POBOLJŠANI MODEL ZA PLANIRANJE NISKONAPONSKIH DISTRIBUCIJSKIH MREŽA KOMBINIRANJEM HIJERARHIJSKIH I STOHASTIČKIH OPTIMIZACIJSKIH METODA

Softić, Amir

Doctoral thesis / Disertacija

2017

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://urn.nsk.hr/urn:nbn:hr:200:606876

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-16**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ELEKTROTEHNIČKI FAKULTET OSIJEK
Poslijediplomski sveučilišni studij Elektrotehnika

Amir Softić

POBOLJŠANI MODEL ZA PLANIRANJE NISKONAPONSKIH DISTRIBUCIJSKIH MREŽA KOMBINIRANJEM HIJERARHIJSKIH I STOHASTIČKIH OPTIMIZACIJSKIH METODA

Doktorska disertacija

Osijek, 2016.

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ELEKTROTEHNIČKI FAKULTET OSIJEK
Poslijediplomski sveučilišni studij Elektrotehnika

Amir Softić

POBOLJŠANI MODEL ZA PLANIRANJE NISKONAPONSKIH DISTRIBUCIJSKIH MREŽA KOMBINIRANJEM HIJERARHIJSKIH I STOHASTIČKIH OPTIMIZACIJSKIH METODA

Doktorska disertacija

Osijek, 2016.

Doktorska disertacija izrađena je na Zavodu za elektroenergetiku
Elektrotehničkog fakulteta u Osijeku

Mentor: prof. dr. sc. Marinko Stojkov

Doktorska disertacija ima 271 stranicu.

Disertacija br.: 53

Povjerenstvo za ocjenu doktorske disertacije:

1. Dr. sc. Damir Šljivac, redoviti profesor, predsjednik, Elektrotehnički fakultet Osijek
2. Dr. sc. Marinko Stojkov, redoviti profesor, mentor, Strojarski fakultet Slavonski Brod
3. Dr. sc. Ivica Pavić, redoviti profesor, član, Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu

Povjerenstvo za obranu doktorske disertacije:

1. Dr. sc. Damir Šljivac, redoviti profesor, predsjednik, Elektrotehnički fakultet Osijek
2. Dr. sc. Marinko Stojkov, redoviti profesor, mentor, Strojarski fakultet Slavonski Brod
3. Dr. sc. Ivica Pavić, redoviti profesor, član, Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu
4. Dr. sc. Zvonimir Klaić, docent, član, Elektrotehnički fakultet Osijek
5. Dr. sc. Danijel Topić, docent, član, Elektrotehnički fakultet Osijek

Srdačno se zahvaljujem prof. dr. sc. Marinku Stojkovu
na svesrdnoj pomoći pri izradi ove doktorske disertacije

SADRŽAJ

1. UVOD 1

2. DISTRIBUCIJSKE MREŽE 6

2.1. STRUKTURA DISTRIBUCIJSKIH MREŽA 6

2.2. NISKONAPONSKE DISTRIBUCIJSKE MREŽE 9

2.2.1. Transformatorske stanice 10

2.2.2. Niskonaponski vodovi 11

2.2.3. Niskonaponski potrošači 12

2.3. ENERGETSKI PRORAČUNI U NISKONAPONSKIM DISTRIBUCIJSKIM MREŽAMA 14

2.3.1. Proračun opterećenja potrošača 14

2.3.2. Proračun gubitaka snage i energije 17

2.3.3. Proračun padova napona 18

2.3.4. Odabir snage transformatora 19

2.3.5. Proračun tokova struja i odabir tipa vodiča 19

2.4. PLANIRANJE DISTRIBUCIJSKIH SUSTAVA 20

2.4.1. Matematički modeli planiranja 20

2.4.2. Planiranje niskonaponskih distribucijskih mreža 20

2.4.3. Opći kriteriji planiranja 22

2.4.4. Tehnički kriteriji planiranja 23

2.4.5. Ekonomski kriteriji planiranja 23

2.4.6. Kriterij pouzdanosti napajanja 25

3. HIJERARHIJSKE I STOHASTIČKE METODE OPTIMIZACIJE 28

3.1. OPĆENITO O OPTIMIZACIJI 28

3.1.1. Formuliranje problema optimizacije 28

3.1.2. Klasificiranje optimizacijskih problema 30

3.1.3. Pregled optimizacijskih metoda 33

3.2. HIJERARHIJSKE METODE OPTIMIZACIJE 41

3.2.1. Općenito o hijerarhijskim optimizacijskim metodama 41
3.2.2. Analitički hijerarhijski postupak (AHP) 42
3.2.3. Metoda neizrazitog grupiranja 52
3.3. STOHASTIČKE METODE OPTIMIZACIJE 67
3.3.1. Općenito o stohastičkim optimizacijskim metodama 67
3.3.2. Algoritam simuliranog kaljenja 68
4. MODEL PLANIRANJA NISKONAPONSKIH DISTRIBUCIJSKIH MREŽA 83
4.1. OPĆENITO O MODELIMA PLANIRANJA 83
4.2. DIJAGRAM TOKA 84
4.3. KORACI PREDLOŽENOG MODELA PREMA DIJAGRAMU TOKA 86
4.3.1. Ulazni podaci 86
4.3.2. Formiranje alternativa 88
4.3.3. Formiranje mrežne topologije 93
4.3.4. Proračuni – formiranje kriterija 95
4.3.5. Rangiranje kriterija i alternativa 97
4.3.6. Optimalno rješenje 99
5. PRAKTIČNI PRIMJER PRIMJENE MODELA PLANIRANJA 105
5.1. ULAZNI PODACI 106
5.2. PRORAČUN OPTEREĆENJA POTROŠAČA 109
5.3. ODREĐIVANJE LOKACIJE TRANSFORMATORSKE STANICE 113
5.4. ODREĐIVANJE NISKONAPONSKIH IZVODA 114
5.5. FORMIRANJE MREŽNE TOPOLOGIJE 119
5.6. FORMIRANJE KRITERIJA 124
5.6.1. Padovi napona kod krajnjih potrošača 125
5.6.2. Gubici snage 126
5.6.3. Opterećenje vodova 126
5.6.4. Investicijski troškovi 127
5.7. RANGIRANJE 130
5.7.1. Rangiranje kriterija 130
5.7.2. Rangiranje alternativa 132

5.8. OPTIMALNO RJEŠENJE 136
5.9. UTJECAJ OPTEREĆENJA POTROŠAČA NA PROSTORNO RJEŠENJE 141
5.9.1. Minimalno opterećenje transformatorske stanice 142
5.9.2. Opterećenje transformatorske stanice u proljetnom periodu 143
5.9.3. Opterećenje transformatorske stanice u ljetnom periodu 145
5.9.4. Opterećenje transformatorske stanice u jesenskom periodu 147
5.9.5. Opterećenje transformatorske stanice u zimskom periodu 149
5.10. UTJECAJ NESIMETRIJE NA PROSTORNO RJEŠENJE 151
5.10.1. Prostorno rješenje pri maksimalnoj vrijednosti nesimetrije 154
5.10.2. Prostorno rješenje pri minimalnoj vrijednosti nesimetrije 156
5.10.3. Prostorno rješenje pri prosječnoj vrijednosti nesimetrije 158
5.10.4. Prostorno rješenje pri najvjerojatnijoj vrijednosti nesimetrije 160
5.11. PROSTORNO RJEŠENJE PRI IZGRADNJI NOVIH MREŽA 161
5.11.1. Prosječno istodobno opterećenje potrošača 162
5.11.2. Maksimalno istodobno opterećenje potrošača 164
5.11.3. Minimalno istodobno opterećenje potrošača 166
5.12. UTJECAJ PROMJENE OPTEREĆENJA POTROŠAČA NA OPTIMALNO RJEŠENJE 167
5.13. USPOREDBA REZULTATA SA POSTOJEĆOM MREŽOM – POTVRDA MODELA 168
5.13.1. Usporedba rezultata padova napona 169
5.13.2. Usporedba rezultata gubitaka radne snage 179
5.13.3. Ekonomski pokazatelji primjene modela planiranja 185
6. ZAKLJUČAK 191
SAŽETAK 196
ABSTRACT 197
LITERATURA 198
POPIS KRATICA 204
POPIS SLIKA 207
POPIS TABLICA 210
PRILOG 1. Zemljopisne koordinate mjernih mjesta 215
PRILOG 2. Pojedinačna utrošena godišnja energija niskonaponskih potrošača 217

PRILOG 3. Jednodnevno, satno mjerenje opterećenja transformatorske stanice i niskonaponskih izvoda (period vršnog opterećenja) 218

PRILOG 4. Pojedinačno godišnje vršno opterećenje niskonaponskih potrošača 219

PRILOG 5. Zemljopisne koordinate stupnih mjesta mreže sa 5 niskonaponskih izvoda 220

PRILOG 6. Zemljopisne koordinate stupnih mjesta mreže sa 6 niskonaponskih izvoda 221

PRILOG 7. Zemljopisne koordinate stupnih mjesta mreže sa 7 niskonaponskih izvoda 223

PRILOG 8. Zemljopisne koordinate stupnih mjesta mreže sa 8 niskonaponskih izvoda 224

PRILOG 9. Duljine i presjeci dionica distribucijske mreže sa 5 niskonaponskih izvoda 226

PRILOG 10. Duljine i presjeci dionica distribucijske mreže sa 6 niskonaponskih izvoda 228

PRILOG 11. Duljine i presjeci dionica distribucijske mreže sa 7 niskonaponskih izvoda 231

PRILOG 12. Duljine i presjeci dionica distribucijske mreže sa 8 niskonaponskih izvoda 234

PRILOG 13. Godišnje vršno opterećenje potrošača – podaci za Matpower 237

PRILOG 14. Dionice distribucijske mreže sa 5 niskonaponskih izvoda – podaci za Matpower 238

PRILOG 15. Dionice distribucijske mreže sa 6 niskonaponskih izvoda – podaci za Matpower 241

PRILOG 16. Dionice distribucijske mreže sa 7 niskonaponskih izvoda – podaci za Matpower 243

PRILOG 17. Dionice distribucijske mreže sa 8 niskonaponskih izvoda – podaci za Matpower 246

PRILOG 18. Opterećenje potrošača (sabirnica) – podaci za metodu simuliranog kaljenja 249

PRILOG 19. Dionice najbolje prostorne distribucijske mreže – podaci za metodu simuliranog kaljenja 252

PRILOG 20. Minimalno godišnje opterećenje potrošača – podaci za Matpower 255

PRILOG 21. Vršno opterećenje potrošača u periodu proljeća – podaci za Matpower 256

PRILOG 22. Vršno opterećenje potrošača u periodu ljeta – podaci za Matpower 258

PRILOG 23. Vršno opterećenje potrošača u periodu jeseni – podaci za Matpower 259

PRILOG 24. Vršno opterećenje potrošača u periodu zime – podaci za Matpower 261

PRILOG 25. Opterećenje potrošača pri maksimalnoj vrijednosti nesimetrije – podaci za Matpower 263

PRILOG 26. Opterećenje potrošača pri minimalnoj vrijednosti nesimetrije – podaci za Matpower 264

PRILOG 27. Opterećenje potrošača pri prosječnoj vrijednosti nesimetrije – podaci za Matpower 266

PRILOG 28. Opterećenje potrošača pri najvjerojatnijoj vrijednosti nesimetrije – podaci za Matpower 267

ŽIVOTOPIS 270

1. UVOD

Elektroenergetski sustav čine proizvodnja, prijenos, distribucija i potrošnja električne energije i njegova temeljna zadaća je pouzdana i kvalitetna opskrba električnom energijom svih kupaca. Ovaj sustav je najrasprostranjeniji od svih tehničkih sustava, te je zbog svoje kompleksnosti i najskuplji. Elektroenergetska mreža može se definirati kao uži dio elektroenergetskog sustava koja obuhvaća elemente preko kojih se direktno proizvodi, prenosi, distribuira i troši električna energije, odnosno generatori, vodovi, transformatori i trošila. Elektroenergetska mreža se u različitim analizama nikada ne promatra u cjelini, već samo pojedini (manji) dijelovi, dok se ostatak nadomješta s većom ili manjom točnošću na fizikalno prihvatljiv način.

U uvjetima deregulacije tržišta izuzetan značaj imaju kriteriji pouzdanosti, ekonomičnosti i sigurnosti u snabdijevanju krajnjih potrošača kvalitetnom električnom energijom. Proces deregulacije tržišta je proces kojim se liberaliziraju i demonopoliziraju tržište i utjecaj tržišnih subjekata kako bi se stvorilo tržište sa većom učinkovitošću i nižim cijenama električne energije. Za razliku od monopolističke organizacije elektroenergetskog sektora potrebno je razdvojiti tržišne djelatnosti od djelatnosti sa obilježjima prirodnog monopola [1]. Tržišne djelatnosti je potrebno liberalizirati i omogućiti ravnopravno učešće svih sudionika tržišta. Potencijalne tržišne djelatnosti kod kojih je moguć razvoj tržišta su proizvodnja, trgovina i opskrba električnom energijom. Djelatnostima prirodnog monopola pripadaju prijenos i distribucija električne energije [2]. One imaju status prirodnog monopola obzirom da su neophodne za povezivanje mjesta proizvodnje i mjesta potrošnje električne energije.

Stalno povećanje potražnje za električnom energijom stvara potrebu za izgradnjom novih i unapređenjem postojećih objekata elektroenergetskog sustava. Kako bi se opravdala velika ulaganja potrebno je praviti projekte ekonomske isplativosti i do 20 godina unaprijed. Dakle, u novim uvjetima tržišnog poslovanja planiranje elektroenergetskog sustava, bilo kratkoročno, srednjoročno ili dugoročno, zauzima bitno mjesto u cjelokupnoj strategiji elektrodistribucijske tvrtke.

Izradom matematičkih modela koji opisuju trenutačno stanje sustava moguće je dobiti najbolja rješenja koja su najučinkovitija za tvrtku, ali koja istovremeno mogu osigurati najkvalitetnije i najpouzdanije snabdijevanje svih potrošača električnom energijom. Odluka o izboru modela ili simulacijske tehnike ovisi o karakteristikama sustava i željenim ulaznim, odnosno izlaznim parametrima. Izlazni rezultati ovakvih modela namijenjeni su osobama odgovornim za projekt kako bi mogli donijeti odluku o njegovoj izgradnji ili ne izgradnji.

Budući razvoj energetskog sustava mora zadovoljiti niz različitih ciljeva. Prije svega, elektroenergetski sustav mora biti ekonomski učinkovit, mora osigurati pouzdanu opskrbu krajnjih potrošača i ne bi trebao imati negativnih utjecaja na okolinu. Pored ovih, općih ciljeva, postoji i veći broj dodatnih ciljeva i kriterija. U isto vrijeme, na rad i razvoj sustava utječu različiti neizvjesni i slučajni faktori. Stoga se u konačnici često dobiva veći broj mogućih alternativa (varijanti). Iz cjelokupne skupine mogućih rješenja planer nastoji da pronađe

najbolju ili u ovisnosti o prihvaćenim uvjetima optimalnu alternativu. U biti, to je složen problem povezan sa višestrukim ciljevima, nesigurnostima i većim brojem promjenjivih veličina. Obzirom da se radi o složenom problemu planer se, u biti, susreće sa multikriterijskim optimizacijskim zadatkom.

Proces planiranja sastoji se od nekoliko koraka temeljem kojih se, sukladno zadanim kriterijima, dobiva niz prigodnih alternativa [3]:

1. Identificiranje problema – definiranje opsega primjene i ograničenja;
2. Određivanje ciljeva – definiranje što treba minimizirati;
3. Identificiranje alternativa – koje su dostupne opcije;
4. Proračun alternativa – proračun svih mogućnosti;
5. Odabir najbolje alternative – izbor opcije koja najbolje zadovoljava ciljeve;
6. Donošenje konačne odluke – temeljem dobivenih rezultata odabir alternative koja će se u konačnici i provesti.

U ovoj disertaciji bit će predočen novi, poboljšani model planiranja niskonaponskih distribucijskih mreža temeljen na višekriterijskom odlučivanju, uz uporabu suvremenih optimizacijskih metoda.

Niskonaponske distribucijske mreže karakterizira niža naponska razina u odnosu na prijenosne i srednjenaponske mreže, smanjena pogonska sigurnost, izostanak dvostranog napajanja, mala opterećenja potrošača, česta uporaba zračnih vodova, te veća duljina niskonaponskih izvoda. Najčešći problemi koji se javljaju kod ovih mreža u vezi su sa kvalitetom i gubicima električne energije. Rješavanje ovih problema je izazov za distribucijske tvrtke obzirom da su u tržišnim uvjetima poslovanja obvezne isporučiti kvalitetnu električnu energiju do krajnjih kupaca, ali istovremeno vodeći računa i o vlastitim interesima.

Planiranjem niskonaponskih distribucijskih mreža nastoji se odrediti optimalna konfiguracija mreže za snabdijevanje električnom energijom potrošača raspoređenih na određenom zemljopisnom području. U biti, sastoji se od određivanja veličine i lokacije transformatorske stanice, tipova vodiča koje je potrebno upotrijebiti, te prostorne konfiguracije mreže. Dakle, temeljni cilj je pronalaženje radijalne konfiguracije mreže sa najnižim ukupnim troškovima, pri čemu se mora voditi računa o veličini i lokaciji transformatorske stanice, smjerovima rasprostiranja i kapacitetu niskonaponskih vodova kojima se snabdijevaju prostorno raspoređeni potrošači s određenim prognoziranim opterećenjem, toplinskim ograničenjima koja su u vezi sa izdržljivošću uređaja i opreme u transformatorskoj stanici i niskonaponskih vodova, te naponskim razinama.

Kako bi se dobile prigodne alternative potrebno se držati određenih kriterija. Definiranje kriterija temelji se na procjeni planera pri čemu se mora voditi računa kako o interesima potrošača tako i o interesima tvrtke. Za razliku od monopolističkog sustava, u tržišnim uvjetima poslovanja zahtjevi potrošača za kvalitetnom i sigurnom isporukom električne energije dolaze u prvi plan.

U predloženom modelu planiranja u razmatranje su uzeta četiri kriterija temeljem kojih se dobivaju najbolje alternative, a to su:

1. Padovi napona kod krajnjih potrošača;
2. Gubici radne snage u distributivnim vodovima;
3. Investicijski troškovi izgradnje mreže;
4. Propusna moć distributivnih vodova.

U uvjetima tržišnog poslovanja, kada kvaliteta električne energije koja se isporučuje krajnjim kupcima ima jednu od najvažnijih uloga, kao primarni cilj kod planiranja niskonaponskih distribucijskih mreža uspostavlja se dovođenje razine napona kod svakog potrošača u granice sukladne propisanoj normi. Nakon toga, gledano iz kuta distribucijske tvrtke, kao naredni cilj uspostavlja se dovođenje gubitaka u mreži na što nižu razinu, što se može postići pravilnim odabirom vrste vodiča i optimalnom prostornom razdiobom niskonaponske distribucijske mreže. Naravno, od značaja za distribucijsku tvrtku su i troškovi izgradnje jedne ovakve mreže, ali u tržišnim uvjetima zahtjevi kupaca su prioritetni tako da ovi troškovi nisu u prvom planu. Na kraju, od značaja je i kapacitet, odnosno propusna moć niskonaponskih vodova, koji limitiraju iznos opterećenja koja moraju prenijeti do krajnjih kupaca. Ovakav problem može se riješiti adekvatnim odabirom tipova i presjeka vodiča. Dakle, radi se o kompleksnom problemu gdje je istovremeno potrebno riješiti pitanje optimalne lokacije transformatorske stanice i konfiguracije niskonaponske mreže, ali uz uvažavanje spomenutih kriterija.

U biti, odabir kriterija ovisi o tome što se želi postići kao krajnji cilj i stvar su subjektivne procjene onoga tko vrši planiranje. Cilj planiranja niskonaponskih distribucijskih mreža je konstruiranje mreže koja će zadovoljiti prognozirane potrebe potrošača za električnom energijom na siguran, pouzdan i učinkovit način. Kako bi se postigao ovaj cilj nastoje se minimizirati investicijski troškovi i troškovi gubitaka, uz uvažavanje ograničenja koja uključuju kapacitet opreme (vodova), maksimalne padove napona i radijalnu konfiguraciju mreže [4].

U ovome trenutku postoji vrlo malo (gotovo da i ne postoje u dostupnoj literaturi) modela za planiranje niskonaponskih distribucijskih mreža. Oni se u praksi najčešće i ne primjenjuju jer nisu naišli na potporu distribucijskih tvrtki, obzirom da je financijska dobit od poboljšanog planiranja relativno mala kada se promatraju pojedinačna transformatorska područja. Međutim, promatrajući cjelokupnu elektroenergetsku mrežu i stanje u njoj, ekonomski pokazatelji su drugačiji. Pravilnom primjenom i mogućnošću različitog vrednovanja kriterija model nudi niz rješenja iz kojih se može dobiti jedinstveno, optimalno rješenje, što u dosadašnjem načinu izgradnje i razvoja niskonaponskih distribucijskih mreža nije bilo moguće.

Temeljna teza ove doktorske disertacije je da do sada za niskonaponsku distribucijsku mrežu nisu rađeni/prihvaćeni jedinstveni modeli planiranja rekonstrukcije i izgradnje ovakvih mreža, tako da je cilj disertacije izrada jednog takvog modela. Taj model će davati rješenja kod kojih su padovi napona kod krajnjih potrošača sukladni propisanim normama, što je u uvjetima tržišnog poslovanja od velikog značaja. Isto tako, model će ponuditi rješenja sa najmanjim

gubicima snage, što je vrlo važno za distribucijsku tvrtku jer se na taj način ostvaruju financijske uštede, čime se stvaraju uvjeti za ostvarivanje veće dobiti, te omogućava preusmjeravanje financijskih sredstava za druge potrebe. Primjenom jednog ovakvog modela planiranja distribucijske tvrtke mogu unaprijed planirati potrebna sredstva za rekonstrukciju, odnosno izgradnju distribucijske mreže.

Dakle, ova disertacija će dati jedan prihvatljiv i lako primjenjiv model kojim će biti riješena pitanja:

- izbora instalirane snage i optimalne lokacije transformatorske stanice,
- određivanja broja niskonaponskih izvoda iz transformatorske stanice potrebnih za napajanje potrošača,
- prostornog rasprostiranja niskonaponske distribucijske mreže,
- izbora tipa i presjeka niskonaponskih vodova,
- izbora najpovoljnije prostorne konfiguracije distribucijske mreže,
- određivanja optimalnog uklopnog stanja niskonaponske distribucijske mreže obzirom na iznos gubitaka u mreži i padove napona kod krajnjih potrošača.

Pošto se radi o višekriterijskom odlučivanju, sa nizom nesigurnosti i ograničenja tipa jednakosti i nejednakosti, kao vrlo prigodne za primjenu u modelu planiranja nameću se suvremene optimizacijske metode koje se upravo temelje na rješavanju ovakvih složenih problema. Izrada matematičkih modela koji koriste optimizacijske algoritme zahtijeva poznavanje energetskog sustava i njegovih fizikalnih svojstava, ali i poznavanje matematičkih formulacija problema koji se u njemu pojavljuju. Najčešće korištene optimizacijske metode su [5]:

- Umjetna inteligencija;
- Ekspertni sustavi;
- Neuronske mreže;
- Genetski algoritmi.

Svaki od ovih algoritama ima svoje prednosti i nedostatke, a njihova primjena ovisi o odluci planera. Uporaba umjetne inteligencije zahtijeva dobar opis problema, dok ekspertni sustavi nemaju mogućnost učenja za razliku od neuronskih mreža i genetskih algoritama itd.

Obzirom na kompleksnost problema planiranja, karakter varijabli koje se pojavljuju i njihovu slučajnu prirodu, promjenjivost parametara (opterećenje, padovi napona), u predloženom modelu planiranja se primjenjuju hijerarhijske i stohastičke optimizacijske metode.

Za određivanje prostorne lokacije transformatorske stanice u predloženom modelu planiranja koristi se metoda neizrazitog grupiranja (*eng. fuzzy clustering*). Ova metoda pripada skupinama i hijerarhijskih i stohastičkih metoda. Metoda je, isto tako, vrlo prigodna za prostorno grupiranje potrošača, odnosno formiranje niskonaponskih izvoda iz transformatorske stanice.

Nekim prigodnim grafičkim programom formiraju se alternative, odnosno različite prostorne varijante distribucijske mreže, od kojih je potrebno odabrati najbolju. Za odabir najbolje prostorne varijante model koristi tzv. analitički hijerarhijski postupak (*eng. analytic hierarchy process – AHP*) koji pripada skupini hijerarhijskih algoritama.

Nakon odabira najboljeg prostornog rješenja određuje se njegovo optimalno uklopno stanje. Za tu svrhu, u predloženom modelu planiranja, upotrebljava se metoda simuliranog kaljenja (*eng. simulated annealing*). Ova metoda pripada skupini stohastičkih metoda.

U polaznom istraživanju, koje je napravljeno u prvoj fazi izrade disertacije, obrađeni su teorijski i praktični rezultati objavljenih radova drugih istraživača. Iz dostupne literature koja se odnosi na planiranje niskonaponskih distribucijskih mreža može se uočiti da ni u jednom radu nije ponuđen model koji se temelji na korištenju predviđenih optimizacijskih algoritama. To se odnosi i na objavljene radove iz ovog područja. Dakle, razvoj novog modela planiranja je težište rada u ovoj disertaciji.

U okviru doktorske disertacije očekuju se slijedeći izvorni znanstveni doprinosi:

- Izrada poboljšanog modela za planiranje niskonaponskih distribucijskih mreža kombiniranjem metoda neizrazitog grupiranja, analitičkog hijerarhijskog postupka i simuliranog kaljenja sa ciljem dobivanja optimalne konfiguracije distribucijske mreže;
- Definiranje kriterija optimalne konfiguracije distribucijske mreže;
- Potvrda modela usporedbom sa rezultatima dobivenim mjerenjem i proračunom za postojeću niskonaponsku distribucijsku mrežu.

Razvijeni model će biti namijenjen za planiranje kako rekonstrukcija postojećih, tako i za izgradnju u cijelosti novih niskonaponskih distribucijskih mreža, te detektiranje problema u postojećim mrežama. Pravilnim odabirom i vrednovanjem određenih kriterija i što preciznijim definiranjem topologije mreže, model treba ponuditi najbolje rezultate. Stoga, iskusnim inženjerima, koji se bave planiranjem mreža, ovaj model treba poslužiti kao vrlo koristan alat.

2. DISTRIBUCIJSKE MREŽE

Distribucijske mreže su dio elektroenergetskog sustava koji služi za dovođenje električne energije od prijenosne mreže ili elektrana priključenih na distribucijsku mrežu do potrošača priključenih na distribucijsku mrežu. Dijele se na:

- srednjenaponske distribucijske mreže, naponskih razina 35 kV, 20 kV, 10 kV i 6 kV i
- niskonaponske distribucijske mreže, naponske razine 0,4 kV.

Položaj distribucijskih mreža u elektroenergetskom sustavu može se prikazati prema shemi na slici 2.1 [6].

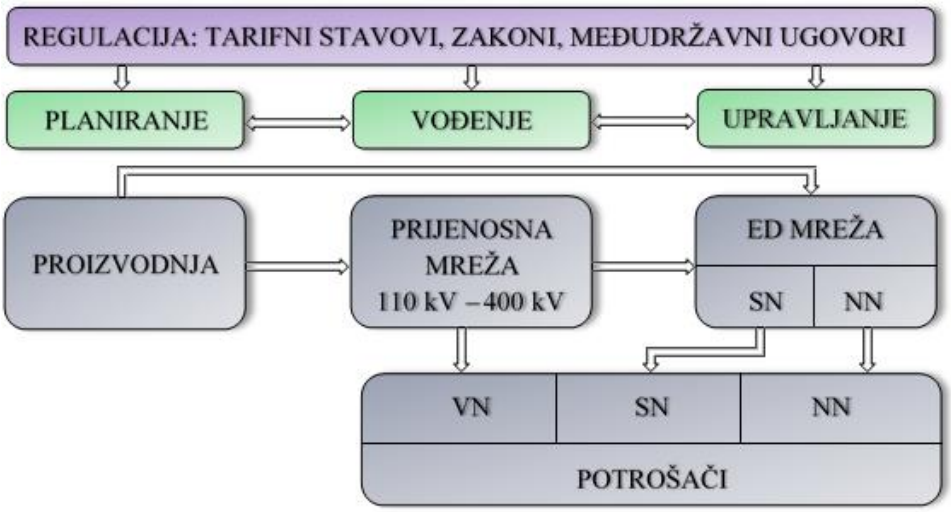

Slika 2.1. *Elektroenergetski sustav*

Regulacija rada elektroenergetskog sustava podrazumijeva tarifne stavove, zakonodavni okvir i međudržavne ugovore temeljem kojih su uređeni odnosi unutar elektroenergetskog sustava. Planiranje, vođenje i upravljanje proizvodnjom, prijenosnim i distribucijskim mrežama vrši se jednim dijelom odvojeno za svaki segment, a drugim dijelom koordinirano između pojedinih dijelova elektroenergetskog sustava. Koordinaciju rada između proizvodnje, prijenosa i distribucije električne energije vrše nacionalni i regionalni dispečerski centri, odnosno operator sustava u decentraliziranom sustavu.

2.1. STRUKTURA DISTRIBUCIJSKIH MREŽA

Napajanje distribucijskih mreža vrši se preko prijenosne mreže ili elektrana. Napajanje iz prijenosne mreže vrši se preko VN/SN transformatora, ali postoji i mogućnost direktnog povezivanja elektrana na distribucijsku mrežu preko blok transformatora. Veće elektrane uvijek su priključene na prijenosnu mrežu, preko koje se energija isporučuje distribucijskoj mreži. Priključenje elektrane na prijenosnu mrežu vrši se preko blok transformatora (Slika 2.2).

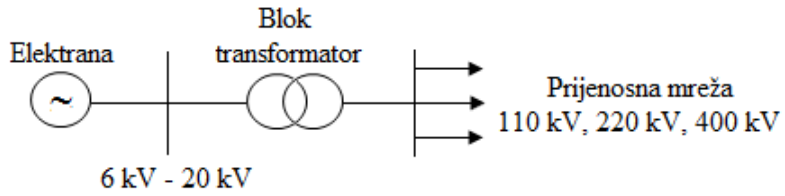

Slika 2.2. *Priključak elektrane na prijenosnu (visokonaponsku) mrežu*

Male elektrane se mogu priključiti direktno na distribucijsku mrežu i to na dva načina:

1. Preko blok transformatora na srednjenaponsku distribucijsku mrežu, za elektrane snage od 1 MW i više (Slika 2.3),

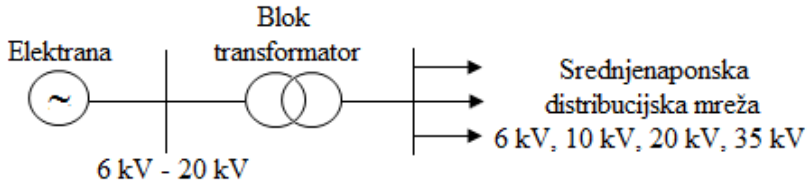

Slika 2.3. *Priključak male elektrane na srednjenaponsku distribucijsku mrežu*

2. Direktno na niskonaponsku distribucijsku mrežu, za elektrane snage do nekoliko stotina kW (Slika 2.4).

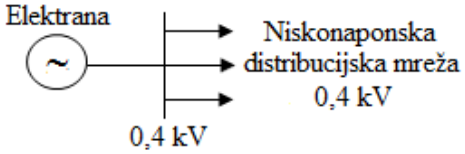

Slika 2.4. *Priključak male elektrane na niskonaponsku distribucijsku mrežu*

Obzirom da u elektroenergetskom sustavu postoje različite naponske razine tako se i potrošači električne energije dijele na:

- velepotrošače, koji su priključeni direktno na prijenosnu mrežu,
- industrijske potrošače, koji su priključeni na srednjenaponsku mrežu (6 kV, 10 kV, 20 kV, 35 kV),
- niskonaponske potrošače, priključene na 0,4 kV mrežu.

Dakle, za napajanje distribucijskih potrošača potrebna je veza između prijenosne i distribucijske mreže. Ova veza može se ostvariti na dva načina:

1. Distribucija prema niskom naponu vrši se preko dvije transformacije, i to: putem 35 kV i putem 10(20) kV distribucijske mreže. Prijenosna mreža napaja 110/35/10(20) kV transformatorsku stanicu, s tim da je na tercijaru transformatora moguć i direktan priključak 10(20) kV mreže. Primjer takve mreže prikazan je na slici 2.5.

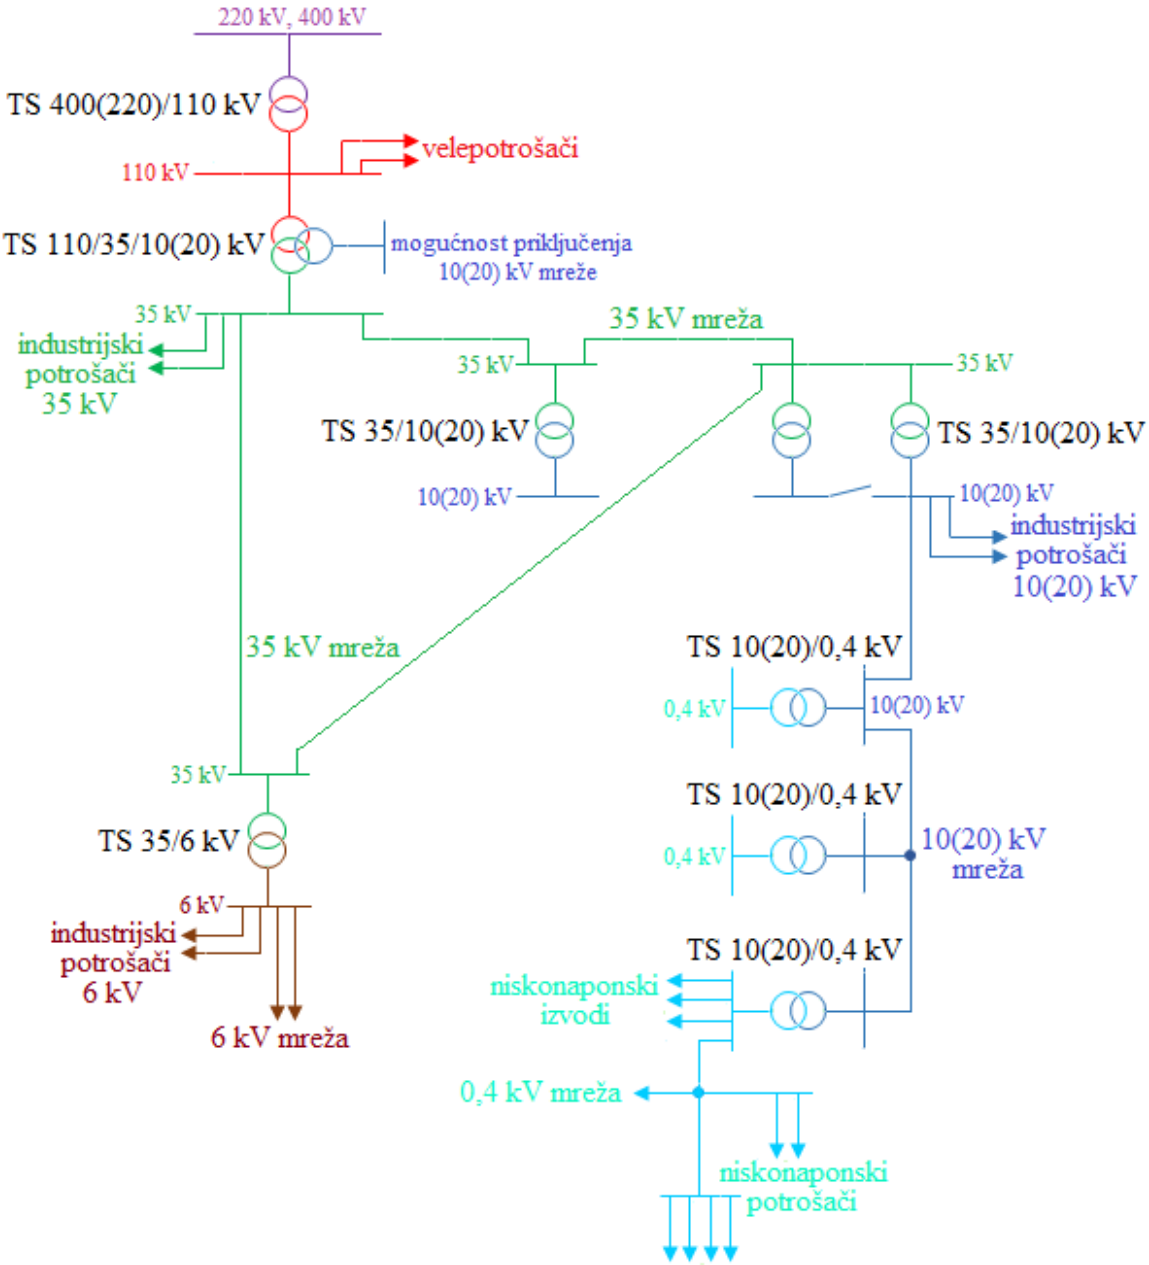

Slika 2.5. *Distribucijska mreža sa tri srednjenaponske razine (6 kV, 35 kV i 10(20) kV)*

2. Distribucija prema niskom naponu vrši se direktnom transformacijom 110/10(20) kV čime se eliminira potreba za 35 kV mrežom, odnosno ne postoji transformacija 35/10(20) kV. Tendencija razvoja distribucijskih mreža je da se smanji broj naponskih razina, čime bi se smanjili gubici u distribuciji električne energije, te smanjila zauzetost prostora mnogim lokacijama i trasama dalekovoda i kabela, uz olakšano održavanje postrojenja i vodova [7]. Opredjeljenje je ukidanje 35 kV naponske razine. Osim toga, tendencija je i promjena naponske razine sa 10 kV na 20 kV, gdje god je to moguće. To se radi na način da se ugrađuje oprema za naponsku razinu 20 kV, s tim da mreža radi na 10 kV naponskoj razini dok se ne steknu uvjeti za prijelaz na 20 kV naponsku razinu. Primjer ovakve mreže prikazan je na slici 2.6.

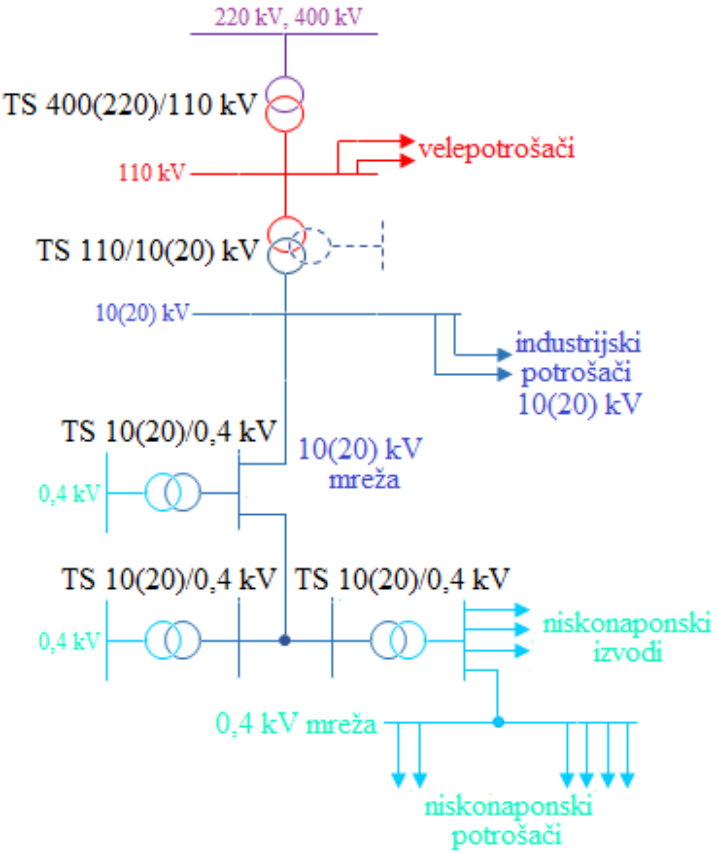

Slika 2.6. *Distribucijska mreža sa jednom srednjenaponskom razinom (10 kV ili 20 kV)*

2.2. NISKONAPONSKE DISTRIBUCIJSKE MREŽE

Niskonaponske distribucijske mreže služe za napajanje niskonaponskih potrošača električne energije iz srednjenaponske distribucijske mreže. Nazivni napon ovih mreža je 230/400 V, a izgrađuju se za napajanje jednofaznih i trofaznih potrošača. Izvode se sa četiri (tri fazna i nulti) vodiča, odnosno dva (fazni i nulti) vodiča.

Po svojoj strukturi niskonaponske distribucijske mreže mogu biti [8]:

- Radijalne – najčešće se koriste u praksi pošto su najjednostavnije i najekonomičnije. Nemaju mogućnost rezervnog napajanja, pa kvar na bilo kojem dijelu mreže uzrokuje prekid napajanja niskonaponskog izvoda u cijelosti;
- Zamkaste – imaju mogućnost rezervnog napajanja iz iste ili susjedne TS 10(20)/0,4 kV. U normalnom (redovitom) pogonu međuveze su isključene tako da rade kao radijalne mreže;
- Petljaste – koriste se u uvjetima gdje je velika površinska gustoća opterećenja i gdje je potrebna veća pouzdanost isporuke električne energije. Pogon nije radijalan već su zatvorene sve petlje u niskonaponskoj mreži, ali i petlje preko 10(20) kV mreže.

Osnovna struktura niskonaponske distribucijske mreže prikazana je na slici 2.7 [9].

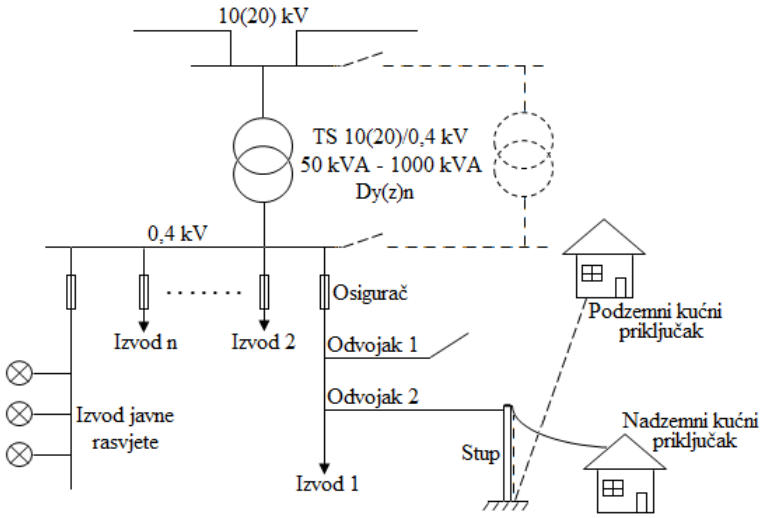

Slika 2.7. *Niskonaponska distribucijska mreža*

Osnovni elementi niskonaponske distribucijske mreže su:

- Transformatorske stanice;
- Niskonaponski vodovi;
- Niskonaponski potrošači.

2.2.1. Transformatorske stanice

Temeljna zadaća distribucijskih transformatorskih stanica je povezivanje srednjenaponske i niskonaponske distribucijske mreže (SN/NN). Rade se kao tipski proizvodi i mogu biti:

- stupne, koje se postavljaju na stupu nadzemne 10(20) kV mreže i obično su manjih snaga, reda 50 kVA–250 kVA,
- izgrađene u posebnom građevinskom objektu i veće su snage, reda 400 kVA–1000 kVA.

Distribucijske transformatorske stanice grade se sa jednim ili više transformatora, prijenosnog odnosa 10(20)/0,4 kV. Temeljni elementi su:

- Građevinski dio ili noseći stup;
- Sustav uzemljenja i gromobranske zaštite;
- Transformator, nazivne snage 50 kVA–1000 kVA, grupe spoja Dyn (za veće snage) ili Yzn (za manje snage);
- Srednjenaponsko postrojenje (srednjenaponski sklopni blok). Sadrži obični ili učinski rastavljač. Može biti zrakom izolirano ili SF6 postrojenje. Ukoliko je priključak sa nadzemne mreže potrebni su i odvodnici prenapona;
- Niskonaponsko postrojenje (niskonaponski sklopni blok). Sadrži prekidač u transformatorskom polju i osigurače u vodnim poljima, te uređaje za mjerenje i zaštitu;
- Pomoćni sustav (rasvjeta, klimatizacija i sl.).

2.2.2. Niskonaponski vodovi

Vodovi su dijelovi električne mreže koji povezuju objekte istog nazivnog napona. Temeljna zadaća niskonaponskih vodova je prijenos električne energije do krajnjih, niskonaponskih potrošača. Dijele se na:

- Nadzemne (zračne) vodove;
- Podzemne (kabelske) vodove.

Osnovni elementi nadzemnih vodova su:

- Stup – po položaju u trasi dijele se na linijske i kutne. Po načinu vješanja vodiča dijele se na nosne i zatezne. Po materijalu od kojeg su izrađeni dijele se na drvene, armirano–betonske i čelično–rešetkaste;
- Vodiči – izrađuju se u obliku žica ili užadi za prijenos većih snaga. Presjek vodiča i materijal od kojeg su izrađeni definiraju maksimalno dozvoljenu struju koja smije trajno protjecati vodom u pogonu. Od materijala za izradu vodiča se koriste: bakar (Cu), aluminij (Al), čelik (Fe) i kombinacija aluminija i čelika (Al–Fe). Vodiči od bakra se koriste za male presjeke i raspone, i to presjeka najčešće 16 mm^2. Ostali tipovi vodiča se izrađuju u obliku užadi, a presjeci užadi su normirani nizom: 10 mm^2, 16 mm^2, 25 mm^2, 35 mm^2, 70 mm^2, 95 mm^2, 120 mm^2, 150 mm^2. Za nadzemne kućne priključke danas se najčešće koristi tzv. samonosivi kabelski snop (SKS), odnosno izolirani zračni vodič. Fazni vodič se izrađuje od aluminijskog užeta presjeka 16 mm^2, 25 mm^2, 35 mm^2, 50 mm^2, 70 mm^2 i 150 mm^2, a nulti vodič od legure Al–Mg, presjeka 50 mm^2 i 70 mm^2, dok je izolacija najčešće polietilenskog tipa XLPE;
- Izolatori – imaju ulogu da električki izoliraju vodiče od stupa i da ih mehanički drže u određenom položaju, te prenose mehaničke sile sa vodiča na stup. Materijali za izradu izolatora su: porculan, steatit, kaljeno staklo i kompozitni materijali. Po načinu na koji nose vodiče dijele se na: potporne i ovjesne;
- Uzemljenje – ovom sustavu pripada zaštitno uže (ako postoji), uzemljivač stupa i galvanski spojevi metalnih dijelova koji nisu pod naponom;
- Temelji – uloga temelja je da sve sile sa stupa prenesu na tlo.

Podzemni (kabelski) vodovi dijele se na jednožilne i trožilne. Osnovni dijelovi kabelskih vodova su: fazni vodič, poluvodljivi sloj, izolacija, ispuna, vodljivi plašt i vanjski omotač. Fazni vodiči se izrađuju u vidu užeta, a kao materijal se koriste bakar i aluminij. Izolacija dolazi iznad faznog vodiča, a najčešće korišteni materijal je umreženi polietilen. Vodljivi plašt se nalazi iznad izolacije kabela. Iznad vodljivog plašta se nalazi vanjski omotač izrađen od izolacijskog materijala (PVC ili obični polietilen), a služi za zaštitu kabela od vanjskih utjecaja (mehanička oštećenja, vlaga i sl.).

Osnovni električki parametri kabela su:

- Nazivni napon U_n – napon za koji je projektirana izolacija kabela;
- Nazivna struja I_n – dozvoljeno strujno opterećenje za odgovarajući tip i presjek kabela, u nazivnim uvjetima;
- Dozvoljeno strujno opterećenje kabela I_t – najveća struja kojom se kabel može trajno opteretiti uvjetovana dozvoljenim zagrijavanjem kabela. U redovitom pogonu je 80 % toplinski dopuštenog opterećenja, a u izvanrednom pogonu je 120 % toplinski dopuštenog opterećenja;
- Radni otpor, induktivitet i kapacitet kabela.

Prednosti kabela u odnosu na zračne vodove su:

- Nema vizualne degradacije prostora;
- Imaju veću pogonsku pouzdanost jer nisu izloženi atmosferskim utjecajima;
- Zaštićeni su od namjernog uništavanja.

Nedostaci kabela u odnosu na zračne vodove su:

- Daleko veća cijena;
- Daleko teže lociranje mjesta kvara;
- Potrebno je znatno više vremena za otklanjanje kvara.

2.2.3. Niskonaponski potrošači

Pod niskonaponskim potrošačem se smatra pojedinačno trošilo ili skupina trošila koja je priključena na distribucijsku mrežu, odakle uzimaju potrebnu električnu energiju za svoj rad.

Općenito, potrošači se razlikuju prema:

- načinu priključka na distribucijsku mrežu (trofazni, dvofazni i jednofazni),
- naponskoj razini preko koje su priključeni na distribucijsku mrežu (niskonaponski potrošači su: kućanstva, obrti, usluge, rasvjeta itd.),
- tehničkim karakteristikama,
- tarifama po kojima plaćaju energiju, odnosno snagu.

Pojedinačna trošila mogu biti jednofazna ili trofazna (i rijetko dvofazna), dok grupna trošila predstavljaju skupinu kućanstava, niskonaponski izvod, konzum trafostanica 10(20)/0,4 kV itd.

Osnovne vrste pojedinačnih trošila su:

- Termička trošila;
- Rasvjeta;
- Elektromotori;
- Elektronički pretvarači.

U specijalna trošila ubrajaju se:

- Željezare (elektrolučne peći);
- Veliki asinkroni motori;
- Veliki pretvarači;
- Elektrovuča.

Različita trošila imaju i različitu potrošnju električne energije. Primjer potrošnje električne energije jednog kućanstva, za različite vrste trošila, prikazan je na slici 2.8 [10].

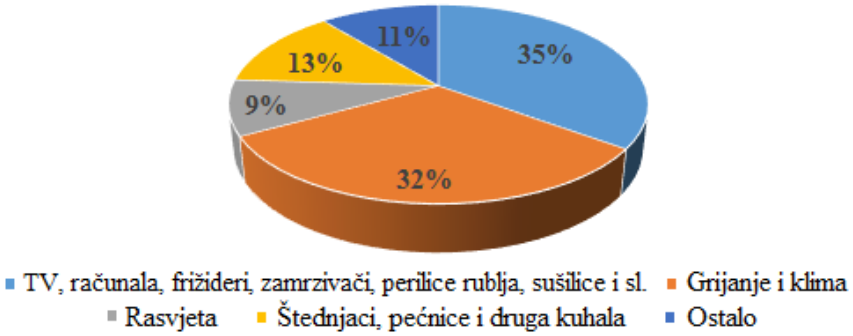

Slika 2.8. *Primjer potrošnje električne energije različitih kućanskih trošila*

Nazivni podaci svakog trošila su:

- Nazivna snaga P_n (jednofazna ili trofazna);
- Nazivni faktor snage $\cos\varphi_n$;
- Nazivni napon U_n.

Nazivne vrijednosti struja trošila mogu se odrediti iz nazivnih podataka i trokuta snaga prikazanog na slici 2.9.

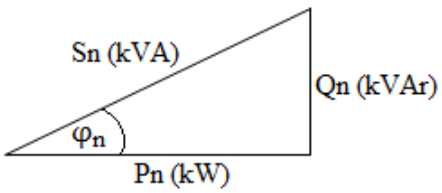

Slika 2.9. *Trokut snaga*

$$S_n = \frac{P_n}{\cos\varphi_n} \tag{2.1}$$

$$I_n = \frac{P_n}{\sqrt{3} \cdot \cos\varphi_n \cdot U_n} \tag{2.2}$$

$$I_n = \frac{P_n}{\cos\varphi_n \cdot V_n} \tag{2.3}$$

gdje su: U_n – nazivni linijski napon na koji je priključeno trošilo (kV)
V_n – nazivni fazni napon na koji je priključeno trošilo (kV)

2.3. ENERGETSKI PRORAČUNI U NISKONAPONSKIM DISTRIBUCIJSKIM MREŽAMA

2.3.1. Proračun opterećenja potrošača

Potrošači u niskonaponskoj distribucijskoj mreži se dijele u tri kategorije, i to:

1. Kućanstva;
2. Ostali potrošači;
3. Javna rasvjeta.

Temeljni parametri koje je potrebno poznavati kod potrošača su radna snaga koju uzimaju iz mreže i faktor snage (ili jalova snaga).

a) Proračun opterećenja kućanstava

Obzirom da sva trošila u kućanstvu nisu uključena u isto vrijeme onda vrijedi [9], [11], [12]:

$$P_v < P_i \tag{2.4}$$

gdje su: P_v – vršno opterećenje kućanstva (kW)
P_i – instalirana snaga kućanstava (kW)

Obzirom da svako kućanstvo ima svoje navike kada je u pitanju potrošnja električne energije, zbroj pojedinačnih vršnih opterećenja $P_{v1}, P_{v2}, \ldots, P_{vn}$ veći je od vršnog opterećenja skupine kućanstava. Zato je neophodno uvesti faktor:

$$f_i = \frac{P_{vn}}{P_{v1} + P_{v2} + \ldots + P_{vi}} \tag{2.5}$$

gdje je: f_i – faktor istodobnosti (Ruscov (*Rusc*) faktor – za kućanstva obično 0,17)

Ovaj faktor je manji što je broj kućanstava veći. Ukoliko su kućanstva približno jednakih karakteristika, odnosno vršne snage, vršno opterećenje skupine kućanstava računa se preko formule:

$$P_{vn} = P_{v1} \cdot (f_i \cdot n + (1 - f_i) \cdot \sqrt{n}) \quad (2.6)$$

gdje su: n – broj kućanstava u promatranoj skupini
f_i – faktor istodobnosti za vrlo veliki (teorijski beskonačan) broj kućanstava

Temeljem izračunatog vršnog opterećenja skupine od *n* kućanstava može se dobiti udio (ekvivalentno opterećenje) pojedinog kućanstva:

$$P_1 = \frac{P_{vn}}{n} \quad (2.7)$$

Jalova snaga računa se preko faktora snage *cosφ*:

$$Q_1 = P_1 \cdot tg\varphi \quad (2.8)$$

b) Proračun opterećenja javne rasvjete i ostalih potrošača

Faktor istodobnosti za javnu rasvjetu je 1, tako da je snaga pojedinog rasvjetnog tijela jednaka nazivnoj snazi, a vršno opterećenje je zbroj svih nazivnih snaga.

Ostali potrošači, koji ne pripadaju u kategoriju kućanstava, su definirani vlastitom instaliranom snagom P_{inst}, faktorom istodobnosti prema ostalim potrošačima f_i i faktorom snage *cosφ*. Faktor istodobnosti je različit od 1 u slučaju da vršno opterećenje promatranog potrošača ne nastupa istovremeno sa vršnim opterećenjem ostalih potrošača u mreži. U čvoru u koji su priključeni ostali potrošači oni sudjeluju s opterećenjem:

$$P_{ost} = P_v \cdot f_i \quad (2.9)$$

$$Q_{ost} = P_{ost} \cdot tg\varphi \quad (2.10)$$

Izračunate vrijednosti za javnu rasvjetu i ostalu potrošnju se pribrajaju potrošnji kućanstava, te se u odgovarajućem čvoru u konačnici dobiva:

$$P_{uk} = P_{kuć} + P_{ost} + P_{jav.ras.} \quad (2.11)$$

$$Q_{uk} = Q_{kuć} + Q_{ost} + Q_{jav.ras.} \quad (2.12)$$

Proračun pojedinačnih opterećenja potrošača za postojeće niskonaponske distribucijske mreže moguće je provesti temeljem drugačijeg postupka. Potrebni ulazni podaci za jedan ovakav proračun su godišnja utrošena radna energija svakog potrošača i jednodnevno mjerenje satnih opterećenja na 0,4 kV strani transformatora i svim niskonaponskim distribucijskim izvodima. Za potrošače iz kategorije ostale potrošnje potrebni su podaci o vršnom opterećenju i utrošenoj radnoj i jalovoj energiji.

Proračun pojedinačnih opterećenja potrošača provodi se prema slijedećem postupku [13]:

- Temeljem jednodnevnih, satnih očitanja radne i jalove energije određuju se vrijednosti faktora snage *cosφ* transformatorske stanice i svih niskonaponskih distribucijskih izvoda. Ukoliko nisu dostupna mjerenja jalove energije, za kućanstva se obično uzima cosφ = 0,95–0,98, a za potrošače iz kategorije ostale potrošnje uzima se stvarna vrijednost temeljem mjerenja radne i jalove energije. Na ovaj način, dobiva se dnevni dijagram opterećenja (Slika 2.10).

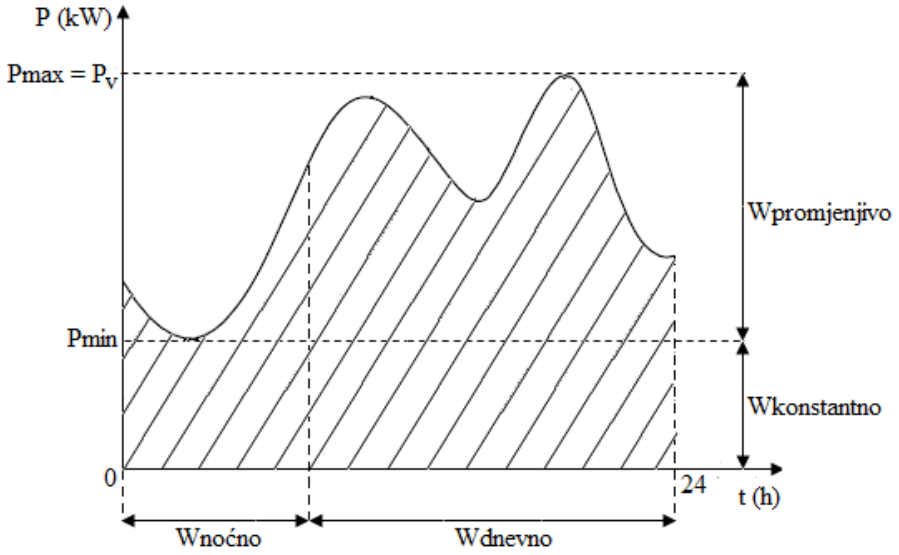

Slika 2.10. *Dnevni dijagram opterećenja*

- Temeljem jednodnevnog satnog očitanja brojila radne energije pojedinih niskonaponskih izvoda određuje se maksimalna (vršna) snaga izvoda (maksimalno satno očitanje),
- Dijeljenjem sumarne godišnje utrošene energije za svaki niskonaponski izvod sa maksimalnom postignutom snagom izvoda dobiva se polazna minimalna vrijednost upotrebnog vremena,

$$T_{up_{min}} = \frac{W_{uk_{god}}}{P_{max}} \tag{2.13}$$

gdje su: $W_{uk_{god}} = W_{uk_{dnev}} \cdot 365$ (kWh)

$W_{uk_{dnev}}$ – sumarno jednodnevno satno očitanje brojila radne energije (kWh)

- Maksimalna radna snaga svakog potrošača dobiva se dijeljenjem ukupne godišnje utrošene energije potrošača sa dobivenim upotrebnim vremenom,

$$P_{max_{pot}} = \frac{W_{ostv_{pot}}}{T_{up_{min}}} \tag{2.14}$$

- Uz poznati faktor snage *cosφ* dobiva se i maksimalna jalova snaga potrošača,

$$Q_{max_{pot}} = P_{max_{pot}} \cdot tg\varphi \tag{2.15}$$

- Za dobivene vrijednosti maksimalnih radnih snaga potrošača, proračunom tokova snaga, dobivaju se vrijednosti snaga injektiranih u svaki niskonaponski izvod,

$$P_{inj} = P_{pot} + P_{gub} \tag{2.16}$$

gdje su: P_{gub} – gubici prijenosa električne energije u niskonaponskim vodovima (kW)

- Proračunom koeficijenta *c* za svaki niskonaponski izvod vrši se procjena godišnje utrošene energije svakog izvoda temeljem dnevne utrošene energije, pri čemu je:

$$c = \frac{W_{uk_{god}} \cdot P_{inj}}{365 \cdot W_{uk_{dnev}} \cdot P_{pot}} \tag{2.17}$$

- Korigiranjem $W_{uk_{god}} = W_{uk_{dnev}} \cdot 365 \cdot c$ dobiva se korigirana vrijednost upotrebnog vremena za sve niskonaponske izvode, a samim tim i konačne, korigirane vrijednosti maksimalnog opterećenja svakog pojedinačnog potrošača.

2.3.2. Proračun gubitaka snage i energije

Dobivanjem vrijednosti opterećenja svakog potrošača proračunom tokova snaga u nekome od softverskih paketa (PowerCAD, Matpower, Windis i sl.) moguće je odrediti vrijednosti gubitaka radne i jalove snage. Točniji proračun gubitaka snage podrazumijeva poznavanje krivulje trajanja opterećenja i u praksi je vrlo teško doći do podataka temeljem kojih bi se mogla formirati godišnja krivulja trajanja opterećenja. Stoga se temeljem rezultata proračuna gubitaka snage radi aproksimativni proračun gubitaka energije na godišnjoj razini na slijedeći način [13], [14]:

- Temeljem proračunatih P_{inj} i P_{pot} dobiva se vrijednost ukupnih gubitaka:

$$P_{gub} = P_{inj} - P_{pot} \tag{2.18}$$

- Gubici snage ovisni o opterećenju (varijabilni) su:

$$P_{var} = P_{gub} - P_0 \tag{2.19}$$

gdje su: P_0 – gubici praznog hoda (kW)

- Korekcija polaznog upotrebnog vremena ili tzv. vrijeme trajanja gubitaka računa se kao:

$$T_{gub} = \left[a \cdot T_{up} + (1 - a) \cdot \frac{T_{up}^2}{8760} \right] \tag{2.20}$$

pri čemu je *a* konstanta koja se u distribucijskim mrežama, ovisno o obliku krivulje trajanja opterećenja, kreće u granicama 0,15–0,2. Najčešće se uzima a = 0,17.

- Temeljem gubitaka praznog hoda P_0 računaju se gubici energije praznog hoda W_0, kao:

$$W_0 = P_0 \cdot 8760 \tag{2.21}$$

- Temeljem vremena trajanja gubitaka i varijabilnih gubitaka snage dobivaju se varijabilni gubici energije kao:

$$W_{var} = T_{gub} \cdot P_{var} \tag{2.22}$$

- Ukupni godišnji gubici energije su:

$$W_{gub} = W_0 + W_{var} \tag{2.23}$$

odnosno u postotnom iznosu,

$$w_{gub}(\%) = \frac{W_{gub}}{W_{uk_{god}}} \cdot 100\% \tag{2.24}$$

2.3.3. Proračun padova napona

Pad napona u simetrično opterećenoj mreži računa se kao [9], [12]:

$$\Delta u(\%) = \frac{k_f \cdot k_t \cdot P \cdot l \cdot (r + x \cdot tg\varphi)}{U^2} \cdot 100\% \tag{2.25}$$

gdje su: P – opterećenje voda (kW)
l – duljina voda (km)
r , x – jedinične konstante voda (Ω/km)
k_f – faktor ovisan o broju faza
k_t – faktor težišta opterećenja na vodu

Tablica 2.1 prikazuje faktor k_f ovisno o broju faza.

Tablica 2.1. *Faktor k_f u ovisnosti o broju faza*

Vod	Jednofazni	Dvofazni	Trofazni
U (kV)	0,23	0,40	0,40
k_f	3,0	1,5	1,0

Faktor težišta opterećenja voda k_t računa se prema izrazu:

$$k_t = \frac{l_0 + l_1 \cdot \frac{n - 1}{2}}{l_0 + l_1 \cdot (n - 1)} \tag{2.26}$$

gdje su: l_0 – udaljenost od transformatorske stanice do prvog potrošača na vodu (km)
l_1 – prosječna udaljenost među potrošačima na vodu (km)
n – broj potrošača na vodu

2.3.4. Odabir snage transformatora

Za više niskonaponskih izvoda, ukupno maksimalno opterećenje kućanstava određuje se Ruscovom formulom. Zbrajanjem maksimalnih opterećenja svih izvoda ne bi bio uvažen faktor istodobnosti potrošnje kućanstava na različitim izvodima. Ukupnom maksimalnom opterećenju kućanstava pridodaje se maksimalno opterećenje ostalih potrošača sa uračunatim faktorom istodobnosti, te ukupno opterećenje javne rasvjete. Na ovaj način dobiva se ukupno maksimalno opterećenje niskonaponske mreže.

Minimalna potrebna snaga transformatora računa se kao [9] , [15]:

$$S_n \geq \frac{P_{max_{mreže}}}{r_{pre} \cdot (1 - r_{rez}) \cdot \cos\varphi} \tag{2.27}$$

gdje su: $P_{max_{mreže}}$ – ukupno maksimalno opterećenje mreže (kW)
$\cos\varphi$ – prosječni faktor snage
r_{pre} – faktor dopuštenog preopterećenje transformatora
r_{rez} – faktor rezerve

2.3.5. Proračun tokova struja i odabir tipa vodiča

Proračunom tokova snaga (P, Q), kroz sve dionice niskonaponske mreže, odgovarajuće vrijednosti struja koje teku svakom dionicom dobivaju se kao:

$$I = \frac{\sqrt{P^2 + Q^2}}{\sqrt{3} \cdot U} \tag{2.28}$$

gdje su: P, Q – snage u početnoj točki promatrane dionice (kW, kVAr)
U – napon u početnoj točki promatrane dionice (kV)

Obzirom da je za svaki tip vodiča, u ovisnosti o njegovom presjeku i materijalu od kojeg je izrađen, definirana maksimalna vrijednost struje I_n koja može protjecati kroz njega, temeljem izračunate vrijednosti struje za svaku dionicu može se odrediti da li odabrani tip vodiča zadovoljava. Obično, odabrani tip vodiča zadovoljava ukoliko je ispunjen uvjet:

$$I \leq 0{,}8 \cdot I_n \tag{2.29}$$

2.4. PLANIRANJE DISTRIBUCIJSKIH SUSTAVA

Izgled distribucijskog sustava strateško je pitanje za većinu distribucijskih tvrtki. Ključni problem je lociranje postrojenja i alociranje potrošača. Sam izgled distribucijskog sustava je usko povezan sa lokacijom, odnosno prostornim rasporedom objekata koje je potrebno opskrbiti električnom energijom. Naravno, odabir što povoljnijih lokacija za vlastita postrojenja je jedan od važnih faktora za distribucijske tvrtke. Primarna uloga planiranja distribucijskog sustava je usklađivanje vlastitih interesa distribucijskih tvrtki sa interesima potrošača.

2.4.1. Matematički modeli planiranja

Modeli planiranja mogu se klasificirati kako slijedi [16]:

- Kontinuirani modeli lokacija (modeli u ravnini) (*eng. continuous location models*) – karakteriziraju ih dvije značajke: prostor rješenja je kontinuiran, odnosno izvodljiv je za lociranje postrojenja u svakoj točki ravnine i udaljenost se mjeri prigodnom metrikom, obično Manhattan, Euclidean ili metrika ravne–crte (zračna udaljenost);
- Modeli lokacije mreže (*eng. network location models*) – kod ovih modela udaljenost se računa kao najkraći put na grafu;
- Modeli mješovito–cjelobrojnog programiranja (*eng. mixed–integer programming models*) – za razliku od prethodnih modela ovi modeli predstavljaju diskretizirane optimizacijske modele i koriste ulazne podatke bez ispitivanja odakle dolaze. Gruba podjela ovih modela izgleda kako slijedi:
  a) jedno–fazni u usporedbi sa više–faznim modelima (*eng. single–stage vs. multi–stage models*),
  b) opterećeni u usporedbi s neopterećenim modelima (*eng. capacitaded vs. uncapacitaded models*),
  c) jedno–izvorni u usporedbi sa više–izvornim modelima (*eng single–sourcing vs. multiple–sourcing*),
  d) jedno–proizvodni u usporedbi sa više–proizvodnim modelima (*eng. single–product vs. multi–product*),
  e) statički u usporedbi sa dinamičkim modelima (*eng. static vs. dynamic models*),
  f) modeli s i bez mogućnosti usmjeravanja (*eng. with or without routing options*).

Kada se radi o elektroenergetskom sustavu ovi modeli se najčešće primjenjuju u analizama grupiranja.

2.4.2. Planiranje niskonaponskih distribucijskih mreža

Planiranje niskonaponskih distribucijskih mreža je važno zbog zadovoljavanja određenih zahtjeva i temelji se na prognozi opterećenja i pouzdanosti u napajanju potrošača. Postoje tri kategorije planiranja i to: dugoročno planiranje, planiranje razvoja mreže i planiranje izgradnje mreže [17].

Zadaća dugoročnog planiranja je određivanje optimalnog rasporeda mreže i investicijskih troškova, pri čemu se mora uzeti u obzir budući razvoj. Planiranje razvoja mreže (tzv. razvoj korak po korak) mora biti sukladno prognoziranom povećanju opterećenja kako bi se na vrijeme osigurale dovoljne količine električne energije sukladne rastu potrošnje. Planiranje izgradnje mreže (tzv. dizajn) je aktualni inženjerski posao gdje se planiraju i prihvaćaju potrebni strujni krugovi i transformatorske stanice.

Jedan od esencijalnih elemenata u planiranju distribucijskih mreža je određivanje lokacije centra potrošnje gdje treba biti smještena transformatorska stanica. Ovo se radi u dugoročnom planiranju (npr. desetogodišnji plan). Nadalje, planiranjem razvoja mreže određuju se niskonaponski izvodi kojim će se vršiti snabdijevanje krajnjih potrošača električnom energijom. Temeljem ovoga na kraju se vrši planiranje izgradnje mreže.

Pri planiranju mreža značajna pažnja se mora pridati pouzdanosti koja je u vezi sa sposobnošću kontinuiranog snabdijevanja električnom energijom svih kupaca. Ona se može mjeriti brojem prekida u danom periodu ili prosječnom dužinom trajanja prekida. Ona je uvijek proporcionalna troškovima. Stoga je veoma važno iznaći ravnotežu između pouzdanosti i troškova.

Sustavno planiranje niskonaponske distribucijske mreže moguće je samo onda kada je uspostavljen i prihvaćen jedinstveni sustav aksioma za planiranje mreže. Odluke su to bolje, što je sustav aksioma potpuniji. Ovakav sustav treba sadržavati [18]:

- Zakone i tehničke propise;
- Zahtjeve koje trebaju ispuniti komponente mreže;
- Dopušteno trajanje prekida u napajanju;
- Prognozu opterećenja;
- Pogonske zahtjeve.

Sustav za planiranje razvoja mreže sadrži sve pripadajuće zakone, propise i norme za distribucijska postrojenja, uključujući i propise o zaštiti na radu.

Zahtjevi koje trebaju ispuniti komponente mreže promatraju se za dva pogonska stanja, i to: za normalan pogon i nakon kvara. Ako kvar nastane slučajno, u periodu velikih opterećenja, čime se kratkotrajno mora preopteretiti neka druga komponenta mreže, to skraćuje njezin vijek trajanja. Skraćenje vijeka trajanja komponenti mreže uspostavlja granice zahtjeva za komponente koji se moraju uvrstiti u načela planiranja. Dakle, za potrebe pričuvnog pogona u slučaju kvara, neke od komponenti mreže mogu biti opterećene više od nazivne snage dok traje popravak oštećenog dijela mreže, ali se mora voditi računa o granicama do kojih se komponente mogu preopteretiti, kao i o vremenu trajanja preopterećenja.

Važan parametar za pogon i planiranje niskonaponskih distribucijskih mreža je trajanje prekida nakon kvara. Ako se prihvati da svakom kvaru odgovara određena neisporučena električna energija, koja ovisi o vjerojatnosti nastanka kvara, odatle slijedi da za svaku veličinu prekinutog opterećenja postoji određeno trajanje prekida napajanja. Načelo (n–1) ne može se u mrežama

primijeniti dosljedno, u smislu da svaka komponenta ima svoju pričuvnu komponentu. Mora se krenuti više prema tome da se za svako ispalo opterećenje predvidi odgovarajuće pričuvno napajanje, koje se ne mora uvijek aktivirati odmah, nego treba biti u vremenu odgovarajućeg dopuštenog trajanja prekida. Prekide napajanja nije moguće izbjeći. Zato je potrebno svesti njihovo trajanje na podnošljivu mjeru za potrošače, kao i za troškove isporučitelja.

O prognozi potrošnje ovisi pravilno predviđanje potrebnih ulaganja, a veliki utjecaj na kvalitetu prognoze ima porast opterećenja. Iz navedenog razloga, procjena opterećenja mora biti što pouzdanija i uz nju se treba dati procjena nesigurnosti mogućih odstupanja. Nadalje, vrijedi da bi pomoću statističke metode bilo dobro pronaći ovisnost između porasta potrošnje i porasta općih veličina. Porast opterećenja (snage) teže je procijeniti jer je to slučajna veličina koja ovisi o načinu i vrsti potrošnje samoga potrošača. Iz toga se može zaključiti da porast opterećenja za dva područja može biti različit, uz isti porast potrošnje električne energije. Postoji niz prognostičkih metoda koje se bave trendom potrošnje električne energije, a jedna od njih je ekstrapolacija trenda pomoću regresije. Ova metoda koristi podatke iz prošlosti za zaključivanje tijeka potrošnje u budućnosti. Prognoze mogu biti kratkoročne ili dugoročne, ali ih svakako treba revidirati u određenim vremenskim razmacima.

U načelu, u planiranje razvoja niskonaponskih distribucijskih mreža pripadaju i zahtjevi za ponašanjem mreže u pogonu, kao i učestalost održavanja komponenti mreže. Ponašanje mreže u pogonu može biti određeno na način da se traži da uklopno stanje nadređene mreže ne utječe bitno na sklopne radnje u podređenoj mreži. Daljnji zahtjev može biti da se odredi maksimalni broj sklopnih radnji za promjenu uklopnog stanja mreže.

Planiranje distribucijskih mreža je posao koji obično obavlja veći broj inženjera–planera u distribucijskim tvrtkama. Pritom, sve više podrške im dolazi novim, gotovim programima za planiranje i vjerojatno će se u budućnosti takvi oblici planiranja još više proširiti i produbiti. Međutim, kriterije planiranja, čak i pri radu s računalnim programima za planiranje, mora ipak odrediti sam planer mreže, a najbolje je da glavni dio kriterija bude usuglašen unutar distribucije. Prelaskom na deregulirano poslovanje elektroprivrednih djelatnosti, dakle i distribucijske, važnu će kariku predstavljati planiranje koje će obavljati, i biti za to odgovorni, budući operateri mreža. Osim do sada prihvaćenih, morat će se uvesti i kategorije planiranja koje u netržišnoj i reguliranoj elektroprivredi uglavnom nisu bile poznate ili nisu bile uvažene, kao što je npr. ugovorena pouzdanost napajanja, odšteta za neisporučenu energiju i snagu i sl.

2.4.3. Opći kriteriji planiranja

Postoje li dileme o načinu ulaganja, troškovima mreže i sl. mora se, u načelu, načiniti više različitih varijanti razvitka mreže. Svaka varijanta promatra se neovisno. Pojedine vremenske etape razvoja mreže moraju biti sadržane jednako u svim varijantama i obrađuju se jednako. Komponente mreže moraju biti dimenzionirane tako da na kraju pojedine etape izdrže dostignuta opterećenja, imaju gubitke napona u dopuštenim granicama i traženu pouzdanost napajanja. Ne može se unaprijed odrediti koliko varijanti ili etapa u nekoj razradi mreže treba načiniti.

Varijante se uspoređuju prema padovima napona, gubicima snage, troškovima izgradnje mreže, te ukupnim troškovima nastalim tijekom cijelog razdoblja planiranja (sve planirane etape). Dakle, troškove pojedine varijante čine:

- Troškovi ulaganja (investicija);
- Troškovi pogona (troškovi gubitaka električne energije i snage, te troškovi održavanja).

Upotrijebljena godišnja stopa porasta vršnog opterećenja u jednoj varijanti mora se upotrijebiti jednako u svim varijantama. Godišnju stopu porasta treba dogovoriti sa širim krugom poznavatelja okolnosti na danom području (naročito s urbanistima). Stopu porasta tijekom perioda planiranja moguće je i mijenjati, a podrazumijeva se da će se to dosljedno provesti u svim uspoređenim varijantama.

