	12
%P _n	0	0	0	0	0	0	0,17	0,37	0,55	0,70	0,90	0,97
sati	13	14	15	16	17	18	19	20	21	22	23	24
%P _n	1	1	0,83	0,70	0,37	0,20	0,13	0	0	0	0	0


Prilikom ocjene ispravnosti modelirane umjetne neuronske mreže bitni su svi pokazatelji: ocjena najbolje valjanosti (engl. Best Validation Performance) i prikaz linijske regresije (engl. *Regression Plot*). Ocjena najbolje valjanosti neuronske mreže prilikom procesa učenja,

uspoređivanja i ispitivanja prikazan je slikom 5.3., sa koje je razvidno kako nakon 6 etapa učenja srednja kvadratna pogreška iznosi $9,57 \times 10^{-5}$ i postignuta je u četvrtoj etapi.




Slika 5.3. Ocjena najbolje valjanosti modelirane umjetne neuronske mreže

Sljedeći korak u ocjenu ispravnosti modelirane umjetne neuronske mreže je prikaz linijske regresije kojim se prikazuje odnos između izlaznih veličina koje pruže umjetna neuronska mreža i ciljanih iznosa. Kada bi umjetna neuronska mreža bila idealna ne bi postojalo rasipanje podataka oko pravca linijske regresije. Za potrebe ove analize potrebno je modeliranom umjetnom neuronskom mrežom provesti sve postupke provedbe provjere vladanja opisane ranije u ovom potpoglavlju. Nakon provedenih postupaka provedbe vladanja, naredbom *plotregression* izrađuje se slika 5.4. za postupak učenja i uspoređivanja te slika 5.5. za procese ispitivanja i za ukupan postupak provjere vladanja modelirane umjetne neuronske mreže.



Slika 5.4. Regresijski pravac za proces učenja i uspoređivanja umjetne neuronske mreže



Slika 5.5. Regresijski pravac za proces ispitivanja i za ukupnu provjeru vladanja umjetne neuronske mreže

Promatrajući rezultate ocjena najbolje valjanosti i prikaza linijske regresije moguće je zaključiti kako modelirana umjetna neuronska mreža za predviđanje proizvodnje sunčanih elektrana temeljem pokazatelja o temperaturi zraka, relativnoj vlažnosti zraka, intenzitetu sunčevog zračenja i brzini vjetra pokazuje kvalitetno vladanje i kako se rezultati predviđanja ovom umjetnom neuronskom mrežom mogu opravdano koristiti u sljedećoj cjelini algoritma kratkoročnog planiranja pogona distribuiranih izvora.

Podaci za izradu vektora prikazanog tablicom 5.1. nasumično su odabrani iz skupa podataka sunčanog ljetnog dana kako bi se u sljedećoj cjelini optimizacije hibridnom metodom analizirao slučaj u kojem postoji proizvodnja sunčane elektrane u svakom raspoloživom čvoru.

5.2. Hibridna metoda za planiranje optimalnog pogona distribuiranih izvora

Načela optimizacijske metode inteligencije roja čestica proširene načelom *elitizma* kako je prikazano u potpoglavlju 4.5. koriste se za modeliranje jedinstvene optimizacijske metode za planiranje optimalnog pogona distribuiranih izvora.

Sjedinjenje modelskog i proračunskog postupka simulacijskog paketa *MATPOWER* i jedinstveno modelirane optimizacijske metode inteligencije roja čestica razinom totalne integracije rezultiralo je novom hibridnom metodom za planiranje optimalnog pogona distribuiranih izvora zapisane jednom naredbenom datotekom u programskom okruženju

MATLAB. Cjelokupna naredbena datoteka sastoji se od 8 logičkih podjela, a osmi dio sadrži zasebnih 9 koraka odvijanja algoritma, prikazanih tablicom 5.2.

Tablica 5.2. Prikaz strukture izvođenja hibridne optimizacijske metode inteligencije roja čestica

1	Početak metode;
2	Definiranje broj čestica $\{X_j(0), j = 1, 2, \dots, n\}$ parametrom n_{part} i najveće radne snage distribuirane proizvodnje u mega-vatima (MW);
3	Postavljanje parametara c_1 i c_2 i težinskih koeficijenata iz izraza (4-50);
4	Postavljanje ograničenja optimizacijske metode i definiranje prostora pretrage;
5	Stvaranje nulte populacije čestica sa nasumično odabranim brzinama;
6	Stvaranje korisničkih pomoćnih struktura A, B, S, r koje se koriste za odvijanje optimizacijske metode;
7	Preuzimanje vektora proizvodnje sunčanih elektrana iz rezultata prve cjeline predloženog algoritma;
8	Postupak optimizacije;
8.1	Učitavanje modela mreže iz zasebne naredbene datoteke simulacijskog paketa <i>MATPOWER</i> i proračun tokova snaga za početne uvjete;
8.2	Dodavanje čestica u prostor pretrage, odnosno, dodavanje proizvodnih jedinica u čvorove strukture r nasumičnim odabirom čvora i pozivanje naredbene datoteke <i>runpf</i> simulacijskog paketa <i>MATPOWER</i> ;
8.3	Provjera dobrote svake čestice zasebno i postavljanje $pbest$ temeljem usporedbe postojeće <i>MATPOWER</i> strukture $Losstotal$ sa novom izrađenom strukturom $LosstotalDG$ za sve čestice
8.4	Provjera dobrote populacije i postavljanje $gbest$ usporedbom $pbest$ rješenja
8.5	Izdvajanje najbolje čestice u populaciji u pomoćnu strukturu S i novi proračun strukture r
8.6	Razdvojeni izračun novih brzina čestica za odabir čvora i snagu distribuirane proizvodnje u novoj populaciji
8.7	Provjera uvjeta za prekoračenje brzina uvažavanjem ograničenja simulacijskog paketa <i>MATPOWER</i>
8.8	Ažuriranje čestica po broju čvora i snazi i povećanje brojača iteracije za 1: $i = i + 1$;
8.9	Provjera uvjeta konvergencije;

Ograničenje radne snage distribuirane proizvodnje u drugom koraku izvodi se zbog postavljenog uvjeta iz izraza (3-8). Ishod optimizacije je podatak o potrebnim snagama hibridnih sustava distribuirane proizvodnje koji se sastoje od podatka o proizvodnji sunčane elektrane u

promatranom periodu i moguće potrebne dodatne proizvodnje sinkronog generatora prema rezultatima optimizacije, uvažavajući spomenuti uvjet izraza (3-8). Ukoliko se u drugom koraku hibridne optimizacijske metode definira najveća snaga distribuirane proizvodnje jednaka najmanjoj snazi potrošača nekog čvora moguće je pri uvjetima najveće proizvodnje sunčanih elektrana iz nekih čvorova izostaviti angažman sinkronih generatora jer uvjet prema (3-8) nije moguće ispuniti u slučaju postavljanja dodatne čestice koja predstavlja upravljivu proizvodnu jedinicu u čvor u kojem već postoji neupravljiva distribuirana proizvodnja sunčane elektrane čija je snaga u potpunosti zadovoljila navedeni kriterij. Dakle, prema izrazu (3-7) $p_{g,min}$ sinkronog generatora može posjedovati i iznos nula. Pod pretpostavkom da su gubici rezultat tokova snaga kroz grane, na ovaj način izbjegava se dodatno opterećenje pojedinih grana nakon što se gubici u njima svedu na najmanju moguću mjeru.

Za svaki promatrani satni interval podatak o potrebnoj snazi hibridnog sustava sadržava različite omjere snaga sunčane elektrane i sinkronog generatora, što je potpuno razumljivo s obzirom na promjenjivu proizvodnju sunčane elektrane kroz vremensko razdoblje od jednog dana. Cilj optimizacije je za svaki sat u danu pružiti informaciju o potrebnim dodatnim snagama upravljive distribuirane proizvodnje po čvorovima za slučaj u kojem na svim čvorovima sunčane elektrane proizvode električnu energiju prema vrijednostima iz tablice 5.1., odnosno prema vektoru definiranog umjetnog neuronskom mrežom u prvoj cjelini predloženog algoritma koji se u optimizacijskom postupku preuzima u sedmom koraku.

Peti korak ispunjava osnovno načelo izvođenja optimizacijske metode inteligencije roja čestica koje zahtijeva nasumično stvaranje čestica u nultoj iteraciji i koje se nakon tog nultog stvaranja mogu obrađivati odgovarajućim izrazima i operacijama u sljedećim koracima optimizacijske metode.

Korisničke pomoćne strukture A, B, S, r koje se definiraju šestim korakom predložene metode koriste se za jednostavnije odvijanje optimizacijske i predloženog postupka. Korisničkom pomoćnom strukturom A definira se cjelobrojni prostor pretrage ograničen topologijom promatrane distributivne mreže. Naredbenim retkom $Common.A = 1:n_bus$ definira se struktura $Common$ i u njoj skup vrijednosti varijable A koji posjeduje cjelobrojne redne vrijednosti od broja 1 do ukupnog broja čvorova u mreži, prilikom čega je nužno da čvorovi u mreži posjeduju redne cjelobrojne oznake.

Naredbenim retkom $Common.B = [1 \ 2 \ 13 \ \dots \ X]$ se sličnim postupkom definiraju čvorovi u testnom *IEEE* sustavu koji već prema zadanim parametrima sustava posjeduju proizvodne

jedinice. U primjeru naredbenog retka potrebno je navesti sve takve čvorove cjelobrojnim iznosima. Razlika A i B dijelova $Common$ strukture rezultirati će novim skupom S koji se definira naredbenim retkom $Common.S = setdiff(Common.A, Common.B)$ i koji predstavlja cjelobrojne oznake čvorova na kojima se integriraju hibridni proizvodni sustavi, odnosno, u kojem su mogući položaji čestica predodređeni brojem čvorova u mreži. Zbog zahtjeva simulacijskog paketa $MATPOWER$ i načina modeliranja proizvodnih jedinica kako je opisano potpoglavljem 3.2.3, definirana je dodatna pomoćna struktura $Common.r$ koja se formira kao matrica potrebnog oblika za unos proizvodnih jedinica i sa brojevima čvorova iz skupa $Common.S$. Pomoćna struktura $Common.r$ koristi se i za nasumično stvaranje čestica prve populacije, koje predstavljaju nasumično dodane sinkrone generatore u promatranu mrežu.

Postupak optimizacije započinje osmim korakom i sastoji se od tri hijerarhijske ugniježdene (engl. *nested*) *for* petlje:

- *for* petlja promatranog vremenskog intervala h u kojoj se i računaju početni uvjeti
- *for* petlja iterativnog postupka nasumičnih isprobavanja i omeđenog prostora pretrage
 - *for* petlja stvaranja određenog broja čestica n_{part} u svakom iterativnom postupku j

U predloženom algoritmu kratkoročnog planiranja pogona distribuiranih izvora promatra se vremenski period od jednoga dana, podijeljen na 24 satna intervala te se prema tome prvom *for* petljom određuje kako će procesom optimizacije biti najmanje 24 iterativna postupka.

Drugom *for* petljom promatraju se svi dostupni čvorovi s ciljem pronalaska čvora u kojem će angažman dodatne proizvodne jedinice uzrokovati najveće smanjenje gubitaka. Prema tome, broj ponavljanja druge *for* petlje odgovara broju čvorova definiranih strukturom $Common.S$. Broj ponavljanja treće *for* petlje određen je brojem čestica koji treba biti najmanje jednak broju promatranih čvorova definiranih strukturom $Common.S$. Spomenutim rješenjem i djelovanjem pomoću tri ugniježdene *for* petlje od koje se dvije izvode najmanje onoliko puta koliko je dostupnih čvorova za angažman dodatne snage za svaki promatrani sat se promatraju svi čvorovi i to na način u kojem se dodatna snaga angažira prvotno u čvorovima u kojima će uzrokovati najveće smanjenje gubitaka u promatranom elektroenergetskom sustavu. Izraz (5-2) opisuje ugniježdene tri *for* petlje koje pružaju informaciju o potrebnom broju n i snazi P_{DG} dodatno angažiranih jedinica hibridne distribuirane proizvodnje DG_{max} za vremenskom razdoblju od jednog dana u promatranom elektroenergetskom sustav koji sadrži n_{ξ} broja dostupnih čvorova i uz mogući broj jedinica za angažman n_{part} .

$$f_1 = \sum_{h=1}^{24} \sum_{i=1}^{n_{\xi}} \sum_{j=1}^{n_{part}} DG_{max}(P_{DG}, n) \quad (5-2)$$

Koracima 8.1 – 8.3 i 8.7 postignuta je totalna integracija simulacijskog paketa *MATPOWER* u predloženu jedinstvenu optimizacijsku metodu i *ko-simulacija* proračunskog i optimizacijskog rješenja. Korak 8.1 izvodi se pozivanjem naredbene datoteke *runpf* sadržane u simulacijskom paketu *MATPOWER* s ciljem određivanja početnih vrijednosti gubitaka u promatranom testnom sustavu. Sljedeći korak je naredbenim retkom *mpc.DG = loadcase('caseXY')* definirati novu strukturu varijable *mpc* koja sadrži podatke o elementima promatranog testnog sustava, u ovom slučaju nekog sustava *XY*, a u koju je moguće dodavati podatke o distribuiranoj proizvodnji. Popis testnih sustava sadržanih u simulacijskom paketu *MATPOWER* i nazivi prema kojima se mogu pozivati spomenutim naredbenim retkom prikazan je tablicom 3.2., a značaj varijable *mpc* opisan je potpoglavljem 3.1. Novom varijablom i strukturom *mpc.DG* definirana je izvedenica osnovnog testnog sustava u koju se dodaju jedinice distribuirane proizvodnje (engl. *Distributed Generation*).

Korak 8.2 realiziran je trećom *for* petljom koja se izvodi onoliko puta koliko je čestica dodijeljeno postupku optimizacije u drugom koraku predložene metode parametrom *n_part* koji sadrži cjelobrojnu informaciju. Za svaku postavljenu česticu izvršava se zasebni proračun tokova snaga i česticama se dodjeljuje informacija o individualnom iskustvu. Ukoliko se broj čestica postavi na 1 tada će se treća *for* petlja izvesti jednom te će se izvršiti jedan proračun za česticu stvorenu na nasumično odabranom čvoru i sa nasumično određenom snagom pozivanjem naredbenog rješenja *runpf* za proračun tokova snaga sadržanog u simulacijskom paketu *MATPOWER*. Takva jedna čestica predstavlja nasumično stvorenu upravljivu distribuiranu proizvodnju dodanu postojećoj sunčanoj elektrani čija je proizvodnja u toj iteraciji prve *for* petlje jednaka pripadajućoj snazi tog sata iz tablice 5.1. Međutim, u takvom jednostavnom primjeru jasno je kako populacija sadržana od jedne čestice nema mogućnost međusobnog uspoređivanja čestica unutar populacije, a individualna informacija koju čestica posjeduje nakon jedne iteracije sastoji se od jednog podatka o čvoru i jednog podatka o snazi sinkronog generatora te je vrlo izvjesno da se ne radi o optimalnom ili barem provjerenom rješenju, a pogotovo se ne radi o rješenju u čvoru u kojem će angažman dodatne snage uzrokovati najveće smanjenje gubitaka u promatranom sustavu.

Ciljevi optimizacije obuhvaćaju i pronalazak čvora za svaku iteraciju u kojem je angažman dodatne snage najpotrebniji, a drugom i trećom *for* petljom uvjetuje se željeni broj iteracija koji odgovara broju promatranih čvorova u testnoj mreži te se na taj način u prvoj iteraciji druge *for*

petlje pronalazi čvor u kojem je će integracija dodatne proizvodne jedinice uzrokovati najveće smanjenje gubitaka u promatranoj testnoj mreži. Varijabla koja sadrži informaciju o dobroti te jedne čestice naziva se *LosstotalDG* i sadrži podatak o gubicima u promatranom sustavu sa dodatnom proizvodnom jedinicom. Usporedbom te nove varijable sa postojećom vrijednosti varijable *Losstotal* simulacijskog paketa *MATPOWER* koja je kreirana u koraku 8.1 i sadrži informaciju o gubicima u promatranom sustavu prije integracije nove proizvodne jedinice dobije se informacija o utjecaju nasumično stvorene čestice na gubitke snage u modeliranom elektroenergetskom sustavu. Najveće smanjenje gubitaka određeno rezultira najboljom ocjenom dobrote čestice *pbest* (engl. *personal best*) prema izrazu (5-3).

$$f(pbest) = \begin{cases} P_{gubitaka,DG} & P_{gubitaka,DG} < P_{gubitaka} \\ P_{gubitaka} & P_{gubitaka,DG} > P_{gubitaka} \end{cases} \quad (5-3)$$

Svrha druge *for* petlje je namjerno obuhvaćanje cjelokupnog prostora pretrage sadržanog od cjelobrojnih vrijednosti dostupnih čvorova jer se predloženom metodom razmatraju svi dostupni čvorovi strukture *Common.S*, a parametri promatranog testnog sustava se mijenjaju nakon svakog jedinstvenog postupka *izolacije*. Naime, cilj optimizacijskog postupka je predočiti potrebne dodatne snage za sve dostupne čvorove za svaki interval promatranog budućeg perioda, a nakon ocjene dobrote nasumično stvorenih čestica postupkom *izolacije* će se upravljiva distribuirana proizvodnja koja uzrokuje najveće smanjenje gubitaka dodatno angažirati u promatrani testni sustav.

Predloženim postupkom optimizacije razmatraju se dva svojstva čestica, lokacije i snage više jedinica distribuirane proizvodnje, što se promatra kao dva cilja koja je potrebno razmatrati populacijom sadržane od više čestica. Čestice mogu biti modelirane nepromjenjivom snagom čiji se utjecaj provjerava za više lokacija, nepromjenjivim položajem čestica promjenjivih snaga ili nasumično promjenjivim i neponovljivim položajem i snagom, što je slučaj u ovom radu. U trećoj *for* petlji izvršava se proces ažuriranja čestica prema ocjenama dobrote svake čestice i mijenjaju se parametri čestica prema položaju i snazi najbolje čestice uz pohranu individualne informacije svake čestice.

Konačno, najmanji broj čestica koji se koristi u trećoj *for* petlji treba odgovarati broju čvorova u mreži na kojima se implementira hibridna distribuirana proizvodnja koja se sastoji od neupravljive sunčane elektrane i upravljivog sinkronog generatora kako bi se u svakoj iteraciji razmotrili svi dostupni čvorovi, a broj iteracija određen drugom *for* petljom mora najmanje biti jednak broju čvorova koji se razmatraju kako bi se izvjesno angažirale dodatne snage u svim

čvorovima za koje će ukupni gubici biti manji od početnih gubitaka, odnosno točno određen broj dodatno angažiranih upravljivih sinkronih generatora koji neće uzrokovati povećanje gubitaka. Izrazom (5-4) se promatra testni elektroenergetski sustav od n_{ξ} broja čvorova i sa n_{part} raspoloživih hibridnih jedinica distribuirane proizvodnje. Gubici prilikom promatranja i -te iteracije dodatnog angažmana u nekom čvoru su u istom izrazu označeni sa $P_{L,DG}$ i odgovaraju varijabli $LosstotalDG$ spomenutoj ranije u ovom potpoglavlju, dok ranije spomenutoj varijabli $Losstotal$ odgovara veličina $P_{L,T}$ u izrazu (5-4). Sve dok je uvjet izraza (5-4) ispunjen u promatrani elektroenergetski sustav dodavati će se nove jedinice hibridne i upravljive distribuirane proizvodnje, no ukoliko prilikom dodatne integracije nove snage na nekom čvoru gubici porastu tada se predloženim algoritmom smatra kako dodatni proizvodni kapacitet negativno utječe na smanjenje gubitaka u sustavu. Najveći broj angažiranih jedinica definiran je varijablom DG_{max} .

$$f_2 = \sum_{i=1}^{n_{\xi}} \sum_{j=1}^{n_{part}} \left((P_{L,DG(i,j)} < P_{L,T(i,j)}) \rightarrow DG_{max} = DG_{\max(i,j)} \right) \wedge \quad (5-4)$$

$$\left(\neg(P_{L,DG(i,j)} < P_{L,T(i,j)}) \rightarrow DG_{max} = DG_{\max(i-1,j)} \right)$$

Čestice u predloženoj metodi pamte najbolju individualnu informaciju o čvoru i snazi za cjelokupni proces optimizacije, ali prema društvenom modelu uvažavaju individualnu informaciju najbolje čestice. Predloženim postupkom postigla se inicijalna provjera svih čvorova u prvoj iteraciji čime su određeni čvorovi u kojima je dodatna snaga najpotrebnija što postupkom *izolacije* rezultira integracijom dodatne proizvodne jedinice u tom čvoru. Takav pristup značajno ubrzava optimizacijski postupak bez posljedičnog gubitka u kvaliteti dobivenih rješenja. Nakon jedinstvenog postupka *izolacije* iterativni postupak se ponavlja prema drugoj *for* petlji za sljedeći najpotrebniji čvor.

5.2.1. Posebnost predloženog postupka i načelo izolacije

U potpoglavlju 4.5. pojašnjena su svojstva metode inteligencije roja čestica i skup pravila kojima se određuje kretanje roja kroz višedimenzionalni prostor pretrage. Postupak jedinstvene metode inteligencije roja čestica, predložen u ovoj doktorskoj disertaciji i pojašnjen u istom potpoglavlju, uvodi načelo *izolacije* najboljih čestica prema kojem se skup rješenja o potrebnoj proizvodnji distribuiranih izvora popunjava sukcesivno kretanjem roja kroz prostor pretrage. U varijablu *gbest* (engl. *global best*) spremaju se informacija o čestici koja je rezultira najboljom individualnom ocjenom dobrote spremljenom u varijablu *pbest* (engl. *personal best*) za svaku iteraciju druge i treće *for* petlje. Struktura *gbest* posjeduje informaciju o čestici koja posjeduje

najbolju ocjenu $pbest$ i koja je, s obzirom na lokaciju i snagu, uvjetovala najveće smanjenje gubitaka u promatranom testnom sustavu. Određivanje vrijednosti $gbest$ i $pbest$ odvija se u trećoj ugniježdenoj petlji za svaku česticu zasebno i za populaciju od n_part čestica ukupno čime se postiglo pamćenje individualnih iskustava svake čestice uz uspoređivanje svake čestice sa drugim česticama prilikom određivanja novog smjera kretanja roja u prostoru pretrage prema izrazu (5-5).

$$gbest(i) = \begin{cases} \min(pbest(i)) & gbest(i-1) > \min(pbest(i)) \\ gbest(i-1) & gbest(i-1) < \min(pbest(i)) \end{cases} \quad (5-5)$$

Dodatna značajka predložene jedinstvene metode inteligencije roja čestica za planiranje optimalnog pogona distribuiranih izvora je uvažavanje tri vrijednosti $gbest$ strukture kao značajne za razmatranje dodatnog angažmana sinkronih generatora. Navedeni pristup nastao je s ciljem usmjeravanja roja prema sljedećem najboljem prostoru pretrage, a prednost takvog pristupa očituje se i prilikom prepoznavanja povećanja gubitaka prema izrazu (5-4) jer se ipak dodatno provjerava mogućnost angažmana upravljive distribuirane proizvodnje još dva puta za naredna dva čvora i snage.

Kako bi se izbjegla preuranjena konvergencija i dominacija nasumičnog rješenja jedne čestice nad čitavim rojem čestica u predloženoj jedinstvenoj metodi za planiranje optimalnog pogona distribuiranih izvora uvažena su načela PSO-III razvijenog modela inteligencije roja čestica [180] kojima se proširuje prostor pretrage.

Nakon potpunog izvođenja treće *for* petlje dodaje se najbolje ocjenjena čestica, odnosno, upravljivi distribuirani izvor određene snage koji uzrokuje najveće smanjenje gubitaka u određeni čvor strukture *Common.S*. Kako je treća *for* petlja određena brojem čestica, odnosno brojem čvorova, u strukturu *Common.S* dodati će se podatak o angažmanu upravljive distribuirane proizvodnje koja posjeduje najbolju ocjenu dobrote, odnosno one snage koja će u određenom čvoru rezultirati najvećim smanjenjem gubitaka. Navedeni postupak predstavlja *izolaciju* jedinke koja posjeduje najbolju ocjenu dobrote, a sličnost sa načelom *elitizma* u genetskom algoritmu očituje se kroz očuvanje najbolje jedinke u skup trajnih rješenja.

Uz izraze (5-2) i (5-4) dodatna funkcija koja se promatra optimizacijom opisana je izrazom (5-6) i predstavlja početnu i glavnu funkciju cilja iz koje su logički proizašle sve ostale navedene funkcije koje se mogu shvatiti kao određenja optimizacijskog procesa.

$$f_3 = \min(P_{L,T}) \quad (5-6)$$

Gubici radne snage se promatraju kao gubici u granama koje *izlaze* i koje *ulaze* u neki čvor te se izraz (5-6) može zapisati kao izraz (5-7) koji je ujedno definiran zasebnom naredbenom datotekom kao glavna funkcija cilja. U izrazu (5-7) varijabla $P_{L,prema}$ predstavlja gubitke radne snage u grani koja *dolazi* prema promatranom čvoru, a varijabla $P_{L,od}$ predstavlja gubitke radne snage u grani koja *odlazi* iz tog istog čvora prema nekom drugom čvoru.

$$f_3 = \min \Delta P_{i,j} = \min(\text{abs}(P_{L,prema} + P_{L,od})) \quad (5-7)$$

Dodatno određenje optimizacijskog procesa predstavljeno je izrazom (5-8) kojim se definira vladanja optimizacijskog algoritma, ali ne uvjetuje konvergencija, na način da ukupna snaga distribuirane proizvodnje u svakom promatranom satu h , koja uključuje snagu sunčanih elektrana i upravljivih sinkronih generatora u čvorovima strukture *Common.S*, bude u što većoj mjeri jednaka zbroju snaga potrošača u svim čvorovima strukture *Common.A* i gubitaka radne snage u svim granama u . Na taj način dobivena rješenja bliska su rješenju koje predstavlja preduvjet otočnog pogona dijela distributivne mreže i čiji se potrošači u tom slučaju snabdijevaju isključivo pripadajućom lokalnom distribuiranom proizvodnjom, pojašnjenom u potpoglavlju 2.1.

$$f_4(h) = \sum_{k=1}^S P_{DG,i} \approx \sum_{k=1}^A P_P + \sum_{k=1}^u P_{L,T} \quad (5-8)$$

Proučavajući gubitke radne snage kroz način modeliranja opisan trećim poglavljem izraz (5-7) se može zapisati kao:

$$f_{3.1} = \min \sum_{k=1}^u |I_k|^2 R_k \quad (5-9)$$

Istovremeno zadovoljenje svih postavljenih uvjeta nije moguće te dobivena rješenja predstavljaju kompromis između realizacije potpunog otočnog pogona, pridruživanja krajnje distributivne proizvodnje svakom potrošaču, integracije dovoljnog broja distribuiranih izvora koji neće uzrokovati povećanja gubitaka radne snage i određivanja najvećeg mogućeg broja i snage distribuiranih izvora koji će rezultirati najvećim smanjenjem gubitaka. Opisani kompromis predstavlja optimalno rješenje koje je rezultat prethodno opisanog optimizacijskog procesa.

5.2.2. Promjene parametara čestica

Ažuriranje čestica se izvodi na kraju treće ugniježdene *for* petlje uvažavajući rješenja prethodnih iteracija čiji uz najveći broj iteracija jednak varijabli n_part . Uvažavajući izraz (4-50)

parametri čestica se u naredbenoj datoteci programskog okruženja *MATLAB* računaju prema izrazu (5-10) za svaki broj iteracije veći od 1.

$$b(h, i, j) = w(i) \times b(h, i - 1, j) + r_1(j)c_1(pbest(h, i, j) - p(h, i - 1, j)) + r_2(j)c_2(gbest(h, i, j) - p(h, i - 1, j)) \quad (5-10)$$

Izraz (5-10) koristi se dva puta u trećoj *for* petlji jer se česticama određuju dva svojstva, snaga i čvor. Izrazi se razlikuju po pozivanju različitih parametara strukture *Common.r*, u prvom slučaju pozivaju se parametri kojima je definiran čvor u kojem postoji distribuirana proizvodnja, a u drugom slučaju poziva se parametar o snazi distribuirane proizvodnje. Vrijednosti konstanti c_1 i c_2 su identične kako bi čestice jednako uvažavale individualna najbolja iskustva i iskustva cjelokupnog roja.

Nakon izračuna brzina čestica za najbolji položaj i najbolju snagu u roju izvodi se ažuriranje čestica za sljedeću iteraciju prema izrazu (5-11) koji se u naredbenoj datoteci programskog okruženja *MATLAB* izvodi dva puta, za snagu i položaj zasebno, uvažavajući formu pomoćne strukture *Common.r*.

$$DG(h, i + 1, j) = DG(h, i, j) + b(h, i, j) \quad (5-11)$$

Uvjet za prekoračenje brzine čestica prema izrazima (4-52) i (4-53) integriran je u korak nakon izračuna novih brzina, a prije ažuriranja kako bi se čestice ažurirale isključivo dopuštenim novim vrijednostima te kako ne bi napustile omeđeni prostor pretrage. Prostor pretrage omeđen je brojem čvorova što uvjetuje provjeru uvjeta za prekoračenje brzine prema dimenziji strukture *Common.S*. Najbitniji parametar čestica je njihova brzina, točnije, interval u kojem se brzina može mijenjati po iteracijama. Interval brzine određen je izrazima (4-52) i (4-53) i vezan je uz najveću dopuštenu snagu čestica.