2.4.4. Tehnički kriteriji planiranja

Dopušteni gubitak napona u bilo kojem čvoru mreže, na kraju određene etape razvoja mreže, u redovitom (normalnom) pogonu, je, prema Europskoj normi EN50160, $\Delta u = \pm 10\%$ [19]. Ako taj temeljni uvjet nije zadovoljen, mreža se dijeli, odnosno uvode se novi strujni krugovi, koji preuzimaju dio tereta preopterećenog strujnog kruga. Vod koji se tom prilikom uvodi u mrežu mora biti tipizirani vod, optimalnog presjeka vodiča koji udovoljava zahtjevima toplinske čvrstoće kod kratkog spoja.

Dopušteno relativno opterećenje komponenti sustava, pri razradi planirane mreže, je slijedeće:

- Opterećenje u normalnom pogonu: 80% toplinski dopuštenog opterećenja;
- Opterećenje u izvanrednom pogonu: 120% toplinski dopuštenog opterećenja.

Kod nadzemnih vodova nije dopušteno toplinsko preopterećenje, nego se ograničenje ogleda u padu napona na njihovom kraju u redovitom, odnosno izvanrednom pogonu.

Novi vodovi, koji se ugrađuju, moraju imati tipski presjek vodiča, po mogućnosti optimalni, odnosno ovisan o veličini konzuma kojega napajaju. Optimalni presjek vodiča nadzemnog voda i kabela određuje se posebnim računom, a potom se iz standardnog niza ili niza tipiziranih vodova odabiru vodovi čiji je presjek najbliži optimalnom.

Jedinice transformatora koji se ugrađuju moraju biti tipske (blizu optimalne) veličine, ovisno o veličini konzuma koji napajaju. Optimalna veličina (nazivna snaga) transformatora određuje se posebnim proračunom, a potom se iz standardnog niza ili niza tipiziranih transformatora odabire onaj čija je nazivna snaga najbliža optimalnoj.

2.4.5. Ekonomski kriteriji planiranja

Gubici električne energije valoriziraju se odgovarajućim cijenama na razini svih komponenti. Jedan primjer je dan u tablici 2.2.

Tablica 2.2. *Primjer proračuna gubitaka po komponentama mreže*

Komponenta mreže	Uporabno vrijeme vršnog opterećenja (h)	Faktor oblika dijagrama opterećenja	Faktor gubitaka ϑ	Cijena snage k_s (€/kW)	Cijena energije k_e (€/kWh)	Faktor istodobnosti	Cijena gubitaka na razini komponente mreže C_e (€/kW)
Transformator 10(20)/0,4 kV	2.500	0,285	0,112	170	0,06	0,72	191
Kabel 0,4 kV	1.800	0,205	0,070	170	0,06	0,55	130
Nadzemni vod 0,4 kV	1.500	0,171	0,053	170	0,06	0,50	113

Cijena gubitaka praznog hoda transformatora jednaka je za sve planirane transformatore (za transformatorske stanice sa više transformatora), jer gubici nastaju istodobno, pod uvjetom da su svi transformatori uključeni cijele godine (8760 sati). Ta cijena iznosi:

$$C_0 = k_s + k_e \cdot 8760 \quad (€/kW/god) \tag{2.30}$$

gdje su: k_s – cijena snage (€/kW)
k_e – cijena energije (€/kWh)

Približan izračun investicijskih troškova izgradnje mreže treba sadržavati podatke kako je to prikazano u tablici 2.3.

Tablica 2.3. *Primjer cjenika investicijskih troškova izgradnje mreže*

Transformator 10(20)/0,4 kV, 400 kVA, sa ugradnjom (€)	Stupovi sa ovjesnom opremom i ugradnjom (€/stup)	SKS 70 mm^2 (€/m)	SKS 35 mm^2 (€/m)	SKS 16 mm^2 (€/m))	Kućni priključak sa opremom i ugradnjom (€/kom)
30.519	871	10	8	4	1.573

Dakle, približni ukupni troškovi izgradnje distribucijske mreže mogu se prikazati kao:

$$C_i = t \cdot c_T + s \cdot c_s + l_1 \cdot c_{70} + l_2 \cdot c_{35} + l_3 \cdot c_{16} + n \cdot c_p \tag{2.31}$$

gdje su: t – broj transformatora u transformatorskoj stanici
c_T – cijena jednog transformatora sa ugradnjom (€)
s – broj stupova
c_S – prosječna cijena jednog stupa sa ovjesnom opremom i ugradnjom (€)
l_1, l_2, l_3 – ukupna dužina potrebnog SKS 70 mm^2, 35 mm^2 i 16 mm^2 (m)
c_{70}, c_{35}, c_{16} – cijena SKS 70 mm^2, 35 mm^2 i 16mm^2 (€/m)
n – ukupan broj potrošača
c_P – cijena kućnog priključka sa opremom i ugradnjom (€/kom)

Proračun troškova je potrebno izvesti određenom stopom aktualizacije troškova. Aktualizacijom troškova ulaganja i ostalih troškova svode se sve financijske veličine ulaganja i pogonskih troškova pojedinih etapa razvitka na početnu godinu, kako bi se ukupni troškovi pojedinih varijanti mogli međusobno usporediti. U svim promatranim varijantama planiranja moraju se primijeniti jednake stope aktualizacije troškova.

2.4.6. Kriterij pouzdanosti napajanja

Kvarovi u mreži ne mogu se izbjeći. Dopušteno vrijeme prekida napajanja kod kvara ovisno je o količini neisporučene električne snage, a posredno i električne energije. Temeljna zadaća inženjera–planera je da sustav radi pouzdano i sigurno uz prihvatljive troškove i da se održi raspoloživost, sigurnost i cjelovitost sustava na zadovoljavajućoj razini, te da se sustav odupre raznim poremećajima i kvarovima koji su široko rasprostranjeni u svim dijelovima sustava.

U procesu deregulacije elektroenergetskog tržišta i uvođenja konkurencije među distributerima aktualizira se problem pouzdanosti, odnosno kvalitete električne energije koja se isporučuje krajnjim kupcima. Električna energija, kao i svaki drugi proizvod, mora ispunjavati određene ugovorene norme. Normiranje kvalitete isporučene električne energije u biti se vrši preko dvije grupe pokazatelja:

- Pokazatelji koji se odnose na pouzdanost/kvalitetu isporuke, koji odražavaju stanje elektroenergetske mreže, te učestalost i trajanje prekida u opskrbi;
- Pokazatelji koji se odnose na kvalitetu napona, koji odražavaju razinu i oblik napona na mjestu isporuke i definirani su normom EN50160.

Pokazatelji kvalitete napona imaju izuzetnu važnost za manju skupinu specifičnih kupaca, dok pokazatelji pouzdanosti isporuke imaju važnost za svakoga kupca. Osiguranje pouzdane opskrbe kupaca električne energije, osim u fazi planiranja razvoja mreže, je obveza distributera i u fazi vođenja, rada i održavanja mreže. Kupci se moraju napajati pouzdano i sigurno. Kako bi se to i ostvarilo potrebno je ispuniti i određene ekonomske uvjete vezane sa pouzdanošću. U slučaju nedovoljnih ulaganja u mrežu kao rezultat se javlja nedovoljna pouzdanost koja se očituje u čestim prekidima u opskrbi kupaca. Prekomjerna ulaganja rezultiraju nepotrebnim troškovima koji se odražavaju na povećanje krajnje cijene električne energije, što za posljedicu ima negativan utjecaj na krajnje kupce. U oba ova slučaja, u jednom monopolističkom sustavu, posljedice ne snose tvrtke nego krajnji kupci. Međutim, u uvjetima dereguliranih tržišta električne energije situacija se bitno mijenja jer nastaju novi, pravno i vlasnički neovisni subjekti.

Prema podacima iz literature koja analizira praksu distribucijskih tvrtki [20], za ocjenu pouzdanosti isporuke električne energije iz distribucijskih mreža koristi se dvadesetak pokazatelja koje definira Standard IEE 1366–2003, odnosno „Vodič pokazatelja pouzdanosti distributivnog sustava“ (*eng. Guide for Electric Power Distribution Reliability Indices*). Proračun pokazatelja pouzdanosti temelji se na registriranju broja i dužine trajanja prekida u isporuci električne energije i utvrđivanju posljedica prekida. Ovisno o načinu praćenja

posljedica prekida računaju se pokazatelji pouzdanosti prema broju potrošača koji su ostali bez opskrbe ili prema neisporučenoj energiji.

Većina tvrtki ili regulatornih agencija odlučuje se za izbor nekoliko pokazatelja po kojima se prati pouzdanost isporuke električne energije i najčešće su to: SAIFI, SAIDI i CAIDI.

Ovi pokazatelji pouzdanosti definirani su na slijedeći način [21], [22], [23], [24]:

1. SAIFI – *eng. System Average Interruption Frequency Index*

   Ovaj pokazatelj naziva se indeks prosječne učestalosti prekida sustava i pokazuje prosječan broj prekida po kupcu godišnje na razini sustava. Matematički, računa se prema jednadžbi:

$$SAIFI = \frac{\sum_{i=1}^{K} N_i}{N_T} \tag{2.32}$$

   gdje su: K – ukupan broj prekida
   N_i – broj kupaca koji su osjetili prekid opskrbe
   N_T – ukupan broj usluženih kupaca

2. SAIDI – *eng. System Average Interruption Duration Index*

   Ovaj pokazatelj naziva se indeks prosječne dužine trajanja prekida sustava i pokazuje prosječno trajanje prekida po kupcu na razini sustava. Obično se mjeri u minutama prekida. Matematički, računa se prema jednadžbi:

$$SAIDI = \frac{\sum_{i=1}^{K} N_i \cdot t_i}{N_T} \tag{2.33}$$

   gdje su: K – ukupan broj prekida
   N_i – broj kupaca koji su osjetili prekid opskrbe
   N_T – ukupan broj usluženih kupaca
   t_i – trajanje i–tog prekida u minutama

3. CAIDI – *eng. Customer Average Interruption Duration Index*

   Ovaj pokazatelj naziva se indeks prosječnog trajanja prekida kupaca i pokazuje prosječno vrijeme potrebno da se ponovno uspostavi opskrba kupaca. Matematički, računa se prema jednadžbi:

$$CAIDI = \frac{\sum_{i=1}^{K} N_i \cdot t_i}{\sum_{i=1}^{K} N_i} = \frac{SAIDI}{SAIFI} \tag{2.34}$$

Predočeni pokazatelji pouzdanosti mogu značajno odstupati na različitim područjima potrošnje. Najznačajnija odstupanja su pri podjeli potrošnje na pretežito urbano i pretežito ruralno područje potrošnje. Niže vrijednosti pokazatelja pouzdanosti očekuju se u pretežito urbanim područjima u kojima dominira kabelska mreža, dok se više vrijednosti ovih pokazatelja očekuju u pretežito ruralnim područjima u kojima dominira nadzemna mreža.

Regulatorne agencije, kroz regulatorne mehanizme, provjeravaju potrebe i očekivanja potrošača u vezi sa kvalitetom isporuke električne energije, odnosno procjenjuju spremnost potrošača da plate veću cijenu električne energije u cilju poboljšanja pouzdanosti isporuke (*eng. willingness to pay*).

3. HIJERARHIJSKE I STOHASTIČKE METODE OPTIMIZACIJE

3.1. OPĆENITO O OPTIMIZACIJI

Problemi pronalaženja optimalnog rješenja susreću se i rješavaju svakodnevno. Na njih se nailazi skoro posvuda, a po prirodi su veoma raznovrsni. Zajedničko za sve njih je nastojanje da se pronađe rješenje koje u najvećoj mogućoj mjeri udovoljava potrebama, odnosno stvara najveću korist.

Predmet razmatranja optimizacije su problemi za koje postoje manje ili više dobro razrađeni matematički modeli ili za koje se takvi modeli moraju napraviti. Konkretnije, predmet su modeli i metode optimizacije za odabrane klase problema koji se često susreću u praksi, a matematički su relativno dobro obrađeni. Pri ovome se mora uzeti u obzir da se u teoriji optimizacije prvenstveno traži rješenje postavljenog optimizacijskog problema i ne razmatra se pitanje koliko postojeći model odgovara realnom zadatku.

3.1.1. Formuliranje problema optimizacije

Teorija optimizacije se bavi razvojem modela i metoda kojima se nalaze optimalna rješenja matematički formuliranih problema [25]. Bilo koje rješenje problema označavamo sa *x*. U pravilu, *x* u stvari predstavlja $x = (x_1, \ldots, x_n)$. Komponente rješenja x_j , $j = 1,\ldots,n$, nazivaju se *upravljačke varijable* ili *varijable odluke*. Uobičajeno je da se optimalno rješenje označava kao $x^* = (x_1^*, \ldots, x_n^*)$.

Optimalno u pravilu znači najbolje. Da bi se za neko rješenje moglo reći da je najbolje potrebno je imati mjeru temeljem koje će se odrediti kvaliteta rješenja i koja će omogućiti njegovu usporedbu sa drugim mogućim rješenjima. U matematičkom modelu stoga mora postojati funkcija kojom se svakom rješenju pridružuje odgovarajuća vrijednost koja predstavlja mjeru njegove kvalitete. Ta funkcija se naziva *kriterijska funkcija* ili *funkcija cilja*. Uobičajeno se označava sa *f(x)*. Zadatak optimizacije je pronalaženje rješenja koje daje ekstremnu vrijednost kriterija (maksimum ili minimum), kao i određivanje vrijednosti kriterija. Varijable koje je potrebno odrediti međusobno su uvjetovane relacijama i ograničenjima. Matematički izrazi kojima se predočavaju ova ograničenja nazivaju se zajedničkim imenom *skup ograničenja*. Svako rješenje koje zadovoljava postojeća ograničenja naziva se *dopustivim*. Dopustiva rješenja formiraju skupinu dopustivih rješenja ili dopustivu skupinu rješenja *D*. Dopustiva skupina rješenja *D* je određena sustavom ograničenja, koja su obično tipa nejednakosti [26]:

$$D = \{ x \in R^n \mid g_i(x) \leq 0,\ i=1,\ldots,m \} \tag{3.1}$$

gdje su: i – indeks ograničenja
m – ukupan broj ograničenja
g(x) – funkcija ograničenja

Opća zadaća optimizacije je pronalaženje $x \in D$ za koje funkcija $f(x)$ dostiže optimalnu (maksimalnu ili minimalnu) vrijednost.

Kao primjer može se navesti postavka zadatka linearnog programiranja u kojem je potrebno pronaći vrijednost za x koja ima maksimum matematičke linearne funkcije:

$$z = c \cdot x \tag{3.2}$$

pri ograničenjima,

$$\begin{aligned} A \cdot x &\leq b \\ x &\geq 0 \end{aligned} \tag{3.3}$$

gdje su koeficijenti dani matricama,

$$\begin{aligned} c &= \| c_j \|_{1xn} \\ A &= \| a_{ij} \|_{mxn} \\ b &= \| b_i \|_{mx1} \end{aligned} \tag{3.4}$$

Koeficijenti u matematičkom modelu nazivaju se *parametrima modela* ili *parametrima sustava*, a u općem slučaju mogu se označiti kao jedinstvena skupina parametara *A*.

Optimalno rješenje x^* optimizacijskog zadatka je ono za koje vrijedi:

$$f(x^*) \geq f(x), \quad x \in D \tag{3.5}$$

Vrijednost kriterija $f^* = f(x^*)$ koja odgovara optimalnom rješenju naziva se *optimalna vrijednost* ili *optimum*. Ovakva definicija optimuma naziva se i *globalni optimum*, a postavljeni zadatak naziva se *zadatak globalne optimizacije*. Osnovna zadaća teorije optimizacije je rješavanje zadatka globalne optimizacije, čije rješavanje ovisi o kriterijskoj funkciji, tipovima ograničenja i primijenjene metode. Pri ovome postoji rizik da se primjenom određene metode kao rješenje dobije *lokalni optimum*, kao što je prikazano na slici 3.1 [27].

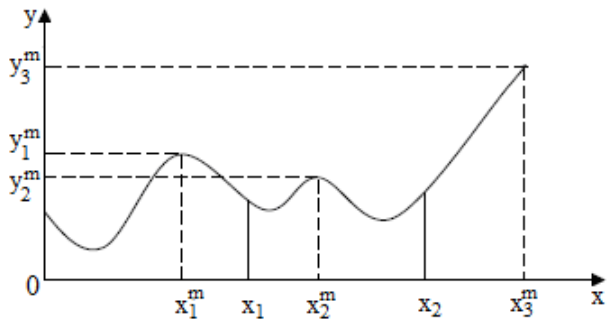

Slika 3.1. *Lokalni i globalni optimum*

U intervalu $0 \le x \le x_1$ maksimalna vrijednost funkcije se dostiže u točki x_1^m i iznosi $y_1^m = f(x_1^m)$. Ukoliko se promatra samo interval $x_1 \le x \le x_2$ maksimalna vrijednost funkcije se dostiže u točki x_2^m i iznosi $y_2^m = f(x_2^m)$, dok je za interval $0 \le x \le x_2$ maksimalna vrijednost funkcije u točki x_1^m. Međutim, kada se promatra cijeli interval $0 \le x \le x_3^m$ maksimalna vrijednost funkcije je u točki x_3^m koja se nalazi na granici intervala. Tako se može reći da u točkama x_1^m i x_2^m funkcija ima lokalne maksimume, dok se globalni maksimum funkcije dostiže u točki $x^* = x_3^m$. U općem slučaju može se reći da funkcija f (x) ima lokalni maksimum u točki x^m ukoliko za sve točke definirane δ-okoline, $| x - x^m | < \delta$, vrijedi $f(x^*) \ge f(x)$.

3.1.2. Klasificiranje optimizacijskih problema

Za potrebe klasificiranja optimizacijskih problema mogu se koristiti različiti kriteriji. Ovdje će biti navedene samo neke od temeljnih klasifikacija [28].

Ovisno o tome da li postoje ograničenja na promjenjivim veličinama razlikuju se problemi:

- *uvjetne optimizacije*, odnosno optimizacije u ovisnosti o zadanim ograničenjima,
- *bezuvjetne optimizacije*, kada promjenjive veličine nisu međusobno uvjetovane jednadžbama i/ili nejednadžbama.

Ovisno o tome da li su parametri u optimizacijskom problemu poznati, slučajnog karaktera ili su neodređeni, razlikuju se:

- *deterministički zadaci*,
- *zadaci stohastičke optimizacije*,
- *zadaci optimizacije u uvjetima neodređenosti*.

U stohastičkim sustavima parametri sustava ili promatrani proces imaju slučajan karakter koji je opisan metodama iz teorije vjerojatnosti i statistike. Postoje dvije velike skupine metoda stohastičke optimizacije, a to su:

- *Implicitne metode*;
- *Eksplicitne metode*.

Implicitne metode mogu se primjenjivati samo za diskretne stohastičke probleme u kojima je broj mogućih rješenja relativno malen, odnosno takav da se svako rješenje može analizirati. U primjeni ovih metoda razlikuju se tri temeljna koraka:

1. Određivanje svih mogućih realizacija slučajnih veličina;
2. Izvršavanje determinističkih optimizacija za svaku realizaciju;
3. Analiziranje rezultata i odabir rješenja.

Eksplicitne metode stohastičkog programiranja primjenjuju se za diskretne i kontinuirane stohastičke probleme. Pri tome se može dogoditi da kriterijska i/ili funkcija ograničenja ima stohastičku prirodu.

Kada su parametri u kriterijskoj funkciji stohastičke prirode uobičajena su slijedeća dva pristupa:

1. Potrebno je odrediti *x* tako da se dobije maksimum kriterijske funkcije,

$$\max_{x \in D} E\,[\,f(x)\,] \tag{3.6}$$

2. Potrebno je odrediti *x* tako da se dobije maksimum vjerojatnosti da je kriterijska funkcija veća od neke zadane vrijednosti,

$$\max_{x \in D} P_r\,[\,f(x) \geq f_0\,] \tag{3.7}$$

U slučaju da parametri u funkcijama ograničenja imaju slučajan karakter nije izvjesno da se odabirom upravljačkih varijabli može osigurati da ona uvijek bude zadovoljena. Zato se formulira novi zadatak optimizacije u kojem se traži da je vjerojatnost da će ograničenje biti zadovoljeno veća od neke zadane vrijednosti.

Promatrajmo zadatak linearnog programiranja u kojem su parametri u sustavu ograničenja stohastičke prirode. Potrebno je odrediti $x = (x_1, \ldots, x_n)$ tako da se nađe maksimum funkcije:

$$z = \sum_{j=1}^{n} c_j \cdot x_j \tag{3.8}$$

pri ograničenjima,

$$\sum_{j=1}^{n} a_{ij} \cdot x_j \leq b_i\,, \quad i = 1, \ldots, m$$
$$x_j \geq 0\,, \; j = 1, \ldots, n \tag{3.9}$$

U ovom slučaju se originalni zadatak transformira u novi zadatak, pri čemu se nova ograničenja formuliraju temeljem zahtjeva da originalna ograničenja budu zadovoljena sa određenim zadanim vjerojatnostima α_i , $i = 1, \ldots, m$. To znači da je potrebno odrediti $x = (x_1, \ldots, x_n)$ tako da se nađe maksimum funkcije 3.8, uz ograničenja:

$$P_r\left[\sum_{j=1}^{n} a_{ij} \cdot x_j \leq b_i\right] \geq \alpha_i\,, \quad i = 1, \ldots, m \tag{3.10}$$

gdje su $\alpha_i \in (0\,,\,1)$ zadane vrijednosti.

Kada su slučajne veličine samo sa desne strane nejednadžbi u sustavu ograničenja, odnosno kada su slučajne prirode samo parametri b_i , $i = 1, \dots , m$, i to tako da su opisani normalnim razdiobama, sa parametrima $\mu_i = E [b_i]$ i $\sigma_i^2 = Var [b_i]$, tada se uspostavljeni zadatak linearnog programiranja zamjenjuje slijedećim deterministčkim zadatkom. Potrebno je odrediti $x = (x_1, \dots , x_n)$ tako da se nađe maksimum funkcije 3.8, uz ograničenja:

$$\sum_{j=1}^{n} a_{ij} \cdot x_j \leq \mu_i + K_{\alpha i} \cdot \sigma_i , \quad i = 1, \dots , m \tag{3.11}$$

$$x_j \geq 0 , \; j = 1, \dots , n$$

gdje se faktor povjerenja $K_{\alpha i}$ određuje iz uvjeta,

$$P_r \left\{ K_{\alpha i} \leq \frac{b_i - \mu_i}{\sigma_i} \right\} = \alpha_i \tag{3.12}$$

Slijedeća podjela optimizacijskih problema je na:

- *Kontinuirane*;
- *Diskretne*.

U kontinuiranim problemima upravljačke varijable uzimaju vrijednosti iz skupa realnih problema.

U diskretnim problemima postoji dodatno ograničenje takvo da upravljačke varijable mogu imati samo određene diskretne vrijednosti iz skupa realnih brojeva. Obično se radi o skupu cijelih brojeva, o skupu prirodnih brojeva ili o binarnom skupu {0 , 1}.

Značajnu klasu zadataka optimizacije predstavljaju problemi optimalnog upravljanja sustavima. To su zadaci upravljanja kao funkcije vremena. Upravljanjem je potrebno promatrani sustav, uz poštivanje određenih uvjeta i ograničenja, u nekom vremenskom intervalu prevesti iz početnog u željeno stanje, a da pri tome odabrani kriterij, tzv. *indeks performanse*, dobije ekstremnu vrijednost. Rješenje zadatka optimalnog upravljanja nisu brojevi nego funkcije. To je bitna razlika u odnosu na do sada promatrane zadatke optimizacije. Nekom upravljanju, odnosno nekoj određenoj vremenskoj funkciji, pridružuje se broj koji označava kvalitetu upravljanja. Drugim riječima, *indeks performanse* je preslikavanje skupa funkcija na skup točaka [29].

Dakle, optimizacija u biti predstavlja postupak maksimiziranja, odnosno minimiziranja nekog cilja (ili ciljeva), uz zadovoljavanje objektivnih ograničenja. Proces optimizacije podrazumijeva sustavno traženje optimalnog rješenja zadanog problema, a u uvjetima zadovoljavanja zadanih kriterija. Procesi optimizacije danas imaju sve veću važnost i sve širu

primjenu. Današnja logika kod upravljanja distribucijskim elektroenergetskim sustavom nije samo odrediti rješenje koje zadovoljava sve uvjete, nego i minimiziranje troškova, odnosno maksimiziranje uspostavljenih ciljeva. Optimizacija se stoga istovremeno može shvatiti i kao način uspostavljanja inženjerskog zadatka, ali i kao specijalizirani alat, odnosno način potpore pri odlučivanju u sustavu upravljanja distribucijskim sustavom. Kod optimizacije se tijek predloženih rješenja sustavno vodi na način da sve bolje ispunjava postavljene kriterije optimalnosti, uz istovremeno zadovoljavanje ograničenja. Optimizacija je iterativni postupak bez obzira da li se sprovodi klasičnim putem (inženjersko naslijeđe, iskustvo, intuicija) ili je potpomognuta numeričkim postupcima. Na slici 3.2 je dat prikaz klasičnog optimizacijskog procesa [30].

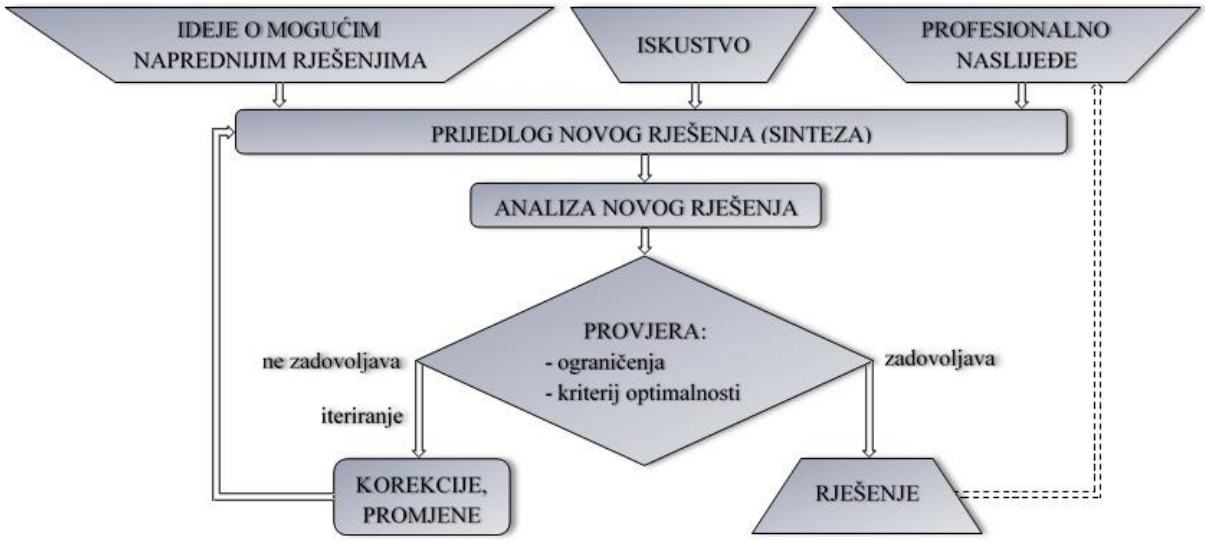

Slika 3.2. *Opći prikaz optimizacijskog procesa*

3.1.3. Pregled optimizacijskih metoda

Raniji optimizacijski postupci bili su temeljeni uglavnom na profesionalnom iskustvu, intuiciji i brojnim pokušajima. Široka primjena numeričkih, a u posljednje vrijeme sve više heurističkih optimizacijskih metoda, u uvjetima sve zahtjevnijeg tržišnog poslovanja, omogućena je razvojem računala, sa velikom mogućnošću obrade podataka koja je potrebna u postupku optimizacije. Uz suvremenu primjenu računala razvijeni su i odgovarajući algoritmi i programski alati. Danas se postupci optimizacije primjenjuju u cijelom nizu linearnih i nelinearnih problema.

Optimizacijske metode mogu se uglavnom klasificirati u tri skupine [31], i to:

a) *Konvencionalne optimizacijske metode*;
b) *Metode inteligentnog pretraživanja*;
c) *Metode rješavanja neizvjesnosti ciljeva i ograničenja*.

a) Konvencionalne optimizacijske metode

Ove metode su se sustavno počele razvijati još u antičkoj Grčkoj, i nastavile su se razvijati kroz čitavu povijest. Ovim metodama se kroz povijest bavio veliki broj matematičara i fizičara kao što su: Euklid, Arhimed, Fibonacci, Lagrange, Fourier, Newton, Gauss, Seidel, Ljapunov itd. Rezultate koje su ovi znanstvenici dobili svojim istraživanjima su kasnije preuzeli matematičari i dalje ih usavršili, dokazali i generalizirali.

Ova skupina uključuje [32], [33], [34]:

1) optimizaciju bez ograničenja (*eng. unconstrained optimization*),
2) linearno programiranje (*eng. linear programming*),
3) nelinearno programiranje (*eng. nonlinear programming*),
4) kvadratno programiranje (*eng. quadratic programming*),
5) Newtonovu metodu (*eng. Newton method*),
6) metodu unutarnje točke (*eng. interior point method*),
7) mješovito–cjelobrojno programiranje (*eng. mixed–integer programming*),
8) programiranje mrežnih tokova (*eng. network flow programming*).

1) Optimizacija bez ograničenja

   Optimizacijski pristup bez ograničenja je temelj optimizacijskih algoritama sa ograničenjima. Većina optimizacijskih problema sa ograničenjima, u distribucijskom elektroenergetskom sustavu, mogu se prevesti u optimizacijske probleme bez ograničenja. Glavne optimizacijske metode bez ograničenja, koje se koriste u optimizaciji distribucijskih elektroenergetskih sustava, su: gradijentna metoda (*eng. gradient method*), linijsko pretraživanje (*eng. line search*), Lagrangeova metoda multipliciranja (*eng. Lagrange multiplier method*), Newton–Raphsonova metoda (*eng. Newton–Raphson method*), kvazi–Newtonova metoda (*eng. quasi–Newton method*) itd.

2) Linearno programiranje

   Linearno programiranje se koristi za linearizaciju nelinearnih optimizacijskih problema distribucijskog elektroenergetskog sustava. Funkcija cilja i ograničenja imaju linearnu formu. Najpoznatija metoda za rješavanje linearnih problema je simpleks metoda (*eng. simplex method*).

   Ovaj pristup ima nekoliko prednosti, od kojih su neke:

   - Pouzdanost, naročito kada su u pitanju svojstva konvergencije;
   - Brzo identificiranje neizvodljivosti;
   - Pribrajanje velikog izbora ograničenja distribucijskog elektroenergetskog sustava, uključujući veoma važna nepredviđena ograničenja.

Nedostaci ovog pristupa su:

- Netočna procjena gubitaka sustava;
- Nedovoljna preciznost u pronalaženju točnog rješenja.

Međutim, praktična uporaba pokazuje da rezultati dobiveni primjenom linearnog programiranja uglavnom zadovoljavaju zahtjeve inženjerske točnosti. Stoga se linearno programiranje široko primjenjuje u rješavanju problema distribucijskog elektroenergetskog sustava kao što su upravljanje sustavom (dispečing), optimalni tokovi snaga, optimizacija jalove snage itd.

3) Nelinearno programiranje

Problemi distribucijskog sustava uglavnom su nelinearni. Stoga se tehnike nelinearnog programiranja mogu veoma lako primijeniti za rješavanje ovakvih problema, kod kojih i funkcija cilja, kao i ograničenja imaju nelinearan karakter. Prvi korak u primjeni ovih tehnika je odabir smjera pretraživanja u iterativnoj proceduri, koji je određen prvom parcijalnom derivacijom jednadžbi (reducirani gradijent). Zato se ove tehnike mogu klasificirati kao metode prvog reda. Metode nelinearnog programiranja imaju znatno veću točnost nego metode linearnog programiranja i također imaju globalnu konvergenciju, što znači da ovakva konvergencija garantira rješenje koje je neovisno o polaznoj točki. Ipak, u određenim slučajevima konvergiranje ka rješenju može biti sporo radi cik–cak kretanja u prostoru pretraživanja.

4) Kvadratno programiranje

Kvadratno programiranje je specijalna forma nelinearnog programiranja. Funkcija cilja je kvadratna, a ograničenja imaju linearnu formu. I ove metode imaju znatno veću točnost nego metode linearnog programiranja. Najčešće korištena funkcija cilja u optimizaciji elektroenergetskog sustava je cijena troškova generatora, koja je u pravilu kvadratna.

5) Newtonova metoda

Newtonova metoda zahtijeva računanje parcijalnih derivacija drugog reda u jednadžbama tokova snaga i ograničenjima, te se još naziva i metoda drugog reda. Nužni uvjeti optimalnosti uobičajeno su Kuhn–Tuckerovi uvjeti. Newtonova metoda je u širokoj uporabi zbog svojih kvadratnih svojstava konvergencije.

6) Metoda unutarnje točke

Ova metoda je izvorno korištena za rješavanje problema linearnog programiranja. Ona je brža i možda bolja od konvencionalnog simpleks algoritma u linearnom programiranju. Metoda je 1990–tih godina primjenjivana za rješavanje problema optimalnih tokova snaga, a u posljednje vrijeme je proširena i poboljšana kako bi se njom mogli rješavati problemi optimalnih tokova snaga kvadratnih i nelinearnih formi.

7) Mješovito–cjelobrojno programiranje

   Problemi u elektroenergetskom sustavu mogu se formulirati i kao mješovito–cjelobrojni optimizacijski problemi sa cjelobrojnim varijablama, kao što su kut faznog pomaka ili uključen/isključen status uređaja. Mješovito–cjelobrojno programiranje zahtijeva velike računalne resurse, a veliki broj diskretnih varijabli je važan pokazatelj koliko je ova metoda teška za rješavanje. Za razdvajanje problema mješovito–cjelobrojnog programiranja na kontinuirane i cjelobrojne probleme koriste se dekompozicijske tehnike. Ove tehnike mogu u velikoj mjeri reducirati dimenzije pojedinih podproblema. Rezultati pokazuju značajno reduciranje broja iteracija, potrebno vrijeme proračuna i memorijski prostor. Mješovito–cjelobrojno programiranje može se koristiti za rješavanje optimalnih tokova snaga, kao i za optimalnu rekonfiguraciju distribucijske elektroenergetske mreže.

8) Programiranje mrežnih tokova

   Ova metoda je specijalizirana metoda linearnog programiranja. Upotrijebljena je prvi put za rješavanje optimizacijskih problema 1980–tih godina. U početku je uglavnom korištena na linearnim modelima. U novije vrijeme se koristi metoda nelinearnog konveksnog programiranja mrežnih tokova u optimizaciji elektroenergetskih sustava. Algoritme temeljene na programiranju mrežnih tokova karakterizira velika brzina i jednostavan proračun.

b) Metode inteligentnog pretraživanja

Ove metode pripadaju heurističkim (iskustvenim) metodama i danas imaju primjenu u rješavanju širokog spektra optimizacijskih problema. Naročito su prikladne za rješavanje problema koji se ne mogu dobro matematički formulirati. Također, prigodne su za rješavanje problema koji bi se mogli rješavati matematičkim metodama, ali zbog nedostatka ili nepouzdanosti raspoloživih podataka nisu prigodne. Ove metode su prigodne za rješavanje problema sa poznatim matematičkim algoritmom, ponekad čak i jednostavnim, ali bi njegova primjena zbog velikog broja nepoznatih veličina zahtijevala nedopustivo mnogo vremena. Metodama umjetne inteligencije nastoji se eliminirati traženje rješenja za koja se približnim rezoniranjem može zaključiti da vjerojatno ne sadrže optimum. Na taj način se rješenja dobivaju relativno brzo, ali se ne može dokazati da su apsolutno najbolja, odnosno ne može se sa sigurnošću tvrditi da su to optimalna rješenja. Za ovakva rješenja se može jedino tvrditi, sa velikom vjerojatnoću, da su ona bolja od rješenja koja bi se dobila bez primjene određene metode. Lista ovih metoda je dosta dugačka, ali neke od najšire upotrebljavanih pri rješavanju optimizacijskih problema su [35], [36]:

1) Monte Carlo metoda (*eng. Monte Carlo method*);
2) Ekspertni sustavi (*eng. expert systems*);
3) Neuronske mreže (*eng. neural networks*);
4) Genetski algoritmi (*eng. genetic algorithms*);

5) Evolucijsko programiranje (*eng. evolutionary programming*);
6) Simulirano kaljenje (*eng. simulated annealing*);
7) Tabu algoritam (*eng. tabu search algorithm*);
8) Rojenje čestica (*eng. particle swarm*).

1) Monte Carlo metoda

Kod ove metode se umjesto pretraživanja cjelokupnog područja mogućih rješenja pretražuju samo slučajno odabrane točke u tom području. Nakon toga se traži optimum među tim točkama. Slučajno pretraživanje u stvari na računalu znači kvazi–slučajno, odnosno postiže se pomoću deterministčkih algoritama, odnosno generatorom slučajnih brojeva. Obzirom da generator slučajnih brojeva u biti podsjeća na kockarnicu onda i naziv Monte Carlo proizlazi iz toga. Dobivene točke najčešće se upotrebljavaju za lokalnu optimizaciju. Postoji mnogo varijanti Monte Carlo metode.

2) Ekspertni sustavi

Ovi sustavi se služe iskustvenim (heurističkim) pravilima kojima oponašaju žive eksperte. U principu se pravila utvrđuju u suradnji sa više stručnjaka, a mogu se i automatski određivati drugim metodama. Ovi sustavi su se pokazali djelotvornim u mnogim praktičnim primjenama.

3) Neuronske mreže

Neuronske mreže su prvi put upotrijebljene za rješavanje problema linearne optimizacije 1986 godine. Kasnije su proširene na rješavanje problema nelinearnog programiranja i u cijelosti su drugačije od tradicionalnih optimizacijskih metoda. One mijenjaju rješenje optimizacijskog problema u točku ravnoteže (*eng. equilibrium point*) nelinearnih dinamičkih sustava i mijenjaju optimalni kriterij u energetske funkcije dinamičkih sustava. Ove mreže se sastoje od sustava čvorova i veza između njih tako da pokušavaju simulirati funkcioniranje ljudskog mozga. Većinom su realizirane softverski i predstavljaju u stvari programske pakete. One se ne programiraju nego se uče na primjerima. Kao podaci u njih se unose primjeri sa gotovim rješenjima pa računalo, temeljem toga, automatski generira određena pravila. To znači da se prije uporabe ovakvi programi moraju dobro istrenirati.

4) Genetski algoritmi

Genetski algoritam je pretraživački algoritam temeljen na pretpostavci prirodne selekcije i genetike. U biti predstavlja pokušaj primjene Darwinove (*Darwin*) teorije. Značajke genetskog algoritma su drugačije od drugih pretraživačkih algoritama u nekoliko aspekata:

1. To je više–putni algoritam koji pretražuje mnogo vrhova istovremeno i stoga reducira mogućnost zapadanja u stupicu lokalnog minimuma;

2. Radi sa kodiranjem parametara umjesto sa samim parametrima. Kodiranje parametara potpomaže razvoj trenutnog stanja u slijedeće stanje sa minimumom proračuna;
3. Ocjenjuje funkciju cilja svakog niza kao vodiča svog pretraživanja umjesto optimizacijske funkcije;
4. Istražuje prostor pretraživanja gdje je vjerojatnost pronalaženja najboljeg rješenja najveća.

Kod ovog algoritma se u nultom koraku, pomoću generatora slučajnih brojeva, generira populacija potencijalnih rješenja koja zadovoljavaju propisana ograničenja i koja se nazivaju *genomi*. Između njih se odabere podskup odabranog broja najboljih. Najbolja rješenja se dobiju kao skup rješenja koja imaju najmanju vrijednost funkcije cilja. Svako od tih rješenja je definirano odabranim brojem *gena*. U svakom od narednih koraka se generiraju potomci koji od svakog roditelja nasljeđuju dio *genetskog koda*. U ovom slučaju priroda se ne kopira dosljedno tako da svako dijete može imati i više od dva roditelja. Osim toga, rješenja koja su dovoljno dobra ne stare i ne umiru, nego mogu živjeti vječno. Unija skupa roditelja i skupa potomaka čini novi zajednički skup iz kojeg se ponovno odabire podskup najboljih. Osim križanja predviđene su i mutacije, odnosno slučajne promjene vrijednosti nekog gena, iz razloga što je u konačnom rješenju moguća pojava gena koje nema niti jedan roditelj, a koji mogu dovesti do boljeg rješenja. Radi još veće raznolikosti postoji mogućnost uvođenja *genoma* koji nisu dobiveni modificiranjem starih. To su tzv. *genomi imigranti*. Ovaj algoritam nema definiran kraj, nego se postupak uvijek može nastaviti. Ipak, nakon određenog broja koraka nova poboljšanja su vrlo rijetka i mala, pa se postupak obično prekida po nekom kriteriju. Genetski algoritmi se primjenjuju za mnoge vrste problema, a naročito za rješavanje problema kombinatorne optimizacije. Još bolji rezultati dobivaju se kombiniranjem sa nekom od klasičnih metoda. Svako rješenje dobiveno genetskim algoritmom postaje polazni uvjet za lokalni postupak klasične optimizacije. Lokalni optimumi ponovo ulaze u novi korak genetskog algoritma. Dakle, potomci se generiraju križanjem roditelja i optimizacijom.

5) Evolucijsko programiranje

Evolucijsko programiranje je stohastički proces sličan genetskom algoritmu. Može se primijeniti i na izradu računalnih programa. U tom programu geni su različite programske naredbe, koje se u početku generiraju kao slučajni nizovi naredbi. Bolji je onaj program koji za više setova ulaznih podataka da više ispravnih rezultata. Između programa se provode postupci križanja i mutacije pa se odabire skup najboljih. Istovremeno se provodi slična prirodna selekcija među setovima. Najbolji set ulaznih podataka je onaj koji je najkritičniji, odnosno onaj na kojem najviše programa daje pogrešne rezultate, pa se mogu eliminirati. Ako neki program zadovoljava sve evoluirane setove znači da je prošao test. U toku evolucije programi zadovoljavaju sve više strogih testova, tako da na kraju procesa ostaju samo oni programi koji su zadovoljili sve testove, pa se kao konačni program uzima onaj koji zadovoljava neki drugi kriterij, npr. brzina.

6) Simulirano kaljenje

Algoritam simuliranog kaljenja pripada skupini aproksimacijskih algoritama. Algoritam se temelji na stohastičkoj tehnici, ali uključuje mnoge dijelove algoritma iterativnog poboljšanja. Algoritam je poznat pod nazivom simulirano kaljenje, ali se u literaturi nalazi još i pod nazivima Monte Carlo kaljenje, stohastičko hlađenje, stohastička relaksacija i algoritam slučajne zamjene. Rezultati dobiveni ovim algoritmom su vrlo blizu optimuma, te ne ovise o polaznoj konfiguraciji. Na taj način, metoda simuliranog kaljenja ne pokazuje nedostatke metode iterativnog poboljšanja, te daje bolje rezultate, ali je nešto sporija. U svom originalnom obliku algoritam simuliranog kaljenja se temelji na analogiji između simulacije kaljenja metala i problema kombinatorne optimizacije. U fizici krutih tvari, kaljenje predstavlja proces u kojemu se materijal zagrije do maksimalne temperature (temperatura kaljenja) pri kojoj je unutarnja struktura stohastički organizirana. Niz postupaka laganog hlađenja uzrokuje da unutrašnji raspored elementarnih jedinica poprima stanje sve manje energije, prilagođavajući se temperaturi (unutarnja energija proporcionalna je temperaturi). Algoritam polazi od slučajnog ili drugim metodama dobivenog polaznog rješenja i pokušava slučajnim varijacijama određenog rješenja naći bolje. Pri tome je dopušteno i pogoršano rješenje u pojedinim koracima, kako bi se izašlo iz lokalnog minimuma. U tijeku postupka dolazi do postupnog snižavanja temperature. Najnovije varijante algoritma automatski popravljaju parametre optimizacije za vrijeme proračuna temeljem iskustva iz dotadašnjeg tijeka procesa.

7) Tabu algoritam

Jednostavni heuristički algoritmi često ne konvergiraju zbog pojave višestrukog pretraživanja već pretraženih dijelova dopuštenog područja, pa se pojavljuju beskonačni ciklusi. Tabu algoritam čuva podatke o povijesti već obavljenog pretraživanja, pa se ne dozvoljava ponovno pretraživanje istih područja. Na ovaj način se uvijek istražuje novo područje zbog čega se povećava vjerojatnost pronalaženja globalnog optimuma. I ovaj algoritam se često kombinira sa drugim metodama.

8) Rojenje čestica

Ovo je nova metodologija u evolucijskom programiranju koja je na neki način slična genetskom algoritmu. U ovoj metodologiji se sustav pokreće populacijom slučajnih rješenja. Za razliku od ostalih algoritama, svakom potencijalnom rješenju, nazvanom čestica, je dodijeljena nasumična brzina, a zatim se takvo rješenje kreće kroz hiper prostor rješenja. Ova vrsta optimizacije je ekstremno djelotvorna u rješavanju širokog opsega inženjerskih problema. Veoma je jednostavna za primjenu jer algoritam sadrži dva reda računalnog koda i rješava probleme veoma brzo.

c) Metode rješavanja neizvjesnosti ciljeva i ograničenja

U ovu skupinu pripadaju [37], [38], [39]:

1) Optimizacija temeljem vjerojatnosti (*eng. probabilistic optimization*);
2) Neizrazita logika (*eng. fuzzy logic*);
3) Analitički hijerarhijski postupak (*eng. analytic hierarchy process*).

1) Optimizacija temeljem vjerojatnosti

Metode temeljene na teoriji vjerojatnosti su učinkovite tehnike za dokazivanje postojanja kombinatornih problema koji imaju neka specifična svojstva. Temeljene su na teoriji vjerojatnosti, ali se mogu koristiti za dokazivanje teorema koji nemaju ništa sa teorijom vjerojatnosti. Najčešće se koriste pri analizama modela sa neizvjesnostima i promjenjivim parametrima, a mogu se koristiti i za rješavanje stohastičkih optimizacijskih problema.

2) Neizrazita logika

U praksi postoje sustavi sa tzv. *"mutnom" logikom*. Prema klasičnoj logici neka tvrdnja može biti ili istinita ili lažna. Prema mutnoj logici neka tvrdnja nije sasvim istinita, ali ni sasvim lažna, nego joj se može odrediti tzv. *stupanj istinitosti*. Na primjer, za neki predmet možemo reći da nije u cijelosti svijetao, ali niti u cijelosti taman, nego je 30% svijetao i 70% taman. U primjeni neizrazite logike se koriste pravila koja u biti predstavljaju uopćavanje Booleove (*Boole*) algebre. Neizrazita logika može se primijeniti na funkciju cilja, kao i na ograničenja, a posebno na neprobabilističke neizvjesnosti pridružene zahtjevima za reaktivnom snagom sa izvjesnim tehničkim ograničenjima. Uopćeno govoreći, odabirom zadovoljavajućih parametara u ciljevima i ograničenjima postiže se stupanj rješenja veoma blizak optimumu, kao i stupanj izvršenja ograničenja. Maksimiziranjem ovih parametara postiže se cilj optimizacije. Ova metoda se pokazala kao vrlo uspješna i to naročito kod problema automatiziranog upravljanja u realnom vremenu, kada je potrebno vrlo brzo pronaći približno rješenje. Ova metoda se često primjenjuje u kombinaciji sa drugim deterministčkim i probabilističkim metodama.

3) Analitički hijerarhijski postupak

Analitički hijerarhijski postupak (AHP) je strukturalna tehnika za organiziranje i analizu kompleksnih odluka koje se temelje na matematici i psihologiji. Razvijen je 70–tih i 80–tih godina prošloga stoljeća od strane sveučilišnog profesora Thomasa L. Saatyija (*Thomas L. Saaty*). Ova metoda, umjesto predočavanja korektne odluke, pomaže donositeljima odluke da pronađu najbolju odluku koja odgovara njihovim ciljevima i njihovom razumijevanju problema. Ona pruža cjelovit i racionalan okvir za strukturiranje problema odlučivanja, za predstavljanje i kvantificiranje svojih elemenata, za usporedbu ovih elemenata sa krajnjim ciljevima i za vrednovanje alternativnih rješenja. Ovom metodom se prvo vrši

dekompozicija problema u hijerarhiju koju čine jednostavniji podproblemi, od kojih se svaki može neovisno analizirati. Kada se uspostavi hijerarhija, vrši se usporedba elemenata po parovima pri čemu se mora voditi računa o njihovom utjecaju na elemente koji su iznad njih u hijerarhiji. Pri usporedbi se mogu koristiti konkretni podaci o elementima, ali uobičajeno se koristi ocjena njihovog relativnog značaja i važnosti. Suština ove metode je da u donošenju konačne odluke bitnu komponentu čini i ljudska procjena, odnosno procjena donositelja odluke. Ova metoda pretvara ove procjene u numeričke vrijednosti koje mogu biti procesuirane i uspoređivane tijekom cijelog procesa. Na kraju cijeloga procesa dobivaju se izračunate numeričke vrijednosti prioriteta za svaku alternativnu odluku. Te vrijednosti predstavljaju relativne sposobnosti alternativa za postizanje cilja odluke. Ova metoda je najkorisnija gdje skupina ljudi radi na rješavanju složenih problema, koji uključuju ljudska opažanja i procjene, čija primjena ima dugoročne posljedice i efekte.

3.2. HIJERARHIJSKE METODE OPTIMIZACIJE

Prethodno je dan opći prikaz podjele optimizacijskih metoda. Sve navedene metode mogu se koristiti pri rješavanju širokog spektra optimizacijskih problema. Obzirom na veličinu i kompleksnost problema u distribucijskom elektroenergetskom sustavu, u današnje vrijeme, kao najbolje su se pokazale suvremene metode optimizacije, iako i klasične metode nalaze svoju primjenu, naročito kada su u pitanju proračuni tokova snaga u distribucijskim elektroenergetskim mrežama.

U nastavku su dane temeljne teorijske postavke suvremenih optimizacijskih metoda, koje će biti korištene u predloženom modelu planiranja niskonaponskih distribucijskih mreža. Ovdje su obrađene hijerarhijske metode optimizacije.

3.2.1. Općenito o hijerarhijskim optimizacijskim metodama

Sve što radimo, svjesno ili nesvjesno, rezultat je nekih odluka. Ali nisu sve informacije koje dobivamo korisne za poboljšanje razumijevanja i odluka. Ako samo donosimo odluke intuitivno, skloni smo razmišljanju da su sve informacije korisne i što ih više imamo to je bolje. Ali to nije točno. Veće poznavanje informacija ne garantira nam da ćemo bolje razumjeti [40].

Donošenje odluka danas više predstavlja matematičku znanost. Donošenje odluka uključuje mnoge kriterije i podkriterije koji se koriste za rangiranje alternativa odluka. Kriteriji nemaju mjere da posluže kao vodič u rangiranju alternativa i kreiranju prioriteta samih kriterija kako bi se izvagali prioriteti alternativa i dobio željeni rang svih alternativa.

Obzirom da su psihološka istraživanja pokazala da ljudski mozak funkcionira jednodimenzionalno, odnosno na razini usporedbe dva objekta, pojavio se problem kako dati definitivne (ali subjektivne) ocjene većem broju objekata. Dodatni problem se javlja ukoliko donošenje odluke postane još složenije uvođenjem kriterija, koji ovisno o svom prioritetu, različito utječe na odluku.

Tom problematikom se bave višekriterijske metode odlučivanja. U višekriterijske metode mogu se ubrojiti i hijerarhijske metode kao što su: metoda potencijala (*eng. method of potentials*), Saatyjeva metoda svojstvenog vektora ili analitički hijerarhijski postupak (*eng. analytic hierarchy process*), metoda neizrazitog grupiranja (*eng. fuzzy clustering method*), metoda upravljanja portfeljem (*eng. method of portfolio management*) itd.

3.2.2. Analitički hijerarhijski postupak (AHP)

Analitički hijerarhijski postupak (AHP) je razvio Thomas L. Saaty, sveučilišni profesor Sveučilišta u Pittsburgh–u, 70–tih i 80–tih godina 20–tog stoljeća i često se u literaturi može naći pod nazivom Saatyjeva metoda. Ova metoda omogućuje korisniku da procijeni relativnu težinu višekratnih kriterija ili višekratnih opcija, u odnosu na dani kriterij, na intuitivan način. U slučaju da nisu dostupne kvantitativne ocjene procjenitelj i dalje može prepoznati da li je neki kriterij važniji od drugog. Saaty je uspostavio konzistentan način konvertiranja usporedbi (X je važnije od Y) u set brojeva koji predstavljaju relativne prioritete svakog kriterija [41].

Ideja AHP metode je prvo uspostavljanje cilja, a zatim uspostavljanje kriterija koji mogu zadovoljiti, a utječu na odluku donositelja odluke. Kriteriji se mogu svrstati u jednu ili više razina (prva, druga,...) čime se postiže hijerarhija kriterija, pri čemu kriteriji prve razine najviše utječu na odluku.

Temeljna procedura kojom se provodi AHP metoda može se prikazati u nekoliko koraka [42]:

1. Strukturiranje problema odlučivanja i odabir kriterija

Prvi korak je razlaganje problema odlučivanja na sastavne dijelove. U svom najjednostavnijem obliku, ova struktura sadrži cilj na najvišoj razini, kriterije (i podkriterije) na srednjim razinama, dok najniža razina sadrži opcije (alternative). Uređenje svih komponenti hijerarhijski osigurava cjelokupni prikaz kompleksnih odnosa i pomaže donositelju odluke da procijeni da li su elementi na svakoj razini iste veličine kako bi bili točno uspoređeni. Element na danoj razini ne mora funkcionirati kao kriterij za sve elemente na nižim razinama. Svaka razina može predstavljati različiti prekid problema tako da hijerarhija ne mora biti kompletna. Pri hijerarhijskom konstruiranju bitno je uzeti u obzir okruženje problema i identificirati pitanja ili atribute koji utječu na rješenje kao i identificirati sve sudionike pridružene problemu.

2. Uspostavljanje prioriteta kriterija usporedbom po parovima (vaganje – *eng. weighing*)

Za svaki par kriterija, donositelj odluke mora odgovoriti na pitanje: Kolika je važnost kriterija A u odnosu na kriterij B ? Rangiranje relativnih prioriteta kriterija završava se dodjeljivanjem težine između 1 (jednaka važnost) i 9 (izuzetna važnost) za važnije kriterije, a recipročna vrijednost se odnosi na drugi kriterij u paru. Vaganja su tada normalizirana i uprosječena, sa ciljem dobivanja prosječne težine svakog kriterija.

3. Usporedba parova opcija za svaki kriterij (bodovanje – *eng. scoring*)

Svako uparivanje unutar svakog kriterija, usporedbom važnosti opcija, se boduje, ponovno na skali od 1 (jednako dobro) do 9 (apsolutno bolje), dok se drugoj opciji u uparivanju dodjeljuje ocjena jednaka recipročnoj vrijednosti ove ocjene. Svaki skor pokazuje koliko dobro opcija X zadovoljava kriterij Y. Nakon toga, ocjenjivanje se normalizira i uprosječuje. Usporedba elemenata po parovima zahtijeva njihovu međusobnu homogenost, odnosno bliskost, uz uvažavanje zajedničkih atributa. U suprotnom, u procesu mjerenja, mogu se javiti značajne pogreške.

4. Dobivanje pregleda relativnog bodovanja za svaku opciju

U završnom koraku, bodovanje opcija se kombinira sa težinama kriterija kako bi se dobilo ukupno bodovanje za svaku opciju. Obim u kojemu opcije zadovoljavaju kriterije ima težinu sukladno relativnoj važnosti kriterija. Ovo se radi jednostavnim zbrajanjem težina. Na kraju, nakon donošenja odluke o utjecaju svih elemenata i proračunu prioriteta, elementi manje važnosti mogu biti izbačeni iz daljnjeg razmatranja zbog njihovog relativno malog utjecaja na konačni cilj. Nakon toga, prioriteti mogu biti ponovno preračunati, sa ili bez mijenjanja odluke.

U suštini, AHP metoda se može primijeniti u četiri temeljna koraka [43]:

1. Dekompozicija problema u hijerarhiju;
2. Usporedba po parovima i uspostavljanje prioriteta među elementima u hijerarhiji;
3. Sintetiziranje odluka radi dobivanja seta ukupnih odluka ili težina za dostizanje cilja;
4. Evaluacija i provjera konzistentnosti odluka.

Dekompozicija problema za koji treba donijeti odluku u hijerarhiju kriterija i alternativa je prikazana na slici 3.3.

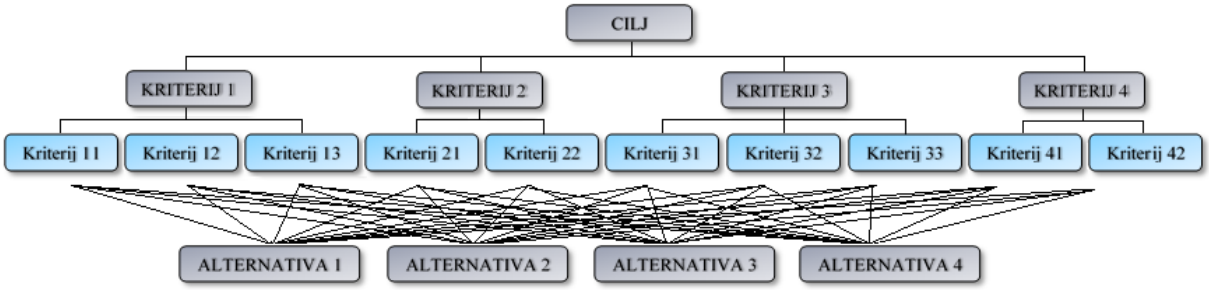

Slika 3.3. *Shematski prikaz dekompozicije problema*

Prva razina je cilj analize. Druga razina je višekriterijska i sastoji se od nekoliko kriterija. Može se također, dodati i nekoliko drugih razina koje čine podkriteriji. Posljednju razinu čine alternative (varijante).

Kako bi se napravila usporedba, potrebna je skala brojeva koja naznačuje koliko je jedan element važniji od drugog. Stoga je prvi korak AHP procedure napraviti usporedbu među parovima svih kriterija. Svaka odluka može se predočiti brojem na određenoj skali. Jedna uobičajena skala je predočena u tablici 3.1 [40], [44], [45], [46].

Tablica 3.1. *Primjer Saatyjeve skale relativne važnosti*

Ocjena važnosti	Definicija	Objašnjenje
1	Jednaka važnost	Dvije aktivnosti doprinose podjednako cilju
2	Slaba ili neznatna važnost	
3	Umjerena važnost	Iskustvo i prosudba blago favoriziraju jednu aktivnost u odnosu na drugu
4	Više umjerena važnost	
5	Jaka važnost	Iskustvo i prosudba jako favoriziraju jednu aktivnost u odnosu na drugu
6	Još jača važnost	
7	Velika važnost	Jedna aktivnost je veoma jako favorizirana u odnosu na drugu. Njena važnost je demonstrirana u praksi
8	Veoma velika važnost	
9	Ekstremna važnost	Jedna aktivnost je ekstremno favorizirana u odnosu na drugu

Rezultati usporedbe (za svaki par) su dani kao cjelobrojne vrijednosti od 1 (jednaka važnost) do 9 (ekstremna važnost), gdje veći broj znači da se odabrana aktivnost promatra kao značajnija u većem stupnju nego druga aktivnost sa kojom se uspoređuje.

Temeljna pretpostavka je da ukoliko je aktivnost A ekstremno važnija od aktivnosti B i ocijenjena sa 9, onda B mora biti apsolutno manje važno od A i ocijenjeno sa 1/9. Ova usporedba se radi za sve faktore koji se razmatraju (obično ne više od 7) i formira se matrica usporedbe.

Težinski omjeri određuju se jednadžbom [43], [47]:

$$w_{ij} = \frac{w_i}{w_j} \tag{3.13}$$

gdje su w_i , w_j relativne važnosti kriterija.

Težinski omjeri se zapisuju u obliku matrice težinskih omjera koja ima oblik:

$$W = \begin{bmatrix} w_{11} & \cdots & w_{1q} \\ \vdots & \ddots & \vdots \\ w_{q1} & \cdots & w_{qq} \end{bmatrix} \tag{3.14}$$

gdje je q broj kriterija.

Slijedeća važna stvar je utvrditi konzistentnost matrice, što znači provjeriti vrijedi li:

$$w_{ij} = w_{ji}^{-1} \tag{3.15}$$

Ponekad može vrijediti i relacija:

$$w_{ij} = w_{ik} \cdot w_{kj} \text{ , } \forall \text{ i, j, k} \tag{3.16}$$

ali pošto se radi o ljudskoj procjeni navedena relacija ne mora vrijediti.

Za matematičko utvrđivanje konzistentnosti koristi se slijedeći postupak:

- Računanje sume stupaca;
- Normiranje matrice (svaki element stupca se podijeli sa zbrojem elemenata tog stupca);
- Računanje sume redaka (težine) u normiranoj matrici;
- Dijeljenje težine sa vektorom prioriteta prve matrice;
- Računanje prosječne vrijednosti dobivenih veličina λ_{max};
- Računanje indeksa konzistencije CI:

$$CI = \frac{\lambda_{max} - n}{n - 1} \tag{3.17}$$

  gdje je *n* stupanj matrice;
- Računanje omjera konzistencije CR:

$$CR = \frac{CI}{RI} \tag{3.18}$$

  gdje je *RI* slučajni indeks.

Vrijednost slučajnog indeksa RI određuje se iz tablice 3.2 [43], [44], [48].

Tablica 3.2. *Vrijednosti slučajnog indeksa konzistencije RI*

n	1	2	3	4	5	6	7	8	9	10
RI	0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49

Ukoliko je $CR \leq 0{,}1$ matrica je konzistentna.

Prioritet pokazuje koliko pojedino svojstvo utječe na odluku. On predstavlja omjer geometrijske sredine jednog retka matrice i zbroja geometrijskih sredina svih redaka:

$$p_i = \frac{m_i}{\sum_{j=1}^{s} m_j} \tag{3.19}$$

gdje je *s* broj stupaca.

Nakon što se sve izračuna konačno se dolazi do vektora prioriteta alternativa iz kojeg se iščita najbolja alternativa. Vektor prioriteta alternativa dobije se množenjem matrice prioriteta alternativa po kriterijima sa vektorom prioriteta kriterija:

$$\begin{bmatrix} \text{prioritet 1.alternative za kriterij 1} & \cdots & \text{prioritet 1.alternative za kriterij m} \\ \vdots & \ddots & \vdots \\ \text{prioritet n.alternative za kriterij 1} & \cdots & \text{prioritet n.alternative za kriterij m} \end{bmatrix} \tag{3.20}$$

odnosno,

$$\begin{bmatrix} \text{prioritet kriterija 1} \\ \vdots \\ \text{prioritet kriterija m} \end{bmatrix} \tag{3.21}$$

Praktična primjena AHP postupka može se prikazati u dva koraka [49].

1) Ispitivanje konzistentnosti kriterija

Pretpostavka je da su nekoj tvrtki u poslovanju bitna četiri kriterija (faktora): K_1, K_2, K_3 i K_4.

Postupak ispitivanja konzistentnosti (dosljednosti) kriterija provodi se kako slijedi.

a) Postavljanje kriterija u redove i stupce

Prvo se uspostavlja inicijalna tablica za usporedbu parova u kojoj glavna dijagonala sadrži brojeve 1, obzirom da je svaki kriterij važan sam sebi.

Kriterij	K_1	K_2	K_3	K_4
K_1	$C_{11} = 1$	C_{12}	C_{13}	C_{14}
K_2	C_{21}	$C_{22} = 1$	C_{23}	C_{24}
K_3	C_{31}	C_{32}	$C_{33} = 1$	C_{34}
K_4	C_{41}	C_{42}	C_{43}	$C_{44} = 1$

b) Usporedba parova kriterija u odnosu na cilj

Nakon toga je potrebno napraviti usporedbu parova. Ne postoji standardni način da se napravi ova usporedba. Primjenom AHP metode to se radi uporabom Saatyjeve tablice (Tablica 4.1).

Pretpostavimo da za tvrtku kriterij K_2 ima neznatnu važnosti u odnosu na kriterij K_1 (ocjena 2). To znači da u tablici element C_{21} dobiva vrijednost 2, a element C_{12} vrijednost 1/2.

Kriterij	K_1	K_2	K_3	K_4
K_1	1	1/2		
K_2	2	1		
K_3			1	
K_4				1

Također, za tvrtku kriterij K_1 ima jaku važnost u odnosu na kriterij K_3 (ocjena 5). Dakle, u tablici element C_{13} dobiva vrijednost 5, a element C_{31} vrijednost 1/5.

Kriterij	K_1	K_2	K_3	K_4
K_1	1	1/2	5	
K_2	2	1		
K_3	1/5		1	
K_4				1

Nadalje, kriterij K_1 ima jednaku važnost u odnosu na kriterij K_4 (ocjena 1). To znači da u tablici elementi C_{14} i C_{41} dobivaju istu vrijednost 1.

Kriterij	K_1	K_2	K_3	K_4
K_1	1	1/2	5	1
K_2	2	1		
K_3	1/5		1	
K_4	1			1

Za tvrtku kriterij K_2 ima veliku važnost u odnosu na kriterij K_3 (ocjena 7). Dakle, u tablici element C_{23} dobiva vrijednost 7, a element C_{32} vrijednost 1/7.

Kriterij	K_1	K_2	K_3	K_4
K_1	1	1/2	5	1
K_2	2	1	7	
K_3	1/5	1/7	1	
K_4	1			1

Isto tako, kriterij K_2 ima jaku važnost u odnosu na kriterij K_4 (ocjena 5). To znači da u tablici element C_{24} dobiva vrijednost 5, a element C_{42} dobiva vrijednost 1/5.

Kriterij	K_1	K_2	K_3	K_4
K_1	1	1/2	5	1
K_2	2	1	7	5
K_3	1/5	1/7	1	
K_4	1	1/5		1

I na kraju, kriterij K_4 ima malo umjereniju vrijednost od kriterija K_3 (ocjena 4). Dakle, u tablici element C_{43} dobiva vrijednost 4, a element C_{34} vrijednost 1/4.

Kriterij	K_1	K_2	K_3	K_4
K_1	1	1/2	5	1
K_2	2	1	7	5
K_3	1/5	1/7	1	1/4
K_4	1	1/5	4	1

Dakle, inicijalna matrica usporedbe kriterija u promatranom primjeru izgleda ovako:

$$\begin{bmatrix} 1 & 1/2 & 5 & 1 \\ 2 & 1 & 7 & 5 \\ 1/5 & 1/7 & 1 & 1/4 \\ 1 & 1/5 & 4 & 1 \end{bmatrix}$$

Nadalje, određuje se težina, odnosno geometrijska sredina svakog retka. Geometrijska sredina prvog retka određuje se prema jednadžbi:

$$m_1 = \sqrt[s]{\prod_{i=1}^{s} w_{1,i}} \tag{3.22}$$

gdje je *s* broj stupaca.

Proračunom geometrijskih sredina svakog retka, prema jednadžbi 3.22, dobiva se:

Kriterij	K_1	K_2	K_3	K_4	Geometrijska sredina
K_1	1	1/2	5	1	1,257
K_2	2	1	7	5	2,893
K_3	1/5	1/7	1	1/4	0,291
K_4	1	1/5	4	1	0,946

Vrijednosti prioriteta kriterija računaju se prema jednadžbi (3.19), tako da se dobiva:

Kriterij	K_1	K_2	K_3	K_4	Geometrijska sredina	Prioritet
K_1	1	1/2	5	1	1,257	0,233
K_2	2	1	7	5	2,893	0,537
K_3	1/5	1/7	1	1/4	0,291	0,054
K_4	1	1/5	4	1	0,946	0,176

odnosno,

$$\begin{bmatrix} p_{k_1} \\ p_{k_2} \\ p_{k_3} \\ p_{k_4} \end{bmatrix} = \begin{bmatrix} 0,233 \\ 0,537 \\ 0,054 \\ 0,176 \end{bmatrix}$$

c) Određivanje vektora svojstvenih vrijednosti matrice usporedbe

Prvo se vrši dijeljenje svakog elementa matrice usporedbe sa zbrojem odgovarajućeg stupca u kojemu se taj element nalazi, prema jednadžbi:

$$X_{ij} = \frac{C_{ij}}{\sum_{i=1}^{n} C_{ij}} = \begin{bmatrix} X_{11} & X_{12} & X_{13} & X_{14} \\ X_{21} & X_{22} & X_{23} & X_{24} \\ X_{31} & X_{32} & X_{33} & X_{34} \\ X_{41} & X_{42} & X_{43} & X_{44} \end{bmatrix} \tag{3.23}$$

odnosno dobiva se,

Kriterij	K_1	K_2	K_3	K_4
K_1	0,238	0,271	0,294	0,138
K_2	0,476	0,543	0,412	0,690
K_3	0,048	0,078	0,059	0,028
K_4	0,238	0,109	0,235	0,138

Na ovaj način se dobiva normalizirana matrica usporedbe.

Nakon toga se vrši zbrajanje redaka:

Kriterij	K_1	K_2	K_3	K_4	Zbroj redaka
K_1	0,238	0,271	0,294	0,138	0,941
K_2	0,476	0,543	0,412	0,690	2,121
K_3	0,048	0,078	0,059	0,028	0,213
K_4	0,238	0,109	0,235	0,138	0,720

Dijeljenjem zbroja redaka normalizirane matrice sa ukupnim brojem redaka dobiva se matrica težinskih vrijednosti, prema jednadžbi:

$$W_{ij} = \frac{\sum_{j=1}^{n} X_{ij}}{n} = \begin{bmatrix} W_{11} \\ W_{12} \\ W_{13} \\ W_{14} \end{bmatrix} \tag{3.24}$$

odnosno,

Kriterij	K_1	K_2	K_3	K_4	Zbroj redaka	Težinski vektor
K_1	0,238	0,271	0,294	0,138	0,941	0,235
K_2	0,476	0,543	0,412	0,690	2,121	0,530
K_3	0,048	0,078	0,059	0,028	0,213	0,053
K_4	0,238	0,109	0,235	0,138	0,720	0,180

d) Ispitivanje konzistentnosti procjene kriterija

Prvo se množenjem matrice usporedbe sa težinskim vektorom dobiva vektor konzistencije, prema jednadžbi:

$$\begin{bmatrix} C_{11} & C_{12} & C_{13} & C_{14} \\ C_{21} & C_{22} & C_{23} & C_{24} \\ C_{31} & C_{32} & C_{33} & C_{34} \\ C_{41} & C_{42} & C_{43} & C_{44} \end{bmatrix} \cdot \begin{bmatrix} W_{11} \\ W_{12} \\ W_{13} \\ W_{14} \end{bmatrix} = \begin{bmatrix} C_{v_{11}} \\ C_{v_{21}} \\ C_{v_{31}} \\ C_{v_{41}} \end{bmatrix} \tag{3.25}$$

odnosno,

$$\begin{bmatrix} 1 & 1/2 & 5 & 1 \\ 2 & 1 & 7 & 5 \\ 1/5 & 1/7 & 1 & 1/4 \\ 1 & 1/5 & 4 & 1 \end{bmatrix} \cdot \begin{bmatrix} 0,235 \\ 0,530 \\ 0,053 \\ 0,180 \end{bmatrix} = \begin{bmatrix} 0,945 \\ 2,271 \\ 0,221 \\ 0,733 \end{bmatrix}$$

Nakon toga se vrši dijeljenje vrijednosti vektora konzistencije sa odgovarajućim vrijednostima težinskog vektora:

$$\begin{bmatrix} \frac{C_{v_{11}}}{W_{11}} \\ \frac{C_{v_{21}}}{W_{12}} \\ \frac{C_{v_{31}}}{W_{13}} \\ \frac{C_{v_{41}}}{W_{14}} \end{bmatrix} = \begin{bmatrix} \frac{0,945}{0,235} \\ \frac{2,271}{0,530} \\ \frac{0,221}{0,053} \\ \frac{0,733}{0,180} \end{bmatrix} = \begin{bmatrix} 4,021 \\ 4,285 \\ 4,170 \\ 4,072 \end{bmatrix}$$

Prosječna vrijednost dobivenih vrijednosti je:

$$\lambda_{max} = \frac{4{,}021 + 4{,}285 + 4{,}170 + 4{,}072}{4} = 4{,}137$$

Vrijednost indeksa konzistencije dobiva se prema jednadžbi 3.17:

$$CI = \frac{\lambda_{max} - n}{n - 1} = \frac{4{,}137 - 4}{4 - 1} = 0{,}046$$

Iz tablice 4.2, za n = 4 se dobiva RI = 0,90. Stupanj konzistentnosti prema jednadžbi 3.18 je:

$$CR = \frac{CI}{RI} = \frac{0{,}046}{0{,}9} = 0{,}051$$

Obzirom da je CR = 0,051 < 0,1 procjene kriterija su konzistentne (dosljedne, dobre).

2) Proračun prioriteta alternativa u odnosu na zadane kriterije

Nakon utvrđivanja konzistentnosti kriterija vrši se proračun prioriteta alternativa u odnosu na zadane kriterije. Postupak se provodi na isti način kao u prethodnom slučaju i to za svaki kriterij posebno. U konačnici se dobivaju prioriteti alternativa u odnosu na kriterije:

$$\begin{bmatrix} p_{a_1,k_1} \\ \vdots \\ p_{a_n,k_1} \end{bmatrix}, \begin{bmatrix} p_{a_1,k_2} \\ \vdots \\ p_{a_n,k_2} \end{bmatrix}, \ldots, \begin{bmatrix} p_{a_1,k_i} \\ \vdots \\ p_{a_n,k_i} \end{bmatrix}$$

gdje je *n* broj alternativa, a *i* broj kriterija.

Množenjem ovih vrijednosti sa vrijednostima prioriteta iz prethodnog postupka dobiva se konačno rješenje kao:

$$\begin{bmatrix} R_{a_1} \\ \vdots \\ R_{a_n} \end{bmatrix} = p_{k_1} \cdot \begin{bmatrix} p_{a_1,k_1} \\ \vdots \\ p_{a_n,k_1} \end{bmatrix} + p_{k_2} \cdot \begin{bmatrix} p_{a_1,k_2} \\ \vdots \\ p_{a_n,k_2} \end{bmatrix} + \ldots + p_{k_i} \cdot \begin{bmatrix} p_{a_1,k_i} \\ \vdots \\ p_{a_n,k_i} \end{bmatrix}$$

Najbolja alternativa je ona kojom se dobiva maksimalno rješenje, odnosno

$$R_{opt} = \max (R_{a_1} , \ldots , R_{a_n})$$

Analitički hijerarhijski postupak najčešće se upotrebljava u:

- cost/benefit analizama,
- strateškom planiranju,
- odabiru tehnologija,

- odabiru investicijskih prioriteta,
- drugim procjenama alternativa.

U planiranju niskonaponskih distribucijskih mreža ova metoda se može primijeniti za odabir najbolje prostorne konfiguracije mreže (alternative), uz uvažavanje određenih kriterija kao što su padovi napona u mreži, gubici snage u vodovima, investicijski troškovi i sl.

3.2.3. Metoda neizrazitog grupiranja

a) Općenito o neizrazitoj logici

U klasičnoj teoriji skupova, skup predstavlja kolekciju objekata koji dijele neko zajedničko svojstvo. Pripadnost objekta klasičnom skupu je egzaktno određena time da je objekt unutar skupa ili izvan njega. Ovakvi skupovi se često nazivaju i izraziti skupovi.

Ako se pripadnost objekta skupu želi izraziti funkcijski, tada pripadnost objekta *x* skupu *A* ima samo dvije vrijednosti i definirana je kao [50], [51]:

$$\mu_A(x) = \begin{cases} 1, \text{ za } x \in A \\ 0, \text{ za } x \notin A \end{cases} \tag{3.26}$$

Za razliku od tradicionalnog pristupa, teorija neizrazitih skupova dopušta djelomičnu ili stupnjevanu pripadnost elementa skupu, a funkcijske vrijednosti funkcije pripadnosti se nalaze u intervalu [0, 1]. Pri tome vrijednost 0 označava da je objekt potpuno izvan skupa, 1 da je potpuno unutar skupa, a bilo koja vrijednost između označava djelomičnu pripadnost.

Dakle, teorija neizrazitih skupova bavi se neodređenošću i višeznačnošću lingvističkih izraza, koji se mogu preslikati u neizrazite skupove koji mogu biti interpretirani računalnim jezicima. Neizraziti skup bi se na primjer mogao definirati kao:

$$\mu_A(x) = \begin{cases} 1 \text{ , za } x \in A \\ \dfrac{x - 3}{5} \text{ , za } 3 \le x \le 8 \\ 0 \text{ , za } x \notin A \end{cases} \tag{3.27}$$

Neizraziti skup je određen funkcijom pripadnosti. Način zadavanja funkcije pripadnosti najviše ovisi o karakteru objekta ili podataka koji se grupiraju (brojivi ili nebrojivi, diskretni ili kontinuirani), odnosno tipu domene (područje definicije) nad kojom se zadaju.

Ako su domene kontinuirane i brojive (npr. podskup ili cijeli skup realnih brojeva R), tada je najčešći oblik zadavanja funkcije pripadnosti preko funkcijskog izraza, kao na primjer:

$$\mu_A(x) = 1 / (1 + (x - a)^2) \tag{3.28}$$

koji predstavlja neizraziti skup A, sa maksimumom funkcije pripadnosti u točki x = a.

Funkcija pripadnosti definira stupanj pripadnosti elementa nekom skupu. Funkcije pripadnosti neizrazitih skupova uvijek su normalizirane, što znači da je maksimalna vrijednost funkcije pripadnosti jednaka 1. Odabir oblika funkcije pripadnosti pojedinih neizrazitih skupova je subjektivan i ovisi o razmatranom problemu. Na slici 3.4 su prikazani neki od oblika funkcije pripadnosti [51], [52].

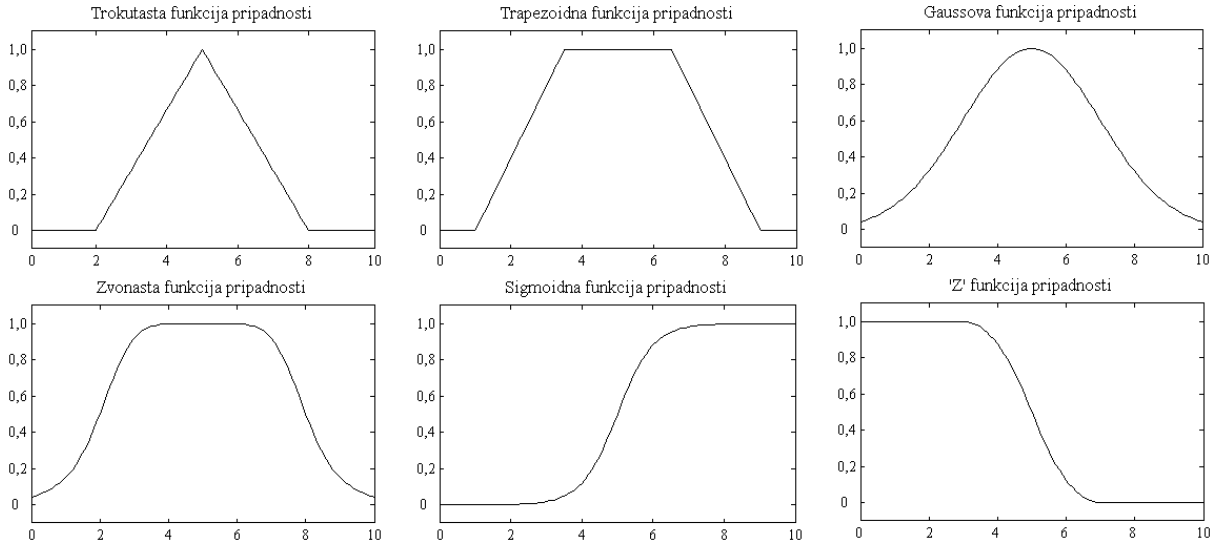

Slika 3.4. *Različiti oblici funkcije pripadnosti*

U klasičnoj teoriji temeljne teorijske operacije nad klasičnim skupovima su definirane kao unija, presjek i komplement. Te su operacije ujedno i podloga operacijama disjunkcije, konjunkcije i negacije u binarnoj logici.

Na sličan način je teorija neizrazitih skupova temelj neizrazite logike. Veza je uspostavljena preko definicije temeljnih operacija nad skupovima i njihovih logičkih ekvivalenata. Proširenje skupa funkcijskih vrijednosti sa samo dvije (0 i 1) u klasičnoj, na cijeli interval [0, 1] u neizrazitoj teoriji omogućilo je i znatno veći broj definicija temeljnih operacija nad neizrazitim skupovima. Općenita definicija operacija unije i presjeka nad neizrazitim skupovima izvedena je preko trokutnih normi i konormi [51].

Trokutna norma (t – norma) je binarna operacija na intervalu [0, 1], $T : [0, 1]^2 \rightarrow [0, 1]$ koja ima slijedeća svojstva:

$$T(x, y) = T(y, x) \quad \text{komutativnost} \quad (3.29)$$

$$T(T(x, y), z) = T(x,T(y, z)) \quad \text{asocijativnost} \quad (3.30)$$

$$T(x, y) \leq T(z, w) \text{ ako je } x \leq z \text{ i } y \leq w \quad \text{monotonost} \quad (3.31)$$

te zadovoljava rubni uvjet

$$T(x, 1) = x \quad (3.32)$$

Odgovarajuća trokutna konorma $S : [0, 1]^2 \rightarrow [0, 1]$ zadana je kao:

$$S(x, y) = 1 - T(1 - x, 1 - y) \tag{3.33}$$

Ako su zadane t – norma, t – konorma i neizraziti skupovi A i B na domeni X, onda su funkcije pripadnosti presjeka, unije i komplementa zadane kao [53]:

$$\mu_{A\cap B}(x) = T(\mu_A(x), \mu_B(x)) \quad \text{presjek} \tag{3.34}$$

$$\mu_{A\cup B}(x) = S(\mu_A(x), \mu_B(x)) \quad \text{unija} \tag{3.35}$$

$$\mu_{A^c}(x) = 1 - \mu_A(x) \quad \text{komplement} \tag{3.36}$$

Neizraziti sustav je bilo koji statički ili dinamički sustav koji koristi neizrazitu logiku i pripadajući matematički okoliš (teoriju neizrazitih skupova, neizrazita pravila i neizrazito zaključivanje). Ova relativno široka definicija obuhvaća neizrazite sustave koji se primjenjuju u različitim područjima i za koje se mogu koristiti i drugi nazivi kao na primjer: neizraziti ekspertni sustav (*eng. fuzzy expert system*), neizraziti regulator (*eng. fuzzy logic controller*), neizraziti model (*eng. fuzzy model*), sustav neizrazitih pravila (*eng. fuzzy rule based system*) itd. Struktura neizrazitog sustava (*eng. fuzzy system*) je prikazana na slici 3.5 [54], [55].

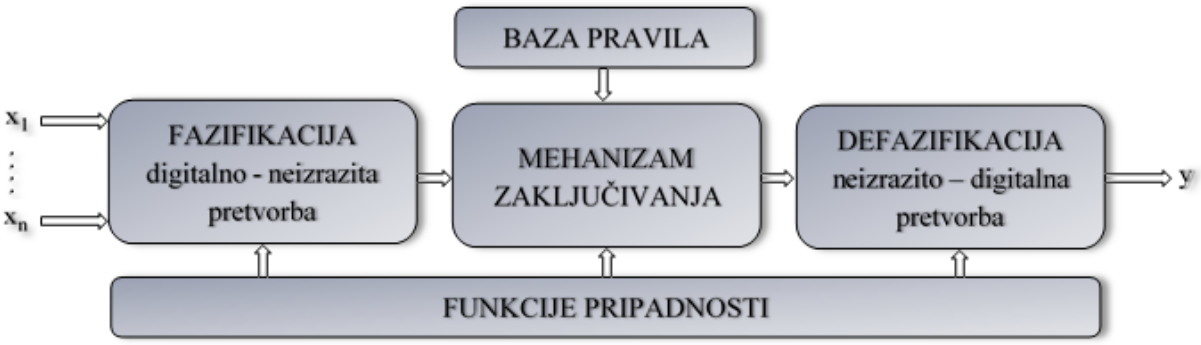

Slika 3.5. *Neizraziti sustav*

Bez obzira na naziv ili područje primjene, neizraziti sustavi sadrže tri temeljne komponente: bazu pravila, bazu podataka o funkcijama pripadnosti koje su zadane nad domenama ulaznih i izlaznih varijabli, te mehanizam zaključivanja. Neizraziti sustavi općenito su predviđeni za obradu neizrazitih ulaznih podataka izraženih preko neizrazitog skupa. Izraziti ulazni podaci mogu se promatrati kao poseban oblik neizrazitog skupa (*eng. singleton*) ili se za transformiranje ulaznih podataka koristi poseban blok digitalno–neizrazite pretvorbe (*eng. fuzzification*). Ovisno o primjeni kao i odabranom tipu neizrazitog modela izlaz iz neizrazitog sustava može biti izrazita veličina ili neizraziti skup. Za dobivanje izrazite izlazne veličine u neke sustave je potrebno ugraditi i blok neizrazito–digitalne pretvorbe (*eng. defuzzification*). Obzirom na mehanizam zaključivanja neizraziti sustavi načelno se mogu podijeliti u dvije kategorije: globalni i lokalni pristup. U praktičnim primjenama dominira postupak lokalnog zaključivanja. Razlog je u memorijskim i procesorskim ograničenjima računala. Kod ovog načina zaključivanja izračunavaju se samo ona pravila koja su u promatranom trenutku

relevantna, obzirom na vrijednost ulaznih varijabli. Memorijski zahtjevi su niži jer se u memoriju računala spremaju samo parametri funkcija pripadnosti ulaznih i izlaznih varijabli. Najčešće korišteni modeli lokalnog zaključivanja su *Mamdani* i *Sugeno* neizraziti modeli.

b) Mamdani model

Algoritam zaključivanja prema ovom modelu može se ilustrirati na jednom primjeru. Neka je zadan neizraziti sustav sa jednom ulaznom i jednom izlaznom varijablom, te tri pravila oblika *AKO x je A_i ONDA y je B_i , i = 1, 2, 3, ...* gdje *x* i *y* predstavljaju ulazne i izlazne varijable (općenito neizrazite) iz skupova *X* i *Y*, nad kojima su zadane particije A_i i B_i.

Neka je ulazna varijabla *x* definirana neizrazitim skupom A'. Jezična interpretacija skupa A' bi mogla biti *„x je približno 6“*. U algoritmu zaključivanja razlikuju se slijedeći koraci [56]:

- Određivanje stupnja prekrivanja (ili stupnja istinitosti premise) β_i između ulaznog skupa i skupova u premisama neizrazitih pravila,

$$\beta_i = \max_x \left[\mu_{A'}(x) \wedge \mu_{A_i}(x)\right] \ , \ i = 1, 2, 3 \tag{3.37}$$

- Određivanje lokalnog izlaznog skupa,

$$\mu_{B_i'}(y) = \beta_i \wedge \mu_{B_i}(y) \tag{3.38}$$

- Akumuliranje lokalnih skupova u jedinstveni neizraziti skup izlazne varijable,

$$\mu_{B_i'}(y) = \max_{1 \le i \le 3} \mu_{B_i'}(y) \tag{3.39}$$

Grafička interpretacija ovog primjera je prikazana na slici 3.6.

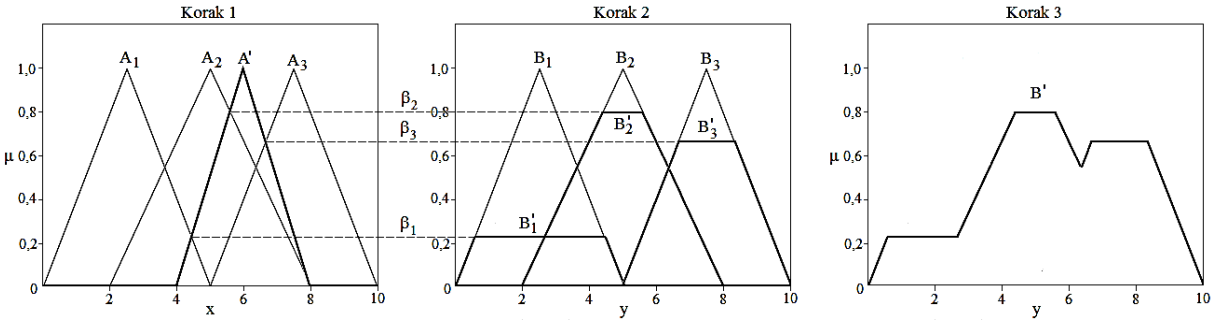

Slika 3.6. *Grafički prikaz Mamdani algoritma neizrazitog zaključivanja*

U ovom primjeru vrijede pravila:

1. ako x je A_1 onda y je B_1
2. ako x je A_2 onda y je B_2
3. ako x je A_3 onda y je B_3

odnosno zaključivanje ako *x* je A' onda *y* je B'.

U većini primjena neizrazite logike potrebno je osigurati da izlazni skup ima izrazitu vrijednost (analognu ili digitalnu). Za određivanje izrazite vrijednosti koriste se različite metode neizrazito–izrazite pretvorbe (*eng. defuzzification*), a najpoznatije su [57] , [58]:

- Metoda težišta (*eng. Center of gravity*) geometrijskog lika (tijela) definiranog rezultantnim neizrazitim skupom. Može se koristiti i za skupove zadane u više dimenzija. Ova metoda se najčešće koristi u praktičnim primjenama;
- Metoda središta ukupne površine (*eng. Center of area*) u kojem su površine neizrazitog skupa lijevo i desno od izlazne veličine identične;
- Metoda središnje točke maksimuma (*eng. Mean of maximum*), odnosno srednja vrijednost apscisa točaka u kojima funkcija pripadnosti izlaznog neizrazitog skupa ima maksimum.

c) Sugeno model

U usporedbi sa Mamdani modelom Sugeno model (često se naziva i Takagi–Sugeno model) se razlikuje u načinu definiranja zaključka. Umjesto neizrazite propozicije koristi se izrazita funkcija čiji su argumenti ulazne izrazite varijable. Pravilo Sugeno modela se zadaje u obliku *AKO x je* A_i *I y je* B_i *ONDA je* $z_i = f_i(x, y)$, gdje su A_i i B_i particije neizrazitih skupova zadane nad domenama ulaznih varijabli *X* i *Y*, a $f_i(x, y)$ izrazite funkcije zaključka. Funkcije f_i zadaju se polinomski, najčešće polinomom nultog ili prvog stupnja, a stupanj polinoma određuje naziv modela (Sugeno modeli nultog i prvog reda) [58].

Izlaz iz Sugeno modela uvijek je izrazit i određuje se interpolacijom zaključka prema izrazu:

$$z = \frac{\sum_i \beta_i \cdot z_i}{\sum_i \beta_i} \tag{3.40}$$

gdje je β_i stupanj istinitosti premise pojedinog pravila, a *i* broj važećih pravila ili ukupan broj pravila neizrazitog sustava.

Najlakši način za vizualizaciju Sugeno modela prvog reda je razmišljati o svakom pravilu kao načinu za definiranje lokacije pokretnog „singltona“, koji se može kretati uokolo, linearno u izlaznom prostoru, ovisno o tome što je ulaz. Ovo ima tendenciju da zapis sustava učini vrlo kompaktnim i učinkovitim.

Sugeno model je idealan za djelovanje kao interpolacijski nadzor multi-linearnih regulatora, odnosno za različite radne uvjete dinamičkog nelinearnog sustava. Dakle, prigodan je za modeliranje nelinearnih sustava interpolacijom između više linearnih modela.

Jedan takav primjer (tzv. primjer dvije crte) je prikazan na slici 3.7.

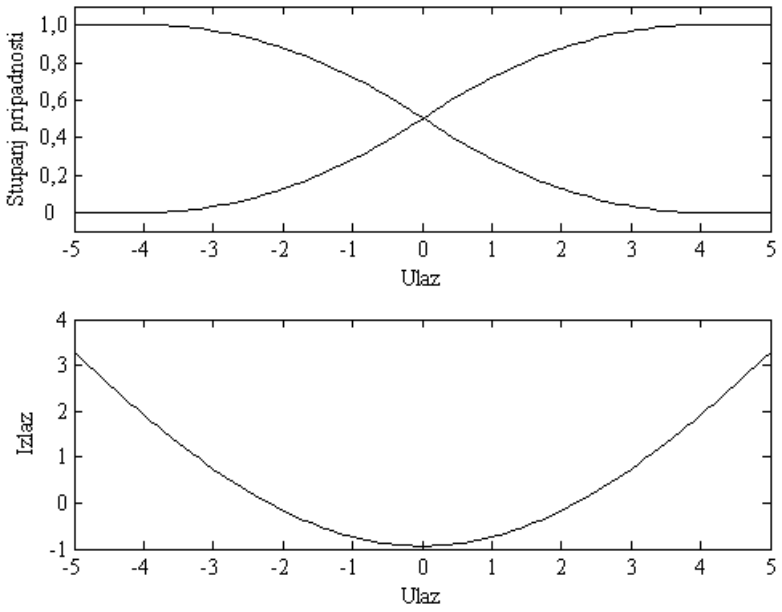

Slika 3.7. *Primjer Sugeno modela dvije crte*

U ovom primjeru izlazna varijabla ima dvije funkcije pripadnosti, koje su linearne funkcije ulazne varijable. Ulazna funkcija pripadnosti i pravila definiraju koja će od izlaznih funkcija biti prikazana i kada.

Sugeno sustav daje slobodu inkorporiranja linearnih sustava u neizrazite sustave. Dakle, može se izgraditi neizraziti sustav koji se prebacuje između nekoliko optimalnih linearnih regulatora pošto se nelinearni sustav kreće oko svog radnog prostora. Prednosti Sugeno u odnosu na Mamdani model su [59]:

- Računski je učinkovitiji;
- Radi dobro sa linearnim tehnikama;
- Radi dobro sa optimizacijskim i adaptivnim tehnikama;
- Ima zajamčen kontinuitet izlazne površine;
- Dobro je prilagođen matematičkim analizama.

Prednosti Mamdani u odnosu na Sugeno model su:

- Intuitivan je;
- Ima široku prihvaćenost;
- Dobro je prilagođen ljudskim ulazima.

Temeljni principi neizrazite logike poslužili su za razvoj niza naprednih tehnika koje su svoju primjenu našle u rješavanju širokog spektra praktičnih problema. Jedna od takvih tehnika je i algoritam neizrazitog grupiranja (*eng. fuzzy clustering algorithm*). Ovaj algoritam je vrlo prigodan za primjenu u distribucijskim elektroenergetskim sustavima, prije svega za prostorno grupiranje potrošača, kako će to biti pokazano u predloženom modelu planiranja niskonaponskih distribucijskih mreža.

d) Algoritam neizrazitog grupiranja

Klaster analiza je naziv za skupinu multivarijacijskih tehnika čija je primarna svrha grupiranje objekata temeljena na karakteristikama koje posjeduju. Izraz klaster dolazi od engleske riječi *cluster*, što u prijevodu znači *skupina istovrsnih stvari, grozd, skupiti u hrpu*. Klaster analiza klasificira objekte (ispitanike, proizvode ili druge objekte) tako da je svaki objekt veoma sličan drugim u klasteru, uz poštivanje nekog unaprijed određenog kriterija selekcije. Nastale skupine objekata bi trebale pokazati visoku internu homogeniziranost (sličnost) unutar skupine i visoku eksternu (između skupina) različitost.

Ovisno o cilju, mogu se formulirati različite definicije grupiranja. Općenito, može se prihvatiti da je klaster skupina objekata koji su sličniji nego objekti neke druge skupine. Pojam sličnosti se mora shvatiti kao matematička sličnost mjerena određenom mjerom.

Podaci se obično promatraju kao neki fizički proces. Svako promatranje se sastoji od n mjerenih varijabli, grupiranih u n – *dimenzionalni vektor* stupca $z_k = [\, z_{1k},...,z_{nk} \,]^T$, $z_k \in R^n$. Set od N promatranja je označen sa $Z = \{ z_k \mid k=1,2,...,N \}$ i može se predočiti kao matrica $n \times N$ [60]:

$$Z = \begin{bmatrix} z_{11} & z_{12} & \cdots & z_{1N} \\ z_{21} & z_{22} & \cdots & z_{2N} \\ \vdots & \vdots & \vdots & \vdots \\ z_{n1} & z_{n2} & \cdots & z_{nN} \end{bmatrix} \tag{3.41}$$

Ovisno o prirodi i svrsi podataka koriste se različite mjere za ocjenu sličnosti koje smještaju podatke u skupine. Neki od primjera mjera koje se mogu upotrijebiti pri formiranju skupina su razdaljina, uvezanost ili intenzitet. Na slici 3.8 su prikazane skupine različitih oblika i dimenzija.

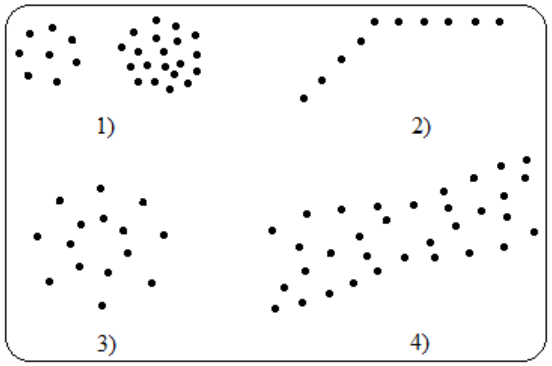

Slika 3.8. *Skupine različitog oblika i dimenzija*

Neizrazito grupiranje (*eng. fuzzy clustering*) je proces dodjeljivanja pripadnih razina, a nakon toga dodjeljivanja elemenata u jednu ili više skupina. U literaturi se može pronaći dosta algoritama neizrazitog grupiranja. Osnovna podjela je na: *hard clustering* i *soft clustering* [61].

Hard clustering je metoda grupiranja određenih podataka u skupine i to tako da elementi mogu pripadati isključivo jednoj skupini. Pripadnost elementa u više skupina nije dozvoljena.

Soft clustering je metoda grupiranja određenih podataka gdje elementi mogu pripadati u više od jedne skupine, a pridružen svakom elementu je set pripadnih razina. To pokazuje jačinu veze između određenog elementa i skupine.

Jedna druga klasifikacija je temeljena na različitim tehnikama [62], [63], [64]:

- Aglomerativne hijerarhijske metode (*eng. Agglomerative hierarchical methods*) i metode hijerarhijske podjele (*eng. Splitting hierarchical methods*) formiraju novu skupinu preraspodjelom članova skupine u određenom vremenskom trenutku temeljem prigodne mjere sličnosti;
- Grafičko–teorijske metode (*eng. Graph–theoretic methods*) gdje se *Z* smatra kao skupina čvorova. Rubne težine među parovima čvorova se temelje na mjeri sličnosti između tih čvorova;
- Kriterijska funkcija (*eng. Objective function methods*) se koristi kao mjera poželjnosti podataka za grupiranje. Za traženje lokalnog optimuma funkcije cilja koriste se nelinearni optimizacijski algoritmi.

Cilj analize neizrazitog grupiranja je identificiranje skupina objekata koji su vrlo slični. Postoje različiti pristupi od kojih su u najširoj primjeni: hijerarhijske metode, metode razdiobe (*eng. partitioning methods*) i grupiranje u dva koraka (*eng. two–step clustering*). Koraci analize neizrazitog grupiranja mogu se prikazati dijagramom danim na slici 3.9 [65].

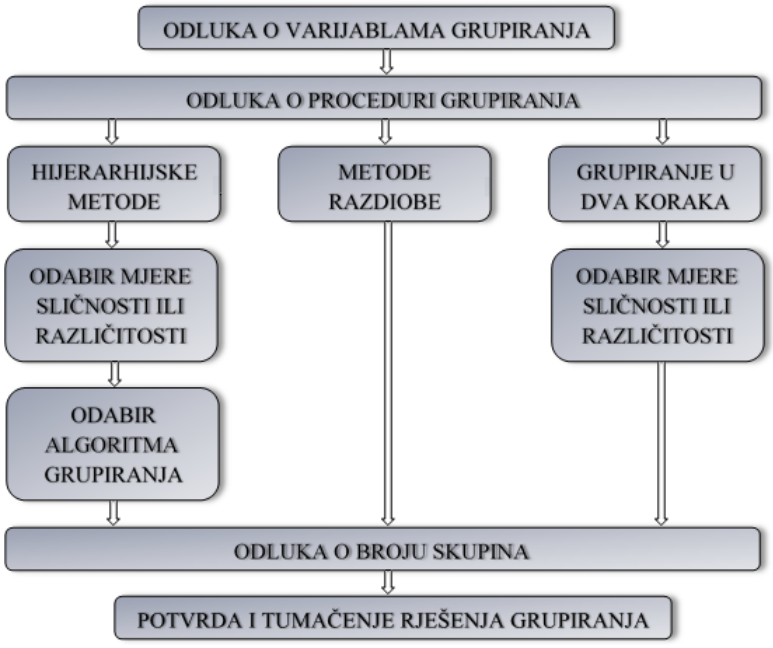

Slika 3.9. *Koraci analize neizrazitog grupiranja*

Odluka o varijablama temeljem kojih treba uraditi grupiranje objekata uvijek ovisi o dostupnosti podataka. Odabir varijabli ovisi o kriteriju temeljem kojeg treba izvršiti grupiranje. Pri planiranju distribucijskih mreža, najpogodniji podatak temeljem kojeg se može napraviti grupiranje potrošača su koordinate mjernih mjesta.

Odabirom odgovarajuće procedure grupiranja određuje se izgled skupina. Ovo uvijek uključuje optimiziranje nekog kriterija. Procedura, također, može odgovoriti na pitanje kako odrediti sličnost ili različitost među objektima u novooformljenoj skupini.

Najčešće upotrebljavane su hijerarhijske metode grupiranja. Hijerarhijske metode karakterizira struktura u obliku drveta. Većina hijerarhijskih metoda pripada kategoriji aglomerativnog grupiranja. U ovom tipu grupiranja se skupine formiraju od objekata. Nakon toga se skupine mjere prema njihovoj sličnosti, određenom mjerom. Prvo se dvije slične skupine (npr. one sa najmanjom međusobnom razdaljinom) mjere i formira se nova skupina na dnu hijerarhijske ljestvice. U slijedećem koraku se mjeri drugi par skupina i povezuje sa većom hijerarhijskom razinom itd. Ovo omogućuje uspostavljanje hijerarhije skupina od dna prema vrhu.

Procedura grupiranja može se primijeniti i od vrha prema dnu. Takav oblik grupiranja naziva se grupiranje dijeljenjem. Kod ovakvog grupiranja se svi objekti postupno dijele od vrha prema dnu. Na slici 3.10 je prikazan primjer aglomerativnog grupiranja i grupiranja dijeljenjem [65].

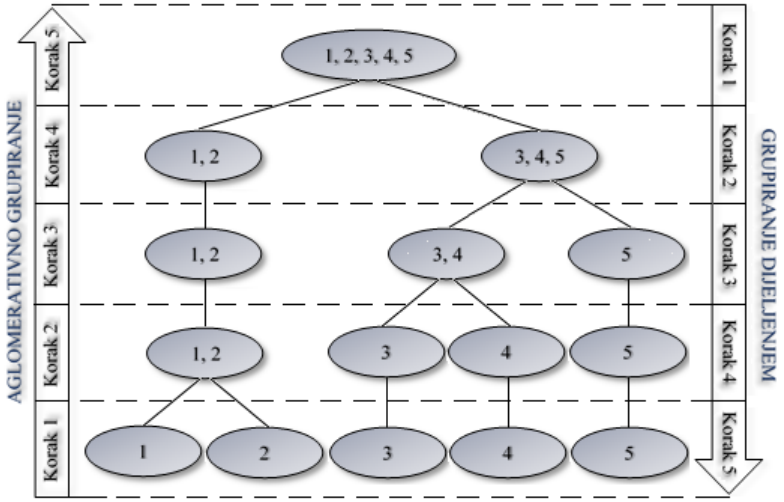

Slika 3.10. *Aglomerativno grupiranje i grupiranje dijeljenjem*

Postoje različite mjere kojima se izražava sličnost, odnosno različitost parova elemenata [65], [66]. Najčešće upotrebljavana je mjera udaljenosti između elemenata. Direktan način za određivanje bliskosti dva elementa je povlačenje prave crte između njih. Ovaj tip udaljenosti naziva se i *Euclidean udaljenost* (*eng. straight–line distance*) i najčešće se upotrebljava. Ukoliko se želi upotrijebiti procedura hijerarhijskog grupiranja ova udaljenost se mora prikazati matematički. Euclidean udaljenost između elemenata 1 i 2 računa se kao:

$$d_{\text{Euclidean}}(1,2) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \tag{3.42}$$

Ova udaljenost odgovara dužini crte koja povezuje elemente 1 i 2. Na isti način mogu se izračunati udaljenosti između svih parova elemenata. Sve ove udaljenosti obično su predstavljene u obliku matrice udaljenosti. U ovoj matrici nedijagonalni elementi predstavljaju udaljenosti između parova, a dijagonalni elementi su 0 (udaljenost elementa od samog sebe).

Pošto je udaljenost između elemenata 1 i 2 identična kao i udaljenost između elemenata 2 i 1 matrica udaljenosti je simetrična. Ova matrica je prikazana u tablici 3.3.

Tablica 3.3. *Euclidean matrica udaljenosti*

Element	1	2	3	4	5	6	7
1	0	$d_{1,2}$	$d_{1,3}$	$d_{1,4}$	$d_{1,5}$	$d_{1,6}$	$d_{1,7}$
2	$d_{2,1}$	0	$d_{2,3}$	$d_{2,4}$	$d_{2,5}$	$d_{2,6}$	$d_{2,7}$
3	$d_{3,1}$	$d_{3,2}$	0	$d_{3,4}$	$d_{3,5}$	$d_{3,6}$	$d_{3,7}$
4	$d_{4,1}$	$d_{4,2}$	$d_{4,3}$	0	$d_{4,5}$	$d_{4,6}$	$d_{4,7}$
5	$d_{5,1}$	$d_{5,2}$	$d_{5,3}$	$d_{5,4}$	0	$d_{5,6}$	$d_{5,7}$
6	$d_{6,1}$	$d_{6,2}$	$d_{6,3}$	$d_{6,4}$	$d_{6,5}$	0	$d_{6,7}$
7	$d_{7,1}$	$d_{7,2}$	$d_{7,3}$	$d_{7,4}$	$d_{7,5}$	$d_{7,6}$	0

Postoje i alternativne mjere udaljenosti. Jedna je tzv. *City–block udaljenost*, a koja upotrebljava sumu apsolutnih razlika. Često se naziva i *Manhattan metric* jer je srodna sa pješačkom udaljenosti između dvije točke grada kao što je New York, distrikt Manhattan, gdje je udaljenost jednaka broju blokova u pravcu Sjever–Jug i Istok–Zapad. Korištenje *City–block distance* za računanje udaljenosti između elemenata 1 i 2 daje:

$$d_{\text{City-block}}(1,2) = | x_1 - x_2 | + | y_1 - y_2 | \tag{3.43}$$

U radu sa metričkim podacima istraživači često koriste tzv. *Chebychev udaljenost*, koja predstavlja maksimum apsolutnih razlika:

$$d_{\text{Chebychev}}(1,2) = \max \left(| x_1 - x_2 | , | y_1 - y_2 | \right) \tag{3.44}$$

Slika 3.11 prikazuje korelaciju između ova tri tipa mjera udaljenosti [65].

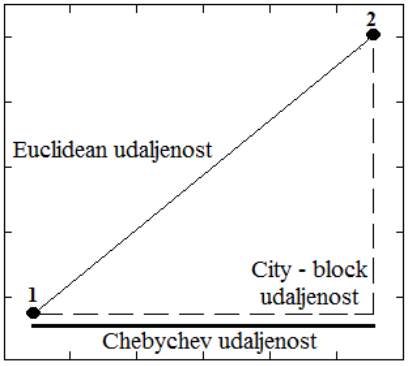

Slika 3.11. *Korelacija između mjera udaljenosti*

Nakon odabira mjera sličnosti, odnosno različitosti, potrebno je odabrati algoritam grupiranja. Postoji nekoliko aglomerativnih procedura koje se razlikuju prema načinu definiranja udaljenosti; od novooformljene skupine do određenog objekta, odnosno do drugih skupina. Najviše korištene aglomerativne procedure grupiranja uključuju slijedeće:

- Jedna veza (najbliži susjed) – udaljenost između dvije skupine odgovara najmanjoj udaljenosti između bilo koja dva elementa u dvije skupine;
- Potpuna veza (najdalji susjed) – suprotan pristup pristupu jedne veze koji pretpostavlja da se udaljenost između dvije skupine temelji na najdaljoj udaljenosti između bilo koja dva elementa u dvije skupine;
- Prosječna veza – udaljenost između dvije skupine definirana je kao prosječna udaljenost između svih parova elemenata dvije skupine;
- Centroid – prvo se računa geometrijski centar (centroid) svake skupine. Udaljenost između dvije skupine jednaka je udaljenosti između dva centroida.

Na slici 3.12 su prikazane procedure vezivanja elemenata dvije slučajne skupine.

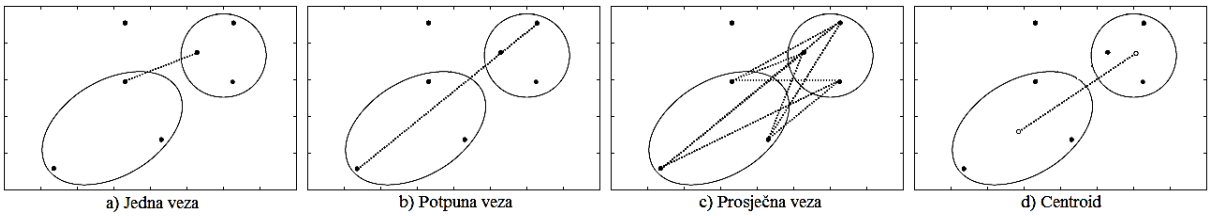

Slika 3.12. *Aglomerativne procedure vezivanja elemenata skupina*

Svaki od ovih algoritama daje različite rezultate ukoliko se upotrebljavaju na istom setu podataka, obzirom da svaki od njih ima svoje posebnosti. Pošto se algoritam jedne veze temelji na minimalnoj udaljenosti, on nastoji da formira jednu veliku skupinu, dok ostale skupine sadrže samo jedan ili nekoliko elemenata, i to svaka od njih. S druge strane, na algoritam potpune veze najveći utjecaj imaju rubni objekti obzirom da se on temelji na maksimalnim udaljenostima. Skupine proizvedene ovom metodom su kompaktnije i uže vezane. Algoritam prosječne veze i centroid algoritam nastoje proizvesti skupine slične veličine. Međutim, i ove procedure ovise o rubnim objektima, mada ne kao algoritam potpune veze.

Uobičajeni način za vizualizaciju napretka analize neizrazitog grupiranja je crtanje dendograma koji prikazuje razinu udaljenosti na kojoj se nalazi kombinacija elemenata i skupina (Slika 3.13).

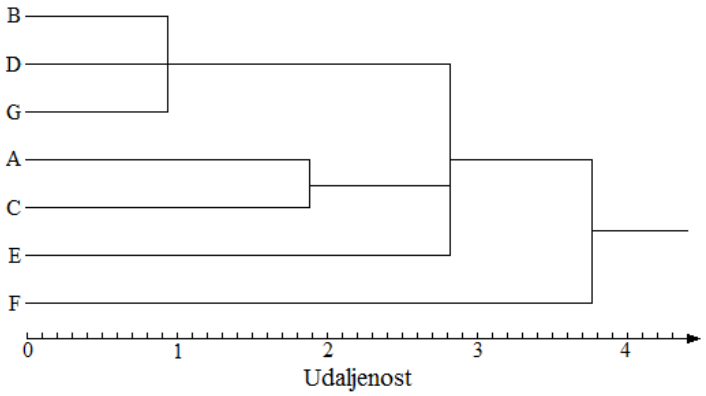

Slika 3.13. *Dendogram*

U većini slučajeva broj skupina je unaprijed poznat. U ostalim slučajevima podaci se mogu grupirati na više načina, pri čemu je broj skupina svaki put drugačiji. U tim slučajevima postoji potreba pronalaženja najvjerojatnijeg broja skupina za dane podatke. To je poznato pod nazivom *valjanost skupina*. Ukoliko su podaci označeni i broj skupina je unaprijed zadan, a za neoznačene podatke nema točnog broja skupina.

Za klasificiranje podataka koriste se razni algoritmi [67]. Jedan od njih je HCM (*eng. Hard c–Means*). Koristi se za klasificiranje podataka na način da se svaki podatak dodjeljuje samo jednoj skupini. Tada se skupine mogu nazvati i particije jer jednoznačno dijele podatke. Ako particije definiramo preko obitelji skupova A_i , i = 1, 2, …, c , može se napisati slijedeće:

$$\bigcup_{i=1}^{c} A_i = X \tag{3.45}$$

$$A_i \bigcap A_j = \emptyset \tag{3.46}$$

$$\emptyset \subset A_i \subset X \text{ za } \forall i \tag{3.47}$$

gdje je $X = \{x_1, x_2, \ldots, x_n\}$ konačni prostor uzoraka, a *c* je broj skupina.

Prostor c–particija za skup uzoraka X definira se kao:

$$M_c = \left\{ U \in V_{cxN} \left| \chi_{ik} \in [0, 1] \;\; \forall i, k \; ; \sum_{i=1}^{c} \chi_{ik} = 1 \;\; \forall k \; ; \; 0 < \sum_{i=1}^{N} \chi_{ik} < N \;\; \forall i \right. \right\} \tag{3.48}$$

U je matrica sa *c* redaka koji predstavljaju skupine i *n* stupaca koji predstavljaju uzorke. Broj mogućih c–particija unutar prostora M_c je slijedeći:

$$\eta_{M_c} = \left(\frac{1}{c!} \right) \left[\sum_{i=1}^{c} \binom{c}{i} (-1)^{c-i} \, i^n \right] \tag{3.49}$$

Kriterijska funkcija koja služi za grupiranje podataka određuje koja c-particija je najbolja od svih mogućih. Preporučena je slijedeća kriterijska funkcija:

$$J_w(U, V) = \sum_{k=1}^{N} \sum_{i=1}^{c} \chi_{ik} \, (d_{ik})^2 \tag{3.50}$$

$$d_{ik} = d(x_k - v_i) = \| x_k - v_i \| = \sqrt{\sum_{j=1}^{n} (x_{kj} - v_{ij})^2} \tag{3.51}$$

$$V = (v_1, v_2, \dots, v_c) \in R^{nxc} \quad \forall i \tag{3.52}$$

$$U = [\chi_{ik}] \in M_c \tag{3.53}$$

Vektor *V* je vektor prototipova centara skupina, a v_i su centri pojedinih skupina. Particija koja najbolje dijeli prostor uzoraka je ona koja daje minimum kriterijske funkcije:

$$\min_{M_c \times R^{nxc}} \{ J_w(U, v) \} \tag{3.54}$$

HCM algoritam koji aproksimira minimum kriterijske funkcije može se prikazati u nekoliko koraka:

Korak 1: Izaberi c, $2 \le c \le N$
Inicijaliziraj $U^{(0)} \in M_c$
Ponavljaj za svaki l = 0, 1, 2, ...

Korak 2: Izračunaj vektore $\{v_i^{(l)}\}$ koristeći $U^{(l)}$ i formulu:

$$v_i = \frac{\sum_{k=1}^{N} \chi_{ik} x_k}{\sum_{k=1}^{N} \chi_{ik}}$$

Korak 3: Ponovo izračunaj $U^{(l)}$. Nove vrijednosti se računaju za ∀ i, k kako slijedi:

$$\begin{Bmatrix} 1, & d_{ik}^{(l)} = \min\limits_{1 \le j \le c} \{ d_{jk}^{(l)} \} \\ 0, & \text{inače} \end{Bmatrix}$$

Korak 4: Usporedi $U^{(l)}$ i $U^{(l+1)}$.
Ako je $\| U^{(l+1)} - U^{(l)} \| \le \varepsilon$ zaustavi iteraciju.
Ako nije, nastavi od koraka 2.

Jedan od najšire primjenjivanih algoritama je FCM (*Fuzzy c–Means*) algoritam (Bezdek 1981). I kod ovog algoritma je potrebno pronaći minimum kriterijske funkcije. Kriterijska funkcija ima slijedeći oblik:

$$J_m(U, V) = \sum_{k=1}^{N} \sum_{i=1}^{c} (\mu_{ik})^m (d_{ik})^2 \tag{3.55}$$

$$d_{ik} = \| x_k - v_i \| \tag{3.56}$$

$$V = (v_1, v_2, \dots, v_c) \in R^{nxc},\ v_i \in R^n \tag{3.57}$$

Vektor *V* je vektor prototipova centara skupina, a v_i su centri pojedinih skupina. $U \in M_{fc}$ je neizrazita particija prostora X, a M_{fc} je:

$$M_{fc} = \left\{ U \in V_{cxN} \;\middle|\; \mu_{ik} \in [0, 1]\ \forall i, k\ ;\ \sum_{i=1}^{c} \mu_{ik} = 1\ \forall k\ ;\ 0 < \sum_{i=1}^{N} \mu_{ik} < N\ \ \forall i \right\} \tag{3.58}$$

Parametar *m* se naziva *težinski parametar*. On određuje količinu neizrazitosti u klasifikacijskom procesu. I ovdje je potrebno pronaći minimum kriterijske funkcije:

$$\min_{M_{fc}\ x\ R^{nxc}} \{ J_m(U, v) \} \tag{3.59}$$

FCM algoritam može se prikazati u slijedećim koracima:

Korak 1: Izaberi c, $2 \le c \le N$
Izaberi $m \in [1, \infty)$
Inicijaliziraj $U^{(0)} \in M_{fc}$

Korak 2: Izračunaj centre neizrazitih grupa $\{v_i^{(l)}\}$ koristeći $U^{(l)}$ i formulu:

$$v_i = \frac{\sum_{k=1}^{N} (\mu_{ik})^{m'} x_k}{\sum_{k=1}^{N} \chi_{ik}}$$

Korak 3: Ponovo izračunaj $U^{(l)}$ koristeći $\{v_i^{(l)}\}$ i sljedeće izraze:

$$I_k = \emptyset \Longrightarrow \mu_{ik} = \frac{1}{\sum_{i=1}^{c} \left(\frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{m-1}}}$$

$$I_k \neq \emptyset \Longrightarrow \mu_{ik} = 0\ \ \forall i \in I_k\ i$$

$$\sum_{i \in I_k} \mu_{ik} = 1$$

gdje je $I_k = \{ i \mid 1 \le i \le c\ ;\ d_{ik} = \|x_k - v_i\| = 0 \}$

Korak 4: Usporedi $U^{(l)}$ i $U^{(l+1)}$.
Ako je $\|U^{(l+1)} - U^{(l)}\| \leq \varepsilon$ zaustavi iteraciju.
Ako nije, nastavi od koraka 2.

Dakle, FCM algoritam nastoji da podijeli skupinu od *n* elemenata $X = \{x_1, \ldots, x_n\}$ u podskupine uvažavajući određene zadane kriterije. Temeljem danih podataka algoritam daje listu centara skupina $C = \{c_1, \ldots, c_c\}$ i matricu podjele $V = v_{i,j} \in [0, 1], \; i = 1, \ldots, n, \; j = 1, \ldots, c$ gdje svaki element $v_{i,j}$ označava stupanj pripadnosti elementa x_i skupini c_j. Standardna funkcija je:

$$v_k(x) = \frac{1}{\sum_j \left(\frac{d(\text{center}_{k.x})}{d(\text{center}_{j,x})} \right)^{\frac{2}{m-1}}} \tag{3.60}$$

gdje *k* označava k–tu skupinu.

Prije nego što se prihvati rješenje, potrebno je procijeniti stabilnost i valjanost rješenja. Stabilnost se procjenjuje uporabom različitih procedura grupiranja na istim podacima, a onda se promatra da li daju iste rezultate. U hijerarhijskom grupiranju, na primjer, mogu se koristiti različite mjere udaljenosti.

Drugi, uobičajeni, pristup je podjela skupine podataka na dvije polovice i nakon toga odvojena analiza podskupina, uz korištenje istih parametara. Ukoliko se rezultati ne razlikuju značajno može se zaključiti da ukupno rješenje ima visoku razinu stabilnosti.

Također, može se izvršiti promjena redoslijeda elemenata u skupini podataka i izvršiti ponovna provjera stabilnosti. Rezultati ne bi trebali ovisiti o redoslijedu.

Za procjenu valjanosti rješenja potrebno je procijeniti valjanost kriterija. U istraživanjima, može se fokusirati na varijable kriterija koje imaju teorijski temeljenu povezanost sa varijablama skupina, ali nisu uključene u analizu.

Zadnji korak u svakoj analizi grupiranja je predstavljanje skupina. Ono uvijek uključuje istraživanje centara skupina, koje predstavljaju prosječne vrijednosti varijabli svih elemenata u određenoj skupini. Ovo je od velike važnosti obzirom da se analizom utvrđuje da li su segmenti konceptualno različiti. Samo određene skupine pokazuju da li su varijable različite, iz kuta podataka. Ovo se može najlakše utvrditi usporedbom skupina sa neovisnim testnim uzorcima.

Algoritmi neizrazitog grupiranja mogu se svrstati i u skupinu stohastičkih algoritama.

3.3. STOHASTIČKE METODE OPTIMIZACIJE

Stohastičke metode optimizacije su metode koje generiraju i upotrebljavaju slučajne varijable. Kod stohastičkih problema slučajne varijable se pojavljuju kod formuliranja optimizacijskog problema, što uključuje slučajne funkcije cilja ili slučajna ograničenja. Ove metode uključuju također i metode sa slučajnim iteracijama. Isto tako, stohastičke metode generaliziraju determinističke metode za determinističke probleme [68].

Stohastička optimizacija je proces maksimiziranja ili minimiziranja vrijednosti matematičke ili statističke funkcije [69]. Stohastički procesi uvijek uključuju vjerojatnost, za razliku od determinističkih procesa koji se temelje na predvidivim i egzaktnim ulaznim vrijednostima.

Stohastička optimizacija razmatra probleme iz stvarnog života obzirom da mnogi problemi u fizičkom svijetu uključuju neizvjesnost, nepreciznost i slučajnost. Stoga stohastička optimizacija igra značajnu ulogu u analizama, dizajniranju i radu modernih sustava.

Metode stohastičke optimizacije rješavaju probleme nelinearnih, predimenzioniranih i drugih neprikladnih problema koji nisu prigodni za rješavanje klasičnim determinističkim postupcima. Ovi algoritmi imaju široku primjenu u statistici, znanosti, inženjerstvu i poslu. Algoritmi koji imaju bilo kakvu stohastičku formu su široko rasprostranjeni.

U ovome poglavlju bit će obrađen stohastički algoritam koji će u predloženom modelu planiranja niskonaponskih distribucijskih mreža biti upotrijebljen za određivanje optimalne konfiguracije distribucijske mreže, u cilju minimiziranja gubitaka radne snage u mreži i padova napona kod krajnjih potrošača. To je algoritam simuliranog kaljenja (*eng. simulated annealing algorithm*).

3.3.1. Općenito o stohastičkim optimizacijskim metodama

U zadnjih nekoliko desetljeća značajno se povećala uloga optimizacije u mnogo različitih područja, kao što su elektrotehnika, operacijska istraživanja, računarstvo i komunikacije. Linearne i nelinearne optimizacije, optimum funkcije kontinuiranih varijabli, doživjeli su značajan napredak tijekom 50–tih i 60–tih godina dvadesetog stoljeća. Bolji rezultati kombinatorne optimizacije, optimumi funkcija diskretnih varijabli, postignuti su kasnije (70–tih godina). Međutim, problemi kombinatorne optimizacije većih razmjera predstavljaju i danas problem, i pored znatno bržih računala. Takvi se problemi rješavaju aproksimacijom, gdje je kvaliteta rješenja proporcionalna vremenu računanja [70].

Kombinatorni optimizacijski problem je problem minimiziranja ili maksimiziranja problema, koji uključuje pronalaženje optimalnog ili najboljeg rješenja iz seta pozitivnih rješenja. Može se u potpunosti okarakterizirati prostorom pretraživanja i funkcijom cilja.

Prostor pretraživanja S je konačan ili izračunljiv set mogućih rješenja, a funkcija cilja $f : S \rightarrow IR$ mapira svaku točku u prostoru pretraživanja u realni broj kako bi se dobila mjera koliko je

dobiveno rješenje dobro u usporedbi sa ostalim rješenjima. U slučaju minimiziranja željeno optimalno rješenje x_{opt} je jedno od kojih je [71]:

$$f\left(x_{opt}\right) \leq f\left(x\right) \text{ , za } \forall\, x \in S \tag{3.61}$$

Problem se može postaviti jednostavno kao:

$$\underset{x \in S}{\text{minimize}}\, f\left(x\right) \tag{3.62}$$

Rješenje x_{opt} naziva se *globalni optimum* i njegova ciljna vrijednost je $f_{opt} = f\left(x_{opt}\right)$. Pošto može postojati više od jednog rješenja koje zadovoljava uvjete, set globalnih optimalnih rješenja može se prikazati kao S_{opt}.

Pri rješavanju ovakvog problema postoje dva pristupa [70], [72]:

1) Traženje globalnog optimuma po svim konfiguracijama, što je nemoguće u prihvatljivom vremenu;
2) Aproksimacijski algoritam, koji pokušava dobiti zadovoljavajuće rješenje u prihvatljivom vremenu.

3.3.2. Algoritam simuliranog kaljenja

Algoritam simuliranog kaljenja pripada skupini aproksimacijskih algoritama. Algoritam se temelji na stohastičkoj tehnici, ali uključuje mnoge dijelove algoritma iterativnog poboljšanja.

Algoritam iterativnog poboljšanja pretpostavlja zadanu definiciju konfiguracije, funkcije cilja i mehanizam generiranja slijedeće konfiguracije, malom promjenom. Počevši od polazne konfiguracije, generira se niz iteracija, od kojih se svaka sastoji od mogućeg prijelaza u slijedeću. Ukoliko ta slijedeća konfiguracija daje smanjenje funkcije cilja onda se ona prihvaća, a inače se odbacuje i traži naredna. Algoritam završava kada sve slijedeće konfiguracije daju povećanje funkcije cilja [70].

Nedostaci iterativnog algoritma su slijedeći:

- Prema definiciji, algoritam završava u lokalnom minimumu tako da se ne zna koliko je on udaljen od globalnog minimuma;
- Dostignuti minimum ovisi o polaznoj konfiguraciji.

Prednosti iterativnog algoritma su njegova opća primjenjivost, te relativno kratko vrijeme računanja za jednu polaznu konfiguraciju.

Moguća poboljšanja ovog algoritma su slijedeća:

- Izvođenje algoritma za veliki broj polaznih konfiguracija;
- Uporaba informacija iz prethodnih pokušaja;
- Povećanje skupa susjednih konfiguracija;
- Prihvaćanje prijelaza koji uzrokuju povećanje funkcije cilja.

Algoritam koji slijedi zadnji pristup poboljšanja predstavili su neovisno *S. Kirkpatrik* i *V. Černy*. Poznat je pod nazivom simulirano kaljenje (*eng. simulated annealing*), ali se u literaturi nalazi još i pod nazivima *Monte Carlo kaljenje, stohastičko hlađenje, stohastička relaksacija* i *algoritam slučajne zamjene*. Rezultati dobiveni ovim algoritmom su vrlo blizu optimuma, te ne ovise o polaznoj konfiguraciji. Na taj način, metoda simuliranog kaljenja ne pokazuje nedostatke metode iterativnog poboljšanja, te daje bolje rezultate, ali je nešto sporija.

a) Matematička interpretacija algoritma simuliranog kaljenja

U svom originalnom obliku, algoritam simuliranog kaljenja temeljen je na analogiji između simulacije kaljenja metala i problema kombinatorne optimizacije. U fizici krutih tvari, kaljenje predstavlja proces u kojem se materijal zagrije do maksimalne temperature (temperatura kaljenja) pri kojoj je unutarnja struktura stohastički organizirana. Niz postupaka laganog hlađenja uzrokuje da unutrašnji raspored elementarnih jedinica poprima stanje sve manje energije, prilagođavajući se temperaturi (unutarnja energija proporcionalna je temperaturi). Pri svakoj temperaturi T materijal dostiže termičku ravnotežu, koja se može okarakterizirati vjerojatnošću posjedovanja energije E prema Boltzmannovoj (*Boltzmann*) raspodjeli [73], [74]:

$$P(E) = \frac{1}{Z(T)} \cdot e^{\left(-\frac{E}{k_B \cdot T}\right)} \tag{3.63}$$

gdje su: Z(T) – faktor normalizacije
k_B – Boltzmannova konstanta

Kako se temperatura smanjuje prema nuli, samo stanja minimalne energije imaju vjerojatnost pojavljivanja veću od nule. Također, poznato je da ako je hlađenje prebrzo, odnosno ako se pri svakoj temperaturi ne dostiže termalna ravnoteža, struktura materijala postaje amorfna, a ne kristalna rešetka niske unutarnje energije.

Evolucija stanja čvrstog materijala ka toplinskoj ravnoteži može se efikasno simulirati jednostavnim algoritmom temeljenim na Monte Carlo tehnici. Ovaj algoritam uzima trenutno stanje *x* i generira novo stanje *y* uz primjenu malih perturbacija. Prelazak iz stanja *x* u stanje *y* je prihvatljivo sa vjerojatnošću:

$$P_{\text{prihvatljivo}}(x, y) = \begin{cases} 1, & \text{ako je } E_x - E_y \leq 0 \\ e^{-\left(\frac{E_x - E_y}{k_B \cdot T}\right)}, & \text{ako je } E_x - E_y > 0 \end{cases} \tag{3.64}$$

Ako je prihvatljivo, *y* postaje trenutno stanje i procedura se ponavlja. Ovo pravilo prihvaćanja se naziva *Metropolis kriterij* [75].

Dani partikularni, kombinatorni optimizacijski problem daje rješenje *x* koje odgovara trenutnom stanju čvrstog materijala, funkciju cilja *f(x)* koja odgovara energiji trenutnog stanja i kontrolni parametar *T* koji odgovara trenutnoj temperaturi čvrstog materijala. Algoritam simuliranog kaljenja jednostavno se sastoji od iteriranja Metropolis algoritma, pri čemu se smanjuje vrijednosti umjetnog parametra temperature *T*. Algoritam je primjenjiv na problem kombinatorne optimizacije, uz preslikavanje: jedna konfiguracija strukture u jednu konfiguraciju problema, energija u funkciju cilja i temperatura *T* u kontrolni parametar *c*.

Neke od analogija između toplinskog procesa fizikalnog kaljenja i umjetnog procesa simuliranog kaljenja u kombinatornom optimizacijskom problemu su dane u tablici 3.4 [76], [77].

Tablica 3.4. *Analogija između simuliranog i fizikalnog kaljenja*

OPTIMIZACIJSKI PROBLEM	FIZIKALNI SUSTAV
Polazno rješenje x	Trenutno stanje materijala
Funkcija cilja f(x)	Energija trenutnog stanja
Kontrolni parametar T	Temperatura
Optimalno rješenje x_{opt}	Temeljno stanje
Simulirano kaljenje	Postupno hlađenje

Vjerojatnost prihvaćanja predloženog rješenja, poznata kao prihvatljiva vjerojatnost, je dana izrazom:

$$P_{prihvatljivo}(\Delta f, T) = \begin{cases} 1, & \Delta f \le 0 \\ e^{-\left(\frac{\Delta f}{T}\right)}, & \Delta f > 0 \end{cases} \tag{3.65}$$

ili alternativno,

$$P_{prihvatljivo}(\Delta f, T) = \min\left(1, e^{-\frac{\Delta f}{T}}\right) \tag{3.66}$$

Ovdje je Δf promjena u funkciji cilja koja odgovara predloženoj promjeni stanja, a *T* je umjetni kontrolni parametar koji predstavlja temperaturu. Činjenica da je prihvatljiva vjerojatnost točno 1 kada je Δf negativno, ukazuje da su potezi koji poboljšavaju funkciju cilja uvijek prihvatljivi. Simulirano kaljenje može prihvatiti i povećanje ciljne funkcije, omogućavajući da algoritam izbjegne lokalni minimum.

U pravilu, algoritam počinje na vrlo visokim temperaturama. Kako se temperatura smanjuje simulirano kaljenje vrlo rijetko prihvaća rješenja koja vode ka povećanju ciljne funkcije. Intuitivno ovo znači da algoritam započinje traženje globalno, bez restrikcije od strane lokalnog

okruženja ciljne funkcije, ali kako se temperatura smanjuje algoritam gravitira rješenjima sa nižom ciljnom funkcijom, dok na kraju, na veoma niskoj temperaturi, ne počne vršiti lokalno pretraživanje [77].

$$P_a(\Delta f, T) = \min\left(1, e^{-\frac{\Delta f}{T}}\right) \tag{3.67}$$

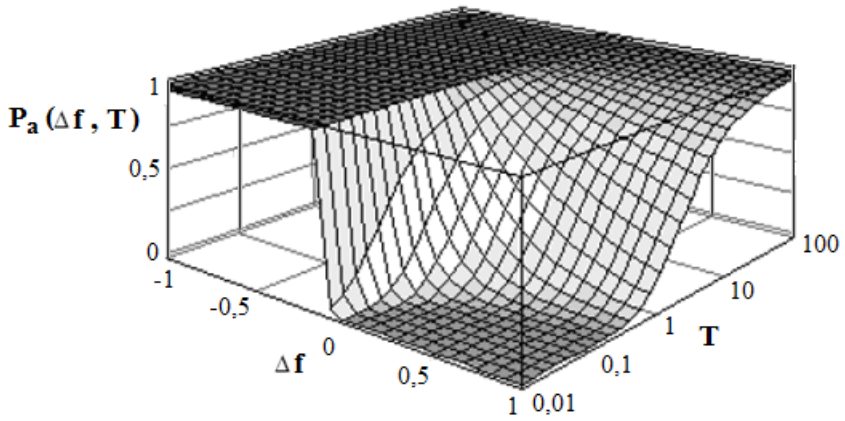

Slika 3.14. *Prihvatljiva vjerojatnost u odnosu na temperaturu i promjene u funkciji cilja*

Dani mehanizam definira generacijsku matricu vjerojatnosti *G(T)* kao matricu čiji *(i, j)* ulazi su vjerojatnost generiranja stanja *j* iz stanja *i*. Određivanjem ulaza matrice prihvatljive vjerojatnosti *A(T)* donosi matricu čiji *(i, j)* ulazi su vjerojatnost prihvaćanja predložene tranzicije iz stanja *i* u stanje *j*. Kompletna vjerojatnost pokretanja iz stanja *i* u stanje *j* može se okarakterizirati tranzicijskom matricom vjerojatnosti *P(T)* čiji *(i, j)* ulazi mogu biti prikazani kao:

$$P_{ij}(T) = \begin{cases} G_{ij}(T) \cdot A_{ij}(T), & \text{ako je } i \neq j \\ 1 - \sum_{k \in S, k \neq 1} P_{ik}(T), & \text{ako je } i = j \end{cases} \tag{3.68}$$

Sa sigurnim uvjetima generiranja i matricama prihvatljive vjerojatnosti, algoritam simuliranog kaljenja radi na fiksnoj temperaturi generirajući *Markovljev niz* sa prijelaznom matricom *P(T)*. Sa beskonačnim brojem tranzicija na fiksnoj temperaturi *T*, ovaj *Markovljev niz* ima stacionarnu razdiobu *q(T)* čija vjerojatnost da je u *i-tom* stanju nakon neograničenog broja tranzicija, može biti prikazana kao:

$$q_i(T) = \frac{e^{-\frac{f(i)}{T}}}{\sum_{k \in S} e^{-\frac{f(k)}{T}}} \tag{3.69}$$

Razdioba je ekvivalentna Boltzmannovoj razdiobi. Može se pokazati da stacionarna razdioba daje slijedeći rezultat:

$$q_i^* = \lim_{T\to 0} q_i(T) = \begin{cases} \dfrac{1}{|S_{opt}|}, & \text{ako je } i \in S_{opt} \\ 0, & \text{ako je } i \notin S_{opt} \end{cases} \tag{3.70}$$

Drugim riječima, davanjem prigodnog mehanizma perturbacije i neograničenog broja tranzicija, simulirano kaljenje će pronaći globalno optimalno rješenje optimizacijskog problema, sa vjerojatnošću 1.

Pošto je jasno da u praksi nije moguće pokretati algoritam u neograničenom broju iteracija, upotrebljava se aproksimacija konačnog vremena. U algoritmu konačnog vremena detalji aproksimacije su specificirani sa nečim što je poznato kao raspored hlađenja. Raspored hlađenja je veoma bitan za konvergenciju i brzinu konvergiranja algoritma simuliranog kaljenja. On specificira polaznu vrijednost temperature, kako i kada se temperatura mijenja tijekom procesa kaljenja, i kada se algoritam treba zaustaviti. Postoji mnogo različitih tipova rasporeda hlađenja, od kojih su neki vrlo jednostavni, a neki više kompleksni.

Jedan od tipova hlađenja može se prikazati u slijedećim koracima [78], [79]:

1. Polazna temperatura;
2. Promjena temperature;
3. Dužina Markovljevog niza;
4. Kriterij završetka hlađenja.

U algoritmu simuliranog kaljenja postoje mnoge varijacije kada se radi o rasporedu hlađenja. Određivanje učinkovitog rasporeda hlađenja je vrlo često slučaj izvođenja probne simulacije i ustanovljavanja greške. Pri ovoj implementaciji, raspored hlađenja se odabire relativno jednostavno i vrši se nekoliko prilagođavanja parametara temeljenih na rezultatima nekoliko probnih simulacija.

Polazna vrijednost toplinskog parametra se pronalazi pokretanjem iteracija Metropolis algoritma na temperaturi 1. Ako je prihvatljiv odnos za prvih 10 iteracija manji od 90%, temperatura se udvostruči i algoritam se pokreće za 10 novih iteracija. Ova procedura se ponavlja sve dok prihvatljiv odnos ne postane veći ili jednak 90%. U toj točki se vrijednost temperature uzima kao polazna temperatura za algoritam simuliranog kaljenja. Ova metoda osigurava da je polazna temperatura dovoljno visoka tako da je većina poteza prihvatljiva na početku procesa kaljenja.

Toplinski parametar se mijenja sukladno veoma jednostavnim, uobičajeno korištenim, pravilom. Nakon određenog broja iteracija određenih procedurom toplinski parametar se množi sa konstantom α koja se nalazi u granicama između 0 i 1.

Cilj određivanja optimalne dužine Markovljevog niza je da se dopusti da algoritam dostigne ravnotežu na danoj temperaturi. Nakon dostizanja ravnoteže, brojanje za generiranje novog stanja nije potrebno.

Algoritam se zaustavlja kada se pronađe rješenje i kada je temperatura dovoljno niska, praktično u stanju zamrznutosti. Ako zadnje stanje Markovljevog niza ostane nepromijenjeno za četiri iteracije, stanje se podrazumijeva zamrznutim i pretraživanje se obustavlja.

Jedan od najčešćih rasporeda hlađenja uključuje postavljanje polazne temperature na neku veliku konstantu vrijednost T_0 (dovoljno veliku da je inicijalni prihvatljivi omjer blizu 1) i nastavlja kako slijedi [79]:

1. Pokretanje Metropolis algoritma za *n* iteracija, za neko konstantno *n*, za generiranje dužine *n* Markovljevog niza;
2. Ako je konačno stanje zadnjeg *m* Markovljevog niza ostalo nepromijenjeno, gdje je *m* mala konstanta, onda se algoritam zaustavlja, a u suprotnom se nastavlja;
3. Promjena temperature *T* njenim množenjem sa konstantom α, gdje je α između 0 i 1;
4. Vraćanje na korak 1.

Konačna vremenska aproksimacija algoritma simuliranog kaljenja ne može garantirati konvergenciju ka optimalnom rješenju. Međutim, u mnogim slučajevima može naći rješenje blizu optimalnog u razumnom vremenskom periodu.

Iako je algoritam simuliranog kaljenja poznat kao alat za neograničenu optimizaciju, može se također koristiti za rješavanje problema sa ograničenjima. Ograničenja se mogu uzeti u proračun u mehanizmu perturbacije za generiranje novog stanja. U stvarnosti, mogu se generirati određeni tipovi nemogućih rješenja, ali se ona odbacuju i ne daju se kao predložena rješenja algoritma simuliranog kaljenja.

b) Opća primjena algoritma simuliranog kaljenja

Jedna od posebnosti algoritma simuliranog kaljenja je njegova jednostavna primjena. U principu, algoritam se može kodirati u samo nekoliko redaka, kako je to prikazano u pseudo C kodu [74], [77], [80].

```
x = Initial_State ;
f = Cost (x) ;
T = Initial_Temperature ( ) ;
do   {
     do   {
          new_x = Apply_Perturbation_To (x) ;
          Δf = Cost (new_x) – f ;
           if ( (Δf < 0)  OR  (random [0,1] < exp (-Δf/T))   {
                x = new_x ;
                f = f + Δf ;
           }
     }  while Not_At_Equilibrium ( ) ;
}  while Exit_Condition_not_Met  ( ) ;
```

Postoje četiri temeljne komponente koje se moraju specificirati za svaki pojedinačni optimizacijski problem:

1. Prostor pretraživanja;
2. Minimiziranje funkcije cilja u danom prostoru pretraživanja;
3. Mehanizam perturbacije za generiranje novog rješenja iz trenutnog;
4. Raspored hlađenja koji uključuje polaznu temperaturu, proceduru za promjenu temperature i kriterij za zaustavljanje algoritma.

Prostor pretraživanja i funkcija cilja su specificirani kao dio formulacije problema, dok mehanizam perturbacije i raspored hlađenja rade sa parametrima koji kontroliraju pretraživanje.

U okviru odabira tehnike hlađenja potrebno je [81] , [82]:

- odabrati polaznu vrijednost c_0 ,
- odabrati konačnu vrijednost c_f ,
- odrediti funkciju hlađenja.

Polazna vrijednost c_0 odabire se tako da su u početku gotovo svi prijelazi prihvaćeni, odnosno da budu prihvaćeni sa vjerojatnošću p_0. Ako sa ΔC^+ označimo prosječno povećanje funkcije cilja, tada vrijedi:

$$p_0 = e^{-\left(\frac{\Delta C^+}{c_0}\right)} \tag{3.71}$$

iz čega slijedi,

$$c_0 = \frac{\Delta C^+}{\ln\left(\frac{1}{p_0}\right)} \tag{3.72}$$

Što se tiče c_f, obično se unaprijed zada određeni broj koraka (10–50). Postoje mnoge funkcije hlađenja predložene u literaturi, ali se najčešće koristi najjednostavnija, množenje sa brojem manjim od 1, tipično u granicama [0,5–0,99].

c) Primjena algoritma na distribucijske sustave

Distribucijski sustav uobičajeno ima prekidače za sekcioniranje čije stanje određuje topološku konfiguraciju mreže. Konfiguracija sustava utječe na njegovu učinkovitost. Proizvođače električne energije, uglavnom, interesira pronalaženje najučinkovitije konfiguracije koja će minimizirati gubitke radne snage distribucijskog sustava.

U biti, rekonfiguracija mreže se može formulirati kao optimizacijski problem sa ograničenjima tipa jednakosti i nejednakosti. Rješenje problema može se temeljiti na općem kombinatornom

optimizacijskom algoritmu poznatom kao simulirano kaljenje. Odgovarajuće rješenje mora zadovoljiti Kirchhoffove (*Kirchhoff*) zakone.

U posljednje vrijeme, sa napretkom komunikacijskih i računalnih tehnologija, tvrtke za distribuciju električne energije su sve više zainteresirane za automatiziranje distribucije. Obzirom na povećanje kompleksnosti distribucijskih sustava, postalo je izuzetno važno automatiziranje određenih funkcija koje su uvijek bile izvođene manualno. Proračunato je da tvrtke mogu uštedjeti i više od 10% od svojih godišnjih troškova uporabom ovih tehnologija [83].

Jedno važno područje gdje se automatizacija primjenjuje je područje mrežne rekonfiguracije. Rekonfiguracija mreže u biti se odnosi na otvaranje i zatvaranje prekidača u distribucijskoj mreži u namjeri da se izmijeni topologija mreže, te na taj način i tok snage od transformatorskih stanica do potrošača. Postoje dva primarna razloga za rekonfiguraciju distribucijske mreže tijekom normalnog rada:

1. Eliminiranje preopterećenja komponenti sustava (transformatori, vodovi);
2. Reduciranje gubitaka radne snage.

Ovisno o tokovima struja, rekonfiguracija može postati neophodna da bi se eliminirala preopterećenja komponenti sustava. U ovom slučaju to se naziva balansiranje opterećenja.

Pošto se uvjeti opterećenja u mreži mijenjaju to, također, može postati isplativo jer se mogu reducirati gubici radne snage. Ovo se uglavnom odnosi na reduciranje gubitaka.

Rekonfiguracija mreže u oba slučaja se može klasificirati kao nelinearni optimizacijski problem. Metoda koja će riješiti ovaj problem mora brzo pronaći konfiguraciju mreže koja će minimizirati ukupne gubitke uz istovremeno zadovoljavanje sustavnih ograničenja. Za pronalaženje optimalnog rješenja može se koristiti metoda simuliranog kaljenja [77].

- Formuliranje problema

Sa ciljem da ostanu konkurentne na tržištu, za distribucijske tvrtke postaje sve važnije da osiguraju što kvalitetnije napajanje svojih kupaca. To znači da je jedan od primarnih ciljeva pronalaženje radnog stanja za velike, trofazne, nebalansirane distribucijske mreže, koje će osigurati minimum troškova snabdijevanja, uz zadovoljavanje zahtjeva potrošača.

Ako se pretpostavi da postoji neka trenutna konfiguracija distribucijskog sustava koja je definirana određenim radnim troškovima, kako bi ona predstavljala rješenja problema moraju se zadovoljiti određena topološka ograničenja, električna ograničenja u smislu poštivanja Kirchhoffovih zakona, radna ograničenja, kao i fizikalna ograničenja svih komponenti sustava.

Osim ovoga, jedno ovakvo rješenje mora zadovoljiti i zahtjeve potrošača za radnom snagom, ali i ograničenja vezana za održavanje napona na sabirnicama u zadanim granicama.

Dakle, cilj je pronalaženje odgovarajuće konfiguracije distribucijske mreže koja će dati minimum funkcije cilja, ali uz zadovoljavanje svih navedenih ograničenja. Svako rješenje koje zadovoljava ograničenja naziva se *moguća konfiguracija*.

- Funkcija cilja

Cilj problema rekonfiguracije mreže je minimiziranje ukupnih gubitaka radne snage distribucijskog sustava. Gubici radne snage uključuju gubitke u prijenosnim vodovima, toplinske gubitke u transformatorima i gubitke naponske regulacije. Ovi individualni gubici mogu se proračunati iz analize tokova snaga i mogu se prikazati kao:

$$f(x, u) = \left(\sum_{i=1}^{n_v} P_i^{\text{vodova}}\right) + \left(\sum_{j=1}^{n_t} P_j^{\text{transformatora}}\right) + \left(\sum_{k=1}^{n_r} P_k^{\text{regulatora}}\right) \tag{3.73}$$

gdje su: P_i^{vodova}, $P_j^{\text{transformatora}}$, $P_k^{\text{regulatora}}$ – gubici radne snage u vodu i, transformatoru j i naponskom regulatoru k

n_v , n_t , n_r – brojevi vodova, transformatora i naponskih regulatora sustava

U funkciju cilja se jednostavno može uključiti i cijena prijelaza sa jedne konfiguracije na drugu.

- Prostor pretraživanja

Kako bi se mogla provjeriti postavljena ograničenja, u svakom trenutku mora postojati informacija o amplitudama i kutovima napona na svakoj sabirnici. Ukoliko na bilo kojoj sabirnici amplituda napona ili njegov kut ne odgovaraju zadanim granicama, dobivena konfiguracija mreže ne može se uzeti kao jedno od rješenja.

Pošto je ova informacija uključena u varijablu stanja x, ona se može prikazati kao:

$$x = [\theta_1, \theta_2, \dots, \theta_n, |V_1|, |V_2|, \dots, |V_n|]^T \tag{3.74}$$

a prostor stanja $IR^{6(n-1)}$.

- Ograničenja

Bilo koja dobivena konfiguracija u setu mogućih konfiguracija ne znači da je ona nužno rješenje problema rekonfiguracije. Može se dogoditi da u set mogućih rješenje uđe i konfiguracija u kojima su gubici radne snage nula. To će se dogoditi ako sve prekidače isključimo. Na taj način je zadovoljen kriterij minimiziranja funkcije cilja, ali je rad sustava na ovaj način praktički nemoguć, niti je u praksi izvodljiv, a posebno nije prihvatljiv jer se na taj način uzrokuju gubici kod potrošača. Zato se mora točno odrediti koja su stanja prihvatljiva, a koja nisu. Kako bi se ovo uzelo u obzir, moraju se zadovoljiti već spomenuta četiri tipa ograničenja [84]:

1. Topološka ograničenja;
2. Električna ograničenja;
3. Radna ograničenja;
4. Ograničenja u napajanju.

1. Topološka ograničenja

Pošto skoro sve distribucijske mreže imaju topologiju radijalnog karaktera (Slika 3.15), odnosno u mreži ne postoje zatvorene petlje, prilikom primjene bilo kakve optimizacijske metode mora se voditi računa da se kao moguća rješenje ne prihvaćaju ona u kojima postoji ijedna zatvorena petlja. Druga karakteristika topologije je da svaka sabirnica mora biti povezana sa izvorom sa najmanje jednim vodom. Kada se zadovolje ova dva zahtjeva, njihova kombinacija određuje moguću topologiju distribucijskog sustava.

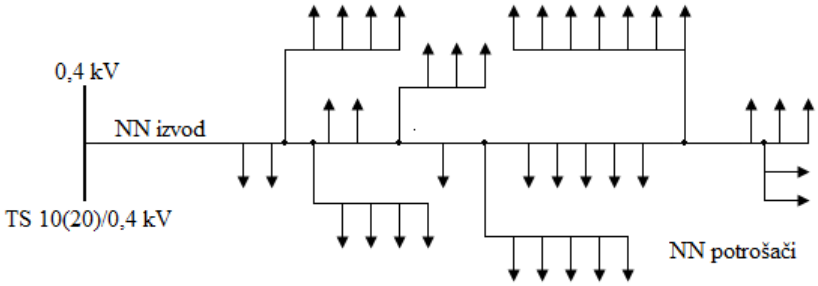

Slika 3.15. *Primjer radijalne distribucijske mreže*

Topološka ograničenja predstavljaju restrikciju vektora položaja prekidača. Pretpostavimo da u sustavu postoji ukupno $n_s = n_{otvoren} + n_{zatvoren}$ prekidača, gdje je $n_{otvoren}$ broj normalno otvorenih prekidača, a $n_{zatvoren}$ broj normalno zatvorenih prekidača. Pošto je mreža radijalna, pri čemu je svaka sabirnica povezana na neki način sa sabirnicom podstanice, nikad ne smije biti više od $n_{otvoren}$ otvorenih prekidača. Otvaranje još jednog prekidača će podijeliti mrežu na dva nepovezana dijela. Zatvaranje još jednog prekidača će proizvesti petlju koja će narušiti radijalni karakter mreže. Stoga, u mreži nikada ne može biti manje od $n_{otvoren}$ otvorenih prekidača.

Drugim riječima, broj otvorenih prekidača u svakom trenutku mora biti točno $n_{otvoren}$, a broj zatvorenih točno $n_{zatvoren}$. S ovom restrikcijom ukupan broj mogućih konfiguracija bi bio:

$$\binom{n_s}{n_{otvoren}} = \binom{n_s}{n_{zatvoren}} = \frac{n_s!}{n_{otvoren}! \cdot (n_s - n_{otvoren})!} \tag{3.75}$$

Predstavljanjem jedne radijalne konfiguracije, nova radijalna konfiguracija može se pronaći primjenom dva jednostavna koraka u implementiranoj proceduri:

- Zatvori točno jedan otvoreni prekidač, nasumice odabran iz seta svih otvorenih prekidača. Ovo će stvoriti petlju u sustavu pošto je ona radijalnog karaktera;

- Otvori točno jedan zatvoreni prekidač, nasumice odabran iz seta svih zatvorenih prekidača, a koji je lociran u petlji stvorenoj u prvome koraku.

U cilju pronalaženja potencijalnog prekidača za razbijanje petlje, neophodno je spremiti veći broj povezanih informacija u podacima strukture mreže. Podaci se spremaju u dvije skupine; jedni za sabirnice, a drugi za vodove. Svaki element u sabirničkoj skupini sadrži polje kojim se specificira dolazni vod i polje sa listom odlaznih vodova. U grupi vodova, svaki element sadrži dva polja kojima se specificiraju sabirnice na krajevima vodova.

Ovakva elementarna promjena u konfiguraciji rezultira novom, validnom konfiguracijom koja je na neki način blizu prethodne konfiguracije i može se promatrati kao mala perturbacija prethodnog rješenja. Ova metoda generiranja nove vrijednosti osigurava da će samo moguća konfiguracija biti usvojena. Iako se mogu upotrebljavati i druge metode za generiranje nove moguće točke, ova na jednostavan način osigurava da svako rješenje generirano algoritmom simuliranog kaljenja bude dostupno kroz sekvencu promjene prekidača, što će sve rezultirati konfiguracijama koje zadovoljavaju topološka ograničenja.