5.2.3. Funkcije cilja i model njihove integracije

Određivanje dobrote jedinke izvodi se proračunom tokova snaga za svaku jedinku zasebno integracijom simulacijskog paketa *MATPOWER* u optimizacijsku metodu zapisanu naredbenom datotekom u programskom okruženju *MATLAB*. Prilikom određivanja dobrote jedinke stvaraju se varijable strukture *mpc.DG* definirane veličinama iz izraza (5-2), (5-4), (5-6) - (5-8) koje se mogu objediniti u zajedničku funkciju cilja (engl. *objective function*) prema izrazu (5-12) u kojem težinski koeficijenti $w_1 - w_4$ određuju koliko će koja funkcija biti zastupljena u konačnom rješenju.

$$f_{of} = w_1 f_1 + w_2 f_2 + w_3 f_3 + w_4 f_4 \quad (5-12)$$

Funkcija f_3 (5-6) integrirana je u optimizacijski proces kao glavna funkcija cilja, a preostale funkcije objedinjene su kao ograničenja ili omeđenja procesa optimizacije jedinstvenom metodom inteligencije roja čestica i to na način:

- Funkcija f_1 u trećoj ugniježdenoj *for* petlji prilikom ažuriranja čestice.
- Funkcija f_2 u trećoj ugniježdenoj *for* petlji prilikom izračuna parametra *pbest*
- Funkcija f_4 u drugoj ugniježdenoj *for* petlji prilikom provjeravanja uvjeta konvergencije

Opisanim pristupom prioritet optimizacijskog procesa je smanjenje gubitaka radne snage angažiranjem dodatnih upravljivih jedinica distribuirane proizvodnje čije se djelovanje zasebno pod-optimizira u zasebnim cjelinama iterativnog postupka.

5.2.4. Ograničenja i kriterij završetka optimizacijske metode

Uvjet konvergencije integriran je u drugoj ugniježdenoj *for* petlji i smatra se da je optimizacijski postupak uspješno proveden ukoliko je ispunjen jedan od sljedećih uvjeta:

- Ispunjen uvjet otočnog pogona prema izrazu (5-8) u kojem se nejednakost definira vrijednošću funkcije f_4 iz izraza (5-13) od $\pm 0,01 \sum P_p$.

$$f_4(h) = \sum_{k=1}^S P_{DG,i} - \sum_{k=1}^A P_P - \sum_{k=1}^u P_{L,T} \quad (5-13)$$

- Postignut najveći broj dodatno angažiranih jedinica distribuirane proizvodnje i ispunjen uvjet iz izraza (5-2). Ovaj uvjet se provjerava promjenom parametra *gbest* do promjene vrijednosti od 0,000001.
- U svim čvorovima pomoćne strukture *Common.S* postoji distribuirana proizvodnja
- Broj iteracija određen brojem čvorova i brojem čestica je postignut

Optimizacijski postupak će biti prekinut i neće biti uspješno proveden ukoliko se proračunom tokova snaga simulacijskog paketa *MATPOWER* integriranim u optimizacijski proces uoče narušavanja postavljenih ograničenja. U predloženi optimizacijski proces integrirana su ograničenja o vrijednosti napona u čvorovima izrazom (5-14).

$$|V_j^{min}| \leq |V_j| \leq |V_j^{max}|, \quad \forall j \in i \in h \quad (5-14)$$

Iako simulacijski paket *MATPOWER* ne raspolaže ograničavanjem struje kroz grane u predloženu optimizacijsku metodu integrirana je naredbena funkcija koja provjerava određeno polje strukture koja sadrži podatak o iznosu struje pa je tako moguće definirati ograničenja prema izrazima (5-15) i (5-16).

$$|I_u^{prema}| \leq |I_u^{prema}|_{max} \quad (5-15)$$

$$|I_u^{od}| \leq |I_u^{od}|_{max} \quad (5-16)$$

Ograničenje o snazi hibridne distribuirane proizvodnje prikazano je izrazom (3-7), a kako je opisano na stranici 107, a snaga upravljivog sinkronog generatora može poprimiti bilo koju vrijednost u intervalu $[0, P_{DG}^{max}]$. Vrijednost varijable P_{DG}^{max} definira se u drugom koraku predložene hibridne metode za planiranje optimalnog pogona distribuiranih izvora.


Ukoliko za neku česticu nije moguće provesti proračun tokova snaga te ako simulacijski paket *MATPOWER* postigne maksimalni broj iteracija proračuna zadan parametrom *PF MAX IT* za postupak Newton – Raphsonovom metodom promatrana čestica se briše, a njeno rješenje iz vektora *pbest* postaje zabranjeno rješenje za sve ostale čestice. Na taj način se neće ponoviti postupak provjere ocjene dobrote za česticu u kojoj to nije moguće provesti. Međutim, prilikom istraživanja autora ovog znanstvenog rada i prilikom optimizacije pogona distribuiranih izvora na testnim sustavima opisanim sljedećim poglavljem, nije se dogodio slučaj u kojem za neku česticu nije bilo moguće provesti proračun tokova snaga, što ukazuje na ispravno, možda i suviše strogo ograničavanje postupka optimizacije.

Kriterij za uspješno proveden postupak optimizacije uz zadovoljenje svih ograničenja optimizacijskog procesa, omeđenja prostora pretrage i funkcija cilja je ispunjenje nejednakosti iz izraza (5-17) kojim se definira kako najmanji modelirani broj čestica mora odgovarati broju čvorova raspoloživih za dodatni angažman hibridne distribuirane proizvodnje. Idealan postupak posjedovao bi dvostruko veći broj čestica od broja raspoloživih čvorova jer bi se takvim pristupom svaki čvor provjerio dva puta, svaki put sa različitom snagom te bi se time povećala količina podataka strukture sa informacijom o čvoru na kojem dodatna distribuirana proizvodnja uzrokuje najveće smanjenje gubitaka.

$$|n_{part}| \geq |n_{\zeta}|, \quad \forall i \in h \quad (5-17)$$

5.2.5. Prikaz predložene optimizacijske metode

Hibridna optimizacijska metoda za planiranje optimalnog pogona distribuiranih izvora opisana do sada u potpoglavlju 5.2. može se prikazati dijagramom toka na slici 5.6..



Slika 5.6. Dijagram toka predložene hibridne metode za planiranje optimalnog pogona distribuiranih izvora

Na slici 5.6. žutim blokom vanjskih podataka koji se integrira u sedmi korak prikazana je *hibridizacija transformacijom podataka* iz prve cjeline u drugu cjelinu predloženog algoritma. Ljubičasto naznačeni podprocesi predstavljaju *totalnu integraciju* i *ko-simulaciju* proračunskog djela simulacijskog paketa *MATPOWER* sa jedinstvenom optimizacijskom metodom inteligencije roja čestica.

Posebnost predloženog optimizacijskog postupka, opisana potpoglavljem 5.2.1., te načelo *izolacije* naznačeni su crvenim blokovima podprocesa u koracima 6 i 8.5. Dodatno, uvažavajući omeđenosti prostora pretrage, ograničenja optimizacijskog postupka i prikazane četiri funkcije cilja, u koraku 8.3. se integrira vanjska naredbena datoteka programskog okruženja *MATLAB* koja sadrži funkciju cilja definiranu izrazom (5-7) i potpoglavljem 5.2.3.

Tri hijerarhijske ugniježdene (engl. *nested*) *for* petlje objašnjene potpoglavljem 5.2. prikazane su narančastim blokom procesa 8.2. Nakon pozivanja proračuna tokova snaga simulacijskog paketa *MATPOWER* za svaku česticu j definiraju se vektori najboljih individualnih iskustava $pbest$, a zatim se određuje čvor i u kojem će dodatna angažirana snaga upravljive distribuirane proizvodnje uzrokovati najveće smanjenje gubitaka radne snage i to rješenje postaje $gbest$. Navedene rješenje integrira se u pomoćnu strukturu *Common.S* i koja tada sadrži informaciju o dodatnoj proizvodnoj jedinici, njenoj snazi i čvoru u promatranom testnom sustavu.

Kako je postupkom *izolacije* najbolja čestica integrirana u model testnog elektroenergetskog sustava kretanje roja se nastavlja prema sljedećim poznatim najboljim rješenjima, ali nije ograničeno na taj dio prostora rješenja. Naime, modeliranjem broja čestica koji odgovara broju raspoloživih čvorova u svakoj iteraciji popunjavanja čvora provjeriti će se utjecaj distribuiranih izvora za sve čvorove, pa i one u kojima je neka dodatna snaga već angažirana. Iz tog razloga je moguće preciznije odrediti prethodno određenu snagu, a ujedno se ovakvim pristupom jamči pronalazak najpotrebnijeg čvora u svakoj iteraciji. Obzirom da broj iteracija druge petlje također odgovara broju raspoloživih čvorova, jasno je kako će se pri svakom određivanju dodatne snage upravljive distribuirane proizvodnje provjeriti svi čvorovi, dodatna snaga će se angažirati u onom čvoru u kojem uzrokuje najveće smanjenje gubitaka, a najveći broj jedinica distribuirane proizvodnje koji je moguće angažirati jednak je broju raspoloživih čvorova.

Repozitorij rješenja koji proizlazi iz koraka 8.5. sadrži informacije o potrebnim dodatnim angažmanima upravljive distribuirane proizvodnje za svaki promatrani naredni sat i to u zasebnom strukturi koja objedinjuje broj čvora i potrebnu snagu na tom čvoru.

Blokom procesa 8.6. prikazan je postupak promjene parametara čestica opisan potpoglavljem 5.2.2., a blokovima procesa 8.7. i odluke 8.9. prikazani su postupci ograničenja i kriterija završetka optimizacije opisani potpoglavljem 5.2.4.

5.3. Rasuđivanje prilikom planiranja optimalnog pogona,

Sustav odlučivanja i rasuđivanja o optimizacijskim rješenjima temelji se na sustavu neizrazite logike opisanog u potpoglavlju 4.3. i sa hibridnom metodom za planiranje optimalnog pogona distribuiranih izvora sjedinjen je nejakom spregom, pojašnjenom u potpoglavlju 4.6. Odlučivanje i rasuđivanje o rješenjima izvodi se nakon postupka optimizacije te se prema zadanim kriterijima dodjeljuju smjernice za prihvaćanjem ili ponavljanjem optimizacijskog postupka. Sustav odlučivanja i rasuđivanja modeliran sustavom neizrazite logike razvijen je s ciljem zornog izlaganja mogućnosti računalne inteligencije u stvarnim pogonskim okolnostima.

Rješenja dobivena optimizacijskim procesom i predstavljena u sljedećem poglavlju sastoje se od različitih omjera snaga sunčane elektrane i upravljivog sinkronog generatora u svakom čvoru, a uslijed ograničenja i omeđenja optimizacijskog procesa ukupna snaga hibridne distribuirane proizvodnje može biti manja, veća ili jednaka snazi potrošača u pripadajućem čvoru. Zavisno o topologiji elektroenergetske mreže koja se promatra, zahtjevima potrošača, stanju proizvodnje sunčanih elektrana i pogonskim uvjetima u mreži, angažman dodatne snage upravljive distributivne proizvodnje može biti nekoliko puta veći od gubitaka radne snage. Cilj optimizacije opisane prethodnim potpoglavljem je pružiti pregled o potrebnim dodatnim angažmanima upravljive distribuirane proizvodnje za svaki čvor i za svaki sat narednog dana, a cilj sustava odlučivanja je provjeriti odgovaraju li predložena rješenja dodatnim kriterijima.

Dodatni kriteriji pretpostavljeni za izlaganje postupka odlučivanja i zaključivanja sustavom neizrazite logike su opravdanost dodatnog angažmana u odnosu prema apsolutnoj vrijednosti smanjenja gubitaka, promatranih kroz troškove gubitaka radne snage. Podaci o troškovi gubitaka razmatraju se kao troškovi neisporučene električne energije po tarifi za kućanstva na razini EU-28 zemalja u iznosu od 0,211 EUR/kWh ili 211 EUR/MWh [332]. Trošak proizvodnje električne energije iz tehnologija opisanih drugim poglavljem, a koje omogućavaju upravljivost proizvodnje, prema [333] iznosi 86,9 EUR/MWh za cijenu koju postiže električna energije proizvedena iz biomase. U slučaju kada se iz literature [332] preuzme cijena prirodnog plina kao primarnog energenta od 34 EUR/MWh i u obzir uzme okvirna učinkovitost proizvodnje električne energije od 40% [71] dobije se cijena od 85 EUR/MWh, što je vrlo bliska vrijednost prve navedene cijene te je moguće zaključiti kako su troškovi proizvodnje električne energije tehnologijama koje omogućavaju upravljivost proizvodnje u pravilu 2,5 puta manji od troškova izazvanih gubicima, ukoliko se troškovi gubitaka radne snage promatraju kao neisporučena električna energija krajnjim kupcima.

Način kojim se inovativnim pristupom odlučuje o angažmanu snage potpuno aktivnih i razvijenih naprednih distributivnih mreža prikazan je u literaturi [334]–[336] na primjeru napredne distributivne mreže grada Brooklyn, SAD. Cilj sustava odlučivanja i rasuđivanja o optimizacijskim rješenjima temeljen na sustavu neizrazite logike predložen ovom doktorskom disertacijom je ponuditi potporu i objektivnu ocjenu predloženog rješenja, a nikako uvjetovati ili upravljati dodatnim angažmanom jer je iz navedene literature jasno kako je to složen višeslojni izazov čijim rješavanjem se bave vodeći znanstvenici iz područja elektroenergetike i računarstva.


Sustav odlučivanja i rasuđivanja o optimizacijskim rješenjima temeljen na sustavu neizrazite logike modeliran je u *MATLAB* programskom okruženju korištenjem *Fuzzy Logic Designer* programskog dodatka.

5.3.1. Kriteriji pripadnosti

Ocjena rješenja dobivenih optimizacijskim postupkom jedinstvene hibridne metode inteligencije roja čestica izvodi se lingvističkim osvrtom na troškove predloženih rješenja i troškovnu korisnost optimizacijskog postupka obradom ulaznih veličina prema pravilima iz tablice 5.3. Broj pravila definiran je brojem ulaznih veličina i količinom vrijednosti koje svaka od tih veličina može poprimiti prema izrazu (5-18). Broj ulaznih veličina, broj funkcija pripadnosti i vrijednosti koje se mogu poprimiti pojašnjen je dalje u tekstu.

$$\Gamma_1(x) = \prod_{i=1}^2 f_i(x) = f_1 \times f_2 = 6 \quad (5-18)$$

Sustav rasuđivanja i ocjene o optimizacijskim rješenjima razvijen kao sastavni dio predloženog algoritma kratkoročnog planiranja pogona distribuiranih izvora, sadrži dvije ulazne varijable i jednu izlaznu varijablu nastalu kao rezultat obrade korištenjem pravila iz tablice 5.3., a prikaz modeliranog *Mamdani* sustava preuzet iz programskog okruženja *MATLAB* prikazan je slikom 5.7. U tablici 5.3. koristi se matematički operator \wedge za logički uvjet *i*.



Slika 5.7. Sinteza sustava rasuđivanja korištenjem sustava neizrazite logike

Zadovoljenje uvjeta univerzalnosti uvjetuje pripremu ulaznih podataka za sustav rasuđivanja promjenom izlaznih vrijednosti optimizacije iz područja apsolutnih vrijednosti u područje relativnog univerzalnog skupa intervala $[0, 1]$. Ulazne varijable sustava rasuđivanja o troškovima gubitaka i troškovima pogona upravljive distribuirane proizvodnje moraju biti univerzalne bez obzira na promatrani testni elektroenergetski sustav i iznose tehničkih veličina u njemu.

Tablica 5.3. Skup pravila obrade ulaznih veličina predloženim sustavom rasuđivanja

Br.	Vrijednost lingvističke varijable o troškovima gubitaka	Operator	Vrijednost lingvističke varijable o trošku dodatnog pogona upravljive proizvodnje	Lingvistička vrijednost ocjene o pogonskim troškovima predloženog rješenja
1.	Mali troškovi gubitaka	\wedge	Dvostruki	Prihvatljivi
2.	Mali troškovi gubitaka	\wedge	Veći troškovi	Veliki
3.	Mali troškovi gubitaka	\wedge	Manji troškovi	Mali
4.	Veliki troškovi gubitaka	\wedge	Veći troškovi	Veliki
5.	Veliki troškovi gubitaka	\wedge	Dvostruki	Veliki
6.	Veliki troškovi gubitaka	\wedge	Manji troškovi	Veliki

Apsolutni podaci o troškovima gubitaka preračunavaju se u relativni iznos usporedbom podataka o postignutim gubicima nakon optimizacijskog procesa sa podacima o iznosu gubitaka pri početnom stanju promatrane elektroenergetske mreže. Lingvistička vrijednost *Mali troškovi gubitaka* podrazumijeva zrcalnu S -funkciju, nazvanu i Z -funkcija, uz parametre izraza (4-43) prema izrazu (5-19).

$$\begin{aligned}
 a &= 0,75 \\
 b &= 1 \\
 m &= 0,375
 \end{aligned}
 \tag{5-19}$$

Prema parametrima izraza (5-19) jasno je kako će tek prilikom smanjenja gubitaka u relativnom iznosu od 25%, u usporedbi sa gubicima pri početnim uvjetima promatrane elektroenergetske mreže, modelirani sustav rasuđivanja u potpunosti ustanoviti kako se radi o značajnijem smanjenju gubitaka radne snage u sustavu. Razumljivo, parametrom a pripadajuće funkcije pripadnosti moguće je promijeniti navedeni iznos na bilo koju vrijednost.

Lingvistička vrijednost *Veliki troškovi gubitaka* podrazumijeva punu S -funkciju sa parametrima prema izrazu (5-20), a sukladno pojašnjenju parametara za prethodni izraz, samo oni

gubici nakon optimizacijskog procesa koji poprimaju tek 25% vrijednosti gubitaka iz početnog proračuna tokova snaga, se smatraju malim gubicima i ne sadrže dodatnu vrijednost neke druge funkcije pripadnosti.

$$\begin{aligned} a &= 0,25 \\ b &= 1 \\ m &= 0,625 \end{aligned} \tag{5-20}$$


Vrijednost lingvističke varijable o trošku dodatnog pogona upravljive proizvodnje može poprimiti tri logičke vrijednosti prilikom usporedbe sa troškovima gubitak: *Veći troškovi*, *Dvostruki troškovi* i *Manji troškovi*. Vrijednost lingvističke varijable nastaje zbrajanjem svih dodatno angažiranih snaga upravljive distribuirane proizvodnje i preračunavanjem tehničkih podataka u financijske pokazatelje usporedive sa odgovarajućim pokazateljima gubitaka. Vrijednost ulaznog parametra o trošku proizvodnje dodatne električne energije iz upravljive distribuirane proizvodnje nastaje kao rezultat obrade pomoću tri funkcije pripadnosti: *Z-funkcija*, *S-funkcija* i *trapezoidna* funkcija. Trapezoidna funkcija opisuje slučajeve u kojima su pogonski troškovi distribuirane proizvodnje najviše dvostruko veći u odnosu na troškove gubitaka radne snage, a opisana je izrazom (4-42) te u modeliranom sustavu rasuđivanja posjeduje parametre pripadnosti prema izrazu (5-21).

$$\begin{aligned} a &= 0,455 \\ b &= 0,455 \\ c &= 0,55 \\ d &= 0,555 \end{aligned} \tag{5-21}$$

S-funkcija i *Z-funkcija* zrcalnog su oblika i opisuju *Manje* i *Veće* troškove distribuirane proizvodnje. *Z-funkcija* modelirana je od vrijednosti 0 do vrijednosti 0,6, a *S-funkcija* iz vrijednosti 0,4 do vrijednosti 1, sukladno izrazima (4-40) i (4-41).


Ocjena o stanju troškova elektroenergetskog sustava prilikom pogona distribuiranih izvora prema rezultatima optimizacije i uz definirani dodatni angažman upravljive distribuirane proizvodnje rezultat je triju funkcija pripadnosti: *S-funkcije*, *Z-funkcije* te *trapezoidne* funkcije. Lingvistička vrijednost *Mali* pogonski troškovi određena je *S-funkcijom* pripadnosti sa granicom u vrijednosti od 0,35. Sukladno tome, lingvistička vrijednost *Veliki* određena je *Z-funkcijom* sa granicom pripadanja u vrijednosti 0,65. U intervalu [0,45 – 0,55] određena je *trapezoidna* funkcija pripadanju lingvističkoj vrijednosti *Prihvatljivi* pogonski troškovi, što za potrebe

modeliranja sustava rasuđivanja podrazumijeva troškove pogona distribuiranih izvora u iznosu najviše dvostrukom u usporedbi sa troškovima gubitaka. Parametarski blok koji sadrži pravila za ocjenu predloženih rješenja, preuzet iz *Fuzzy Logic Designer* programskog dodatka, prikazan je slikom 5.8.



Slika 5.8. Programski blok ocjene predloženih rješenja u programskog dodatku *Fuzzy Logic Designer*

Primjenom funkcija opisanih potpoglavljem 4.3.1. modeliran je sustav rasuđivanja temeljen na sustavima neizrazite logike i to primjenom grafičkog sučelja *Fuzzy Inference System Modeling* sadržanog u programskom okruženju *MATLAB*. Navedena pravila obrade ulaznih veličina i opisane funkcije pripadnosti rezultiraju plohom odlučivanja, prikazanom slikom 5.9. na kojoj je žutom bojom naznačeno područje *Malih* pogonskih troškova, svjetlo plavom bojom su opisana rješenja *Prihvatljivih* pogonskih troškova, a tamno plavom bojom rješenja koja će uzrokovati *Velike* pogonske troškove.



Slika 5.9. Pravila modeliranog sustava rasuđivanja prikazana plohom odlučivanja

6. Rezultati određivanja optimalnog pogona distribuiranih izvora razvijenom hibridnom metodom

Prethodnim poglavljem opisan je algoritam kratkoročnog planiranja pogona distribuiranih izvora koji uzima u obzir samodostatnost mreže prema izrazu (5-13) i smanjenje gubitaka prema izrazu (5-7). Predloženi algoritam sastoji se od tri cjeline načelno opisane u uvodu prethodnog poglavlja i zasebno obrazložene potpoglavljima 5.1., 5.2. i 5.3. Najznačajnija cjelina predloženog algoritma je hibridna metoda za planiranje optimalnog pogona distribuiranih izvora opisana potpoglavljem 5.2. i koja razinom *totalne integracije* sjedinjuje optimizacijski i proračunski postupak. Posebnost optimizacijskog postupka iskazana je načelom *izolacije* najboljih rješenja primjenom kriterija *elitizma* svojstvenog za genetski algoritam. Dodatak hibridnoj metodi za planiranje optimalnog pogona je sustav rasuđivanja i razvrstavanja predloženih rješenja temeljen na sustavu neizrazite logike i pojašnjen u potpoglavljju 5.3. Sustav rasuđivanja zasnivan na sustavima neizrazite logike sjedinjen je sa optimizacijskom metodom na razini *nejake sprege*. Razine sjedinjenja različitih postupaka, tzv. *hibridizacija* obrazloženi su potpoglavljem 4.6., a u uvodu prethodnog poglavlja pojašnjen je pojam *ko-simulacije* koji se odnosi na posebnu vrstu *hibridizacije* nastalu sjedinjenjem proračunskih i optimizacijskih postupaka.

Svrha ovog poglavlja je provjeriti pragmatičnost predloženog algoritma i metode prilikom rješavanja optimizacijskog problema pogona distribuiranih izvora potpuno aktivnih elektroenergetskih mreža. Sve cjeline predloženog algoritma izrađene su u programskom okruženju *MATLAB* s kojim je spojiv i simulacijski paket *MATPOWER*, integriran u optimizacijsku metodu.

Pretpostavljeni optimizacijski problem pogona distribuiranih izvora potpuno aktivnih elektroenergetskih mreža moguće je promatrati sa više gledišta, a u ovom znanstveno-istraživačkom radu u prvom redu se promatraju gubici radne snage u elektroenergetskoj mreži, što je određeno vanjskom funkcijskom naredbenom datotekom programskog okruženja *MATLAB*, kako je prikazano odvojenim podprocesom kraj koraka 8.3 na slici 5.6. Predloženim algoritmom i optimizacijskom metodom moguće je ispitivati sve testne sustave sadržane u simulacijskom paketu *MATPOWER*, ali i bilo koji drugi elektroenergetski sustav modeliran prema pravilima i postupcima iz trećeg poglavlja ove doktorske disertacije. Tehnički parametri fizikalnih modela promatrani optimizacijskim procesom integrirani su u predloženu metodu kao ograničenja optimizacijskog postupka, a dodatni ciljevi kao omeđenja koja se provjeravaju u različitim dijelovima hibridne metode. Pregled bitnih parametara obuhvaćenih optimizacijskom metodom i

predloženim algoritmom kratkoročnog planiranja prikazan je tablicom 6.1. U radu su kroz prethodna poglavlja izneseni svi tehnički parametri obuhvaćeni simulacijskim paketom *MATPOWER* i koji se mogu promatrati funkcijom cilja.

Tablica 6.1. Parametri obuhvaćeni optimizacijskom metodom i predloženim algoritmom

Ulazni podaci	Broj raspoloživih čvorova za integraciju hibridne distribuirane proizvodnje
	Predviđena proizvodnja sunčanih elektrana u raspoloživim čvorovima
	Naponska ograničenja u svim čvorovima
	Raspored i snaga potrošača po čvorovima
	Ograničenja tokova snaga kroz grane
Izlazni podaci	Optimalna lokacija hibridne distribuirane proizvodnje
	Optimalna snaga hibridne distribuirane proizvodnje
	Gubici u elektroenergetskoj mreži bez distribuirane proizvodnje
	Gubici u elektroenergetskoj mreži sa predloženim angažmanom dodatne hibridne distribuirane proizvodnje
	Vrijednosti napona u svima čvorovima nakon optimizacije
	Struje kroz sve grane
	Ukupna potrebna dodatno angažirana snaga upravljive distribuirane proizvodnje
	Ocjena troškovne opravdanosti dodatno angažirane snage distribuirane proizvodnje

Optimizacijskim postupkom predodređena su rješenja koja će omogućiti najveći mogući broj dodatno angažiranih jedinica distribuirane proizvodnje, sukladno izrazu (5-2), a sustavom rasuđivanja tada donijeti prosudbu o isplativosti takvog rješenja i eventualnim potrebnim izmjenama. Značajno složeniji i tržišno orijentirani pristup prikazan je u literaturi [335] koja obrazlaže primjenu tehnologije ulančanih blokova (engl. *blockchain*).

Dodatno, trenutna promjenjivost proizvodnje sunčanih elektrana uslijed naglih promjena meteoroloških uvjeta modelirana je nasumičnim isključivanjima do 30% modeliranih elektrana u sustavu. U svakoj iteraciji h nasumično se iz strukture *Common.S* odabire cjelobrojni broj čvorova u kojima će proizvodnja sunčanih elektrana promijeniti iznos na nulu. Kriterij do 30% realiziran je zaokruživanjem na prvi manji cijeli broj. Ovim pristupom unosi se značajan poremećaj u proizvodnji hibridnih distribuiranih izvora, ali se optimizacijska metoda mora uspješno nositi sa

takvim promjenjivim karakteristikama proizvodnje i za svaki sat optimalno nadomjestiti izgublenu snagu određivanjem dodatnog angažmana upravljive distribuirane proizvodnje.

Varijablom *tic – toc* mjeri se vrijeme potrebno za optimizacijski postupak kako bi se predložena metoda ocijenila za primjenu prilikom kratkoročnog planiranja. Sve simulacije izvode se na osobnom računalu sa procesorom Intel Core2 Quad Q6600 i sa 4 gigabajta *RAM* memorije.

6.1. Primjeri ispitnih sustava korištenih u simulacijama

Za ispitivanje primjenjivosti predloženog algoritma i optimizacijske metode koriste se prstenasto-povezani, *zamkasti*, ispitni sustavi od 30 i 57 čvorova te radijalni ispitni sustav od 33 čvora. Svi ispitni sustavi modelirani su prema zahtjevima opisanih u trećem poglavlju ove doktorske disertacije i sadržani su unutar simulacijskog paketa *MATPOWER*. Ispitni sustav od 30 čvorova zasnivan je na *IEEE* ispitnom sustavu, a ispitni sustavi od 57 čvorova i od 33 čvora su *IEEE* ispitni sustavi.

Promatrani testni sustavi od 30, 33 i 57 čvorova su prstenasto-povezane i radijalne izvedbe jer je takva topologija najčešće promatrana u izloženoj literaturi. Radijalni tipovi elektroenergetskih mreža češće su obrađeni u znanstvenoj literaturi [41]–[47], [50], [54]–[58], [66], [81], [87], [92], [94] jer pružaju jednostavnije okruženje za rješavanje identificiranih optimizacijskih problema i jednostavnije je intuitivno donijeti zaključke o ispravnosti rješenja. Prstenasto-povezane elektroenergetske mreže promatrane su kroz rješavanje različitih optimizacijskih izazova u znanstvenim radovima [46], [48], [49], [51]–[53], [57], [59]–[61].


Podaci o ispitnim sustavima predočeni su u ovom potpoglavlju jer predstavljaju uzročno-posljedičnu poveznicu sa ciljevima optimizacije te su na taj način nedjeljivi od rezultata optimizacije. Izdvajanjem podataka o ispitnim sustavima u poseban prilogu ove doktorske disertacije izgubila bi se cjelovitost spoznajnog procesa i narušio bi se pregled djelovanja predložene metode i algoritma. Ipak, grupiranjem potpoglavlja 6.1.1 - 6.1.3 na sljedećim stranicama, omogućeno je upućenom čitatelju preskočiti pregled korištenih ispitnih elektroenergetskih sustava.

6.1.1. Ispitni sustav zasnivan na *IEEE* ispitnom sustavu od 30 čvorova

Ispitni sustav od 30 čvorova koristi se kao početni ispitni sustav za provjeru primjenjivosti predložene metode jer se radi o prstenasto-povezanom, tj. *zamkastom*, sustavu sa manjim brojem čvorova za kojeg je postupak optimizacije vremenski najmanje zahtjevan. Sustav sadrži 30 čvorova i 41 vod, a na 6 čvorova definirana je elektrana. Sustav nema potrošače u svim čvorovima,

a jedan čvor definiran je kao referentni čvor. Naponske razine čvorova su prema nekim izvorima 132 kV i 33 kV, a prema nekim izvorima 11 kV i 1,0 kV [337], [338]. Ovako prilagođeni ispitni sustav od 30 čvorova zasnovan na *IEEE* ispitnom sustavi izvrstan je primjer složene distributivne mreže, prikazan slikom 6.1. [337].

Električni podaci ispitnog sustava definiranog simulacijskim paketom *MATPOWER*, koji sadrži 30 čvorova i temelji se na *IEEE* ispitnom sustavu, prikazani su u tablicama 6.2. i 6.3. [160], [175], uz baznu snagu na koju su preračunate sve veličine od 100 MVA i veličine iskazane po jedinici (p.u.).



Slika 6.1. Ispitni sustav zasnovan na *IEEE* ispitnom sustavu od 30 čvorova [337]

Oznake u tablici 6.2. odgovaraju referentnom čvoru za oznaku *ref*, čvoru sa kontrolom napona za oznaku *P-V*, čvoru sa opterećenjem sa oznakom *P-Q*, radnoj snazi potrošača u čvoru sa oznakom P_p i jalovoj snazi potrošača u čvoru sa oznakom Q_p .

Tablica 6.2. Podaci o čvorovima i potrošačima ispitnog sustava od 30 čvorova

Broj čvora	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Tip čvora	ref.	P-V	P-Q	P-Q	P-Q	P-Q	P-Q	P-Q	P-Q	P-Q	P-Q	P-Q	P-V	P-Q	P-Q
P_p [MW]	0	21,7	2,40	7,60	0	0	22,8	30	0	5,80	0	11,2	0	6,20	8,20
Q_p [MVar]	0	12,7	1,20	1,60	0	0	10,9	30	0	2	0	7,50	0	1,60	2,50
Broj čvora	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Tip čvora	P-Q	P-Q	P-Q	P-Q	P-Q	P-Q	P-V	P-V	P-Q	P-Q	P-Q	P-V	P-Q	P-Q	P-Q
P_p [MW]	3,50	9	3,20	9,50	2,20	17,5	0	3,20	8,70	0	3,50	0	0	2,40	10,6
Q_p [MVar]	1,80	5,80	0,90	3,40	0,70	11,2	0	1,60	6,70	0	2,30	0	0	0,90	1,90

Oznake u tablici 6.3. odgovaraju broju čvora u kojem započinje vod sa oznakom *Od*, broju čvora do kojeg se proteže vod sa oznakom *Do*, djelatnom otporu sa oznakom *R*, reaktanciji sa oznakom *X*, susceptanciji sa oznakom *B* i prijenosnom kapacitetu S_{ka} .


Tablica 6.3. Podaci o vodovima ispitnog sustava od 30 čvorova

Od:	1	1	2	3	2	2	4	5	6	6	6	6	9	9
Do:	2	3	4	4	5	6	6	7	7	8	9	10	11	10
R (p. u.)	0,02	0,05	0,06	0,01	0,05	0,06	0,01	0,05	0,03	0,01	0,00	0,00	0,00	0,00
X (p. u.)	0,06	0,19	0,17	0,04	0,20	0,18	0,04	0,12	0,08	0,04	0,21	0,56	0,21	0,11
B (p. u.)	0,03	0,02	0,02	0,00	0,02	0,02	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00
S_{ka} [MVA]	130	130	65	130	130	65	90	70	130	32	65	32	65	65
Od:	4	12	12	12	12	14	16	15	18	19	10	10	10	10
Do:	12	13	14	15	16	15	17	18	19	20	20	17	21	22
R (p. u.)	0,00	0,00	0,12	0,07	0,09	0,22	0,08	0,11	0,06	0,03	0,09	0,03	0,03	0,07
X (p. u.)	0,26	0,14	0,26	0,13	0,20	0,20	0,19	0,22	0,13	0,07	0,21	0,08	0,07	0,15
B (p. u.)	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
S_k [MVA]	65	65	32	32	32	16	16	16	16	32	32	32	32	32
Od:	21	15	22	23	24	25	25	28	27	27	29	8	6	
Do:	22	23	24	24	25	26	27	27	29	30	30	28	28	
R (p. u.)	0,01	0,10	0,12	0,13	0,19	0,25	0,11	0,00	0,22	0,32	0,24	0,06	0,02	
X (p. u.)	0,02	0,20	0,18	0,27	0,33	0,38	0,21	0,40	0,42	0,60	0,45	0,20	0,06	
B (p. u.)	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,01	
S_k [MVA]	32	16	16	16	16	16	16	65	16	16	16	32	32	

Kod *IEEE* ispitnog sustava od 30 čvorova riječ je o testnom sustavu zastupljenog u znanstvenoj literaturi [49], [51], [62], [64], [65], [233], [234], [277], [307], [339]–[341] čime se potvrđuje ispravnost odabira testnog sustava.

6.1.2. *IEEE* ispitni sustav od 57 čvorova

IEEE Ispitni sustav od 57 čvorova također je prstenasto-povezane izvedbe sa 7 definiranih lokacija elektrana i ne sadrži potrošače u svim čvorovima, a jedan čvor je referentni čvor. Sustav se koristi u znanstvenoj literaturi [252], [277], [307], [342]–[345] i predstavlja pojednostavljeni elektroenergetski sustav u dijelu srednjeg Zapada SAD-a, prikazan slikom 6.2.



Slika 6.2. *IEEE* ispitni sustav od 57 čvorova

Ispitni sustav od 57 čvorova sadrži 80 vodova, prosječna snaga potrošača je 7,89 MW, najveća snaga potrošača je 29,7 MW, a najmanja snaga potrošača je 1,6 MW. Na petnaest čvorova ne postoje potrošači. *IEEE* ispitni sustav od 57 čvorova sadrži sedam čvorova sa elektranama, ukupne snage 944,96 MVA.

Električni podaci ispitnog sustava od 57 čvorova definiranog simulacijskim paketom *MATPOWER* prikazani su u tablicama 6.4. i 6.5. [160], [175], uz baznu snagu na koju su preračunate sve veličine od 100 MVA i veličine iskazane po jedinici (p.u.).

Oznake u tablici 6.4. odgovaraju referentnom čvoru za oznaku *ref*, čvoru sa kontrolom napona za oznaku *P-V*, čvoru sa opterećenjem sa oznakom *P-Q*, radnoj snazi potrošača u čvoru sa oznakom P_p i jalovoj snazi potrošača u čvoru sa oznakom Q_p .

Tablica 6.4. Podaci o čvorovima i potrošačima *IEEE* ispitnog sustava od 57 čvorova

Broj čvora	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Tip čvora	<i>ref.</i>	<i>P-V</i>	<i>P-V</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-V</i>	<i>P-Q</i>	<i>P-V</i>	<i>P-V</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-V</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>
P_p [MW]	55	3	41	0	13	75	0	150	121	5	0	377	18	10,5	22
Q_p [MVA _r]	17	88	21	0	4	2	0	22	26	2	0	24	2,30	5,30	5
Broj čvora	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Tip čvora	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>
P_p [MW]	43	42	27,2	3,30	2,30	0	0	6,30	0	6,30	0	9,30	4,60	17	3,60
Q_p [MVA _r]	3	8	9,80	0,60	1	0	0	2,10	0	3,20	0	0,50	2,30	2,60	1,80
Broj čvora	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
Tip čvora	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>
P_p [MW]	5,80	1,60	3,80	0	6	0	0	14	0	0	6,30	7,10	2	12	0
Q_p [MVA _r]	2,90	0,80	1,90	0	3	0	0	7	0	0	3	4,40	1	1,80	0
Broj čvora	46	47	48	49	50	51	52	53	54	55	56	57			
Tip čvora	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>			
P_p [MW]	0	29,7	0	18	21	18	4,90	20	4,10	6,80	7,60	6,70			
Q_p [MVA _r]	0	11,6	0	8,50	10,5	5,30	2,20	10	1,40	3,40	2,20	2			

Oznake u tablici 6.5., kao i prethodnom primjeru, odgovaraju broju čvora u kojem vod, što označava oznaka *Od*, broju čvora do kojeg se vod nastavlja sa oznakom *Do*, djelatnom otporu sa oznakom *R*, reaktanciji sa oznakom *X* i susceptanciji sa oznakom *B*. Prijenosni kapaciteti vodova su za sve vodove jednaki i iznose $S_{ka} = 9900$ MVA.

Tablica 6.5. Podaci o vodovima *IEEE* ispitnog sustava od 57 čvorova


<i>Od:</i>	1	2	3	4	4	6	6	8	9	9	9	9
<i>Do:</i>	2	3	4	5	6	7	8	9	10	11	12	13
<i>R</i> (p.u.)	0,0083	0,0298	0,0112	0,0625	0,043	0,02	0,0339	0,0099	0,0369	0,0258	0,0648	0,0481
<i>X</i> (p.u.)	0,028	0,085	0,0366	0,132	0,148	0,102	0,173	0,0505	0,1679	0,0848	0,295	0,158
<i>B</i> (p.u.)	0,129	0,0818	0,038	0,0258	0,0348	0,0276	0,047	0,0548	0,044	0,0218	0,0772	0,0406

Od:	13	13	1	1	1	3	4	4	5	7	10	11
Do:	14	15	15	16	17	15	18	18	6	8	12	13
<i>R (p. u.)</i>	0,0132	0,0269	0,0178	0,0454	0,0238	0,0162	0	0	0,0302	0,0139	0,0277	0,0223
<i>X (p. u.)</i>	0,0434	0,0869	0,091	0,206	0,108	0,053	0,555	0,43	0,0641	0,0712	0,1262	0,0732
<i>B (p. u.)</i>	0,011	0,023	0,0988	0,0546	0,0286	0,0544	0	0	0,0124	0,0194	0,0328	0,0188
Od:	12	12	12	14	18	19	21	21	22	23	24	24
Do:	16	13	17	15	19	20	20	22	23	24	25	25
<i>R (p. u.)</i>	0,018	0,0178	0,0397	0,0171	0,461	0,283	0	0,0736	0,0099	0,166	0	0
<i>X (p. u.)</i>	0,0813	0,058	0,179	0,0547	0,685	0,434	0,7767	0,117	0,0152	0,256	1,182	1,1,202 3
<i>B (p. u.)</i>	0,0216	0,0604	0,0476	0,0148	0	0	0	0	0	0,0084	0	0
Od:	24	26	27	28	7	25	30	31	32	34	34	35
Do:	26	27	28	29	29	30	31	32	33	32	35	36
<i>R (p. u.)</i>	0	0,165	0,0618	0,0418	0	0,135	0,326	0,507	0,0392	0	0,052	0,043
<i>X (p. u.)</i>	0,0473	0,254	0,0954	0,0587	0,0648	0,202	0,497	0,755	0,036	0,953	0,078	0,0537
<i>B (p. u.)</i>	0	0	0	0	0	0	0	0	0	0	0,0032	0,0016
Od:	36	37	37	36	22	11	41	41	38	15	14	46
Do:	37	38	39	40	38	41	42	43	44	45	46	47
<i>R (p. u.)</i>	0,029	0,0651	0,0239	0,03	0,0192	0	0,207	0	0,0289	0	0	0,023
<i>X (p. u.)</i>	0,0366	0,1009	0,0379	0,0466	0,0295	0,749	0,352	0,412	0,0585	0,1042	0,0735	0,068
<i>B (p. u.)</i>	0	0,002	0	0	0	0	0	0	0,002	0	0	0,0032
Od:	47	48	49	50	10	13	29	52	53	54	11	44
Do:	48	49	50	51	51	49	52	53	54	55	43	45
<i>R (p. u.)</i>	0,0182	0,0834	0,0801	0,1386	0	0	0,1442	0,0762	0,1878	0,1732	0	0,0624
<i>X (p. u.)</i>	0,0233	0,129	0,128	0,22	0,0712	0,191	0,187	0,0984	0,232	0,2265	0,153	0,1242
<i>B (p. u.)</i>	0	0,0048	0	0	0	0	0	0	0	0	0	0,004
Od:	40	56	56	39	57	38	38	9				
Do:	56	41	42	57	56	49	48	55				
<i>R (p. u.)</i>	0	0,553	0,2125	0	0,174	0,115	0,0312	0				
<i>X (p. u.)</i>	1,195	0,549	0,354	1,355	0,26	0,177	0,0482	0,1205				
<i>B (p. u.)</i>	0	0	0	0	0	0,003	0	0				

6.1.3. Radijalni *IEEE* ispitni sustav od 33 čvora

Radijalni ispitni sustav od 33 čvora sadrži jedan referentni čvor, potrošače u svim čvorovima osim u prvom čvoru i koristi se u znanstvenoj literaturi [16], [57], [58], [346]–[351]. Navedeni ispitni sustav nije prstenasto-povezano izvedbe kao dva prethodno promatrana ispitna sustava i predstavlja izvrstan primjer za ispitivanje vladanja predložene optimizacijske metode na drugačijem tipu elektroenergetske mreže. Naponska razina čvorova u sustavu je 12,66 kV, sustav se sastoji od jednog glavnog izvoda koji se proteže od čvora 1 do čvora 2, a iz čvorova 2, 3 i 6 se izdvajaju četiri odcjepa, kako je prikazano slikom 6.3. [352]. Ukupna radna snaga potrošača u radijalnom *IEEE* ispitnom sustavu od 33 čvora iznosi 3,71 MW uz prosječnu radnu snagu po čvoru

od 112,58 kW. Ukupna radna snaga potrošača izvoda od čvora 7 do čvora 18 iznosi 1075 kW, ukupna snaga izvoda od čvora 23 do čvora 25 iznosi 930 kW, ukupna radna snaga potrošača izvoda od čvora 26 do čvora 33 iznosi 920 kW. Izvod od čvora 19 do čvora 22 sadrži najmanju snagu potrošača u iznosu od 360 kW.



Slika 6.3. Radijalni *IEEE* ispitni sustav od 33 čvora

Električni podaci *IEEE* ispitnog sustava od 33 čvora, definiranog simulacijskim paketom *MATPOWER*, prikazani su u tablicama 6.6. i 6.7. [160], [175], uz baznu snagu na koju su preračunate sve veličine od 100 MVA i veličine iskazane po jedinici (p.u.).

Tablica 6.6. Podaci o čvorovima i potrošačima radijalnog *IEEE* ispitnog sustava od 33 čvora

Broj čvora	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Tip čvora	<i>ref.</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>
P_p [kW]	0	100	90	120	60	60	200	200	60	60	45	60	60	120	60
Q_p [kVAr]	0	60	40	80	30	20	100	100	20	20	30	35	35	80	10
Broj čvora	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Tip čvora	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>
P_p [kW]	60	60	90	90	90	90	90	90	420	420	60	60	60	120	200
Q_p [kVAr]	20	20	40	40	40	40	40	40	50	200	200	25	25	20	70
Broj čvora	31	32	33												
Tip čvora	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>												
P_p [kW]	150	210	60												
Q_p [kVAr]	70	100	40												

Podaci o vodovima radijalnog *IEEE* sustava od 33 čvora nalaze se u tablici 6.7. Oznake u tablici 6.7. označavaju broj čvora u kojem vod započinje čemu odgovara oznaka *Od*, broju čvora do kojeg se vod nastavlja čemu odgovara oznaka *Do*, djelatnom otporu voda čemu odgovara oznaka *R* i reaktanciji voda sa oznakom *X*. Susceptancija voda i prijenosni kapacitet su u ovom *IEEE* ispitnom sustavu postavljeni na vrijednost nula.

Tablica 6.7. Podaci o vodovima radijalnog *IEEE* ispitnog sustava od 33 čvora

<i>Od:</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14
<i>Do:</i>	2	3	4	5	6	7	8	9	10	11	12	13	14	15
<i>R (p. u.)</i>	0,09	0,49	0,37	0,38	0,82	0,19	0,71	1,03	1,04	0,20	0,37	1,47	0,54	0,59
<i>X (p. u.)</i>	0,05	0,25	0,19	0,19	0,71	0,62	0,24	0,74	0,74	0,07	0,12	1,16	0,71	0,53
<i>Od:</i>	15	16	17	2	19	20	21	3	23	24	6	26	27	28
<i>Do:</i>	16	17	18	19	20	21	22	23	24	25	26	27	28	29
<i>R (p. u.)</i>	0,75	1,29	0,73	0,16	1,50	0,41	0,71	0,45	0,90	0,90	0,20	0,28	1,06	0,80
<i>X (p. u.)</i>	0,55	1,72	0,57	0,16	1,36	0,48	0,94	0,31	0,71	0,70	0,10	0,14	0,93	0,70
<i>Od:</i>	29	30	31	32	21	9	12	18	25					
<i>Do:</i>	30	31	32	33	8	15	22	33	29					
<i>R (p. u.)</i>	0,51	0,97	0,31	0,34	2,00	2,00	2,00	0,50	0,50					
<i>X (p. u.)</i>	0,26	0,96	0,36	0,53	2,00	2,00	2,00	0,50	0,50					

6.2. Određivanje parametara optimizacije

Prema izrazu (5-17), broj čestica mora najmanje odgovarati broju raspoloživih čvorova za integraciju hibridne distribuirane proizvodnje sadržane od sunčane elektrane i upravljivog sinkronog generatora. Obzirom da se simulacijama analiziraju ispitni sustavi različitog ukupnog i raspoloživog broja čvorova, u drugom koraku predložene hibridne metode za planiranje optimalnog pogona distribuiranih izvora se zahtjeva ulazni podatak o broju čestica. Isprva je razlog takvog naredbenog retka bio za potrebe analize utjecaja broja čestica na konačna rješenja, brzinu konvergencije i računalnu zahtjevnost optimizacijskog procesa sa različitim brojem čestica. Za svaku česticu se izvodi iterativni proračun tokova snaga pozivanjem simulacijskog paketa *MATPOWER* pa time povećani broj čestica značajno povećava računalne potrebe.

Smanjenjem broja čestica, načelno je potrebno povećati broj iteracija isprobavanja prostora pretrage jer će u protivnom optimizacijski postupak izostaviti globalno optimalno rješenje i *zapeti* će u prostoru lokalnog rješenja. Optimalni broj čestica i optimalni broj iteracija može biti predmet

meta-heurističkog pristupa [61], [81] u kojem se jednom metodom računalne inteligencije određuju parametri druge metode, koja se koristi za promatranje izvjesnog problema.

Postupkom predloženim ovom doktorskom disertacijom postiže se inicijalni pregled cjelokupnog prostora pretrage lokacija već u prvoj iteraciji jer broj čestica odgovara broju raspoloživih čvorova u promatranom testnom sustavu. Prva iteracija tako ima svrhu proširenja skupa rješenja na sve raspoložive lokacije što uvjetuje kompromis određivanju preciznosti snage pojedinačnog najboljeg rješenja. Dodatna prednost ovakvog pristupa je što će u prvoj, ali i svakoj sljedećoj, iteraciji *gbest* rješenje zahvatiti čvor u kojem integracija distribuirane proizvodnje uzrokuje najpovoljniji utjecaj na smanjenje gubitaka radne snage.

Cilj optimizacijskog postupka se može raščlaniti u dva sloja: određivanje optimalnog pogona hibridnih distribuiranih izvora i određivanje potrebnog dodatnog angažmana upravljive distribuirane proizvodnje. Dva sloja informacija potrebno je odrediti za svaki naredni odsječak promatranog budućeg vremenskog razdoblja, što u ovom istraživanju predstavlja svaki sat u narednom dana. Za sva sat optimizacijski proces mora pružiti pregled potrebnih snaga i lokacija čvorova u kojima se te snage moraju angažirati. Iz navedenog proizlazi kako je moguće dodati broj upravljivih distribuiranih izvora istovjetan broju raspoloživih čvorova, odnosno broj hibridnih distribuiranih izvora, koji se sastoji od sunčane elektrane i sinkronog generatora, jednak je broju raspoloživih čvorova. Međutim, kako je optimizacijski proces modeliran na način obuhvaćanja cjelokupnog prostora rješenja lokacija, precizno pronalaženje optimalnih snaga rezultat je broja iteracija. Iz navedenih razmatranja proizlazi kako je broj čestica definiran izrazom (5-17) bitan za postizanje preciznih rješenja optimizacijskog procesa. Empirijskim postupkom određen je podatak o modeliranom broju čestica za potrebe opisanog znanstveno-istraživačkog rada koji je uvijek jednak ukupnom broju čvorova u ispitnim elektroenergetskom sustavu. Primjerice, prilikom optimizacijskog procesa ispitnog sustava od 30 čvorova, optimizacijski postupak sa 30 čestica traje 127,697 sekundi, a sa 24 čestice 111,147 sekundi te razlika od 16,55 sekundi nije presudna za primjenjivost predložene optimizacijske metode u algoritmu kratkoročnog planiranja. Ovdje je bitno napomenuti kako su zbog smanjenja vremenske i računalne zahtjevnosti provedbe optimizacijskog procesa izostavljene sve ispisne naredbe simulacijskog paketa *MATPOWER*.

Dodatna prednost modeliranja broja čestica koji odgovara ukupnom broju čvorova ispitnog sustava je što se takvim postupkom, pri kojem je broj raspoloživih čvorova manji od ukupnog broj čestica, najbolja rješenja jedne populacije dodatno provjere unutar iste iteracije, čime je značajno povećana preciznost svake iteracije u skupu rješenja za snagu distribuirane proizvodnje.

Primjenom analitičkog sučelja *Profiler* programskog okruženja *MATLAB* se za spomenuti slučaj od 30 modeliranih čestica prilikom optimizacije ispitnog sustava od 30 čvorova, pri čemu je broj raspoloživih čvorova 24, nakon 15384 iteracija postiže uvjet konvergencije pri kojem nema promjene snage rješenja *g_{best}* manje od 1%. Najveći mogući broj iteracija u takvom slučaju je 17280, što odgovara produktu vrijednosti u varijablama *h*, *i* i *j* opisanih u prethodnom poglavlju. Za iste uvjete, ali uz 24 modelirane čestice broj izvedenih iteracija je 12504 uz najveći mogući ukupni broj iteracija od 13824. Razlika od 2880 iteracija odgovara vremenu od 23 sekunde što ne predstavlja značajnu prepreku za učinkovitu primjenu predloženog algoritma.

Simulacije na ispitnom sustavu od 30 čvorova predstavljene u potpoglavlju 6.3.1, predstavljaju prve provjere upotrebljivosti i učinkovitosti predložene optimizacijske metode. Sukladno tome, za navedeni ispitni sustav izvršeno je više optimizacijskih procesa s ciljem pronalaska parametara optimizacije koji rezultiraju najboljim rješenjima. Upravljanjem omeđenjima i ograničenjima optimizacijskog procesa, promjenom parametara čestica, promjenom vrijednosti u kriterijima konvergencije i povećanjem ili smanjenjem broja čestica utječe se na uspješnosti, preciznost i upotrebljivost predložene hibridne optimizacijske metode. Uspješnost predložene metode očita je uspješno provedenom postupku bez prijavljenih grešaka i bez nemogućnosti provedbe proračuna tokova snaga. Preciznost predložene metode iskazuje se u poboljšanjima promatranih ciljeva optimizacijskog procesa. Obzirom da predložena metoda ima za cilj smanjiti gubitke radne snage na najmanju moguću mjeru angažiranjem više jedinica dodatne upravljive distribuirane proizvodnje uz poštivanje pogonskih uvjeta sunčanih elektrana fotonaponske pretvorbe, preciznost predložene optimizacijske metode očituje se u apsolutnom i relativnom smanjenju tehničkih gubitaka radne snage. Upotrebljivost predložene hibridne optimizacijske metode u algoritmu kratkoročnom planiranja pogona distribuiranih izvora iskazuje se računalnim zahtjevima i trajanjem vremena izvođenja koje bi za kratkoročne uvjete planiranja trebalo biti manje od najmanje podjele promatranog vremenskog intervala.

Ipak, uz iznimno stroge kriterije završetka optimizacijskog procesa, kako je prikazano potpoglavljem 5.2.4., optimizacijski postupak izvršavati će se u potpunosti kako je zadano ugniježdenim *for* petljama.

6.3. Rezultati optimizacija i prikaz rješenja

Rezultati simulacije se u nastavku ove doktorske disertacije prikazuju kao skupni prikaz svih čvorova promatranog elektroenergetskog sustava sa snagama distribuirane proizvodnje u svakom satu promatranog budućeg razdoblja od jednog dana. Takav prikaz izveden je

dvodimenzionalnim prikazom na kojem su na apscisi smješteni sati promatranog budućeg razdoblja, a na ordinati čvorovi od 1 do n_{ζ} . Snaga distribuirane proizvodnje prikazana je različitim intenzitetom boje po segmentima podjele

Osim navedenog prikaza, za potrebe posebnih analiza rezultate je moguće zasebno prikazati za svaki sat ili za svaki čvor. Ukoliko se promatra jedan satni interval tada su pri dvodimenzionalnom prikazu na apscisi smješteni brojevi čvorova, a na ordinati se prikazuju dodatno angažirane snage upravljive distribuirane proizvodnje. Takav prikaz rezultat je tablične analize po satima kojom se stvara ulazni podatak za sustav rasuđivanja temeljen na sustavima neizravne logike.

U slučaju da je predmet promatranja iz rezultata simulacije pojedini čvor, koji iz nekog razloga može biti od povećanog značaja, tada su na apscisi smješteni satni intervali promatranog budućeg razdoblja, a na ordinati snage koje će u tim satima trebati biti dodatno angažirane. Takav prikaz može biti zanimljiv proizvođaču električne energije u promatranom čvoru jer se na taj način dobiva potpuna informacija o potrebnim angažmanima proizvodne jedinice.

6.3.1. Rezultati za ispitni sustav od 30 čvorova

Ispitni sustav od 30 čvorova posjeduje 20 potrošača prosječne snage od 6,3 MW, najveće snage od 30 MW u osmom čvoru i najmanje snage od 2,2 MW u dvadesetom čvoru, uz ukupnu snagu potrošača od 189,2 MW. Čvorovi 1, 2, 13, 22, 23 i 27 u kojima se nalazi šest zadanih elektrana koje u potpunosti zadovoljavaju potrebe potrošača i tehničkih gubitaka nisu čvorovi u kojima se razmatra integracija hibridne distribuirane proizvodnje. Pri početnim uvjetima ukupni gubici u promatranom ispitnom sustavu za promatrano vremensko razdoblje iznose 58,65 MWh.

Za ispitni sustav od 30 čvorova proveden je veći broj optimizacijskih postupaka s različitim postavkama i ograničenjima hibridne metode s ciljem analize učinka i upotrebljivosti različitih pristupa optimizacijskom procesu. U prvom optimizacijskom postupku modelira se 30 čestica hibridne distribuirane proizvodnje sa ograničenjem snage prema izrazu (6-1). U drugom optimizacijskom procesu uvažavaju se ista ograničenja snage, ali je broj čestica povećan na 60. Trećim optimizacijskim postupkom modelirano je 60 čestica hibridne distribuirane proizvodnje uz povećano gornje ograničenje radne snage sinkronog generatora na 10 MW. Očekivano, povećanjem broj čestica povećava se preciznost predloženih rješenja, ali i utječe na vrijeme izvođenja hibridne optimizacijske metode. Vrijeme izvođenja hibridne optimizacijske metode svakako ovisi o računalnoj snazi koja podupire optimizacijski postupak te nije predmetno kritički



se odnositi na vrijeme izvođenje, već je dovoljno znakovito iznijeti pokazatelje učinkovitosti optimizacijskog postupka hibridnom metodom temeljenoj na metodi roja čestica.

Uz modeliranih 30 čestica raspoložive snage dodatne upravljive distribuirane proizvodnje prema izrazu (6-1), jednakih koeficijenata uvažavanja individualnog i grupnog iskustva te intervalom težinskog koeficijenta izraza (5-10) prema izrazu (6-2), vrijeme izvođenja hibridne metode za planiranje optimalnog pogona je 131 sekunda. Vrijeme je različito od vremena prikazanog u potpoglavlju 6.2. zbog drugačijeg programske okoline i pokrenutih aplikacija u *Windows* okruženju, što je rezultiralo nešto manjom procesorskom snagom raspoloživom za programsko okruženje *MATLAB*.

$$0 \leq p_g(t) \leq 5 \quad \forall t \in \mathcal{T} \quad (6-1)$$


$$w_{min} = 0,4 \quad \& \quad w_{max} = 0,9 \quad (6-2)$$

Izvod iz *Profiler* grafičkog sučelja programskog okruženja *MATLAB* prikazan je slikom 6.4. sa koje ja razvidno kako najzahtjevniji postupak prilikom optimizacijskog procesa predstavlja *hibridizirani* proračun tokova snaga koji se izvodi za svaku česticu. Od ukupnog vremena potrebnog za optimizacijski proces, čak 85 % vremena izvodi se proračun tokova snaga.