2. Električna ograničenja

Obzirom da kroz distribucijski sustav teku struje, ovaj tip ograničenja je isključivo vezan za poštivanje Kirchhoffovih zakona. Ovo je vrlo važno ograničenje koje se mora uzeti u obzir obzirom da distribucijski sustav može biti izuzetno velik, sa tisućama sabirnica.

3. Radna ograničenja

Može se dogoditi da se jedna ili više dobivenih konfiguracija, kojima se dobiva minimum zadane funkcije cilja, odnosno koje daju optimalno rješenje problema, ipak ne mogu uzeti u obzir kao moguća rješenja. Naime, obzirom da svaki element sustava ima svoje fizikalno ograničenje vezano za termička naprezanja, ne može se dozvoliti da bilo koji element sustava radi iznad dopuštenih granica. Stoga, iako neko rješenje daje optimalnu vrijednost funkcije cilja, ukoliko nisu zadovoljena i ova radna ograničenja, takvo rješenje ne može se uzeti u razmatranje. Ova ograničenja mogu se uvrstiti u proračun ograničavanjem struje i napona u odgovarajuće granice.

4. Ograničenja u napajanju

Prilikom odabira optimalnog rješenja mora se voditi računa o činjenici da i potrošači imaju svoje zahtjeve vezane za kvalitetu električne energije kojom su snabdjeveni. To se u prvome redu odnosi na kontinuitet i kvalitetu energije koju primaju. Najčešće je to vezano za kontinuiranu isporuku i postojan napon i frekvenciju. S toga, svaki proizvođač električne energije mora voditi računa da osigura stabilan napon na svakoj sabirnici, za svakog potrošača, tako da se i ova ograničenja moraju uzeti u obzir prilikom određivanja optimalne konfiguracije mreže.

- Matematička interpretacija

Svaka sabirnica u sustavu može se klasificirati u jednu od tri kategorije:

1. PQ sabirnica – poznate su injektirana radna i jalova snaga, a nepoznate magnituda (veličina, vrijednost) i kut napona;
2. PV sabirnica – poznate su injektirana radna snaga i magnituda napona, a nepoznate injektirana jalova snaga i kut napona;
3. Referentni čvor – poznata je magnituda i kut napona, a nepoznata injektirana radna i jalova snaga.

U tipičnim distribucijskim sustavima sve sabirnice su PQ sabirnice, osim jedne koja se uzima kao referentni čvor.

U trofaznoj distribucijskoj mreži koja ima ukupno *n* sabirnica, gdje je sabirnica 1 referentni čvor, vektor nepoznanica je [85]:

$$x = [\theta_2, \dots, \theta_i, |V_2|, \dots, |V_i|]^T \tag{3.76}$$

pri čemu je,

$$\theta_i = \left[\theta_i^a, \theta_i^b, \theta_i^c\right]^T \tag{3.77}$$

$$|V_i| = \left[|V_i^a|, |V_i^b|, |V_i^c|\right]^T \tag{3.78}$$

gdje je *i* broj čvora, a *a, b, c* su oznake faza.

Tada se problem tokova snaga može definirati kao problem pronalaženja *x* tako da su *ΔP(x)* i *ΔQ(x)* nula na svakoj PQ sabirnici. Drugim riječima, treba pronaći *x* tako da je:

$$\Delta P_i^p(x) = 0 \tag{3.79}$$

$$\Delta Q_i^p(x) = 0 \tag{3.80}$$

za i = 1, 2, 3, ... i p = a, b, c gdje je neslaganje snage dano kao:

$$\Delta P_i^p(x) = P_i^p - |V_i^p| \sum_{k=1}^{n} \sum_{m=a}^{c} |V_k^m| \cdot [\, G_{ik}^{pm} \cdot \cos\theta_{ik}^{pm} + B_{ik}^{pm} \cdot \sin\theta_{ik}^{pm} \,] \tag{3.81}$$

$$\Delta Q_i^p(x) = Q_i^p - |V_i^p| \sum_{k=1}^{n} \sum_{m=a}^{c} |V_k^m| \cdot [\, G_{ik}^{pm} \cdot \sin\theta_{ik}^{pm} - B_{ik}^{pm} \cdot \cos\theta_{ik}^{pm} \,] \tag{3.82}$$

Imajući na umu da je matrica admitancija sustava funkcija trenutne konfiguracije mreže *u*, posljednje jednadžbe mogu biti prikazane u kompaktnoj formi kao ograničenja tipa jednakosti na *x* i *u*,

$$F(x, u) = 0 \tag{3.83}$$

Nakon rješavanja ovog sustava od (6n – 6) nelinearnih algebarskih jednadžbi, injektirana radna i jalova snaga na referentnom čvoru mogu se naći korištenjem jednadžbi:

$$P_i^p = \left|V_i^p\right| \sum_{k=1}^{n} \sum_{m=a}^{c} |V_k^m| \cdot [\, G_{ik}^{pm} \cdot \cos\theta_{ik}^{pm} + B_{ik}^{pm} \cdot \sin\theta_{ik}^{pm} \,] \tag{3.84}$$

$$Q_i^p = \left|V_i^p\right| \sum_{k=1}^{n} \sum_{m=a}^{c} |V_k^m| \cdot [\, G_{ik}^{pm} \cdot \sin\theta_{ik}^{pm} - B_{ik}^{pm} \cdot \cos\theta_{ik}^{pm} \,] \tag{3.85}$$

- Algoritam

Pošto je problem tokova snaga sustav nelinearnih algebarskih jednadžbi, ne postoji zatvorena forma rješenja. Stoga su algoritmi koji se koriste za rješavanje ovog problema iterativni. Neslaganja radne i jalove snage se računa uporabom polazne vrijednosti za *x*, kao trenutna radna točka ili *flat start* konfiguracija. Nakon toga se dobivene vrijednosti koriste za *update* vrijednosti *x*. Ako je polazno stanje dovoljno blizu rješenju i ako je korištena dobra metoda za update *x*, algoritam će konvergirati u validno rješenje. Ovaj tip algoritma može se prikazati u slijedećim koracima:

1. Pretpostaviti polaznu vrijednost za x;
2. Izračunati ΔP i ΔQ;
3. Upotrijebiti ΔP i ΔQ u narednoj iteraciji za x;
4. Ponavljati korake 2 i 3 sve dok ΔP i ΔQ ne budu manji od neke tolerancije.

Prikazano rješavanje jednadžbi tokova snaga odnosi se na Newton–Raphsonovu metodu. Osim ove, koristi se i jednostavnija (za manje sustave) Gauss–Seidelova metoda. Ona zahtijeva manje računanja po koraku, dok Newton–Raphsonova metoda zahtijeva računanje matrice Jacobijana. Ipak, Newton–Raphsonova metoda ima bržu kvadratnu konvergenciju i upotrebljava se za proračune kod velikih sustava, dok se Gauss–Seidelova metoda kod velikih sustava često koristi za određivanje prvog, aproksimativnog rješenja, koje zatim postaje polazna vrijednost za Newton–Raphsonovu metodu.

- Primjer primjene algoritma

Metoda simuliranog kaljenja može se uspješno primijeniti u širokom spektru optimizacijskih problema. Jedan od primjera gdje se ova metoda može primijeniti je prikazan na slici 3.16.

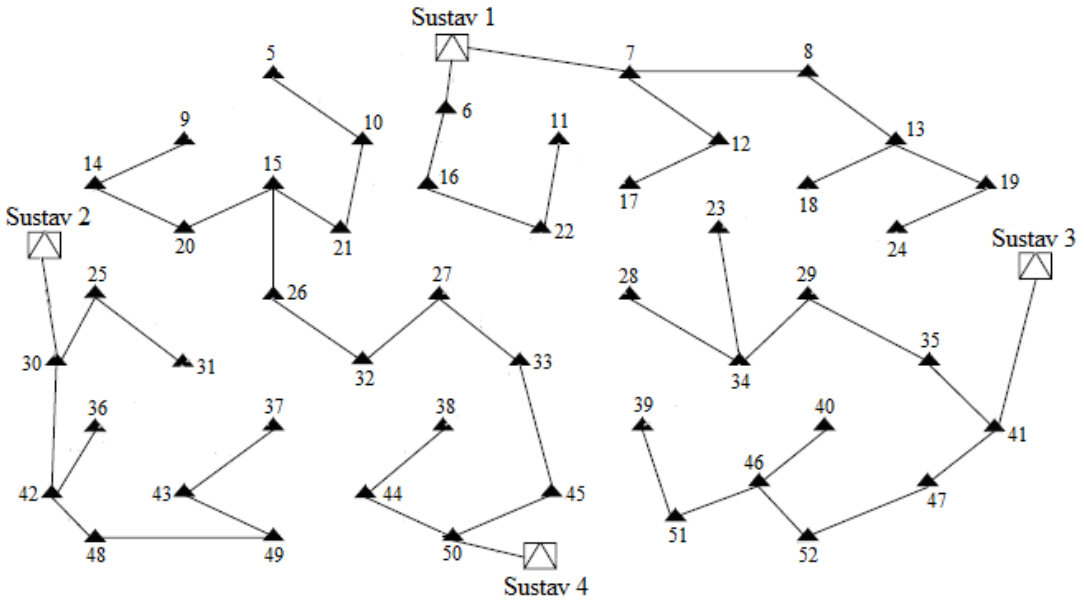

Slika 3.16. *Primjer četiri nepovezana distribucijska sustava*

Ukoliko se ova četiri nepovezana distribucijska sustava žele električki povezati, te dobiti optimalna konfiguracija, u prvom koraku između ovih sustava se može postaviti proizvoljan broj interkonekcija. Na taj način će odvojeni sustavi međusobno biti povezani, pri čemu se u ovom koraku ne mora voditi računa o tome hoće li nove interkonekcije prouzročiti pojavu zatvorenih petlji ili ne (Slika 3.17).

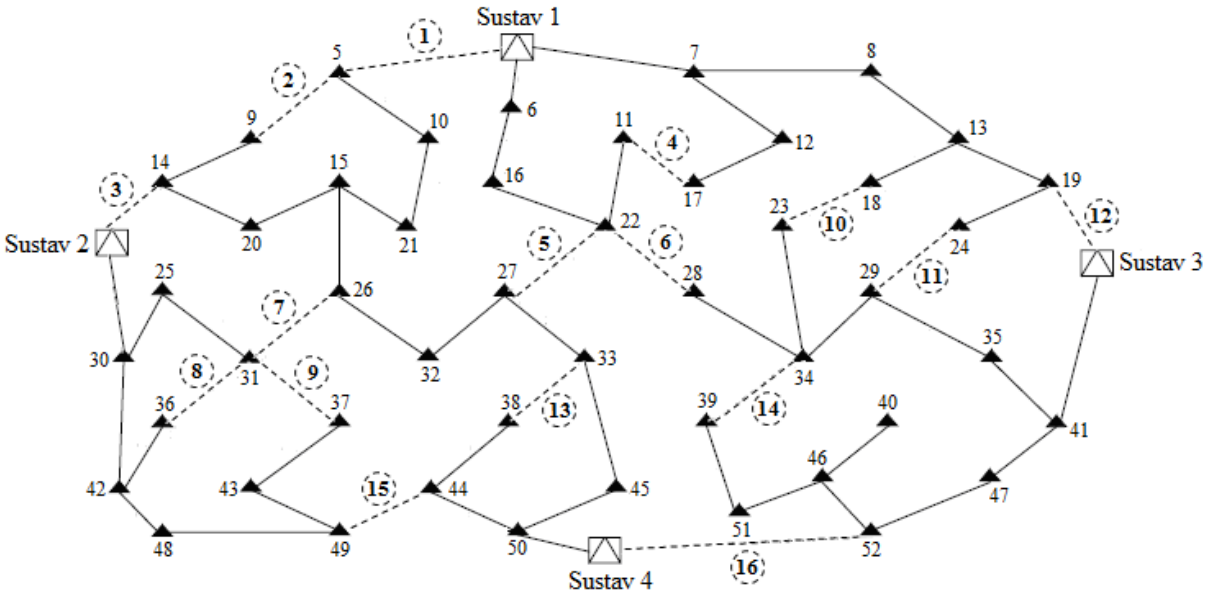

Slika 3.17. *Povezani distribucijski sustav*

Odabranim interkonekcijama od četiri nepovezana dobiva se jedan povezan distribucijski sustav. Pošto su interkonekcije nasumice odabrane novoformirani sustav nije radijalnog karaktera, nego u njemu egzistira veći broj petlji.

Ukoliko se, u drugom koraku, dodane interkonekcije promatraju kao prekidači, na novoformirani sustav se može primijeniti metoda simuliranog kaljenja. Primjenom ove metode može se dobiti optimalna konfiguracija, pri čemu će mreža sigurno biti radijalnog karaktera, što je i stvarni cilj.

Ova metoda je naročito prigodna za primjenu kod projektiranja u cijelosti novih distribucijskih sustava. Naime, prostorno se mogu projektirati odvojeni, manji sustavi koje kasnije treba međusobno povezati i napojiti iz jedne točke. Primjenom metode simuliranog kaljenja se, kako je to prikazano, mogu jednostavno odrediti međusobne interkonekcije između sustava i izvora, uz zadovoljavanje svih uvjeta i postizanje optimalnih ciljeva.

U predloženom modelu planiranja niskonaponskih distribucijskih mreža ova metoda se upotrebljava za određivanje optimalne konfiguracije najboljeg prostornog rješenja mreže, a koje se dobiva primjenom hijerarhijskih optimizacijskih metoda.

4. MODEL PLANIRANJA NISKONAPONSKIH DISTRIBUCIJSKIH MREŽA

4.1. OPĆENITO O MODELIMA PLANIRANJA

Sustavnim planiranjem niskonaponskih distribucijskih mreža nastoji se odrediti optimalna konfiguracija niskonaponske distribucijske mreže, za snabdijevanje električnom energijom potrošača raspoređenih na određenom zemljopisnom području. U biti se sastoji od određivanja instalirane, odnosno nazivne snage i lokacije transformatorske stanice, tipova vodiča koje je potrebno upotrijebiti, te prostorne konfiguracije (topologije) niskonaponske distribucijske mreže.

Niskonaponsku distribucijsku mrežu karakteriziraju mala opterećenja potrošača, česta uporaba zračnih vodova i uglavnom veća dužina niskonaponskih izvoda. Temeljni problem kod planiranja niskonaponskih distribucijskih mreža u biti je pronalaženje radijalne konfiguracije mreže sa najnižim ukupnim troškovima, pri čemu se mora voditi računa o nazivnoj snazi i lokaciji transformatorske stanice, smjerovima rasprostiranja i prijenosnoj moći niskonaponskih vodova kojima se snabdijevaju prostorno raspoređeni potrošači sa određenim prognoziranim opterećenjima, toplinskim ograničenjima (transformatori i niskonaponski vodovi), te naponskim razinama.

U uvjetima tržišnog poslovanja, kada kvaliteta električne energije koja se isporučuje krajnjim potrošačima ima jednu od najvažnijih uloga, kao primarni cilj kod planiranja niskonaponskih distribucijskih mreža postavlja se kvaliteta, odnosno razina napona koja kod svakog potrošača mora biti sukladna propisanoj normi.

Nakon toga, gledano iz kuta distribucijske tvrtke, kao naredni cilj se postavlja dovođenje na što nižu razinu gubitaka u mreži, što se može postići pravilnim odabirom vrste vodiča, odnosno kabela mreže i optimalnom prostornom razdiobom niskonaponske distribucijske mreže.

Naravno, od značaja za distribucijsku tvrtku su i troškovi izgradnje jedne ovakve mreže, ali u tržišnim uvjetima zahtjevi kupaca su prioritetni tako da ovi troškovi nisu u prvome planu.

Na kraju, od značaja je i kapacitet, odnosno propusna moć niskonaponskih vodova, koji limitiraju iznose opterećenja koja se moraju prenijeti do krajnjih potrošača. Ovakav problem se može riješiti adekvatnim odabirom tipova i presjeka vodiča.

Dakle, radi se o kompleksnom problemu gdje je istovremeno potrebno riješiti pitanje optimalne lokacije transformatorske stanice i konfiguracije niskonaponske mreže, ali uz uvažavanje spomenutih kriterija.

Pregledom dostupne literature može se konstatirati da se većina istraživanja, kada se radi o modelima planiranja elektroenergetskih mreža, temelji na analizama i softverskim rješenjima vezanim za srednjenaponske distribucijske mreže. Ipak, postoje i određena istraživanja kada su u pitanju niskonaponske distribucijske mreže, iako u manjem obimu. Skoro svi ponuđeni algoritmi koji bi trebali riješiti pitanje planiranja niskonaponskih distribucijskih mreža temelje se na evolucijskom programiranju, korištenju genetskih algoritama, dinamičkoj optimizaciji, stohastičkim pristupima itd. [86], [87], [88], [89].

Sve su to veoma dobri i korisni pokušaji rješavanja ovog bitnog pitanja, ali sa jednim važnim nedostatkom. Naime, pregledom dostupnih modela može se doći do zaključka da je većina njih pravljena da zadovolji potrebe distribucijskih tvrtki jer su nekako uvijek u prvome planu investicijski troškovi izgradnje i održavanja ovakvih elektroenergetskih objekata. To je razumljivo u jednom monopolističkom sustavu poslovanja kada distribucijske tvrtke imaju monopol na tržištu i kada su praktički svi troškovi tvrtki pokriveni cijenom električne energije koju plaćaju kupci. Međutim, uvođenjem tržišnih uvjeta poslovanja u elektroenergetski sektor situacija se bitno mijenja. Sada potrošači imaju mogućnost izbora vlastitog opskrbljivača električne energije i njihovi zahtjevi dolaze u prvi plan, a to su prije svega opskrba kvalitetnom električnom energijom sa, po mogućnosti, što nižom cijenom. Dakle, ukoliko želi zadržati kupca distribucijska tvrtka mora prvo zadovoljiti uvjete potrošača pa tek onda voditi računa o vlastitim troškovima.

U ovome poglavlju će biti predstavljen jedan novi model planiranja niskonaponskih distribucijskih mreža koji upravo zahtjeve potrošača stavlja u prvi plan. To ni u kom slučaju ne znači da se interesi tvrtke stavljaju u drugi plan jer se sam model temelji na vrednovanju određenih kriterija, koji su opet subjektivna stvar inženjera–planera uposlenih u distribucijskim tvrtkama. Ipak, prijedlog je da kvaliteta isporučene električne energije, prije svega naponska razina, igra najvažniju ulogu, pa tek onda svi kriteriji neophodni za donošenje konačne odluke, odnosno rješenja.

Predloženi model temelji se na uporabi suvremenih hijerarhijskih i stohastičkih algoritama opisanim u poglavlju 3. Svi algoritmi su specijalno programirani i prilagođeni modelu. Vrlo su jednostavni za primjenu i iskusnim inženjerima mogu biti veoma koristan alat pri rješavanju problema planiranja niskonaponskih distribucijskih mreža. Ovaj model se bez ikakvih problema može primijeniti i u planiranju srednjenaponskih distribucijskih mreža.

4.2. DIJAGRAM TOKA

Model planiranja niskonaponskih distribucijskih mreža, korištenjem spomenutih hijerarhijskih i stohastičkih metoda, može se jednostavno prikazati kao na dijagramu toka prikazanom na slici 4.1.

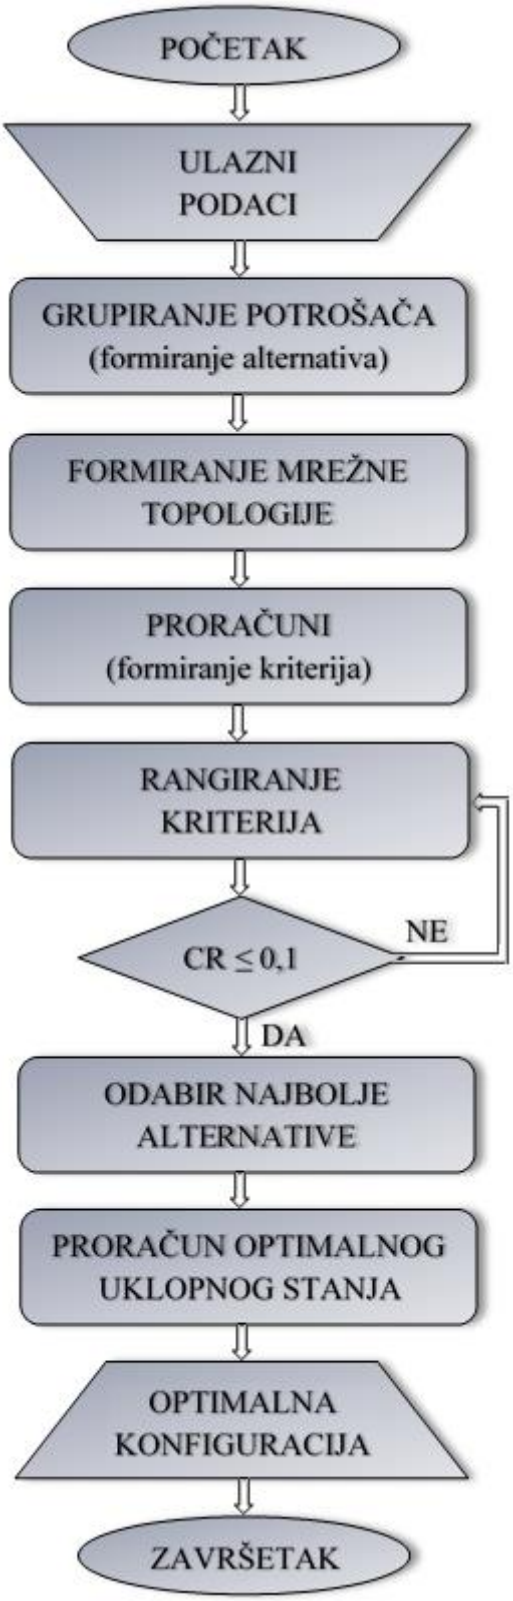

Slika 4.1. *Dijagram toka predloženog modela planiranja niskonaponskih distribucijskih mreža*

4.3. KORACI PREDLOŽENOG MODELA PREMA DIJAGRAMU TOKA

Predloženi model planiranja niskonaponskih distribucijskih mreža u konačnici treba ponuditi optimalnu konfiguraciju niskonaponske distribucijske mreže, koja daje najmanje vrijednosti padova napona na niskonaponskim izvodima, odnosno u zadanim granicama, kao i minimalne gubitke snage cjelokupne distribucijske mreže. To su dva temeljna uvjeta koja moraju biti zadovoljena kada su u pitanju zahtjevi potrošača za kvalitetnom opskrbom električnom energijom (padovi napona), te temeljni kriterij koji će zadovoljiti potrebe distribucijske tvrtke (gubici snage).

Dakle, ako sa x_{opt} označimo optimalnu konfiguraciju distribucijske mreže, a sa *f(x)* funkciju cilja primjenom modela treba se dobiti funkcija za koju vrijedi,

$$f\left(x_{opt}\right) \leq f(x), \ \forall x \in S \tag{4.1}$$

gdje je *S* set svih mogućih rješenja *x*, uz uvjet minimiziranja gubitaka u mreži i održavanje padova napona u unaprijed zadanim granicama, odnosno

$$\begin{aligned} &\underset{x \in S}{\text{minimize}}\, P_{gub} \\ &\underset{x \in S}{\text{minimize}}\, Q_{gub} \\ &\text{-}10\%\ (U_n) \leq \Delta u \leq +10\%\ (U_n) \end{aligned} \tag{4.2}$$

Cjeloviti model može se definirati i objasniti u nekoliko koraka koji su prikazani dijagramom toka na slici 4.1.

4.3.1. Ulazni podaci

Za proračune tokova snaga u distribucijskoj mreži potrebno je poznavati pojedinačna opterećenja potrošača koji se napajaju preko niskonaponske distribucijske mreže, te je stoga potrebno imati odgovarajuće podatke o samim potrošačima kako bi se došlo do podataka o opterećenjima. Za to je potrebno imati podatke o ukupnoj godišnjoj utrošenoj energiji svakog potrošača, kao i jednodnevno, satno mjerenje opterećenja svakog od niskonaponskih izvoda, kao i same transformatorske stanice. Temeljem ovih podataka je metodom vršnih opterećenja moguće odrediti vršno opterećenje svakog od potrošača, kako je to opisano u poglavlju 2.3.1.

Ukoliko se radi o planiranju, odnosno projektiranju u cijelosti nove niskonaponske distribucijske mreže onda ovi podaci, naravno, nemaju smisla, te se vrši približna procjena opterećenja potrošača primjenom procijenjenog faktora istodobnosti potrošnje, uz uvažavanje određenih posebnosti, odnosno karakteristika samih potrošača (Poglavlje 2.3.1).

Za bilo kakve proračune u dobivenoj niskonaponskoj distribucijskoj mreži je potrebno poznavati i parametre mreže. Tu se prvenstveno misli na karakteristike transformatorske stanice

koju je potrebno ugraditi, kao i na temeljne parametre vodova i to prije svega na presjeke vodova koji će se upotrebljavati u topološkoj konfiguraciji mreže, odnosno na otpornosti (R i X) svakog predloženog tipa voda.

Kada su vodovi u pitanju, potrebno je poznavati i njihove dužine kako bi se mogli vršiti proračuni, ali one ne spadaju u polazne ulazne podatke jer se ti podaci dobivaju kasnijim crtanjem mreže, te se određuju na georeferenciranim zemljopisnim kartama (podlogama).

Cjelovita grafička interpretacija predloženog modela temelji se na georeferenciranim zemljopisnim kartama (podlogama). Na tim kartama je vrlo jednostavno doći do *zemljopisnih koordinata mjernih mjesta* svakoga potrošača kojeg je putem isplanirane distribucijske mreže potrebno opskrbiti električnom energijom, kako je to prikazano na slici 4.2.

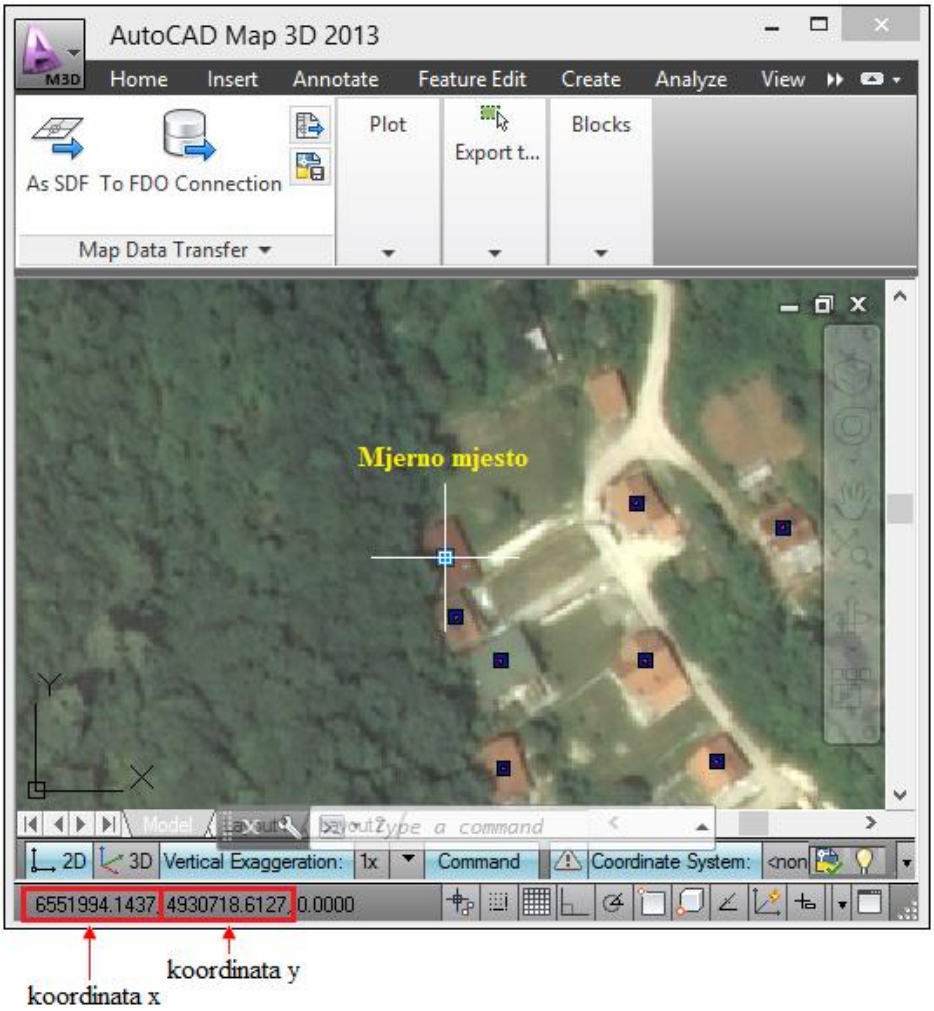

Slika 4.2. *Zemljopisne koordinate mjernog mjesta*

Dakle, označavanjem mjernih mjesta i čitanjem zemljopisnih koordinata za svako od njih, sa georeferencirane podloge, u prigodnom programskom alatu (AutoCAD i sl.) dobiva se set podataka neophodnih za daljnji tijek primjene modela. Ovi podaci se u Matlab-u smještaju u jednu *.dat* datoteku (Slika 4.3) i koriste se kao ulazni podaci algoritma grupiranja potrošača.

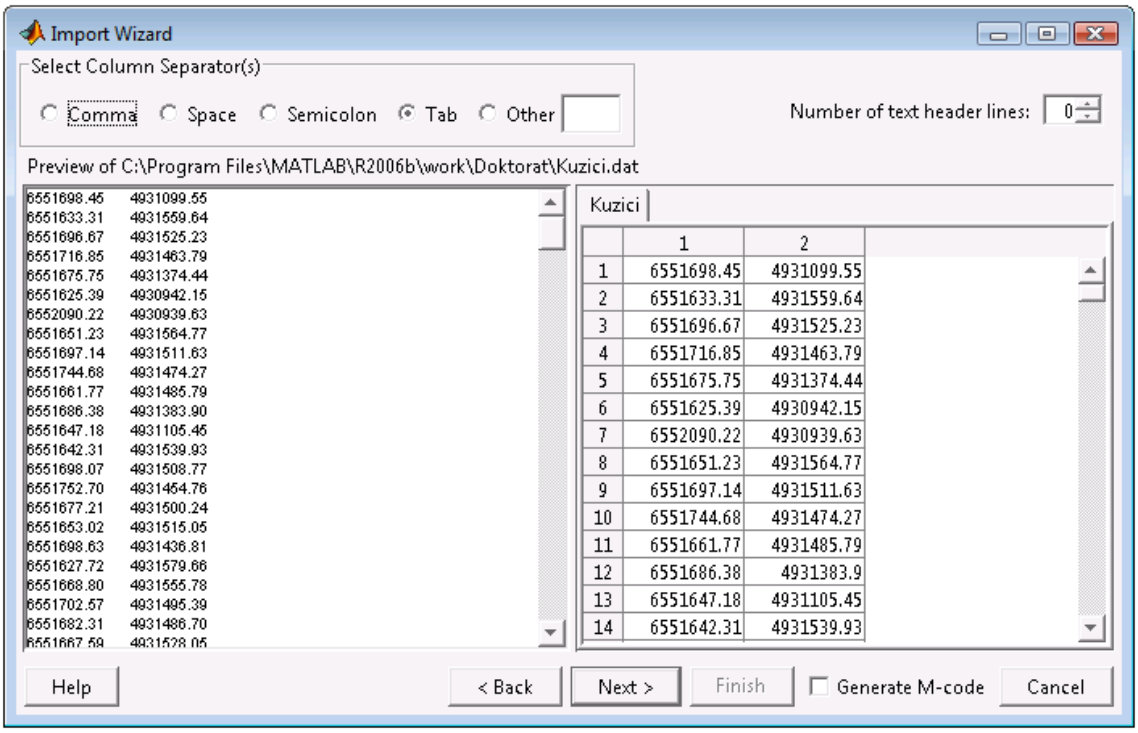

	1	2
1	6551698.45	4931099.55
2	6551633.31	4931559.64
3	6551696.67	4931525.23
4	6551716.85	4931463.79
5	6551675.75	4931374.44
6	6551625.39	4930942.15
7	6552090.22	4930939.63
8	6551651.23	4931564.77
9	6551697.14	4931511.63
10	6551744.68	4931474.27
11	6551661.77	4931485.79
12	6551686.38	4931383.9
13	6551647.18	4931105.45
14	6551642.31	4931539.93

Slika 4.3. *Zemljopisne koordinate mjernih mjesta u .dat datoteci*

U ovom modelu ovi podaci se koriste za grupiranje budućih potrošača, odnosno u konačnici dobivanje alternativa (varijanti) čijom prigodnom procjenom se dobiva optimalno rješenje.

4.3.2. Formiranje alternativa

Nakon što se definiraju koordinate mjernih mjesta svih potrošača koje je potrebno priključiti na distribucijsku mrežu, prije svega je nužno odrediti veličinu (tip) transformatorske stanice preko koje će potrošači biti opskrbljeni električnom energijom. Veličina transformatorske stanice, a samim tim i njen tip, može se odrediti temeljem proračuna danim u poglavlju 2.3 ovisno da li se radi o postojećem konzumu ili je potrebno izvršiti planiranje za u cijelosti novi konzum.

Ukoliko se radi o postojećem konzumu onda se veličina transformatorske stanice određuje temeljem zbirnog opterećenja svih potrošača. Pojedinačna opterećenje potrošača mogu se dobiti metodom vršnih opterećenja temeljem godišnje ostvarene energije svakog potrošača i jednodnevnog satnog očitanja opterećenja svih niskonaponskih izvoda transformatorske stanice. Zbrajanjem ovih opterećenja dobiva se minimalna potrebna snaga transformatorske stanice.

Ukoliko se vrši planiranje u cijelosti novoga konzuma onda se opterećenje svakog potrošača može procijeniti uzimajući u obzir faktor istodobnosti opterećenja, pri čemu se moraju poznavati i određene individualne posebnosti i navike potrošača. Zbrajanjem pojedinačnih opterećenja potrošača dobiva se minimalno potrebna snaga transformatorske stanice (na primjer, 115 kupaca × 1,1 kW/kupcu = 126,5 kW, odnosno odabire se tipska transformatorska stanica instalirane snage 160 kVA).

U oba ova slučaja mora se voditi računa da odabrani tip transformatorske stanice zadovolji potrebe potrošača, ali da istovremeno ne smije dolaziti do preopterećenja same transformatorske stanice. Stoga uvijek treba odabrati snagu transformatorske stanice makar za jedan stupanj (tipski) veću nego što to pokaže proračun.

Pri odabiru veličine transformatorske stanice poželjno je poznavati i perspektivu razvoja transformatorskog područja, odnosno prognozu potrošnje područja, kako bi se i ovaj faktor mogao uzeti u obzir. Na taj način bi se osiguralo da transformatorska stanica može sigurno raditi u određenom budućem vremenskom periodu, bez pojave preopterećenja i eventualnih kvarova zbog preopterećenja. To je jako bitno jer je osim opskrbe kvalitetnom električnom energijom sigurnost u napajanju potrošača veoma važan faktor u tržišnim uvjetima poslovanja.

Isto tako, treba imati na umu da se transformatorske stanice do 250 kVA izgrađuju kao stupne, dok se transformatorske stanice veće snage izgrađuju kao zasebni građevinski objekti za koje je potrebno osigurati znatno veće građevinsko zemljište. Ovo dolazi do izražaja kod određivanja lokacije transformatorske stanice, jer je za stupne izvedbe potrebno znatno manje prostora i puno je lakše rješavanje imovinsko–pravnih odnosa. U slučaju nemogućnosti rješavanja imovinsko–pravnih odnosa pomicanje lokacije transformatorske stanice dovodi do njenog dislociranja iz centra konzuma, što nije dobro.

Dakle, kada se donosi odluka o veličini i tipu transformatorske stanice sve navedene činjenice je potrebno razmotriti i donijeti odluku koja će sve zadovoljiti, pri čemu se ipak najviše mora voditi računa o rezervi snage kako bi potrošači imali stabilno i sigurno napajanje.

Nakon određivanja veličine i tipa transformatorske stanice potrebno je odrediti i njenu lokaciju. Prirodno je da transformatorska stanica bude smještena u prostornom centru potrošnje jer prevelika dislociranost znači duže niskonaponske izvode, a samim time i veće padove napona kod krajnjih potrošača, što se ne smije dozvoliti.

Za određivanje lokacije transformatorske stanice kao vrlo prigodan se pokazuje algoritam neizrazitog grupiranja (*eng. fuzzy clustering*). Korištenjem *Matlab Fuzzy Toolbox–a* i promatranjem svih potrošača kao jedne jedinstvene skupine, specijaliziranim algoritmom se dobivaju zemljopisne koordinate centra potrošnje. Pokretanjem dijela programskog koda

```
%Ucitavanje podataka
      load Kuzici.dat

%Pronalazenje centra konzuma
      findcluster
      pause;
```

dobiva se dijaloški okvir (Slika 4.4) pomoću kojeg se dobivaju koordinate prostornog centra konzuma, odnosno lokacije transformatorske stanice, koje se snimaju u novu *.dat* datoteku radi daljnje uporabe.

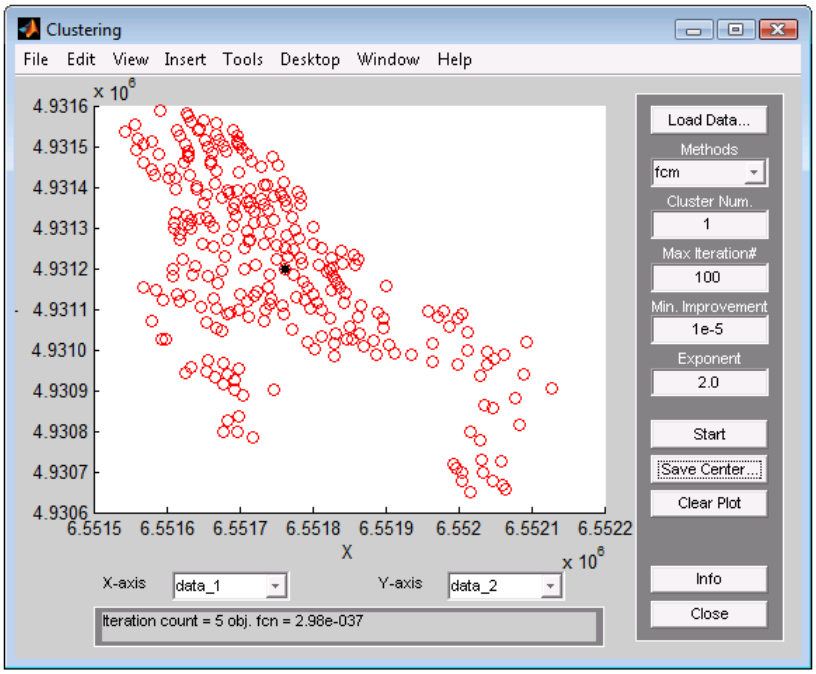

Slika 4.4. *Dijaloški okvir za pronalaženje centra konzuma*

Transformatorska stanica treba biti smještena u centru konzuma. U ovisnosti o koncentraciji drugih građevinskih objekata je moguće njeno blago prostorno pomicanje, koje ne bi trebalo biti preveliko. Prihvatljivo je blago pomicanje u koncentričnom krugu oko centra potrošnje. Tako se znatno ne mijenja topologija buduće mreže kao ni rezultati proračuna bitnih za odabir konačnog rješenja. Jedan primjer je prikazan na slici 4.5.

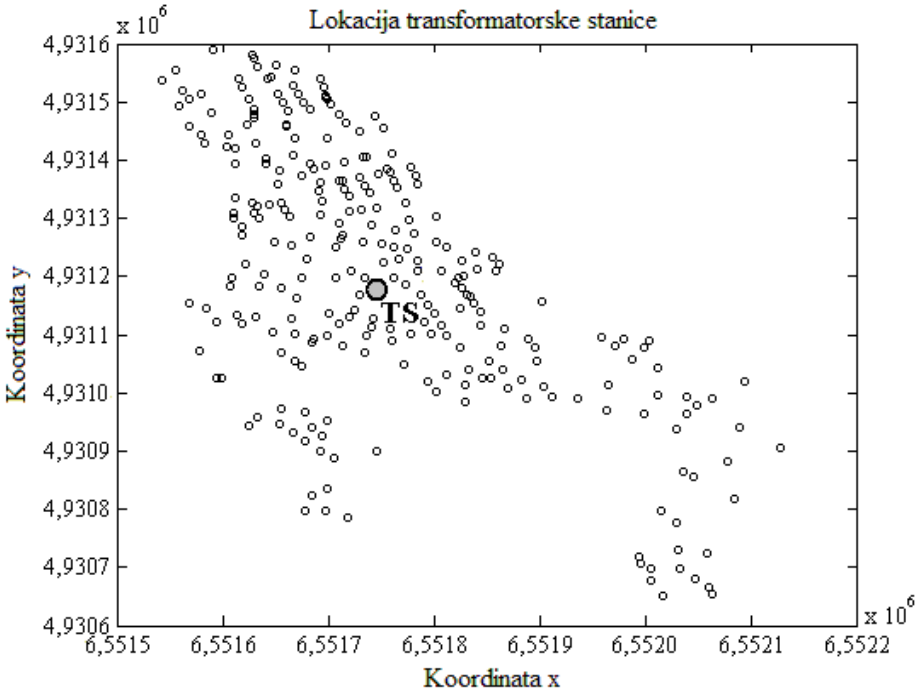

Slika 4.5. *Lokacija transformatorske stanice – prostorni centar konzuma*

Nakon što se odredi veličina i lokacija transformatorske stanice, uporabom istog algoritma moguće je izvršiti prostorno grupiranje potrošača u određeni broj skupina:

```
%Pronalazenje clustera
      n=input('Unesi broj clustera:');
      figure
      [center,U]=fcm(Kuzici,n);
      maxU=max(U);
      l=0;
      for i=1:n
            indexi=find(U(i,:)==maxU);
            [X]=Kuzici(indexi,1);
            [Y]=Kuzici(indexi,2);
            Clusteri=[X Y];
            A=['Cluster',num2str(i),'.dat'];
            save(A,'Clusteri','-ascii','-tabs');
            l=l+1;
      end
```

Broj dobivenih skupina praktički definira broj niskonaponskih izvoda transformatorske stanice. Na isti način, ukoliko je to potrebno, moguće je unutar jedne skupine definirati i podskupine:

```
%Pronalazenje podclustera
      k=input('Unesi broj podclustera:');
      for m=1:l
            A=['Cluster',num2str(m),'.dat'];
            load (A,'-ascii')
            B=['Centar',num2str(m),'.dat'];
            load (B,'-ascii')
            D=Cluster(m)
            [center,U]=fcm(D,k);
            maxU=max(U);
            figure
            for i=1:k
                  indexi=find(U(i,:)==maxU);
                  [X]=D(indexi,1);
                  [Y]=D(indexi,2);
                  Podclusteri=[X Y];
                  C=['Podcluster',num2str(i),'.dat'];
                  save(C,'Podlusteri','-ascii','-tabs');
            end
      end
```

Definiranjem skupina moguće je definirati i njihove prostorne centre. Unutar jedne skupine mogu se definirati i prostorni centri podskupina. Sve ovo služi kao orijentacija u kom smjeru je potrebno vršiti izgradnju mreže, odnosno koje tipove vodiča je potrebno odabrati. Na slici 4.6 je prikazan primjer razdiobe jedne skupine na podskupine sa danim prostornim centrima, kako same skupine tako i definiranih podskupina unutar nje. U biti, u ovom modelu, skupina definira jedan niskonaponski izvod kojeg je potrebno izgraditi iz transformatorske stanice do krajnjih potrošača, a podskupine su bliži orijentiri za izgradnju mreže.

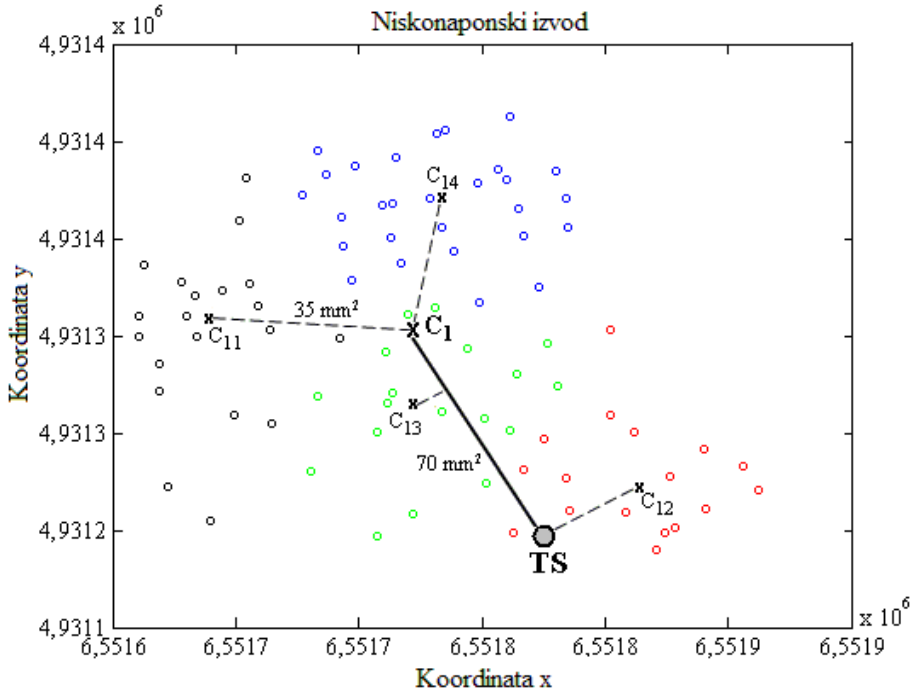

Slika 4.6. *Niskonaponski izvod sa podskupinama potrošača*

Ponovi li se postupak za odabrani broj niskonaponskih izvoda, u konačnici se dobiva prostorno locirana transformatorska stanica, u centru konzuma, te prostorno grupirane skupine potrošača koje određuju broj niskonaponskih izvoda i smjernice prostornog rasprostiranja mreže, kao što je to prikazano na slici 4.7.

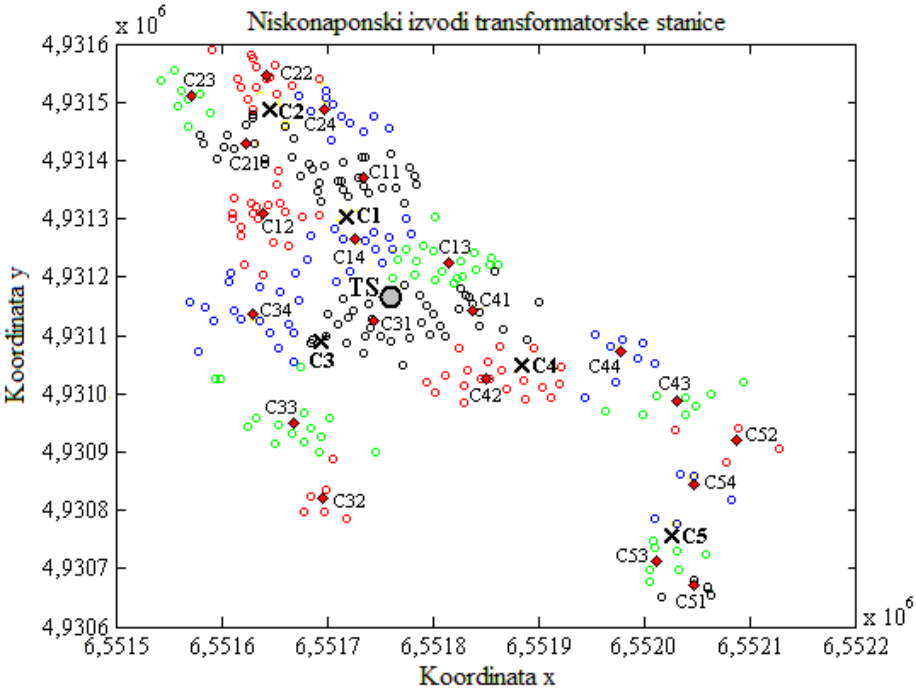

Slika 4.7. *Prostorni raspored skupina i podskupina potrošača i njihovih centara i podcentara*

Primjenom algoritma neizrazitog grupiranja može se predložiti niz rješenja jer čak ni najiskusniji inženjeri ne mogu precizno i točno odrediti topološki izgled niskonaponske distribucijske mreže, niti broj niskonaponskih izvoda kojima je potrebno električnu energiju dovesti do krajnjih potrošača.

Dakle, ovim algoritmom može se dati niz rješenja od kojih je potrebno odabrati najbolje. Ova rješenja u daljnjem tumačenju modela će se nazivati *alternative* ili *varijante*.

Alternative ili varijante u stvari predstavljaju niskonaponske mreže transformatorske stanice sa dva, tri ili više niskonaponskih izvoda. Određene su brojem skupina potrošača koje se dobivaju algoritmom neizrazitog grupiranja.

U biti, može se napraviti onoliko alternativa koliko inženjer–planer smatra da treba, ali tu postoji ograničenje koje je povezano sa veličinom i tipom transformatorske stanice. Naime, stupne transformatorske stanice su manjih snaga i u pravilu se grade sa manjim brojem niskonaponskih izvoda (obično do četiri). Stoga se kod ovakvih transformatorskih stanica obično prave alternative sa jednim, dva, tri ili četiri izvoda. Kod transformatorskih stanica većih snaga, sa većim brojem niskonaponskih izvoda obično se prave alternative sa pet, šest, sedam i više niskonaponskih izvoda.

Iskusan inženjer samim pogledom na prostorni raspored potrošača može približno odrediti broj potrebnih niskonaponskih izvoda, ali to ne mora uvijek biti dobra procjena jer za odabir najboljeg rješenja nije dovoljna samo dobra prostorna razdioba. Algoritam neizrazitog grupiranja će dati dobru prostornu razdiobu, ali ona ne znači i najbolje rješenje jer se u obzir mora uzeti i niz drugih faktora kako bi se dobilo najbolje rješenje. Dobro prostorno rješenje ne znači i optimalno, pogotovo kada su u pitanju energetski pokazatelji, prije svih padovi napona kod krajnjih potrošača i gubici radne snage u niskonaponskim vodovima.

U ovome koraku je potrebno samo odabrati određeni broj alternativa, a pitanje najboljih će se rješavati u narednim koracima. Bez obzira koliki se broj alternativa odabere, temeljni cilj cijelog modela je odabrati najbolju, a zatim odrediti njenu optimalnu topologiju, odnosno optimalno uklopno stanje niskonaponske distribucijske mreže.

4.3.3. Formiranje mrežne topologije

Određivanjem lokacije transformatorske stanice i grupiranjem potrošača stvaraju se uvjeti za formiranje topologije niskonaponske distribucijske mreže. Vodeći računa o prostornom rasporedu objekata, putova i sl. temeljem dobivenih podataka algoritmom neizrazitog grupiranja, iskusan inženjer je u mogućnosti da na georeferenciranim kartama iscrta distribucijsku mrežu. U ovome koraku inženjersko iskustvo je od iznimno važnog značaja jer se pravilnim crtanjem mreže dobivaju vrlo važni podaci za daljnji tijek procesa planiranja. Što su ovi podaci točniji, konačno rješenje je preciznije. Jedan od najpogodnijih softverskih paketa za iscrtavanje mreže je AutoCAD. Primjer jedne iscrtane mreže je prikazan na slici 4.8.

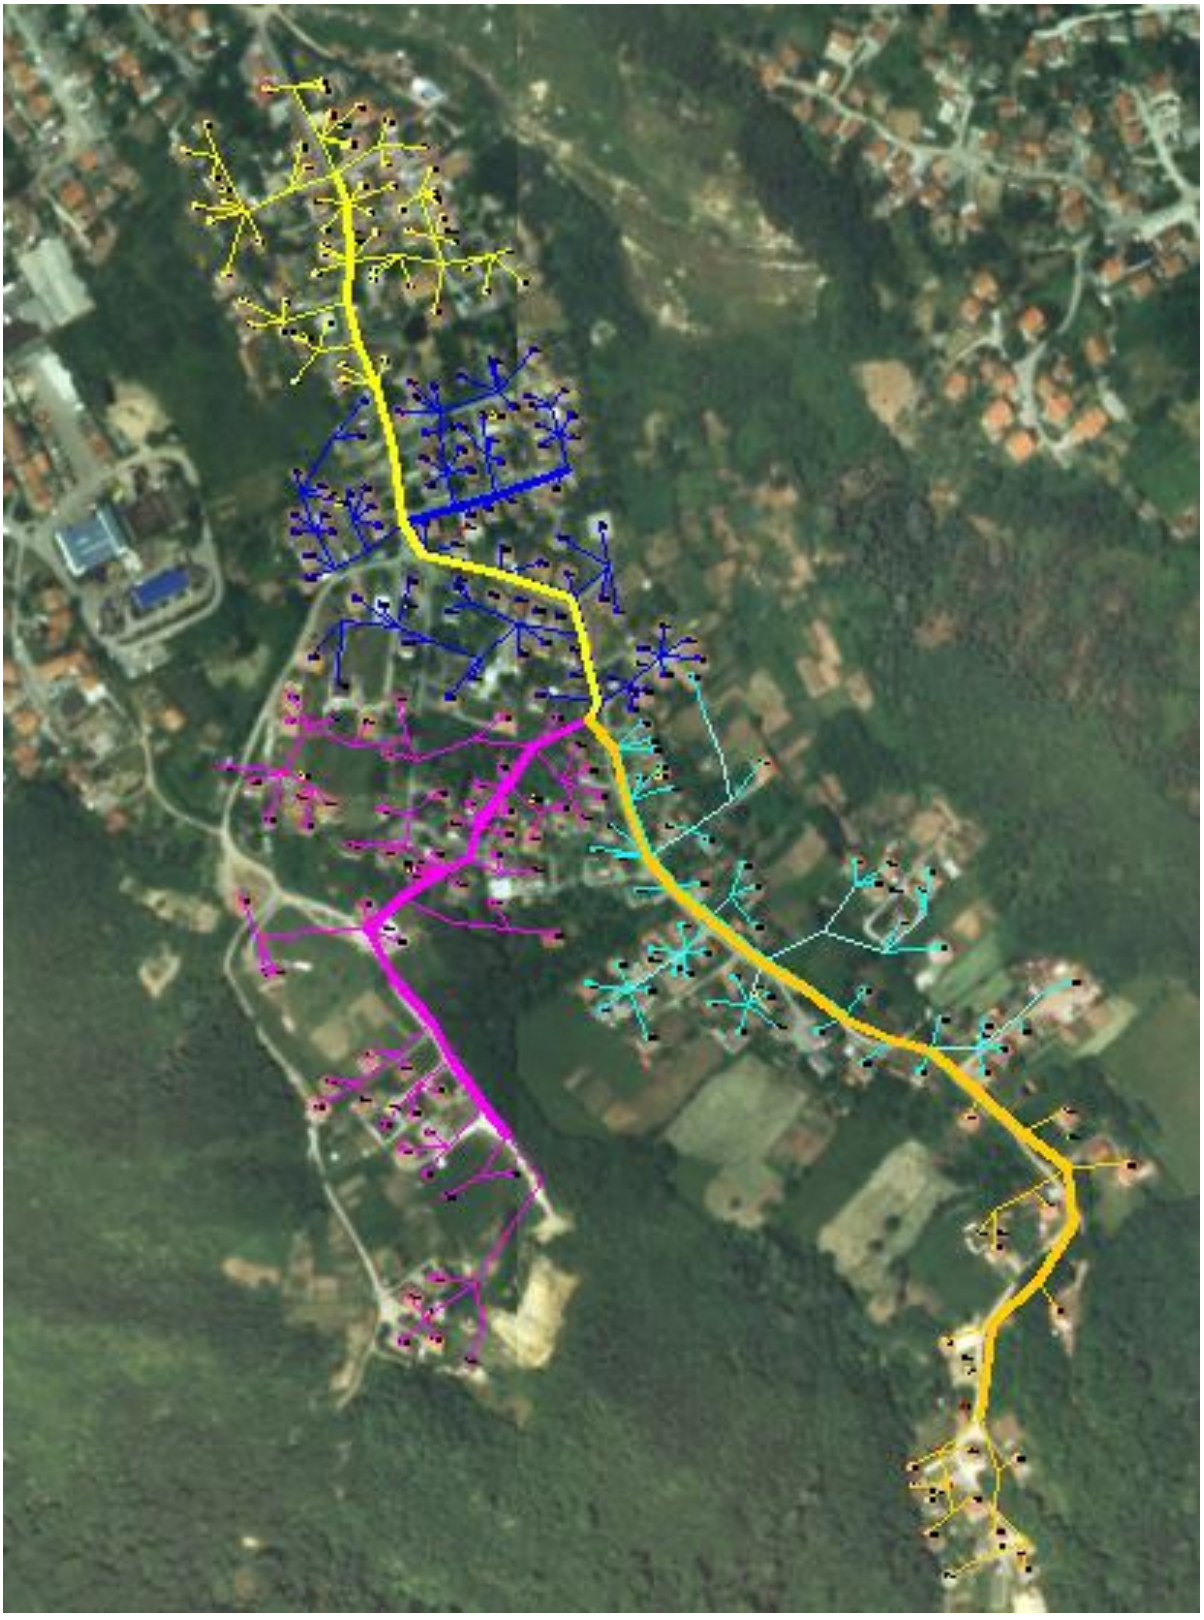

Slika 4.8. *Primjer niskonaponske distribucijske mreže*

4.3.4. Proračuni – formiranje kriterija

Iscrtavanjem niskonaponskih mreža dobiva se topološki izgled svih alternativa. Temeljem toga se, međutim, ne može donijeti odluka koja od ponuđenih alternativa je najbolja za dano područje. Kako bi se mogla donijeti kvantitativna ocjena ponuđenih rješenja nužno je uspostaviti određene kriterije temeljem kojih će se izvršiti vrednovanje ponuđenih alternativa. Zato je potrebno izvršiti određene proračune koji će ponuditi kriterije za ocjenu alternativa. Crtanjem niskonaponske distribucijske mreže na georeferenciranim kartama se osim topologije mreže dobivaju i podaci o karakteristikama i dužinama niskonaponskih vodova.

Temeljni proračun koji se primjenjuje kod svih elektroenergetskih mreža je *proračun tokova snaga*. Ulazni podaci za ovaj proračun su: opterećenje potrošača koje se dobiva ranije prezentiranim proračunom, parametri transformatorske stanice, te parametri niskonaponskih vodova R i X (Slike 4.9 i 4.10).

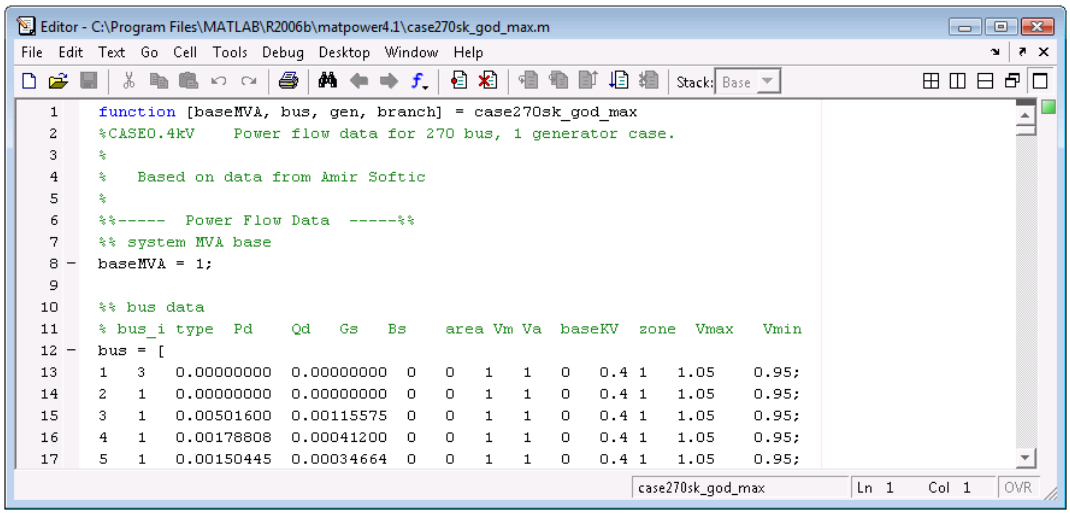

Slika 4.9. *Podaci o opterećenju sabirnica za proračun tokova snaga*

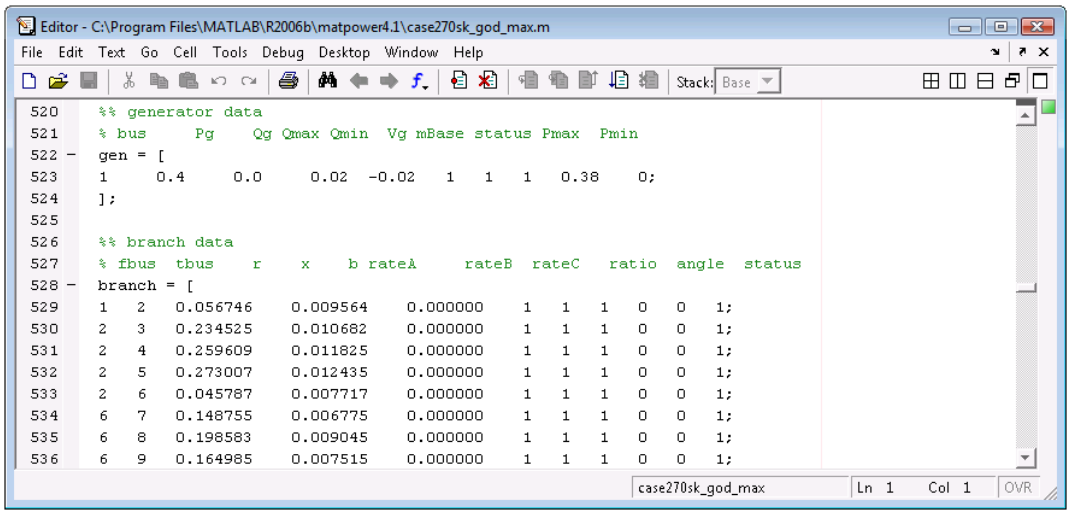

Slika 4.10. *Podaci o transformatorskoj stanici i vodovima za proračun tokova snaga*

Ovim proračunom dobivaju se podaci o padovima napona i gubicima snage u svakome dijelu distribucijske mreže. Ovaj proračun može se provesti primjenom bilo kojeg softverskog paketa za proračun tokova snaga, kao što su Matpower, PowerCAD i sl. Rezultati jednog takvog proračuna su prikazani na slici 4.11.

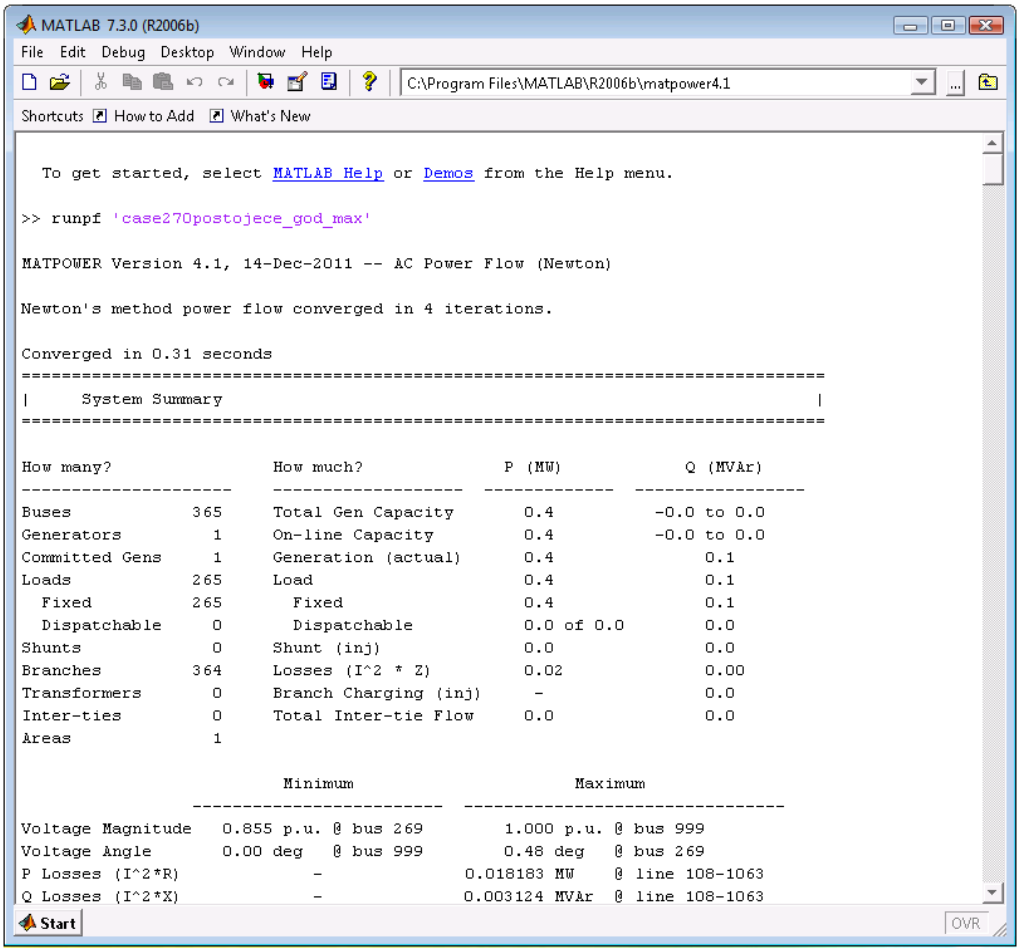

Slika 4.11. *Rezultati proračuna tokova snaga u Matlab-u (Matpower)*

Dakle, proračunom tokova snaga dobivaju se prva dva kriterija temeljem kojih će se vrednovati alternative, a to su:

- Padovi napona kod krajnjih potrošača;
- Gubici snage u niskonaponskim vodovima.

Padovi napona su vrlo važni gledano iz kuta potrošača jer svaki kupac želi imati stabilne naponske prilike, dok su gubici snage značajni za distribucijske tvrtke jer o njima ovisi i njihova dobit. Pravilnim odabirom trasa vodova i presjeka vodiča prilikom crtanja niskonaponske distribucijske mreže padovi napona i gubici se mogu svesti na što nižu razinu.

Ova dva kriterija bi trebala biti najvažniji kriteriji za ocjenu ponuđenih rješenja i u svakom slučaju bi trebali biti uključeni u model planiranja jer su na određeni način glavni pokazatelji interesa potrošača s jedne strane i interesa distribucijske tvrtke s druge strane.

Broj kriterija, kao ni broj alternativa nije precizno definiran. Što više, veći broj kriterija znači kvalitetniji i pouzdaniji odabir alternative. Zato, za dobivanje najbolje ocjene ponuđenih rješenja nije dovoljno poznavati samo padove napona i gubitke snage u niskonaponskoj distribucijskoj mreži. Ovi podaci mogu poslužiti kao određeni kriteriji temeljem kojih će se donositi odluka, ali nisu dovoljni. Kako bi odluka bila što preciznija i kvalitetnija potrebno je uvesti i neke druge kriterije koji isključivo ovise o interesima distribucijske tvrtke, potrošača električne energije ili osobne procjene inženjera. Neki od njih su investicijski troškovi, troškovi održavanja, pouzdanost i sigurnost isporuke, isplativost investicije, opterećenost vodova i sl.

4.3.5. Rangiranje kriterija i alternativa

Za donošenje konačne odluke, odnosno odabir najpovoljnijeg rješenja, potrebno je usuglasiti sve kriterije i izvršiti rangiranje svih ponuđenih rješenja. Kao vrlo prigodan alat za takav proračun je AHP metoda (*eng. Analytic Hierarchy Process*). Ova metoda se u biti temelji na odabiru najboljeg rješenja (alternative, varijante) vrednovanjem svakog rješenja sa određenim zadanim kriterijima.

Cjelokupan postupak proračuna se provodi u Microsoft Excel-u i za njega nije potrebno imati posebna softverska rješenja. Potrebno je samo dosljedno provesti postupak opisan u poglavlju 3.2.2.

Prvi korak za primjenu ove metode je formiranje određenog broja alternativa od kojih treba odabrati najbolju. To se kod predloženog modela postiže u koraku neizrazitog grupiranja kada se mogu formirati varijante niskonaponske mreže sa pet, šest, sedam ili više niskonaponskih izvoda. U koraku crtanja topologije mreže potrebno je iscrtati sve ove mreže, te se na taj način dobiva potreban broj varijanti niskonaponske distribucijske mreže od kojih je potrebno odabrati najbolju.

U drugom koraku je potrebno formirati kriterije temeljem kojih će se izvršiti rangiranje alternativa. Što se tiče niskonaponskih distribucijskih mreža ti kriteriji mogu biti, na primjer:

- Padovi napona kod krajnjih potrošača;
- Gubici snage u vodovima;
- Opterećenje vodova;
- Investicijski troškovi itd.

Svi kriteriji, međutim, nemaju podjednak utjecaj na donošenje konačne odluke. Neki imaju znatno veći utjecaj, dok drugi i nisu toliko značajni kada se radi o donošenju konačne odluke. Zbog toga je potrebno prvo izvršiti tzv. međusobno rangiranje, odnosno međusobnu usporedbu kriterija. Na taj način će svaki kriterij imati različit utjecaj na donošenje konačne ocjene svake alternative.

Na primjer, padovi napona kod krajnjih kupaca bi trebali imati najveći utjecaj na donošenje odluke, gubici snage u vodovima nešto manji, dok investicijski troškovi i opterećenje vodova bi trebali imati najmanji utjecaj na odluku. Pri rangiranju kriterija mora se voditi računa i o

interesima potrošača kao i o interesima tvrtke. Ove interese inženjer–planer mora imati na umu kada vrši rangiranje kriterija.

Svakom kriteriju se daje ocjena prema Saatyjevoj skali danoj u poglavlju 3.2.2 (Tablica 3.1) kako bi se mogla izvršiti međusobna usporedba kriterija. Pretpostavimo da od četiri predočena kriterija padovi napona imaju najveću važnost, gubici snage nešto manju, opterećenje vodova još manju, a investicijski troškovi najmanju važnost. Temeljem ovog dobiva se inicijalna tablica usporedbe parova kriterija (Tablica 4.1).

Tablica 4.1. *Tablica usporedbe kriterija po parovima*

Kriterij	Pad napona	Gubici snage	Opterećenje vodova	Investicijski troškovi
Pad napona	1	2	6	7
Gubici snage	1/2	1	5	6
Opterećenje vodova	1/6	1/5	1	2
Investicijski troškovi	1/7	1/6	1/2	1

Dosljednim provođenjem postupka u konačnici se dobivaju vrijednosti kao u tablici 4.2.

Tablica 4.2. *Vrijednosti prioriteta i težinskog vektora nakon provođenja AHP metode*

Kriterij	Pad napona	Gubici snage	Opterećenje vodova	Investicijski troškovi	Prioritet	Težinski vektor
Pad napona	0,55263	0,59406	0,48000	0,43750	0,51894	0,51605
Gubici snage	0,27632	0,29703	0,40000	0,37500	0,33734	0,33709
Opterećenje vodova	0,09211	0,05941	0,08000	0,12500	0,08710	0,08913
Investicijski troškovi	0,07895	0,04950	0,04000	0,06250	0,05662	0,05774

Dobivene vrijednosti prioriteta se koriste za kasnije rangiranje alternativa, dok se vrijednosti težinskog vektora koriste za provjeru rezultata dobivenih rangiranjem kriterija. Naime, nakon izvršenog rangiranja kriterija potrebno je utvrditi da li je to izvršeno na adekvatan način, obzirom da je to subjektivno pitanje inženjerske procjene. Prema AHP metodu potrebno je utvrditi konzistentnost i ukoliko su rezultati konzistentni (dosljedni) onda je rangiranje izvršeno korektno, a ukoliko nisu onda je potrebno izvršiti ponovno rangiranje. Takav postupak se ponavlja dok se ne dobije zadovoljavajuće (konzistentno) rješenje.

Postupak se provodi na način da se inicijalna matrica usporedbe kriterija po parovima množi sa vrijednostima težinskog vektora, a zatim se te dobivene vrijednosti dijele sa vrijednostima težinskih vektora, što daje vrijednosti:

$$\begin{bmatrix} 4{,}12589 \\ 4{,}11520 \\ 4{,}01703 \\ 4{,}02168 \end{bmatrix}$$

Temeljem ovih vrijednosti se dobiva njihova prosječna vrijednost:

$$\lambda_{max} = \frac{4{,}12589 + 4{,}11520 + 4{,}01703 + 4{,}02168}{4} = 4{,}06995$$

Temeljem ovog *indeks konzistencije* iznosi:

$$CI = \frac{\lambda_{max} - n}{n - 1} = \frac{4{,}06995 - 4}{4 - 1} = 0{,}02332$$

Iz tablice 3.2, za n = 4 je RI = 0,90. Tada je *stupanj konzistentnosti*:

$$CR = \frac{CI}{RI} = \frac{0{,}02959}{0{,}9} = 0{,}02591$$

Obzirom da je CR = 0,02591 < 0,1 procjene kriterija su *konzistentne (dobre)*.

Nakon što se izvrši pravilno rangiranje zadanih kriterija potrebno je izvršiti rangiranje alternativa (varijanti). Postupak je isti kao i kod rangiranja kriterija osim što se vrši za svaki kriterij zasebno. Na ovaj način se dobiva ocjena koliko koji kriterij utječe na svaku alternativu zasebno. Zbrajanjem ovih ocjena dobivaju se ocjene prioriteta svake alternative. *Alternativa sa najvećom ocjenom se smatra najboljom*. Na ovaj način se dobiva najbolje prostorno topološko rješenje niskonaponske distribucijske mreže.

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22965 \\ 0{,}24758 \\ 0{,}25210 \\ 0{,}27067 \end{bmatrix}$$

Cjelokupna procedura i proračun koji se sprovodi primjenom AHP metode opisana je u poglavlju 3.2.2.

4.3.6. Optimalno rješenje

Prethodnim koracima modela dobiva se najbolje prostorno topološko rješenje niskonaponske distribucijske mreže. Međutim, obzirom da izgled topološkog rješenja ovisi isključivo o subjektivnoj inženjerskoj procjeni ne može se reći da je jedno takvo rješenje u stvari optimalno. Iako bi se moglo reći da ovo rješenje predstavlja dobar prostorni izgled mreže, koji je najbliži optimalnom, ne može se reći da to sigurno i je optimalno rješenje. S druge strane, to isto važi i za energetske parametre (padovi napona, gubici). Zbog toga je za najbolju prostornu varijantu potrebno odrediti i optimalno uklopno stanje koje će dati optimalnu konfiguraciju niskonaponske distribucijske mreže, što je u biti i konačni cilj planiranja prema danom modelu.

Za rješenje ovoga problema kao jedan od najpogodnijih pokazuje se algoritam simuliranog kaljenja (*eng. simulated annealing*).

Za dobivanje optimalnog uklopnog stanja mreže ovim algoritmom potrebno je uspostaviti niz međuveza između potrošača unutar jednog niskonaponskog izvoda i/ili potrošača između više niskonaponskih izvoda. Na ovaj način se unutar mreže stvaraju zatvorene petlje, što nije dozvoljeno, ali će one programskim rješenjem biti "razbijene" tako da će se u konačnici dobiti optimalna konfiguracija niskonaponske mreže koja će biti radijalnog karaktera. Primjena ovog algoritma daje zasigurno najbolju prostornu topologiju mreže uz minimalne gubitke snage i padove napona na krajevima niskonaponskih izvoda.

Algoritam se može predočiti u nekoliko koraka kako slijedi.