Function Name	Calls	Total Time	Self Time*	Total Time Plot (dark band = self time)
ZP1	1	131.054 s	17.481 s	
runpf	14880	112.477 s	12.482 s	

Slika 6.4. Izvod iz *Profiler* grafičkog sučelja programskog okruženja *MATLAB*

Prikaz svih 30 čvorova promatranog elektroenergetskog sustava sa pripadajućim potrebama dodatno angažiranih snaga upravljive distribuirane proizvodnje za svaki sat promatranog budućeg razdoblja od jednog dana i za slučaj u kojem u svakom raspoloživom čvoru postoji sunčana elektrana čija je proizvodnja određena tablicom 5.1., prikazan je slikom 6.5.




Slika 6.5. Rezultati planiranja optimalnog pogona distribuiranih izvora za slučaj ispitnog sustava od 30 čvorova i za razdoblje od 24 sata sa 30 modeliranih čestica

Prema rezultatima optimizacije ispitnog sustava od 30 čvorova, uz pristup sa 30 modeliranih čestica i ograničenje snage prema izrazu (6-1), u svakom je satu potrebno angažirati dodatnih 22,03 MW snage upravljive distribuirane proizvodnje, odnosno za razdoblje cjelokupnog dana potrebno je planirati dodatni angažman distribuirane proizvodnje u iznosu od 528,75 MWh.

Najveća dodatna ukupno angažirana snaga distribuirane proizvodnje u ispitnom sustavu od 30 čvorova, uz određenu najveću moguću snagu prema izrazu (6-1), je između 00 sati i 01 sata kada iznosi 36,54 MW. Najmanja dodatno angažirana snaga distribuirane proizvodnje u promatranom sustavu je između 17 i 18 sati te iznosi 7,18 MW. Dodatna angažirana snaga se, prema rezultatima, raspoređuje na prosječno 6 čvorova ispitnog sustava, pri čemu najveći broj čvorova u kojima se angažira dodatna snaga iznosi 8 za vremenska razdoblje između 00 sati i 01 sata te između 20 sati i 21 sata.

Gubici radne snage nakon optimizacijskog procesa uz uvažavanje dodatnog pogona upravljivih distribuiranih izvora i proizvodnje sunčanih elektrana prikazani su slikom 6.6. i prosječno po intervalu iznose 1,45 MW. Najmanja vrijednost snage gubitaka je između 20 sati i 21 sat i u tom slučaju tehnički gubici radne snage iznose 1,1347 MW. Najveća vrijednost snage gubitaka razvidna je u intervalu između 19 sati i 20 sati kada iznosi 1,92 MW.




Slika 6.6. Gubici u ispitnom sustavu od 30 čvorova za promatrani naredni period uz optimizaciju sa 30 modeliranih čestica

U razdoblju između 10 sati i 16 sati potrošači se ponajviše opskrbljuju krajnjom proizvodnjom u pripadajućem čvoru, a potrebe za lokalnom distribuiranom proizvodnjom su najmanje te su time gubici najmanji. U razdobljima bez proizvodnje sunčanih elektrana aktivna je isključivo upravljiva distribuirana proizvodnja koju je moguće preciznije optimirati te su gubici i tada manji. Pojmovi krajnje i lokalne proizvodnje pojašnjeni su u potpoglavlju 2.1.


Ukupni gubici za naredno razdoblje od 24 sata nakon optimizacijskog procesa iznosi 34,99 MWh, dok su za isto promatrano razdoblje pri početnim uvjetima promatranog sustava bez distribuirane proizvodnje ukupni gubici bili 58,65 MWh. Razlog tolike vrijednosti gubitaka može biti u posebnosti izvedbe hibridne optimizacijske metode zasnovane na inteligenciji roja čestica i načelu *elitizma* preuzetog iz genetskog algoritma. O razlozima za pojavu skokovitih promjena gubitaka poput onih između 7 sati i 8 sati te gubitaka između 19 sati i 20 sati iznosi se više u sedmom poglavlju.

Ukoliko se broj modeliranih čestica udvostruči i postavi na 60, uz sve ostale parametre optimizacijskog procesa identične kao u prethodnom slučaju očituje se povećanje preciznosti pri ispunjenju cilja optimizacijskog postupka. Ukupni gubici radne snage za promatrano vremensko razdoblje u ovom slučaju iznose 30,91 MW, što predstavlja dodatno smanjenje gubitaka radne snage od 11,25 % u odnosu na prethodni slučaj. Prema slici 6.7., najmanja snaga gubitaka radne snage iznosi 0,998 MW u vremenskom razdoblju između 4 i 5 sati ujutro. Prema istoj slici, najveća snaga gubitaka iznosi 1,88 MW u periodu između 6 sati i 7 sati ujutro.



Slika 6.7. Gubici u ispitnom sustavu od 30 čvorova za promatrani naredni period uz optimizaciju sa 60 modeliranih čestica

Modeliranjem većeg broja čestica optimizacijski postupak odredio je veće snage upravljive distribuirane proizvodnje pa je tako ukupna snaga proizvodnje za promatrani period od jednog dana 564 MW, a prosječna dodatno angažirana snaga distribuirane proizvodnje u svakom satu iznosi 23,52 MW te je raspoređena na prosječno sedam čvorova. Najviše čvorova u kojima se angažira dodatna distribuirana proizvodnja je između 7 sati i 8 sati ujutro kada se dodatni kapaciteti u iznosu od 18,98 MW raspoređuju na 10 čvorova. U 10 sati ujutro najmanji je broj čvorova u kojima su raspoređeni dodatni kapaciteti pa je tako snaga u iznosu od 13,57 MW raspoređena u 4 čvora. Ukupni rezultati optimizacijskog procesa sa 60 modeliranih čestica i uz najveću snagu distribuirane proizvodnje prema izrazu (6-1), za sve čvorove promatranog ispitnog elektroenergetskog sustava i za svaki sat promatranog perioda prikazani su slikom 6.8. Prosječna snaga dodatno angažirane upravljive distribuirane proizvodnje iznosi 3,23 MW, dok je najveća snaga 4,99 MW, odnosno postignuto je gornje ograničene snage distribuirane proizvodnje.




Slika 6.8. Rezultati planiranja optimalnog pogona distribuiranih izvora za slučaj ispitnog sustava od 30 čvorova i za razdoblje od 24 sata sa 60 modeliranih čestica

Postupkom optimizacije određenim na ovakav način prednost je dana krajnjoj distribuiranoj proizvodnji, a zbog specifične topologije ispitnog elektroenergetskog sustava i definiranih omeđenja i ograničenja optimizacijskog postupka postignuto smanjenje gubitaka ne predstavlja značajnu razliku u odnosu na prethodni slučaj. Vrijeme izvođenja optimizacijskog postupka sa snagom distribuirane proizvodnje ograničenom prema izrazu (6-1) i sa 60 modeliranih čestica iznosi 379,02 sekundi ili šest i pol minuta što ukazuje kako je hibridna optimizacijska metoda upotrebljiva za integraciju u algoritam kratkoročnog planiranja pogona distribuiranih izvora. Povećana preciznost u određivanju snage dodatno angažirane upravljive distribuirane proizvodnje nastala kao rezultat povećanog broja čestica opravdava dulje vrijeme izvođenja optimizacijskog postupka.

Konačno, povećanjem broja čestica na 60 i gornje granice snage upravljive distribuirane proizvodnje na 10 MW, postupak hibridne optimizacijske metode se izvodi 358,74 sekundi, odnosno nešto manje od 6 minuta. Uz povećanjem najveće moguće snage distribuirane proizvodnje potrebno je optimizacijskom postupku i povećati omeđenje definirano odnosom snage potrošača i snage hibridne distribuirane proizvodnje u nekom čvoru.

Ovakvim pristupom povećana je važnost lokalne proizvodnje, česticama je prošireno područje pretrage i više se uvažavaju utjecaji dodatnog angažmana upravljive distribuirane proizvodnje na šire područje, odnosno na više susjednih čvorova. Rezultati optimizacije sa dvostruko većim brojem čestica precizniji su od rezultata sa manjim brojem čestica uz održivu upotrebljivost predložene hibridne optimizacijske metode za primjenu u algoritmu kratkoročnog planiranja pogona distribuiranih izvora. Povećana preciznost očituje se većim smanjenjem gubitaka te za promatrano razdoblje ukupna snaga tehničkih gubitaka radne snage iznosi 26,15 MW te je u odnosu na rezultat prve optimizacije sa 30 čestica manja za 25 %. Ukupni gubici radne snage po promatranim vremenskim intervalima za naredni period od 24 sata prikazani su slikom 6.9.




Slika 6.9. Gubici u ispitnom sustavu od 30 čvorova za promatrani naredni period uz optimizaciju sa 60 modeliranih čestica i povećanom snagom distribuirane proizvodnje

Prosječna snaga gubitaka u ovom slučaju iznosi 1,08 MW, uz najmanju vrijednost između 4 sata i 5 sati ujutro, kada iznosi 0,9496 MW. Gubici između 12 sati i 13 sati, usporedivi sa gubicima iz prvog slučaja, iznose 1,0179 MWh.

Dodatno smanjenje gubitaka rezultat je povećane ukupne snage distribuirane proizvodnje, a slikom 6.10. prikazani su rezultati optimizacijskog procesa sa 60 modeliranih čestica, za sve čvorove promatranog elektroenergetskog sustava i za svaki sat promatranog perioda. Prilikom modeliranja 60 čestica i uz najveću moguću snagu dodatne upravljive distribuirane proizvodnje od 10 MW, prosječna dodatna angažirana snaga u promatranom testnom sustavu od 30 čvorova iznosi od 47,91 MW ili gotovo trećinu ukupne potrošnje.

Prosječna dodatno angažirana snaga u promatranom razdoblju je generalno raspoređena na 9 dodatnih čvorova, od 24 raspoloživa čvora, iz čega je moguće zaključiti kako je prosječna dodatno angažirana snaga po čvoru 5,32 MW.



Slika 6.10. Rezultati planiranja optimalnog pogona distribuiranih izvora za slučaj ispitnog sustava od 30 čvorova i za razdoblje od 24 sata sa 60 modeliranih čestica i uz povećanu snagu distribuirane proizvodnje

Povećanje snage distribuirane proizvodnje čak četiri puta koje rezultira smanjenjem gubitaka od 25 % u odnosu na prvi promatrani slučaj zasigurno nije ekonomski isplativo unutar okvira analize iz potpoglavlja 5.3. Međutim, potrebno je naglasiti kako su početni uvjeti promatranog ispitnog sustava iznimno zahtjevni sa gledišta rješavanja problema jer početni gubici prilikom opskrbe 29 potrošača ukupne snage 189,20 MW iznose tek 2,4438 MW ili manje od 1,5 %.

Dodatno, omeđenje optimizacijskog postupka ukupnom snagom hibridne distribuirane proizvodnje u promatranom ispitnom sustavu predstavlja značajnu prepreku jer je najmanja snaga potrošača čak deset puta manja od snage najvećeg potrošača te je time otežano određivanje snage

kojom se ograničava hibridni sustav distribuirane proizvodnje. Srednja snaga potrošača od 6,30 MW gotovo je pet puta veća od najmanje snaga potrošača te se ni ona ne može uzeti kao mjerodavna prilikom optimizacije ispitnog sustava od 30 čvorova.

Obzirom da ispitni sustav od 30 čvorova pri početnim uvjetima ne upućuje na probleme tehničkih gubitaka radne snage i uvažavajući rezultate prethodno opisanih optimizacijskih postupaka, moguće je donijeti potvrdnu ocjenu o upotrebljivosti hibridne optimizacijske metode. Promjenom broja čestica i ograničenja optimizacijskom procesa pristupilo se stanovitoj analizi osjetljivosti parametra optimizacije i utjecaju na ukupne rezultate. Od parametara optimizacije moguće je dodatno mijenjati koeficijente uvažavanja individualnog iskustva i iskustva roja, no kako je pokazano u potpoglavlju 4.5.1., najbolje vladanje postiže se ujednačenim koeficijentima kao što je predstavljeno u znanstvenom radu [62].

Na temelju izloženih razmatranja moguće je zaključiti kako se predložena metoda uspješno primjenjuje u svim pokazanim pristupima optimizacijskom procesu, a prilikom optimizacije realnih distributivnih mreža urbanih ili ruralnih sredina, u kojoj su snage potrošača približno međusobno ujednačene i nema velikih međusobnih razlika u snazi kao u ispitnom sustavu od 30 čvorova, predložena metoda koristila bi se u punoj mogućnosti.

Uvažavajući navedene pretpostavke o primjenjivosti predložene hibridne optimizacijske metode, sljedeći ispitni sustav je izmijenjen kako je pokazano u nastavku, a primjenom optimizacijske metode na trećem ispitnom radijalnom *IEEE* sustavu pokazuje se mogućnosti optimizacijske metode u punom opsegu.

6.3.2. Rezultati za *IEEE* ispitni sustav od 57 čvorova

IEEE ispitni sustav od 57 čvorova u zadanim parametrima posjeduje 41 potrošača prosječne snage od 29,78 MW, najveće snage od 377 MW u dvanaestom čvoru i najmanje snage od 1,6 MW u trideset i drugom čvoru, uz ukupnu snagu potrošača od 1250,8 MW. Čvorovi 1, 2, 3, 6, 8, 9 i 12 u kojima se nalazi šest zadanih elektrana koje u potpunosti zadovoljavaju potrebe potrošača i tehničkih gubitaka nisu čvorovi u kojima se razmatra integracija hibridne distribuirane proizvodnje, niti dodatni angažman upravljivog sinkronog generatora. Pri početnim uvjetima ukupni tehnički gubici u promatranom ispitnom sustavu za promatrano vremensko razdoblje od 24 sata iznose 1466,40 MWh, odnosno snaga gubitaka je 61,10 MW u svakom periodu.

Kako električne veličine zadanog *IEEE* ispitnog sustava jednako odskakuju od međusobnih vrijednosti kao što je to slučaj kod ispitnog sustava od 30 čvorova, moguće je zaključiti kako će

vladanje optimizacijske metode rezultirati jednako ocjenom primjenjivosti kao u prethodnom slučaju. Potvrdu primjenjivosti i učinkovitosti metode na sustavima sa ujednačenijim snagama potrošača, što je bliže realnim gradskim ili ruralnim elektroenergetskim mrežama, moguće je izvesti izmjenom snaga potrošača *IEEE* ispitnog sustava od 57 čvorova prema tablici 6.8. i postupkom optimizacije takvim parametrima elektroenergetske mreže.

Tablica 6.8. Podaci o čvorovima i potrošačima modificiranog *IEEE* ispitnog sustava od 57 čvorova


Broj čvora	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Tip čvora	<i>ref.</i>	<i>P-V</i>	<i>P-V</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-V</i>	<i>P-Q</i>	<i>P-V</i>	<i>P-V</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-V</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>
P_p [MW]	8	10	7	9	8	10	8	7	9	6	0	8	10	7	9
Q_p [MVar]	2	4	3	1	2	2	0	2	4	2	0	2	3	3	2
Broj čvora	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Tip čvora	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>
P_p [MW]	8	10	6	8	7	0	0	9	0	6	0	9	6	10	6
Q_p [MVar]	3	2	2	4	1	0	0	2	0	2	0	2	2	2	1
Broj čvora	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
Tip čvora	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>
P_p [MW]	8	6	8	0	10	0	0	10	0	0	8	7	6	10	0
Q_p [MVar]	2	2	1	0	3	0	0	3	0	0	3	2	1	1	0
Broj čvora	46	47	48	49	50	51	52	53	54	55	56	57			
Tip čvora	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>	<i>P-Q</i>			
P_p [MW]	0	12	0	12	12	12	6	10	6	6	7	7			
Q_p [MVar]	0	1,60	0	2,50	1,50	3	2	1	1	2	2	2			

Na ovaj način modificiran *IEEE* ispitni sustav od 57 čvorova sadrži isti broj potrošača, ali su ukupna snaga potrošača u ovom slučaju 364 MW, prosječna snaga potrošača je 8,27 MW, najmanja snaga potrošača je 6 MW, a najveća snaga potrošača je dvostruko veća od najmanje i iznosi 12 MW. Ukupna snaga gubitaka u razdoblju od 24 sata u ovom ispitnom sustavu iznosi 439,25 MW ili 18,30 MW u svakom pojedinom periodu. Gubici snage od 18,30 MW u usporedbi sa snagom potrošača od 364 MW čine 5% radne snage u sustavu.

Za modeliranih 57 čestica vrijeme izvođenja optimizacijske metode je 435,15 sekundi, odnosno sedam i pol minuta. Ukupna snaga gubitaka za razdoblje od 24 sata, nakon postupka optimizacije, iznosi 201,06 MW, što podrazumijeva prosječnu snagu gubitaka u svakom satu od 8,37 MW. Smanjenje gubitaka za čak 55% ukazuje na visoku razinu učinkovitosti optimizacijske metode prilikom optimizacije elektroenergetskog sustava koji posjeduje ujednačenije snage


potrošača bez iznimno visokih odstupanja između pojedinih snaga. Smanjenje gubitaka postiglo se dodatnim angažmanom upravljive distribuirane proizvodnje u prosječno 13 čvorova ispitnog elektroenergetskog sustava. Gornje ograničenje snage distribuirane proizvodnju ovom optimizacijskom postupku iznosi 10 MW.

Dijagram gubitaka po satima za naredno promatrano razdoblje prikazan je slikom 6.11. sa koje je vidljivo kako su najmanji tehnički gubici radne snage, u iznosu od 6,26 MW, u periodu između 13 sati i 14 sati, a najveći gubici radne snage iznosu od 13,30 MW se pojavljuju u periodu između 19 sati i 20 sati.




Slika 6.11. Gubici u ispitnom sustavu od 57 čvorova za promatrani naredni period od 24 sata

Značajno smanjenje tehničkih gubitaka radne snage rezultat je dodatno angažirane snage distribuirane proizvodnje, a slikom 6.12. prikazani su rezultati optimizacijskog procesa sa 57 modeliranih čestica, za sve čvorove promatranog elektroenergetskog sustava od 57 čvorova i za svaki sat promatranog perioda.




Slika 6.12. Rezultati planiranja optimalnog pogona distribuiranih izvora za slučaj ispitnog sustava od 57 čvorova

U uvodu potpoglavlja 6.3. iznesene su dodatne mogućnosti prikaza rezultata optimizacijskog postupka jer su svi podaci nastali optimizacijskim procesom, uključujući i proračunate veličine ispitnog elektroenergetskog sustava, sadržani su u definiranim strukturama *MATLAB* programskog okruženja. Izdvajanjem određenog skupa podataka iz navedenih struktura moguće je dobiti uvid u specifične informacije koje bi mogle biti od interesa. Primjerice, ukoliko na čvoru broj 24 postoji proizvođač električne energije kojeg zanima kakvi su zahtjevi za proizvodnjom električne energije njegove elektrane te iz nekog razloga taj proizvođač želi unaprijed znati kada će i koliku snagu morati angažirati, moguće je pružiti takvu informaciju, prikazanu slikom 6.13.



Slika 6.13. Dodatna potrebna snaga po satima za čvor broj 24

Dodatna mogućnost prikaza rezultata optimizacije je pregled željenog vremenskog razdoblja s ciljem uvida u zahtjeve za dodatnim pogonom upravljive distribuirane proizvodnje cjelokupnog promatranog sustava. Primjerice, ukoliko u dijelu elektroenergetskog sustava postoje distribuirani izvori zasnovani na tehnologijama korištenja obnovljivih izvora energije, postoji realna potreba za uvidom u dodatne angažmane snage u željenom vremenskom razdoblju kako bi se mogle planirati tržišno orijentirane aktivnosti, poput trgovanja kvotom stakleničkog plina CO₂ [353]–[357]. Iz navedenog razloga, slikom 6.14. je moguće prikazati potrebu za dodatnom snagom u odabranom razdoblju, primjerice, između 17 sati i 18 sati, a koja prema slici iznosi 47,82 MW.




Slika 6.14. Dodatno angažirana snaga po čvorovima za odabrano vremensko razdoblje

Ograničenje prema izrazu (5-14) za sve optimizacijske postupke definirano je odnosom donje vrijednosti napona i gornje vrijednosti napona naprama nazivnoj vrijednosti napona razinom $\pm 10\%$, što u konkretnim razmatranjima definira dopuštene naponske razine optimizacijskih postupaka prema izrazu (6-3).

$$|0,9 V_j| \leq |V_j| \leq |1,1 V_j|, \quad \forall j \in i \in h \quad (6-3)$$

Provjera uvjeta naponskih ograničenja optimizacijskog postupka za slučaj optimizacije *IEEE* ispitnog sustava od 57 čvorova prikazana je slikom XXX. Kako su na slici čvorovi slijedno poredani od prvog do zadnjeg, slika predstavlja naponski profil promatranog sustava.




Slika 6.15. Naponski profil *IEEE* ispitnog sustava od 57 čvorova prije i nakon optimizacijskog postupka

6.3.3. Rezultati za radijalni *IEEE* ispitni sustav od 33 čvora

Radijalni *IEEE* ispitni sustav od 33 čvora posjeduje 32 potrošača prosječne snage od 112,58 kW, najveće snage od 420 kW u čvorovima broj 24 i 25, najmanje snage od 45 kW u jedanaestom čvoru te ukupnu snagu potrošača u iznosu od 3715 kW. U prvom čvoru nalazi se elektrana koja u potpunosti zadovoljava potrebe potrošača i tehničkih gubitaka. Prvi čvor nije čvor u kojem se razmatra dodatni angažman upravljive distribuirane proizvodnje. Pri početnim uvjetima ukupan iznos tehničkih gubitaka radne snage iznosi 360,40 kW, ili 9,7 % snage potrošača.


Za 33 modelirane čestice ukupno vrijeme izvođenja optimizacijskog postupka iznosi 156,19 sekundi. Gornje ograničenje radne snage upravljive distribuirane proizvodnje je 500 kW. Najveća trenutna snaga tehničkih gubitaka nakon optimizacije iznosi 160,20 kW, što predstavlja smanjenje od 55,6 %. Dijagram gubitaka po satima za radijalni ispitni sustav od 33 čvora prikazan je slikom

6.16. sa koje je vidljivo kako su najmanji tehnički gubici radne snage, u iznosu od 42,18 kW, u periodu između 13 sati i 14 sati. Najveći gubici radne snage iznosu od 137,41 MW razvidni su u periodu između 17 sati i 18 sati. Pregled rezultata optimizacije promatranog radijalnog sustava od 33 čvora prikazan je slikom 6.17.



Slika 6.16. Gubici nakon optimizacije u radijalnom ispitnom sustavu od 33 čvora za naredni period od 24 sata


Smanjenje gubitaka sa početnih 8649,6 kWh na 1740,71 kWh ukupnih dnevnih gubitaka nakon optimizacije postiglo se planiranjem pogona distribuirane proizvodnje u prosječno 6 čvorova ispitnog elektroenergetskog sustava.



Slika 6.17. Rezultati optimizacije radijalnog *IEEE* ispitnog sustava od 33 čvora

Smanjenje gubitaka sa početnih 8649,6 kWh na 1740,71 kWh koliko iznose ukupni dnevni gubici nakon optimizacije, postiglo se dodatnim angažmanom upravljive distribuirane proizvodnje u prosječno 6 čvorova ispitnog elektroenergetskog sustava. Ponovljena visoka učinkovitost optimizacijskog postupka dodatno potvrđuje primjenjivost predložene hibridne optimizacijske metode u algoritmu kratkoročnog planiranja pogona distribuiranih izvora.


Na slici 6.17. vidljivo je kako je u čvoru broj 33 dodatnu snagu potrebno angažirati kroz cijeli dan, što je razumljivo s obzirom na topologiju radijalnog ispitnog sustava od 33 čvora, prikazanu slikom 6.3. u potpoglavlju 6.1.3. Planirani dodatni angažman upravljive distribuirane proizvodnje za čvor broj 33 prikazan je slikom 6.18.



Slika 6.18. Dodatna potrebna snaga po satima za čvor broj 33 radijalnog ispitnog sustava od 33 čvora


Osim čvora broj 33 u kojem se dodatna snaga upravljive distribuirane proizvodnje angažira u svakom satu promatranog narednog razdoblja od jednog dana, rezultati optimizacije ukazuju kako je dodatnu snagu potrebno angažirati i u čvoru broj 18 u razdoblju od 18 sati tijekom narednog dana. U vremenskom razdoblju između 12 i 13 sati potrebno je dodatno angažirati snagu u ukupnom iznosu od 3,71 MW i to u čvorovima kako je prikazano slikom 6.19. Kako gubici u istom vremenskom razdoblju iznose 42,54 kW, zbroj gubitaka radne snage i snage potrošača iznosi 3,75 MW što je vrlo blisku uvjetu zadanom izrazom (5-13).

Promjenom gornjeg ograničenja distribuirane proizvodnje na 1 MW i povećanjem broja čestica na 66 vrijeme izvođenja optimizacijskog postupka iznosi 267,44 sekundi ili nešto manje od pet minuta, a trenutna najveća snaga tehničkih gubitaka nakon ponovljene optimizacije pod ovim uvjetima iznosi 137,15 kW.



Slika 6.19. Dodatno angažirana snaga za razdoblje između 12 i 13 sati za radijalni ispitni sustav od 33 čvora


Smanjenje gubitaka sa 1740,71 kWh iz prve optimizacije, na 1276,10 kWh koliko ukupni dnevni gubici iznose u drugoj optimizaciji, predstavljaju dodatno smanjenje tehničkih gubitaka radne snage za 26,7 %, što je za promatrano razdoblje od 24 sata prikazano slikom 6.20.



Slika 6.20. Gubici nakon druge optimizacije u radijalnom ispitnom sustavu od 33 čvora za naredni period od 24 sata

Najmanji gubici postignuti su u razdoblju između 6 sati i 7 sati ujutro, kada iznose 32,58 kW. Srednja vrijednost snage gubitaka za promatrana 24 razdoblja iznosi 53,17 kW.


Postignuto smanjenje ukupnih tehničkih gubitaka radne snage i dalje se postiže dodatnim angažmanom upravljive distribuirane proizvodnje 6 čvorova ispitnog elektroenergetskog sustava. Pregled svih čvorova promatranog radijalnog sustava od 33 čvora sa rezultatima druge optimizacije prikazan je slikom 6.21.



Slika 6.21. Rezultati drugog postupka planiranja optimalnog pogona distribuiranih izvora za slučaj radijalnog ispitnog sustava od 33 čvora

Čvor broj 33 i dalje je čvor u kojem se dodatna snaga najčešće angažira, a prema rezultatima optimizacije angažira se snaga koja je gotovo jednaka ukupnoj snazi odcjeka kojem pripada i navedeni čvor. Naime, u 23 perioda od naredna 24 sata u čvoru broj 33 potrebno je angažirati dodatnu radnu snagu upravljive distribuirane proizvodnje u iznosu od 927,74 kW. Za razliku od prethodnog slučaja, uvjet iz izraza (5-13) je ispunjen nakon druge optimizacije, za razdoblje između 13 sati i 14 sati. U navedenom razdoblju tehnički gubici radne snage iznose 31,71 kW, a ukupna proizvodnja hibridnih izvora iznosi 3,83 MW. Uz snagu potrošača od 3,71 MW, moguće je zaključiti kako su zahtjevi potrošača u promatranom razdoblju, pri navedenim pogonskim uvjetima, u potpunosti osigurani lokalnom i krajnjom distribuiranom proizvodnjom.

Planirani pogon distribuiranih izvora za razdoblje između 13 sati i 14 sati, prema rezultatima druge optimizacije, prikazan je slikom 6.22.




Slika 6.22. Dodatno angažirana snaga za razdoblje između 13 i 14 sati za radijalni ispitni sustav od 33 čvora prema rezultatima druge optimizacije

Rezultati druge optimizacije ukazuju na visoki stupanj primjenjivosti predložene optimizacijske metode. Naime, ponovljenim optimizacijskim postupcima za iste uvjete optimizacijskog procesa dobiveni su iznimno bliski rezultati što ukazuje na sljedivost predložene metode.

Promatranjem naponskih razina po čvorovima provjerava se ispunjenje kriterija ograničenja optimizacije. Radijalni ispitni sustav izvrstan je primjer utjecaja distribuirane proizvodnje na uravnoteženje naponskih razina po čvorovima.

Iznosi napona za radijalni *IEEE* ispitni sustav od 33 čvora prikazani su slikom XXX, za slučajeve sa 33 modelirane čestice i sa 66 modeliranih čestica hibridne distribuirane proizvodnje. Naponske razine zadane su po jedinici (p.u), a slijednim prikazom svih čvorova pružen je prikaz naponskog profila izvoda.