- Učitavanje podataka polaznog stanja;

```
%% Read data
baseMVA=pr_baseMVA;
bus=pr_bus;
gen=pr_gen;
branch=pr_branch;
   if isim>1
         if korak>0
               for ii=1:korak
                     branch(uklj(ii),11)=1;
                     branch(isklj(ii),11)=0;
               end
         end
         n_branch=size(branch,1);
         n_bus=size(bus,1);
   end
```

- Određivanje polazne temperature kaljenja (T = 1000);

```
%% Polazna temperatura kaljenja
T=1000;
```

- Određivanje funkcije cilja;

```
function[gubici,uklj,isklj,cv_uklj,cv_isklj,isim,branch,broj_pokusaja,
vrijeme]=Softic(casename,n_prek,n_uklj)
```

- Formiranje matrice za pronalaženje puta;

```
%% Formiranje matrice za pronalazenje puta
matrica_put=zeros(n_bus);
   for ii=1:n_bus
         for jj=1:n_bus
               matrica_put(ii,jj)=inf;
         end
   end
   for ii=1:n_bus
         matrica_put(ii,ii)=0;
   end
```

```
    for kk=1:n_branch
        if branch(kk,11)==1
            matrica_put(branch(kk,1),branch(kk,2))=1;
            matrica_put(branch(kk,2),branch(kk,1))=1;
        end
    end
```

- Pronalaženje grane (prekidača) koja će se uključiti između dva čvora (zatvaranje petlje);

```
%% Pronalazenje grane koja ce se ukljuciti: grana1 izmedju cvor1 i cvor2
nadji=ceil((n_prek-n_uklj)*rand);
brojacp=0;
nasao=0;
    for ii=(n_branch - n_prek + 1):n_branch
        if branch(ii,11)==0
            brojacp=brojacp+1;
            if brojacp==nadji
                nasao=1;
                cvor1=branch(ii,1);
                cvor2=branch(ii,2);
                grana1=ii;
            end
        end
    end
```

- Pronalaženje puta i broja prekidača između zadanih čvorova preko uključenih grana;

```
%% Pronalazenje puta izmedju cvor1 i cvor2 preko ukljucenih grana
[sp, spcost] = dijkstra(matrica_put, cvor1, cvor2);

% Broj prekidaca u nadjenom putu
brojac=0;
put=size(sp,2)-1;
    for ii=(n_branch-n_prek+1):n_branch
        if branch(ii,11)==1
            for jj=1:put
                if(branch(ii,1)==sp(jj)) && (branch(ii,2)==sp(jj+1))
                    brojac=brojac+1;
                end
                if(branch(ii,1)==sp(jj+1)) && (branch(ii,2)==sp(jj))
                    brojac=brojac+1;
                end
            end
        end
    end
```

- Pronalaženje grane (prekidača) u nađenom putu koja će se isključiti (razbijanje petlje);

```
%% Pronalazenje grane koja ce se iskljuciti: grana2 izmedju cvor3 i cvor4
nadji=ceil(brojac*rand);
brojac=0;
    for ii=(n_branch-n_prek+1):n_branch
```

```
        if branch(ii,11)==1
              for jj=1:put
                    if(branch(ii,1)==sp(jj)) && (branch(ii,2)==sp(jj+1))
                          brojac=brojac+1;
                          if brojac==nadji
                                cvor3=branch(ii,1);
                                cvor4=branch(ii,2);
                                grana2=ii;
                          end
                    end
                    if(branch(ii,1)==sp(jj+1)) && (branch(ii,2)==sp(jj))
                          brojac=brojac+1;
                          if brojac==nadji
                                cvor3=branch(ii,1);
                                cvor4=branch(ii,2);
                                grana2=ii;
                          end
                    end
              end
        end
  end
```

- Proračun tokova snaga formirane konfiguracije (određivanje gubitaka i padova napona);

```
  %% Proracun tokova snaga
  [MVAbase, bus, gen, branch, success, et]=runpf(baseMVA, bus, gen, branch);
    if success==1
          uspj_korak=uspj_korak+1;
          gubici(uspj_korak)=sum(abs(branch(:,12)+branch(:,14)));
          if uspj_korak>1
                pokusaj=pokusaj+1;
                razlika=gubici(uspj_korak)-gubici(uspj_korak-1);
                if razlika>0
                      prihvatanje=exp(-razlika/T);
                      granica_prihv=rand;
                      if prihvatanje<granica_prihv
                            korak=korak-1;
                            uspj_korak=uspj_korak-1;
                      else
                            broj_pokusaja(uspj_korak-1)=pokusaj;
                            vrijeme(uspj_korak-1)=etime(clock,t0);
                            pokusaj=0;
                      end
                else
                      broj_pokusaja(uspj_korak-1)=pokusaj;
                      vrijeme(uspj_korak-1)=etime(clock,t0);
                      pokusaj=0;
                end
          end
    else
          korak=korak-1;
    end
```

- Primjena postupka hlađenja ($T_{novo} = 0{,}95 \times T_{staro}$);
- Formiranje nove konfiguracije;
- Zaustavljanje postupka nakon dostignute funkcije cilja i odgovarajuće zadane temperature ($T < 10^{-6}$);

```
if T<1.e-06
   break
end
```

Ovim algoritmom u konačnici se dobiva radijalna konfiguracija niskonaponske distribucijske mreže koja daje najmanje iznose gubitaka u mreži, odnosno najmanje padove napona na niskonaponskim izvodima. U biti, to predstavlja optimalnu konfiguraciju mreže. Primjenom ovog algoritma, optimalna konfiguracija mreže sa slike 4.8 bi izgledala kao na slici 4.12.

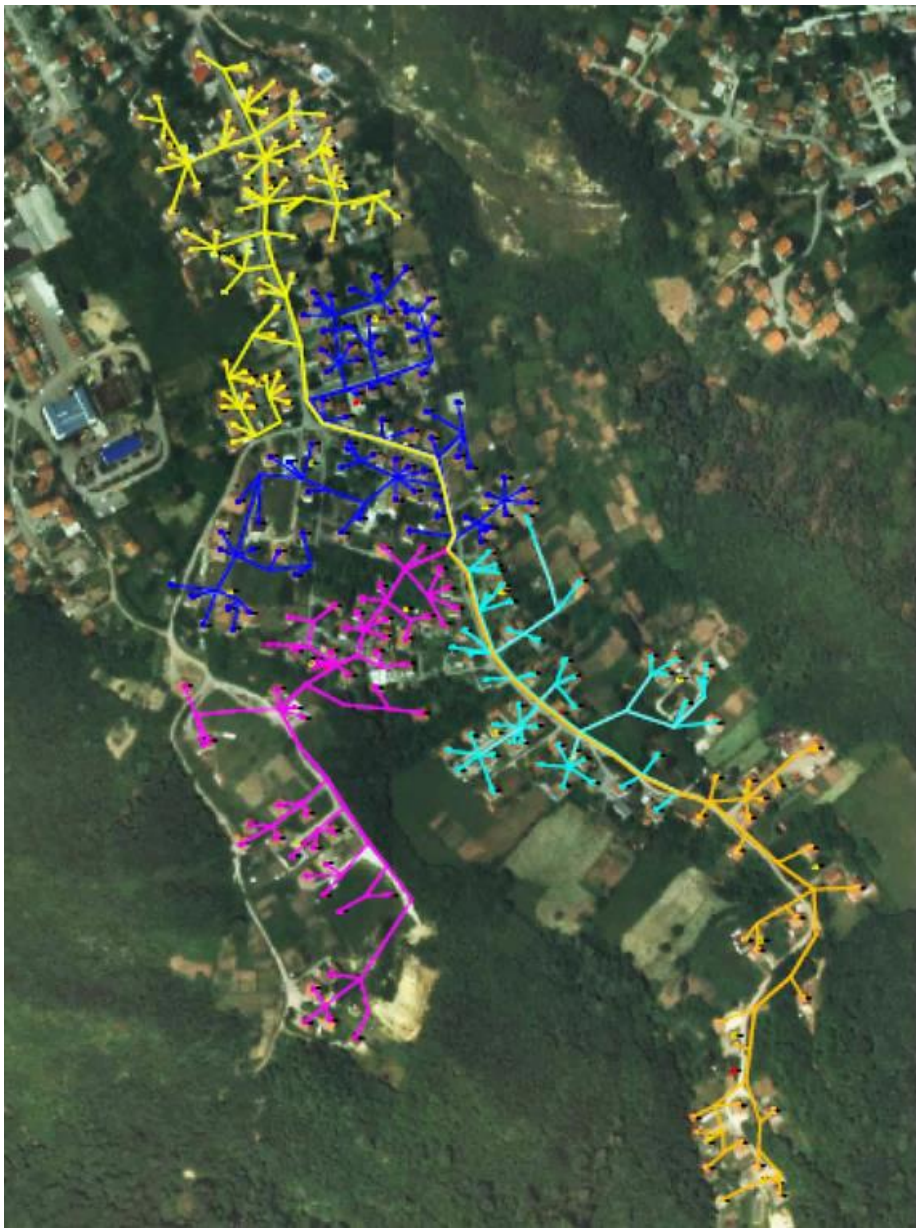

Slika 4.12. *Optimalno uklopno stanje niskonaponske distribucijske mreže*

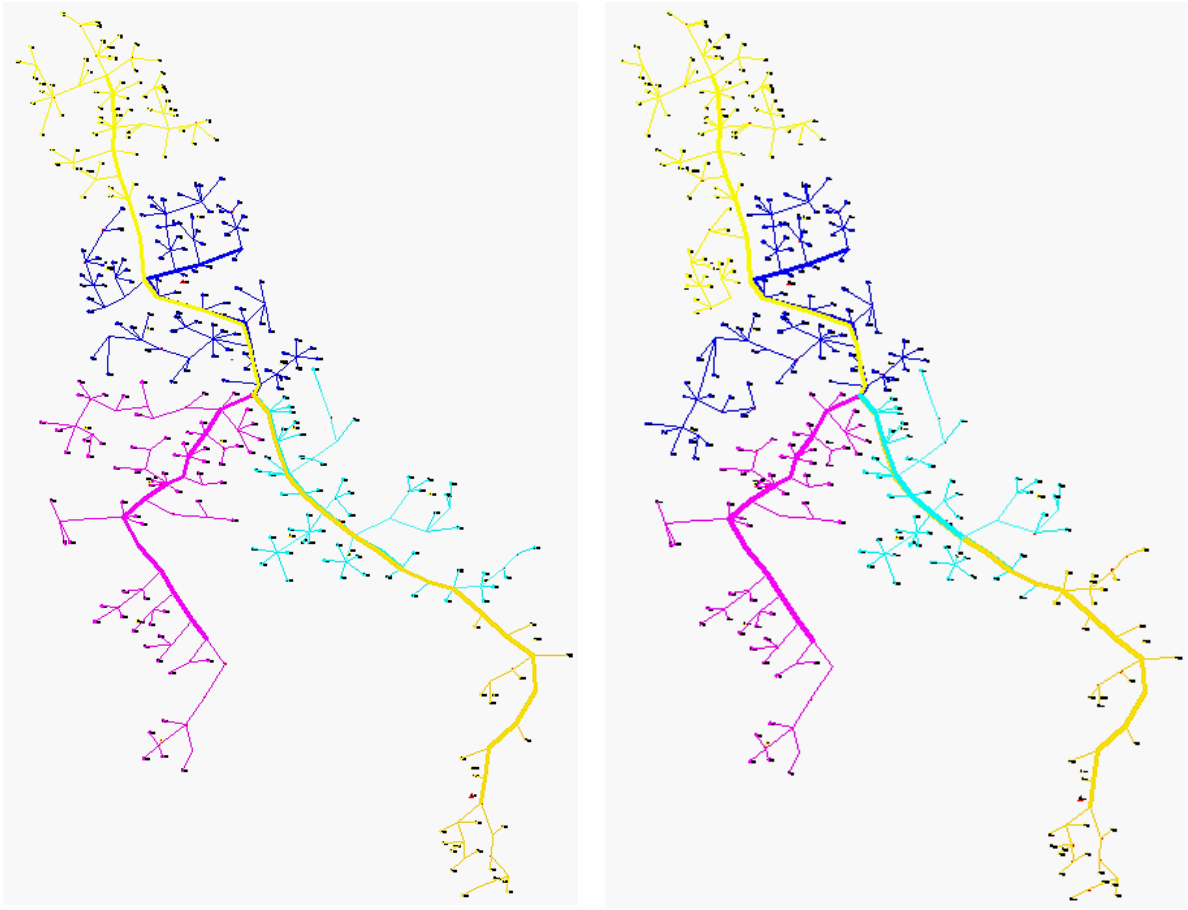

a) b)

Slika 4.13. *Usporedni prikaz najboljeg prostornog (a) i optimalnog (b) rješenja niskonaponske distribucijske mreže*

Usporedni prikaz najboljeg prostornog i optimalnog rješenja niskonaponske distribucijske mreže je dan na slici 4.13. Vidljivo je da se optimalno rješenje razlikuje od prostornog obzirom da dolazi do preraspodjele određenih potrošača po niskonaponskim izvodima, odnosno mijenja se njihova pripadnost niskonaponskom izvodu. Svrha primjene optimizacijskog algoritma nije samo preraspodjela potrošača između izvoda nego je to i preraspodjela unutar jednog izvoda. To isključivo ovisi o uspostavljenim međuvezama. Zbog toga je poželjno uspostaviti međuveze unutar jednog izvoda kao i između izvoda međusobno što će polučiti najbolje rješenje.

5. PRAKTIČNI PRIMJER PRIMJENE MODELA PLANIRANJA

Predloženi model planiranja prikazan u prethodnom poglavlju je primijenjen na praktičnom primjeru jedne realne niskonaponske distribucijske mreže. U ovom poglavlju će biti predočeni dobiveni rezultati koji će dati potvrdu funkcionalnosti ovakvog pristupa pri planiranju, projektiranju i izgradnji elektroenergetskih distribucijskih mreža.

Dakle, funkcionalnost predloženog modela je provjerena na primjeru realne niskonaponske distribucijske mreže preko koje je napojeno 270 kupaca električne energije, uglavnom iz kategorije kućanstava. Mreža je napojena iz transformatorske stanice 10(20)/0,4 kV, nazivne snage 400 kVA, preko 5 niskonaponskih izvoda. Prostorni raspored potrošača je prikazan na slici 5.1, a na slici 5.2 izgled postojeće niskonaponske distribucijske mreže.

Slika 5.1. *Prostorni raspored niskonaponskih potrošača*

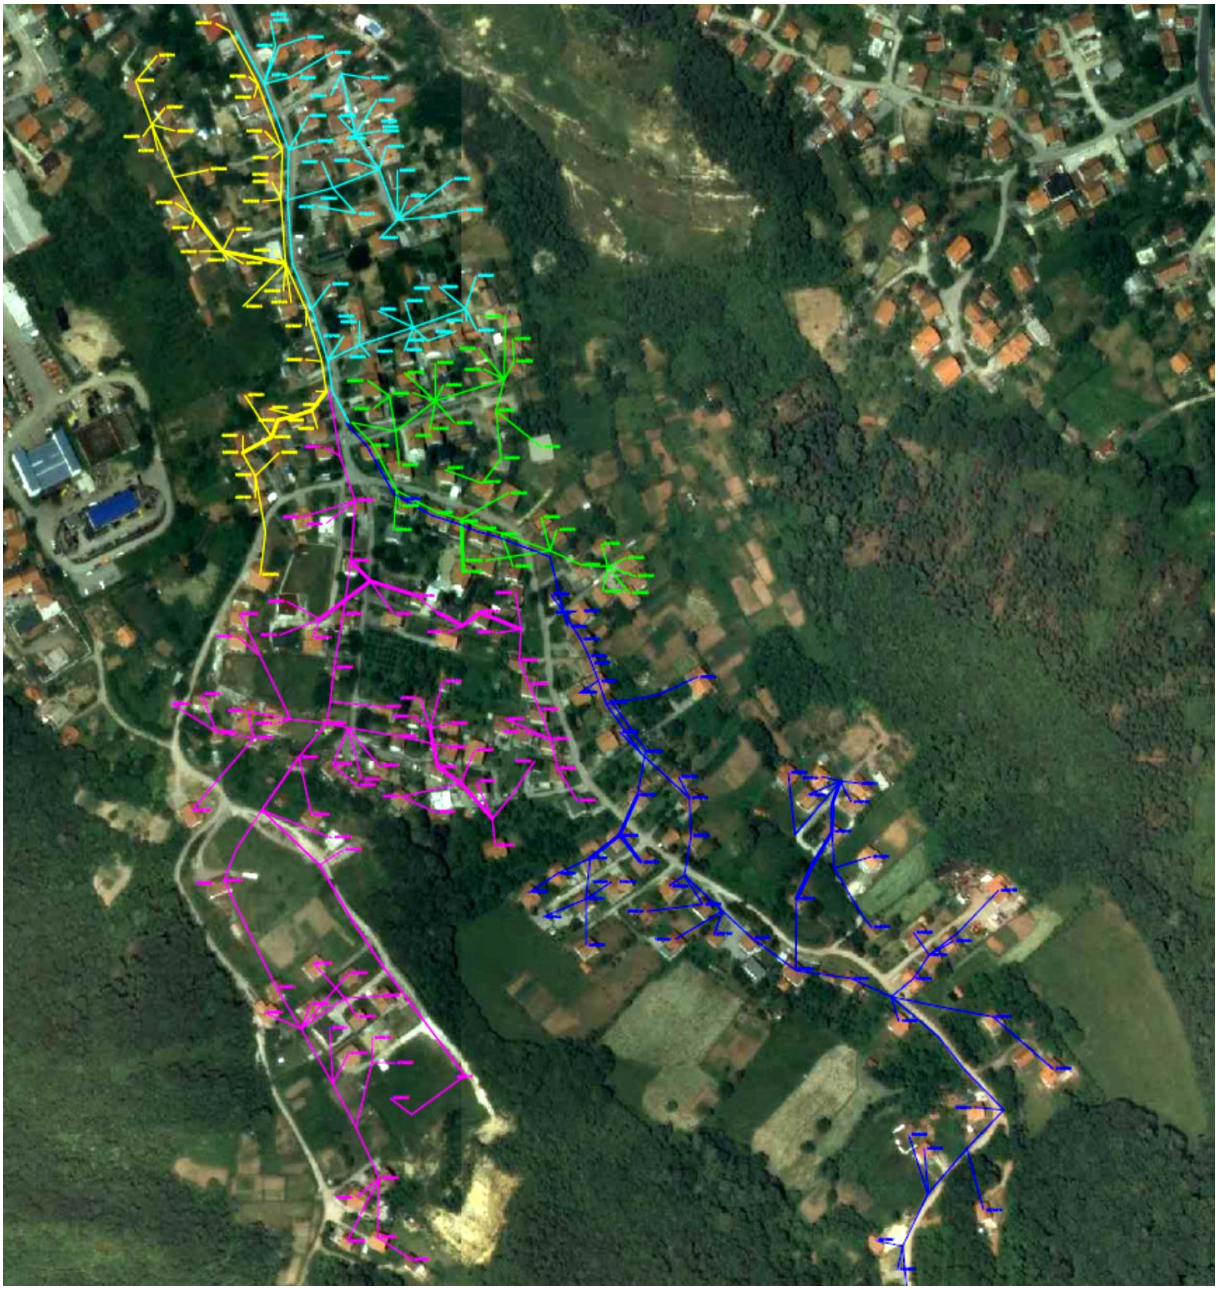

Slika 5.2. *Postojeća niskonaponska distribucijska mreža*

5.1. ULAZNI PODACI

Kako je to već opisano u prethodnom poglavlju kao prvi ulazni podatak za predloženi model koriste se koordinate objekata koje treba opskrbiti električnom energijom, a koje se vrlo jednostavno mogu dobiti sa georeferenciranih zemljopisnih podloga, kako je to prikazano na slici 5.3 za jedan dio razmatranog područja. Koordinate svih mjernih mjesta razmatranog područja dane su u prilogu 1.

Slika 5.3. *Određivanje zemljopisnih koordinata dijela potrošača razmatranog područja*

Drugi ulazni podatak je godišnja utrošena energija svakog potrošača. Ovi podaci su dani u prilogu 2. Osim ovoga, za proračun prosječnog vršnog opterećenja svakog potrošača potrebni su podaci o jednodnevnom, satnom mjerenju opterećenja svakog niskonaponskog izvoda i transformatorske stanice u periodu vršnih opterećenja. Ovi podaci su dani u prilogu 3.

Za proračune tokova snaga potrebno je poznavati i karakteristike vodova kojima su potrošači povezani sa transformatorskom stanicom To se prije svega odnosi na tipove vodova (nadzemni ili podzemni), presjeke vodiča, R i X za različite tipove, kao i dužine vodova. Podaci koji se odnose na karakteristike vodova su dani u tablici 5.1.

Tablica 5.1. *Karakteristike niskonaponskih vodova*

Tip	Naziv	I_{max} (A)	R (Ω/km)	X (Ω/km)
Kabel za podzemnu mrežu	PP00 4×16 mm² - jednožilni (Cu)	110	1,340	0,110
	PP00 4×25 mm² - jednožilni (Cu)	140	0,847	0,107
	PP00 4×35 mm² - jednožilni (Cu)	170	0,615	0,097
	PP00 4×50 mm² - jednožilni (Cu)	200	0,454	0,096
	PP00-A 2×35 mm² - jednožilni (Al)	130	1,032	0,097
	PP00-A 2×50 mm² - jednožilni (Al)	155	0,775	0,096
Nadzemni vod	Al-Fe 2×16 mm²	101	2,108	0,366
	Al-Fe 2×25 mm²	135	1,350	0,345
	Al-Fe 2×35 mm²	170	0,937	0,322
	Al-Fe 4×16 mm²	101	2,108	0,366
	Al-Fe 4×25 mm²	135	1,350	0,345
	Al-Fe 4×35 mm²	170	0,937	0,322
Kabel za nadzemnu mrežu	SKS 2×16 mm²	81	2,140	0,087
	SKS 4×16 mm²	81	2,140	0,087
	SKS 3×35+71,5 mm²	131	0,972	0,083
	SKS 3×70+71,5 mm²	198	0,496	0,077

Obzirom da se dužine vodova mogu odrediti tek kada je poznata konfiguracija niskonaponske mreže ovi podaci se ne mogu pribrojiti ulaznim podacima jer se dobivaju u kasnijem tijeku provedbe modela planiranja.

Karakteristike distribucijskih transformatora dane su u tablici 5.2.

Tablica 5.2. *Karakteristike tipskih SN/NN distribucijskih transformatora*

Tip	S_n (kVA)	P_{ks} (kW)	U_{ks} (%)	P_0 (kW)	I_0 (%)	Grupa spoja
Transformator 10(20)/0,4 kV	50	1,05	4,0	0,19	8,0	Yz5
	100	1,75	4,0	0,32	7,0	Yz5
	160	2,35	4,0	0,46	6,7	Yz5
	250	3,25	4,0	0,65	6,4	Dy5
	400	4,60	4,0	0,93	6,0	Dy5
	630	6,50	4,0	1,30	5,7	Dy5
	1000	13,50	6,0	1,75	5,0	Dy5
	1600	19,80	6,0	2,56	5,0	Dy5

U disertaciji će biti prikazani proračuni koji se odnose na uporabu nekoliko tipova vodova, kako je to uobičajeno danas u praksi, mada to ništa ne mijenja u slučaju da se inženjer–projektant (planer) odluči za druge tipove (samo se mijenjaju karakteristike vodova, a proračun ostaje isti).

5.2. PRORAČUN OPTEREĆENJA POTROŠAČA

Obzirom na sve energetske proračune koje je potrebno provesti u predloženom modelu mora se izvršiti proračun pojedinačnih opterećenja potrošača. To je potrebno uraditi na samom početku obzirom da se temeljem toga određuje veličina (snaga) transformatorske stanice koja će napajati predmetni konzum. Proračun se može provesti na dva načina, i to:

- pomoću faktora istodobnosti,
- metodom vršnih opterećenja.

Iz iskustva je poznato da kod potrošača koji pretežito pripadaju kategoriji kućanstava, kakvi su i odabrani potrošači sa slike 5.2, istodobni udio jednog potrošača je 0,8 kW–1,4 kW u ukupnom opterećenju cijeloga područja. Dakle, cijelo područje u određenome vremenskom trenutku može biti opterećeno sa $0{,}8\ \text{kW} \cdot 270 \leq P_{opt} \leq 1{,}4\ \text{kW} \cdot 270$, odnosno $216\ \text{kW} \leq P_{opt} \leq 378\ \text{kW}$. Ako uzmemo da je prosječno ukupno opterećenje između ovih granica, odnosno $P_{opt} \approx 300\ \text{kW}$ onda se može reći da je za napajanje jednog ovakvog zemljopisnog područja potrebno instalirati tipsku transformatorsku stanicu, nominalne snage $S_n = 400\ \text{kVA}$.

Ukoliko je potrebno izvršiti proračun opterećenja potrošača već izgrađenog transformatorskog područja, točniji proračun se dobiva temeljem utrošene godišnje energije potrošača i jednodnevnog, satnog mjerenja opterećenja niskonaponskih izvoda i transformatorske stanice u periodu vršnog opterećenja. Tim proračunom dobiva se vršno opterećenje svakoga potrošača pojedinačno, koje ovisi o utrošenoj godišnjoj energiji svakoga potrošača posebno.

Temeljem jednodnevnog, satnog očitanja opterećenja niskonaponskih izvoda i transformatorske stanice (Prilog 3) dobivaju se dnevni dijagrami opterećenja (Slike 5.4 i 5.5).

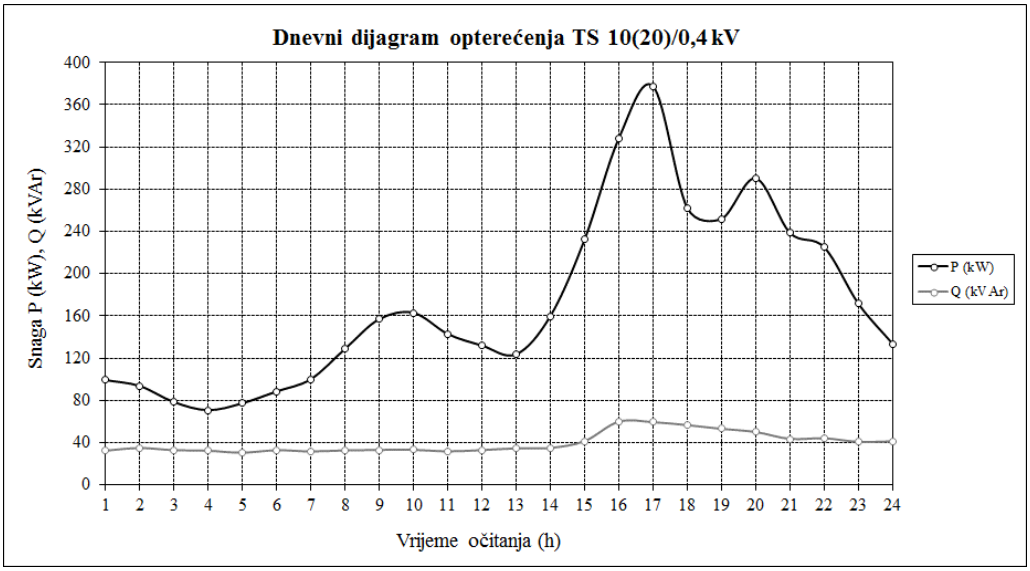

Slika 5.4. *Dnevni dijagram opterećenja transformatorske stanice*

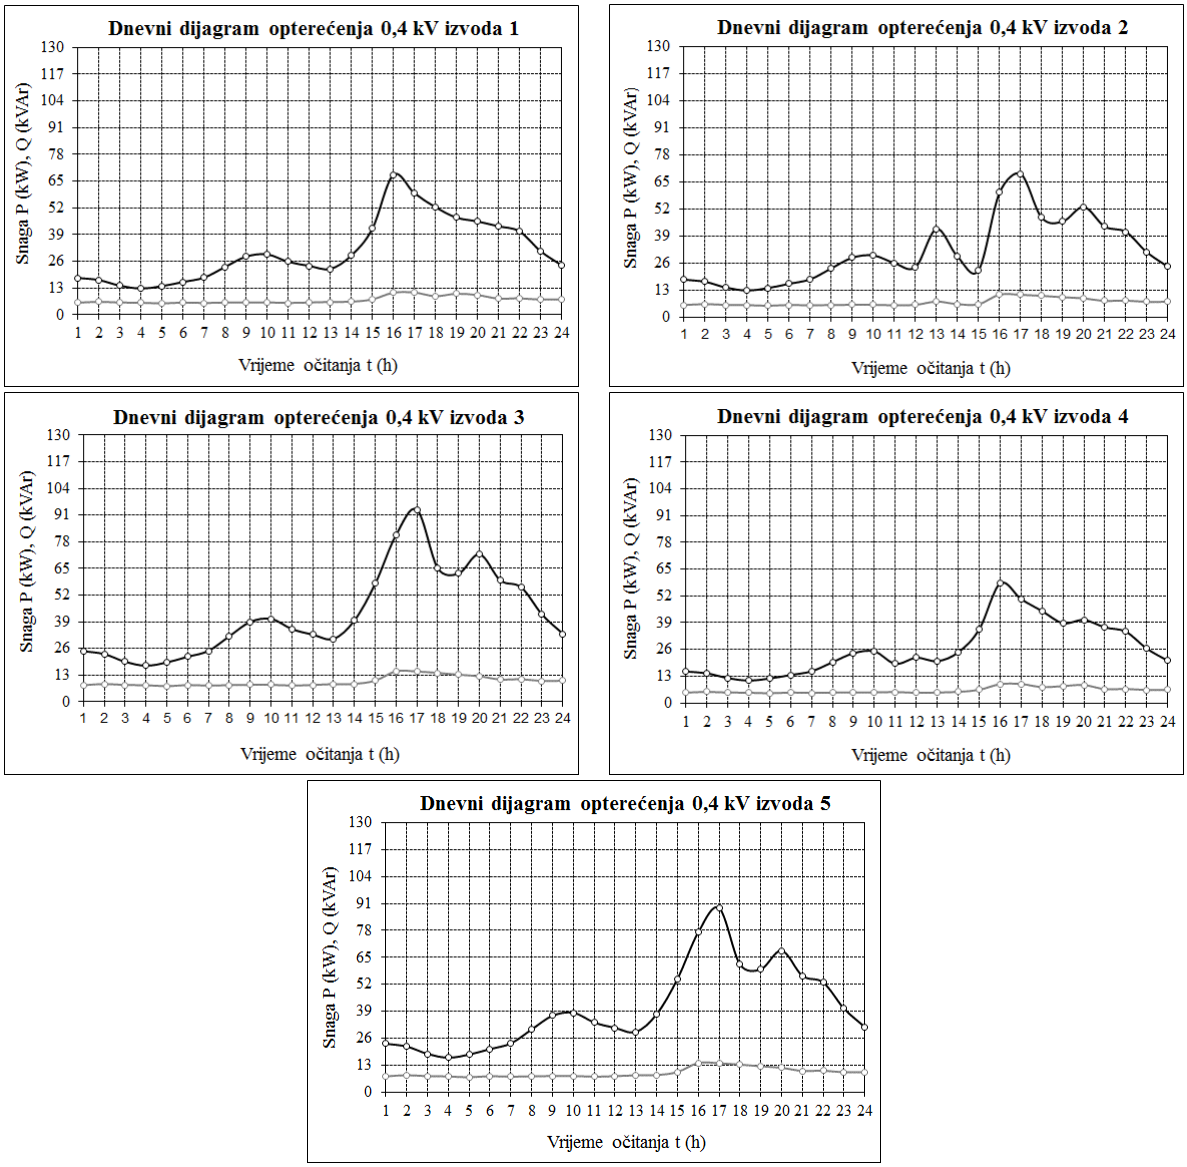

Slika 5.5. *Dnevni dijagram opterećenja niskonaponskih izvoda*

Temeljem ovih dijagrama, u prvom koraku dobivaju se maksimalne radne snage pojedinih niskonaponskih izvoda, kako je to prikazano u tablici 5.3.

Tablica 5.3. *Maksimalne radne snage niskonaponskih izvoda*

P_{max} (kW)				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
68,04	69,03	93,61	58,07	88,78

Temeljem satnih očitanja radne energije dobivaju se ukupne dnevne radne energije pojedinih niskonaponskih izvoda (kWh), kao zbroj pojedinih satnih očitanja i dane su u tablici 5.4.

Tablica 5.4. *Ukupne dnevne radne energije niskonaponskih izvoda*

$W_{uk.\ dnevno} = \Sigma\ W_{satno}$ (kWh)				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
743,76	754,58	1.023,23	634,72	970,39

Ukupne godišnje radne energije pojedinih niskonaponskih izvoda dobivaju se množenjem ukupnih dnevnih radnih energija sa brojem dana u godini (Tablica 5.5).

Tablica 5.5. *Ukupne godišnje radne energije niskonaponskih izvoda*

$W_{uk.\ godišnje} = W_{uk.\ dnevno} \cdot 365$ (kWh)				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
271.471,20	275.423,36	373.479,29	231.672,96	354.192,22

Dijeljenjem ukupnih godišnjih radnih energija za svaki niskonaponski izvod sa maksimalnom postignutom snagom pojedinog izvoda dobivaju se polazne minimalne vrijednosti upotrebnih vremena, koje su u ovome slučaju jednake za sve izvode, kao u tablici 5.6.

Tablica 5.6. *Minimalne vrijednosti upotrebnih vremena pojedinih izvoda*

$T_{up.\ min} = W_{uk.\ godišnje} / P_{max}$ (h)				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
3.990	3.990	3.990	3.990	3.990

Vršna radna snaga svakoga potrošača dobiva se dijeljenjem ukupne godišnje utrošene energije pojedinih potrošača sa dobivenim upotrebnim vremenom. Uz poznati cosφ niskonaponskog izvoda dobiva se i vršna jalova snaga potrošača.

U drugom koraku, kako bi se dobilo konačno opterećenje potrošača, potrebno je korigirati vrijednosti ukupnih godišnjih radnih energija niskonaponskih izvoda kako bi se uskladila ukupna godišnja utrošena radna energija potrošača sa godišnjom radnom energijom dobivenom temeljem jednodnevnog očitanja. Na taj način se mijenjaju i vrijednosti upotrebnih vremena za sve niskonaponske izvode čime se dobivaju konačna opterećenja potrošača.

U tu svrhu je potrebno za vrijednosti opterećenja potrošača dobivene u prvome koraku izvršiti proračun tokova snaga u nekome od dostupnih softverskih paketa (u ovome primjeru je korišten PowerCAD, tvrtke Fractal d.o.o Split). Na ovaj način dobivaju se iznosi gubitaka u prijenosu električne energije za svaki niskonaponski izvod kao u tablici 5.7.

Tablica 5.7. *Vrijednosti gubitaka radne snage niskonaponskih izvoda*

P_{gub} (kW)				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
0,60	0,69	3,40	0,48	6,48

Vrijednosti potrebnih snaga koje treba injektirati u svaki niskonaponski izvod radi zadovoljenja potreba potrošača i pokrivanja gubitaka u prijenosu električne energije dane su u tablici 5.8.

Tablica 5.8. *Vrijednosti potrebnih injektiranih snaga niskonaponskih izvoda*

$P_{inj} = P_{potrošača} + P_{gubitaka}$ (kW)				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
52,81	53,68	75,23	45,05	74,61

Nadalje, potrebno je izvršiti aproksimiranje godišnjih radnih energija svakog izvoda temeljem dnevnih radnih energija, pri čemu se dobivaju tzv. *korekcijski faktori c* (Tablica 5.9).

Tablica 5.9. *Vrijednosti korekcijskih faktora c niskonaponskih izvoda*

$c = (W_{uk.\ godišnje} \cdot P_{inj}) / (365 \cdot W_{uk.\ dnevno} \cdot P_{potrošača})$				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
0,768381	0,768946	0,801217	0,768558	0,838320

Zatim se vrši korigiranje godišnjih radnih energija niskonaponskih izvoda (Tablica 5.10).

Tablica 5.10. *Korigirane vrijednosti godišnjih radnih energije niskonaponskih izvoda*

$W_{uk.\ godišnje} = W_{uk.\ dnevno} \cdot 365 \cdot c$ (kWh)				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
208.593,37	211.785,67	299.238,02	178.054,07	296.926,46

Korigiranjem godišnjih radnih energija mijenjaju se i vrijednosti upotrebnih vremena svih niskonaponskih izvoda (Tablica 5.11).

Tablica 5.11. *Korigirane vrijednosti upotrebnih vremena pojedinih izvoda*

$T_{up.\ min} = W_{uk.\ godišnje} / P_{max}$ (h)				
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5
3.066	3.068	3.197	3.066	3.345

Korigirana (konačna) vrijednost vršne radne snage svakog potrošača dobiva se dijeljenjem ukupne godišnje utrošene energije pojedinačnih potrošača sa novodobivenim, korigiranim upotrebnim vremenom. Uz poznavanje vrijednosti cosφ dobiva se i vršna jalova snaga potrošača (Prilog 4).

Konačne vrijednosti opterećenja pojedinih niskonaponskih izvoda su dane u tablici 5.12.

Tablica 5.12. *Konačne vrijednosti opterećenja niskonaponskih izvoda*

P_{opt} (kW)					
Izvod 1	Izvod 2	Izvod 3	Izvod 4	Izvod 5	Ukupno TS
68,96	70,06	95,09	58,85	90,56	383,52

Dakle, temeljem dobivenih rezultata očito je da za ovo zemljopisno područje treba odabrati tipsku transformatorsku stanicu, najmanje nominalne snage S_n = 400 kVA.

5.3. ODREĐIVANJE LOKACIJE TRANSFORMATORSKE STANICE

Nakon određivanja veličine i tipa transformatorske stanice potrebno je odrediti i njenu lokaciju. Za određivanje lokacije transformatorske stanice predloženi model koristi algoritam neizrazitog grupiranja (*eng. fuzzy clustering*) i to *Matlab Fuzzy Toolbox* (Slika 5.6).

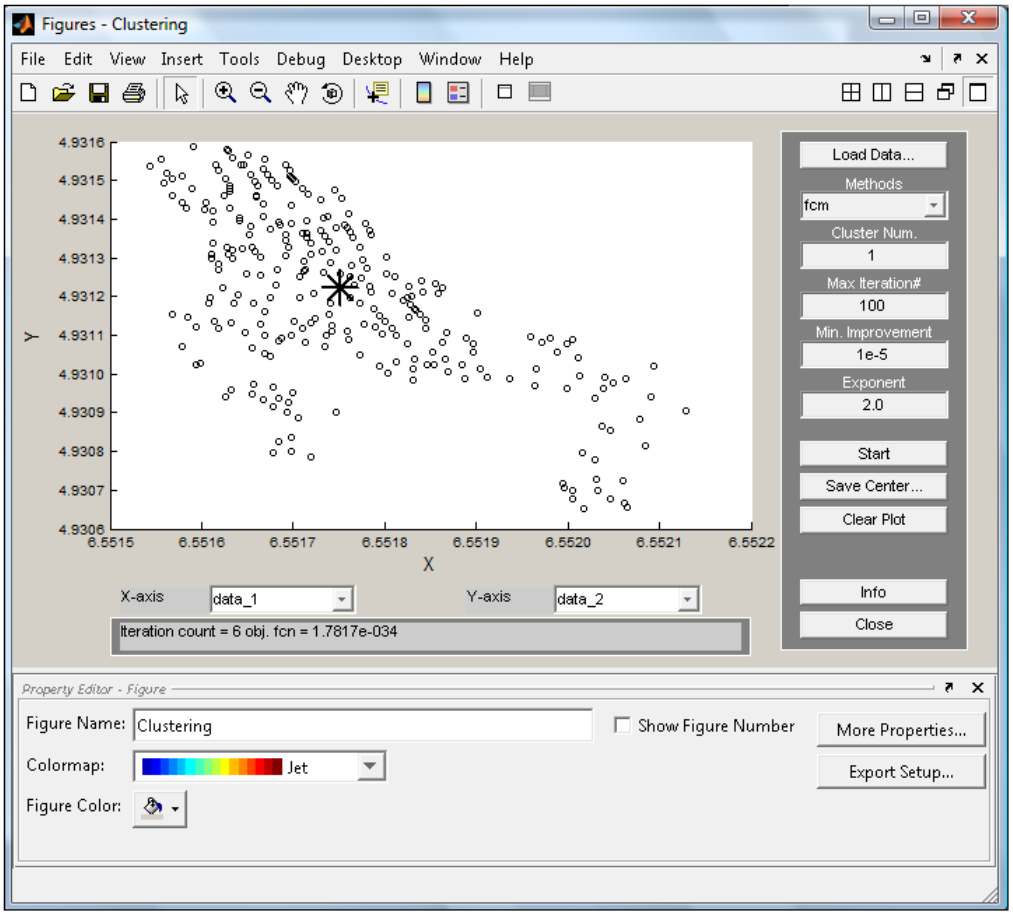

Slika 5.6. *Matlab Fuzzy Toolbox za određivanje centra skupine*

Naime, kao ulazni podaci u Matlab Fuzzy Toolbox koriste se zemljopisne koordinate mjernih mjesta svih potrošača kojim je definiran položaj svakog potrošača u dvodimenzionalnoj koordinatnoj ravnini. Prirodno je da se transformatorska stanica smješta u prostorni centar potrošnje kako je to prikazano na slici 5.6.

Obzirom da zemljopisne koordinate centra, u koji bi trebalo locirati transformatorsku stanicu, mogu „pasti“ na lokaciju nekog objekta, puta i slično, na georeferenciranoj karti, sa prostornim prikazom je moguće izvršiti malo pomicanje centra na neku prigodnu lokaciju, odnosno izvršiti korigiranje njegove prostorne lokacije (relociranje).

S novim, točnim koordinatama centra, dobiva se i konačni grafički prikaz centra konzuma, odnosno lokacije buduće transformatorske stanice u dvodimenzionalnoj ravnini kako je to prikazano na slici 5.7.

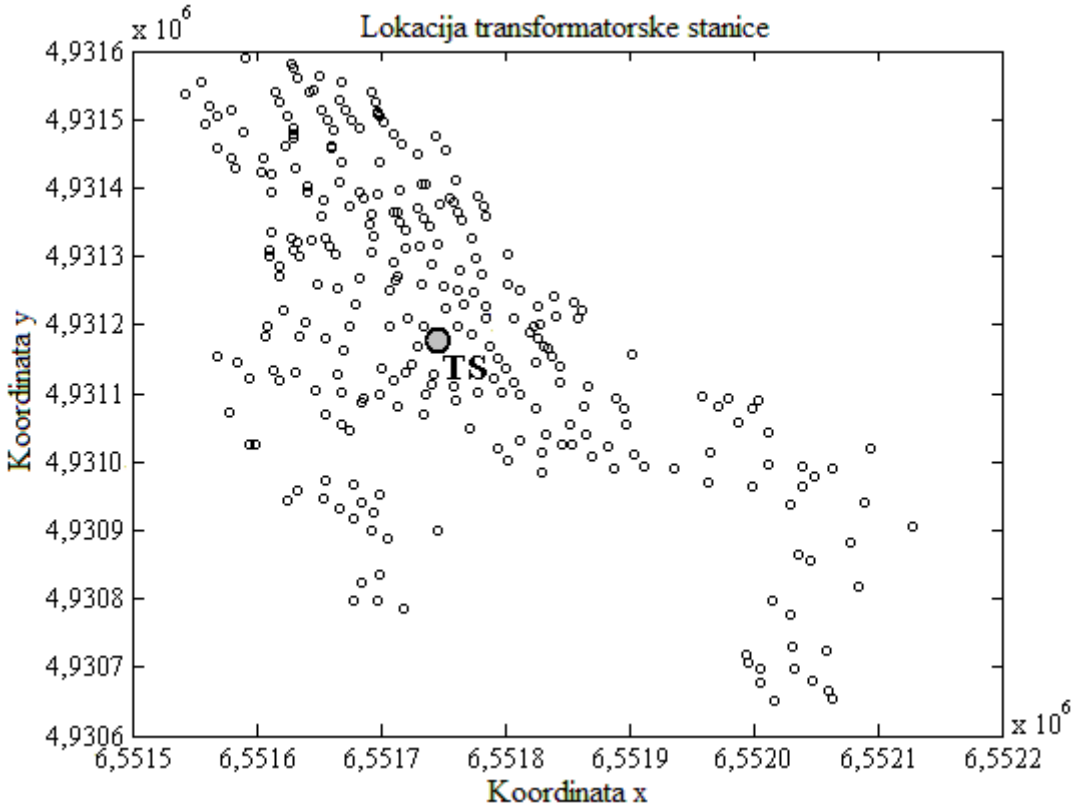

5.7. *Lokacija transformatorske stanice*

5.4. ODREĐIVANJE NISKONAPONSKIH IZVODA

Nakon određivanja veličine i lokacije transformatorske stanice vrši se prostorno grupiranje potrošača. Broj dobivenih skupina praktički definira broj niskonaponskih izvoda transformatorske stanice. Nakon što se definiraju skupine, mogu se definirati i prostorni centri svake od njih.

Grupiranje potrošača kao i definiranja njihovih prostornih centara postiže se primjenom specijaliziranog algoritma, posebno priređenog u Matlab–u, temeljenog na metodi neizrazitog grupiranja.

Obzirom da se predloženi model planiranja temelji na rangiranju različitih alternativa (varijanti), odnosno odabiru najbolje od njih, ovim rješenjem se formiraju alternative sa različitim brojem niskonaponskih izvoda. Na slikama 5.8–5.11 predstavljen je predmetni konzum sa različitim brojem skupina (5, 6, 7 i 8) i njihovi centri.

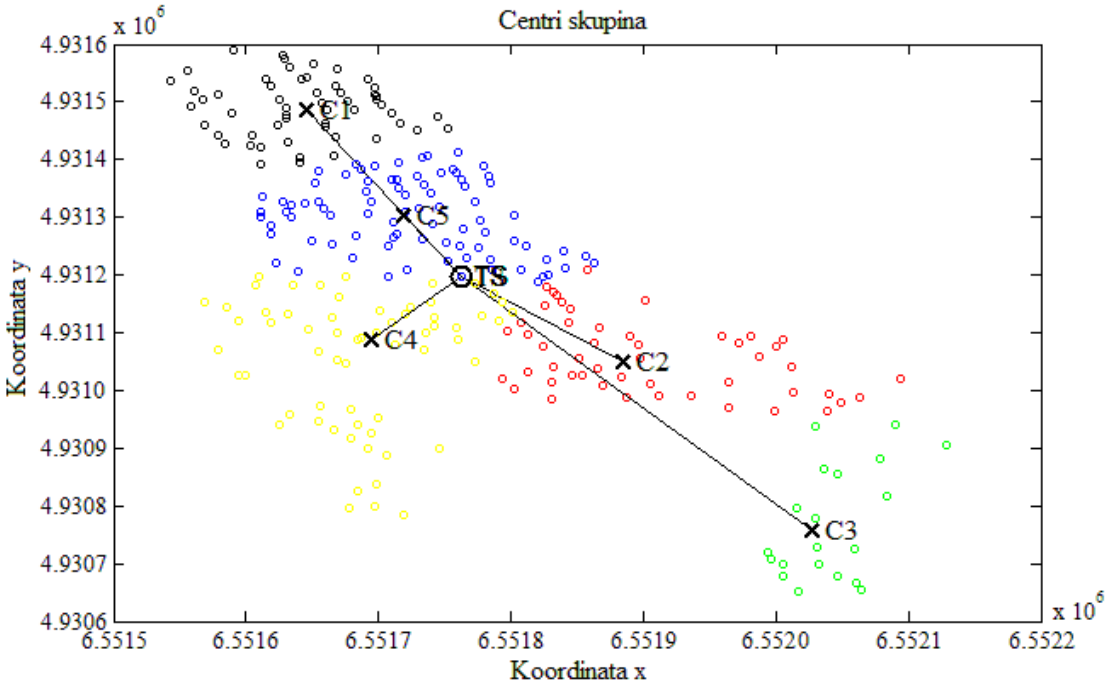

Slika 5.8. *Razdioba konzuma na 5 skupina*

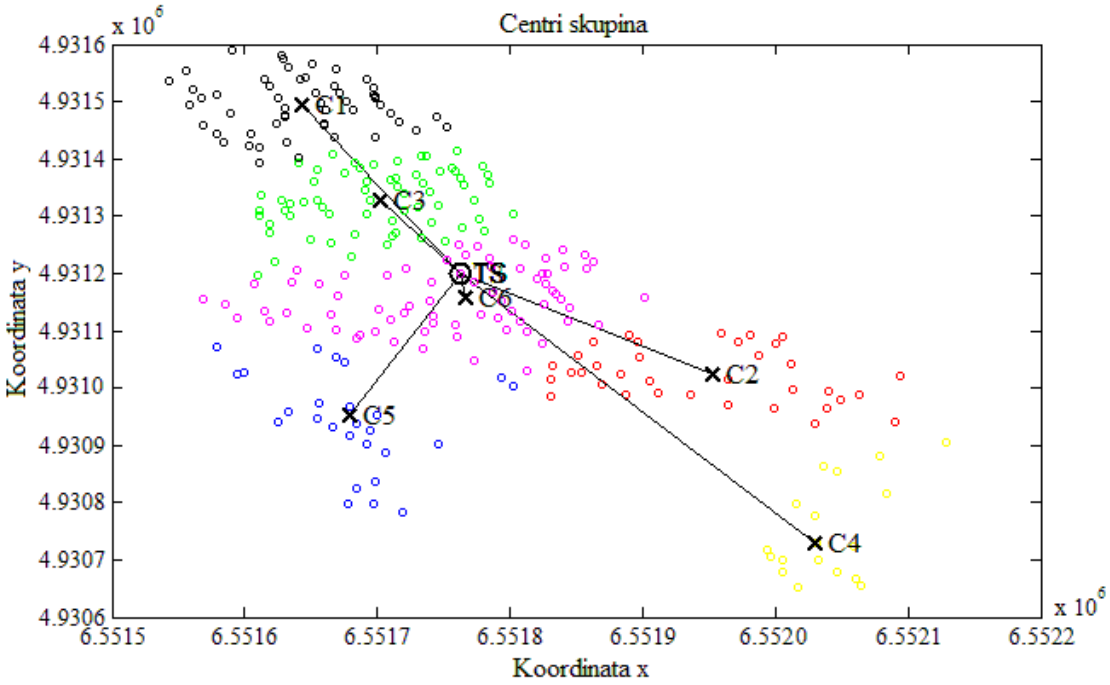

Slika 5.9. *Razdioba konzuma na 6 skupina*

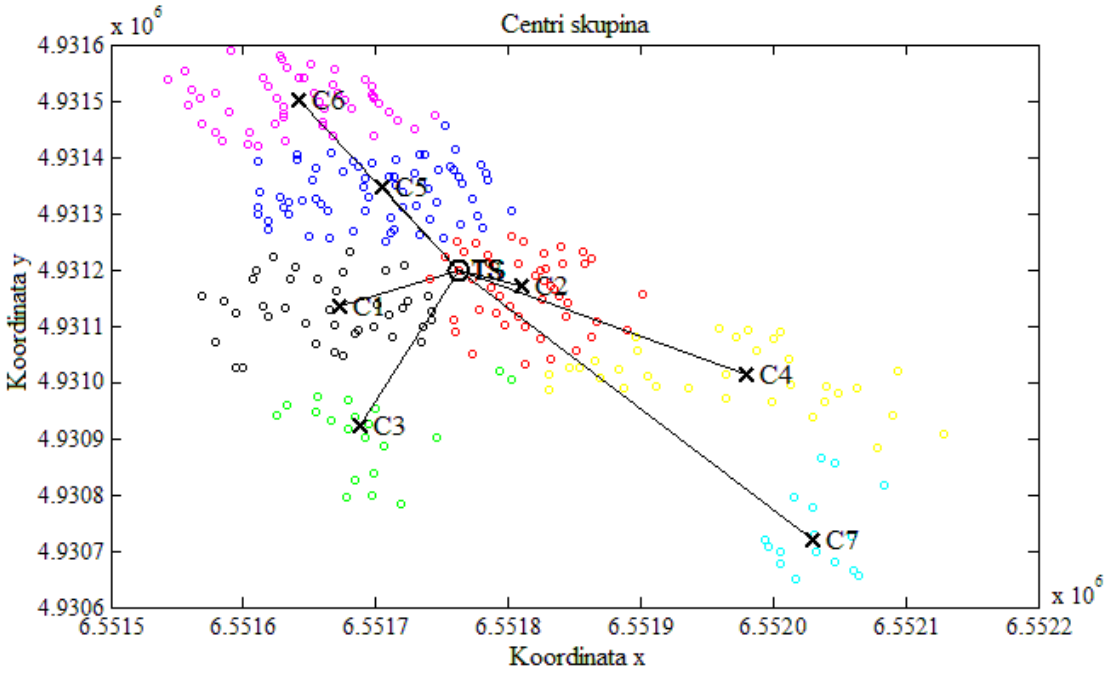

Slika 5.10. *Razdioba konzuma na 7 skupina*

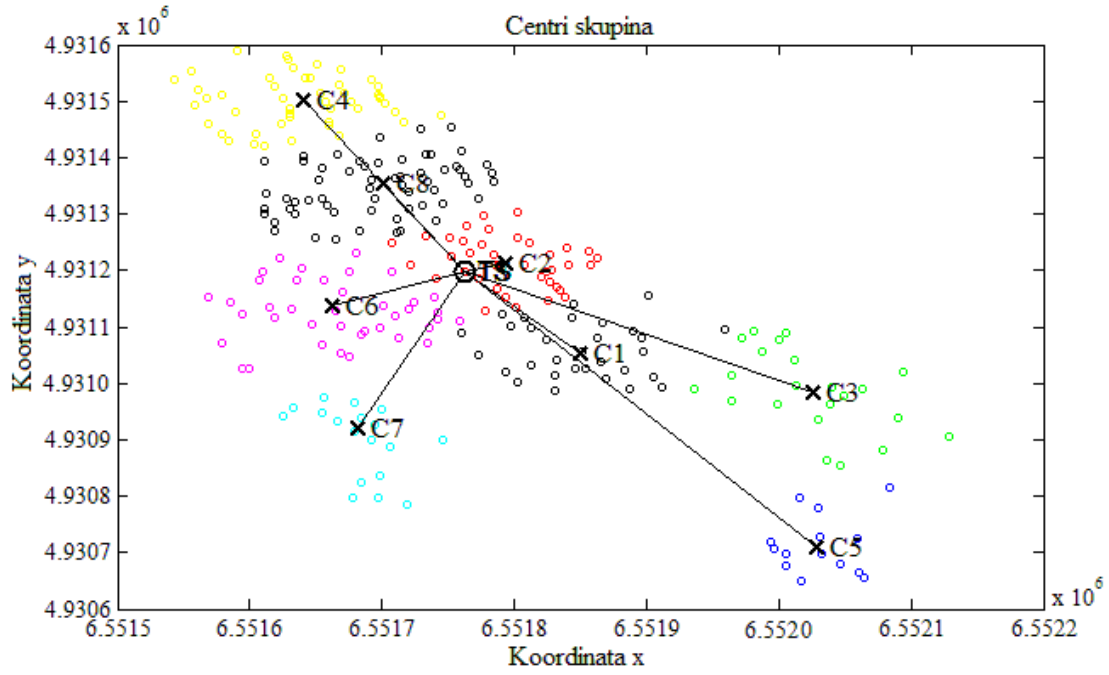

Slika 5.11. *Razdioba konzuma na 8 skupina*

Ukoliko je potrebno, unutar jedne skupine mogu se definirati i podskupine sa svojim prostornim podcentrima. Sve ovo zajedno služi kao orijentacija u kom smjeru je potrebno vršiti izgradnju mreže, odnosno koje tipove vodiča je potrebno odabrati.

I ovo se može definirati istim softverskim rješenjem.

U konačnici se dobivaju grupirani potrošači, sa različitim brojem skupina i njihovim centrima, te podskupinama unutar svake skupine i njihovim podcentrima. Na slikama 5.12–5.15 su prikazani konačni izgledi skupina i podskupina, te njihovi centri i podcentri. Broj skupina ujedno definira i broj niskonaponskih izvoda, dok centri i podcentri daju smjernica rasprostiranja niskonaponske distribucijske mreže.

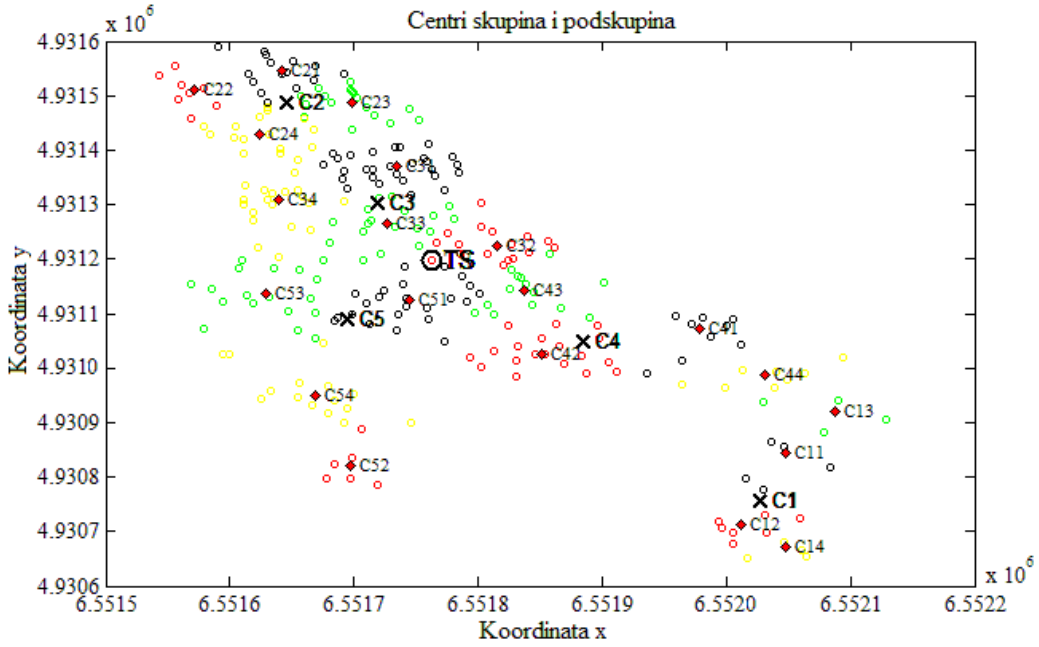

Slika 5.12. *Razdioba konzuma na 5 skupina i 4 podskupine*

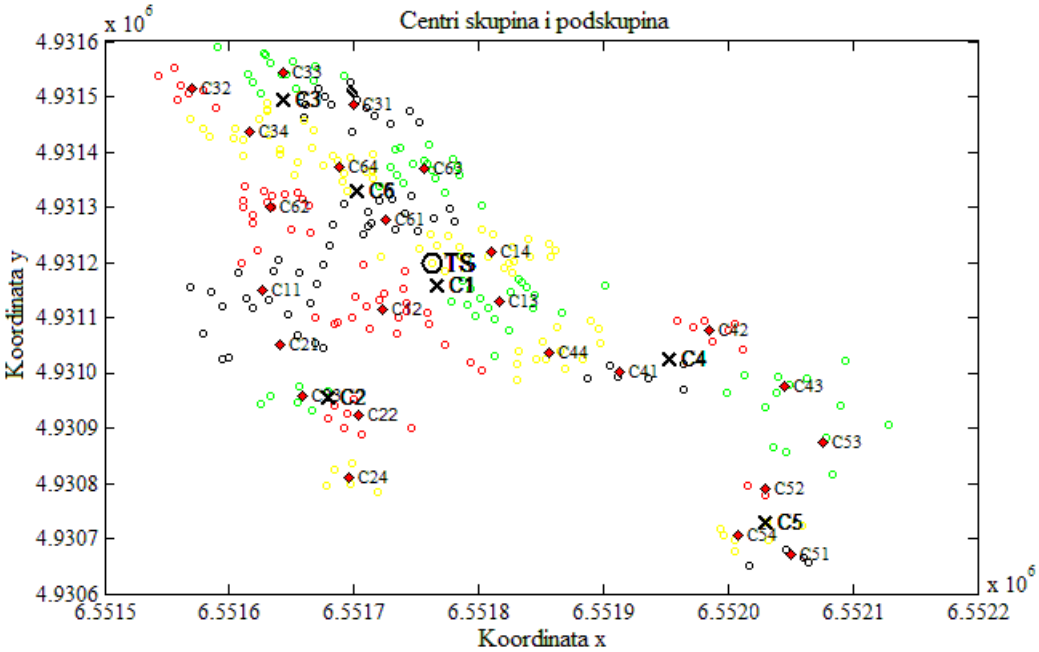

Slika 5.13. *Razdioba konzuma na 6 skupina i 4 podskupine*

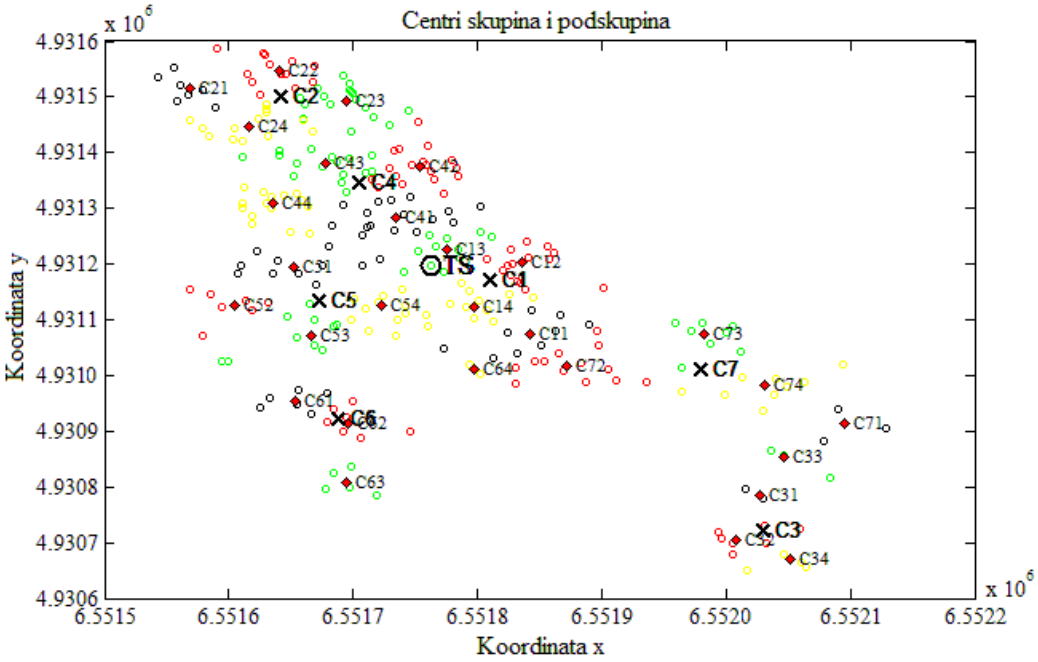

Slika 5.14. *Razdioba konzuma na 7 skupina i 4 podskupine*

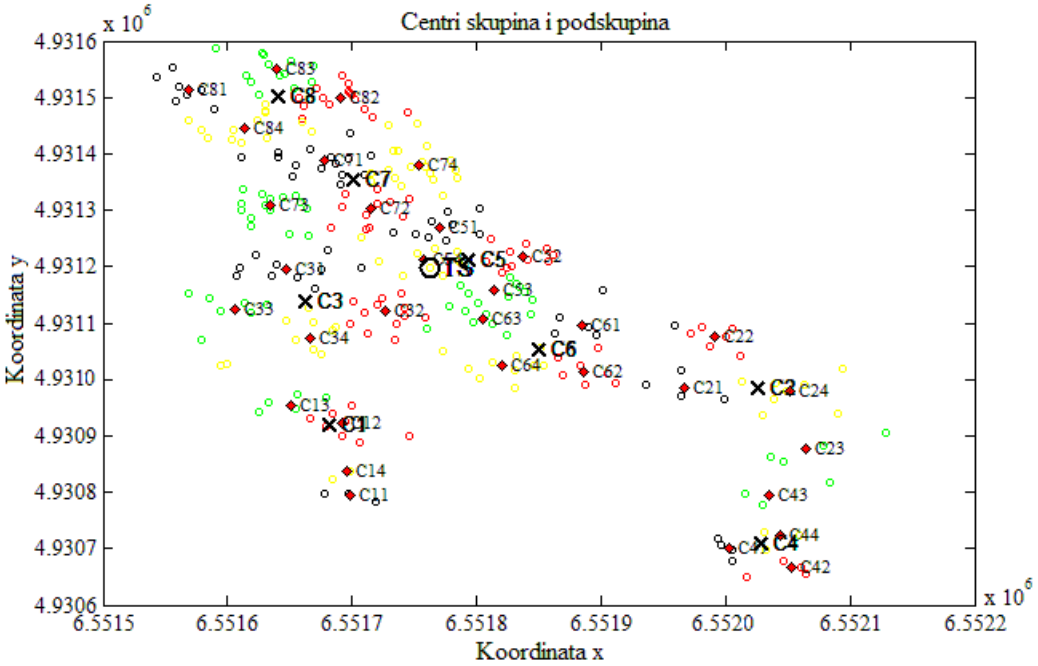

Slika 5.15. *Razdioba konzuma na 8 skupina i 4 podskupine*

Ovime se stvaraju smjernice za formiranje 4 alternative temeljem kojih je u narednom koraku potrebno formirati niskonaponsku distribucijsku mrežu. Broj skupina, odnosno podskupina ovisi isključivo o procjeni inženjera–planera. Za mreže s manjim brojem potrošača, jednostavnijom prostornom razdiobom i sl. potrebno je formirati manji broj alternativa, dok je za složenije mreže, s koncentriranim potrošačima, potreban veći broj alternativa kako bi se dobilo kvalitetnije rješenje.

5.5. FORMIRANJE MREŽNE TOPOLOGIJE

Ovaj korak u biti predstavlja korak u kojem je inženjersko iskustvo jako bitno. Naime, pravilnim i što preciznijim formiranjem mrežne topologije iskusan inženjer stvara dobar temelj (u biti bazu podataka) za dobivanje podataka vrlo bitnih za daljnji tijek planiranja. Što su podaci točniji, konačno rješenje je preciznije.

Mrežne topologije svih alternativa formiraju se na georeferenciranim podlogama sa prostornim pogledom na kojem se može vidjeti prostorni raspored objekata, putova, šuma, rijeka i sl. Formiraju se crtanjem mreža u softverskim paketima prigodnim za crtanje. U ovoj disertaciji koristi se AutoCAD. U prvom koraku vrši se bojenje (označavanje) skupina, podskupina i njihovih centara, odnosno podcentara, a zatim se crtaju mreže, prema smjernicama rasprostiranja koje su dobivene u prvom koraku. Idejna rješenja niskonaponskih distribucijskih mreža svih alternativa, koja se dobivaju metodom neizrazitog grupiranja prikazana su na slikama 5.16–5.19.