Slika 6.23. Naponski profil radijalnog IEEE ispitnog sustava prije i nakon postupaka optimizacije

6.4. Rasuđivanje o rješenjima

Rasuđivanje o pogonskim uvjetima za prvi optimizacijski postupak na radijalnom IEEE ispitnom sustavu od 33 čvora izvodi se usporedbom ulaznih podataka o smanjenju gubitaka radne snage pretvorenih u financijsku uštedu prema podacima iz potpoglavlja 5.3. sa podacima o troškovima planiranog pogona distribuirane proizvodnje, također prema podacima iz istog potpoglavlja. Za potrebe ispitivanja vladanja sustava rasuđivanja modeliranog sustavom neizrazite logike potrebno je u radnom prostoru (engl. *Workspace*) programskog okruženja *MATLAB* stvoriti strukturu koja sadržava modelirani sustav rasuđivanja korištenjem naredbenog retka *readfis*. Pripremljene podatke o koeficijentima gubitaka i koeficijentima proizvodnje distribuiranih izvora je potrebno pohraniti u matricu dimenzija $h \times k$, gdje je h broj razmatranih vremenskih razdoblja, u ovom slučaju je to naredna 24 sata, a k je broj ulaznih veličina sustava rasuđivanja. Matrica koeficijenata stoga posjeduje dimenzije 24×2 .

Dimenzija k ulazne matrice koeficijenata sadrži dva koeficijenta koja se obrađuju kriterijima pripadnosti prema izrazima (5-19) i (5-20), a priprema koeficijenata uslijed nejake sprege hibridizacije odvija se zasebnom procedurom prema izrazima (6-4) i (6-5) u kojima k_G predstavlja koeficijent gubitaka nakon integracije distribuirane proizvodnje, a k_{DG} predstavlja koeficijent troška proizvodnje električne energije prema rezultatima optimizacije.

$$k_G = \frac{|P_{Loss,DG,h}|}{|P_{Loss,h}|} \quad (6-4)$$

$$k_{DG} = \frac{|\mathfrak{I}_{Loss,h}|}{|\mathfrak{I}_{DG,h}|} \quad (6-5)$$


U izrazu (6-5) uvela su se dva nova parametra troška označena pisanim slovom T i to zasebno za trošak gubitaka i trošak proizvodnje električne energije iz distribuiranih izvora. Novi parametri definirani su izrazima (6-6) i (6-7) u kojima $P_{DG,h}$ predstavlja snagu distribuirane proizvodnje u tom satu, odnosno iteraciji h , c_{DG} predstavlja cijenu proizvodnje električne energije prikazanu u potpoglavlju 5.3, $P_{Loss,DG,h}$ podrazumijeva gubitke nakon integracije distribuirane proizvodnje, $P_{Loss,h}$ predstavlja gubitke u promatranoj mreži bez distribuirane proizvodnje, a c_{Loss} je cijena električne energije po tarifi za kućanstva prikazana u potpoglavlju 5.3.

$$\mathfrak{I}_{DG} = P_{DG,h} \times c_{DG} \quad (6-6)$$

$$\mathfrak{I}_{Loss} = (P_{Loss,DG,h} - P_{Loss,h}) \times c_{Loss} \quad (6-7)$$

Izrazima (6-4) - (6-7) troškovi proizvodnje električne energije iz distribuiranih izvora promatraju se kroz troškovne uštede uslijed manje neisporučene električne energije krajnjim kupcima. Takvim pristupom očekivano je kako će sustav rasuđivanja donositi visoke ocjene za one pogonske slučajeve pri kojima je proizvodnja distribuiranih izvora troškovno opravdana. Kako je za ovakvu modelsku primjenu iznimno složeno obuhvatiti sve komparativne prednosti korištenja distribuirane proizvodnje, koeficijentom povećanja prihvatljivih rješenja proširio se skup visoko ocjenjenih pogonskih uvjeta.

Obrada koeficijenata pohranjenih u matricu $h \times k$ izvodi se naredbom *evalfis* nad kreiranim skupom podataka, a rezultati obrade ulaznih koeficijenata za prvu optimizaciju radijalnog *IEEE* ispitnog sustava od 33 čvora i za razdoblje od 24 sata prikazani su slikom 6.24.



Slika 6.24. Rezultati sustava rasuđivanja za prvu optimizaciju radijalnog *IEEE* sustava


Za promatranog vremensko razdoblje od 24 sata i prema smanjenju gubitaka prema slici 6.16. te uz planirani pogon distribuirane proizvodnje prema slici 6.17., moguće je donijeti ocjenu o pogonu promatranog ispitnog sustava pretvorbom brojevanih vrijednosti u lingvističke. Prema modeliranim parametrima sustava rasuđivanja, temeljenog na sustavu neizrazite logike, opisanog potpoglavljem 5.3, tablicom 6.9. prikazani su rezultati ocjene pogona pretvoreni u lingvističke vrijednosti. U tablici 6.9., oznaka *V* podrazumijeva lingvističku vrijednost *Velikih* pogonskih troškova, oznaka *M* podrazumijeva lingvističku vrijednost *Malih* pogonskih troškova, a oznaka *P* predstavlja lingvističku vrijednost *Prihvatljivih* pogonskih troškova.

Tablica 6.9. Lingvističke vrijednosti rezultata rasuđivanja za prvu optimizaciju radijalnog *IEEE* ispitnog sustava od 33 čvora

Sati [h]	1	2	3	4	5	6	7	8	9	10	11	12
Ocjena:	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>M</i>	<i>P</i>	<i>P</i>	<i>P</i>	<i>V</i>	<i>V</i>
Sati [h]	13	14	15	16	17	18	19	20	21	22	23	24
Ocjena:	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>P</i>	<i>M</i>	<i>M</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>

Prema rezultatima rasuđivanja nastalim na temelju troškovnih pokazatelja iz potpoglavlja 5.3. u samo 7 promatranih razdoblja planirani pogon distribuirane proizvodnje je troškovno opravdan uzme li se obzir usporedba troškova gubitaka neisporučene radne snage sa troškovima proizvodnje električne energije. U svim preostalim satnim razdobljima troškovi pogona distribuiranih izvora veći su od troškova koji bi nastali gubitkom radne snage u sustavu. Ovakav zaključak o pogonu distribuiranih izvora valja uzeti vrlo kritično jer se u ovom slučaju ipak radi o demonstracijskom primjeru uporabe sustava rasuđivanja temeljenog na sustavu neizrazite logike. U zadanim okvirima rasuđivanja, a koji prema financijskim pokazateljima svakako ne idu u prilog distribuiranoj proizvodnji, modelirani sustav rasuđivanja rezultira sljedećim i ispravnim rezultatima. U stvarnoj primjeni, ulazne podatke je potrebno svesti na stvarne troškove pogona pojedinih tehnologija distribuiranih izvora, umjesto na cijenu električne energije preuzetu iz literature [332], [333].

Za drugu optimizaciju radijalnog *IEEE* ispitnog sustava od 33 čvora rezultati rasuđivanja o optimizacijskim rješenjima su prikazani na slici 6.25.



Slika 6.25. Rezultati sustava rasuđivanja za drugu optimizaciju radijalnog *IEEE* sustava

Rezultate prikazane slikom 6.25. potrebno je prevesti u lingvističke izraze kojima se opisuje ocjena o pogonu promatranom ispitnog sustava. Jednakim postupkom kao u prethodnom slučaju, lingvističke vrijednosti ocjena prikazane su tablicom 6.10.

Tablica 6.10. Lingvističke vrijednosti rezultata rasuđivanja za drugu optimizaciju radijalnog *IEEE* ispitnog sustava od 33 čvora

Sati [h]	1	2	3	4	5	6	7	8	9	10	11	12
Ocjena:	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>M</i>	<i>M</i>	<i>P</i>	<i>P</i>	<i>V</i>	<i>V</i>
Sati [h]	13	14	15	16	17	18	19	20	21	22	23	24
Ocjena:	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>M</i>	<i>M</i>	<i>M</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>	<i>V</i>

U jednakom broju razdoblja su troškovi pogona distribuiranih izvora opravdanim, uz razliku da se radi o većem broju slučajeva u kojima su troškovi pogona *Mali* prema pravilima rasuđivanja. Iz navedenog se može donijeti zaključak kako je rezultat druge optimizacije troškovno opravdaniji jer u manjem broju odgovarajućih razdoblja troškovi pogona distribuiranih izvora dostižu granicu od dvostrukog iznosa troškova gubitaka.

U razdobljima vršne proizvodnje sunčanih elektrana podrazumijeva se i vršna proizvodnja hibridnog distribuiranog izvora te su takva razdoblja, potpuno razumljivo s obzirom na troškovne parametre proizvodnje, označena kao razdoblja *Velikih* troškova pogona.

7. Mogućnosti za buduće istraživanje

U potpoglavlju 4.1 prikazan je kognitivni proces odabira metode računalne inteligencije na čijim načelima se zasniva predložena optimizacijska metoda. Istim potpoglavljem ukazane su prepreke koje sprječavaju korištenje nekih drugih metoda za rješavanje izazova predstavljenih ovom doktorskom disertacijom. Obzirom da potpuna rasprava o nekom izazovu i načinima njegova rješavanja zahtjeva, u najvećoj mjeri, iznimno vrijeme, ovim poglavljem nastoje se smanjiti daljnji napori i učinkovito usmjeriti buduće istraživanje.

Mišljenje autora ove doktorske disertacije je kako predloženi algoritam kratkoročnog planiranja pogona distribuiranih izvora koji sjedinjuje tri postupka računalne inteligencije, među kojima je naglasak na optimizacijskoj metodi planiranja optimalnog pogona temeljnoj na inteligenciji roja čestica, može biti dodatno razvijen i poboljšan u više smjerova.

Prvi smjer podrazumijeva povećanje osjetljivosti optimizacije razvidnu kroz preciznost danih rješenja prilikom promatranja elektroenergetskih sustava sa značajnim razlikama među potrošačima, kao što je ispitni sustav od 30 čvorova. Postojeće djelovanje optimizacijske metode preuzima način odvijanja iz metode inteligencije roja čestica, a ograničenja čestica definirana samom metodom ujedno su i ograničenja elektrana definiranih optimizacijom. Upravljanje brzinama čestica prilikom promjena snage elektrana može biti dodatno nadzirano posebnom metodom računalne inteligencije i primjenom jake sprege hibridizacije. U tom slučaju, optimizacijski proces uzimao bi u obzir snagu svakog pojedinog potrošača u svakom pojedinom čvoru prije nego li bi se definirao željeni interval snage distribuirane proizvodnje, ali u tom slučaju takav interval bi vrijedio isključivo za jedan promatrani čvor sa pripadajućim potrošačem. Drugim riječima, dodatnim ograničenjima snaga distribuirane proizvodnje na razini svakog čvora umjesto na razini promatranog sustava postigla bi se povećana preciznost optimizacijskog postupka.

Dodatnom primjenom računalne inteligencije u potpunoj meta-heuristici, moguće je riješiti i izazov pojave skokovitih gubitaka poput onih između 5 sati i 6 sati te najvećih gubitaka između 18 sati i 19 sati iznosi koji su rezultat posebno izvedene hibridne optimizacijske metode zasnovane na inteligenciji roja čestica i načelu *elitizma* preuzetog iz genetskog algoritma. Naime, kako je pojašnjeno u zaključku potpoglavlja 4.5.1. i prikazano u potpoglavlju 5.2 nakon *izolacije* čestice sa najboljom ocjenom *gbest*, kretanje roja usmjerava se prema sljedećem najboljem prostoru pretrage. U slučaju značajne promjene uvjeta u elektroenergetskoj mreži potrebno je iznova proračunati novo početno stanje sustava te bi u tom slučaju prostor pretrage bio u potpunosti iznova definiran. Osim ponovljene provjere, u slučaju naglih promjena u sustavu, moguće je djelovati na

koeficijente uvažavanja individualnog i grupnog iskustva u svakoj iteraciji i pod-iteraciji za što je potrebno primijeniti dodatnu meta-heuristiku.

Nastavak razvoja predstavljenog algoritma moguće je usmjeriti ka optimizaciji radne i jalove snage distribuirane proizvodnje čime bi uvjet samodostatnosti mreže u potpunosti mogao biti zadovoljen. Obuhvaćanjem pogonske karte generatora uzrokovalo bi dodatno povećanje promatranog broja varijabli optimizacijske metode te bi bilo potrebno, svojevrsno, optimirati optimizacijski postupak. Znanstveni projekti spomenuti u uvodu petog poglavlja izučavaju upravo takvu tematiku te je izvjesno kako će se u budućnosti pojaviti i takva rješenja.

Treća cjelina predloženog algoritma kratkoročnog planiranja pogona distribuiranih izvora, rasuđivanje o rješenjima optimizacije, može biti dodatno proširena složenijim modeliranjem financijskih pokazatelja distribuirane proizvodnje pri čemu treba uvažiti sve prihode ostvarive proizvodnjom električne energije iz obnovljivih izvora energije. Povećanjem razlike u cijeni električne energije za potrošače i cijeni električne energije pri proizvodnji povećati će se udio razdoblja u kojima je troškovno opravdano angažirati snagu distribuirane proizvodnje. Već spomenuto trgovanje kvotom stakleničkog plina CO₂ svakako treba u nastavku znanstveno-istraživačkog rada obuhvatiti prilikom određivanja koeficijenata proizvodnje distribuiranih izvora. Dodatno, umjesto cijene električne energije treba promatrati troškove proizvodnje iz pojedinih tehnologija te uvrštavanjem takvih pokazatelja donositi ocjenu o planiranom pogonu aktivne elektroenergetske mreže.

Konačno, vrijeme izvođenja, iako ne presudno, moguće je značajno poboljšati hibridizacijom predložene metode sa drugim proračunskim alatima ili razvojem posebnim metoda računalne inteligencije primjenjivih na radijalne elektroenergetske mreže. Za proračun tehničkih gubitaka radne snage je moguće koristiti umjetne neuronske mreže te time izbjeci zahtjevno korištenje iterativnog postupka proračuna tokova snaga.

8. Zaključak

Integracija distribuirane proizvodnje zahtjeva promjenu postojećih pravila i metoda planiranja pogonskih uvjeta pri čemu je presudno pravilno, precizno i pravovremeno odrediti ukupni utjecaj povećane zastupljenosti distribuiranih izvora u elektroenergetskom sustavu. Temeljna razumna pretpostavka predstavljenog znanstveno-istraživačkog rada je visoka primjenjivost naprednih metoda računalne inteligencije za primjenu u planiranju optimalnog pogona distribuirane proizvodnje u potpuno aktivnoj distributivnoj mreži. Provjera navedene pretpostavke ostvarena je predstavljanjem algoritma kratkoročnog planiranja pogona distribuiranih izvora s ciljem značajnog smanjenja gubitaka, razvojem hibridne metode planiranja temeljene na inteligenciji roja čestica, prijedlogom sustava ocjenjivanja rješenja optimizacije obzirom na ciljeve algoritma te obrazloženju odabira specifičnih metoda računalne inteligencije za primjenu u predstavljenom algoritmu.

Ishod znanstveno-istraživačkog rada ove doktorske disertacije je algoritam kratkoročnog planiranja pogona distribuiranih izvora koji sadrži tri funkcionalne cjeline, međusobno *hibridizirane* različitim razinama sjedinjenja. Prva cjelina predloženog algoritma podrazumijeva predviđanje proizvodnje električne energije iz sunčanih elektrana, a realizirana je modeliranjem umjetne neuronske mreže koja temeljem ulaznih podataka o temperaturi zraka, relativnoj vlažnosti zraka, intenzitetu sunčevog zračenja i brzini vjetra određuje očekivanu snagu sunčane elektrane. Model umjetne neuronske mreže zasniva se na višeslojnom *MADLINE* modelu i razvijen je u programskom okruženju *MATLAB*. Rezultati prve cjeline uvažavaju se u nastavku algoritma kratkoročnog planiranja i predstavljaju dio ulaznih podataka druge cjeline.

Druga cjelina algoritma kratkoročnog planiranja je jedinstveno modelirana hibridna optimizacijska metoda temeljena na inteligenciji roja čestica u koju je integrirano načelo *elitizma* specifično za genetski algoritam. Naime, znanstveno istraživanje doktorske disertacije započelo je primjenom genetskog algoritma s ciljem određivanja optimalnog čvora i snage jedne distribuirane proizvodnje u distributivnoj mreži. Uspješna primjena navedenog algoritma popraćena objavom znanstvenih radova iz rezultata navedenog istraživanja postavila je smjer daljnjeg razvoja i primjene tadašnjih rješenja. Međutim, operatori karakteristični za pravilno izvođenje genetskog algoritma značajno utječu na njegovu primjenu u predloženom algoritmu kratkoročnog planiranja pogona distribuiranih izvora. Proučavanjem znanstvene literature istraživanje je usmjereno ka primjeni optimizacijske metode inteligencije roja čestica u koju je, s ciljem isticanja primjenjivosti u predstavljenom algoritmu, integrirano načelo izolacije najboljih jedinki, specifično za genetski

algoritam. U jedinstvenoj optimizacijskoj metodi *elitne* čestice bivaju izdvojene u repozitorij rješenja te se na taj način kretanje roja prinudno usmjerava u novi prostor pretrage. U predloženu jedinstvenu optimizacijsku metodu u potpunosti su integrirani visokom razinom *hibridizacije* proračunski i modelski postupci simulacijskog paketa *MATPOWER*. Navedeni simulacijski paket se koristi za modeliranje ispitnih elektroenergetskih sustava, proračune tokova snaga Newton-Raphson metodom i preslikavanje parametara čestica optimizacijske metodu u tehničke parametre distribuirane proizvodnje.

Rješenja optimizacijskog postupka predstavljaju visoku razinu primjene distribuirane proizvodnje s ciljem postizanja najvećeg smanjenje tehničkih gubitaka radne snage. Tehnički u potpunosti opravdan, navedeni cilj je dodatno osmotren sa stajališta opravdanosti troškova distribuirane proizvodnje električne energije u usporedbi sa uštedama postignutim smanjenjem tehničkih gubitaka. Navedene provjera realizirana je razvojem treće *hibridizirane* cjeline predloženog algoritma koja podrazumijeva sustav rasuđivanja i donošenja odluke o troškovnoj opravdanosti distribuirane proizvodnje obzirom na učinak smanjenja tehničkih gubitaka radne snage, izveden sustavom neizrazite logike. Lingvistički pojmovi o postignutom smanjenju tehničkih gubitaka radne snage i potrebnoj snazi distribuirane proizvodnje za takvo smanjenje gubitaka pretvoreni su u funkcije pripadnosti sustava neizrazite logike i postavljeni kao ulazni koeficijenti za primjenu pravila odlučivanja. Ocjena prihvatljivosti ponuđenih optimalnih rješenja je brojčana vrijednosti nastala kao rezultat matematičkih postupaka neizrazitih skupova. Konačno, brojčana vrijednosti ocjene pretvorena je u lingvistički pojam kojim se opisuje predloženi pogon distribuiranih izvora.

Predloženi algoritma kratkoročnog planiranja pogona distribuiranih izvora koji obuhvaća jedinstvenu optimizacijsku metodu uspješno je primijenjen za optimizaciju distribuiranih izvora u tri ispitna sustava: ispitnom prstenasto-povezanom sustavu od 30 čvorova, ispitnom *IEEE* prstenasto-povezanom sustavu od 57 čvorova i radijalnom *IEEE* ispitnom sustavu od 33 čvora. Posebnosti tehničkih parametara korištenih ispitnih sustava pokazali su se kao značajan izazov učinkovitoj primjeni predloženog algoritma. Prema rezultatima provedenih optimizacija, predloženi algoritam najveću učinkovitost primjene pokazuje prilikom optimizacije radijalnog *IEEE* sustava od 33 čvora. Potvrda da prstenasto-povezana topologija promatranog sustava ne predstavlja prepreku predloženom algoritmu realizirana je ujednačavanjem snaga potrošača u ispitnom *IEEE* sustavu od 57 čvorova, kada predloženi algoritam ukazuje na visoku učinkovitost primjene. Konačno, uspješnom primjenom potvrđene su temeljne pretpostavke znanstvenog istraživanja.

Literatura

- [1] EU Commission, “European Task Force for the implementation of Smart Grids into the European Internal Market. Mission and Work Programme,” no. June 2011, pp. 1–15, 2012.
- [2] Joint Research Centre - Smart Electricity Systems and Interoperability, “European Smart Grid projects: relationship matrix.” [Online]. Available: <http://ses.jrc.ec.europa.eu/european-smart-grid-projects-relationship-matrix>. [Accessed: 12-Dec-2017].
- [3] F. Gangale, J. Vasiljevska, C. F. Covrig, A. Mengolini, and G. Fulli, “Smart grid projects outlook 2017: facts, figures and trends in Europe,” Luxembourg, 2017.
- [4] G. Pretico, F. Gangale, A. Mengolini, A. Lucas, and G. Fulli, “DISTRIBUTION SYSTEM OPERATORS OBSERVATORY: From European Electricity Distribution Systems to Representative Distribution Networks,” Luxembourg, 2016.
- [5] W. L. Theo, J. S. Lim, W. S. Ho, H. Hashim, and C. T. Lee, “Review of distributed generation (DG) system planning and optimisation techniques: Comparison of numerical and mathematical modelling methods,” *Renewable and Sustainable Energy Reviews*, vol. 67, pp. 531–573, 2017.
- [6] M. Pesaran H.A, P. D. Huy, and V. K. Ramachandaramurthy, “A review of the optimal allocation of distributed generation: Objectives, constraints, methods, and algorithms,” *Renewable and Sustainable Energy Reviews*, no. October, pp. 1–20, 2016.
- [7] S. Ruiz-Romero, A. Colmenar-Santos, F. Mur-Pérez, and Á. López-Rey, “Integration of distributed generation in the power distribution network: The need for smart grid control systems, communication and equipment for a smart city - Use cases,” *Renewable and Sustainable Energy Reviews*, vol. 38, pp. 223–234, 2014.
- [8] A.-M. Borbely, J. F. Kreider, E. Wong, H. Whittall, P. Dailey, and P. S. Curtiss, *Distributed generation : the power paradigm for the new millennium*. CRC Press, Taylor & Francis Group, 2001.
- [9] T. Ackermann, G. Andersson, and L. Söder, “Distributed generation: A definition,” *Electric Power Systems Research*, vol. 57, no. 3, pp. 195–204, 2001.
- [10] Vlada Republike Hrvatske, *Tarifni sustav za proizvodnju električne energije iz obnovljivih*

izvora energije i kogeneracije, no. 133. Zagreb, Croatia: Vlada Republike Hrvatske, 2013.

- [11] R. Viral and D. K. Khatod, "Optimal planning of distributed generation systems in distribution system: A review," *Renewable and Sustainable Energy Reviews*, vol. 16, no. 7, pp. 5146–5165, 2012.
- [12] A. Yadav and L. Srivastava, "Optimal placement of distributed generation: An overview and key issues," *Power Signals Control and ...*, no. January, pp. 8–10, 2014.
- [13] D. Q. Hung, N. Mithulananthan, and K. Y. Lee, "Optimal placement of dispatchable and nondispatchable renewable DG units in distribution networks for minimizing energy loss," *International Journal of Electrical Power and Energy Systems*, vol. 55, pp. 179–186, 2014.
- [14] T. Gözel and M. H. Hocaoglu, "An analytical method for the sizing and siting of distributed generators in radial systems," *Electric Power Systems Research*, vol. 79, no. 6, pp. 912–918, 2009.
- [15] N. Acharya, P. Mahat, and N. Mithulananthan, "An analytical approach for DG allocation in primary distribution network," *International Journal of Electrical Power and Energy Systems*, vol. 28, no. 10, pp. 669–678, 2006.
- [16] S. K. Injeti, N. Prema Kumar, and N. P. Kumar, "A novel approach to identify optimal access point and capacity of multiple DGs in a small, medium and large scale radial distribution systems," *International Journal of Electrical Power and Energy Systems*, vol. 45, no. 1, pp. 142–151, 2013.
- [17] M. R. Alrashidi and M. F. Alhajri, "Optimal planning of multiple distributed generation sources in distribution networks: A new approach," *Energy Conversion and Management*, vol. 52, no. 11, pp. 3301–3308, 2011.
- [18] O. Ipinnimo, S. Chowdhury, S. P. Chowdhury, and J. Mitra, "A review of voltage dip mitigation techniques with distributed generation in electricity networks," *Electric Power Systems Research*, vol. 103, pp. 28–36, 2013.
- [19] M. Bollen and F. Hassan, *Integration of Distributed Generation in the Power System*. IEEE Pres, 2011.
- [20] T. Lv and Q. Ai, "Interactive energy management of networked microgrids-based active distribution system considering large-scale integration of renewable energy resources," *Applied Energy*, vol. 163, pp. 408–422, 2016.

- [21] C. L. T. Borges and V. F. Martins, "Multistage expansion planning for active distribution networks under demand and Distributed Generation uncertainties," *International Journal of Electrical Power and Energy Systems*, vol. 36, no. 1, pp. 107–116, 2012.
- [22] A. A. Bayod-Rújula, "Future development of the electricity systems with distributed generation," *Energy*, vol. 34, no. 3, pp. 377–383, 2009.
- [23] M. A. Eltawil and Z. Zhao, "Grid-connected photovoltaic power systems: Technical and potential problems-A review," *Renewable and Sustainable Energy Reviews*, vol. 14, no. 1, pp. 112–129, 2010.
- [24] P. S. Moura and A. T. de Almeida, "Multi-objective optimization of a mixed renewable system with demand-side management," *Renewable and Sustainable Energy Reviews*, vol. 14, no. 5, pp. 1461–1468, 2010.
- [25] T. Hu, X. Chu, W. Zhang, and Y. Liu, "An optimal day-ahead dispatch strategy for deferrable loads," *POWERCON 2014 - 2014 International Conference on Power System Technology: Towards Green, Efficient and Smart Power System, Proceedings*, no. Powercon, pp. 1785–1790, 2014.
- [26] J. A. P. Lopes, N. Hatziargyriou, J. Mutale, P. Djapic, and N. Jenkins, "Integrating distributed generation into electric power systems: A review of drivers, challenges and opportunities," *Electric Power Systems Research*, vol. 77, no. 9, pp. 1189–1203, 2007.
- [27] A. Rahiminejad, B. Vahidi, M. A. Hejazi, and S. Shahrooyan, "Optimal scheduling of dispatchable distributed generation in smart environment with the aim of energy loss minimization," *Energy*, vol. 116, pp. 190–201, 2016.
- [28] W. Shi, X. Xie, C. C. Chu, and R. Gadh, "Distributed Optimal Energy Management in Microgrids," *IEEE Transactions on Smart Grid*, vol. 6, no. 3, pp. 1137–1146, 2015.
- [29] D. H. Popović, J. A. Greatbanks, M. Begović, and A. Pregelj, "Placement of distributed generators and reclosers for distribution network security and reliability," *International Journal of Electrical Power and Energy Systems*, vol. 27, no. 5–6, pp. 398–408, 2005.
- [30] W. El-Khattam and M. M. A. Salama, "Distributed generation technologies, definitions and benefits," *Electric Power Systems Research*, vol. 71, no. 2, pp. 119–128, 2004.
- [31] W. S. Tan, M. Y. Hassan, M. S. Majid, and H. Abdul Rahman, "Optimal distributed renewable generation planning: A review of different approaches," *Renewable and*

- Sustainable Energy Reviews*, vol. 18, pp. 626–645, 2013.
- [32] K. Sörensen, “Metaheuristics-the metaphor exposed,” *International Transactions in Operational Research*, vol. 22, no. 1, pp. 3–18, 2015.
- [33] K. S. Tang, *Multiobjective Optimization Methodology: a Jumping Gene Approach*. CRC Press, Taylor & Francis Group.
- [34] G. Molnar, “Heuristički i metaheuristički postupci optimizacije.”
- [35] K. Gopalakrishnan, S. K. Khaitan, and S. Kalogirou, *Soft Computing in Green and Renewable Energy Systems*, vol. 269. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011.
- [36] R. Luna-Rubio, M. Trejo-Perea, D. Vargas-Vázquez, and G. J. Ríos-Moreno, “Optimal sizing of renewable hybrids energy systems: A review of methodologies,” *Solar Energy*, vol. 86, no. 4, pp. 1077–1088, 2012.
- [37] L. Rutkowski, *Computational Intelligence Methods and Techniques*. Warszawa: Springer, 2005.
- [38] D. Ashlock, “Evolutionary Computation for Modeling and Optimization.” Dan Ashlock, 2004.
- [39] C. Wang and M. H. H. Nehrir, “Analytical Approaches for Optimal Placement of Distributed Generation Sources in Power Systems,” *IEEE Transactions on Power Systems*, vol. 19, no. 4, pp. 2068–2076, 2004.
- [40] J.-H. Teng and Department, “A Network-Topology-based Three-Phase Load Flow for Distribution Systems,” *Proc. Natl. Sci. Council. ROC(A)*, vol. 24, no. 4, pp. 259–264, 2000.
- [41] M. M. Aman, G. B. Jasmon, H. Mokhlis, and A. H. A. Bakar, “Optimal placement and sizing of a DG based on a new power stability index and line losses,” *International Journal of Electrical Power and Energy Systems*, vol. 43, no. 1, pp. 1296–1304, 2012.
- [42] S. K. Injeti, “A Pareto optimal approach for allocation of distributed generators in radial distribution systems using improved differential search algorithm,” *Journal of Electrical Systems and Information Technology*, 2017.
- [43] R. K. Singh and S. K. Goswami, “Optimum allocation of distributed generations based on nodal pricing for profit, loss reduction, and voltage improvement including voltage rise issue,” *International Journal of Electrical Power and Energy Systems*, vol. 32, no. 6, pp.