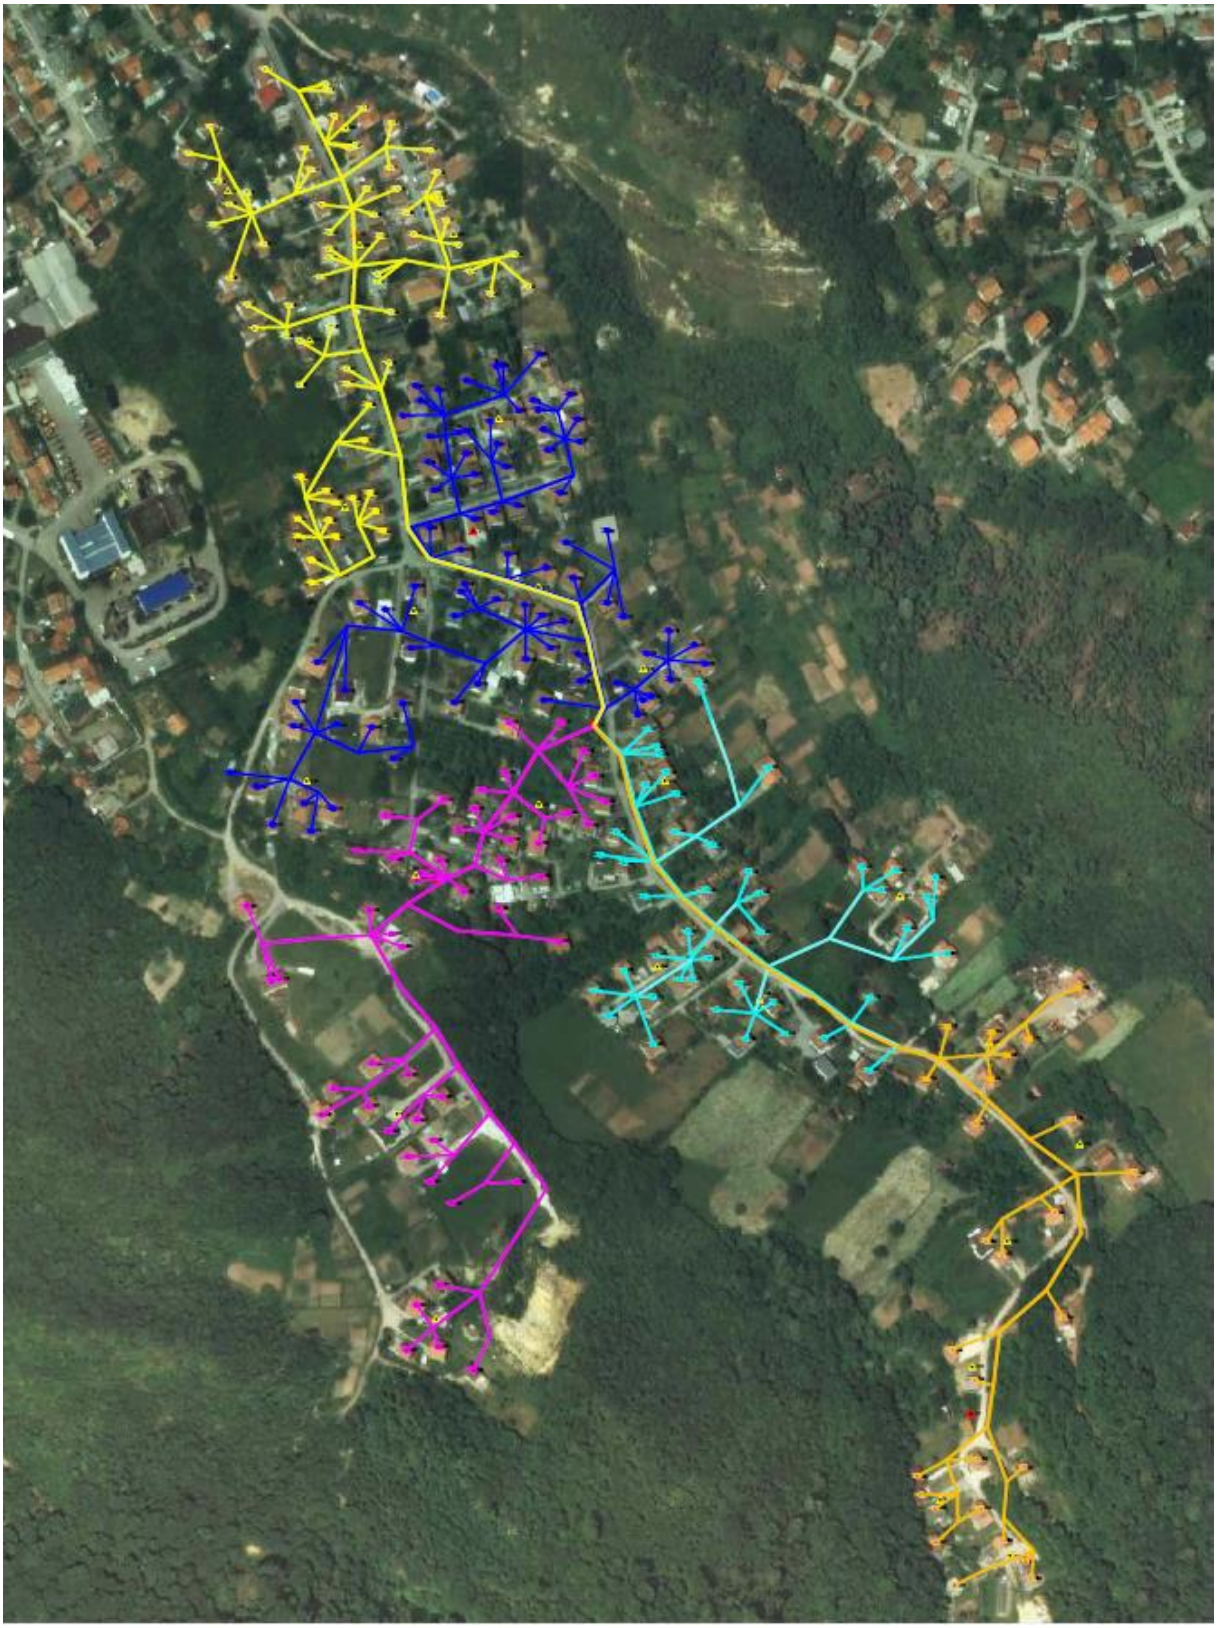

Slika 5.16. *Idejno rješenje distribucijske mreže sa 5 niskonaponskih izvoda*

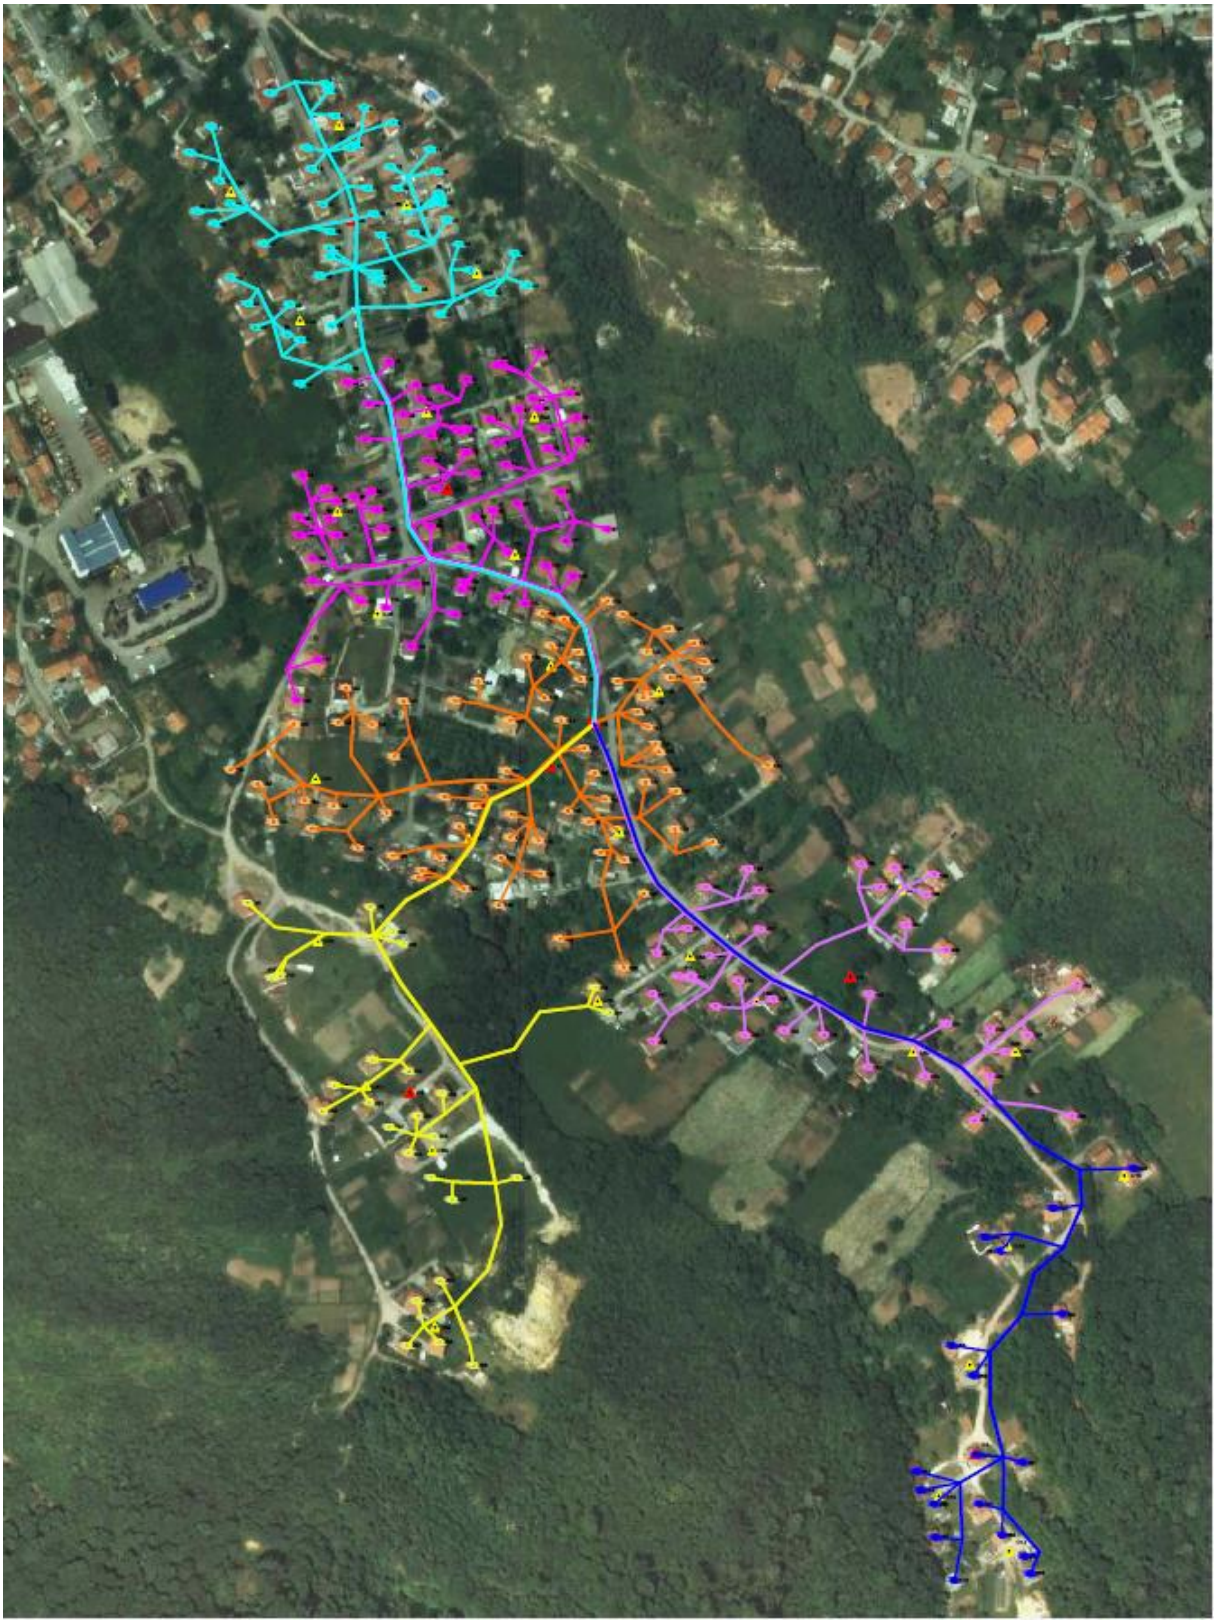

Slika 5.17. *Idejno rješenje distribucijske mreže sa 6 niskonaponskih izvoda*

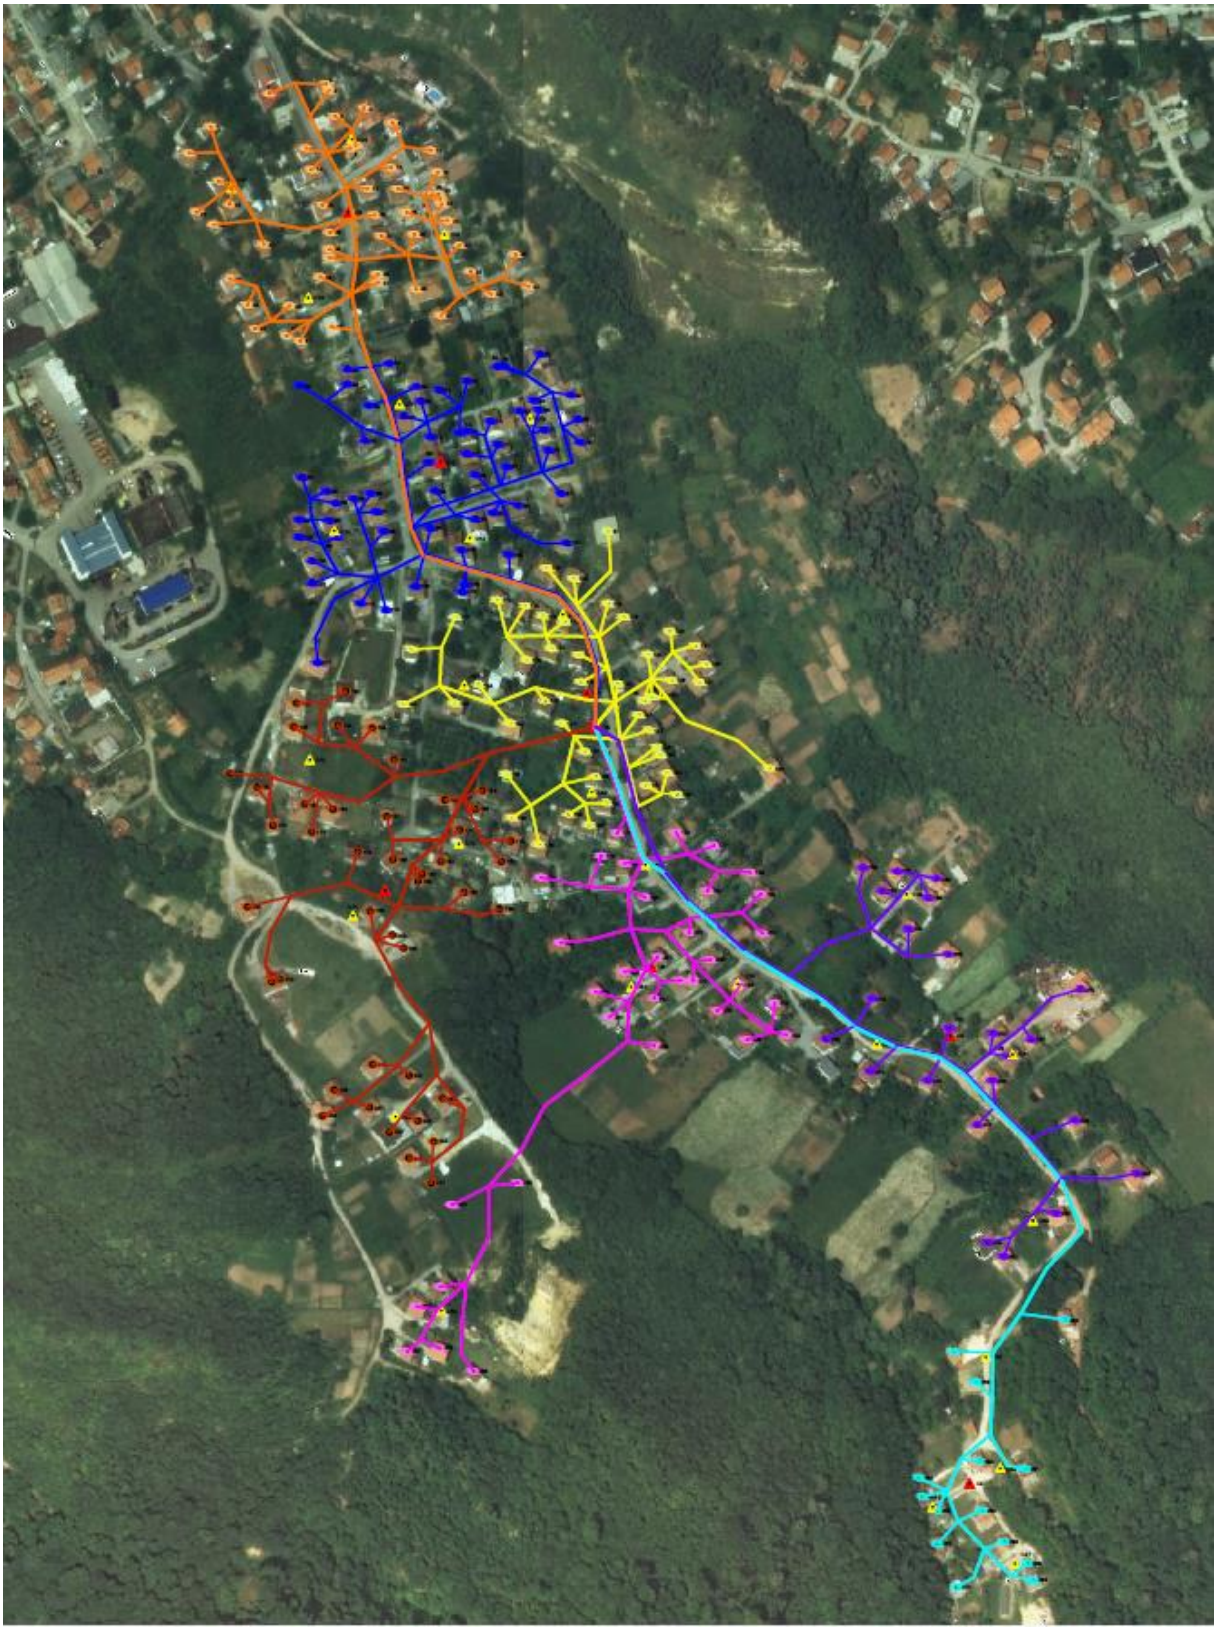

Slika 5.18. *Idejno rješenje distribucijske mreže sa 7 niskonaponskih izvoda*

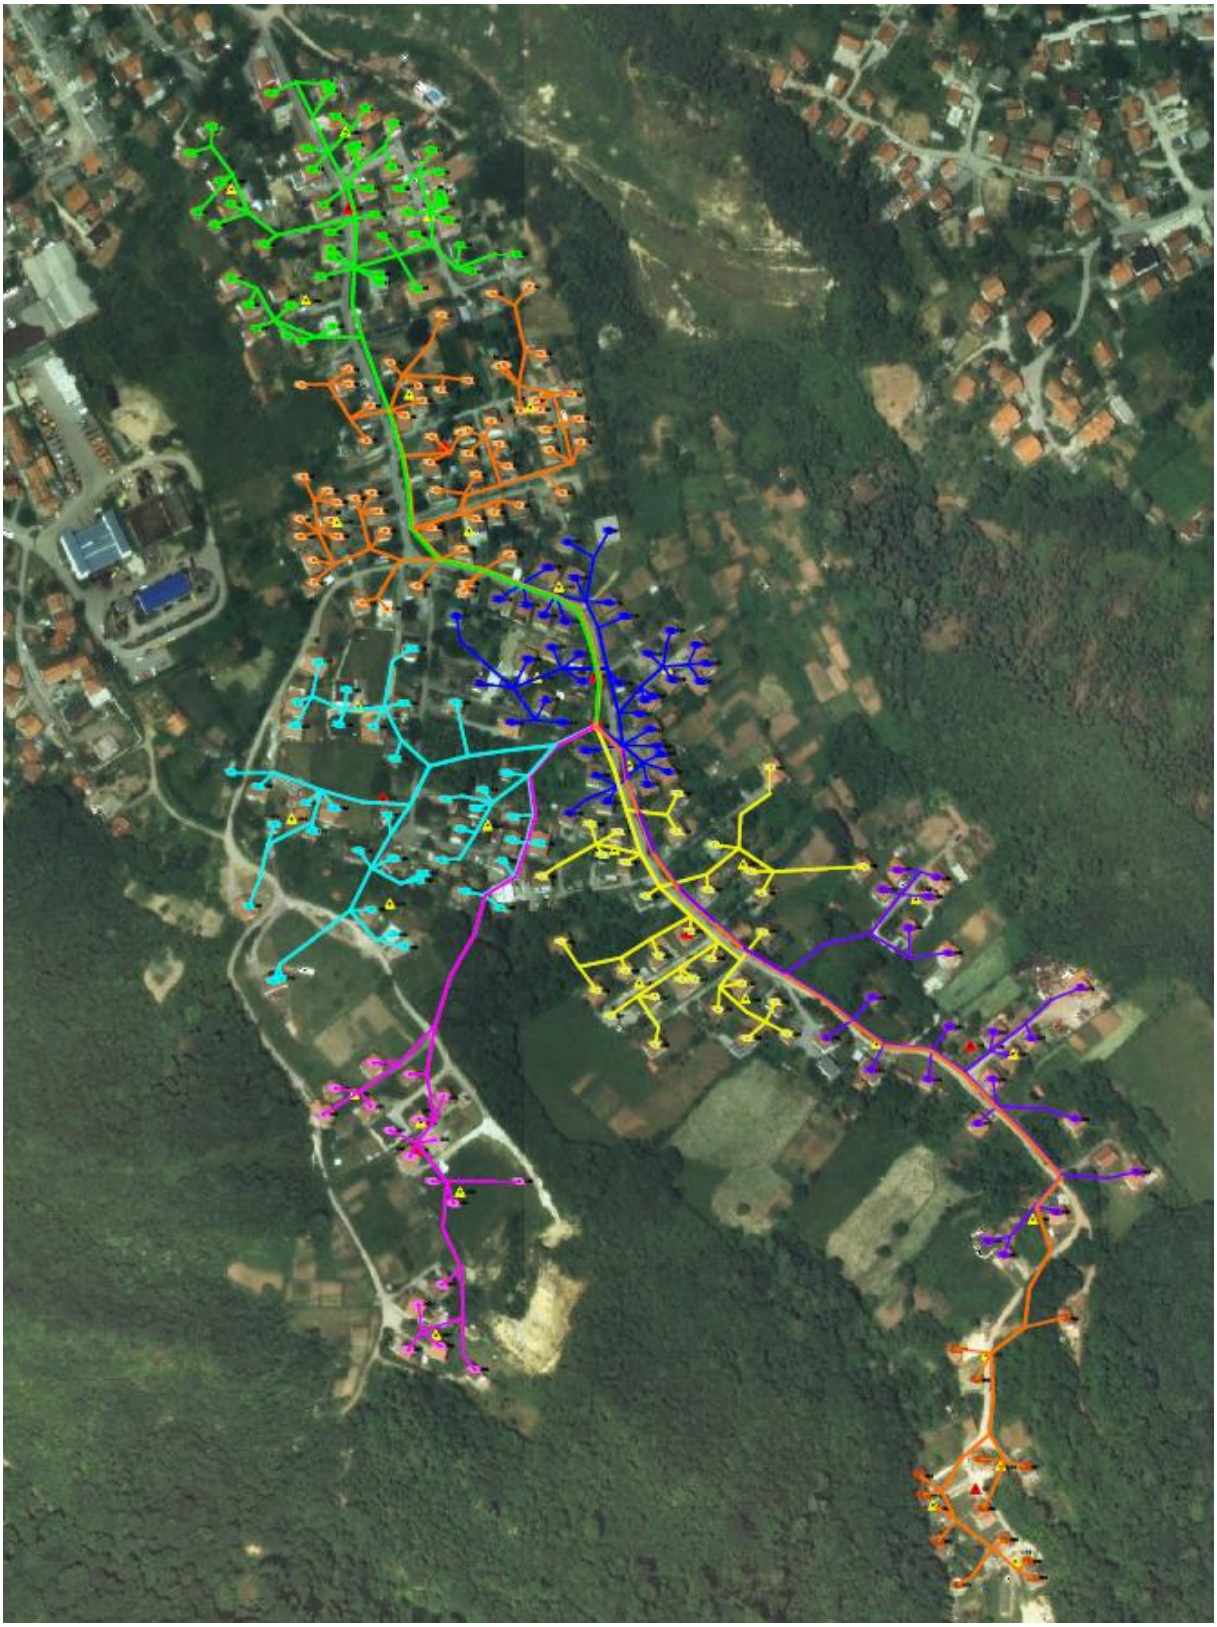

Slika 5.19. *Idejno rješenje distribucijske mreže sa 8 niskonaponskih izvoda*

Sa slika se može uočiti da u svakom ponuđenom rješenju egzistira određeni broj stupnih mjesta. Koordinate stupnih mjesta za svaku alternativu su dane u prilozima 5–8.

5.6. FORMIRANJE KRITERIJA

U prethodnom koraku se dobivaju prostorni izgledi niskonaponskih distribucijskih mreža svih predviđenih alternativa. Ovo, međutim, ne daje odgovor na pitanje koja je od ponuđenih alternativa najbolja. Za to je, na neki način, potrebno ocijeniti svako od ponuđenih rješenja i zatim izvršiti usporedbu jednog sa drugim. Stoga se uspostavljaju kriteriji temeljem kojih će se izvršiti vrednovanje ponuđenih alternativa.

Broj kriterija nije precizno definiran i ovisi isključivo od onoga tko vrši planiranje mreže. Pri odabiru kriterija mora se voditi računa kako o interesima potrošača tako i o interesima elektroenergetske tvrtke. Veći broj kriterija znači odabir kvalitetnije alternative, ali nije uvijek neophodan. Nekada se i s manjim brojem kriterija može dobiti zadovoljavajuće rješenje.

Iscrtavanjem niskonaponskih distribucijskih mreža, za svaku alternativu, dobivaju se podaci o dužinama i presjecima niskonaponskih vodova koji su potrebni za kasnije proračune tokova snaga (Prilozi 9–12).

Kriteriji za vrednovanje alternativa mogu biti različiti. U konkretnom primjeru odabrana su četiri kriterija temeljem kojih će se vrednovati ponuđene alternative, a to su:

1. Padovi napona kod krajnjih potrošača;
2. Gubici snage u niskonaponskim vodovima;
3. Opterećenje niskonaponskih vodova;
4. Investicijski troškovi.

Kvantitativna ocjena prva tri kriterija dobiva se proračunom tokova snaga koji se može provesti bilo kojim softverskim paketom namijenjenim za takvu vrstu proračuna. Predloženi model koristi softverski paket Matpower, koji u biti predstavlja dodatak Matlab–u. Ulazni podaci za proračun tokova snaga svih varijanti su dani u prilozima 13–17.

Podaci o transformatorskoj stanici, odnosno stupnim mjestima su dani u tablicama 5.13 i 5.14.

Tablica 5.13. *Podaci za Matpower o transformatorskoj stanici*

Bus number	P_g (MW)	Q_g (MVAr)	Q_{max} (MVAr)	Q_{min} (MVAr)	V_g (p.u.)	mBase (MVA)	Status	P_{max} (MW)	P_{min} (MW)
999	0.4	0.0	0.02	-0.02	1	1	1	0.38	0

Tablica 5.14. *Podaci za Matpower o jednom stupnom mjestu*

Bus number	Type	Pd (MW)	Qd (MVAr)	Gs (MW)	Bs (MVAr)	Area number	Vm (p.u.)	Va (◦)	Base (kV)	Zone	Vmax (p.u.)	Vmin (p.u.)
1000	1	0.000000	0.000000	0	0	1	1	0	0.4	1	1.05	0.95

Dakle, u podatke o opterećenju sabirnica (Prilog 13) potrebno je za svaku alternativu dodati podatke o svim stupnim mjestima koliko ih ima pojedina alternativa.

5.13.1. Padovi napona kod krajnjih potrošača

Uvođenjem tržišnog poslovanja u elektroenergetski sektor u prvi plan su došli zahtjevi potrošača u vezi s kvalitetom isporučene električne energije. Stoga se kao prvi kriterij u predloženom modelu planiranja uspostavlja veličina pada napona kod krajnjih potrošača. Na dijagramu sa slike 5.18, odnosno u tablici 5.15 predstavljene su vrijednosti napona na sabirnicama potrošača za sve uspostavljene alternative.

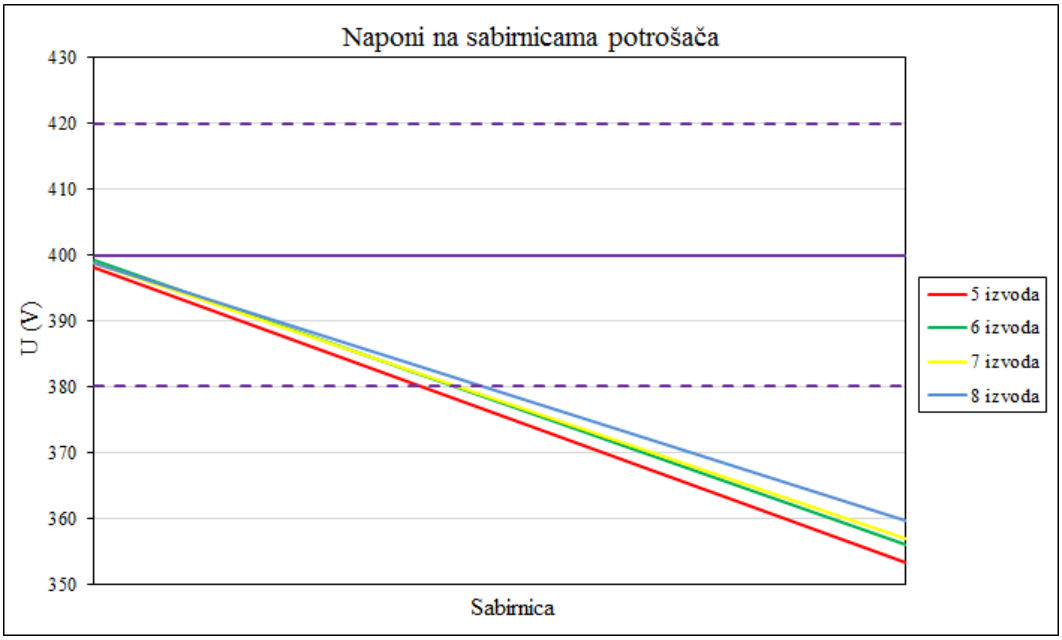

Slika 5.20. *Naponi na sabirnicama potrošača svih alternativa*

Tablica 5.15. *Padovi napona kod krajnjih potrošača*

Broj NN izvoda	Proračunate vrijednosti			
	ΔU (p.u.)	U (V)	ΔU (V)	ΔU (%)
5	0,883	353,2	-46,8	-11,7
6	0,890	356,0	-44,0	-11,0
7	0,892	356,8	-43,2	-10,8
8	0,899	359,6	-40,4	-10,1

Temeljem dobivenih vrijednosti vrši se rangiranje pojedinih alternativa u odnosu na dani kriterij. Ovom kriteriju se daje najveći značaj u odnosu na ostale kriterije obzirom da je cilj svake elektrodistributivne tvrtke što veći broj kupaca električne energije, ali koje je moguće osigurati samo isporukom kvalitetne električne energije. Naravno, ukoliko neka tvrtka posluje u monopolističkom sustavu onda su njeni prioriteti drugačiji, te vrednovanje ovog kriterija ne mora biti na prvom mjestu, odnosno nekim drugim kriterijima, koji za tvrtku mogu biti izuzetno bitni, može se dati određena prednost.

5.6.2. Gubici snage

Gubici radne snage u niskonaponskim vodovima su drugi kriterij za vrednovanje alternativa. Ovaj kriterij ima značaj za elektrodistributivnu tvrtku i u predloženom modelu planiranja se svrstava na drugo mjesto po važnosti. Ukupni gubici u niskonaponskim vodovima, za sve ponuđene alternative, su prikazani u tablici 5.16.

Tablica 5.16. *Gubici aktivne snage u niskonaponskim vodovima*

Broj NN izvoda	P_{pot} (kW)	Gubici	
		(kW)	(%)
5	365,74	20,92	5,41
6		18,71	4,87
7		18,68	4,86
8		17,38	4,54

5.6.3. Opterećenje vodova

Slijedeći kriterij koji se odabire za ocjenu alternativa je opterećenje niskonaponskih vodova. Jasno je da se niskonaponskim vodovima mora prenijeti sva zahtijevana snaga do krajnjih kupaca, ali se vodovi ne smiju preopteretiti. Ovaj kriterij nema toliki značaj kao prethodni kriteriji i daje mu se znatno manja važnost. U tablicama 5.17–5.20 je dan pregled prosječne opterećenosti niskonaponskih vodova svih ponuđenih alternativa.

Tablica 5.17. *Prosječno opterećenje vodova alternative s 5 niskonaponskih izvoda*

Izvod	P_{pot} (kW)	Q_{pot} (kVAr)	P_{gub} (kW)	Q_{gub} (kVAr)	P_{uk} (kW)	Q_{uk} (kVAr)	cosφ	U_n (kV)	I_n (A)	I_{opt}	
										(A)	(%)
1	118,7	27,35	6,01	0,96	124,7	28,31	0,975	0,4	198	184,58	93,22
2	18,48	4,260	0,55	0,09	19,03	4,350	0,975	0,4	198	28,180	14,23
3	72,90	16,80	1,87	0,29	74,78	17,09	0,975	0,4	198	110,71	55,91
4	68,85	15,87	1,75	0,28	70,60	16,14	0,975	0,4	198	104,53	52,79
5	86,80	20,00	10,7	1,77	97,54	21,77	0,976	0,4	198	144,25	72,85
Prosječno opterećenje:										114,45	57,80

Tablica 5.18. *Prosječno opterećenje vodova alternative s 6 niskonaponskih izvoda*

Izvod	P_{pot} (kW)	Q_{pot} (kVAr)	P_{gub} (kW)	Q_{gub} (kVAr)	P_{uk} (kW)	Q_{uk} (kVAr)	cosφ	U_n (kV)	I_n (A)	I_{opt}	
										(A)	(%)
1	94,66	21,81	0,95	0,13	95,62	21,94	0,975	0,4	198	141,60	71,51
2	97,49	22,46	5,72	0,91	103,2	23,37	0,975	0,4	198	152,74	77,14
3	84,78	19,53	9,67	1,60	94,45	21,13	0,976	0,4	198	139,70	70,56
4	30,35	6,990	0,79	0,13	31,13	7,120	0,975	0,4	198	46,100	23,28
5	41,40	9,540	1,06	0,17	42,46	9,710	0,975	0,4	198	62,870	31,75
6	17,06	3,930	0,51	0,08	17,57	4,010	0,975	0,4	198	26,010	13,14
Prosječno opterećenje:										94,840	47,90

Tablica 5.19. *Prosječno opterećenje vodova alternative s 7 niskonaponskih izvoda*

Izvod	P_{pot} (kW)	Q_{pot} (kVAr)	P_{gub} (kW)	Q_{gub} (kVAr)	P_{uk} (kW)	Q_{uk} (kVAr)	cosφ	U_n (kV)	I_n (A)	I_{opt} (A)	I_{opt} (%)
1	55,76	12,85	0,45	0,06	56,21	12,91	0,975	0,4	198	83,250	42,04
2	92,06	21,21	5,87	0,93	97,93	22,14	0,975	0,4	198	144,92	73,19
3	82,21	18,94	9,52	1,57	91,73	20,51	0,976	0,4	198	135,67	68,52
4	50,72	11,69	1,05	0,16	51,77	11,85	0,975	0,4	198	76,650	38,71
5	44,26	10,20	0,82	0,13	45,09	10,32	0,975	0,4	198	66,760	33,72
6	27,65	6,370	0,64	0,10	28,28	6,470	0,975	0,4	198	41,880	21,15
7	13,07	3,010	0,34	0,06	13,41	3,070	0,975	0,4	198	19,850	10,03
Prosječno opterećenje:										81,280	41,05

Tablica 5.20. *Prosječno opterećenje vodova alternative s 8 niskonaponskih izvoda*

Izvod	P_{pot} (kW)	Q_{pot} (kVAr)	P_{gub} (kW)	Q_{gub} (kVAr)	P_{uk} (kW)	Q_{uk} (kVAr)	cosφ	U_n (kV)	I_n (A)	I_{opt} (A)	I_{opt} (%)
1	50,68	11,68	0,38	0,06	51,07	11,73	0,975	0,4	198	75,630	38,20
2	93,91	21,64	6,36	0,99	100,3	22,63	0,975	0,4	198	148,36	74,93
3	77,85	17,94	8,23	1,36	86,08	19,29	0,976	0,4	198	127,33	64,31
4	41,46	9,550	0,49	0,07	41,95	9,630	0,975	0,4	198	62,130	31,38
5	21,72	5,010	0,43	0,07	22,15	5,070	0,975	0,4	198	32,800	16,56
6	39,55	9,110	0,54	0,08	40,10	9,200	0,975	0,4	198	59,380	29,99
7	27,49	6,330	0,62	0,10	28,11	6,430	0,975	0,4	198	41,610	21,02
8	13,07	3,010	0,33	0,06	13,40	3,070	0,975	0,4	198	19,840	10,02
Prosječno opterećenje:										70,880	35,80

5.6.4. Investicijski troškovi

Ovim kriterijem se definiraju investicijski troškovi izgradnje niskonaponske distribucijske mreže. Kao i prethodni kriterij, u uvjetima tržišnog poslovanja, nema toliku važnost u odnosu na prva dva kriterija i na razini je prethodnog kriterija.

Za definiranje ovog kriterija potrebno je uspostaviti određeni cjenik elemenata mreže, opreme i potrebnih radova. U tablicama u nastavku su dani cjenici temeljem kojih je moguće procijeniti investicijske troškove izgradnje predloženih mreža.

Tablica 5.21. *Cjenik nabavke i montaže transformatorske stanice*

Vrsta usluge	Cijena (€)
Građevinski radovi	5.700,26
Elektromontažni radovi + transformator	24.818,41
Ukupno:	30.518,67

Tablica 5.22. *Cjenik nabavke i montaže stupova*

Tip stupa	Cijena (nabavka, transport i montaža) (€/kom)
Nosni	360,61
Nosni	387,21
Zatezni–kutni	555,50
Zatezni–kutni	723,79
Zatezni–kutni	774,42
Kutni	883,38
Kutno–zatezni	997,44
Kutno–zatezni	1.058,82
Prosječna cijena po stupu:	717,65
Ovješenja i odvodnici prenapona (po stupu)	153,45
Ukupno po stupu:	871,10

Tablica 5.23. *Cjenik kabela*

Tip i presjek kabela	Cijena (nabavka, transport i montaža) (€/m)
SKS 4×70 mm^2	10,23
SKS 4×35 mm^2	8,18
SKS 4×16 mm^2	4,09

Temeljem danih cjenika i podataka koje je moguće dobiti iz idejnih rješenja procjenjuju se investicijski troškovi svih alternativa (Tablice 5.24–5.27).

Tablica 5.24. *Procijenjeni investicijski troškovi idejnog rješenja s 5 niskonaponskih izvoda*

Izvod	TS (€)	Broj stupova	Ukupno stupovi (€)	SKS 70 mm^2 (m)	Ukupno SKS (€)	SKS 35 mm^2 (m)	Ukupno SKS (€)	SKS 16 mm^2 (m)	Ukupno SKS (€)	Ukupno (€)
1	30.519	32	27.875	305	3.117	610	4.994	1.482	6.065	48.154
2		17	14.809	598	6.119	243	1.993	382	1.565	30.589
3		38	33.102	354	3.625	796	6.513	1.223	5.003	54.346
4		25	21.777	252	2.582	528	4.324	999	4.087	38.875
5		20	17.422	423	4.323	396	3.238	1.062	4.345	35.431
Ukupno:	30.519	132	114.985	1.932	19.765	2.573	21.062	5.148	21.064	207.395

Tablica 5.25. *Procijenjeni investicijski troškovi idejnog rješenja s 6 niskonaponskih izvoda*

Izvod	TS (€)	Broj stupova	Ukupno stupovi (€)	SKS 70 mm^2 (m)	Ukupno SKS (€)	SKS 35 mm^2 (m)	Ukupno SKS (€)	SKS 16 mm^2 (m)	Ukupno SKS (€)	Ukupno (€)
1	30.519	32	27.875	148	1.510	883	7.230	1.186	4.853	46.554
2		37	32.231	247	2.528	693	5.675	1.009	4.129	49.649
3		36	31.360	410	4.198	512	4.192	837	3.427	48.263
4		19	16.551	371	3.791	450	3.687	384	1.569	30.684
5		26	22.649	298	3.044	446	3.652	628	2.571	37.002
6		14	12.195	627	6.410	166	1.355	350	1.432	26.479
Ukupno:	30.519	164	142.860	2.100	21.481	3.151	25.791	4.394	17.980	238.631

Tablica 5.26. *Procijenjeni investicijski troškovi idejnog rješenja s 7 niskonaponskih izvoda*

Izvod	TS (€)	Broj stupova	Ukupno stupovi (€)	SKS 70 mm^2 (m)	Ukupno SKS (€)	SKS 35 mm^2 (m)	Ukupno SKS (€)	SKS 16 mm^2 (m)	Ukupno SKS (€)	Ukupno (€)
1	30.519	25	21.777	103	1.053	520	4.252	769	3.146	34.588
2		39	33.973	247	2.530	676	5.531	839	3.432	49.825
3		25	21.777	410	4.190	476	3.896	792	3.241	37.464
4		33	28.746	205	2.096	729	5.964	635	2.598	43.764
5		29	25.262	206	2.111	552	4.517	508	2.080	38.329
6		26	22.649	389	3.975	335	2.745	375	1.534	35.262
7		13	11.324	641	6.553	107	878	224	917	24.033
Ukupno:	30.519	190	165.509	2.200	22.507	3.395	27.782	4.142	16.948	263.265

Tablica 5.27. *Procijenjeni investicijski troškovi idejnog rješenja s 8 niskonaponskih izvoda*

Izvod	TS (€)	Broj stupova	Ukupno stupovi (€)	SKS 70 mm^2 (m)	Ukupno SKS (€)	SKS 35 mm^2 (m)	Ukupno SKS (€)	SKS 16 mm^2 (m)	Ukupno SKS (€)	Ukupno (€)
1	30.519	20	17.422	111	1.134	329	2.690	569	2.327	27.388
2		35	30.488	237	2.428	675	5.522	821	3.360	45.613
3		26	22.649	409	4.184	469	3.835	706	2.888	37.371
4		33	28.746	155	1.588	654	5.355	506	2.069	41.573
5		15	13.066	334	3.421	230	1.881	253	1.037	23.220
6		25	21.777	157	1.608	475	3.885	419	1.714	32.800
7		28	24.391	359	3.672	374	3.060	351	1.436	36.374
8		14	12.195	664	6.794	113	927	205	841	24.572
Ukupno:	30.519	196	170.736	2.427	24.829	3.318	27.155	3.830	15.673	268.912

5.7. RANGIRANJE

Nakon uspostavljanja kvantitativnih vrijednosti pojedinih kriterija potrebno je izvršiti:

- rangiranje kriterija,
- rangiranje alternativa (varijanti).

Ovi koraci se provode primjenom AHP metode.

5.7.1. Rangiranje kriterija

Primjenom AHP metode prvo se vrši ocjena važnosti svakog kriterija. Ova ocjena je subjektivna i ovisi o onome tko vrši planiranje. U danom primjeru mreže ocjena važnosti odabranih kriterija se vrši kako je to prikazano u tablici 5.28.

Tablica 5.28. *Ocjena važnosti kriterija*

Kriterij	Ocjena	Objašnjenje
Pad napona	1	Najveća važnost
Gubici snage	2	Malo manja važnost
Opterećenje vodova	4	Mala važnost
Investicija	5	Najmanja važnost

Temeljem ovih ocjena formira se matrica za usporedbu kriterija (Tablica 5.29).

Tablica 5.29. *Matrica usporedbe kriterija*

Kriterij	Pad napona	Gubici	Opterećenje vodova	Investicija
Pad napona	1	2	4	5
Gubici	0,50	1	4	5
Opterećenje vodova	0,25	0,25	1	2
Investicija	0,20	0,20	0,50	1

Težine redaka matrice usporedbe kriterija. odnosno njihove geometrijske sredine, dobivaju se prema jednadžbi 3.22:

$m_1 = 2,51487$
$m_2 = 1,77828$
$m_3 = 0,59460$
$m_4 = 0,37606$

Prema jednadžbi 3.19 dobivaju se vrijednosti prioriteta za matricu usporedbe kriterija koje pokazuju koliki je utjecaj kriterija na odluku, odnosno:

$p_1 = 0,47777$
$p_2 = 0,33783$
$p_3 = 0,11296$
$p_4 = 0,07144$

Nakon ovoga se određuje vektor svojstvenih vrijednosti matrice usporedbe, odnosno radi se normaliziranje matrice usporedbe, prema jednadžbi 3.23. Dobiva se tablica 5.30.

Tablica 5.30. *Normalizirana matrica usporedbe kriterija*

Kriterij	Pad napona	Gubici	Opterećenje vodova	Investicija	Zbroj redaka
Pad napona	0,51282	0,57971	0,42105	0,38462	1,89820
Gubici	0,25641	0,28986	0,42105	0,38462	1,35193
Opterećenje vodova	0,12821	0,07246	0,10526	0,15385	0,45978
Investicija	0,10256	0,05797	0,05263	0,07692	0,29009

Dijeljenjem zbroja redaka normalizirane matrice s ukupnim brojem redaka dobivaju se težinske vrijednosti kriterija. Dakle, prema jednadžbi 3.24 dobiva se zadnji stupac tablice 5.31.

Tablica 5.31. *Vektor težinskih vrijednosti*

Kriterij	Pad napona	Gubici	Opterećenje vodova	Investicija	Zbroj redaka	Vektor težinskih vrijednosti
Pad napona	0,51282	0,57971	0,42105	0,38462	1,89820	0,47455
Gubici	0,25641	0,28986	0,42105	0,38462	1,35193	0,33798
Opterećenje vodova	0,12821	0,07246	0,10526	0,15385	0,45978	0,11494
Investicija	0,10256	0,05797	0,05263	0,07692	0,29009	0,07252

Na kraju ovoga koraka je potrebno provjeriti da li je ocjena važnosti kriterija izvršena na pravilan način, odnosno da li postoji konzistentnost u procjeni kriterija.

Prvo se, množenjem matrice usporedbe kriterija s vektorom težinskih vrijednosti prema jednadžbi 3.25, dobivaju vrijednosti vektora konzistencije:

$C_{v1} = 1,97291$
$C_{v2} = 1,39765$
$C_{v3} = 0,46312$
$C_{v4} = 0,29250$

Dijeljenjem ovih vrijednosti s odgovarajućim vrijednostima vektora težinskih vrijednosti dobiva se:

$$\lambda_1 = \frac{1,97291}{0,47455} = 4,15743$$

$$\lambda_2 = \frac{1,39765}{0,33798} = 4,13526$$

$$\lambda_3 = \frac{0,46312}{0,11494} = 4,02910$$

$$\lambda_4 = \frac{0,29250}{0,07252} = 4,03325$$

Prosječna vrijednost dobivenih vrijednosti je:

$$\lambda_{max} = \frac{4,15743 + 4,13526 + 4,02910 + 4,03325}{4} = 4,08876$$

Vrijednost indeksa konzistencije se dobiva prema jednadžbi 3.17 i iznosi:

CI = 0,02959

Prema tablici 3.2 za n = 4 je slučajni indeks RI = 0,9, pa je prema jednadžbi 3.18 omjer konzistencije:

$$CR = \frac{0,02959}{0,9} = 0,0329$$

Obzirom da je CR = 0,0329 < 0,1 može se konstatirati da su ocjene važnosti kriterija konzistentne (dosljedne), odnosno da je izvršeno pravilno rangiranje kriterija.

5.7.2. Rangiranje alternativa

Utvrđivanje konzistentnosti kriterija omogućuje proračun prioriteta alternativa u odnosu na zadane kriterije, odnosno rangiranje alternativa. Postupak se provodi za svaki kriterij posebno. Postupak je sličan postupku rangiranja kriterija.

Kriterij 1: Pad napona

Vrijednosti padova napona, koje se dobivaju proračunom tokova snaga za svako idejno rješenje, dane su u tablici 5.32.

Tablica 5.32. *Vrijednosti padova napona pojedinih alternativa*

Broj alternative	Alternativa	ΔU (V)
1	5 NN izvoda	$\Delta U_1 = -46,8$
2	6 NN izvoda	$\Delta U_2 = -44,0$
3	7 NN izvoda	$\Delta U_3 = -43,2$
4	8 NN izvoda	$\Delta U_4 = -40,4$

Prvo se uspostavlja matrica usporedbe alternativa kao u tablici 5.33.

Tablica 5.33. *Matrica usporedbe alternativa za kriterij 1*

Pad napona	Alternativa 1	Alternativa 2	Alternativa 3	Alternativa 4
Alternativa 1	$\frac{\Delta U_1}{\Delta U_1} = 1$	$\frac{\Delta U_2}{\Delta U_1} = 0{,}94017$	$\frac{\Delta U_3}{\Delta U_1} = 0{,}92308$	$\frac{\Delta U_4}{\Delta U_1} = 0{,}86325$
Alternativa 2	$\frac{\Delta U_1}{\Delta U_2} = 1{,}06364$	$\frac{\Delta U_2}{\Delta U_2} = 1$	$\frac{\Delta U_3}{\Delta U_2} = 0{,}98182$	$\frac{\Delta U_4}{\Delta U_2} = 0{,}91818$
Alternativa 3	$\frac{\Delta U_1}{\Delta U_3} = 1{,}08333$	$\frac{\Delta U_2}{\Delta U_3} = 1{,}01852$	$\frac{\Delta U_3}{\Delta U_3} = 1$	$\frac{\Delta U_4}{\Delta U_3} = 0{,}93519$
Alternativa 4	$\frac{\Delta U_1}{\Delta U_4} = 1{,}15842$	$\frac{\Delta U_2}{\Delta U_3} = 1{,}08911$	$\frac{\Delta U_3}{\Delta U_4} = 1{,}06931$	$\frac{\Delta U_4}{\Delta U_4} = 1$

Prema jednadžbi 3.22 težine redaka matrice usporedbe alternativa su:

$m_1 = 0{,}93035$
$m_2 = 0{,}98955$
$m_3 = 1{,}00788$
$m_4 = 1{,}07773$

Prema jednadžbi 3.19 vrijednosti prioriteta za matricu usporedbe alternativa su kako je to prikazano u tablici 5.34.

Tablica 5.34. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,94017	0,92308	0,86325	0,23227
Altern. 2	1,06364	1	0,98182	0,91818	0,24705
Altern. 3	1,08333	1,01852	1	0,93519	0,25162
Altern. 4	1,15842	1,08911	1,06931	1	0,26906

Kriterij 2: Gubici snage

Vrijednosti gubitaka radne snage, koje se dobivaju proračunom tokova snaga za svako idejno rješenje, dane su u tablici 5.35.

Tablica 5.35. *Vrijednosti gubitaka radne snage pojedinih alternativa*

Broj alternative	Alternativa	P_{gub} (kW)
1	5 NN izvoda	$P_{gub1} = 20{,}92$
2	6 NN izvoda	$P_{gub2} = 18{,}71$
3	7 NN izvoda	$P_{gub3} = 18{,}68$
4	8 NN izvoda	$P_{gub4} = 17{,}38$

Prema jednadžbi 3.22 težine redaka matrice usporedbe alternativa su:

$m_1 = 0,90251$
$m_2 = 1,00912$
$m_3 = 1,01074$
$m_4 = 1,08634$

Matrica usporedbe alternativa i vrijednosti prioriteta za kriterij 2 dani su u tablici 5.36.

Tablica 5.36. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89436	0,89293	0,83078	0,22514
Altern. 2	1,11812	1	0,99840	0,92892	0,25173
Altern. 3	1,11991	1,00161	1	0,93041	0,25214
Altern. 4	1,20368	1,07652	1,07480	1	0,27099

Kriterij 3: Opterećenje vodova

Vrijednosti prosječnog opterećenja niskonaponskih vodova, koje se dobivaju proračunom tokova snaga za svako idejno rješenje, dane su u tablici 5.37.

Tablica 5.37. *Vrijednosti prosječnog opterećenja vodova pojedinih alternativa*

Broj alternative	Alternativa	$I_{prosječno}$ (%)
1	5 NN izvoda	$I_{prosječno1} = 57,80$
2	6 NN izvoda	$I_{prosječno2} = 47,90$
3	7 NN izvoda	$I_{prosječno3} = 41,05$
4	8 NN izvoda	$I_{prosječno4} = 35,80$

Prema jednadžbi 3.22 težine redaka matrice usporedbe alternativa su:

$m_1 = 0,77700$
$m_2 = 0,93769$
$m_3 = 1,09405$
$m_4 = 1,25453$

Matrica usporedbe alternativa i vrijednosti prioriteta za kriterij 3 dani su u tablici 5.38.

Tablica 5.38. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,82863	0,71021	0,61935	0,19123
Altern. 2	1,20681	1	0,85708	0,74744	0,23077
Altern. 3	1,40804	1,16675	1	0,87208	0,26925
Altern. 4	1,61459	1,33790	1,14669	1	0,30875

Kriterij 4: Investicije

Ukupne procijenjene vrijednosti investicija za svako idejno rješenje dane su u tablici 5.39.

Tablica 5.39. *Vrijednosti investicija pojedinih alternativa*

Broj alternative	Alternativa	T_{inv} (€)
1	5 NN izvoda	T_{inv1} = 207.395
2	6 NN izvoda	T_{inv2} = 238.631
3	7 NN izvoda	T_{inv3} = 263.265
4	8 NN izvoda	T_{inv4} = 268.912

Prema jednadžbi 3.22 težine redaka matrice usporedbe alternativa su:

m_1 = 1,17310
m_2 = 1,01954
m_3 = 0,92414
m_4 = 0,90474

Matrica usporedbe alternativa i vrijednosti prioriteta za kriterij 4 dani su u tablici 5.40.

Tablica 5.40. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Prethodnim postupkom su dobivene vrijednosti prioriteta alternativa u odnosu na kriterije. Množenjem ovih vrijednosti sa vrijednostima prioriteta matrice usporedbe kriterija dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23227 \\ 0{,}24705 \\ 0{,}25162 \\ 0{,}26906 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22514 \\ 0{,}25173 \\ 0{,}25214 \\ 0{,}27099 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19123 \\ 0{,}23077 \\ 0{,}26925 \\ 0{,}30875 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22947 \\ 0{,}24725 \\ 0{,}25223 \\ 0{,}27105 \end{bmatrix}$$

Očito je da rješenje 4 daje najbolje rezultate. Dakle, alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže.

Može se zaključiti da rješenja ovise o bodovanju kriterija, kao i o formiranju idejnih rješenja. To znači da će iskusni inženjeri–planeri postizati bolje rezultate, budući da imaju više iskustva sa planiranjem mreža i mogu ponuditi najbolja prostorna rješenja u ovisnosti o broju niskonaponskih izvoda.

I pored toga, i manje iskusni inženjeri mogu postići zadovoljavajuće rezultate obzirom da se na kraju ipak pokazuje da dobivanje najboljeg prostornog rješenja nije upitno. Najvažnije je izvršiti pravilan odabir i vrednovanje kriterija, te formirati idejna rješenja s najmanjom mogućom dužinom mreže, uvažavajući topološka ograničenja u rasprostiranju mreže, odnosno pravilno odabrati presjeke vodiča pri njenom formiranju.

5.8. OPTIMALNO RJEŠENJE

Prethodnim postupkom odabire se najbolje prostorno rješenje za niskonaponsku distribucijsku mrežu koja treba napajati potrošače na danom zemljopisnom području. To, međutim, ne znači da je ono i najbolje kada se promatraju padovi napona kod krajnjih potrošača, gubici snage i sl. U biti, ovakvo rješenje nije uvijek optimalno, iako to može biti.

Za dobivanje optimalnog rješenja u predloženom modelu planiranja koristi se algoritam simuliranog kaljenja. Prema ovom algoritmu je za dobivanje optimalnog uklopnog stanja mreže neophodno samo, na odabranom prostornom rješenju, dodati određeni broj međuveza između potrošača, odnosno stvoriti međuveze kao na slici 5.21 (dijelovi mreže, odnosno vodovi označeni crnom bojom).

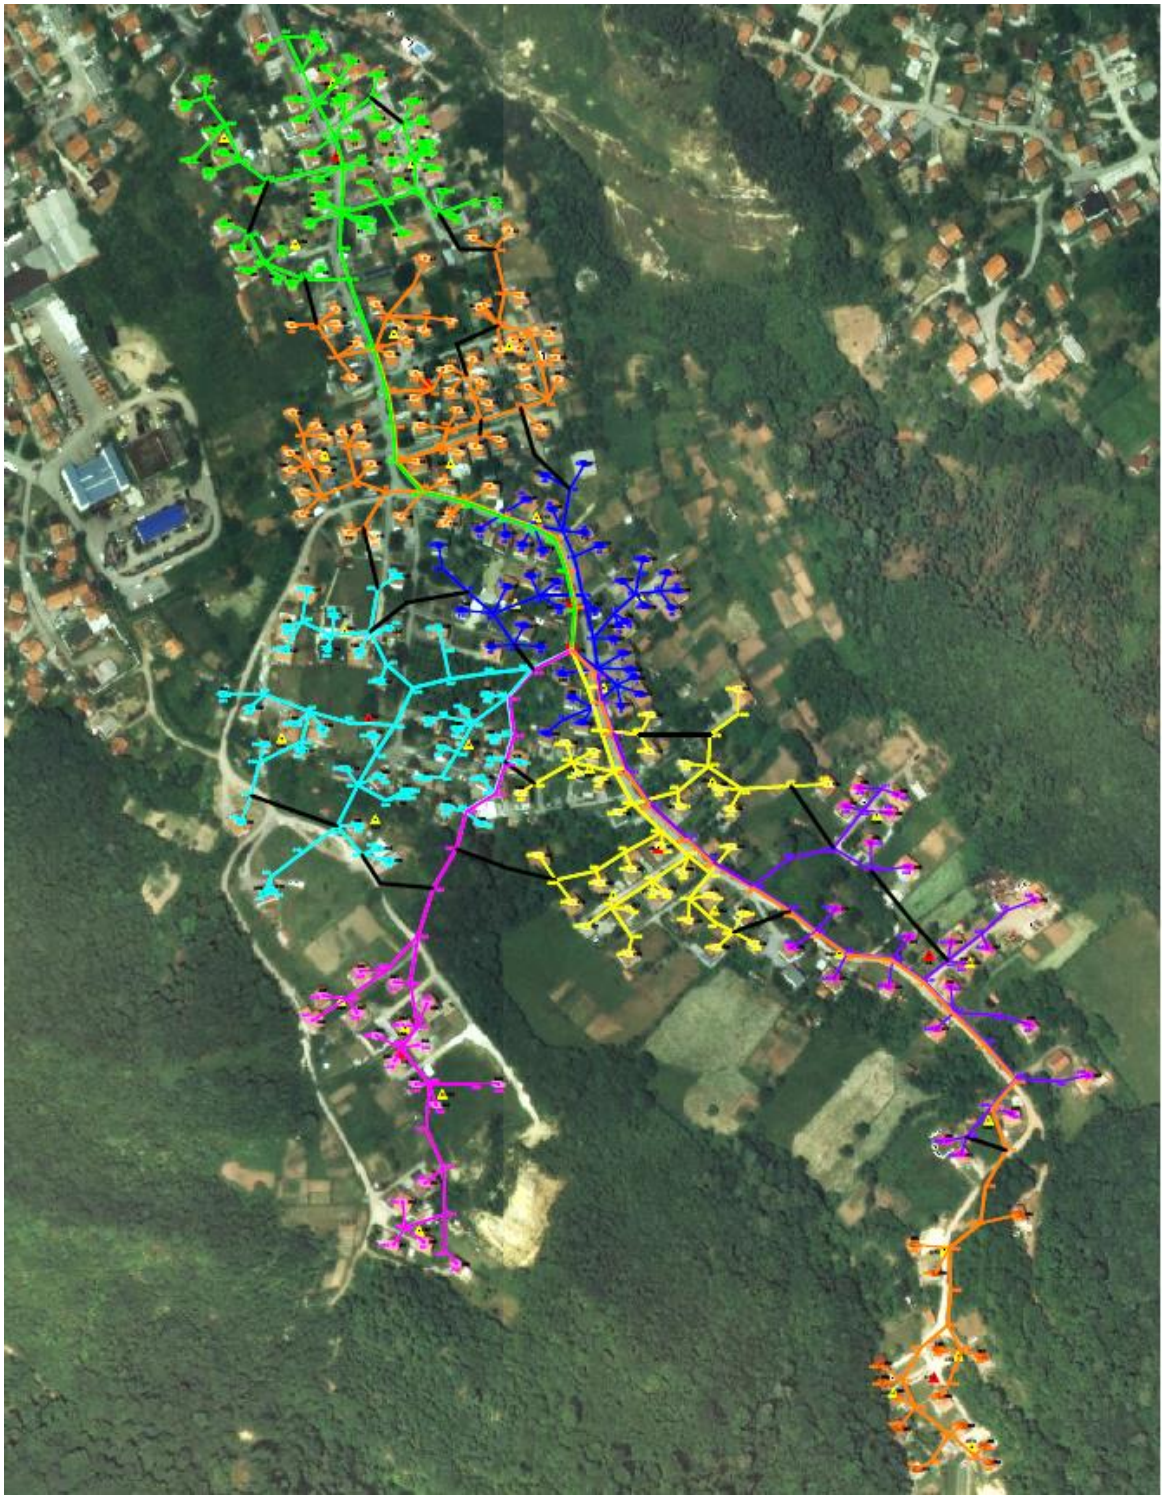

Slika 5.21. *Uspostavljanje međuveza u niskonaponskoj distribucijskoj mreži*

Broj međuveza koje je potrebno uspostaviti nije ograničen. Što više, veći broj međuveza znači dobivanje najboljeg mogućeg rješenja. U tom slučaju vrijeme proračuna se nešto produžava, ali ono nije presudno za primjenu modela. Bitno je samo voditi računa da se i međuveze uspostavljaju prema topološkim mogućnostima, s pravilnim odabirom vodiča, kao i njihovih dužina.

Pošto algoritam simuliranog kaljenja radi na principu otvaranja i zatvaranja mrežnih prekidača, u biti se može smatrati da svaka od novoformiranih međuveza predstavlja prekidač koji je potrebno uključiti ili isključiti, u ovisnosti o optimalnoj konfiguraciji mreže.

Što se tiče ostatka mreže svaka dionica, na isti način, može se promatrati kao prekidač čije stanje (uključen/isključen) definira optimalna konfiguracija. Međutim, to bi vrijeme proračuna produžilo do u nedogled, bez ikakvih značajnijih učinaka. Stoga se, osim novoformiranih, mora definirati i određeni broj postojećih dionica koje će biti predstavljene kao prekidači. Potrebno je odabrati samo dionice koje u biti služe za razbijanje petlji koje se stvaraju uključivanjem novoformiranih dionica. Njihovim uključivanjem, odnosno isključivanjem ponovno se uspostavlja radijalna konfiguracija mreže.

U danom primjeru definirana su ukupno 42 prekidača, od kojih je 19 isključenih (novoformirane dionice označene podebljanom crnom bojom) i 23 uključena (postojeće dionice najboljeg idejnog rješenja označene podebljanom crvenom bojom) kao na slici 5.22.

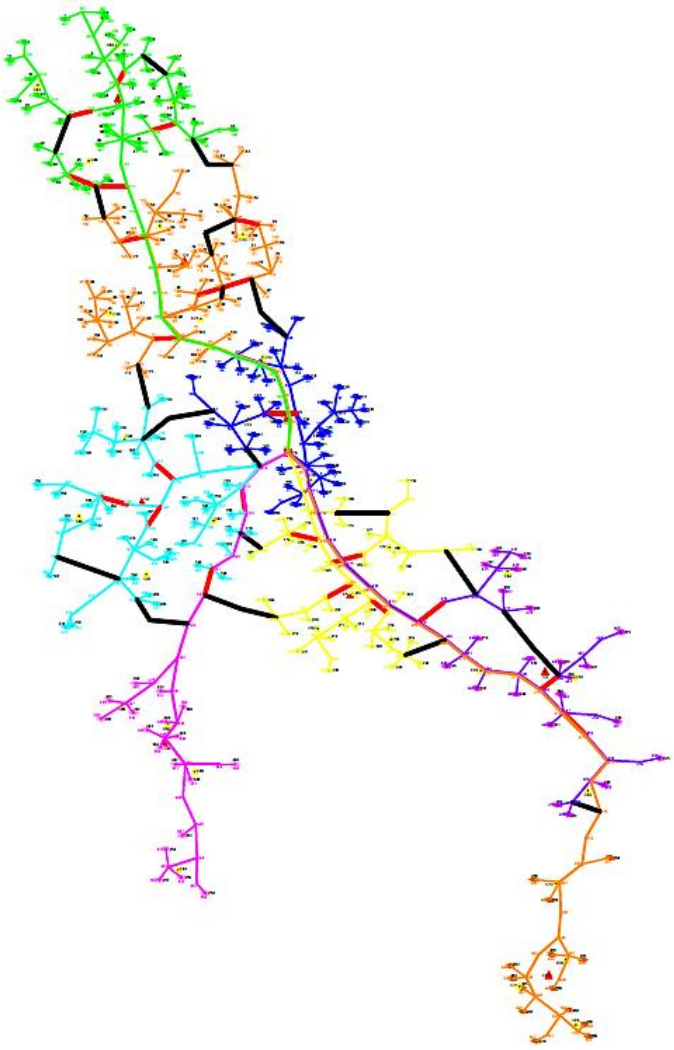

Slika 5.22. *Definiranje mrežnih prekidača*

Nakon definiranja dionica (prekidača) definiraju se i ulazni podaci za algoritam simuliranog kaljenja. Ulazni podaci su dani u prilozima 18 i 19. Za dobivanje optimalnog uklopnog stanja upotrebljava se specijalizirani algoritam, posebno priređen u Matlab–u, temeljen na metodi simuliranog kaljenja.

Odabrana polazna temperatura simuliranja je T = 1000, a krajnja T = 0,000001. Odabrani faktor hlađenja je 0,95. Ukupno je provedeno 405 simulacija pri čemu je uspješno uspostavljeno 310 mogućih konfiguracija. Ukupno vrijeme trajanja simulacija je 7,4 minute. Iznos gubitaka radne snage je P_{gub} = 13,09 kW, a maksimalni pad napona kod krajnjih potrošača je ΔU = – 7,5%.

Na slici 5.23 je prikazano kretanje gubitaka radne snage pri procesu simuliranja.

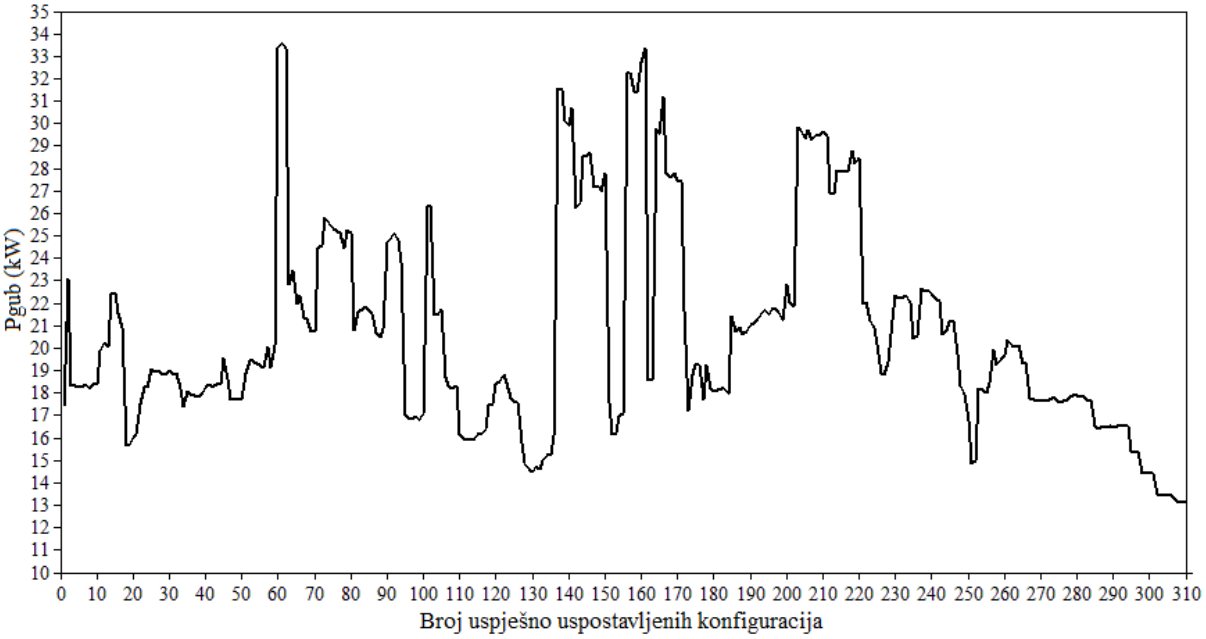

Slika 5.23. *Kretanje gubitaka radne snage pri procesu simuliranog kaljenja*

U tablici 5.41 je prikazana usporedba između vrijednosti padova napona kod krajnjih potrošača i gubitaka radne snage najboljeg prostornog i optimalnog rješenja.

Tablica 5.41. *Usporedni rezultati padova napona i gubitaka radne snage*

Najbolje rješenje	ΔU (%)	P_{gub} (kW)
Prostorno	– 10,1	17,38
Optimalno	– 7,5	13,09
Razlika:	2,6	4,29

Rezultati o stanju definiranih prekidača pokazuju da je potrebno promijeniti status dionica (prekidača) danih u tablici 5.42.

Tablica 5.42. *Status dionica (uključen/isključen) nakon provedenog simuliranog kaljenja*

Iz čvora	U čvor	Status prije simuliranog kaljenja	Status nakon simuliranog kaljenja
36	114	0	1
73	276	0	1
147	172	0	1
179	213	0	1
316	53	0	1
323	309	0	1
357	379	0	1
421	440	0	1
469	407	0	1
29	46	1	0
69	72	1	0
106	114	1	0
171	172	1	0
212	213	1	0
285	299	1	0
368	370	1	0
391	401	1	0
439	440	1	0

Iz tablice 5.41 može se uočiti da, u odnosu na najbolje prostorno rješenje, optimalno rješenje daje bolje rezultate. Dobivaju se bolji rezultati i kada se radi o naponskim prilikama kao i o gubicima radne snage. Dakle, primjenom predloženog modela planiranja u konačnici se dobivaju najbolji mogući rezultati.

Kao zaključak provedenog procesa simuliranja može se reći da dobiveni rezultati ne ovise o izboru polazne temperature kaljenja. Naime, isti rezultati se dobivaju i kada proces simuliranog kaljenja započne na visokoj temperaturi (T = 1000), kao i na niskoj temperaturi (T = 100). Isto tako, dobiveni rezultati ne ovise o brzini hlađenja. Isti rezultati se dobivaju i kada se uspostavi brzo hlađenje (faktor 0,95), kao i sporo hlađenje (faktor 0,99).

Uvijek, međutim, kada vrijeme nije odlučujući faktor, je bolje simuliranje vršiti sa visokom polaznom temperaturom i sporim hlađenjem, jer ponekad preniska polazna temperatura (ispod T = 100) i prebrzo hlađenje (0,90), kod mreža sa znatno većim brojem sabirnica i puno većim brojem prekidača, mogu dovesti do toga da se ne postigne optimalno rješenje. U takvim slučajevima naprosto nedostaje potreban broj simulacija kako bi se dostiglo optimalno rješenje. Također, povećavanje krajnje temperature uzrokuje smanjenje broja simulacija što može dovesti do istoga problema. Visoka polazna temperatura i sporo hlađenje, uz dovoljno nisku krajnju temperaturu hlađenja garantiraju sigurno dobivanje optimalnog rješenja.

Na slici 5.24 je dan usporedni prikaz najboljeg prostornog i optimalnog rješenja.

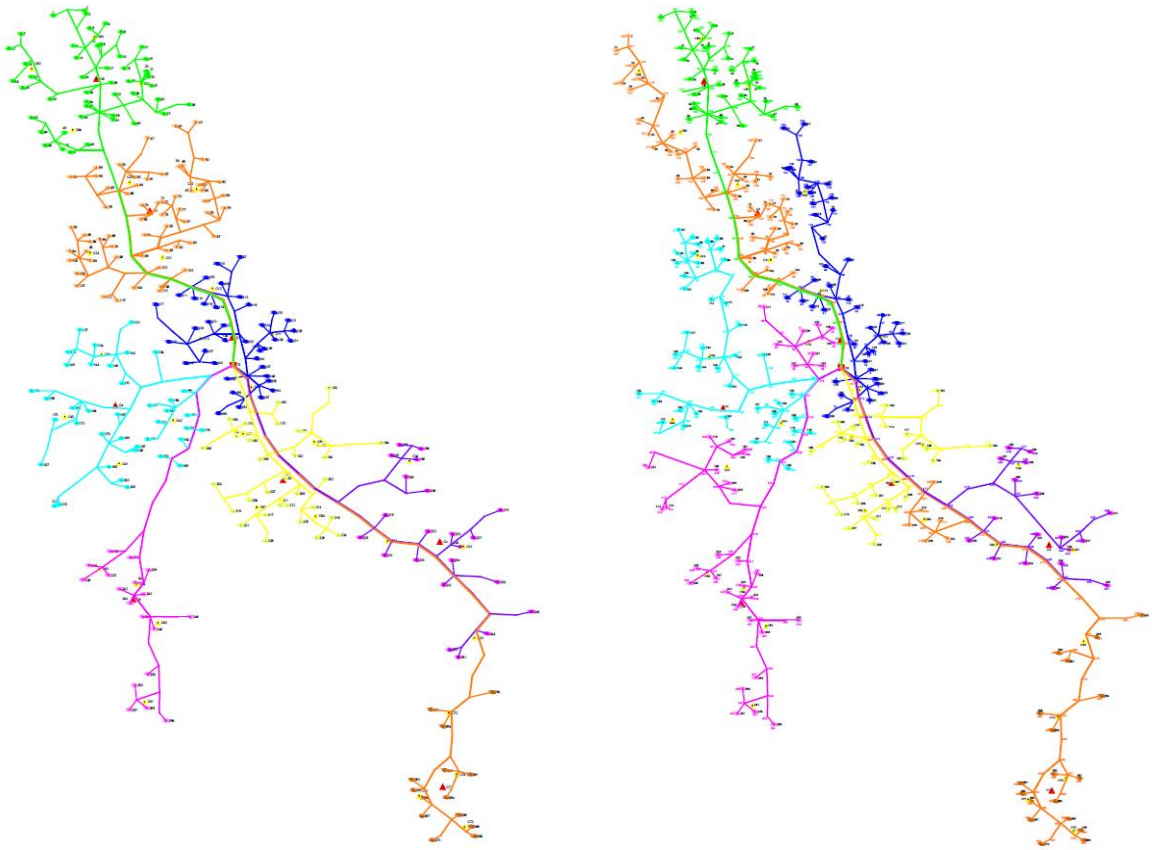

a) b)

Slika 5.24. *Usporedni prikaz najboljeg prostornog i optimalnog rješenja*

Dakle, primjenom predloženog modela planiranja dobiveno je novo, optimalno uklopno stanje postojeće niskonaponske distribucijske mreže. Temeljem ovoga se može vršiti planiranje rekonstrukcije postojeće mreže u cilju smanjenja padova napona kod krajnjih potrošača, kao i ukupnih gubitaka radne snage. Isto tako, jedno ovakvo rješenje daje mogućnost procjene potrebnih investicijskih ulaganja što daje mogućnost planiranja i osiguravanja potrebnih financijskih sredstava.

5.9. UTJECAJ OPTEREĆENJA POTROŠAČA NA PROSTORNO RJEŠENJE

Najbolje prostorno rješenje je dobiveno korištenjem podataka o opterećenju potrošača dobivenih proračunom temeljem jednodnevnog, satnog, vršnog opterećenja niskonaponskih izvoda (dan sa godišnjim vršnim opterećenjem transformatorske stanice) i ukupne utrošene godišnje energije svakog potrošača. Na taj način su u biti dobivena vršna opterećenja potrošača na godišnjoj razini. Postavljaju se pitanja da li ovo rješenje ovisi o vrijednostima opterećenja potrošača i kako dobiti ove podatke ukoliko ne postoje podaci o opterećenosti niskonaponskih izvoda, odnosno transformatorske stanice za svaki dan u godini. Obzirom da su dostupni svi ovi podaci u nastavku su prezentirani proračuni koji se temelje na različitim iznosima dnevnih opterećenja transformatorske stanice.

5.9.1. Minimalno opterećenje transformatorske stanice

Minimalna opterećenja potrošača se dobivaju na isti način kao u prethodnome slučaju, s tim da se odabire dan sa najnižim opterećenjem transformatorske stanice. Podaci o opterećenju potrošača dani su u prilogu 20. U cijelosti je primijenjen identičan pristup kao u prethodnom slučaju.

Obzirom da su kriteriji rangirani kao u prethodnom slučaju, vrijednosti prioriteta kriterija su:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama investicijski troškovi su isti kao u prethodnom slučaju. Dobiveni rezultati su prikazani u tablici 5.43.

Tablica 5.43. *Vrijednosti kriterija pri minimalnom opterećenju potrošača*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 25,2	6,29	32,28	207.395
6	– 23,6	5,64	26,82	238.631
7	– 23,2	5,33	22,96	263.265
8	– 22,0	5,26	20,08	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.44–5.47.

Tablica 5.44. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. opter.)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,93651	0,92063	0,87302	0,23259
Altern. 2	1,06780	1	0,98305	0,93220	0,24836
Altern. 3	1,08621	1,01724	1	0,94828	0,25264
Altern. 4	1,14545	1,07273	1,05455	1	0,26642

Tablica 5.45. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (min. opter.)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89666	0,84738	0,83625	0,22266
Altern. 2	1,11525	1	0,94504	0,93262	0,24832
Altern. 3	1,18011	1,05816	1	0,98687	0,26276
Altern. 4	1,19582	1,07224	1,01331	1	0,26626

Tablica 5.46. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (min. opter.)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,83087	0,71115	0,62207	0,19167
Altern. 2	1,20355	1	0,85591	0,74869	0,23069
Altern. 3	1,40618	1,16835	1	0,87474	0,26952
Altern. 4	1,60754	1,33566	1,14320	1	0,30812

Tablica 5.47. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (min. opter.)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23259 \\ 0{,}24836 \\ 0{,}25264 \\ 0{,}26642 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22266 \\ 0{,}24832 \\ 0{,}26276 \\ 0{,}26626 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19167 \\ 0{,}23069 \\ 0{,}26952 \\ 0{,}30812 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22883 \\ 0{,}24672 \\ 0{,}25633 \\ 0{,}26811 \end{bmatrix}$$

I u ovome slučaju rješenje 4 daje najbolje rezultate, odnosno alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže.

5.9.2. Opterećenje transformatorske stanice u proljetnom periodu

I ova opterećenja potrošača se dobivaju na isti način kao u prethodnim slučajevima, s tim da je odabran dan s vršnim opterećenjem transformatorske stanice u tromjesečnom periodu. U ovom slučaju radi se o periodu proljeća, s tim da se za proračun koriste podaci o tromjesečnoj utrošenoj energiji svakog potrošača i jednodnevnom, satnom očitanju opterećenja niskonaponskih izvoda i transformatorske stanice na dan vršnog opterećenja tog perioda. Podaci o opterećenju potrošača dani su u prilogu 21. I u ovome slučaju u cijelosti je primijenjen identičan pristup kao u prethodnim slučajevima.

Obzirom da su kriteriji rangirani na isti način, vrijednosti prioriteta kriterija su:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima. Dobiveni rezultati su prikazani u tablici 5.48.

Tablica 5.48. *Vrijednosti kriterija pri opterećenju potrošača u periodu proljeća*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 39,6	14,32	47,77	207.395
6	– 37,6	12,80	39,62	238.631
7	– 37,2	12,77	33,96	263.265
8	– 35,2	11,81	29,63	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.49–5.52.

Tablica 5.49. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (proljeće)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,94949	0,93939	0,88889	0,23570
Altern. 2	1,05319	1	0,98936	0,93617	0,24824
Altern. 3	1,06452	1,01075	1	0,94624	0,25090
Altern. 4	1,12500	1,06818	1,05682	1	0,26516

Tablica 5.50. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (proljeće)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89385	0,89176	0,82472	0,22458
Altern. 2	1,11875	1	0,99766	0,92266	0,25125
Altern. 3	1,12138	1,00235	1	0,92482	0,25184
Altern. 4	1,21253	1,08383	1,08129	1	0,27232

Tablica 5.51. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (proljeće)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,82943	0,71086	0,62015	0,19139
Altern. 2	1,20564	1	0,85704	0,74768	0,23075
Altern. 3	1,40675	1,16680	1	0,87239	0,26924
Altern. 4	1,61252	1,33748	1,14628	1	0,30862

Tablica 5.52. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (proljeće)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23570 \\ 0{,}24824 \\ 0{,}25090 \\ 0{,}26516 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22458 \\ 0{,}25125 \\ 0{,}25184 \\ 0{,}27232 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19139 \\ 0{,}23075 \\ 0{,}26924 \\ 0{,}30862 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}23094 \\ 0{,}24766 \\ 0{,}25179 \\ 0{,}26962 \end{bmatrix}$$

Dakle, rješenje 4 daje najbolje rezultate, odnosno i u ovom slučaju alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže.

5.9.3. Opterećenje transformatorske stanice u ljetnom periodu

Kao i u prethodnim slučajevima odabran je dan sa vršnim opterećenjem transformatorske stanice i to u periodu ljeta i tromjesečnom utrošenom energijom potrošača za taj period. Podaci o opterećenju potrošača dani su u prilogu 22. I u ovom slučaju u cijelosti je primijenjen identičan pristup kao u prethodnim slučajevima.

Obzirom da su kriteriji rangirani na isti način vrijednosti prioriteta kriterija su:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.53.

Tablica 5.53. *Vrijednosti kriterija pri opterećenju potrošača u periodu ljeta*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 44,0	19,94	57,47	207.395
6	– 41,2	17,95	47,65	238.631
7	– 40,8	17,89	40,84	263.265
8	– 38,0	16,67	35,62	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.54–5.57.

Tablica 5.54. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (ljeto)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,93636	0,92727	0,86364	0,23233
Altern. 2	1,06796	1	0,99029	0,92233	0,24812
Altern. 3	1,07843	1,00980	1	0,93137	0,25055
Altern. 4	1,15789	1,08421	1,07368	1	0,26901

Tablica 5.55. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (ljeto)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,90020	0,89719	0,83601	0,22616
Altern. 2	1,11086	1	0,99666	0,92869	0,25123
Altern. 3	1,11459	1,00335	1	0,93181	0,25208
Altern. 4	1,19616	1,07678	1,07319	1	0,27053

Tablica 5.56. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (ljeto)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,82907	0,71051	0,61975	0,19131
Altern. 2	1,20618	1	0,85699	0,74753	0,23075
Altern. 3	1,40745	1,16687	1	0,87226	0,26926
Altern. 4	1,61356	1,33775	1,14644	1	0,30869

Tablica 5.57. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (ljeto)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23233 \\ 0{,}24812 \\ 0{,}25055 \\ 0{,}26901 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22616 \\ 0{,}25123 \\ 0{,}25208 \\ 0{,}27053 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19131 \\ 0{,}23075 \\ 0{,}26926 \\ 0{,}30869 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22985 \\ 0{,}24759 \\ 0{,}25170 \\ 0{,}27086 \end{bmatrix}$$

Alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže i u ovom slučaju.

5.9.4. Opterećenje transformatorske stanice u jesenskom periodu

U ovome primjeru je odabran dan sa vršnim opterećenjem transformatorske stanice i to u periodu jeseni i tromjesečnom utrošenom energijom potrošača za taj period. Podaci o opterećenju potrošača dani su u prilogu 23. I u ovome slučaju je u cijelosti primijenjen identičan pristup kao u prethodnim slučajevima.

Obzirom da su kriteriji rangirani na isti način, vrijednosti prioriteta kriterija su:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.58.

Tablica 5.58. *Vrijednosti kriterija pri opterećenju potrošača u periodu jeseni*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 36,8	13,90	47,85	207.395
6	– 34,4	12,45	39,70	238.631
7	– 34,0	12,46	34,03	263.265
8	– 30,8	11,64	29,70	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.59–5.62.

Tablica 5.59. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (jesen)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,93478	0,92391	0,83696	0,23005
Altern. 2	1,06977	1	0,98837	0,89535	0,24610
Altern. 3	1,08235	1,01176	1	0,90588	0,24899
Altern. 4	1,19481	1,11688	1,10390	1	0,27486

Tablica 5.60. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (jesen)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89568	0,89640	0,83741	0,22593
Altern. 2	1,11647	1	1,00080	0,93494	0,25224
Altern. 3	1,11557	0,99920	1	0,93419	0,25204
Altern. 4	1,19416	1,06959	1,07045	1	0,26979

Tablica 5.61. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (jesen)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,82958	0,71110	0,62062	0,19146
Altern. 2	1,20542	1	0,85718	0,74811	0,23079
Altern. 3	1,40627	1,16662	1	0,87276	0,26925
Altern. 4	1,61130	1,33671	1,14580	1	0,30850

Tablica 5.62. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (jesen)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23005 \\ 0{,}24610 \\ 0{,}24899 \\ 0{,}27486 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22593 \\ 0{,}25224 \\ 0.25204 \\ 0{,}26979 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19146 \\ 0{,}23079 \\ 0{,}26925 \\ 0{,}30850 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22870 \\ 0{,}24697 \\ 0{,}25094 \\ 0{,}27339 \end{bmatrix}$$

I ovdje, alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže.

5.9.5. Opterećenje transformatorske stanice u zimskom periodu

U ovome primjeru je odabran dan sa vršnim opterećenjem transformatorske stanice i to u periodu zime i tromjesečnom utrošenom energijom potrošača za taj period. Podaci o opterećenju potrošača dani u prilogu 24. I u ovome slučaju je u cijelosti primijenjen identičan pristup kao u prethodnim slučajevima.

Obzirom da su kriteriji rangirani na isti način, vrijednosti prioriteta kriterija su:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.63.

Tablica 5.63. *Vrijednosti kriterija pri opterećenju potrošača u periodu zime*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 42,8	16,87	51,95	207.395
6	– 39,6	15,06	43,07	238.631
7	– 39,2	15,00	36,91	263.265
8	– 36,8	14,01	32,20	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.64–5.67.

Tablica 5.64. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (zima)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,92523	0,91589	0,85981	0,23064
Altern. 2	1,08081	1	0,98990	0,92929	0,24928
Altern. 3	1,09184	1,01020	1	0,93878	0,25183
Altern. 4	1,16304	1,07609	1,06522	1	0,26825

Tablica 5.65. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (zima)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89271	0,88915	0,83047	0,22477
Altern. 2	1,12019	1	0,99602	0,93028	0,25178
Altern. 3	1,12467	1,00400	1	0,93400	0,25279
Altern. 4	1,20414	1,07495	1,07066	1	0,27065

Tablica 5.66. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (zima)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,82905	0,71049	0,61992	0,19132
Altern. 2	1,20619	1	0,85698	0,74775	0,23077
Altern. 3	1,40749	1,16688	1	0,87253	0,26928
Altern. 4	1,61310	1,33735	1,14609	1	0,30862

Tablica 5.67. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (zima)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23064 \\ 0{,}24928 \\ 0{,}25183 \\ 0{,}26825 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22477 \\ 0{,}25178 \\ 0.25279 \\ 0{,}27065 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19132 \\ 0{,}23077 \\ 0{,}26928 \\ 0{,}30862 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22858 \\ 0{,}24834 \\ 0{,}25255 \\ 0{,}27053 \end{bmatrix}$$

I ovo rješenje, alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže.

5.10. UTJECAJ NESIMETRIJE NA PROSTORNO RJEŠENJE

Pojam nesimetrije podrazumijeva neravnomjeran raspored opterećenja po fazama niskonaponske mreže. Obično je posljedica samih kupaca: nesimetričan raspored trošila po fazama u instalaciji kupca, kao i neravnomjeran faktor istodobnosti trošila priključenih na različite faze [90]. Najviše je ipak izražena nesimetrija koja je posljedica neravnomjernog priključenja jednofaznih potrošača po fazama, tako da u određenom trenutku sve tri faze u mreži nisu podjednako opterećene, te se kao posljedica javljaju nesimetrični naponi.

Nesimetričnost napona napajanja se procjenjuje metodom simetričnih komponenti. Naime, u uvjetima nesimetričnosti osim direktne komponente napona U_d postoji najmanje jedna od dvije komponente: inverzna U_i i/ili nulta U_0.

Nesimetrija je definirana Europskom normom EN50160. Osnovna komponenta napona se mjeri u 10–minutnom vremenskom intervalu za 50 Hz sustave ili 12–minutnom vremenskom intervalu za 60 Hz sustave. Prema Europskoj normi EN 50160, pri normalnim pogonskim uvjetima 95% 10–minutnih srednjih vrijednosti efektivne vrijednosti inverzne, odnosno nulte komponente napona ne smije, unutar svakog tjednog intervala, prelaziti 2% odgovarajuće direktne komponente. U iznimnim prilikama mogu se dozvoliti i nesimetrije do 3% [91], [92]. Prema ovoj normi vrijedi:

$$u_i(\%) = \frac{U_i}{U_d} \cdot 100\% \tag{5.1}$$

$$u_0(\%) = \frac{U_0}{U_d} \cdot 100\% \tag{5.2}$$

Obzirom da je za postojeću mrežu postojao veći broj 15–minutnih očitanja napona tijekom perioda od godinu dana primijenjen je proračun nesimetrije prema Standardu IEC 61000–4–30, koji je ranije bio u uporabi. Prema ovom Standardu vrijedi da za trofazni sustav, promatrajući samo osnovne harmonike linijskih napona, vrijedi [92]:

$$u_i(\%) = \sqrt{\frac{1 - \sqrt{3 - 6\beta}}{1 + \sqrt{3 - 6\beta}}} \cdot 100\% \tag{5.3}$$

pri čemu je

$$\beta = \frac{U_{12}^4 + U_{23}^4 + U_{31}^4}{\left(U_{12}^2 + U_{23}^2 + U_{31}^2\right)^2} \tag{5.4}$$

gdje su 1, 2, 3 oznake faza, a U_{12} , U_{23} i U_{31} su osnovni harmonici linijskih napona.

Dakle, prema jednadžbama 5.3 i 5.4, izračunate su postotne vrijednosti nesimetrije, odnosno inverzne komponente napona. Temeljem tih vrijednosti određene se maksimalna i minimalna

vrijednost nesimetrije, te vrijednost standardne devijacije. U slučaju razmatrane mreže ove vrijednosti su:

$u_{max} = 0{,}284488$
$u_{min} = 0$
$\sigma = 0{,}039591$

Nadalje, potrebno je odrediti prema kojoj razdiobi su raspoređene proračunate vrijednosti nesimetrije. Temeljem rezultata prikazanih u tablici 5.68 dolazi se do zaključka da su vrijednosti nesimetrije raspoređene približno Gaussovoj razdiobi.

Tablica 5.68. *Razdioba proračunatih vrijednosti nesimetrije*

Interval	Broj	p–stvarno	p–gauss
0,005	40	0,332419	1,107567
0,015	278	2,310313	1,824040
0,025	566	4,703731	2,818330
0,035	549	4,562453	4,085474
0,045	456	3,789579	5,556307
0,055	994	8,260617	7,089625
0,065	1089	9,050112	8,486986
0,075	1421	11,809191	9,531844
0,085	1213	10,080612	10,043695
0,095	1001	8,318790	9,928950
0,105	1096	9,108286	9,208869
0,115	964	8,011302	8,013135
0,125	766	6,365827	6,541719
0,135	483	4,013962	5,010423
0,145	299	2,484833	3,600395
0,155	244	2,027757	2,427276
0,165	205	1,703648	1,535258
0,175	138	1,146846	0,911038
0,185	83	0,689770	0,507207
0,195	44	0,365661	0,264927
0,205	33	0,274246	0,129826
0,215	28	0,232693	0,059688
0,225	15	0,124657	0,025746
0,235	9	0,074794	0,010419
0,245	5	0,041552	0,003956
0,255	7	0,058173	0,001409
0,265	5	0,041552	0,000471
0,275	1	0,008310	0,000148
0,285	1	0,008310	0,000043

Ovi rezultati su grafički prikazani na slici 5.25 na kojoj se može uočiti približna podudarnost stvarne razdiobe s normalnom Gaussovom razdiobom.

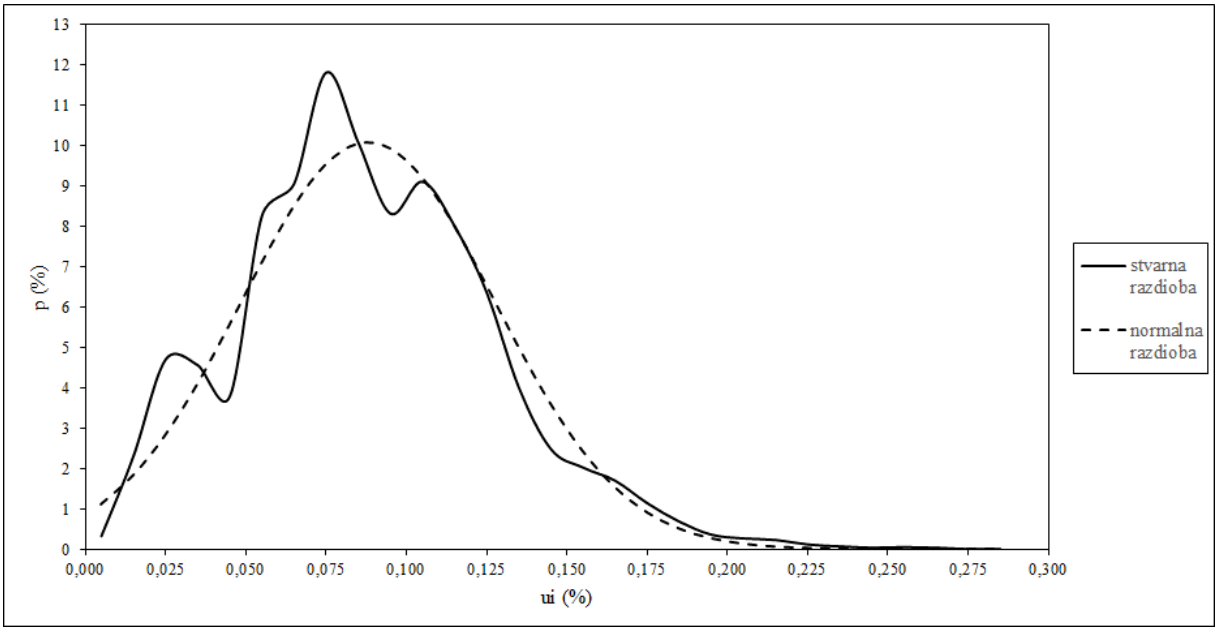

Slika 5.25. *Razdioba proračunatih vrijednosti nesimetrije*

Temeljem rezultata iz tablice 5.68 dobiva se vrijednost prosječne nesimetrije, a sa slike 5.25 može se uočiti najvjerojatnija vrijednost nesimetrije. Ove vrijednosti u ovom slučaju iznose:

$u_{prosječno}$ = 0,088199
$u_{najvjerojatnije}$ = 0,075

Kako bi se potvrdila valjanost ovih proračunatih vrijednosti dobivenih temeljem starog Standarda na transformatorskoj stanici je izvršeno mjerenje naponske nesimetrije instrumentom Mavowatt 50 i to u dva sedmodnevna vremenska intervala, u 10–minutnim ciklusima, prema Europskoj normi EN50160. Rezultati dobivenih mjerenja prikazani su na slikama 5.26 i 5.27.

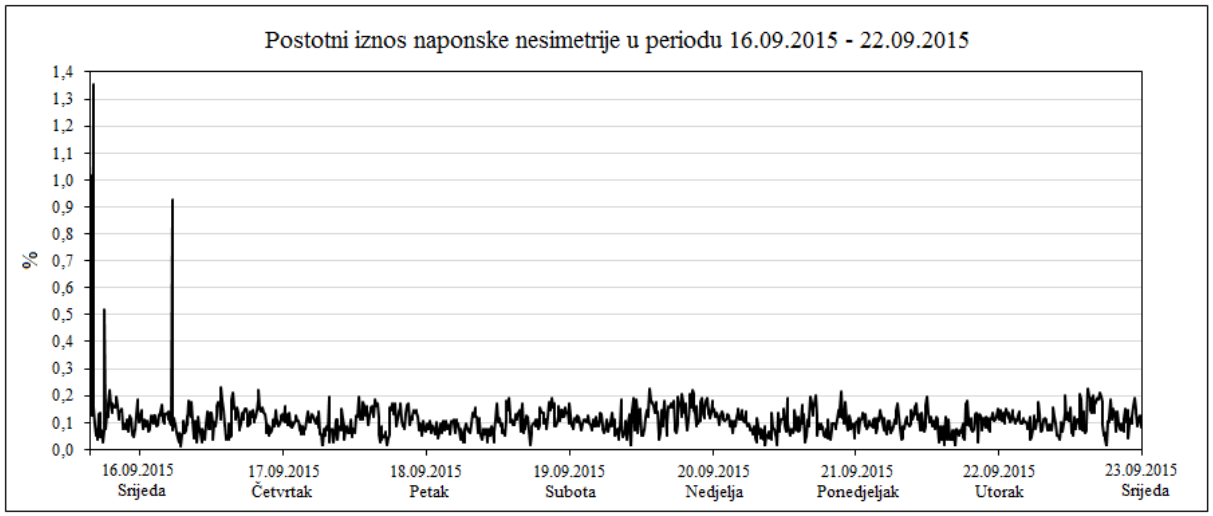

Slika 5.26. *Naponska nesimetrija u prvom sedmodnevnom vremenskom intervalu*

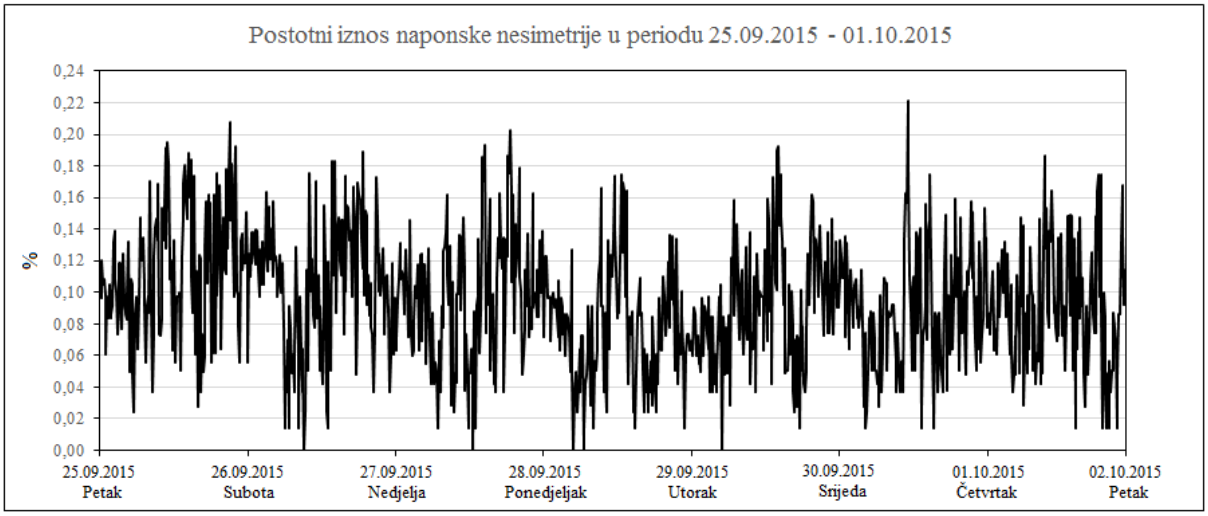

Slika 5.27. *Naponska nesimetrija u drugom sedmodnevnom vremenskom intervalu*

Može se zaključiti da su rezultati mjerenja slični proračunatim vrijednostima. Prosječna vrijednost mjerene nesimetrije u prvom intervalu je $u_{prosječno}$ = 0,10799, a u drugom intervalu $u_{prosječno}$ = 0,09472. Dakle, proračunata vrijednost ne odstupa značajno. Osim toga, sve mjerene vrijednosti nesimetrije su 100% unutar granica propisanih normom, odnosno < 2%.

Može se reći da iako je proračunata maksimalna vrijednost nesimetrije u_{max} = 0,284488 << 2% što implicira zaključak da nesimetrija ne utječe bitno na rezultate, kako bi se to potvrdilo odabrana su očitanja opterećenja transformatorske stanice u dane kada se pojavljuju karakteristične vrijednosti nesimetrije (maksimalna, minimalna, prosječna i najvjerojatnija), te je temeljem njih izvršen proračun opterećenja svih potrošača. Prema istom modelu kao i ranije proveden je postupak kako bi se utvrdilo da li nesimetrija utječe na odabir prostornog rješenja niskonaponske distribucijske mreže. U nastavku su prikazani dobiveni rezultati.

5.10.1. Prostorno rješenje pri maksimalnoj vrijednosti nesimetrije

U ovome primjeru je odabran dan s opterećenjem transformatorske stanice pri maksimalnoj nesimetriji i utrošenom energijom potrošača za period od godinu dana. Podaci o opterećenju potrošača dani su u prilogu 25.

Rangiranje kriterija je isto kao i ranije pa su vrijednosti prioriteta kriterija:

p_1 = 0,47777
p_2 = 0,33783
p_3 = 0,11296
p_4 = 0,07144

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.69.

Tablica 5.69. *Vrijednosti kriterija pri opterećenju potrošača u periodu maksimalne nesimetrije*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 30,8	9,41	39,45	207.395
6	– 29,2	8,44	32,76	238.631
7	– 28,8	8,41	28,08	263.265
8	– 26,6	7,84	24,51	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.70–5.73.

Tablica 5.70. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (max. nesim.)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,94805	0,93506	0,87013	0,23400
Altern. 2	1,05479	1	0,98630	0,91781	0,24682
Altern. 3	1,06944	1,01389	1	0,93056	0,25025
Altern. 4	1,14925	1,08955	1,07463	1	0,26893

Tablica 5.71. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (max. nesim.)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89692	0,89373	0,83316	0,22553
Altern. 2	1,11493	1	0,99645	0,92891	0,25144
Altern. 3	1,11891	1,00357	1	0,93222	0,25234
Altern. 4	1,20026	1,07653	1,07270	1	0,27069

Tablica 5.72. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (max. nesim.)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,83031	0,71162	0,62132	0,19160
Altern. 2	1,20437	1	0,85706	0,74831	0,23076
Altern. 3	1,40524	1,16679	1	0,87311	0,26925
Altern. 4	1,60947	1,33635	1,14533	1	0,30838

Tablica 5.73. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (max. nesim.)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23400 \\ 0{,}24682 \\ 0{,}25025 \\ 0{,}26883 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22553 \\ 0{,}25144 \\ 0.25234 \\ 0{,}27069 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19160 \\ 0{,}23076 \\ 0{,}26925 \\ 0{,}30838 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}23047 \\ 0{,}24705 \\ 0{,}25164 \\ 0{,}27084 \end{bmatrix}$$

Alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže pri maksimalnoj nesimetriji.

5.10.2. Prostorno rješenje pri minimalnoj vrijednosti nesimetrije

U ovom primjeru je odabran dan s opterećenjem transformatorske stanice pri minimalnoj nesimetriji i utrošenom energijom potrošača za period od godinu dana (dan bez nesimetrije). Podaci o opterećenju potrošača dani su u prilogu 26.

Rangiranje kriterija je isto kao i ranije pa su vrijednosti prioriteta kriterija:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.74.

Tablica 5.74. *Vrijednosti kriterija pri opterećenju potrošača u periodu minimalne nesimetrije*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 32,8	10,58	41,78	207.395
6	– 30,8	9,48	34,68	238.631
7	– 30,4	9,46	29,73	263.265
8	– 28,4	8,82	25,95	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.75–5.78.

Tablica 5.75. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. nesim.)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,93902	0,92683	0,86585	0,23262
Altern. 2	1,06494	1	0,98701	0,92208	0,24773
Altern. 3	1,07895	1,01316	1	0,93421	0,25099
Altern. 4	1,15493	1,08451	1,07042	1	0,26866

Tablica 5.76. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (min. nesim.)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89603	0,89414	0,83365	0,22553
Altern. 2	1,11603	1	0,99789	0,93038	0,25170
Altern. 3	1,11839	1,00211	1	0,93235	0,25223
Altern. 4	1,19955	1,07483	1,07256	1	0,27054

Tablica 5.77. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (min. nesim.)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,83010	0,71146	0,62109	0,19156
Altern. 2	1,20468	1	0,85708	0,74822	0,23077
Altern. 3	1,40557	1,16676	1	0,87299	0,26925
Altern. 4	1,61007	1,33651	1,14549	1	0,30842

Tablica 5.78. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (min. nesim.)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23262 \\ 0{,}24773 \\ 0{,}25099 \\ 0{,}26866 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22553 \\ 0{,}25170 \\ 0.25223 \\ 0{,}27054 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19156 \\ 0{,}23077 \\ 0{,}26925 \\ 0{,}30842 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22981 \\ 0{,}24757 \\ 0{,}25196 \\ 0{,}27067 \end{bmatrix}$$

Alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže pri minimalnoj nesimetriji.

5.10.3. Prostorno rješenje pri prosječnoj vrijednosti nesimetrije

U ovome primjeru je odabran dan s opterećenjem transformatorske stanice pri prosječnoj vrijednosti nesimetrije i utrošenom energijom potrošača za period od godinu dana. Podaci o opterećenju potrošača dani su u prilogu 27.

Rangiranje kriterija je isto kao i ranije pa su vrijednosti prioriteta kriterija:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.79.

Tablica 5.79. *Vrijednosti kriterija pri opterećenju potrošača u periodu prosječne nesimetrije*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 36,0	12,65	45,59	207.395
6	– 33,6	11,33	37,83	238.631
7	– 33,2	11,30	32,42	263.265
8	– 31,2	10,52	28,30	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.80–5.83.

Tablica 5.80. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (prosj. nesim.)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,93333	0,92222	0,86667	0,23204
Altern. 2	1,07143	1	0,98810	0,92857	0,24861
Altern. 3	1,08434	1,01205	1	0,93976	0,25161
Altern. 4	1,15385	1,07692	1,06410	1	0,26774

Tablica 5.81. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (prosj. nesim.)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89565	0,89328	0,83162	0,22530
Altern. 2	1,11650	1	0,99735	0,92851	0,25155
Altern. 3	1,11947	1,00265	1	0,93097	0,25222
Altern. 4	1,20247	1,07700	1,07414	1	0,27092

Tablica 5.82. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (prosj. nesim.)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,82977	0,71116	0,62068	0,19148
Altern. 2	1,20516	1	0,85706	0,74802	0,23076
Altern. 3	1,40615	1,16678	1	0,87277	0,26925
Altern. 4	1,61113	1,33687	1,14578	1	0,30850

Tablica 5.83. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (prosj. nesim.)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23204 \\ 0{,}24861 \\ 0{,}25161 \\ 0{,}26774 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22530 \\ 0{,}25155 \\ 0.25222 \\ 0{,}27092 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19148 \\ 0{,}23076 \\ 0{,}26925 \\ 0{,}30850 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22945 \\ 0{,}24794 \\ 0{,}25225 \\ 0{,}27036 \end{bmatrix}$$

Alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže pri prosječnoj vrijednosti nesimetrije.

5.10.4. Prostorno rješenje pri najvjerojatnijoj vrijednosti nesimetrije

U ovome primjeru je odabran dan s opterećenjem transformatorske stanice pri najvjerojatnijoj vrijednosti nesimetriji i utrošenom energijom potrošača za period od godinu dana. Podaci o opterećenju potrošača dani su u prilogu 28.

Rangiranje kriterija je isto kao i ranije pa su vrijednosti prioriteta kriterija:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.84.

Tablica 5.84. *Vrijednosti kriterija pri opterećenju potrošača u periodu najvjerojatnije nesim.*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 29,2	8,50	37,53	207.395
6	– 27,6	7,63	31,17	238.631
7	– 27,2	7,60	26,71	263.265
8	– 25,6	7,09	23,33	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.85–5.88.

Tablica 5.85. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (najvjer. nesim.)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,94521	0,93151	0,87671	0,23408
Altern. 2	1,05797	1	0,98551	0,92754	0,24765
Altern. 3	1,07353	1,01471	1	0,94118	0,25129
Altern. 4	1,14063	1,07813	1,06250	1	0,26699

Tablica 5.86. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (najvjer. nesim.)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,89765	0,89412	0,83412	0,22567
Altern. 2	1,11402	1	0,99607	0,92923	0,25140
Altern. 3	1,11842	1,00395	1	0,93289	0,25239
Altern. 4	1,19887	1,07616	1,07193	1	0,27055

Tablica 5.87. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (najvjer. nesim.)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,83048	0,71175	0,62152	0,19164
Altern. 2	1,20412	1	0,85704	0,74839	0,23076
Altern. 3	1,40498	1,16681	1	0,87323	0,26925
Altern. 4	1,60895	1,33621	1,14518	1	0,30834

Tablica 5.88. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (najvjer. nesim.)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa dobiva se:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}23408 \\ 0{,}24765 \\ 0{,}25129 \\ 0{,}26699 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}22567 \\ 0{,}25140 \\ 0.25239 \\ 0{,}27055 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19164 \\ 0{,}23076 \\ 0{,}26925 \\ 0{,}30834 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}23056 \\ 0{,}24743 \\ 0{,}25215 \\ 0{,}26986 \end{bmatrix}$$

Alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže pri najvjerojatnijoj vrijednosti nesimetrije.

5.11. PROSTORNO RJEŠENJE PRI IZGRADNJI NOVIH MREŽA

Dobiveni rezultati pokazuju da promjena opterećenja potrošača ne utječe na konačno prostorno rješenje niskonaponske distribucijske mreže. Dosadašnja razmatranja, međutim, se mogu primijeniti samo na rekonstrukcije postojećih mreža, kada se prigodnim proračunom mogu izračunati pojedinačna opterećenja potrošača. Postavlja se pitanje kakva se rješenja dobivaju ukoliko je potrebno rezultate iskoristiti za projektiranje u cijelosti novih niskonaponskih mreža, kada nisu poznata pojedinačna opterećenja potrošača, odnosno kada ne postoje podaci o utrošenoj energiji potrošača i dnevnom, satnom očitanju opterećenja transformatorske stanice.

Već ranije je navedeno (točka 5.2) da se u ovakvim slučajevima mogu primijeniti podaci koji se temelje na dosadašnjem iskustvu. Naime, iskustveno je poznato da se istodobno opterećenje niskonaponskih potrošača nalazi u granicama 0,8 kW–1,4 kW. Naravno, ove granice mogu biti i drugačije, u ovisnosti o tipu potrošača, karakteristikama mreže i potrošača, faktoru istodobnosti, navikama potrošača itd. Najbolju procjenu pojedinačnih opterećenja moguće je izvršiti ukoliko su raspoložive snimljene karakteristike raznih tipova potrošača, te se temeljem njih svakom potrošaču može pridružiti određeni iznos opterećenja. Isto tako, za dobivanje što preciznijih podataka, u procesu dugoročnog planiranja, potrebno je poznavati podatke o širenju konzuma predmetnog područja, karakteristikama novih potrošača, te prognozi potrošnje u promatranom vremenskom periodu (trogodišnji, petogodišnji, desetogodišnji planovi razvoja). Sve ovo je potrebno uzeti u obzir kada se određuju vrijednosti opterećenja potrošača temeljem kojih će se izvršiti odabir najpovoljnijeg rješenja prema predloženom modelu planiranja.

U danom primjeru je potrebno izvršiti odabir najboljeg prostornog rješenja temeljem prosječnog opterećenja potrošača (1,1 kW) promatranog područja i to za sve potrošače podjednako, bez analiziranja pojedinačnih karakteristika potrošača. Isto tako, korisno je izvršiti provjeru dobivenog rješenja za slučaj promjene istodobnog opterećenja, odnosno za slučajeve maksimalnog (1,4 kW) i minimalnog opterećenja (0,8 kW) pojedinog potrošača.

5.11.1. Prosječno istodobno opterećenje potrošača

U ovom primjeru je odabrano prosječno istodobno opterećenje potrošača od 1,1 kW i to za sve potrošače podjednako.

Rangiranje kriterija je isto kao i ranije pa su vrijednosti prioriteta kriterija:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.89.

Tablica 5.89. *Vrijednosti kriterija pri prosječnom istodobnom opterećenju potrošača*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 30,8	11,75	47,28	207.395
6	– 28,0	10,38	39,23	238.631
7	– 28,0	10,03	33,59	263.265
8	– 26,0	9,22	29,32	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.90–5.93.

Tablica 5.90. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (prosj. istodob.)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,90909	0,90909	0,84416	0,22807
Altern. 2	1,10000	1	1,00000	0,92857	0,25088
Altern. 3	1,10000	1,00000	1	0,92857	0,25088
Altern. 4	1,18462	1,07692	1,07692	1	0,27018

Tablica 5.91. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (prosj. istodob.)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,88340	0,85362	0,78468	0,21844
Altern. 2	1,13198	1	0,96628	0,88825	0,24727
Altern. 3	1,17149	1,03490	1	0,91924	0,25590
Altern. 4	1,27440	1,12581	1,08785	1	0,27838

Tablica 5.92. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (prosj. istodob.)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,82981	0,71049	0,62010	0,19138
Altern. 2	1,20509	1	0,85621	0,74728	0,23063
Altern. 3	1,40747	1,16794	1	0,87277	0,26936
Altern. 4	1,61265	1,33819	1,14578	1	0,30863

Tablica 5.93. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (prosj. istodob.)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa se dobiva:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}22807 \\ 0{,}25088 \\ 0{,}25088 \\ 0{,}27018 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}21844 \\ 0{,}24727 \\ 0.25590 \\ 0{,}27838 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19138 \\ 0{,}23063 \\ 0{,}26936 \\ 0{,}30863 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22522 \\ 0{,}24756 \\ 0{,}25316 \\ 0{,}27406 \end{bmatrix}$$

Alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže pri prosječnoj istodobnoj vrijednosti opterećenja potrošača.

5.11.2. Maksimalno istodobno opterećenje potrošača

U ovom primjeru je odabrano maksimalno istodobno opterećenje potrošača od 1,4 kW i to za sve potrošače podjednako. Rangiranje kriterija je isto kao i ranije pa su vrijednosti prioriteta kriterija:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama, investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.94.

Tablica 5.94. *Vrijednosti kriterija pri maksimalnom istodobnom opterećenju potrošača*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	– 40,4	19,73	60,89	207.395
6	– 36,4	17,38	50,46	238.631
7	– 36,4	16,79	43,19	263.265
8	– 33,6	15,38	37,66	268.912

Provođenjem AHP metoda dobivaju se rezultati kao u tablicama 5.95–5.98.

Tablica 5.95. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (max. istodob.)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,90099	0,90099	0,83168	0,22613
Altern. 2	1,10989	1	1,00000	0,92308	0,25098
Altern. 3	1,10989	1,00000	1	0,92308	0,25098
Altern. 4	1,20238	1,08333	1,08333	1	0,27190

Tablica 5.96. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (max. istodob.)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,88089	0,85099	0,77952	0,21772
Altern. 2	1,13521	1	0,96605	0,88493	0,24715
Altern. 3	1,17510	1,03514	1	0,91602	0,25584
Altern. 4	1,28283	1,13004	1,09168	1	0,27929

Tablica 5.97. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (max. istodob.)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,82865	0,70924	0,61848	0,19107
Altern. 2	1,20678	1	0,85590	0,74637	0,23058
Altern. 3	1,40995	1,16836	1	0,87203	0,26940
Altern. 4	1,61687	1,33981	1,14675	1	0,30894

Tablica 5.98. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (max. istodob.)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa se dobiva:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}22613 \\ 0{,}25098 \\ 0{,}25098 \\ 0{,}27190 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}21772 \\ 0{,}24715 \\ 0.25584 \\ 0{,}27929 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19107 \\ 0{,}23058 \\ 0{,}26940 \\ 0{,}30894 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22401 \\ 0{,}24757 \\ 0{,}25319 \\ 0{,}27523 \end{bmatrix}$$

Alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže i pri maksimalnoj istodobnoj vrijednosti opterećenja potrošača.

5.11.3. Minimalno istodobno opterećenje potrošača

U ovom primjeru je odabrano minimalno istodobno opterećenje potrošača od 0,8 kW i to za sve potrošače podjednako. Rangiranje kriterija je isto kao i ranije pa su vrijednosti prioriteta kriterija:

$p_1 = 0{,}47777$
$p_2 = 0{,}33783$
$p_3 = 0{,}11296$
$p_4 = 0{,}07144$

Padova napona, vrijednosti gubitaka i opterećenja vodova izračunati su u Matpower–u. Obzirom da se radi o istim alternativama investicijski troškovi su isti kao u prethodnim slučajevima.

Dobiveni rezultati su prikazani u tablici 5.99.

Tablica 5.99. *Vrijednosti kriterija pri minimalnom istodobnom opterećenju potrošača*

Broj clustera	ΔU (V)	P_{gub} (kW)	I_{opt} (%)	Investicije (€)
5	–22,0	6,02	33,99	207.395
6	–20,0	5,33	28,24	238.631
7	–20,0	5,16	24,19	263.265
8	–18,4	4,75	21,13	268.912

Provođenjem AHP metode dobivaju se rezultati kao u tablicama 5.100–5.103.

Tablica 5.100. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. istodob.)*

Pad napona	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k1}$
Altern. 1	1	0,90909	0,90909	0,83636	0,22750
Altern. 2	1,10000	1	1,00000	0,92000	0,25025
Altern. 3	1,10000	1,00000	1	0,92000	0,25025
Altern. 4	1,19565	1,08696	1,08696	1	0,27201

Tablica 5.101. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (min. istodob.)*

Gubici snage	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k2}$
Altern. 1	1	0,88538	0,85714	0,78904	0,21913
Altern. 2	1,12946	1	0,96811	0,89118	0,24750
Altern. 3	1,16667	1,03295	1	0,92054	0,25565
Altern. 4	1,26737	1,12211	1,08632	1	0,27772

Tablica 5.102. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (min. istodob.)*

Opterećenje vodova	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k3}$
Altern. 1	1	0,83088	0,71164	0,62160	0,19166
Altern. 2	1,20354	1	0,85649	0,74811	0,23067
Altern. 3	1,40520	1,16756	1	0,87346	0,26932
Altern. 4	1,60876	1,33670	1,14487	1	0,30834

Tablica 5.103. *Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (min. istodob.)*

Investicije	Altern. 1	Altern. 2	Altern. 3	Altern. 4	Prioritet $P_{a,k4}$
Altern. 1	1	1,15061	1,26939	1,29662	0,29170
Altern. 2	0,86910	1	1,10323	1,12689	0,25352
Altern. 3	0,78778	0,90643	1	1,02145	0,22980
Altern. 4	0,77124	0,88740	0,97900	1	0,22497

Množenjem prioriteta kriterija sa prioritetima alternativa se dobiva:

$$0{,}47777 \cdot \begin{bmatrix} 0{,}22750 \\ 0{,}25025 \\ 0{,}25025 \\ 0{,}27201 \end{bmatrix} + 0{,}33783 \cdot \begin{bmatrix} 0{,}21913 \\ 0{,}24750 \\ 0.25565 \\ 0{,}27772 \end{bmatrix} + 0{,}11296 \cdot \begin{bmatrix} 0{,}19166 \\ 0{,}23067 \\ 0{,}26932 \\ 0{,}30834 \end{bmatrix} + 0{,}07144 \cdot \begin{bmatrix} 0{,}29170 \\ 0{,}25352 \\ 0{,}22980 \\ 0{,}22497 \end{bmatrix}$$

odnosno,

$$\begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ R_4 \end{bmatrix} = \begin{bmatrix} 0{,}22521 \\ 0{,}24734 \\ 0{,}25277 \\ 0{,}27468 \end{bmatrix}$$

Alternativa s 8 niskonaponskih izvoda, prema danim kriterijima, predstavlja najbolje prostorno rješenje niskonaponske distribucijske mreže i pri minimalnoj istodobnoj vrijednosti opterećenja potrošača.

5.12. UTJECAJ PROMJENE OPTEREĆENJA POTROŠAČA NA OPTIMALNO RJEŠENJE

Prethodni rezultati pokazuju da promjena opterećenja potrošača ne utječe na izbor najpovoljnijeg prostornog rješenja. Postavlja se pitanje da li promjena opterećenja utječe na optimalno rješenje. Primjena metode simuliranog kaljenja na sve prezentirane slučajeve opterećenja potrošača pokazuje da se u svim slučajevima dobiva identično optimalno uklopno stanje mreže. To u biti znači da je u svim slučajevima potrebno uključiti/isključiti iste dionice mreže kako je to predočeno u točki 5.8, odnosno u tablici 5.41. Dakle, može se zaključiti da

promjena opterećenja ne utječe na optimalnu konfiguraciju, odnosno promjena opterećenja potrošača ne utječe na rezultate koji se dobivaju primjenom predloženog modela. Za dobivanje optimalnog rješenja mogu se iskoristiti bilo koji dostupni podaci o opterećenju potrošača ili ako ni to nije dostupno mogu se odabrati neke prosječne vrijednosti karakteristične za određene tipove mreža.

U svim slučajevima dobivaju se različiti iznosi gubitaka radne snage, te padovi napona kod krajnjih potrošača, jer su ove veličine u direktnoj ovisnosti o iznosu opterećenja. Podaci o padovima napona i gubicima radne snage za sve slučajeve promjene opterećenja su prikazani u tablici 5.104.

Tablica 5.104. *Padovi napona i gubici radne snage za različita opterećenja potrošača*

Opterećenje transformatorske stanice i izvoda	Prostorno rješenje		Optimalno rješenje		Razlika	
	ΔU (%)	P_{gub} (kW)	ΔU (%)	P_{gub} (kW)	ΔU (%)	P_{gub} (kW)
Godišnji maksimum	– 10,1	17,38	– 7,5	13,09	2,6	4,29
Godišnji minimum	– 5,5	5,26	– 4,1	4,08	1,4	1,18
Proljetni maksimum	– 8,8	11,81	– 6,5	9,07	2,3	2,74
Ljetni maksimum	– 9,5	16,67	– 7,1	12,64	2,4	4,03
Jesenski maksimum	– 7,7	11,64	– 5,8	8,81	1,9	2,83
Zimski maksimum	– 9,2	14,01	– 6,8	10,63	2,4	3,38
Maksimalna nesimetrija	– 6,7	7,84	– 5,0	6,05	1,7	1,79
Minimalna nesimetrija	– 7,1	8,82	– 5,3	6,78	1,8	2,04
Prosječna nesimetrija	– 7,8	10,52	– 5,8	8,07	2,0	2,45
Vjerojatna nesimetrija	– 6,4	7,09	– 4,8	5,48	1,6	1,61
Izgradnja nove mreže - maksimum	– 8,4	15,38	– 6,4	12,93	2,0	2,45
Izgradnja nove mreže - minimum	– 4,6	4,75	– 3,5	4,06	1,1	0,69
Izgradnja nove mreže - prosjek	– 6,5	9,22	– 4,9	7,82	1,6	1,40

Na kraju, može se zaključiti da su ovakvi rezultati i očekivani obzirom da su iznosi istodobnih opterećenja kod niskonaponskih potrošača relativno mali. Obzirom da su na sve to u svim prikazanim slučajevima i promjene opterećenja malene, onda se može reći da takve promjene i ne mogu utjecati na konačno rješenje.

5.13. USPOREDBA REZULTATA SA POSTOJEĆOM MREŽOM – POTVRDA MODELA

U prethodnim točkama su prezentirani rezultati primjene predloženog modela planiranja. Temeljem tih rezultata može se zaključiti da se predloženim modelom mogu dobiti najbolja rješenja prigodna za rekonstrukcije ili izgradnju niskonaponskih distribucijskih mreža. Koliko su ta rješenja dobra ili to nisu, najbolje se može vidjeti ukoliko se izvrši usporedba rezultata za mreže dobivene predloženim modelom i rezultata za postojeću niskonaponsku mrežu.

U ovoj točki su prezentirani rezultati takve usporedbe. Na ovaj način predloženi model planiranja dobiva potvrdu svoje primjenjivosti, čime se ispunjava temeljni cilj istraživanja prezentiranog u ovoj disertaciji, a to je uspostava jednog sasvim novog modela, odnosno pristupa u planiranju niskonaponskih distribucijskih mreža.

Kao što je već ranije rečeno postojeća niskonaponska distribucijska mreža se napaja iz transformatorske stanice 10(20)/0,4 kV, nazivne snage 400 kVA. Preko ove mreže je napojeno 270 kupaca električne energije, uglavnom iz kategorije kućanstava, i to preko 5 niskonaponskih izvoda. Prostorni izgled postojeće mreže prikazan je na slici 5.2.

Kako bi se mogla izvršiti bilo kakva usporedba i za postojeću mrežu je potrebno izvršiti proračune tokova snaga za sve vrijednosti opterećenja potrošača kako je to napravljeno za mreže dobivene primjenom modela (Slika 5.28). Ovo je jako bitno jer se samo na taj način može vršiti usporedba sa rezultatima modela i mogu se vidjeti učinci, odnosno donijeti određeni zaključci u vezi predloženog modela planiranja.

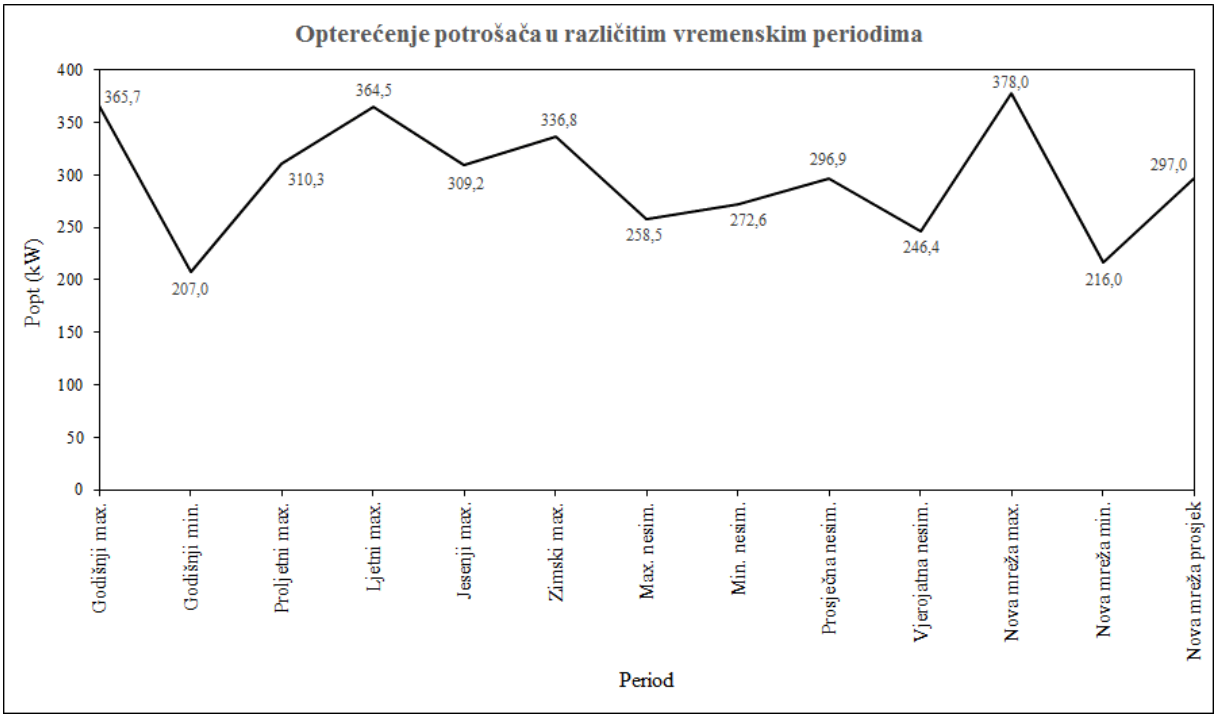

Slika 5.28. *Ukupno opterećenje potrošača za različito dnevno opterećenje transformatorske stanice*

5.13.1. Usporedba rezultata padova napona

Za kupce električne energije najvažnije je da razina napona bude zadovoljavajuća i vremenski nepromjenjiva. Stoga je jedan od parametara kojeg je potrebno usporediti pad napona kod krajnjih potrošača. Ovom parametru je u predloženom modelu dodijeljen najviši stupanj važnosti. Ako se vrši procjena uspješnosti primjene modela onda se pri usporedbi ovog

parametra trebaju promatrati isključivo apsolutni iznosi, bez razmatranja bilo kakvih financijskih učinaka. Ako je dovođenje naponske razine kod svakog potrošača u propisane granice najvažnije onda za ispunjenje tog cilja financijska ulaganja nemaju presudnu važnost.

Ponuđeni model planiranja bi trebao dati rješenje kojim će biti umanjeni padovi napona kod krajnjih potrošača u odnosu na postojeće stanje u mreži. Ukoliko to nije slučaj onda se ne može reći da model daje kvalitetna rješenja jer je jedna od temeljnih zadaća modela dobivanje boljeg stanja od postojećeg. Samo u tom slučaju može se reći da je model kvalitetan i primjenjiv.

Proračunom tokova snaga za postojeću mrežu su dobiveni podaci o padovima napona kod krajnjih potrošača kao u tablici 5.105.

Tablica 5.105. *Padovi napona kod krajnjih potrošača za različite vrijednosti opterećenja potrošača postojeće niskonaponske distribucijske mreže*

Opterećenje transformatorske stanice i izvoda	U (p.u)	U (V)	ΔU (V)	ΔU (%)
Godišnji maksimum	0,855	342,0	– 58,0	– 14,5
Godišnji minimum	0,921	368,4	– 31,6	– 7,9
Proljetni maksimum	0,878	351,2	– 48,8	– 12,2
Ljetni maksimum	0,846	338,4	– 61,6	– 15,4
Jesenski maksimum	0,874	349,6	– 50,4	– 12,6
Zimski maksimum	0,878	351,2	– 48,8	– 12,2
Maksimalna nesimetrija	0,900	360,0	– 40,0	– 10,0
Minimalna nesimetrija	0,894	357,6	– 42,4	– 10,6
Prosječna nesimetrija	0,884	353,6	– 46,4	– 11,6
Vjerojatna nesimetrija	0,906	362,4	– 37,6	– 9,4
Izgradnja nove mreže – maksimum	0,806	322,4	– 77,6	– 19,4
Izgradnja nove mreže – minimum	0,898	359,2	– 40,8	– 10,2
Izgradnja nove mreže – prosjek	0,854	341,6	– 58,4	– 14,6

Predočene rezultate postojeće niskonaponske distribucijske mreže je potrebno usporediti sa rezultatima optimalne mreže dobivene primjenom predloženog modela planiranja. Vrijednosti padova napona kod krajnjih potrošača dobiveni proračunom tokova snaga za optimalnu mrežu su prikazani u tablici 5.106.

Tablica 5.106. *Padovi napona kod krajnjih potrošača za različite vrijednosti opterećenja potrošača optimalne niskonaponske distribucijske mreže*

Opterećenje transformatorske stanice i izvoda	U (p.u)	U (V)	ΔU (V)	ΔU (%)
Godišnji maksimum	0,925	370,0	– 30,0	– 7,5
Godišnji minimum	0,959	383,6	– 16,4	– 4,1
Proljetni maksimum	0,935	374,0	– 26,0	– 6,5
Ljetni maksimum	0,929	371,6	– 28,4	– 7,1
Jesenski maksimum	0,942	376,8	– 23,2	– 5,8
Zimski maksimum	0,932	372,8	– 27,2	– 6,8
Maksimalna nesimetrija	0,950	380,0	– 20,2	– 5,0
Minimalna nesimetrija	0,947	378,8	– 21,2	– 5,3
Prosječna nesimetrija	0,942	376,8	– 23,2	– 5,8
Vjerojatna nesimetrija	0,952	380,8	– 19,2	– 4,8
Izgradnja nove mreže – maksimum	0,936	374,4	– 25,6	– 6,4
Izgradnja nove mreže – minimum	0,965	386,0	– 14,0	– 3,5
Izgradnja nove mreže – prosjek	0,951	380,4	– 19,6	– 4,9

Usporedni rezultati za ove dvije mreže dani su u tablici 5.107, odnosno na slici 5.29.

Tablica 5.107. *Usporedba rezultata o padovima napona kod krajnjih potrošača postojeće i optimalne niskonaponske distribucijske mreže*

Opterećenje transformatorske stanice i izvoda	Postojeća mreža		Optimalna mreža		Razlika u odnosu na postojeću mrežu	
	ΔU (V)	ΔU (%)	ΔU (V)	ΔU (%)	ΔU (V)	ΔU (%)
Godišnji maksimum	– 58,0	– 14,5	– 30,0	– 7,5	28,0	51,7
Godišnji minimum	– 31,6	– 7,9	– 16,4	– 4,1	15,2	51,9
Proljetni maksimum	– 48,8	– 12,2	– 26,0	– 6,5	22,8	53,3
Ljetni maksimum	– 61,6	– 15,4	– 28,4	– 7,1	33,2	46,1
Jesenski maksimum	– 50,4	– 12,6	– 23,2	– 5,8	27,2	46,0
Zimski maksimum	– 48,8	– 12,2	– 27,2	– 6,8	21,6	55,7
Maksimalna nesimetrija	– 40,0	– 10,0	– 20,2	– 5,0	20,0	50,0
Minimalna nesimetrija	– 42,4	– 10,6	– 21,2	– 5,3	21,2	50,0
Prosječna nesimetrija	– 46,4	– 11,6	– 23,2	– 5,8	23,2	50,0
Vjerojatna nesimetrija	– 37,6	– 9,4	– 19,2	– 4,8	18,4	51,1
Prosjek:	– 49,4	– 12,4	– 22,6	– 5,7	26,8	50,6
Izgradnja nove mreže – maksimum	– 77,6	– 19,4	– 25,6	– 6,4	52,0	33,0
Izgradnja nove mreže – minimum	– 40,8	– 10,2	– 14,0	– 3,5	26,8	34,3
Izgradnja nove mreže – prosjek	– 58,4	– 14,6	– 19,6	– 4,9	38,8	33,6
Prosjek:	– 58,9	– 14,7	– 19,7	– 4,9	39,2	33,6

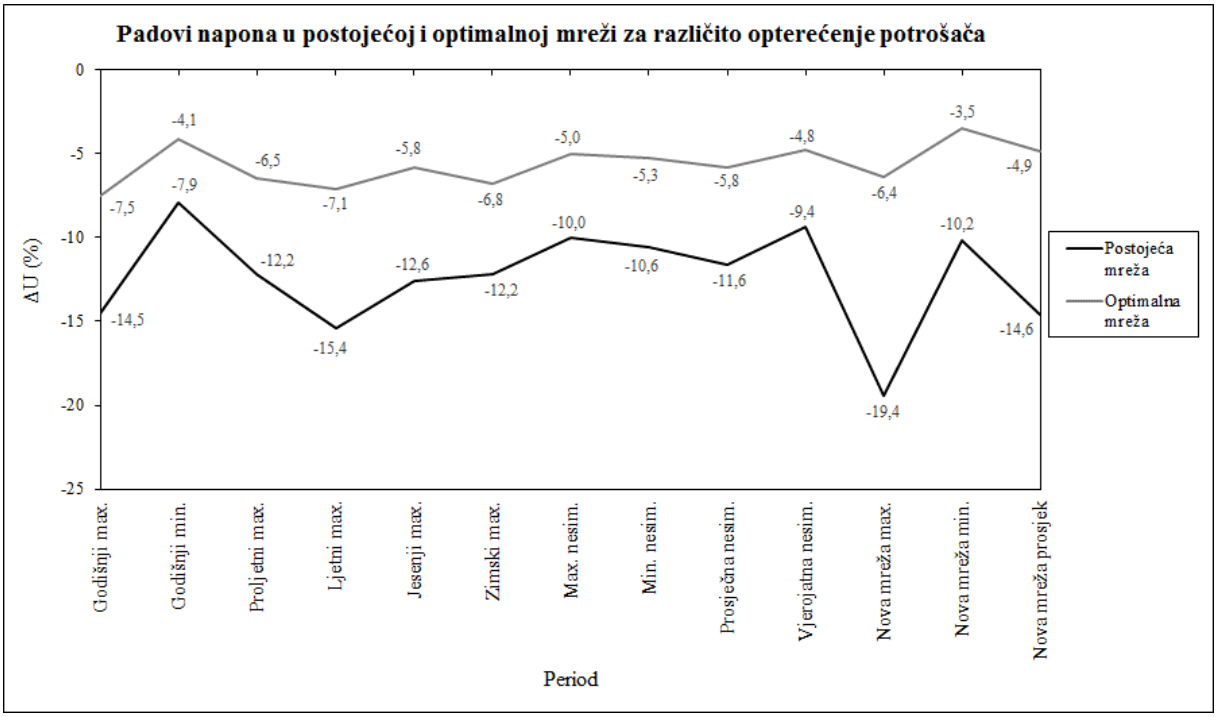

Slika 5.29. *Padovi napona kod krajnjih potrošača u postojećoj i optimalnoj mreži pri različitom opterećenju potrošača i vremenskim periodima*

Iz tablice, kao i sa slike, lako se može uočiti da su padovi napona kod krajnjih potrošača u optimalnoj konfiguraciji dobivenoj primjenom modela znatno niži u odnosu na padove napona u postojećoj mreži. Ukoliko se za proračun koriste podaci o varijacijama stvarnog opterećenja potrošača onda su padovi napona poboljšani u prosjeku za 50,6%, a ukoliko se uzmu identične vrijednosti opterećenja za sve potrošače onda je poboljšanje u prosjeku 33,6%. Dakle, evidentno je da se primjenom ponuđenog modela planiranja, kada je u pitanju ovaj parametar, dobivaju znatno bolji rezultati, odnosno može se zaključiti da je model prihvatljiv.

Mada model daje veoma dobre rezultate, ukoliko se želi postići još veće poboljšanje kada se radi o ovome parametru, prednost modela je što se na jednostavan način može provjeriti učinak eventualnih mjera koje je potrebno provesti kako bi se dobili još bolji rezultati. To je veoma značajno jer se to u praksi može učiniti samo praktičnom primjenom, a učinci se mogu mjeriti tek nakon provođenja mjera. To naravno ne garantira da će provedene mjere biti učinkovite.

Smanjenje padova napona kod krajnjih potrošača može se postići na nekoliko načina i to:

- Smanjenjem dužine niskonaponskih izvoda;
- Prebacivanjem dijela potrošača na drugu transformatorsku stanicu (rasterećenje);
- Povećanjem napona na sabirnicama transformatora („štufanje“);
- Povećanjem presjeka vodiča magistralnih vodova;
- Implementiranjem dodatnog izvora napajanja u dio mreže sa velikim padovima napona.

U prikazanom primjeru je samim dobivanjem optimalnog rješenja sa više niskonaponskih izvoda već izvršeno smanjenje dužina niskonaponskih izvoda. Iskusni inženjeri–planeri će u većini slučajeva formirati izvode sa najkraćim dužinama. I sam model pri procesu grupiranja potrošača, korištenjem algoritma neizrazitog grupiranja koji se temelji na najkraćim udaljenostima, nudi najbolja rješenja.

Rasterećenje niskonaponskih izvoda, odnosno transformatorske stanice izvodi se prebacivanjem određenog broja potrošača na drugu transformatorsku stanicu, ukoliko takva mreža postoji u blizini postojeće mreže. Ukoliko takva mreža ne postoji onda se mora implementirati nova transformatorska stanica što je krajnja mjera koja se primjenjuju kada se iskoriste sve preostale mogućnosti. Ako je postojeća transformatorska stanica preopterećena onda je ova mjera neophodna bez obzira na iznose padova napona kod krajnjih potrošača.

Smanjenje padova napona kod krajnjih potrošača može se postići podizanjem razine napona na niskonaponskim sabirnicama transformatorske stanice ili tzv. *štufanjem*. Štufanjem se u stvari mijenja broj zavoja u primarnom namotaju transformatora (zbog manjih struja), čime se direktno utječe na naponsku razinu. Pri primjeni ovog postupka mora se voditi računa o tome da, u slučaju podizanja razine napona, kod potrošača koji su najbliži transformatorskoj stanici ne smije doći do prekomjernog povišenja razine napona (izvan propisanih vrijednosti) što bi ugrozilo rad i eventualno dovelo do oštećenja njihovih uređaja. Štufanjem se podiže razina napona na svim niskonaponskim izvodima bez obzira da li na njima postoje prekomjerni padovi napona ili ne, što se također mora uzeti u obzir.

U razmatranom primjeru se koristi transformator nazivne snage 400 kVA, kod kojeg se razina napona može mijenjati (štufati) u granicama ± 2,5% i to za dva položaja u plus i dva položaja u minus. Dakle, maksimalna promjena razine napona je ± 5% u odnosu na nazivnu vrijednost od 400 V, što znači da se razina napona na sabirnicama transformatorske stanice može podići maksimalno do 420 V, odnosno sniziti do 380 V.

U praktičnom slučaju učinci štufanja se mogu provjeriti tek nakon izvršenih mjerenja razine napona kod krajnjih potrošača. Prije provođenja postupka je poželjno izvršiti mjerenje naponske razine kod najbližih kupaca kako ne bi došlo do neželjenih posljedica. Za razliku od ovoga, ponuđenim modelom se na vrlo jednostavan način može provjeriti što će se dešavati sa padovima napona u slučaju podizanja naponske razine. Potrebno je samo u podacima o transformatorskoj stanici promijeniti ograničenje u vezi sa naponskom razinom (stupac V_g u tablici 5.108).

Tablica 5.108. *Podaci o transformatorskoj stanici za slučaj maksimalnog štufanja*

Bus number	P_g (MW)	Q_g (MVAr)	Q_{max} (MVAr)	Q_{min} (MVAr)	V_g (p.u)	mBase (MVA)	Status	P_{max} (MW)	P_{min} (MW)
999	0.4	0.0	0.02	– 0.02	1.05	1	1	0.38	0

Ako se to primijeni na postojeću mrežu i optimalnu mrežu prema modelu dobivaju se usporedni rezultati kao u tablici 5.109, odnosno na slici 5.30.

Tablica 5.109. *Padovi napona za različite vrijednosti opterećenja potrošača postojeće i optimalne niskonaponske distribucijske mreže za slučaj „štufanja“ transformatora*

Opterećenje transformatorske stanice i izvoda	Postojeća mreža			Optimalna mreža		
	Bez štufanja	Sa štufanjem	Smanjenje pada napona	Bez štufanja	Sa štufanjem	Smanjenje pada napona
	ΔU (%)		(%)	ΔU (%)		(%)
Godišnji maksimum	– 14,5	– 8,6	40,7	– 7,5	– 2,1	72,0
Godišnji minimum	– 7,9	– 2,5	68,4	– 4,1	1,1	126,8
Proljetni maksimum	– 12,2	– 6,4	47,5	– 6,5	– 1,1	83,1
Ljetni maksimum	– 15,4	– 9,5	38,3	– 7,1	– 1,7	76,1
Jesenski maksimum	– 12,6	– 6,9	45,2	– 5,8	– 0,5	91,4
Zimski maksimum	– 12,2	– 6,5	46,7	– 6,8	– 1,4	79,4
Maksimalna nesimetrija	– 10,0	– 4,4	56,0	– 5,0	0,2	104,0
Minimalna nesimetrija	– 10,6	– 5,0	52,8	– 5,3	0,0	100,0
Prosječna nesimetrija	– 11,6	– 5,9	49,1	– 5,8	– 0,5	91,4
Vjerojatna nesimetrija	– 9,4	– 3,9	58,5	– 4,8	0,5	110,4
Prosjek:	– 11,6	– 6,0	50,3	– 5,9	– 0,6	93,5
Izgradnja nove mreže – maksimum	– 19,4	– 13,1	32,5	– 6,4	– 1,0	84,4
Izgradnja nove mreže – minimum	– 10,2	– 4,6	54,9	– 3,5	1,6	145,7
Izgradnja nove mreže – prosjek	– 14,6	– 8,7	40,4	– 4,9	0,3	106,1
Prosjek:	– 14,7	– 8,8	42,6	– 4,9	0,3	112,1

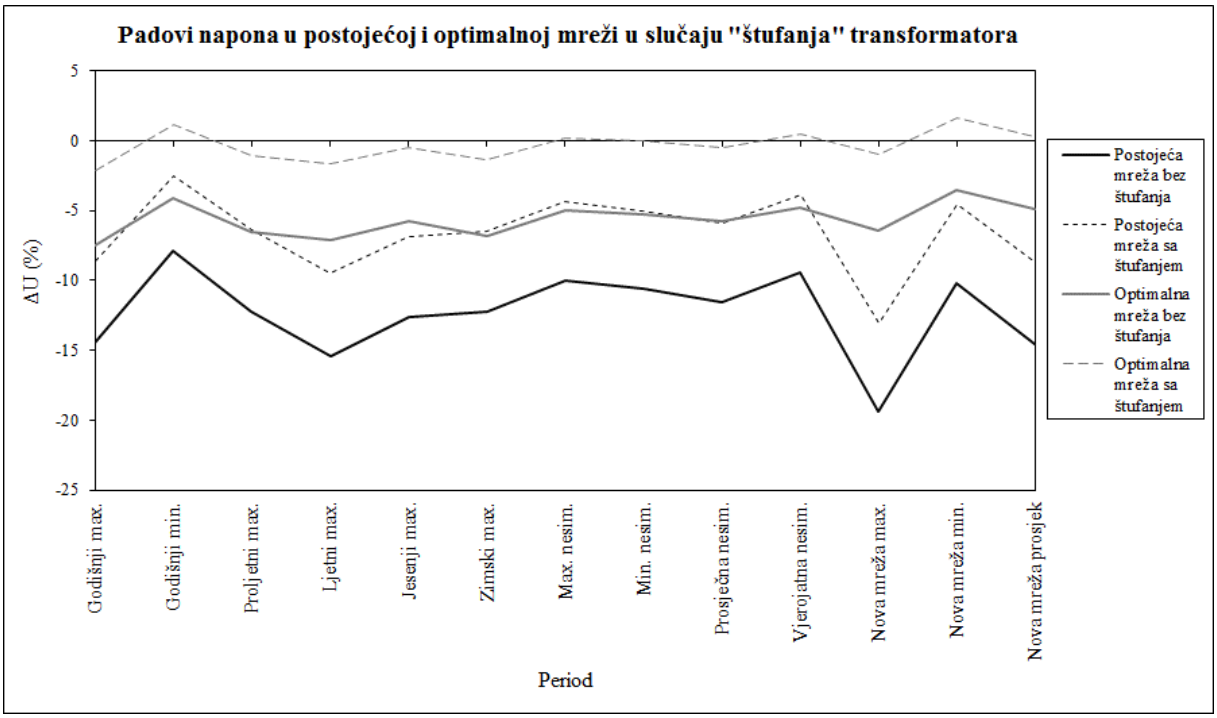

Slika 5.30. *Padovi napona kod krajnjih potrošača u postojećoj i optimalnoj mreži za slučaj „štufanja“ transformatora, pri različitom opterećenju potrošača i vremenskim periodima*

Neovisno o dobivenim rezultatima, ovakav jednostavan pristup pri provjeri određenih parametara omogućava sagledavanje budućeg stanja u mreži bez ikakvih mjerenja što je prednost predloženog modela i predstavlja potvrdu njegove primjenjivosti.

Problem padova napona je moguće riješiti i promjenom presjeka vodiča magistralnih dionica niskonaponskog izvoda na kojem su registrirane nedozvoljene vrijednosti. Primjenom takvog postupka na postojeću mrežu i optimalnu mrežu prema modelu dobivaju se usporedni rezultati kao u tablici 5.110, odnosno na slici 5.31.

Tablica 5.110. *Padovi napona za različito opterećenje potrošača postojeće i optimalne niskonaponske mreže u slučaju promjene presjeka vodiča magistralnog voda*

Opterećenje transformatorske stanice i izvoda	Postojeća mreža			Optimalna mreža		
	Bez promjene presjeka	Sa promjenom presjeka	Smanjenje pada napona	Bez promjene presjeka	Sa promjenom presjeka	Smanjenje pada napona
	ΔU (%)		(%)	ΔU (%)		(%)
Godišnji maksimum	– 14,5	– 6,7	53,8	– 7,5	– 4,6	38,7
Godišnji minimum	– 7,9	– 3,8	51,9	– 4,1	– 2,6	36,6
Proljetni maksimum	– 12,2	– 5,6	54,1	– 6,5	– 4,0	38,5
Ljetni maksimum	– 15,4	– 7,1	53,9	– 7,1	– 4,4	38,0
Jesenski maksimum	– 12,6	– 5,8	54,0	– 5,8	– 3,5	39,7
Zimski maksimum	– 12,2	– 5,6	54,1	– 6,8	– 4,1	39,7
Maksimalna nesimetrija	– 10,0	– 4,6	54,0	– 5,0	– 3,1	38,0
Minimalna nesimetrija	– 10,6	– 4,9	53,8	– 5,3	– 3,3	37,7
Prosječna nesimetrija	– 11,6	– 5,4	53,4	– 5,8	– 3,5	39,7
Vjerojatna nesimetrija	– 9,4	– 4,4	53,2	– 4,8	– 2,9	39,6
Prosjek:	– 11,6	– 5,4	53,6	– 5,9	– 3,6	38,6
Izgradnja nove mreže – maksimum	– 19,4	– 8,5	56,2	– 6,4	– 4,0	37,5
Izgradnja nove mreže – minimum	– 10,2	– 4,7	53,9	– 3,5	– 2,3	34,3
Izgradnja nove mreže – prosjek	– 14,6	– 6,6	54,8	– 4,9	– 3,1	36,7
Prosjek:	– 14,7	– 6,6	55,0	– 4,9	– 3,1	36,2

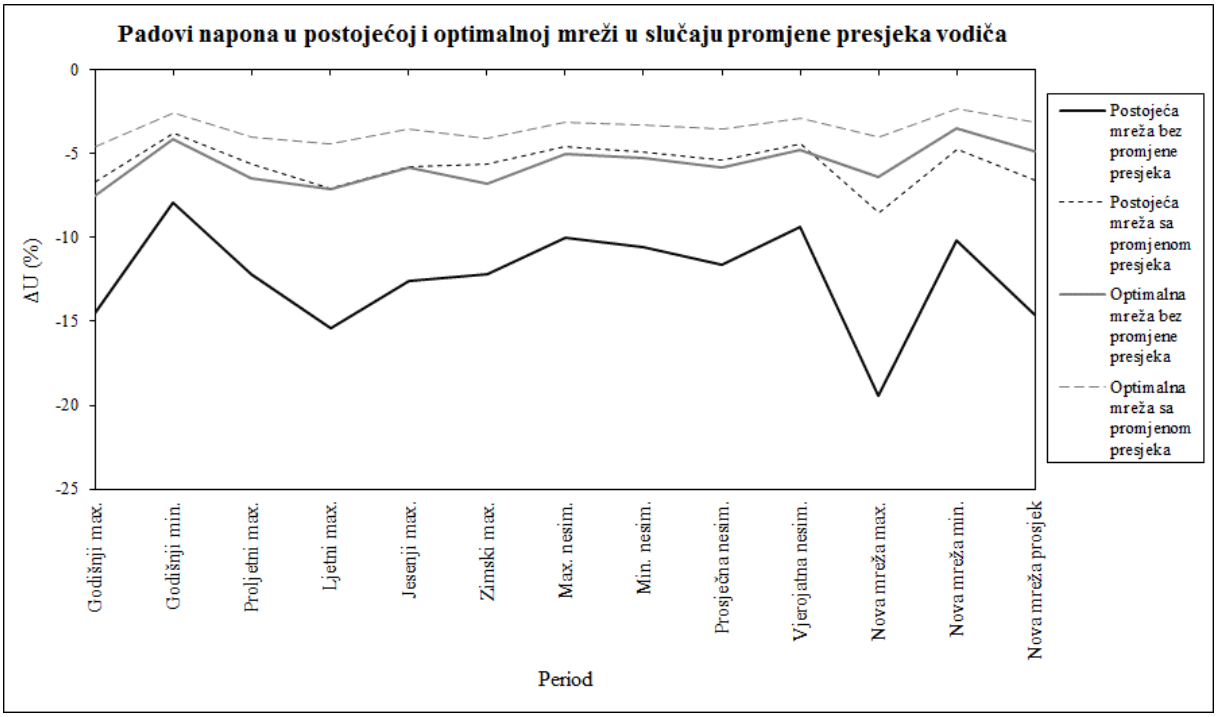

Slika 5.31. *Padovi napona kod krajnjih potrošača u postojećoj i optimalnoj mreži za slučaj promjene presjeka vodiča, pri različitom opterećenju potrošača i vremenskim periodima*

Očito za postojeću mrežu nije dovoljno samo izvršiti zamjenu vodiča magistralnog voda koji ima prekomjerne padove napona. Kako bi se padovi napona doveli u zadovoljavajuće granice osim promjene presjeka potrebno je izvršiti i eventualno štufanje transformatora. Dio mreže koji je potrebno zamijeniti vodičima većeg presjeka nije moguće precizno odrediti bez odgovarajućih proračuna. Bez toga, sve se u biti svodi na pokus i mjerenje („zamijeni dio mreže i izmjeri padove napona itd.“). Stoga model planiranja i u ovom slučaju ima svoju značajnu primjenu jer omogućava da se učinci mjera koje je potrebno poduzeti vide unaprijed.

Iz tablice i sa slike se može uočiti da se promjenom presjeka vodiča magistralnog voda, kod dobivenog optimalnog rješenja, mogu dobiti još bolji rezultati kada se radi o padovima napona kod krajnjih potrošača. Iskusni inženjeri–planeri bi ovo već ranije uočili i kod crtanja mreža bi vjerojatno iscrtali mreže sa većim presjecima vodiča magistralnih vodova niskonaponskih izvoda.

Osim toga, može se uočiti da se promjenom presjeka vodiča u postojećoj mreži pojavljuju znatno veći učinci u odnosu na optimalnu mrežu. To govori da je postojeća mreža izgrađena sa manjim presjecima vodiča nego što je to predviđeno predloženim modelom. To se jasno vidi sa slike i predstavlja značajnu prednost modela u identificiranju problema u postojećoj mreži.

Padovi napona kod krajnjih potrošača mogu se popraviti i eventualnim implementiranjem nekog dodatnog izvora napajanja (obnovljivog izvora) u dio mreže sa prekomjernim padovima napona. Ne ulazeći u problematiku utjecaja ovakvih izvora na kvalitetu električne energije u tablici 5.111, odnosno na slici 5.32 su prezentirani rezultati implementacije 10 kW izvora u jednu točku magistralnog voda sa prekomjernim padovima napona.

Tablica 5.111. *Padovi napona za različito opterećenje potrošača postojeće i optimalne niskonaponske mreže u slučaju implementiranja dodatnog izvora napajanja*

Opterećenje transformatorske stanice i izvoda	Postojeća mreža			Optimalna mreža		
	Bez novog izvora	Sa novim izvorom	Smanjenje pada napona	Bez novog izvora	Sa novim izvorom	Smanjenje pada napona
	ΔU (%)		(%)	ΔU (%)		(%)
Godišnji maksimum	– 14,5	– 2,0	86,2	– 7,5	– 2,3	69,3
Godišnji minimum	– 7,9	– 1,1	86,1	– 4,1	– 1,3	68,3
Proljetni maksimum	– 12,2	– 1,6	86,9	– 6,5	– 2,1	67,7
Ljetni maksimum	– 15,4	– 2,3	85,1	– 7,1	– 2,2	69,0
Jesenski maksimum	– 12,6	– 7,4	85,7	– 5,8	– 1,8	69,0
Zimski maksimum	– 12,2	– 1,8	87,7	– 6,8	– 2,1	69,1
Maksimalna nesimetrija	– 10,0	– 1,5	86,0	– 5,0	– 1,6	68,0
Minimalna nesimetrija	– 10,6	– 1,4	85,8	– 5,3	– 1,7	67,9
Prosječna nesimetrija	– 11,6	– 1,5	86,2	– 5,8	– 1,8	69,0
Vjerojatna nesimetrija	– 9,4	– 1,6	86,2	– 4,8	– 1,5	68,8
Prosjek:	– 11,6	– 1,6	86,2	– 5,9	– 1,8	68,6
Izgradnja nove mreže – maksimum	– 19,4	– 2,5	87,1	– 6,4	– 1,6	75,0
Izgradnja nove mreže – minimum	– 10,2	– 1,4	86,3	– 3,5	– 0,9	74,3
Izgradnja nove mreže – prosjek	– 14,6	– 2,0	86,3	– 4,9	– 1,3	73,5
Prosjek:	– 14,7	– 2,0	86,6	– 4,9	– 1,3	74,3

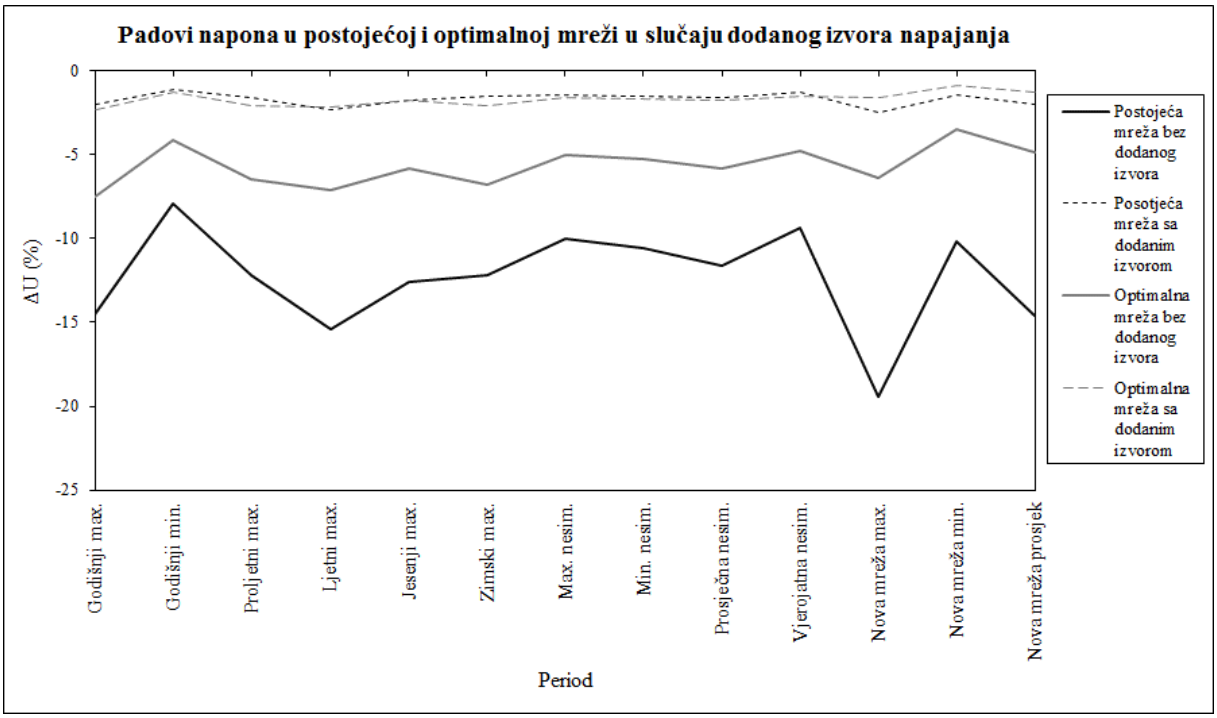

Slika 5.32. *Padovi napona kod krajnjih potrošača u postojećoj i optimalnoj mreži za slučaj dodavanja izvora napajanja, pri različitom opterećenju potrošača i vremenskim periodima*

Rezultati dobiveni za slučaj implementiranja novog izvora napajanja ovise o mjestu implementacije izvora u mrežu. Sa slike je uočljivo da se veće poboljšanje postiže kod postojeće mreže jer je novi izvor implementiran bliže potrošaču sa nezadovoljavajućim padom napona. U ovom slučaju je uzet u obzir samo utjecaj implementiranog izvora na razinu napona kod krajnjih potrošača, a zanemaren je utjecaj izvora na ostale parametre kvalitete električne energije. U praktičnoj primjeni o tome se mora posebno voditi računa. Ovdje je samo pokazano da ovakva mjera može dati rezultate koji vode ka poboljšanju naponskih prilika.

U ovom slučaju predloženi model ima apsolutnu prednost u odnosu na bilo kakvu praktičnu mjeru obzirom da i ne postoji mogućnost da se bez modela provjeri bilo kakav utjecaj izvora pošto je za to potrebno prvo izgraditi i priključiti izvor na mrežu pa tek onda vršiti provjere, što je naravno neprihvatljivo. I prema propisima distribucijskih tvrtki prije priključenja novog izvora na distribucijsku mrežu potrebno je prvo, na modeliranoj mreži, provjeriti njegov utjecaj, odnosno određene parametre i tek nakon toga se može izdati suglasnost za priključenje ukoliko se zadovolje traženi uvjeti. Dakle, u praksi je to bez modela neizvodivo.

Na slici 5.33 je prikazana usporedba padova napona kod krajnjih potrošača svih razmatranih mreža (postojeća, optimalna, sa 5, 6, 7 i 8 izvoda) pri različitom opterećenju potrošača.

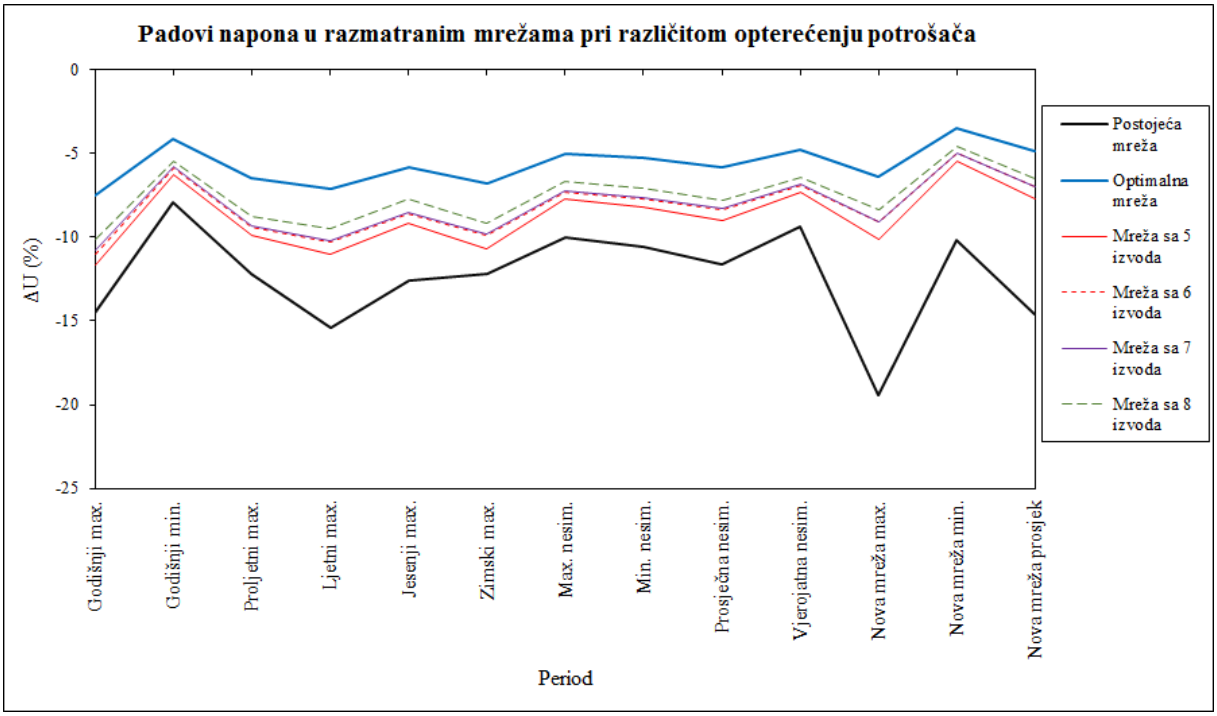

Slika 5.33. *Padovi napona kod krajnjih potrošača u svim razmatranim mrežama pri različitom opterećenju potrošača i vremenskim periodima*

Sa slike se jasno vidi kako se primjenom predloženog modela planiranja postupno dolazi do najboljeg rješenja kada su u pitanju padovi napona kod krajnjih potrošača. Isto tako se vidi da su rezultati kod mreža sa 6 i 7 izvoda skoro identični što govori da veći broj izvoda ne znači u pravilu bolje rješenje. Ipak, konačno, optimalno rješenje se sigurno dobiva bez obzira kakvi se rezultati dobivaju u primijenjenim međukoracima.