- 637–644, 2010.
- [44] P. M. Sotkiewicz and J. M. Vignolo, “Nodal pricing for distribution networks: Efficient pricing for efficiency enhancing DG,” *IEEE Transactions on Power Systems*, vol. 21, no. 2, pp. 1013–1014, 2006.
- [45] A. A. Abou El-Ela, S. M. Allam, and M. M. Shatla, “Maximal optimal benefits of distributed generation using genetic algorithms,” *Electric Power Systems Research*, vol. 80, no. 7, pp. 869–877, 2010.
- [46] S. Biswas, S. K. Goswami, and A. Chatterjee, “Optimum distributed generation placement with voltage sag effect minimization,” *Energy Conversion and Management*, vol. 53, no. 1, pp. 163–174, 2012.
- [47] N. C. Yang and T. H. Chen, “Evaluation of maximum allowable capacity of distributed generations connected to a distribution grid by dual genetic algorithm,” *Energy and Buildings*, vol. 43, no. 11, pp. 3044–3052, 2011.
- [48] Q. H. Wu, Y. J. Cao, and J. Y. Wen, “Optimal reactive power dispatch using an adaptive genetic algorithm,” *International Journal of Electrical Power & Energy Systems*, vol. 20, no. 8, pp. 563–569, 1998.
- [49] P. Subbaraj and P. N. Rajnarayanan, “Optimal reactive power dispatch using self-adaptive real coded genetic algorithm,” *Electric Power Systems Research*, vol. 79, no. 2, pp. 374–381, 2009.
- [50] J. M. López-Lezama, J. Contreras, and A. Padilha-Feltrin, “Location and contract pricing of distributed generation using a genetic algorithm,” *International Journal of Electrical Power & Energy Systems*, vol. 36, no. 1, pp. 117–126, 2012.
- [51] A. M. El-Zonkoly, “Optimal placement of multi-distributed generation units including different load models using particle swarm optimization,” *Swarm and Evolutionary Computation*, vol. 1, no. 1, pp. 50–59, 2011.
- [52] A. El-Zonkoly, “Optimal placement and schedule of multiple grid connected hybrid energy systems,” *International Journal of Electrical Power & Energy Systems*, vol. 61, pp. 239–247, 2014.
- [53] M. Gomez-Gonzalez, A. Lopez, and F. Jurado, “Optimization of distributed generation systems using a new discrete PSO and OPF,” *Electric Power Systems Research*, vol. 84, no.

- 1, pp. 174–180, 2012.
- [54] M. H. Moradi and M. Abedini, “A combination of genetic algorithm and particle swarm optimization for optimal DG location and sizing in distribution systems,” *International Journal of Electrical Power and Energy Systems*, vol. 34, no. 1, pp. 66–74, 2012.
- [55] A. Saif, V. Ravikumar Pandi, H. H. Zeineldin, and S. Kennedy, “Optimal allocation of distributed energy resources through simulation-based optimization,” *Electric Power Systems Research*, vol. 104, pp. 1–8, 2013.
- [56] M. M. Aman, G. B. Jasmon, A. H. A. Bakar, and H. Mokhlis, “A new approach for optimum simultaneous multi-DG distributed generation Units placement and sizing based on maximization of system loadability using HPSO (hybrid particle swarm optimization) algorithm,” *Energy*, vol. 66, pp. 202–215, 2014.
- [57] M. M. Aman, G. B. Jasmon, A. H. A. Bakar, and H. Mokhlis, “A new approach for optimum DG placement and sizing based on voltage stability maximization and minimization of power losses,” *Energy Conversion and Management*, vol. 70, pp. 202–210, Jun. 2013.
- [58] S. Kansal, V. Kumar, and B. Tyagi, “Optimal placement of different type of DG sources in distribution networks,” *International Journal of Electrical Power and Energy Systems*, vol. 53, no. 1, pp. 752–760, 2013.
- [59] T. Niknam, S. I. Taheri, J. Aghaei, S. Tabatabaei, and M. Nayeripour, “A modified honey bee mating optimization algorithm for multiobjective placement of renewable energy resources,” *Applied Energy*, vol. 88, no. 12, pp. 4817–4830, 2011.
- [60] T. Niknam, “An efficient multi-objective HBMO algorithm for distribution feeder reconfiguration,” *Expert Systems with Applications*, vol. 38, no. 3, pp. 2878–2887, Mar. 2011.
- [61] T. Niknam, “An efficient hybrid evolutionary algorithm based on PSO and HBMO algorithms for multi-objective Distribution Feeder Reconfiguration,” *Energy Conversion and Management*, vol. 50, no. 8, pp. 2074–2082, 2009.
- [62] M. S. Kumari, G. Priyanka, and M. Sydulu, “Comparison of Genetic Algorithms and Particle Swarm Optimization for Optimal Power Flow Including FACTS devices,” pp. 1105–1110, 2007.
- [63] P.-Y. Yin, S.-S. Yu, P.-P. Wang, and Y.-T. Wang, “A hybrid particle swarm optimization

- algorithm for optimal task assignment in distributed systems,” *Computer Standards & Interfaces*, vol. 28, no. 4, pp. 441–450, 2006.
- [64] W. Zhang and Y. Liu, “Multi-objective reactive power and voltage control based on fuzzy optimization strategy and fuzzy adaptive particle swarm,” *International Journal of Electrical Power and Energy Systems*, vol. 30, no. 9, pp. 525–532, 2008.
- [65] M. Ashari and A. Soeprijanto, “Optimal Distributed Generation (DG) Allocation for Losses Reduction Using Improved Particle Swarm Optimization (IPSO) Method,” vol. 2, no. 7, pp. 7016–7023, 2012.
- [66] K. Bhumkittipich and W. Phuangpornpitak, “Optimal Placement and Sizing of Distributed Generation for Power Loss Reduction Using Particle Swarm Optimization,” *Energy Procedia*, vol. 34, no. July, pp. 307–317, 2013.
- [67] Y. Zhang, S. Wang, and G. Ji, “A comprehensive survey on particle swarm optimization algorithm and its applications,” vol. 2015, 2014.
- [68] S. M. Moghaddas-Tafreshi, H. A. Zamani, and S. M. Hakimi, “Optimal sizing of distributed resources in micro grid with loss of power supply probability technology by using breeding particle swarm optimization,” *Journal of Renewable and Sustainable Energy*, vol. 3, no. 4, 2011.
- [69] S. Ganguly, N. C. Sahoo, and D. Das, “Multi-objective particle swarm optimization based on fuzzy-Pareto-dominance for possibilistic planning of electrical distribution systems incorporating distributed generation,” *Fuzzy Sets and Systems*, vol. 213, pp. 47–73, 2013.
- [70] A. Colmenar-Santos, C. Reino-Rio, D. Borge-Diez, and E. Collado-Fernández, “Distributed generation: A review of factors that can contribute most to achieve a scenario of DG units embedded in the new distribution networks,” *Renewable and Sustainable Energy Reviews*, vol. 59, pp. 1130–1148, 2016.
- [71] T. Adefarati and R. C. Bansal, “Integration of renewable distributed generators into the distribution system: a review,” *IET Renewable Power Generation*, vol. 10, no. 7, pp. 873–884, Aug. 2016.
- [72] M. Vukobratović, P. Marić, and Ž. Hederić, “Voltage and power losses control using distributed generation and computational intelligence,” *Tehnicki Vjesnik*, vol. 23, no. 4, 2016.

- [73] G. De Tré and S. Zadrozny, *Springer Handbook of Computational Intelligence*. 2015.
- [74] N. Phuangpornpitak and S. Tia, “Opportunities and challenges of integrating renewable energy in smart grid system,” *Energy Procedia*, vol. 34, pp. 282–290, 2013.
- [75] I. Colak, G. Fulli, S. Sagiroglu, M. Yesilbudak, and C. F. Covrig, “Smart grid projects in Europe: Current status, maturity and future scenarios,” *Applied Energy*, vol. 152, pp. 58–70, 2015.
- [76] C. Dunstan, J. Daly, E. Langham, L. Boronyak, and J. Rutovitz, “Institutional Barriers to Intelligent Grid Institutional Barriers to Intelligent Grid,” Project 4, 2011.
- [77] S. Blumsack and A. Fernandez, “Ready or not, here comes the smart grid!,” *Energy*, vol. 37, no. 1, pp. 61–68, 2012.
- [78] M. Wissner, “The Smart Grid – A saucerful of secrets?,” *Applied Energy*, vol. 88, no. 7, pp. 2509–2518, Jul. 2011.
- [79] T. Lambert, P. Gilman, and P. Lilienthal, “Micropower System Modeling with Homer,” in *Integration of Alternative Sources of Energy*, Hoboken, NJ, USA: John Wiley & Sons, Inc., 2006, pp. 379–418.
- [80] E. C. Umeozor and M. Trifkovic, “Operational scheduling of microgrids via parametric programming,” *Applied Energy*, vol. 180, pp. 672–681, 2016.
- [81] T. Niknam, H. Z. Meymand, and M. Nayeripour, “A practical algorithm for optimal operation management of distribution network including fuel cell power plants,” *Renewable Energy*, vol. 35, no. 8, pp. 1696–1714, 2010.
- [82] C. Battistelli and A. J. Conejo, “Optimal management of the automatic generation control service in smart user grids including electric vehicles and distributed resources,” *Electric Power Systems Research*, vol. 111, pp. 22–31, 2014.
- [83] Z. Jun, L. Junfeng, W. Jie, and H. W. Ngan, “A multi-agent solution to energy management in hybrid renewable energy generation system,” *Renewable Energy*, vol. 36, no. 5, pp. 1352–1363, 2011.
- [84] T. Logenthiran, D. Srinivasan, and A. M. Khambadkone, “Multi-agent system for energy resource scheduling of integrated microgrids in a distributed system,” *Electric Power Systems Research*, vol. 81, no. 1, pp. 138–148, 2011.

- [85] W. Gu *et al.*, “Modeling, planning and optimal energy management of combined cooling, heating and power microgrid: A review,” *International Journal of Electrical Power and Energy Systems*, vol. 54, pp. 26–37, 2014.
- [86] A. Mohamed and O. Mohammed, “Real-time energy management scheme for hybrid renewable energy systems in smart grid applications,” *Electric Power Systems Research*, vol. 96, pp. 133–143, 2013.
- [87] D. Q. Hung, N. Mithulananthan, and R. C. Bansal, “Integration of PV and BES units in commercial distribution systems considering energy loss and voltage stability,” *Applied Energy*, vol. 113, pp. 162–170, 2014.
- [88] D. Q. Hung, N. Mithulananthan, and R. C. Bansal, “Analytical strategies for renewable distributed generation integration considering energy loss minimization,” *Applied Energy*, vol. 105, pp. 75–85, 2013.
- [89] D. Q. Hung and N. Mithulananthan, “Loss reduction and loadability enhancement with DG: A dual-index analytical approach,” *Applied Energy*, vol. 115, pp. 233–241, 2014.
- [90] H. Xing, H. Cheng, and Y. Zhang, “Optimal coordination of intermittent distributed generation with probabilistic power flow,” *Journal of Electrical Engineering and Technology*, vol. 10, no. 6, pp. 2211–2220, 2015.
- [91] J. Soares, M. Silva, T. Sousa, Z. Vale, and H. Morais, “Distributed energy resource short-term scheduling using Signaled Particle Swarm Optimization,” *Energy*, vol. 42, no. 1, pp. 466–476, 2012.
- [92] E. Kellerer and F. Steinke, “Scalable Economic Dispatch for Smart Distribution Networks,” *IEEE Transactions on Power Systems*, vol. 30, no. 4, pp. 1739–1746, 2015.
- [93] A. J. Lamadrid *et al.*, “Stochastically optimized, carbon-reducing dispatch of storage, generation, and loads,” *IEEE Transactions on Power Systems*, vol. 30, no. 2, pp. 1064–1075, 2015.
- [94] T. Niknam, H. Z. Meymand, and H. D. Mojarrad, “A practical multi-objective PSO algorithm for optimal operation management of distribution network with regard to fuel cell power plants,” *Renewable Energy*, vol. 36, no. 5, pp. 1529–1544, 2011.
- [95] D. O. Elamine, E. H. Nfaoui, and B. Jaouad, “Multi-agent system based on fuzzy control and prediction using NN for smart microgrid energy management,” in *2015 Intelligent*

Systems and Computer Vision, ISCV 2015, 2015.

- [96] R. Wang, P. Wang, G. Xiao, and S. Gong, “Power demand and supply management in microgrids with uncertainties of renewable energies,” *International Journal of Electrical Power and Energy Systems*, vol. 63, pp. 260–269, 2014.
- [97] A. Zakariazadeh, S. Jadid, and P. Siano, “Smart microgrid energy and reserve scheduling with demand response using stochastic optimization,” *International Journal of Electrical Power and Energy Systems*, vol. 63, pp. 523–533, 2014.
- [98] Z. Sun and X. Zhang, “Advances on Distributed Generation Technology,” *Energy Procedia*, vol. 17, pp. 32–38, 2012.
- [99] B. Banerjee and S. M. Islam, “Reliability based optimum location of distributed generation,” *International Journal of Electrical Power and Energy Systems*, vol. 33, no. 8, pp. 1470–1478, 2011.
- [100] J. W. Smith and D. L. Brooks, “Voltage impacts of distributed wind generation on rural distribution feeders,” *2001 IEEE/PES Transmission and Distribution Conference and Exposition. Developing New Perspectives (Cat. No.01CH37294)*, vol. 1, no. C, pp. 492–497, 2001.
- [101] P. Sreedharan, J. Farbes, E. Cutter, C. K. Woo, and J. Wang, “Microgrid and renewable generation integration: University of California, San Diego,” *Applied Energy*, vol. 169, pp. 709–720, 2016.
- [102] R. Cossent, T. Gómez, and P. Frías, “Towards a future with large penetration of distributed generation: Is the current regulation of electricity distribution ready? Regulatory recommendations under a European perspective,” *Energy Policy*, vol. 37, no. 3, pp. 1145–1155, 2009.
- [103] Z. Chang and S. Tao, “Power Quality Analysis of Photovoltaic Generation Integrated in User-Side Grid,” *International Journal of Computer and Electrical Engineering*, vol. 5, no. 2, 2013.
- [104] J. C. Hernández, M. J. Ortega, J. De La Cruz, and D. Vera, “Guidelines for the technical assessment of harmonic, flicker and unbalance emission limits for PV-distributed generation,” *Electric Power Systems Research*, vol. 81, no. 7, pp. 1247–1257, 2011.
- [105] N. Nair and L. Jing, “Power quality analysis for building integrated PV and micro wind

- turbine in New Zealand,” *Energy and Buildings*, vol. 58, pp. 302–309, 2012.
- [106] J. et al. Luszcz, *Power Quality Issues in Distributed Generation*. AvE4EvA, 2015.
- [107] M. Patsalides, A. Stavrou, V. Efthymiou, and G. E. Georghiou, “Towards the establishment of maximum PV generation limits due to power quality constraints,” *International Journal of Electrical Power and Energy Systems*, vol. 42, no. 1, pp. 285–298, 2012.
- [108] A. H. Samra and K. M. Islam, “Harmonic Effects on Synchronous Generators Voltage Regulation,” *Proceedings IEEE Southeastcon '95. Visualize the Future*, no. 2, pp. 376–380, 1995.
- [109] A. A. Latheef, “Harmonic impact of photovoltaic inverter systems on low and medium voltage distribution systems,” School of Electrical, Computer and Telecommunications Engineering, University of Wollongong, 2006.
- [110] E. Almeshaie and H. Soltan, “A methodology for Electric Power Load Forecasting,” *Alexandria Engineering Journal*, vol. 50, no. 2, pp. 137–144, 2011.
- [111] C. J. Bennett, R. A. Stewart, and J. W. Lu, “Forecasting low voltage distribution network demand profiles using a pattern recognition based expert system,” *Energy*, vol. 67, pp. 200–212, 2014.
- [112] S. Kadir Sheikh and M. G. Unde, “Short-Term Load Forecasting Using Ann Technique,” *International Journal of Engineering Sciences & Emerging Technologies*, vol. 1, no. 2, pp. 97–107, 2012.
- [113] P. Bacher, H. Madsen, and H. A. Nielsen, “Online short-term solar power forecasting,” *Solar Energy*, vol. 83, no. 10, pp. 1772–1783, 2009.
- [114] C. Chen, S. Duan, T. Cai, and B. Liu, “Online 24-h solar power forecasting based on weather type classification using artificial neural network,” *Solar Energy*, vol. 85, no. 11, pp. 2856–2870, 2011.
- [115] H. T. C. Pedro and C. F. M. Coimbra, “Assessment of forecasting techniques for solar power production with no exogenous inputs,” *Solar Energy*, vol. 86, no. 7, pp. 2017–2028, 2012.
- [116] L. A. Fernandez-Jimenez *et al.*, “Short-term power forecasting system for photovoltaic plants,” *Renewable Energy*, vol. 44, pp. 311–317, 2012.
- [117] S. K. H. Chow, E. W. M. Lee, and D. H. W. Li, “Short-term prediction of photovoltaic

- energy generation by intelligent approach,” *Energy and Buildings*, vol. 55, pp. 660–667, 2012.
- [118] C. M. Lee and C. N. Ko, “Short-term load forecasting using lifting scheme and ARIMA models,” *Expert Systems with Applications*, vol. 38, no. 5, pp. 5902–5911, May 2011.
- [119] G. Zahedi, S. Azizi, A. Bahadori, A. Elkamel, and S. R. Wan Alwi, “Electricity demand estimation using an adaptive neuro-fuzzy network: A case study from the Ontario province - Canada,” *Energy*, vol. 49, no. 1, pp. 323–328, 2013.
- [120] L. Xiao, J. Wang, X. Yang, and L. Xiao, “A hybrid model based on data preprocessing for electrical power forecasting,” *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 311–327, 2015.
- [121] H. Hahn, S. Meyer-Nieberg, and S. Pickl, “Electric load forecasting methods: Tools for decision making,” *European Journal of Operational Research*, vol. 199, no. 3, pp. 902–907, 2009.
- [122] R. Harley and J. Liang, “Computational intelligence in smart grids,” *Series on Computational Intelligence CIASG*, 2011.
- [123] D. Niu, Y. Wang, and D. D. Wu, “Power load forecasting using support vector machine and ant colony optimization,” *Expert Systems with Applications*, vol. 37, no. 3, pp. 2531–2539, Mar. 2010.
- [124] G. Sudheer and a. Suseelatha, “Short term load forecasting using wavelet transform combined with Holt–Winters and weighted nearest neighbor models,” *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 340–346, 2015.
- [125] F. Javed, N. Arshad, F. Wallin, I. Vassileva, and E. Dahlquist, “Forecasting for demand response in smart grids: An analysis on use of anthropologic and structural data and short term multiple loads forecasting,” *Applied Energy*, vol. 96, pp. 150–160, 2012.
- [126] C. Wang, G. Grozev, and S. Seo, “Decomposition and statistical analysis for regional electricity demand forecasting,” *Energy*, vol. 41, no. 1, pp. 313–325, 2012.
- [127] R. Yokoyama, T. Wakui, and R. Satake, “Prediction of energy demands using neural network with model identification by global optimization,” *Energy Conversion and Management*, vol. 50, no. 2, pp. 319–327, 2009.

- [128] P. Day *et al.*, “Residential power load forecasting,” *Procedia Computer Science*, vol. 28, pp. 457–464, 2014.
- [129] P. Lauret, M. David, and D. Calogine, “Nonlinear models for short-time load forecasting,” *Energy Procedia*, vol. 14, pp. 1404–1409, 2012.
- [130] M. Vukobratovic, Z. Hederic, and M. Hadziselimovic, “Optimal Distributed Generation placement in distribution network,” in *2014 IEEE International Energy Conference (ENERGYCON)*, 2014, pp. 1176–1183.
- [131] S. Oh, B. Song, S. Song, T. Kim, and D. Rho, “Optimal Voltage Regulation Method for Distribution Systems with Distributed Generation Systems Using the Artificial Neural Networks,” *Journal of Electrical Engineering and Technology*, vol. 8, no. 4, pp. 8–11, 2013.
- [132] A. Deoras, “Electricity Load and Price Forecasting with MATLAB ®.” MathWorks, pp. 1–14, 2010.
- [133] F. Milano, *Power System Modelling and Scripting*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010.
- [134] S. Rebennack, P. M. Pardalos, M. V. F. Pereira, and N. a. Iliadis, *Handbook of Power Systems I*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010.
- [135] S. Rebennack, P. M. Pardalos, M. V. F. Pereira, and N. a. Iliadis, *Handbook of Power Systems II*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010.
- [136] J. Schlabbach and K. Rofalski, *Power System Engineering - Planning, Design, and Operation of Power Systems and Equipment*. Weinheim: WILEY-VCH Verlag GmbH & Co., 2008.
- [137] H. Saadat, “Power System Analysis.” WCB McGraw-Hill, New York, NY, p. 720, 1999.
- [138] D. Glover, M. Sarma, and T. Overbye, *Power System Analysis & Design*, vol. 53, no. 9. 2012.
- [139] R. Idema and D. J. P. Lahaye, *Computational Methods in Power System Analysis*, vol. 1. Paris: Atlantis Press, 2014.
- [140] G. Kusic, *Computer-Aided Power Systems Analysis*, 2nd ed. Boca Raton, FL: CRC Press, Taylor & Francis Group, 2008.
- [141] A. J. Pansini, *Electrical Distribution Engineering*. 2007.

- [142] A. Anwar and H. R. Pota, "Optimum capacity allocation of DG units based on unbalanced three-phase optimal power flow," *IEEE Power and Energy Society General Meeting*, 2012.
- [143] A. Anwar, S. Member, and H. R. Pota, "Loss Reduction of Power Distribution Network Using Optimum Size and Location of Distributed Generation."
- [144] M. Barukcic, Z. Hederic, and K. Miklosevic, "Multi objective optimization of energy production of distributed generation in distribution feeder," in *2014 IEEE International Energy Conference (ENERGYCON)*, 2014, pp. 1325–1333.
- [145] F. Milano, "An open source power system analysis toolbox," *IEEE Transactions on Power Systems*, vol. 20, no. 3, pp. 1199–1206, 2005.
- [146] M. Barukcic, M. Vukobratovic, and T. Bensic, "Evolutionary optimization approach for performing interval power flow considering uncertainties in electric power systems," in *2016 International Conference on Smart Systems and Technologies (SST)*, 2016, pp. 185–190.
- [147] C. H. Dharmakeerthi, N. Mithulananthan, and T. K. Saha, "Impact of electric vehicle fast charging on power system voltage stability," *International Journal of Electrical Power and Energy Systems*, vol. 57, pp. 241–249, 2014.
- [148] Y. Alinejad-Beromi, M. Sedighizadeh, M. R. Bayat, and M. E. Khodayar, "Using genetic algorithm for Distributed generation allocation to reduce losses and improve voltage profile," *Proceedings of the Universities Power Engineering Conference*, no. 1, pp. 954–959, 2007.
- [149] P. Dehghanian, S. H. Hosseini, M. Moeini-Aghaie, and A. Arabali, "Optimal siting of DG units in power systems from a probabilistic multi-objective optimization perspective," *International Journal of Electrical Power & Energy Systems*, vol. 51, pp. 14–26, Oct. 2013.
- [150] A. G. Marinopoulos, M. C. Alexiadis, and P. S. Dokopoulos, "Energy losses in a distribution line with distributed generation based on stochastic power flow," *Electric Power Systems Research*, vol. 81, no. 10, pp. 1986–1994, 2011.
- [151] a. Ozdemir, J. Y. Lim, and C. Singh, "Post-Outage Reactive Power Flow Calculations by Genetic Algorithms: Constrained Optimization Approach," *IEEE Transactions on Power Systems*, vol. 20, no. 3, pp. 1266–1272, 2005.
- [152] H. Falaghi, C. Singh, M. R. Haghifam, and M. Ramezani, "DG integrated multistage

- distribution system expansion planning,” *International Journal of Electrical Power and Energy Systems*, vol. 33, no. 8, pp. 1489–1497, 2011.
- [153] B. Morvaj, R. Evins, and J. Carmeliet, “Optimization framework for distributed energy systems with integrated electrical grid constraints,” *Applied Energy*, vol. 171, pp. 296–313, 2016.
- [154] Y. Y. Chen and C. Y. Chung, “Multi-Constrained Optimal Power Flow by an opposition-based differential evolution,” *IEEE Power and Energy Society General Meeting*, pp. 1–7, 2012.
- [155] A. Sharifian and S. Sharifian, “A new power system transient stability assessment method based on Type-2 fuzzy neural network estimation,” *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 71–87, Jan. 2015.
- [156] G. P. Harrison, A. Piccolo, P. Siano, and A. R. Wallace, “Hybrid GA and OPF evaluation of network capacity for distributed generation connections,” *Electric Power Systems Research*, vol. 78, no. 3, pp. 392–398, 2008.
- [157] M. Baghayipour, A. Akbari Foroud, and A. Soofiabadi, “A comprehensive fair nodal pricing scheme, considering participants’ efficiencies and their rational shares of total cost of transmission losses,” *International Journal of Electrical Power & Energy Systems*, vol. 63, pp. 30–43, Dec. 2014.
- [158] R. D. Zimmerman, C. E. Murillo-Sanchez, and R. J. Thomas, “MATPOWER: Steady-State Operations, Planning, and Analysis Tools for Power Systems Research and Education,” *IEEE Transactions on Power Systems*, vol. 26, no. 1, pp. 12–19, Feb. 2011.
- [159] A. Al-Wakeel, J. Wu, and N. Jenkins, “State estimation of medium voltage distribution networks using smart meter measurements,” *Applied Energy*, vol. 184, pp. 207–218, 2016.
- [160] R. D. Zimmerman and C. E. Murillo-s, “Matpower 4.1 User’s Manual,” *Power Systems Engineering Research Center (Pserc)*. pp. 1–116, 2011.
- [161] A. Barin, L. F. Pozzatti, L. N. Canha, R. Q. MacHado, A. R. Abaide, and G. Arend, “Multi-objective analysis of impacts of distributed generation placement on the operational characteristics of networks for distribution system planning,” *International Journal of Electrical Power and Energy Systems*, vol. 32, no. 10, pp. 1157–1164, 2010.
- [162] K. Balamurugan, D. Srinivasan, and T. Reindl, “Impact of Distributed Generation on Power

- Distribution Systems,” *Energy Procedia*, vol. 25, pp. 93–100, 2012.
- [163] B. Abdi, M. Abroshan, M. H. Aslinezhad, and A. Alimardani, “Coordination return of protective devices in distribution systems in presence of distributed generation,” *Energy Procedia*, vol. 12, pp. 263–270, 2011.
- [164] J. L. Rueda, J. Cepeda, I. Erlich, D. Echeverría, and G. Argüello, “Heuristic optimization based approach for identification of power system dynamic equivalents,” *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 185–193, Jan. 2015.
- [165] T. Aziz, T. K. Saha, and N. Mithulananthan, “Identification of the weakest bus in a distribution system with load uncertainties using reactive power margin,” *2010 20th Australasian Universities Power Engineering Conference*, pp. 1–6, 2010.
- [166] J. M. Abdallah and A. R. Al-Zyoud, “Voltage and Reactive Power Control Simulations Using Neural Networks,” *International Journal of Simulation: Systems, Science & Technology*, vol. 10, no. 4, pp. 64–72, 2013.
- [167] M. Majidi, M. Etezadi-Amoli, and H. Livani, “Distribution system state estimation using compressive sensing,” *International Journal of Electrical Power and Energy Systems*, vol. 88, pp. 175–186, 2017.
- [168] P. Mahat, Z. Chen, and B. Bak-Jensen, “Control and operation of distributed generation in distribution systems,” *Electric Power Systems Research*, vol. 81, no. 2, pp. 495–502, 2011.
- [169] H. B. Funmilayo and K. L. Butler-Purry, “An approach to mitigate the impact of distributed generation on the Overcurrent Protection scheme for radial feeders,” in *2009 IEEE/PES Power Systems Conference and Exposition*, 2009, no. December, pp. 1–11.
- [170] K. Fekete, Z. Klaic, and L. Majdandzic, “Expansion of the residential photovoltaic systems and its harmonic impact on the distribution grid,” *Renewable Energy*, vol. 43, pp. 140–148, 2012.
- [171] K. L. Butler-Purry and H. B. Funmilayo, “Overcurrent protection issues for radial distribution systems with distributed generators,” in *2009 IEEE Power & Energy Society General Meeting*, 2009, pp. 1–5.
- [172] V. Calderaro, J. V. Milanovic, M. Kayikci, and A. Piccolo, “The impact of distributed synchronous generators on quality of electricity supply and transient stability of real distribution network,” *Electric Power Systems Research*, vol. 79, no. 1, pp. 134–143, 2009.

- [173] S. Nikolovski, M. Vukobratović, and L. Majdandžić, “Protection coordination and anti islanding protection solution for biomass power plant connected on distribution network,” *International Journal of Electrical and Computer Engineering*, vol. 6, no. 6, 2016.
- [174] U. Häger, C. Rehtanz, and N. V. Editors, *Power Systems Monitoring, Control and Protection of Interconnected Power Systems*. 2014.
- [175] R. D. Zimmerman and C. E. Murillo-Sanchez, *Matpower 6.0 User’s Manual*. Tempe, AZ, USA: Power Systems Engineering Research Center, 2016.
- [176] P. S. . Murty, *Power System Analysis*. Hyderabad - 500 095 A. P: BS Publications, 2007.
- [177] M. S. Mahmoud, S. Azher Hussain, and M. A. Abido, “Modeling and control of microgrid: An overview,” *Journal of the Franklin Institute*, vol. 351, no. 5, pp. 2822–2859, 2014.
- [178] D. Karavidović and A. Pavić, “Korištenje distribucijske mreže u pogonu proizvodnih postrojenja obnovljivih izvora energije,” in *Hrvatski ogranak međunarodne elektrodistribucijske konferencije – HO CIRED, 1. savjetovanje*, 2008, pp. 1–15.
- [179] G. Ledwich, F. Wen, I. Ziari, D. Jayaweera, S. Islam, and S. N. Sukumar, “INTELLIGENT GRID RESEARCH CLUSTER- PROJECT 3 Optimal Siting and Dispatch of Distributed Generations,” Curtin.
- [180] S. Sumathi and P. Surekha, *Computational intelligence paradigms: theory & applications using MATLAB*. CRC Press, 2010.
- [181] D. Ibrahim, “An Overview of Soft Computing,” *Procedia Computer Science*, vol. 102, no. August, pp. 34–38, 2016.
- [182] J. Kennedy, “Swarm Intelligence,” in *Handbook of Nature-Inspired and Innovative Computing*, Boston: Kluwer Academic Publishers, 2001, pp. 187–219.
- [183] M. Čupić, *Prirodom inspirirani optimizacijski algoritmi. Metaheuristike*. Zagreb, Croatia: Faculty of Electrical Engineering and Computing Zagreb, 2013.
- [184] R. Kruse, C. Borgelt, C. Braune, S. Mostaghim, and M. Steinbrecher, *Computational Intelligence*. London: Springer London, 2016.
- [185] A. A. Hopgood, “The State of Artificial Intelligence,” in *Advances in Computers*, vol. 65, no. 5, 2005, pp. 1–75.
- [186] L. Shengsong, H. Zhijian, and W. Min, “A Hybrid Algorithm for Optimal Power Flow

- Using the Chaos Optimization and the Linear Interior Point Algorithm,” pp. 793–797, 2002.
- [187] M. R. AlRashidi and M. E. El-Hawary, “Applications of computational intelligence techniques for solving the revived optimal power flow problem,” *Electric Power Systems Research*, vol. 79, no. 4, pp. 694–702, 2009.
- [188] M.-J. Santofimia-Romero, X. Toro-García, and J.-C. López-López, “Artificial Intelligence Techniques for Smart Grid Applications,” 2011.
- [189] A. Abraham and S. Das, *Computational Intelligence in Power Engineering*. 2010.
- [190] Z. Wang and R. S. Srinivasan, “A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single and ensemble prediction models,” *Renewable and Sustainable Energy Reviews*, vol. 75, no. September 2015, pp. 796–808, 2017.
- [191] S. K. Jha, J. Bilalovic, A. Jha, N. Patel, and H. Zhang, “Renewable energy: Present research and future scope of Artificial Intelligence,” *Renewable and Sustainable Energy Reviews*, vol. 77, no. April, pp. 297–317, Sep. 2017.
- [192] M. Alshraideh and L. Tahat, “Multiple-population genetic algorithm for solving min-max optimization problems,” *International Review on Computers and Software*, vol. 10, no. 1, pp. 9–19, 2015.
- [193] S. M. Zahraee, M. Khalaji Assadi, and R. Saidur, “Application of Artificial Intelligence Methods for Hybrid Energy System Optimization,” *Renewable and Sustainable Energy Reviews*, vol. 66, pp. 617–630, Dec. 2016.
- [194] A. Y. Abdelaziz, F. M. Mohammed, S. F. Mekhamer, and M. A. L. Badr, “Distribution Systems Reconfiguration using a modified particle swarm optimization algorithm,” *Electric Power Systems Research*, vol. 79, no. 11, pp. 1521–1530, 2009.
- [195] P. J. Garcia Nieto, E. Garciaa-Gonzalo, J. C. Alvarez Anton, V. M. Gonzalez Suarez, R. Mayo Bayon, and F. Mateos Martin, “A comparison of several machine learning techniques for the centerline segregation prediction in continuous cast steel slabs and evaluation of its performance,” *Journal of Computational and Applied Mathematics*, 2016.
- [196] M. K. Saini and R. Kapoor, “Classification of power quality events - A review,” *International Journal of Electrical Power and Energy Systems*, vol. 43, no. 1, pp. 11–19, 2012.

- [197] S. Khokhar, A. A. B. Mohd Zin, A. S. B. Mokhtar, and M. Pesaran, "A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances," *Renewable and Sustainable Energy Reviews*, vol. 51, pp. 1650–1663, 2015.
- [198] K. W. Kow, Y. W. Wong, R. K. Rajkumar, and R. K. Rajkumar, "A review on performance of artificial intelligence and conventional method in mitigating PV grid-tied related power quality events," *Renewable and Sustainable Energy Reviews*, vol. 56, pp. 334–346, 2016.
- [199] M. Joorabian, S. S. Mortazavi, and a. a. Khayyami, "Harmonic estimation in a power system using a novel hybrid Least Squares-Adaline algorithm," *Electric Power Systems Research*, vol. 79, pp. 107–116, 2009.
- [200] L. Merabet, S. Saad, D. O. Abdeslam, and A. Omeiri, "A comparative study of harmonic currents extraction by simulation and implementation," *International Journal of Electrical Power and Energy Systems*, vol. 53, no. 1, pp. 507–514, 2013.
- [201] J. M. Ramirez, B. V. Hernández, and R. E. Correa, "Dynamic equivalence by an optimal strategy," *Electric Power Systems Research*, vol. 84, no. 1, pp. 58–64, 2012.
- [202] A. N. De Souza, M. G. Zago, O. R. Saavedra, C. C. Oba Ramos, and K. Ferraz, "A computational tool to assist the analysis of the transformer behavior related to lightning," *International Journal of Electrical Power and Energy Systems*, vol. 33, no. 3, pp. 556–561, 2011.
- [203] L. Ekonomou, I. F. Gonos, D. P. Iracleous, and I. A. Stathopoulos, "Application of artificial neural network methods for the lightning performance evaluation of Hellenic high voltage transmission lines," *Electric Power Systems Research*, vol. 77, no. 1, pp. 55–63, 2007.
- [204] J. A. Morales, E. Orduña, and C. Rehtanz, "Classification of lightning stroke on transmission line using multi-resolution analysis and machine learning," *International Journal of Electrical Power & Energy Systems*, vol. 58, pp. 19–31, 2014.
- [205] V. H. Ferreira *et al.*, "A survey on intelligent system application to fault diagnosis in electric power system transmission lines," *Electric Power Systems Research*, vol. 136, pp. 135–153, 2016.
- [206] J. Sadeh and H. Afradi, "A new and accurate fault location algorithm for combined transmission lines using Adaptive Network-Based Fuzzy Inference System," *Electric*

- Power Systems Research*, vol. 79, no. 11, pp. 1538–1545, 2009.
- [207] E. M. Meza, J. C. S. De Souza, M. T. Schilling, and M. B. Do Coutto Filho, “Exploring fuzzy relations for alarm processing and fault location in electrical power systems,” *2001 IEEE Porto Power Tech Proceedings*, vol. 3, pp. 207–212, 2001.
- [208] S. S. Gururajapathy, H. Mokhlis, and H. A. Illias, “Fault location and detection techniques in power distribution systems with distributed generation: A review,” *Renewable and Sustainable Energy Reviews*, vol. 74, no. February 2016, pp. 949–958, 2017.
- [209] P. Peretto, *An Introduction to the Modeling of Neural Networks*, vol. 2. Cambridge University Press, 1992.
- [210] R. Pfeifer, D. Damian, and R. Fuchslin, “Neural Networks,” p. 109, 2010.
- [211] D. Graupe, *Principles of Artificial Neural Networks*. Singapore: World Scientific Publishing Co. Pte. Ltd., 1997.
- [212] S. Haykin, *Neural Networks - A Comprehensive Foundation*, 2nd ed. New Jersey, USA: Prentice Hall PTR Upper Saddle River, NJ, USA ©1998, 2009.
- [213] B. Krose and P. van der Smagt, *Introduction To Neural Networks*. The University of Amsterdam, 1996.
- [214] A. Zilouchian, “Fundamentals of Neural Networks,” in *Intelligent Control Systems Using Soft Computing Methodologies*, no. 1, CRC Press, 2001, pp. 1–5.
- [215] B. Dalbelo Bašić, M. Čupić, and J. Šnajder, “Umjetne neuronske mreže.” Fakultet elektrotehnike i računarstva, Zavod za elektroniku, mikroelektroniku i inteligentne sustave, p. 49, 2008.
- [216] TechSource Systems Sdn, “Statistical & Data Analysis Using Neural Network.” TechSource Systems, pp. 1–52, 2005.
- [217] E. J. Kacprzyk, *Software Engineering and Knowledge Engineering: Theory and Practice*, vol. 162. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012.
- [218] J. F. Gonçalves, J. J. de Magalhães Mendes, and M. G. C. Resende, “The Basic Multi-Project Scheduling Problem,” in *Handbook on Project Management and Scheduling Vol. 2*, Cham: Springer International Publishing, 2015, pp. 667–683.
- [219] H. Liu, H. Tian, and Y. Li, “Comparison of new hybrid FEEMD-MLP, FEEMD-ANFIS,

- Wavelet Packet-MLP and Wavelet Packet-ANFIS for wind speed predictions,” *Energy Conversion and Management*, vol. 89, pp. 1–11, Jan. 2015.
- [220] R. Jursa and K. Rohrig, “Short-term wind power forecasting using evolutionary algorithms for the automated specification of artificial intelligence models,” *International Journal of Forecasting*, vol. 24, no. 4, pp. 694–709, 2008.
- [221] H. Deng, L. Wang, F. L. Wang, and J. Lei, *Artificial Intelligence and Computational Intelligence*, vol. 5855. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009.
- [222] L. Jain and P. De Wilde, Eds., *Practical Applications of Computational Intelligence Techniques*, vol. 16. Dordrecht: Springer Netherlands, 2001.
- [223] J. Stuchly, S. Misak, T. Vantuch, and T. Burianek, “A power quality forecasting model as an integrate part of active demand side management using Artificial Intelligence Technique - Multilayer Neural Network with Backpropagation Learning Algorithm,” in *2015 IEEE 15th International Conference on Environment and Electrical Engineering (EEEIC)*, 2015, pp. 611–616.
- [224] M. Buhari and S. S. Adamu, “Short-Term Load Forecasting Using Artificial Neural Network,” *Proceedings of the International MultiConference of Engineers and Computer Scientists*, vol. I, pp. 1–71, 2012.
- [225] G. Li, J. Shi, and X. Qu, “Modeling methods for GenCo bidding strategy optimization in the liberalized electricity spot market-A state-of-the-art review,” *Energy*, vol. 36, no. 8, pp. 4686–4700, 2011.
- [226] G. Kyriakarakos, K. Patlitzianas, M. Damasiotis, and D. Papastefanakis, “A fuzzy cognitive maps decision support system for renewables local planning,” *Renewable and Sustainable Energy Reviews*, vol. 39, pp. 209–222, Nov. 2014.
- [227] M. Gitizadeh, A. A. Vahed, and J. Aghaei, “Multistage distribution system expansion planning considering distributed generation using hybrid evolutionary algorithms,” *Applied Energy*, vol. 101, pp. 655–666, Jan. 2013.
- [228] J. Aghaei, M. A. Akbari, A. Roosta, and A. Baharvandi, “Multiobjective generation expansion planning considering power system adequacy,” *Electric Power Systems Research*, vol. 102, pp. 8–19, 2013.
- [229] A. Soroudi and M. Ehsan, “A distribution network expansion planning model considering

- distributed generation options and techno-economical issues,” *Energy*, vol. 35, no. 8, pp. 3364–3374, Aug. 2010.
- [230] M. Motevasel and A. R. Seifi, “Expert energy management of a micro-grid considering wind energy uncertainty,” *Energy Conversion and Management*, vol. 83, pp. 58–72, Jul. 2014.
- [231] M. A. Abido, “A niched Pareto genetic algorithm for multiobjective environmental/economic dispatch,” *International Journal of Electrical Power and Energy Systems*, vol. 25, no. 2, pp. 97–105, 2003.
- [232] A. Zakariazadeh, S. Jadid, and P. Siano, “Economic-environmental energy and reserve scheduling of smart distribution systems: A multiobjective mathematical programming approach,” *Energy Conversion and Management*, vol. 78, pp. 151–164, 2014.
- [233] M. A. Abido and J. M. Bakhshwain, “Optimal VAR dispatch using a multiobjective evolutionary algorithm,” *International Journal of Electrical Power & Energy Systems*, vol. 27, no. 1, pp. 13–20, 2005.
- [234] S. Sivasubramani and K. S. S. Swarup, “Multi-objective harmony search algorithm for optimal power flow problem,” *International Journal of Electrical Power & Energy Systems*, vol. 33, no. 3, pp. 745–752, 2011.
- [235] A. Rajasekhar, N. Lynn, S. Das, and P. N. Suganthan, “Computing with the collective intelligence of honey bees – A survey,” *Swarm and Evolutionary Computation*, vol. 32, pp. 25–48, 2017.
- [236] T. Niknam, A. Kavousifard, S. Tabatabaei, and J. Aghaei, “Optimal operation management of fuel cell/wind/photovoltaic power sources connected to distribution networks,” *Journal of Power Sources*, vol. 196, no. 20, pp. 8881–8896, 2011.
- [237] J. Zhang, H. Cheng, and C. Wang, “Technical and economic impacts of active management on distribution network,” *International Journal of Electrical Power & Energy Systems*, vol. 31, no. 2–3, pp. 130–138, 2009.
- [238] P. K. Dash, S. Mishra, M. A. Salama, and A. C. Liew, “Classification of power system disturbances using a fuzzy expert system and a Fourier linear combiner,” *IEEE Transactions on Power Delivery*, vol. 15, no. 2, pp. 472–477, Apr. 2000.
- [239] I. Petrović, J. Lajos, and Z. Baus, “USE OF FUZZY LOGIC SYSTEMS FOR

- ASSESSMENT OF PRIMARY FAULTS,” *Journal of ELECTRICAL ENGINEERING*, vol. 66, no. 5, pp. 1–5, 2015.
- [240] K. H. Chao, S. H. Ho, and M. H. Wang, “Modeling and fault diagnosis of a photovoltaic system,” *Electric Power Systems Research*, vol. 78, no. 1, pp. 97–105, 2008.
- [241] A. M. Foley, P. G. Leahy, A. Marvuglia, and E. J. McKeogh, “Current methods and advances in forecasting of wind power generation,” *Renewable Energy*, vol. 37, no. 1, pp. 1–8, 2012.
- [242] T. Popławski, G. Dudek, and J. Łyp, “Forecasting methods for balancing energy market in Poland,” *International Journal of Electrical Power & Energy Systems*, vol. 65, pp. 94–101, Feb. 2015.
- [243] A. Tascikaraoglu, A. R. Boynuegri, and M. Uzunoglu, “A demand side management strategy based on forecasting of residential renewable sources: A smart home system in Turkey,” *Energy and Buildings*, vol. 80, pp. 309–320, 2014.
- [244] O. Ozgonenel, T. Yalcin, I. Guney, and U. Kurt, “A new classification for power quality events in distribution systems,” *Electric Power Systems Research*, vol. 95, pp. 192–199, 2013.
- [245] S. A. Soliman and A. M. Alkandari, *Power Quality Harmonics Analysis and Real Measurements Data*. InTech, 2011.
- [246] F. G. Montoya, A. García-Cruz, M. G. Montoya, and F. Manzano-Agugliaro, “Power quality techniques research worldwide: A review,” *Renewable and Sustainable Energy Reviews*, vol. 54, pp. 846–856, 2016.
- [247] T. X. Zhu, S. K. Tso, and K. L. Lo, “Wavelet-Based Fuzzy Reasoning Approach to Power-Quality Disturbance Recognition,” *IEEE Transactions on Power Delivery*, vol. 19, no. 4, pp. 1928–1935, Oct. 2004.
- [248] M. V. Chilukuri and P. K. Dash, “Multiresolution S-Transform-Based Fuzzy Recognition System for Power Quality Events,” *IEEE Transactions on Power Delivery*, vol. 19, no. 1, pp. 323–330, 2004.
- [249] S. A. Soliman, I. Helal, and A. M. Al-Kandari, “Fuzzy linear regression for measurement of harmonic components in a power system,” *Electric Power Systems Research*, vol. 50, no. 2, pp. 99–105, May 1999.

- [250] D. Connolly, H. Lund, B. V. Mathiesen, and M. Leahy, “A review of computer tools for analysing the integration of renewable energy into various energy systems,” *Applied Energy*, vol. 87, no. 4, pp. 1059–1082, 2010.
- [251] M.-R. Haghifam, H. Falaghi, and O. P. Malik, “Risk-based distributed generation placement,” *IET Generation, Transmission & Distribution*, vol. 2, no. 2, p. 252, 2008.
- [252] A. K. AL-Othman, “A fuzzy state estimator based on uncertain measurements,” *Measurement: Journal of the International Measurement Confederation*, vol. 42, no. 4, pp. 628–637, 2009.
- [253] A. Zangeneh, S. Jadid, and A. Rahimi-Kian, “A fuzzy environmental-technical-economic model for distributed generation planning,” *Energy*, vol. 36, no. 5, pp. 3437–3445, 2011.
- [254] S. N. Sivanandam, S. Sumathi, and S. N. Deepa, *Introduction to Fuzzy Logic using MATLAB*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007.
- [255] K. Peeva and Y. Kyosev, *Fuzzy Relational Calculus: Theory, Applications, and Software*. World Scientific Publishing Co. Pte. Ltd., 2004.
- [256] F. Martin McNeill and E. Thro, *Fuzzy Logic: A Practical Approach*. Morgan Kaufmann Publishing, 1994.
- [257] A. Kandel and M. Schneider, “Fuzzy Sets and Their Applications to Artificial Intelligence,” in *Advances in Computers*, vol. 28, L. A. Zadeh, K.-S. Fu, T. Kokichi, and S. Masamichi, Eds. 1989, pp. 69–105.
- [258] D. Dubois and H. Prade, *Fuzzy Sets and Systems: Theory and Applications*. Orlando, FL, USA: Academic Press, Inc., 1997.
- [259] J. Harris, *Fuzzy Logic Applications in Engineering Science*. Berlin/Heidelberg: Springer-Verlag, 2006.
- [260] L. a. Zadeh, “Fuzzy sets,” *Information and Control*, vol. 8, no. 3, pp. 338–353, 1965.
- [261] P. P. Angelov, *Handbook on Computational Intelligence Volume 1: Fuzzy Logic, Systems, Artificial Neural Networks, and Learning Systems*. 2016.
- [262] R. Eberhart, P. K. Simpson, and R. W. Dobbins, “Computational Intelligence PC Tools,” *Academic Press*, pp. 611–616, 1996.
- [263] Y. Tan, Y. Shi, F. Buarque, A. Gelbukh, and D. Hutchison, *Advances in Swarm and*

- Computational Intelligence*, vol. 9142. 2015.
- [264] Y. Tan, Y. Shi, F. Buarque, A. Gelbukh, and D. Hutchison, *Advances in Swarm and Computational Intelligence*, vol. 9142. Cham: Springer International Publishing, 2015.
- [265] Y. Tan, Y. Shi, F. Buarque, A. Gelbukh, and D. Hutchison, *Advances in Swarm and Computational Intelligence*, vol. 9142. Cham: Springer International Publishing, 2015.
- [266] C. Kahraman, I. Kaya, and S. Cebi, “A comparative analysis for multiattribute selection among renewable energy alternatives using fuzzy axiomatic design and fuzzy analytic hierarchy process,” *Energy*, vol. 34, no. 10, pp. 1603–1616, 2009.
- [267] G. Vachtsevanos, F. L. Lewis, M. . Roemer, A. Hess, and B. Wu, *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. 2006.
- [268] F. Shabani, N. R. Prasad, and H. A. Smolleck, “A fuzzy-logic-supported weighted least squares state estimation,” *Electric Power Systems Research*, vol. 39, no. 1, pp. 55–60, Oct. 1996.
- [269] J. Stępień and S. Filipiak, “Application of the evolutionary algorithm with memory at the population level for restoration service of electric power distribution networks,” *International Journal of Electrical Power & Energy Systems*, vol. 63, no. 0, pp. 695–704, 2014.
- [270] A. Mendes, N. Boland, P. Guiney, and C. Riveros, “Switch and tap-changer reconfiguration of distribution networks using evolutionary algorithms,” *IEEE Transactions on Power Systems*, vol. 28, no. 1, pp. 85–92, 2013.
- [271] B. Venkatesh and R. Ranjan, “Optimal radial distribution system reconfiguration using fuzzy adaptation of evolutionary programming,” *International Journal of Electrical Power and Energy System*, vol. 25, no. 10, pp. 775–780, 2003.
- [272] E. G. Carrano, C. G. Tarôco, O. M. Neto, and R. H. C. Takahashi, “A multiobjective hybrid evolutionary algorithm for robust design of distribution networks,” *International Journal of Electrical Power & Energy Systems*, vol. 63, pp. 645–656, 2014.
- [273] M. Barukcic, M. Vukobratovic, D. Masle, D. Buljic, and Z. Herderic, “The evolutionary optimization approach for voltage profile estimation in a radial distributioacn network with a decreased number of measurements,” in *2017 15th International Conference on Electrical Machines, Drives and Power Systems, ELMA 2017 - Proceedings*, 2017, pp. 26–31.

- [274] P. K. Ray and B. Subudhi, "Neuro-evolutionary approaches to power system harmonics estimation," *International Journal of Electrical Power and Energy Systems*, vol. 64, pp. 212–220, 2015.
- [275] H. M. G. C. Branco, M. Oleskovicz, A. C. B. Delbem, D. V. Coury, and R. P. M. Silva, "Optimized allocation of power quality monitors in transmission systems: A multiobjective approach," *International Journal of Electrical Power and Energy Systems*, vol. 64, pp. 156–166, 2015.
- [276] N. Kinhekar, N. P. Padhy, and H. O. Gupta, "Multiobjective demand side management solutions for utilities with peak demand deficit," *International Journal of Electrical Power & Energy Systems*, vol. 55, pp. 612–619, Feb. 2014.
- [277] M. Varadarajan and K. S. Swarup, "Differential evolutionary algorithm for optimal reactive power dispatch," *International Journal of Electrical Power & Energy Systems*, vol. 30, no. 8, pp. 435–441, 2008.
- [278] T. Bäck, D. B. Fogel, and Z. Michalewicz, "Handbook of Evolutionary Computation," *Evolutionary Computation*, vol. 2, pp. 1–11, 1997.
- [279] W. Banzhaf, "Evolutionary Computation and Genetic Programming," in *Engineered Biomimicry*, Elsevier, 2013, pp. 429–447.
- [280] A. Kordon, *Applying Computational Intelligence*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010.
- [281] R. L. Haupt and S. E. Haupt, *Practical Genetic Algorithms*, 2nd ed. New Jersey, USA: John Wiley & Sons, Inc, 2004.
- [282] S. N. Sivanandam and S. N. Deepa, *Introduction to Genetic Algorithms*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008.
- [283] N. Ansari and E. Hou, *Computational Intelligence for Optimization*. Boston, MA: Springer US, 1997.
- [284] M. Mitchell, *An introduction to genetic algorithms*. Cambridge, Massachusetts, London, England: The MIT Press, 1996.
- [285] R. Poli, W. Langdon, and N. McPhee, *A field guide to genetic programming*. Lulu Press, Inc., 2008.

- [286] J. Dheebea and N. Albert Singh, *Computational Intelligence Applications in Modeling and Control*, vol. 575. 2015.
- [287] S. A.-H. Soliman and A.-A. H. Mantawy, *Modern Optimization Techniques with Applications in Electric Power Systems*. New York, NY: Springer New York, 2012.
- [288] B. K. Panigrahi, Y. Shi, and M.-H. Lim, *Handbook of Swarm Intelligence*, vol. 8. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011.
- [289] X.-S. Yang and M. Karamanoglu, *Swarm Intelligence and Bio-Inspired Computation Theory and Applications*. Elsevier, 2013.
- [290] A. Lazinica, Ed., *Particle Swarm Optimization*. InTech, 2009.
- [291] M. Mohammadi, S. H. Hosseinian, and G. B. Gharehpetian, "Optimization of hybrid solar energy sources/wind turbine systems integrated to utility grids as microgrid (MG) under pool/bilateral/hybrid electricity market using PSO," *Solar Energy*, vol. 86, no. 1, pp. 112–125, 2012.
- [292] J. Olamaei, T. Niknam, and G. Gharehpetian, "Application of particle swarm optimization for distribution feeder reconfiguration considering distributed generators," *Applied Mathematics and Computation*, vol. 201, no. 1–2, pp. 575–586, 2008.
- [293] V. R. Pandi, H. H. Zeineldin, W. Xiao, and A. F. Zobaa, "Optimal penetration levels for inverter-based distributed generation considering harmonic limits," *Electric Power Systems Research*, vol. 97, pp. 68–75, 2013.
- [294] M. Fairuz, L. Tan, A. Date, B. Singh, and A. Akbarzadeh, "Simultaneous power generation and heat recovery using a heat pipe assisted thermoelectric generator system," *Energy Conversion and Management*, vol. 91, pp. 110–119, 2015.
- [295] S. Duman, N. Yorukeren, and I. H. Altas, "A novel modified hybrid PSOGSA based on fuzzy logic for non-convex economic dispatch problem with valve-point effect," *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 121–135, Jan. 2015.
- [296] S. Bahrami, R.-A. Hooshmand, and M. Parastegari, "Short term electric load forecasting by wavelet transform and grey model improved by PSO (particle swarm optimization) algorithm," *Energy*, vol. 72, no. 2014, pp. 434–442, 2014.

- [297] P. Acharjee, "Identification of maximum loadability limit and weak buses using security constraint genetic algorithm," *International Journal of Electrical Power and Energy Systems*, vol. 36, no. 1, pp. 40–50, 2012.
- [298] W. Al-Saedi, S. W. Lachowicz, D. Habibi, and O. Bass, "Power quality enhancement in autonomous microgrid operation using Particle Swarm Optimization," *International Journal of Electrical Power & Energy Systems*, vol. 42, no. 1, pp. 139–149, 2012.
- [299] P. R. López, M. G. González, N. R. Reyes, and F. Jurado, "Optimization of biomass fuelled systems for distributed power generation using Particle Swarm Optimization," *Electric Power Systems Research*, vol. 78, no. 8, pp. 1448–1455, 2008.
- [300] M. Gómez-González, A. López, and F. Jurado, "Hybrid discrete PSO and OPF approach for optimization of biomass fueled micro-scale energy system," *Energy Conversion and Management*, vol. 65, pp. 539–545, Jan. 2013.
- [301] H. Izakian, B. T. Ladani, A. Abraham, and V. Snášel, "a Discrete Particle Swarm Optimization Approach for Grid Job Scheduling," *International Journal of Innovative Computing*, vol. 6, no. 9, pp. 1–9, 2010.
- [302] A. H. Kashan and B. Karimi, "A discrete particle swarm optimization algorithm for scheduling parallel machines," *Computers & Industrial Engineering*, vol. 56, no. 1, pp. 216–223, Feb. 2009.
- [303] D. Datta and J. R. Figueira, "A real-integer-discrete-coded particle swarm optimization for design problems," *Applied Soft Computing*, vol. 11, no. 4, pp. 3625–3633, 2011.
- [304] D. Zhang, S. Liu, and L. G. Papageorgiou, "Fair cost distribution among smart homes with microgrid," *Energy Conversion and Management*, vol. 80, pp. 498–508, 2014.
- [305] F. Marini and B. Walczak, "Particle swarm optimization (PSO). A tutorial," *Chemometrics and Intelligent Laboratory Systems*, vol. 149, pp. 153–165, Dec. 2015.
- [306] M. Varadarajan and K. S. Swarup, "Network loss minimization with voltage security using differential evolution," *Electric Power Systems Research*, vol. 78, no. 5, pp. 815–823, 2008.
- [307] A. H. Khazali and M. Kalantar, "Optimal reactive power dispatch based on harmony search algorithm," *International Journal of Electrical Power & Energy Systems*, vol. 33, no. 3, pp. 684–692, 2011.

- [308] F. Sismotto and E. L. Hage, "An Evolutionary Algorithm for the Optimisation of the Distributed Generation Dispatch," in *CIREC 18th International Conference on Electricity Distribution*, 2005, no. June, pp. 6–9.
- [309] J. M. Keller, D. Liu, and D. B. Fogel, "Fundamentals of computational intelligence : neural networks, fuzzy systems, and evolutionary computation," p. 364, 2016.
- [310] A. Abraham, A. Hassanien, P. Siarry, and A. E. Eds, *Foundations of Computational Intelligence Volume 3*, vol. 203. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009.
- [311] R. Klemous, J. Nikodem, W. Jacak, and Z. Chaczko, Eds., *Advanced Methods and Applications in Computational Intelligence*, vol. 6. Heidelberg: Springer International Publishing, 2014.
- [312] H. Jin and M.-L. Wong, "Adaptive, convergent, and diversified archiving strategy for multiobjective evolutionary algorithms," *Expert Systems with Applications*, vol. 37, no. 12, pp. 8462–8470, Dec. 2010.
- [313] G. Borowik, Z. Chaczko, and W. Jacak, *Computational Intelligence and Efficiency in Engineering Systems*, vol. 595. Cham: Springer International Publishing, 2015.
- [314] S. Garshasbi, J. Kurnitski, and Y. Mohammadi, "A hybrid Genetic Algorithm and Monte Carlo simulation approach to predict hourly energy consumption and generation by a cluster of Net Zero Energy Buildings," *Applied Energy*, vol. 179, pp. 626–637, 2016.
- [315] S. Abdi and K. Afshar, "Application of IPSO-Monte Carlo for optimal distributed generation allocation and sizing," *International Journal of Electrical Power and Energy Systems*, vol. 44, no. 1, pp. 786–797, 2013.
- [316] Z. Su, J. Wang, H. Lu, and G. Zhao, "A new hybrid model optimized by an intelligent optimization algorithm for wind speed forecasting," *Energy Conversion and Management*, vol. 85, pp. 443–452, 2014.
- [317] R. K. Sahu, S. Panda, and S. Padhan, "A hybrid firefly algorithm and pattern search technique for automatic generation control of multi area power systems," *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 9–23, Jan. 2015.
- [318] T. Niknam, "An efficient hybrid evolutionary algorithm based on PSO and ACO for distribution feeder reconfiguration," *European Transactions on Electrical Power*, vol. 36, no. E1, p. n/a-n/a, 2009.

- [319] A. J. da Silva Neto, O. Llanes Santiago, and G. N. Silva, Eds., *Mathematical Modeling and Computational Intelligence in Engineering Applications*. Cham: Springer International Publishing, 2016.
- [320] A. A. El-Dib, H. K. M. Youssef, M. M. El-Metwally, and Z. Osman, “Maximum loadability of power systems using hybrid particle swarm optimization,” *Electric Power Systems Research*, vol. 76, no. 6–7, pp. 485–492, 2006.
- [321] S. Yu, K. Wang, and Y. Wei, “A hybrid self-adaptive Particle Swarm Optimization–Genetic Algorithm–Radial Basis Function model for annual electricity demand prediction,” *Energy Conversion and Management*, vol. 91, pp. 176–185, Feb. 2015.
- [322] E. Naderi, H. Seifi, and M. S. Sepasian, “A Dynamic Approach for Distribution System Planning Considering Distributed Generation,” *IEEE Transactions on Power Delivery*, vol. 27, no. 3, pp. 1313–1322, Jul. 2012.
- [323] J. Jung and R. P. Broadwater, “Current status and future advances for wind speed and power forecasting,” *Renewable and Sustainable Energy Reviews*, vol. 31, pp. 762–777, 2014.
- [324] T. Strasser *et al.*, “Towards holistic power distribution system validation and testing—an overview and discussion of different possibilities,” *Elektrotechnik und Informationstechnik*, vol. 134, no. 1, pp. 71–77, 2017.
- [325] E. F. Saez, “Investigation of Smart Grids scenarios by the use of co-simulation tools with a European low voltage test feeder and an optimal power flow solver,” ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI), 2016.
- [326] K. Johnstone, S. M. Blair, M. H. Syed, A. Emhemed, and G. M. Burt, “A Co-Simulation Approach using Powerfactory And Matlab/Simulink to enable validation of Distributed Control Concepts within Future Power Systems,” in *24th International Conference on Electricity Distribution*, 2017, no. June, pp. 12–15.
- [327] P. Palensky, A. A. Van Der Meer, C. D. López, A. Joseph, and K. Pan, “Cosimulation of Intelligent Power Systems: Fundamentals, Software Architecture, Numerics, and Coupling,” *IEEE Industrial Electronics Magazine*, vol. 11, no. 1, pp. 34–50, 2017.
- [328] P. Palensky, A. Van Der Meer, C. Lopez, A. Joseph, and K. Pan, “Applied Cosimulation of Intelligent Power Systems: Implementing Hybrid Simulators for Complex Power Systems,” *IEEE Industrial Electronics Magazine*, vol. 11, no. 2, pp. 6–21, 2017.

- [329] C. W. J. Richter, "Generation Control: Economic Dispatch and Unit Commitment," in *POWER SYSTEM STABILITY and CONTROL*, Taylor & Francis Group, LLC., 2006, p. 18.
- [330] K. P. Ajoy and D. Popovic, *Computational Intelligence in Time Series Forecasting*. London: Springer-Verlag, 2005.
- [331] D. K. Chaturvedi, *Modeling and Simulation of Systems Using MATLAB and Simulink*. Cambridge: CRC Press, Taylor & Francis Group, 2009.
- [332] Eurorstat, "Energy, transport and environment indicators," Luxembourg, 2016.
- [333] V. Miskinis, E. Norvaisa, A. Galinis, and I. Konstantinaviciute, "Trends of distributed generation development in Lithuania," *Energy Policy*, vol. 39, no. 8, pp. 4656–4663, 2011.
- [334] M. Schwartz *et al.*, "Microgrid Integration in New York," New York, NY, 2017.
- [335] F. Hasse, A. von Perfall, T. Hillebrand, E. Smole, L. Lay, and M. Charlet, "Blockchain – an opportunity for energy producers and consumers?," 2016.
- [336] M. Merz, "Potential of the Blockchain Technology in Energy Trading," 2016.
- [337] "30-Bus System (IEEE Test Case)," 1993. [Online]. Available: <http://al-roomi.org/power-flow/30-bus-system>. [Accessed: 12-Dec-2017].
- [338] R. Christie, "30 Bus Power Flow Test Case," *Power Systems Test Case Archive*. [Online]. Available: <https://www2.ee.washington.edu/research/pstca/>. [Accessed: 12-Dec-2017].
- [339] a. a. El-Dib, H. K. M. Youssef, M. M. El-Metwally, and Z. Osman, "Optimum VAR sizing and allocation using particle swarm optimization," in *2006 IEEE Power Engineering Society General Meeting*, 2006, vol. 77, no. August 2006, pp. 1–8.
- [340] F. Ugranli and E. Karatepe, "Multiple-distributed generation planning under load uncertainty and different penetration levels," *International Journal of Electrical Power and Energy Systems*, vol. 46, no. 1, pp. 132–144, 2013.
- [341] H. Bilil, G. Aniba, and M. Maaroufi, "Probabilistic economic emission dispatch optimization of multi-sources power system," *Energy Procedia*, vol. 50, pp. 789–796, 2014.
- [342] A. R. Phadke, M. Fozdar, and K. R. Niazi, "A new multi-objective fuzzy-GA formulation for optimal placement and sizing of shunt FACTS controller," *International Journal of Electrical Power and Energy Systems*, vol. 40, no. 1, pp. 46–53, 2012.

- [343] D. Devaraj and J. P. Roselyn, "Genetic algorithm based reactive power dispatch for voltage stability improvement," *International Journal of Electrical Power & Energy Systems*, vol. 32, no. 10, pp. 1151–1156, 2010.
- [344] P. Acharjee and S. K. Goswami, "Chaotic Particle Swarm Optimization based reliable algorithm to overcome the limitations of conventional power flow methods," *2009 IEEE/PES Power Systems Conference and Exposition, PSCE 2009*, pp. 9–15, 2009.
- [345] A. Vaccaro, C. A. Cañizares, and K. Bhattacharya, "A range arithmetic-based optimization model for power flow analysis under interval uncertainty," *IEEE Transactions on Power Systems*, vol. 28, no. 2, pp. 1179–1186, 2013.
- [346] Y. Ch, S. K. Goswami, and D. Chatterjee, "Effect of network reconfiguration on power quality of distribution system," *International Journal of Electrical Power & Energy Systems*, vol. 83, pp. 87–95, 2016.
- [347] P. Kayal and C. K. Chanda, "Placement of wind and solar based DGs in distribution system for power loss minimization and voltage stability improvement," *International Journal of Electrical Power and Energy Systems*, vol. 53, pp. 795–809, 2013.
- [348] S. Gopiya Naik, D. K. Khatod, and M. P. Sharma, "Optimal allocation of combined DG and capacitor for real power loss minimization in distribution networks," *International Journal of Electrical Power and Energy Systems*, vol. 53, pp. 967–973, 2013.
- [349] M. H. Haque, "Load flow solution of distribution systems with voltage dependent load models," *Electric Power Systems Research*, vol. 36, no. 3, pp. 151–156, 1996.
- [350] H. Nasiraghdam and S. Jadid, "Optimal hybrid PV/WT/FC sizing and distribution system reconfiguration using multi-objective artificial bee colony (MOABC) algorithm," *Solar Energy*, vol. 86, no. 10, pp. 3057–3071, 2012.
- [351] N. C. Sahoo and K. Prasad, "A fuzzy genetic approach for network reconfiguration to enhance voltage stability in radial distribution systems," *Energy Conversion and Management*, vol. 47, no. 18–19, pp. 3288–3306, 2006.
- [352] N. Mithulananthan, D. Q. Hung, and K. Y. Lee, *Intelligent Network Integration of Distributed Renewable Generation*. Cham: Springer International Publishing, 2017.
- [353] S. Kollenberg and L. Taschini, "Emissions trading systems with cap adjustments," *Journal of Environmental Economics and Management*, vol. 80, pp. 20–36, 2016.

- [354] T. Korpela and T. Uotila, *EU Emission Trading Related CO₂ Monitoring in Power Plants*, vol. 47, no. 3. IFAC, 2014.
- [355] G. C. Piciu and C. L. Trică, “Trends in the Evolution of Environmental Taxes,” *Procedia Economics and Finance*, vol. 3, no. 12, pp. 716–721, 2012.
- [356] V. Solilová and D. Nerudová, “Overall Approach of the EU in the Question of Emissions: EU Emissions Trading System and CO₂ Taxation,” *Procedia Economics and Finance*, vol. 12, no. March, pp. 616–625, 2014.
- [357] R. Arbolino and O. Romano, “A Methodological Approach for Assessing Policies: The Case of the Environmental Tax Reform at European Level,” *Procedia Economics and Finance*, vol. 17, no. 14, pp. 202–210, 2014.

Popis slika

[1.]	Slika 2.1. Broj radova iz promatranog područja objavljenih u bazi ScienceDirect.....	8
[2.]	Slika 2.2. Broj radova iz promatranog područja objavljenih u bazi <i>Scopus</i>	8
[3.]	Slika 2.3 Sustav upravljanja aktivnom distributivnom mrežom prema [90]	37
[4.]	Slika 3.1. Prikaz modela grane sadržane od modela voda i transformatora u simulacijskom paketu <i>MATPOWER</i> [160]	53
[5.]	Slika 4.1 Model neurona umjetne neuronske mreže prema literaturi: a) Haykin [212]; b) Pfeifer et al. [210].....	65
[6.]	Slika 4.2. Prijenosne funkcije neurona: a) prag; b) linearna; c) sigmoidna.....	66
[7.]	Slika 4.3 Model adaptivnog linearnog neurona	67
[8.]	Slika 4.4. Unatražno rasprostiranje informacije o pogrešci izlazne veličine kod višeslojne umjetne neuronske mreže	73
[9.]	Slika 4.5. Oblik funkcija pripadnosti: a) trokutasta; b) jednočlana; c) <i>L</i> -funkcija	78
[10.]	Slika 4.6. Oblik funkcija pripadnosti: a) gamma; b) trapezoidna; c) <i>S</i> -funkcija	78
[11.]	Slika 4.7. Dijagram toka osnovne izvedbe genetskog algoritma	82
[12.]	Slika 4.8. Dijagram toka osnovne izvedbe evolucijskog algoritma.....	83
[13.]	Slika 4.9. Dijagram toka osnovne izvedbe optimizacijske metode inteligencije roja čestica.....	88
[14.]	Slika 5.1. Cjeline predloženog algoritma.....	100
[15.]	Slika 5.2. Umjetna neuronska mreža za predviđanje proizvodnje sunčanih elektrana	101
[16.]	Slika 5.3. Ocjena najbolje valjanosti modelirane umjetne neuronske mreže	104
[17.]	Slika 5.4. Regresijski pravac za proces učenja i uspoređivanja umjetne neuronske mreže.....	104
[18.]	Slika 5.5. Regresijski pravac za proces ispitivanja i za ukupnu provjeru vladanja umjetne neuronske mreže	105
[19.]	Slika 5.6. Dijagram toka predložene hibridne metode za planiranje optimalnog pogona distribuiranih izvora.....	117
[20.]	Slika 5.7. Sinteza sustava rasuđivanja korištenjem sustava neizravne logike	120
[21.]	Slika 5.8. Programski blok ocjene predloženih rješenja u programskog dodatku <i>Fuzzy Logic Designer</i>	123
[22.]	Slika 5.9. Pravila modeliranog sustava rasuđivanja prikazana plohom odlučivanja ..	123
[23.]	Slika 6.1. Ispitni sustav zasnovan na <i>IEEE</i> ispitnom sustavu od 30 čvorova [337]....	127

[24.] Slika 6.2. <i>IEEE</i> ispitni sustav od 57 čvorova.....	129
[25.] Slika 6.3. Radijalni <i>IEEE</i> ispitni sustav od 33 čvora.....	132
[26.] Slika 6.4. Izvod iz <i>Profiler</i> grafičkog sučelja programskog okruženja <i>MATLAB</i>	137
[27.] Slika 6.5. Rezultati planiranja optimalnog pogona distribuiranih izvora za slučaj ispitnog sustava od 30 čvorova i za razdoblje od 24 sata sa 30 modeliranih čestica..	138
[28.] Slika 6.6. Gubici u ispitnom sustavu od 30 čvorova za promatrani naredni period uz optimizaciju sa 30 modeliranih čestica	139
[29.] Slika 6.7. Gubici u ispitnom sustavu od 30 čvorova za promatrani naredni period uz optimizaciju sa 60 modeliranih čestica	140
[30.] Slika 6.8. Rezultati planiranja optimalnog pogona distribuiranih izvora za slučaj ispitnog sustava od 30 čvorova i za razdoblje od 24 sata sa 60 modeliranih čestica..	140
[31.] Slika 6.9. Gubici u ispitnom sustavu od 30 čvorova za promatrani naredni period uz optimizaciju sa 60 modeliranih čestica i povećanom snagom distribuirane proizvodnje	141
[32.] Slika 6.10. Rezultati planiranja optimalnog pogona distribuiranih izvora za slučaj ispitnog sustava od 30 čvorova i za razdoblje od 24 sata sa 60 modeliranih čestica i uz povećanu snagu distribuirane proizvodnje	142
[33.] Slika 6.11. Gubici u ispitnom sustavu od 57 čvorova za promatrani naredni period od 24 sata	145
[34.] Slika 6.12. Rezultati planiranja optimalnog pogona distribuiranih izvora za slučaj ispitnog sustava od 57 čvorova.....	145
[35.] Slika 6.13. Dodatna potrebna snaga po satima za čvor broj 24	146
[36.] Slika 6.14. Dodatno angažirana snaga po čvorovima za odabrano vremensko razdoblje	146
[37.] Slika 6.15. Naponski profil <i>IEEE</i> ispitnog sustava od 57 čvorova prije i nakon optimizacijskog postupka	147
[38.] Slika 6.16. Gubici nakon optimizacije u radijalnom ispitnom sustavu od 33 čvora za naredni period od 24 sata.....	148
[39.] Slika 6.17. Rezultati optimizacije radijalnog <i>IEEE</i> ispitnog sustava od 33 čvora.....	148
[40.] Slika 6.18. Dodatna potrebna snaga po satima za čvor broj 33 radijalnog ispitnog sustava od 33 čvora.....	149
[41.] Slika 6.19. Dodatno angažirana snaga za razdoblje između 12 i 13 sati za radijalni ispitni sustav od 33 čvora.....	149

[42.] Slika 6.20. Gubici nakon druge optimizacije u radijalnom ispitnom sustavu od 33 čvora za naredni period od 24 sata.....	150
[43.] Slika 6.21. Rezultati drugog postupka planiranja optimalnog pogona distribuiranih izvora za slučaj radijalnog ispitnog sustava od 33 čvora.....	150
[44.] Slika 6.22. Dodatno angažirana snaga za razdoblje između 13 i 14 sati za radijalni ispitni sustav od 33 čvora prema rezultatima druge optimizacije.....	151
[45.] Slika 6.23. Naponski profil radijalnog <i>IEEE</i> ispitnog sustava prije i nakon postupaka optimizacije.....	152
[46.] Slika 6.24. Rezultati sustava rasuđivanja za prvu optimizaciju radijalnog <i>IEEE</i> sustava	153
[47.] Slika 6.25. Rezultati sustava rasuđivanja za drugu optimizaciju radijalnog <i>IEEE</i> sustava.....	155

Popis tablica

[1.]	Tablica 2.1 Pregled bitnih svojstava tehnologija distribuirane proizvodnje [7].....	12
[2.]	Tablica 2.2 Usporedni prikaz rezultata predviđanja potrošnje električne energije.....	46
[3.]	Tablica 3.1. Vrijeme izvođenja pojedinih paketa otvorenog koda prilikom analize elektroenergetskog sustava [129].....	49
[4.]	Tablica 3.2. Ispitni sustavi sadržani u simulacijskom paketu <i>MATPOWER</i> 4.1 [156].	51
[5.]	Tablica 3.3. Primjer modeliranih parametara za čvorove ispitnog sustava <i>case4gs</i> simulacijskog paketa <i>MATPOWER</i>	52
[6.]	Tablica 3.4. Primjer modeliranih parametara za čvorove <i>IEEE</i> ispitnog sustava od 118 čvorova simulacijskog paketa <i>MATPOWER</i>	54
[7.]	Tablica 3.5. Primjer modeliranih parametara za čvorove <i>IEEE</i> ispitnog sustava od 30 čvorova simulacijskog paketa <i>MATPOWER</i>	57
[8.]	Tablica 4.1. Prikaz osnovne strukture izvođenja metoda evolucijskog programiranja	81
[9.]	Tablica 4.2 Prikaz strukture izvođenja optimizacije genetskim algoritmom uz razmjernu selekciju jedinki	86
[10.]	Tablica 4.3 Prikaz osnovne strukture izvođenja optimizacije metodom roja čestica ...	95
[11.]	Tablica 5.1. Vrijednosti proizvodnje sunčane elektrane dobivene modeliranom umjetnom neuronskom mrežom za vremenski period od jednog dana	103
[12.]	Tablica 5.2. Prikaz strukture izvođenja hibridne optimizacijske metode inteligencije roja čestica	106
[13.]	Tablica 5.3. Skup pravila obrade ulaznih veličina predloženim sustavom rasuđivanja	121
[14.]	Tablica 6.1. Parametri obuhvaćeni optimizacijskom metodom i predloženim algoritmom.....	125
[15.]	Tablica 6.2. Podaci o čvorovima i potrošačima ispitnog sustava od 30 čvorova	128
[16.]	Tablica 6.3. Podaci o vodovima ispitnog sustava od 30 čvorova	128
[17.]	Tablica 6.4. Podaci o čvorovima i potrošačima <i>IEEE</i> ispitnog sustava od 57 čvorova	130
[18.]	Tablica 6.5. Podaci o vodovima <i>IEEE</i> ispitnog sustava od 57 čvorova	130
[19.]	Tablica 6.6. Podaci o čvorovima i potrošačima radijalnog <i>IEEE</i> ispitnog sustava od 33 čvora.....	132
[20.]	Tablica 6.7. Podaci o vodovima radijalnog <i>IEEE</i> ispitnog sustava od 33 čvora	133

[21.] Tablica 6.8. Podaci o čvorovima i potrošačima modificiranog <i>IEEE</i> ispitnog sustava od 57 čvorova.....	144
[22.] Tablica 6.9. Lingvističke vrijednosti rezultata rasuđivanja za prvu optimizaciju radijalnog <i>IEEE</i> ispitnog sustava od 33 čvora	154
[23.] Tablica 6.10. Lingvističke vrijednosti rezultata rasuđivanja za drugu optimizaciju radijalnog <i>IEEE</i> ispitnog sustava od 33 čvora	155

Sažetak

U doktorskom radu predstavljen je algoritam kratkoročnog planiranja pogona distribuiranih izvora koji ima za cilj smanjenje tehničkih gubitaka radne snage u aktivnoj distributivnoj mreži. Predloženi algoritam se sastoji od tri cjeline realizirane metodama računalne inteligencije: predviđanja proizvodnje sunčanih elektrana, planiranja optimalnog pogona hibridnih distribuiranih izvora i ocjenjivanja optimizacijskih rješenja. Predviđanje proizvodnje sunčanih elektrana realizirano je modeliranjem višeslojne umjetne neuronske mreže koja temeljem ulaznih podataka o temperaturi zraka, intenzitetu sunčevog zračenja, relativnoj vlažnosti zraka i brzini vjetra pruža podataka o očekivanoj proizvodnji sunčane elektrane. Planiranje optimalnog pogona najsloženiji je dio predloženog algoritma jer podrazumijeva jedinstvenu hibridnu optimizacijsku metodu zasnovanu na inteligenciji roja čestica uz uvažavanje načela *elitizma* iz genetskog algoritma. Sa optimizacijskom metodom *hibridiziran* je simulacijski paket *MATPOWER* koji se koristi za modeliranje ispitnih elektroenergetskih sustava, proračune tokova snaga i tehničko određivanje distribuirane proizvodnje prema parametrima čestica optimizacijske metode. Ocjenjivanje optimizacijskih rješenja treća je cjelina predloženog algoritma, realizirana sustavom neizravne logike, a pruža ocjenu troškovne učinkovitosti planiranog pogona distribuiranih izvora s obzirom na uštede postignute smanjenjem gubitaka radne snage. Predloženi algoritam kratkoročnog planiranja uspješno je primijenjen u postupcima optimizacije i planiranja pogona distribuiranih izvora na tri ispitna elektroenergetska sustava te potpunu primjenjivost dokazuje visokom razinom učinkovitosti optimizacije aktivnih radijalnih i prstenasto-povezanih elektroenergetskih mreža.

Ključne riječi: aktivna distributivna mreže, distribuirana proizvodnja, inteligencija roja čestica, kratkoročno planiranje, napredne elektroenergetske mreže, optimiranje, optimalni pogon distribuirane proizvodnje, računalna inteligencija, sustavi neizravne logike, umjetna neuronska mreža

Abstract

The doctoral thesis presents an algorithm for distributed generation short-term planning aimed at reducing the active power technical losses in the distribution network. The proposed algorithm consists of three parts: prediction of solar power plants energy production, optimal operation planning of multiple hybrid distributed generation units, and evaluation of optimization results. Prediction of solar power plants energy production is achieved by modelling multilayer artificial neural network capable of providing the information on expected solar power generation based on input data on air temperature, solar irradiation, relative air humidity, and wind speed. Optimal operation planning of distributed generation is the most complex part of the proposed algorithm because it implies a unique hybrid optimization method based on particle swarm optimization with respect to the elitism principle of the genetic algorithm. The *MATPOWER* simulation package, which is used for test power systems modelling, power flow calculations, and the technical determination of distributed generation according to the particle parameters, has been hybridized within the optimization method. Evaluation of optimal solutions is a third part of the proposed algorithm, achieved by fuzzy logic system, which provides the evaluation of cost efficiency for the planned operation of distributed generation with respect to savings achieved by active power losses reduction. The proposed short-term planning algorithm has been successfully applied in the optimization and planning of distributed generation in three test power systems, and full applicability is proved by a high level of optimization efficiency of active radial and meshed power networks.

Keywords: active distribution networks, artificial neural network, distributed generation, computational intelligence, fuzzy logic system, optimal operation of distributed generation, optimization, particle swarm optimization, short-term planning, smart grid

Životopis

Marko Vukobratović rođen je u Osijeku 09. listopada 1985. godine. Osnovnu školu završio je s odličnim uspjehom u Belišću, a Opću gimnaziju 2004. godine u Valpovu. Iste godine upisuje sveučilišni dodiplomski studij elektrotehnike Elektrotehničkog fakulteta u Osijeku, a zbog obiteljskih razloga studiranje na drugoj godini nastavlja na trogodišnjem stručnom studiju smjera elektroenergetika.

Stručni studij završava 2007. godine obranom diplomskog rada pod nazivom „Inteligentne električne instalacije KNX/EIB i primjena u zgradarstvu“, izrađenim pod mentorstvom prof.dr.sc. Lajos Jozse. U sklopu ovog diplomskog rada predložio je projektno rješenje KNX/EIB laboratorija Elektrotehničkog fakulteta u Osijeku te je iznio teorijska i praktična razmatranja na temelju kojih je objavljena skripta Elektrotehničkog fakulteta u Osijeku pod nazivom „Inteligentne instalacije - European Installation Bus za sustave u zgradarstvu“.

Po završetku stručnog studija i stjecanja zvanja inženjera elektrotehnike upisuje Razlikovnu godinu. Obveze Razlikovne godine ispunjava sljedeće, 2008. godine čime stječe zvanje sveučilišnog prvostupnika. Iste godine kao izvanredni student upisuje sveučilišni diplomski studij elektrotehnike, smjer elektroenergetika.

Diplomski studij završava 2012. godine s temom diplomskog rada „Tehno-ekonomska analiza fotonaponske elektrane 100 kW“, izrađenim pod mentorstvom prof.dr.sc. Damira Šljivca. Iste godine upisuje poslijediplomski doktorski studij znanstvenog polja elektrotehnike, smjera elektroenergetika.

U studenom 2007. godine zaposlen je na radno mjesto višeg laboranta pri Zavodu za elektroenergetiku Elektrotehničkog fakulteta u Osijeku gdje aktivno sudjeluje u izvođenju nastave, izradi stručnih elaborata i objavi stručnih radova. Stručni rad pod nazivom „Energetski potencijali i trenutne aktivnosti korištenja biomase i bioplina u istočnoj Hrvatskoj“ hrvatski ogranak međunarodne elektrodistribucijske konferencije – CIRED, predlaže za istaknutu prijavu na 20. međunarodnoj CIRED konferenciji u Pragu. Posebno se ističe zalaganjem u Programu informatičkog obrazovanja i usavršavanja Elektrotehničkog fakulteta u Osijeku pri kojem uspješno provodi akreditaciju navede ustanove kao *Autodesk – Authorized Training Centre*.

Od 2012. godine zaposlen je na radno mjesto asistenta pri Zavodu za elektroenergetiku Elektrotehničkog fakulteta u Osijeku gdje sudjeluje na dva znanstveno-istraživačka projekta: *UNIREG – IMPULSE* i *Zajedničkom projektu edukacije i istraživanja u području obnovljivih izvora energije s ciljem daljnjeg razvoja panonskog dijela Srbije i Hrvatske*.

Do sada je objavio devet znanstvenih radova u časopisima od kojih su tri rada blisko vezana uz temu doktorske disertacije:

- [1.] Vukobratović, Marko; Marić, Predrag; Hederić, Željko.
Voltage and power losses control using distributed generation and computational intelligence, Tehnički vjesnik, 23 (2016) , 4; 937-944.
- [2.] Vukobratović, Marko; Nikolovski, Srete; Marić, Predrag.
Improving the Conditions in a Radial Distribution Feeder by Implementing Distributed Generation, International Journal of Electrical and Computer Engineering Systems. 6 (2015) , 1; 1-7
- [3.] Vukobratović, Marko; Marić, Predrag; Hederić, Željko
Optimization Method for Control of Voltage Level and Active Power Losses Based on Optimal Distributed Generation Placement using Artificial Neural Networks and Genetic Algorithms, Journal of Energy Technology. 6 (2013) , 4; 11-30

Kao autor ili koautor objavio je dvanaest radova na znanstvenim i stručnim konferencijama od kojih tri rada bliska temi doktorske disertacije:

- [1.] Vukobratović, Marko; Hederić, Željko; Hadžiselimović, Miralem.
Optimal Distributed Generation Placement in Distribution Network, Proceedings EnergyCon 2014 - IEEE International Energy Conference, ur.: Kuzle, Igor ; Capuder, Tomislav ; Pandžić, Hrvoje, Red Hook, NY 12571 USA: IEEE, 2014. 1236-1243.
- [2.] Barukčić, Marinko; Vukobratović, Marko; Masle, Dino; Buljić, Dalibor; Hederić, Željko.
The evolutionary optimization approach for voltage profile estimation in a radial distribution network with a decreased number of measurements, 15th International Conference on Electrical Machines, Drives and Power Systems - ELMA 2017, IEEE Proceedings of., ur.: Lazarov, Vladimir ; Aprahamian, Bohos, Sofia, 2017. 26-31.

[3.] Barukčić, Marinko; Vukobratović, Marko; Benšić Tin.

Evolutionary Optimization Approach for Performing Interval Power Flow Considering Uncertainties in Electric Power Systems, Proceedings of 2016 International Conference on Smart Systems and Technologies (SST), ur.: Žagar, Drago ; Martinović, Goran ; Rimac Drlje, Snježana, Osijek: Faculty of Electrical Engineering, Computer Science and Information Technology Osijek, 2016. 185-190.

Dodatno se stručno usavršavao pohađanjem tečajeva *Projektant u Eplan P8 Electric programskom alatu* 2012. godine u Zagrebu, *ST-TIA programer u SIMATIC okruženju* 2008. godine u Osijeku, *Projektant KNX/EIB električne instalacije* 2007. godine u Budimpešti, Mađarska te *AutoCAD 2D & 3D dizajner* 2006. godine u Osijeku.

Stručnu aktivnost obavljao je pri Fakultetu elektrotehnike, računarstva i informacijskih tehnologija u Osijeku kroz sudjelovanje u izradi osamnaest tehničkih elaborata i studija.

Oženjen je i otac četvero djece, dva sina i dvije kćeri.