5.13.2. Usporedba rezultata gubitaka radne snage

Drugi bitan faktor koji je potrebno usporediti su gubici radne snage u niskonaponskim vodovima. Ovaj faktor je najbitniji za distribucijsku tvrtku jer manji gubici znače veću dobit i obratno. Ovdje će biti prezentirani rezultati za sve razmatrane slučajeve kao u prethodnom poglavlju.

Proračunom tokova snaga za postojeću i optimalnu mrežu dobiveni su podaci o gubicima radne snage u niskonaponskim vodovima kao u tablici 5.112. Na slici 5.34 je prikazana usporedba ovih rezultata.

Tablica 5.112. *Gubici radne snage za različite vrijednosti opterećenja potrošača postojeće i optimalne niskonaponske mreže*

Opterećenje transformatorske stanice i izvoda	Postojeća mreža	Optimalna mreža	Razlika	
	P_{gub} (kW)		(kW)	(%)
Godišnji maksimum	18,18	13,09	5,09	28,00
Godišnji minimum	5,60	4,08	1,52	27,14
Proljetni maksimum	12,63	9,07	3,56	28,19
Ljetni maksimum	18,99	12,64	6,35	33,44
Jesenski maksimum	12,83	8,81	4,02	31,33
Zimski maksimum	14,36	10,63	3,73	25,97
Maksimalna nesimetrija	8,55	6,05	2,50	29,24
Minimalna nesimetrija	9,61	6,78	2,83	29,45
Prosječna nesimetrija	11,50	8,07	3,43	29,83
Vjerojatna nesimetrija	7,72	5,48	2,24	29,02
Prosjek:	12,00	8,47	3,53	29,16
Izgradnja nove mreže – maksimum	27,84	12,93	14,91	53,56
Izgradnja nove mreže – minimum	8,03	4,06	3,97	49,44
Izgradnja nove mreže – prosjek	16,09	7,82	8,27	51,40
Prosjek:	17,32	8,27	9,05	51,46

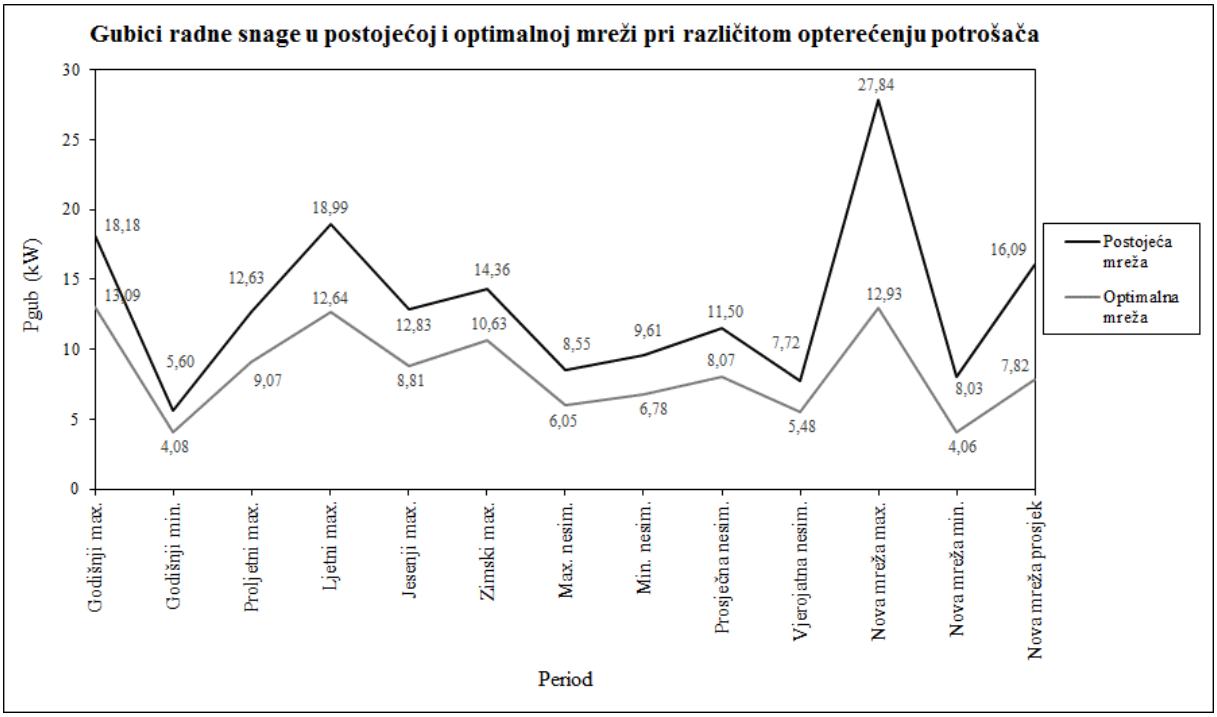

Slika 5.34. *Gubici radne snage postojeće i optimalne distribucijske mreže pri različitom opterećenju potrošača i vremenskim periodima*

Očito je da optimalno rješenje daje niži iznos gubitaka radne snage u usporedbi sa gubicima u postojećoj mreži. Kada se promatra različito pojedinačno opterećenje potrošača onda su ti gubici manji za oko 30 %, a ukoliko se uzme da su svi potrošači opterećeni podjednako onda je to smanjenje za oko 50 %. Iako po apsolutnom iznosu razlika gubitaka postojećeg i optimalnog stanja (u prosjeku 3,5 kW) nije velika mora se imati na umu da u elektrodistributivnim tvrtkama postoji znatan broj transformatorskih područja sa sličnim problemima, tako da se zbrajanjem svih gubitaka dobiva značajan ukupni iznos.

Obzirom da provođenje mjera za reduciranje padova napona kod krajnjih potrošača ima za posljedicu i promjenu iznosa gubitaka interesantno je za vidjeti koliko neka od prikazanih mjera ima utjecaj na gubitke radne snage u niskonaponskim vodovima. Za očekivati je da svaka mjera koja daje smanjenje padova napona direktno utječe i na smanjenje gubitaka radne snage. Kako bi se to i potvrdilo u nastavku su dani rezultati provedenih mjera, ali sada sa osvrtom na iznose gubitaka radne snage u niskonaponskim vodovima.

U tablici 5.113 dan je pregled gubitaka postojeće i optimalne distribucijske mreže za slučaj primjene mjere štufanja transformatora. Na slici 5.35 dan je grafički prikaz dobivenih rezultata.

U tablici 5.114 dan je pregled gubitaka postojeće i optimalne distribucijske mreže za slučaj primjene mjere promjene presjeka vodiča. Na slici 5.36 je grafički prikaz dobivenih rezultata.

U tablici 5.115 dan je pregled gubitaka postojeće i optimalne distribucijske mreže za slučaj primjene mjere implementiranja novog izvora. Na slici 5.37 je grafički prikaz dobivenih rezultata.

Tablica 5.113. *Gubici radne snage za različito opterećenje potrošača postojeće i optimalne niskonaponske mreže u slučaju „štufanja“ transformatora*

Opterećenje transformatorske stanice i izvoda	Postojeća mreža			Optimalna mreža		
	Bez štufanja	Sa štufanjem	Smanjenje gubitaka	Bez štufanja	Sa štufanjem	Smanjenje gubitaka
	P_{gub} (kW)		(%)	P_{gub} (kW)		(%)
Godišnji maksimum	18,18	16,19	10,95	13,09	11,76	10,16
Godišnji minimum	5,60	5,04	10,00	4,08	3,68	9,80
Proljetni maksimum	12,63	11,29	10,61	9,07	8,16	10,03
Ljetni maksimum	18,99	16,88	11,11	12,64	11,36	10,13
Jesenski maksimum	12,83	11,45	10,76	8,81	7,93	9,99
Zimski maksimum	14,36	12,83	10,65	10,63	9,56	10,07
Maksimalna nesimetrija	8,55	7,66	10,41	6,05	5,45	9,92
Minimalna nesimetrija	9,61	8,61	10,41	6,78	6,11	9,88
Prosječna nesimetrija	11,50	10,28	10,61	8,07	7,26	10,04
Vjerojatna nesimetrija	7,72	6,92	10,36	5,48	4,94	9,85
Prosjek:	12,00	10,72	10,59	8,47	7,62	9,99
Izgradnja nove mreže – maksimum	27,84	24,52	11,93	12,93	11,63	10,05
Izgradnja nove mreže – minimum	8,03	7,19	10,46	4,06	3,66	9,85
Izgradnja nove mreže – prosjek	16,09	14,30	11,12	7,82	7,05	9,85
Prosjek:	17,32	15,34	11,17	8,27	7,45	9,92

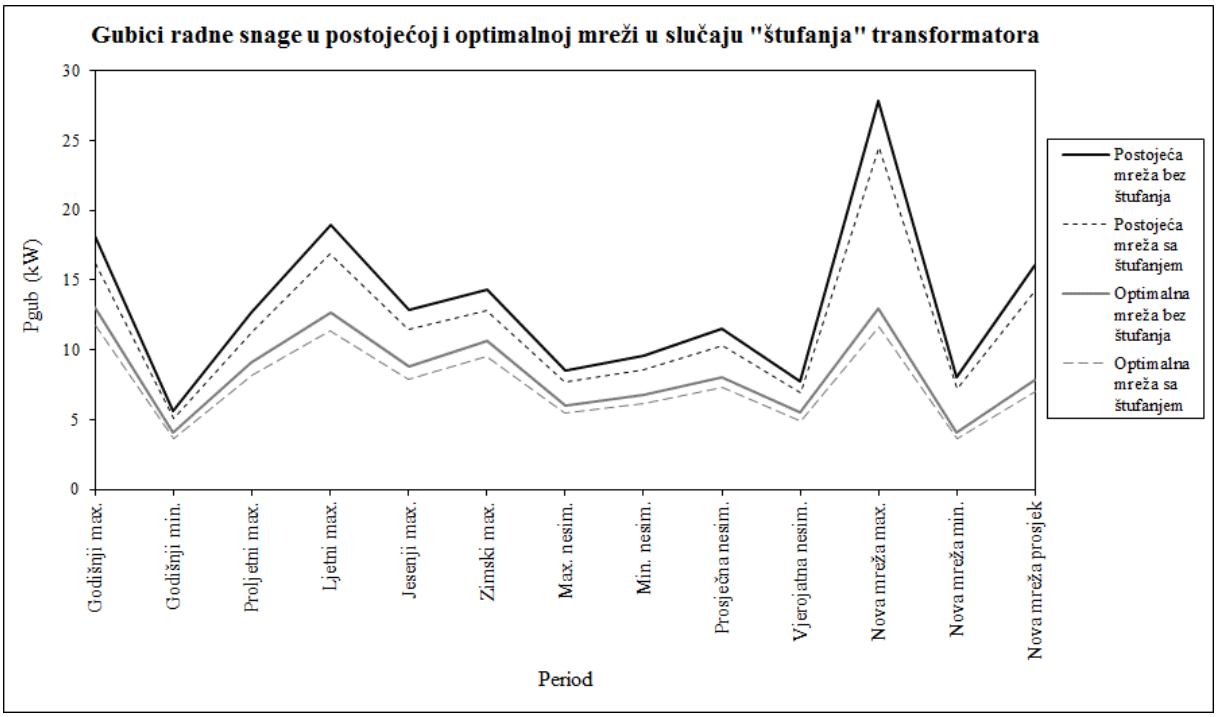

Slika 5.35. *Gubici radne snage postojeće i optimalne distribucijske mreže pri različitom opterećenju potrošača i vremenskim periodima za slučaj „štufanja“ transformatora*

Tablica 5.114. *Gubici radne snage za različito opterećenje potrošača postojeće i optimalne niskonaponske mreže u slučaju promjene presjeka vodiča magistralnog voda*

Opterećenje transformatorske stanice i izvoda	Postojeća mreža			Optimalna mreža		
	Bez promjene presjeka	Sa promjenom presjeka	Smanjenje gubitaka	Bez promjene presjeka	Sa promjenom presjeka	Smanjenje gubitaka
	P_{gub} (kW)		(%)	P_{gub} (kW)		(%)
Godišnji maksimum	18,18	12,71	30,09	13,09	10,17	22,31
Godišnji minimum	5,60	4,03	28,04	4,08	3,22	21,08
Proljetni maksimum	12,63	8,79	30,40	9,07	7,00	22,82
Ljetni maksimum	18,99	13,02	31,44	12,64	9,93	21,44
Jesenski maksimum	12,83	8,84	31,10	8,81	7,05	19,98
Zimski maksimum	14,36	10,31	28,20	10,63	8,21	22,77
Maksimalna nesimetrija	8,55	6,05	29,24	6,05	4,77	21,16
Minimalna nesimetrija	9,61	6,78	29,45	6,78	5,34	21,24
Prosječna nesimetrija	11,50	8,07	29,83	8,07	6,34	21,44
Vjerojatna nesimetrija	7,72	5,48	29,02	5,48	4,32	21,17
Prosjek:	12,00	8,41	29,68	8,47	6,64	21,54
Izgradnja nove mreže – maksimum	27,84	17,78	36,14	12,93	10,62	17,87
Izgradnja nove mreže – minimum	8,03	5,44	32,25	4,06	3,37	17,00
Izgradnja nove mreže – prosjek	16,09	10,62	34,00	7,82	6,46	17,39
Prosjek:	17,32	11,28	34,13	8,27	6,82	17,42

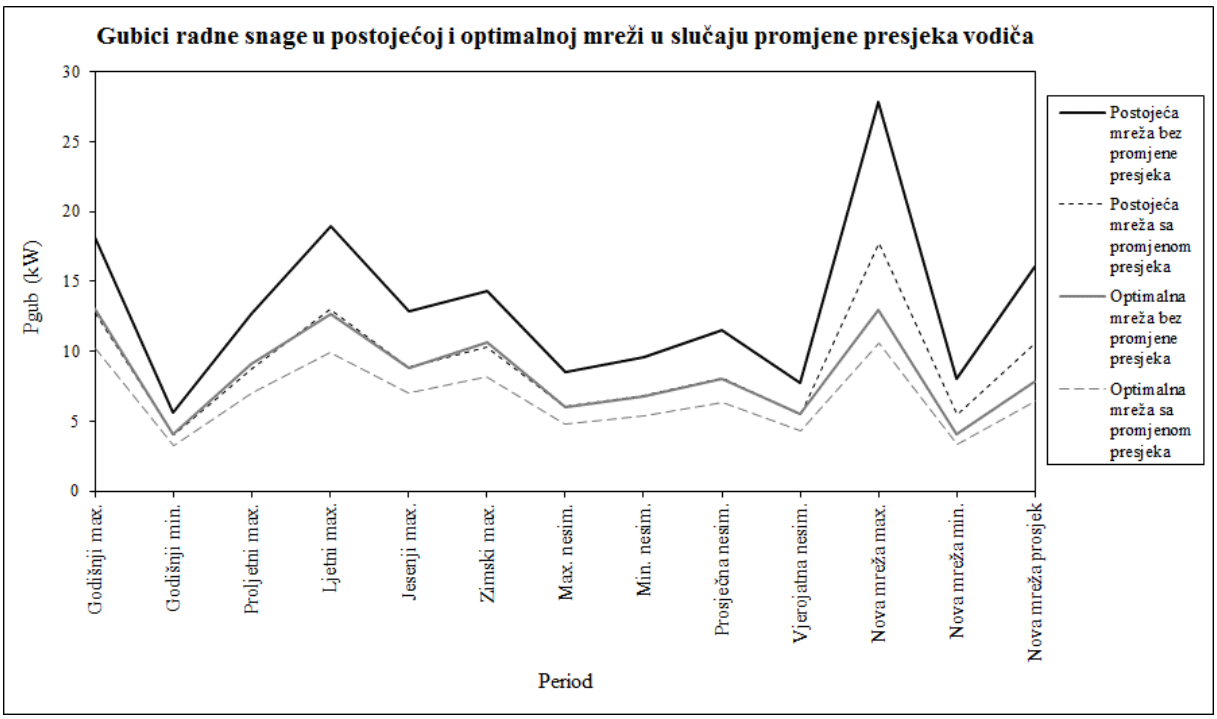

Slika 5.36. *Gubici radne snage postojeće i optimalne distribucijske mreže pri različitom opterećenju potrošača i vremenskim periodima za slučaj promjene presjeka vodiča*

Tablica 5.115. *Gubici radne snage za različite vrijednosti opterećenja potrošača postojeće i optimalne niskonaponske mreže u slučaju implementiranja novog izvora*

Opterećenje transformatorske stanice i izvoda	Postojeća mreža			Optimalna mreža		
	Bez novog izvora	Sa novim izvorom	Smanjenje gubitaka	Bez novog izvora	Sa novim izvorom	Smanjenje gubitaka
	P_{gub} (kW)		(%)	P_{gub} (kW)		(%)
Godišnji maksimum	18,18	10,35	43,07	13,09	7,76	40,72
Godišnji minimum	5,60	3,28	41,43	4,08	2,50	38,73
Proljetni maksimum	12,63	7,08	43,94	9,07	5,31	41,46
Ljetni maksimum	18,99	10,48	44,81	12,64	7,55	40,27
Jesenski maksimum	12,83	7,02	45,28	8,81	5,56	36,89
Zimski maksimum	14,36	8,58	40,25	10,63	6,25	41,20
Maksimalna nesimetrija	8,55	4,90	42,69	6,05	3,69	39,01
Minimalna nesimetrija	9,61	5,50	42,77	6,78	4,12	39,23
Prosječna nesimetrija	11,50	6,53	43,22	8,07	4,88	39,53
Vjerojatna nesimetrija	7,72	4,44	42,49	5,48	3,35	38,87
Prosjek:	12,00	6,82	43,00	8,47	5,10	39,59
Izgradnja nove mreže – maksimum	27,84	13,57	51,26	12,93	8,33	35,58
Izgradnja nove mreže – minimum	8,03	4,18	47,95	4,06	2,68	33,99
Izgradnja nove mreže – prosjek	16,09	8,13	49,47	7,82	5,10	34,78
Prosjek:	17,32	8,63	49,56	8,27	5,37	34,78

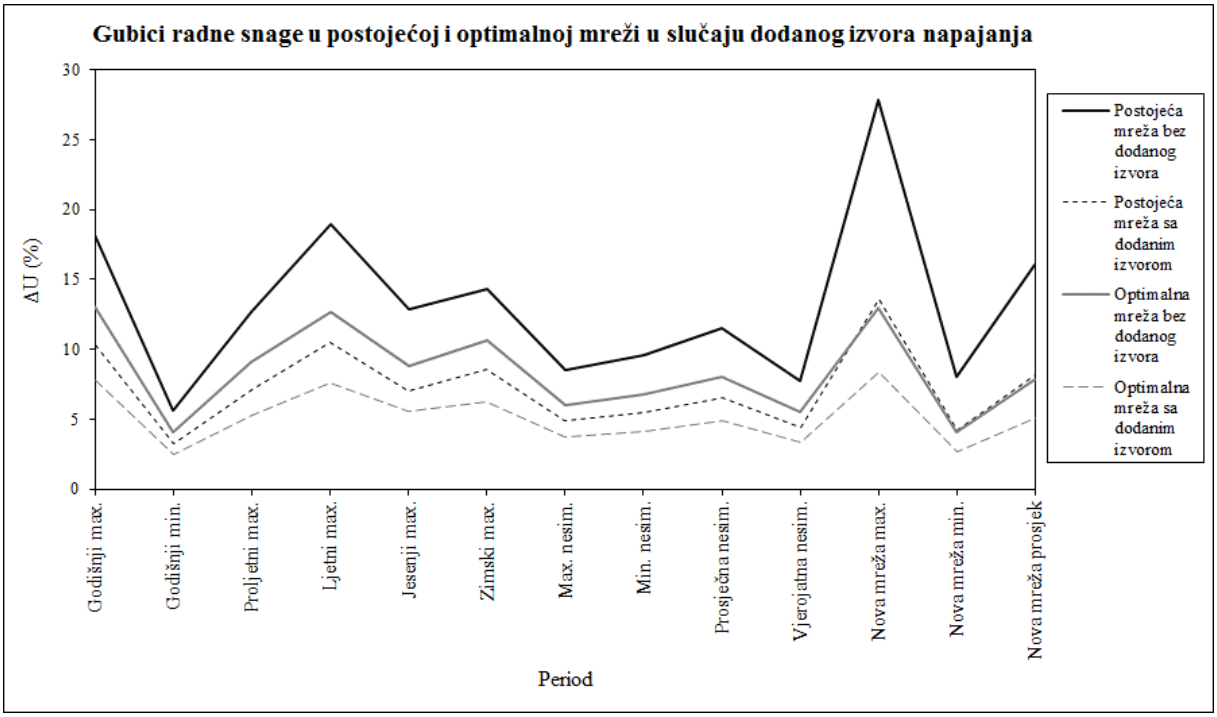

Slika 5.37. *Gubici radne snage postojeće i optimalne distribucijske mreže pri različitom opterećenju potrošača i vremenskim periodima za slučaj dodavanja izvora napajanja*

U slučaju štufanja transformatora smanjenje gubitaka radne snage je oko 10%, što je u odnosu na smanjenje padova napona za taj slučaj znatno manji iznos, odnosno ova mjera daje znatno bolje učinke u pogledu padova napona nego što utječe na gubitke radne snage.

Kada se radi o promjeni presjeka vodiča magistralnog voda, onda su učinci slični mada nešto izraženiji kod padova napona. Za ovu mjeru je karakteristično da se njenom primjenom mogu poboljšati naponske prilike i smanjiti gubici radne snage skoro na razinu dobivene optimalne mreže. To je očigledan primjer loše konfiguracije postojeće niskonaponske mreže.

U slučaju implementiranja novog izvora napajanja, poboljšanja s aspekta padova napona su dvostruko veća u odnosu na smanjenje gubitaka radne snage.

Na slici 5.38 je prikazana usporedba gubitaka radne snage kod krajnjih potrošača svih razmatranih mreža (postojeća, optimalna, sa 5, 6, 7 i 8 izvoda) pri različitom opterećenju potrošača.

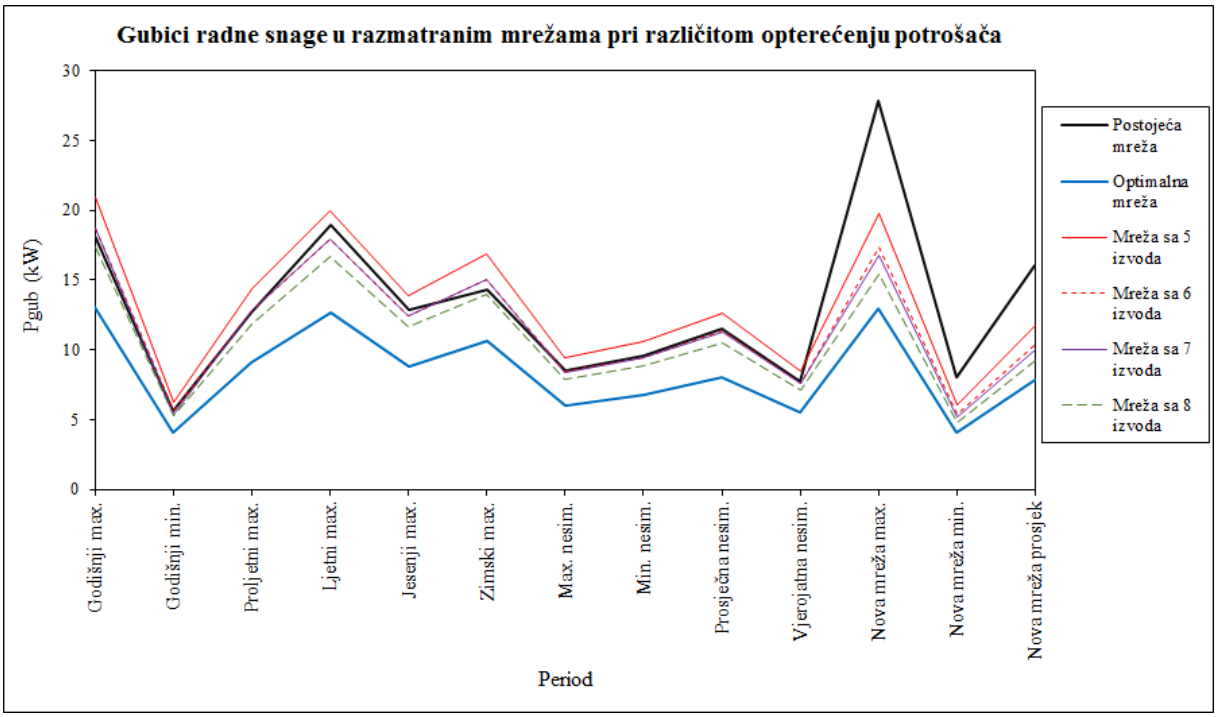

Slika 5.38. *Gubici radne snage u niskonaponskim vodovima svih razmatranih mreža pri različitom opterećenju potrošača i vremenskim periodima*

I ovdje se jasno vidi kako se primjenom predloženog modela planiranja postupno dolazi do najboljeg rješenja kada se radi o gubicima radne snage u niskonaponskim vodovima. Isto tako se vidi da su rezultati kod mreže sa 5 izvoda lošiji nego kod postojeće mreže, a da su rezultati mreža sa 6 i 7 izvoda skoro identični sa postojećom mrežom, što govori da se značajnija poboljšanja kada je u pitanju ovaj parametar postižu tek većim brojem izvoda, odnosno formiranjem optimalne konfiguracije. I ovdje se optimalno rješenje sigurno dobiva bez obzira na rezultate međukoraka.

5.13.3. Ekonomski pokazatelji primjene modela planiranja

Ono što je jako važno za elektrodistributivnu tvrtku je pitanje da li se provođenjem rekonstrukcije određene niskonaponske distribucijske mreže postižu financijski efekti, odnosno da li se kvantitativno može prikazati za koliko će se vremena provedena investicija isplatiti. Mjera temeljem koje se može utvrditi kolika je isplativost određenog projekta su gubici radne snage, odnosno još bolje gubici energije.

Najjednostavniji i najprecizniji način je izvršiti procjenu temeljem nabavljene i utrošene energije potrošača. Nabavljena energija se mjeri u transformatorskoj stanici (10 kV ili 0,4 kV strana), dok se podaci o utrošenoj energiji dobivaju zbrajanjem pojedinačnih računa za utrošenu električnu energiju svakog potrošača. Razlika ove dvije vrijednosti praktički predstavlja izgubljenu energiju, odnosno energiju gubitaka. Njenim množenjem sa prosječnom cijenom kWh može se dobiti koliki je gubitak u novcu na godišnjoj razini ili u nekom drugom vremenskom periodu. Ukoliko se isti proračun provede i za rekonstruiranu mrežu, mogu se dobiti gubici energije za taj slučaj. Usporedbom rezultata postojeće i rekonstruirane mreže dobiva se odgovor na pitanje kolike su to uštede. Ako se zna kolika je vrijednost potrebne investicije, onda se lako dobiva vrijeme za koje se provedena investicija može isplatiti.

Ovakav pristup je, međutim, moguće provesti samo kod postojećih mreža, na kojima se rade rekonstrukcije, jer je za dobivanje bilo kakve ocjene potrebno imati podatke o energijama prije i poslije izvršene rekonstrukcije mreže. Dakle, kod ovakvog pristupa nije moguće unaprijed izvršiti odgovarajuće procjene obzirom da nije moguće odrediti iznos gubitaka energije u novoj konfiguraciji mreže. U biti, ovaj pristup nije pogodan u bilo kakvom planiranju obzirom da se kvantitativne ocjene isplativosti dobivaju tek nakon provedene rekonstrukcije, odnosno bez planiranja.

Zbog svega navedenog u procesu planiranja distribucijskih mreža veličine temeljem kojih se mogu izvršiti određene procjene isplativosti investicija su opterećenje potrošača i gubici radne snage. Ove veličine dobivaju se proračunom, kako za postojeće tako i za neko buduće uklopno stanje mreže. Stoga ih je moguće uspoređivati i to za različite vrijednosti opterećenja, vremenske periode i sl. Za ovakav proračun je bitno da se gubici radne snage postojeće i buduće mreže računaju temeljem istih vrijednosti opterećenja potrošača kako bi se mogla vršiti usporedba rezultata.

U prethodnom poglavlju je prikazano na koji način se može izvršiti proračun pojedinačnih opterećenja potrošača, odnosno gubitaka radne snage. Obzirom da su gubici radne snage vremenski ovisni, odnosno promjenjivi tijekom vremena, postavlja se pitanje koju vrijednost uzeti i koristiti pri usporedbi.

Proračunom opterećenja za maksimalno i minimalno dnevno opterećenje transformatorske stanice i niskonaponskih izvoda, uz godišnju utrošenu energiju potrošača, mogu se dobiti vrijednosti maksimalnih i minimalnih gubitaka snage tijekom godine. Najjednostavniji način je pretpostaviti da se realni gubici radne snage kreću u ovim granicama, odnosno potrebno je pronaći prosječnu vrijednost.

Prosječna vrijednost gubitaka radne snage može se odrediti i temeljem proračunatih vrijednosti gubitaka za sve prikazane varijante opterećenja potrošača (proljetni maksimum, maksimalna nesimetrija itd.). U tablici 5.116 su dane prosječne vrijednosti gubitaka radne snage za sve varijante opterećenja potrošača za postojeću mrežu i optimalnu mrežu dobivenu primjenom predloženog modela planiranja.

Tablica 5.116. *Prosječni gubici radne snage postojeće i optimalne mreže*

Opterećenje potrošača	Gubici (kW)		
	Postojeća mreža	Optimalna mreža	Razlika
Godišnji maksimum	18,18	13,09	5,09
Godišnji minimum	5,60	4,08	1,52
Prosjek:	11,90	8,60	3,30
Proljetni maksimum	12,63	9,07	3,56
Ljetni maksimum	18,99	12,64	6,35
Jesenski maksimum	12,83	8,81	4,02
Zimski maksimum	14,36	10,63	3,73
Maksimalna nesimetrija	8,55	6,05	2,50
Minimalna nesimetrija	9,61	6,78	2,83
Prosječna nesimetrija	11,50	8,07	3,43
Najvjerojatnija nesimetrija	7,72	5,48	2,24
Prosjek:	12,02	8,44	3,58

Dakle, može se pretpostaviti da se u postojećoj mreži gubici radne snage kreću u granicama $11{,}90\ \text{kW} \le P_{gub_{postojeće}} \le 12{,}02\ \text{kW}$, odnosno može se uzeti da je vjerojatna vrijednost gubitaka $P_{gub_{postojeće}} = 11{,}96\ \text{kW}$. Za optimalnu mrežu vrijedi $8{,}44\ \text{kW} \le P_{gub_{optimalne}} \le 8{,}60\ \text{kW}$, odnosno vjerojatna vrijednost gubitaka je $P_{gub_{optimalne}} = 8{,}52\ \text{kW}$. Razlika ovih gubitaka predstavlja uštedu, odnosno $\Delta P_{gub} = P_{gub_{postojeće}} - P_{gub_{optimalne}} = 11{,}96 - 8{,}52 = 3{,}44\ \text{kW}$.

Temeljem ovog podatka i cijene kWh električne energije, u slučaju rekonstrukcije postojeće mreže i stvaranja optimalne konfiguracije ostvarile bi se novčane uštede kako je to prikazano u tablici 5.117.

Tablica 5.117. *Novčane uštede temeljem gubitaka radne snage*

Gubici snage (kW)	Broj sati u godini (h/god)	Gubici energije (kWh/god)	Cijena el. energije (€/kWh)	Ušteda (€/god)
3,44	8760	30.167,25	0,08076	2.436,31

Ukoliko se promatraju prednosti na prihodovnoj strani za jednu transformatorsku stanicu koji se dobivaju samo reduciranjem gubitaka radne snage, onda su oni mali. Međutim, imajući u vidu da u elektroenergetskom sustavu postoji veliki broj ovakvih transformatorskih područja, onda se primjenom predloženih mjera oni multipliciraju. To se naročito odnosi na sustave u kojima je razvoj niskonaponskih distribucijskih mreža tekao nesustavno pa se tijekom vremena, uslijed neplanskog razvoja, stvorio jako veliki broj mreža sa sličnom problematikom. Rekonstrukcija tolikog broja mreža prema istom modelu bi donijela višemilijunske uštede na godišnjoj razini. Ovo je značajno i iz razloga što se ne radi o jednokratnim dobicima nego se ostvaruju trajno i mogu se promatrati i u dužem vremenskom periodu.

Postavlja se pitanje za koji se vremenski period, samo uštedama u gubicima snage, mogu isplatiti uložena sredstva. Stoga je potrebno napraviti usporedbu troškova izgradnje optimalne mreže prema predloženom modelu i postojeće mreže. Usporedba se treba napraviti temeljem istog cjenika za obje mreže obzirom da se radi o približnoj procjeni, ne toliko preciznoj.

U tablicama 5.118 i 5.119 prikazani su procijenjeni investicijski troškovi za postojeću mrežu i optimalnu mrežu dobivenu primjenom predloženog modela planiranja.

Tablica 5.118. *Procijenjeni investicijski troškovi postojeće niskonaponske mreže*

Izvod	Broj stupova	Ukupno stupovi (€)	SKS 70 mm^2 (m)	Ukupno SKS (€)	SKS 35 mm^2 (m)	Ukupno SKS (€)	SKS 16 mm^2 (m)	Ukupno SKS (€)	Al– Fe 25 mm^2 (m)	Ukupno Al–Fe (€)	Ukupno (€)
1	12	10.453	242	2.475	140	2.247	648	2.650	0	0	16.727
2	14	12.195	499	5.104	0	0	777	3.178	0	0	20.477
3	29	25.262	573	5.865	223	3.574	1.507	6.167	488	1.287	40.409
4	8	6.969	258	2.638	33	535	675	2.760	96	253	12.893
5	30	26.133	820	8.386	155	2.477	1.392	5.696	244	643	42.124
Ukupno:	93	81.012	2.392	24.467	552	8.832	4.998	20.451	828	2.182	132.631

Tablica 5.119. *Procijenjeni investicijski troškovi optimalne niskonaponske mreže*

Izvod	Broj stupova	Ukupno stupovi (€)	SKS 70 mm^2 (m)	Ukupno SKS (€)	SKS 35 mm^2 (m)	Ukupno SKS (€)	SKS 16 mm^2 (m)	Ukupno SKS (€)	Ukupno (€)
1	21	18.293	111	1.134	364	2.981	569	2.327	24.736
2	36	31.360	237	2.428	688	5.627	821	3.360	42.775
3	26	22.649	409	4.184	525	4.294	706	2.888	34.015
4	33	28.746	134	1.367	695	5.684	506	2.069	37.867
5	15	13.066	334	3.421	228	1.863	253	1.037	19.387
6	26	22.649	157	1.608	552	4.519	419	1.714	30.490
7	28	24.391	359	3.672	412	3.376	351	1.436	32.875
8	13	11.324	664	6.794	35	284	205	841	19.242
Ukupno:	198	172.478	2.405	24.608	3.498	28.627	3.830	15.673	241.386

Na ove troškove je potrebno dodati cijenu izgradnje transformatorske stanice koja u prikazanom primjeru iznosi 30.519 €, te je razlika u procijenjenim investicijskim troškovima 108.755 €.

U tablici 5.120 je dana gruba vremenska procjena isplativosti investicije samo temeljem ušteda u gubicima radne snage.

Tablica 5.120. *Procijenjeno vrijeme isplate investicije*

Procijenjena razlika investicijskih troškova (€)	Procijenjena ušteda temeljem gubitaka (€/god)	Procijenjeno vrijeme isplate investicije (god)
108.755	2.436	45

Ukoliko bi se promatrala sama ušteda u gubicima radne snage, onda je očito da bi se investicija isplatila tek nakon dugog niza godina, što praktički znači da nema ekonomske isplativosti. Međutim, rekonstrukcije niskonaponskih distribucijskih mreža se ne mogu promatrati na takav način. Temeljni cilj svake rekonstrukcije je poboljšanje kvalitete električne energije koja se isporučuje kupcima, odnosno dovođenje naponskih prilika u propisane okvire. Bit takvih postupaka je zadovoljavanje elementarnih potreba kupaca za kvalitetnom električnom energijom, što je u tržišnim uvjetima poslovanja jako bitno jer se na taj način zadržavaju kupci i stvaraju uvjeti za priključenje novih. Sve to vodi većoj potrošnji električne energije što samo po sebi znači uvećanje profita distribucijske tvrtke.

Dakle, primarne prednosti rekonstrukcije niskonaponske mreže ne treba tražiti kroz uštede u gubicima radne snage. Oni se očito ogledaju u povećanju protoka energije, što se može postići samo isporukom kvalitetne električne energije. Dobre naponske razine na krajevima niskonaponskih izvoda omogućavaju priključenje značajnijih potrošača, koji u slučaju loših naponskih prilika nisu u stanju normalno raditi, a značajniji potrošači znače više isporučene energije, odnosno veći profit. Osim toga, dostizanje propisanih naponskih razina, u uvjetima tržišnog poslovanja, je i cilj distribucijskih tvrtki koje su se obvezale dostići ih u odgovarajućem vremenskom periodu.

Ipak, vrijedno je ponovno napomenuti da u slabije razvijenim distribucijskim sustavima postoji značajan broj transformatorskih područja na koja je potrebno primijeniti slične mjere tako da se cjelokupne uštede koje se postignu preko gubitaka radne snage ni u kojem slučaju ne smiju zanemariti.

O kolikim gubicima u niskonaponskoj mreži se zapravo radi može se pokazati na primjeru realnog distributivnog područja jedne distribucijske tvrtke. Ovo područje zauzima 2.650 km^2 sa oko 500.000 stanovnika, u 380 naseljenih mjesta i gustoćom naseljenosti od 188 stanovnika po km^2. Distribucijska mreža ovog područja napaja se preko prijenosne mreže koja ima 11 TS 110/x kV, ukupne instalirane snage 730 MVA. Zabilježeno sumarno vršno opterećenje ovog područja u 2014 godini je 250 MVA. Distribucijska mreža ima dvije naponske razine i to: 35 kV i 10 kV. Ukupan broj TS 35/x kV je 49, ukupne instalirane snage 512 MVA, dok je ukupan broj TS 10(20)/0,4 kV 2.075, ukupne instalirane snage 585 MVA. Preko ove mreže električnom

energijom je opskrbljeno 181.858 kupaca, od čega je 38 kupaca na 35 kV naponskoj razini, 155 na 10 kV naponskoj razini i 181.665 kupaca na 0,4 kV naponskoj razini. Ukupna nabavljena energija u 2014 godini je 1.227.183.411 kWh, dok je utrošena energija 1.119.016.521 kWh. Proračuni su načinjeni temeljem nabavljene i utrošene energije za različite naponske razine (35 kV, 10 kV i 0,4 kV). U tablici 5.121 su prikazani ukupni gubici energije u cijelome distribucijskom sustavu.

Tablica 5.121. *Ukupni gubici energije realnog distribucijskog sustava*

Nabavljena energija na 35 kV i 10 kV (kWh)	Utrošena energija na 35 kV, 10 kV i 0,4 kV (kWh)	Ukupni gubici energije	
		(kWh)	(%)
1.227.183.411	1.119.016.521	108.166.890	8,81

Ukoliko se promatraju samo niže naponske razine (10 kV i 0,4 kV), bez 35 kV mreže, onda gubici energije iznose kako je to prikazano u tablici 5.122.

Tablica 5.122. *Gubici energije u 10 kV i 0,4 kV distribucijskoj mreži*

Nabavljena energija na 10 kV (kWh)	Utrošena energija na 10 kV i 0,4 kV (kWh)	Gubici energije na 10 i 0,4 kV	
		(kWh)	(%)
996.293.911	898.552.612	97.741.299	9,81

Oduzimanjem vrijednosti gubitaka u 10 kV mreži, koji se dobivaju proračunom, od ovih gubitaka dobiva se procijenjeni iznos gubitaka energije u 0,4 kV mreži (Tablica 5.123).

Tablica 5.123. *Procijenjeni gubici energije u 0,4 kV distribucijskoj mreži*

Gubici energije na 10 kV i 0,4 kV (kWh)	Proračunati gubici energija na 10 kV		Procijenjeni gubici energije na 0,4 kV	
	(kWh)	(%)	(kWh)	(%)
97.741.299	26.640.748	2,25	71.100.551	5,99

U tablici 5.124 je prikazan postotni udio gubitaka prema naponskim razinama.

Tablica 5.124. *Postotni udio gubitaka energije obzirom na naponsku razinu*

Ukupni gubici energije (kWh)	Gubici energije na 35 kV	Udio gubitaka energije na 35 kV	Gubici energije na 10 kV	Udio gubitaka energije na 10 kV	Gubici energije na 0,4 kV	Udio gubitaka energije na 0,4 kV
	(kWh)	(%)	(kWh)	(%)	(kWh)	(%)
108.166.890	10.425.591	9,64	26.640.748	24,63	71.100.551	65,73

Vidi se da u ovom sustavu gubici u niskonaponskoj mreži imaju najveći udio u ukupnim gubicima. Ako se uzme ista cijena energije po kWh dobiva se da su na godišnjoj razini gubici u 0,4 kV distribucijskoj mreži 71.100.551 kWh/god · 0,08076 €/kWh = 5.742.081 €/god.

Ako se pretpostavi da sva transformatorska područja imaju slične probleme, odnosno da se rekonstrukcijom mreže postiže smanjenje gubitaka za približno:

$$\Delta P_{gub}\ (\%) = \frac{\Delta P_{gub}(kW)}{P_{gub_{postojeće}}(kW)} \cdot 100\ \% = \frac{3,44}{11,96} \cdot 100\ \% = 28,8\ \%$$

može se reći da bi, sređivanjem stanja u cjelokupnoj niskonaponskoj mreži, godišnja ušteda iznosila:

$$Ušteda_{god} = 5.742.081 \cdot \frac{28,8}{100} = 1.653.720\ \ €/god$$

Dakle, provođenjem mjera za smanjenje gubitaka u niskonaponskoj distribucijskoj mreži mogu se postići značajni financijski efekti.

6. ZAKLJUČAK

Planiranje distribucijskih mreža je značajan problem kojim se nastoji omogućiti učinkovito korištenje mreže kako bi se zadovoljili zahtjevi svih potrošača. U procesu planiranja distribucijske mreže postoji niz opcija kojim se može poboljšati stanje u mreži, a neke od njih su izgradnja novih ili pojačavanje postojećih vodova, izgradnja novih točaka napajanja, izmjena topologije mreže, uključivanje distribuirane proizvodnje itd. Svaka od ovih mjera mora biti ekonomski opravdana i mora voditi učinkovitijoj mreži.

Klasični modeli planiranja distribucijskih mreža temelje se na približno predvidljivom ponašanju potrošača kojem se prilagođava topologija i prijenosna snaga mreže. Prijenosna snaga mreže određuje se temeljem najvećeg opterećenja, a topologija bi trebala osigurati barem dva različita smjera napajanja, pri čemu je aktivan samo jedan u normalnom pogonu.

Suvremeni modeli planiranja distribucijskih mreža uključuju nekoliko, međusobno povezanih analiza. Temeljni zahtjev, koji uvijek mora biti zadovoljen, je pogon mreže sukladno tehničkim propisima. Stoga, u procesu planiranja uvijek moraju biti zadovoljena dva temeljna kriterija na način da:

1. svaki potrošač ima osiguran napon unutar propisanih granica,
2. niti jedan element mreže (vod ili transformator) nije preopterećen u redovitom pogonu.

Osim toga, suvremeni modeli trebaju uključivati i druge kriterije koji utječu na definiranje najboljeg rješenja. Neki od njih su kriterij minimalnih gubitaka snage i energije, kriterij minimalnih troškova izgradnje mreže, kriterij kvalitete opskrbe korisnika električne energije, kriterij pouzdanosti i sl.

U ovoj disertaciji je prikazan model planiranja niskonaponskih distribucijskih mreža koji pri višekriterijskom odlučivanju koristi četiri kriterija i to:

1. Kriterij padova napona kod krajnjih potrošača;
2. Kriterij minimalnih gubitaka radne snage;
3. Kriterij opterećenja vodova;
4. Kriterij investicijskih troškova.

Izbor kriterija koji će se koristiti pri odlučivanju ovisi isključivo o onom tko vrši planiranje. Općenito, izbor je ovisan o interesima potrošača i interesima distribucijske tvrtke. U uvjetima tržišnog poslovanja interesi kupaca su u blagoj prednosti, ali interesi tvrtki se ni u kojem slučaju ne smiju stavljati u drugi plan. Najbolji izbor je da se podjednako uvaže i jedni i drugi interesi.

Osim toga, pored izbora kriterija, vrlo značajan je i način na koji se izvrši vrednovanje kriterija, odnosno kakav je njihov međusobni odnos po hijerarhiji. Vrednovanje svakog kriterija je subjektivnog karaktera i to u biti predstavlja jedan od najvažnijih koraka.

U predloženom modelu odabran je jedan kriterij koji je na strani potrošača (padovi napona) i tri kriterija koji su na strani distribucijske tvrtke (ostali kriteriji). Ukoliko bi se promatrala samo ova pojednostavljena podjela, moglo bi se doći do zaključka da model ne tretira podjednako interese potrošača i tvrtke. Stoga je, kako bi se interesi na neki način usuglasili, kriteriju koji se odnosi na potrošače dana najveća važnost, odnosno ocjena. Na taj način postignuta je ravnoteža. U monopolističkom sustavu bi ovo zasigurno bilo na strani distribucijskih tvrtki što u tržišnim uvjetima nije prihvatljivo.

Suvremeni modeli planiranja bi se trebali temeljiti na korištenju suvremenih algoritama i softverskih rješenja. Jedinstveni i opće prihvaćeni model ne postoji. U disertaciji je predstavljen model koji se temelji na kombinaciji suvremenih hijerarhijskih i stohastičkih algoritama i to algoritma neizrazitog grupiranja, analitičkog hijerarhijskog postupka, te algoritma simuliranog kaljenja.

Algoritam neizrazitog grupiranja je vrlo prikladan za određivanje lokacije transformatorske stanice i grupiranje potrošača prema njihovoj pripadnosti niskonaponskom izvodu. Analitički hijerarhijski postupak je vrlo prikladno rješenje za odabir najbolje konfiguracije mreže metodom višekriterijskog odlučivanja. Algoritam simuliranog kaljenja je jedan od niza optimizacijskih algoritama koji se mogu koristiti za dobivanje optimalne konfiguracije mreže sa stanovišta energetskih prilika u mreži. Sve zajedno daje jedan vrlo praktičan i lako primjenjiv model planiranja distribucijskih mreža.

Dobiveni rezultati pokazuju da primjena modela daje niz prostornih rješenja. Kod manjih i manje složenih distribucijskih mreža, u nekim slučajevima, ovo je sasvim dovoljno pa nema potrebe da se procedura provodi do kraja. I pored toga, obzirom da se ne radi o složenom postupku, optimalno rješenje bi trebalo uvijek biti krajnji cilj.

Proračuni koji se provode prema ponuđenom modelu načinjeni su temeljem vršnih opterećenja potrošača za različite vremenske periode. Rezultati su pokazali da konačno rješenje ne ovisi o proračunu pojedinačnih opterećenja potrošača. To ukazuje na činjenicu da pojedinačna opterećenja potrošača i ne moraju biti vršna, odnosno mogu se uzeti opterećenja dobivena na neki drugi način. Bitno je samo da se proračuni tokova snaga za sve alternative, odnosno za postojeće mreže vrše temeljem opterećenja potrošača dobivenim na identičan način. Samo na taj način je moguće vršiti usporedbu rezultata i donositi određene zaključke.

Najbolji način za procjenu pojedinačnih opterećenja potrošača je poznavanje krivulje opterećenja za razne kategorije potrošača. Za tu svrhu je potrebno imati dovoljan broj snimljenih dnevnih dijagrama opterećenja različitih potrošača. Uz to, potrebno je poznavati navike svakog potrošača kada je u pitanju potrošnja električne energije. Na taj način, svakom potrošaču posebno može se pridružiti određena krivulja opterećenja temeljem koje će se odabrati određena vrijednost opterećenja bitna za proračun. Naravno, isti princip mora važiti za sve potrošače. Obzirom da u mjernom sustavu elektrodistributivnih tvrtki obično nisu dostupni nikakvi podaci o opterećenju niskonaponskih potrošača, ovo bi bio jedan od učinkovitijih načina za određivanje ukupnog opterećenja promatranog područja.

Kada se radi o projektiranju u cijelosti novih distribucijskih mreža onda postoje dva načina za određivanje opterećenja potrošača:

1. Pomoću faktora istodobnosti (svi potrošači imaju isto opterećenje);
2. Pomoću krivulja opterećenja (svaki potrošač ima drugačije opterećenje u ovisnosti o karakteru potrošnje).

Analiza rezultata pokazuje da ni eventualna nesimetrija napona koja se može pojaviti u mreži nema značajnijeg utjecaja na konačno rješenje. Naime, u disertaciji su prezentirani rezultati proračuna za različite vrijednosti nesimetrije koje su se pojavile tijekom perioda od godinu dana. Može se vidjeti da su vrijednosti nesimetrije u niskonaponskoj mreži daleko ispod granica propisanih normom, što je potvrđeno i mjerenjem u određenim sedmodnevnim intervalima. Očito da tako niske vrijednosti nesimetrije ne mogu utjecati na konačne rezultate. Najbolji način da se zanemari potreba za analiziranjem utjecaja nesimetrije je da se pri proračunu opterećenja potrošača promatraju vrijednosti opterećenja niskonaponskih izvoda i transformatora po fazama, a da se kao satno opterećenje uzima njihov zbroj. Na taj način bi utjecaj nesimetrije bio obuhvaćen vrijednošću maksimalnog opterećenja. Tada bi se samo moglo diskutirati o utjecaju nesimetrije radi pojave napona na nultome vodiču, ali obzirom da se radi o izuzetno malim vrijednostima taj utjecaj bi se mogao zanemariti.

Dobivanje optimalnog rješenja je konačni cilj primjene predloženog modela. Kako je to prezentirano, za dobivanje ovog rješenja neophodno je uspostaviti određeni broj interkonekcija unutar mreže. Njihov broj nije ograničen. Veći broj interkonekcija u principu znači kvalitetnije rješenje, ali se mora imati u vidu da bi zbog prevelikog broja mogućnosti, vrijeme proračuna bilo znatno duže. Osim toga, broj interkonekcija je ograničen i samom topologijom, odnosno prostornom razdiobom mreže. Ukoliko vrijeme nije presudno, onda je uvijek bolje uspostaviti malo veći broj veza kako bi se dobilo što kvalitetnije rješenje.

Za dobivanje optimalnog rješenja predloženi model koristi algoritam simuliranog kaljenja, mada za tu svrhu može poslužiti i neki drugi optimizacijski algoritam. Općenito, u nekim slučajevima rezultati koji se dobivaju ovim algoritmom ovisni su o polaznoj temperaturi kaljenja i uspostavljenoj brzini hlađenja. Dobiveni rezultati pokazuju da se istovjetna rješenja dobivaju ukoliko simulirani proces kaljenja započinje na vrlo visokim temperaturama kao i na nižim temperaturama. Isto tako, pokazalo se da na rješenja nema utjecaj ni brzina hlađenja, odnosno da li se hlađenje odvija brzo ili sporo. Međutim, to je slučaj kada se radi o relativno malom broju sabirnica (potrošača) i ne toliko složenoj (po veličini) mreži. Ukoliko bi se tražilo optimalno rješenje za veliku distribucijsku mrežu, sa jako velikim brojem potrošača, onda bi simulacije trebalo provoditi sa vrlo visokom polaznom temperaturom i veoma sporim hlađenjem. Samo na taj način bi se u procesu hlađenja mogao uspostaviti dovoljno veliki broj simulacija, pri čemu bi svaka davala određeno rješenje. U tom slučaju postoji dovoljan broj simulacija da algoritam dovoljan broj puta „prođe“ kroz točku optimuma što u konačnici garantira dobivanje zasigurno najboljeg, odnosno optimalnog rješenja.

Predloženi model upotrijebljen je za projektiranje niskonaponske distribucijske mreže određenog zemljopisnog područja. U praksi, na tom području postoji izgrađena distribucijska mreža koja opskrbljuje električnom energijom predmetne potrošače. Stoga su i za postojeću mrežu izvršeni identični proračuni kako je to urađeno u modelu. Usporedba rezultata pokazuje da se modelom dobivaju znatno bolji rezultati, što daje praktičnu potvrdu primjene predloženog modela planiranja. Istina, ukoliko se ti rezultati promatraju u apsolutnim vrijednostima onda bi se mogao izvući zaključak da poboljšanja i nisu toliko značajna, barem kada se promatraju gubici radne snage. Pošto se radi o primjeru niskonaponske mreže, sa veoma malim iznosom opterećenja potrošača, onda se i ne mogu očekivati značajnija poboljšanja. Međutim, uzme li se u obzir da u jednom distribucijskom sustavu, sa značajno izraženim neplanskim razvojem niskonaponskih mreža, može postojati veliki broj (ponegdje i tisuće) mreža u sličnom stanju, onda se jednostavnim računom da zaključiti da bi cjelokupne uštede koje bi se mogle ostvariti bile veoma značajne. S druge strane, ukoliko se promatraju poboljšanja koja su vezana za padove napona kod krajnjih potrošača i obveze tvrtki da ih dovedu u propisane granice, onda je primjena jednog ovakvog modela neupitna jer zasigurno nudi rješenja znatno bolja od postojećih.

Jedna važna činjenica je da se primjenom ovakvog modela na postojeće distribucijske mreže mogu detektirati problemi u njima vezani, prije svega, za naponske prilike. Iz tog kuta gledano, model je veoma praktičan za detektiranje kritičnih mjesta i može ponuditi rješenja za njihovo rješavanje. Naime, ukoliko dobiveni rezultati nisu zadovoljavajući onda se unaprijed mogu provjeriti efekti primjene određenih mjera, prije nego što se nešto praktično i uradi na terenu. Poznato je da se naponske prilike u mreži mogu poboljšati primjenom određenih mjera kao što su skraćivanje duljine niskonaponskih izvoda, izgradnja novih niskonaponskih izvoda radi rasterećenja postojećih, promjena presjeka vodiča magistralnih vodova, injektiranje dodatnog izvora napajanja u mrežu (nekog od distribuiranih izora pod uvjetom da se ne narušava kvaliteta električne energije) i sl. U praksi, bez praktične implementacije i mjerenja nije moguće provjeriti koliki su učinci. Stoga model ima značajnu prednost u primjeni.

Predloženi model koristi opisane hijerarhijske i stohastičke metode. Korišteni algoritmi programirani su i prilagođeni modelu kako bi se mogli provoditi pojedini koraci predviđene procedure. U biti, neki sličan model bi mogao koristiti i neke druge metode, s tim da je potrebno zadržati redoslijed koraka u proceduri koja se implementira. Dakle, redoslijed je slijedeći: odrediti lokaciju transformatorske stanice, izvršiti grupiranje potrošača (odrediti broj niskonaponskih izvoda), formirati mrežnu topologiju, odrediti najbolje prostorno rješenje i odrediti optimalno uklopno stanje takvog rješenja. Kojim metodama i algoritmima postići sve ovo pitanje je inženjerske procjene, odnosno poznavanja funkcioniranja distribucijskih sustava i programerskog umijeća onoga tko se bavi izradom modela.

Na kraju, može se reći da model ima svoje mjesto u praktičnoj primjeni. Zbog svog jednostavnog pristupa model je na isti način primjenjiv i za distribucijske mreže srednjeg napona, što mu daje dodatnu težinu i proširuje opseg primjenjivosti.

Iskusnim inženjerima i planerima distribucijskih mreža model može poslužiti kao vrlo koristan alat jer znatno olakšava postupak projektiranja novih mreža, te pruža mogućnost detektiranja i rješavanja problema u postojećim distribucijskim mrežama srednjeg i niskog napona.

POBOLJŠANI MODEL ZA PLANIRANJE NISKONAPONSKIH DISTRIBUCIJSKIH MREŽA KOMBINIRANJEM HIJERARHIJSKIH I STOHASTIČKIH OPTIMIZACIJSKIH METODA

SAŽETAK

U ovoj disertaciji predstavljen je novi, poboljšani model za planiranje niskonaponskih distribucijskih mreža. Model koristi hijerarhijske i stohastičke metode optimizacije, kao i suvremene programe za crtanje i proračune tokova snaga. Iz skupine hijerarhijskih metoda u modelu su korištene metoda neizrazitog grupiranja i analitički hijerarhijski postupak. Uporaba ovih metoda daje najbolje prostorno rješenje niskonaponske distribucijske mreže. Iz skupine stohastičkih metoda u modelu je korištena metoda simuliranog kaljenja. Uporaba ove metode daje optimalno uklopno stanje najboljeg prostornog rješenja. Za crtanje prostornih rješenja distribucijske mreže u modelu je korišten AutoCAD, dok je za proračune tokova snaga korišten Matlab–Matpower. U prvom dijelu disertacije dane su kratke teorijske postavke o distribucijskim mrežama, te matematička interpretacija procesa optimizacije i korištenih optimizacijskih metoda. U drugom dijelu je prezentiran novi, poboljšani model planiranja, rezultati primjene modela za određeno zemljopisno područje, odnosno skupinu potrošača, kao i usporedba rezultata sa postojećom distribucijskom mrežom. Iz rezultati dobivenih primjenom predloženog modela može se uočiti da se dobiva niz prostornih rješenja, pri čemu projektant odabire najprihvatljivije. Također, model daje mogućnost dobivanja optimalnog uklopnog stanja odabranog prostornog rješenja. Usporedni rezultati dobiveni primjenom modela i postojeće distribucijske mreže pokazuju znatna poboljšanja parametara mreže. To je praktična potvrda opravdanosti primjene predloženog modela planiranja. Njegova primjena naročito dolazi do izražaja u neplanski građenim distribucijskim sustavima gdje se zbog velikog broja sličnih mreža, sa izraženim problemima u eksploataciji, njihovim rješavanjem mogu postići značajne financijske uštede. Mogućnost uporabe modela za detektiranje problema u postojećim mrežama i provjeru predloženih rješenja predstavlja dodatnu prednost. Jedna od prednosti modela je i mogućnost uporabe i drugih optimizacijskih metoda koje su prihvatljivije za druge projektante, ovisno o njihovim programerskim sposobnostima, ali uz primjenu istih koraka u implementiranoj proceduri. U disertaciji je obrađen primjer niskonaponske distribucijske mreže, ali model se uspješno može koristiti i za projektiranje distribucijskih mreža srednjeg napona, što dodatno proširuje opseg njegove primjenjivosti. Obzirom na jednostavnost procedure koju je potrebno provesti iskusnim inženjerima i planerima distribucijskih mreža model može poslužiti kao vrlo koristan alat i ima svoje mjesto u praktičnoj primjeni.

Ključne riječi: Distribucijske mreže, Optimizacija, Hijerarhijske metode, Stohastičke metode, Neizrazito grupiranje, AHP, Simulirano kaljenje, Modeli planiranja

IMPROVED MODEL FOR PLANNING OF LOW–VOLTAGE DISTRIBUTION NETWORKS BY COMBINING HIERARCHICAL AND STOCHASTIC OPTIMIZATION METHODS

ABSTRACT

A new, improved model for planning of low–voltage distribution networks is presented in this dissertation. The model uses hierarchical and stochastic optimization methods, as well as modern programs for drawing and load flow calculations. From the group of hierarchical methods, fuzzy clustering method and analytic hierarchy process are used in the model. Usage of these methods gives the best spatial solution of low–voltage distribution network. From the group of stochastic methods, simulated annealing method is used in the model. Usage of this method gives the optimal switching condition of the best spatial solution. For drawing the spatial solutions of distribution network AutoCAD is used in the model, while for load flow calculations Matlab–Matpower is used. In the first part of the dissertation a short theoretical assumptions about distribution networks are given, as well as mathematical interpretation of optimization process and used optimization methods. In the second part, a new, improved planning model, the results of model application to the specific geographical area or group of customers, as well as the comparison of results with the existing distribution network are presented. From the results obtained by the usage of proposed model it can be seen that a series of spatial solutions is obtained, and the designer can select the most appropriate. Also, the model provides the possibility of obtaining the optimal switching condition of selected spatial solution. Comparable results obtained by model implementation and existing distribution network show significant improvement of network parameters. That is a practical confirmation of a justification for the proposed planning model application. Its application is particularly evident in unplanned built distribution systems, where there is a large number of similar networks, with distinct problems in exploitation, so their resolution can give a significant financial savings. The ability of the model to detect problems in the existing networks and verification of proposed solutions is an additional advantage. One of the advantages of the model is the ability for usage the other optimization methods as well, that are more acceptable for other designers, depending on their programming skills, but the same steps in the implemented procedure have to be used. In the dissertation is presented an example of low–voltage distribution network, but the model can be successfully used for designing the medium–voltage distribution networks, which further expands its scope of applicability. Considering the simplicity of the procedure that is necessary to be conducted for experienced engineers and planners of distribution networks the model can serve as a very useful tool and has its place in the practical application.

Key words: Distribution network, Optimization, Hierarchical methods, Stochastic methods, Fuzzy clustering, AHP, Simulated annealing, Planning models

LITERATURA

[1] Carol A. Dahl: *Međunarodna tržišta energije,* Kigen d.o.o, Zagreb, 2008

[2] Slavko Krajcar, Ivan Andročec, Gerd Solem: *Elements for Electricity Trading*, Training Centre for Energy Trading, 2006

[3] Viktoria Neimane: *On Developement Planning of Electricity Distribution Networks*, Royal Institute of Technology, Doctoral Dissertation, Stockholm, 2001

[4] Marcos Carneiro Da Silva, Paulo Morelato Franca, Paulo D. Bishop Da Silveira: *Long–Range Planning of Power Distribution Systems: Secondary Networks*, Computers Electrical Engineering, Elsevier Scienece, Vol. 22, pp. 179–191, 1996

[5] R. C. Bansal Dr.: *Optimization Methods for Electric Power Systems: An Overview*, 2005

[6] Ranko Goić: *Distributivne mreže*, Fakultet elektrotehnike, strojarstva i brodogradnje Split, Lipanj 2001

[7] Nikša Fabris, Josip Letica, Damir Kurtović: *Problematika ukidanja 35 kV napona i prijelaz na izravnu transformaciju 110/20(10) kV na području Elektrodalmacije Split*, HO CIRED, 4 (10). savjetovanje, Trogir, Svibanj 2014

[8] Senad Smaka: *Industrijski i distributivni elektroenergetski sistemi*, Univerzitet u Sarajevu, Elektrotehnički fakultet

[9] Vitomir Komen: *Distribucijske elektroenergetske mreže*, Sveučilište u Rijeci, Tehnički fakultet

[10] Salko Maksumić: *Analiza sistema potrošnje električne energije*, Centar za energetsku efikasnost (CEE)

[11] Ranko Goić: *Windis–Programski paket za analize niskonaponskih distributivnih mreža*, Fractal d.o.o, Split, Siječanj 2003

[12] Salih Sadović: *Elektroenergetske mreže i sistemi*, Univerzitet u Sarajevu, Elektrotehnički fakultet

[13] JP EP BiH: *Elaborat–Rezultati proračuna tokova snaga i tehničkih gubitaka snage i energije u Podružnici Elektrodistribucija Tuzla*, Sektor operatora distribucije, Služba za energetske analize i kvalitet električne energije, Juni 2014

[14] Ranko Goić: *Primjena programskog paketa PowerCAD za analizu gubitaka snage i energije u distributivnim mrežama*, HO CIGRE, 5. savjetovanje, Cavtat, Studeni 2001

[15] Ranko Goić: *Energetski proračuni niskonaponske mreže*, Fakultet elektrotehnike, strojarstva i brodogradnje Split, Zavod za elektroenergetiku, Travanj 2003

[16] Andreas Klose, Andreas Drexl: *Facility Location Models for Distribution System Design*, European Journal of Operational Research, Vol. 162, Issue 1, pp. 4–29, 2005

[17] F. C. Chan: *Electric Power Distribution Systems*, Encyclopedia of Life Support Systems (EOLSS), Vol. III, pp. 317–343, 2009

[18] Branko Štefić, Srete Nikolovski: *Prijenos i distribucija električne energije*, Sveučilište J.J. Strossmayera u Osijeku, Elektrotehnički fakultet, 2001

[19] European Standard: *Voltage Characteristics of Electricity Supplied by Public Electricity Networks*, CENELEC, July 2010

[20] CEER: *5th Benchmarking Report on the Quality of Electricity Supply*, Bruxeless, 2011

[21] The Institute of Electrical and Electronics Engineers: *IEEE Guide for Electric Power Distribution Reliability Indices*, 3 Park Avenue, New York, USA, Page 4, 2004

[22] Dinko Hrkec, Darko Vidović, Ante Pavić, Marin Bošković: *Pokazatelji pouzdanosti napajanja električnom energijom u distribucijskoj mreži*, HO Cired, 1. savjetovanje, Šibenik, 2008

[23] Lahorko Wagmann, Željko Rajić, Zlatko Zmijarević, Hrvoje Miličić: *Regulatorni zahtjevi na izvještavanje o pokazateljima pouzdanosti napajanja*, HO Cired, 3. savjetovanje, Sveti Martin na Muri, 2012

[24] Zlatko Lacković: *Inženjerski menadžment*, Sveučilište J.J. Strossmayera u Osijeku, Elektrotehnički fakultet, str. 297, 2008

[25] R. T. Rockafellar: *Fundamentals of Optimization*, University of Washington, Department of Mathematics, 2007

[26] M. Vujošević: *Metode optimizacije u inženjerskom menadžmentu*, FON, Beograd, 2012

[27] Zorica Stanimirović: *Nelinearno programiranje*, Univerzitet u Beogradu, Matematički fakultet, 2014

[28] D. Nagesh Kumar: *Classification of Optimization Problems–Introduction and Basic Concepts*, Indian Institute of Science, Bangalore

[29] Milica B. Naumović: *Tehnike optimalnog upravljanja*, Univerzitet u Nišu, Elektronski fakultet, 2007

[30] Damir Vučina: *Metode inženjerske numeričke optimizacije*, Fakultet elektrotehnike, strojarstva i brodogradnje, Split, 2005

[31] Jizhong Zhu: *Optimization of Power System Operation*, Institute of Electrical and Electronics Engineers, USA, 2009

[32] G. Venter: *Review of Optimization Techniques*, Stellenbosch University, Department of Mechanical and Mechatronic Engineering, 2010

[33] John W. Chinneck: *Practical Optimization: a Gentle Introduction*, Carleton University, Systems and Computer Engineering, Otawa, Canada, 2000

[34] Gradimir V. Milovanović, Predrag S. Stanimirović: *Simbolička implementacija nelinearne optimizacije*, Serbian Academy of Sciences and Arts, Mathematical Institute, 2000

[35] K. Y. Lee, M. A. El-Sharkawi: *Modern Heuristic Optimization Techniques with Applications to Power Systems*, IEEE Power Engineering Society, USA, 2009

[36] Josip Dvornik: *Numeričke, simboličke i heurističke metode*, Građevinski fakultet Sveučilišta u Zagrebu, Građevinar 55, Vol. 10, pp. 575–582, 2003

[37] Achintya Halder, Sankaran Mahadevan: *Probability, Reliability and Statistical Methods in Engineering Design*, John Wiley & Sons, Inc., New York

[38] L. A. Zadeh: *Fuzzy Sets*, University of California, Berkeley, Department of Electrical Engineering and Electronics, Information and Control 8, pp. 338–353, 1965

[39] Thomas L. Saaty: *Basic Theory of the Analytic Hierarchy Process: How to Make a Decision*, Rev. R. Acad. Cienc. Exact. Fis. Nat (Esp), Vol. 93, No 4, pp. 395–423, 1999

[40] Thomas L. Saaty: *Decision making with the analytic hierarchy process*, Int. J. Services Sciences, Vol. 1, No 1, pp. 83–98, 2008

[41] Geoff Coyle: *The Analytic Hierarchy Process (AHP)*, Practical Strategy, Open Access Material, Pearson Education Limited, 2004

[42] Nadja Kasperczyk, Karlheinz Knickel: *The Analytic Hierarchy Process (AHP)*, VU University

[43] Khwanruthai Bunruamkaew: *How to Do AHP Analysis in Excel*, Division of Spatial Information Science, Graduate School of Life and Environmental Sciences, Univerity of Tsukuba, March 2012

[44] Paraskevopoulos Konstantinos: *The Analytic Hierarchy Process (AHP)*, International Hellenic University

[45] Thomas L. Saaty: *How to Make a Decision: The Analytic Hierarchy Process*, Journal of Operational Research, Vol. 24, Issue 6, pp. 9–26, December 1994

[46] Melvin Alexander: *Decision–Making Using the Analytic Hierarchy Process (AHP) and SAS/IML*, Paper SD-04, SESUG, 2012

[47] Jose Antonio Alonso, Teresa Lamata: *Consistency in the Analytixc Hierarchy Process: A New Approach*, International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems, Vol. 14, No 4, pp. 445–459, May 2006

[48] Ninoslav Holjevac, Igor Kuzle, Matija Zidar, Mladen Modrovčić: *Razvoj modela analitičkog hijerarhijskog procesa i njegovo korištenje pri donošenju odluke o prelasku na 20 kV pogonski napon*, HO CIRED, 4(10). savjetovanje, Trogir, Svibanj 2014

[49] Richard Hodgett: *Model an AHP Decision Problem in Excel*, Guides for Analytics, Data and Decision Sciences, December 2014

[50] Tzung-Pei Hong, Chai-Ying Lee: *Induction of Fuzzy Rules and Membership Functions from Training Examples*, Elsevier, Fuzzy Sets and Systems 84, pp. 33–47, August 1995

[51] Lejla Banjanović – Mehmedović: *Inteligentno upravljanje–Fuzzy Sistemi*, Fakultet elektrotehnike Tuzla

[52] Jin Zhao, Bimal K. Bose: *Evaluation of Membership Functions for Fuzzy Logic Controlled Induction Motor Drive*, pp. 229–234, IEEE, 2002

[53] Marko Čupić, Bojana Delbelo Bašić, Marin Golub: *Neizrazito, evolucijsko i neuroračunarstvo*, Fakultet elektrotehnike i računarstva, Zagreb, Kolovoz 2013

[54] Andri Riid: *Transparent Fuzzy Systems: Modeling and Control*, Tallinn Technical University, Faculty of Information Technology, Thesis on Informatics and System Engineering, 2002

[55] Josip Kasać: *Neizrazita logika*, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje

[56] John G. Vlachogiannis: *Mamdani Fuzzy Load Flow Method*, Engineering Intelligent Systems 1, pp. 45–52, 2004

[57] Ying Bai, Dali Wang: *Fundamentals of Fuzzy Logic Control–Fuzzy Sets, Fuzzy Rules and Defuzzifications*, Springer, Advanced Fuzzy Logic Technologies in Industrial Applications, pp. 17–36, 2006

[58] Li-Xin Wang: *A Course in Fuzzy Systems and Control*, Prentice-Hall International, 1997

[59] Hao Ying, Yongsheng Ding, Shaokuan Li, Shihuang Shao: *Comparison of Necessary Conditions for Typical Takagi-Sugeno and Mamdani Fuzzy Systems as Universal Approximators*, IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans, Vol. 29, Issue 5, Page 508–514, September 1999

[60] Robert Babuška: *Fuzzy Clustering Algorithm*, Fuzzy Modeling for Control, Vol. 12, pp. 49–74, 1998

[61] Michael Kearns, Yishay Mansour, Andrew Y. Ng: *An Information–Theoretic Analysis of Hard and Soft Assignment Methods for Clustering*, Thirteenth Conference on Uncertainty in Artificial Intelligence, February 2013

[62] William H.E. Day, Herbert Edelsbrunner: *Efficient Algorithms for Agglomerative Hierarchical Clustering Methods*, Journal of Classification, Vol. 1, pp. 7–24, 1984

[63] J. Gary Augustson, Jack Minker: *An Analysis of Some Graph Theoretical Cluster Techniques*, Journal of the Association for Computing Machinery, Vol. 17, No 4, pp. 571–588, October 1970

[64] James G. Booth, George Casella, James P. Hobert: *Clustering Using Objective Functions and Stochastic Search*, J. R. Statist. Soc. B 70, Part 1, pp. 119–139, 2008

[65] E. Mooi, M. Sarsedt: *Cluster Analysis*, Springer, A Concise Guide to Market Research, Chapter 9, pp. 237–284, 2011

[66] Peter Grabusts: *The Choice of Metrics for Clustering Algorithms*, Environment Tecnology Resources, 8th Inteernational Scientific and Practical Conference, Vol. 11, pp. 70–76, 2011

[67] Ida Žokalj, Zvonimir Szorsen: *Cluster Analysis–Fuzzy Clustering*, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, 2002

[68] James C. Spall: *Stochastic Optimization*, Handbook of Computational Statistics, Springer, Heildelberg, 2004

[69] Lauren A. Hannah: *Stochastic Optimization*, Columbia University, April 2004

[70] Leonardo Jelenković: *Višedretvena implementacija simuliranog kaljenja*, Fakultet elektrotehnike i računarstva, Konstrukcijski program, Zagreb, Rujan 1996

[71] Zorica Stanimirović: *Nelinearno programiranje*, Matematički fakultet, Beograd, 2014

[72] Sinha S. M: *Mathematical Programming: Theory and Methods*, Elsevier, 2006

[73] S. Kirkpatrick, C. C. Gelatt, M. P. Vecchi: *Optimization by Simulated Annealing*, Science, New Series, Vol. 220, No 4598, pp. 671–680, May 1983

[74] Petru Eles: *Heuristic Algorithms for Combinatorial Optimization Problems*, Linkopings Universitet, Department of Computer and Information Science (IDA), 2010

[75] P. J. M. van Laarhoven, E. H. L. Aarts: *Simulated Annealing: Theory and Applications*, Springer, Mathematics and Its Applications, Chapter 2–Simulated Annealing, 1987

[76] Young-Jae Jeon, Jae-Chul Kim, Jin-O. Kim, Joong-Rin Shin, Kwang Y. Lee: *An Efficient Simulated Annealing Algorithm for Network Reconfiguration in Large-Scale Distribution Systems*, IEEE Transactions on Power Delivery, Vol. 17, No 4, 2002

[77] Ray Daniel Zimmerman: *Network Reconfiguration for Loss Reduction in Three–Phase Power Distribution Systems*, Cornell University, May 1992

[78] Bruce Hajek: *Cooling Schedules for Optimal Annealing*, Mathematics of Operations Research, Vol. 13, No 2, May 1988

[79] Jimmy Kwok-Ching Lam: *An Efficient Simulated Annealing Schedule*, Yale University, Department of Computer Science, December 1988

[80] Stephane Moins: *Implementation of a Simulated Annealing Algorithm for Matlab*, Linkoping Institute of Technology, August 2002

[81] Darrall Henderson, Sheldon H. Jacobson, Alan W. Johnson: *The Theory and Practice of Simulated Annealing*, Springer, Chapter 10–Simulated Annealing, Vol. 57, pp. 287–319, 2003

[82] Emile Aarts, Jan Korst, Wil Michiels: *Search Methodologies*, Springer, Chapter 7–Simulated Annealing, pp. 187–210, 2005

[83] M. A. Matos, Paulo Melo: *Multiobjective Reconfiguration for Loss Reduction and Service Restoration Using Simulated Annealing*, IEEE Power Tech '99 Conference, Budapest, Hungary, September 1999

[84] B. Wah, T. Wang: *Constrained Simulated Annealing with Applications in Nonlinear Continuous Constrained Global Optimization*, Tools with Artificial Intelligence, 11th IEEE International Conference, page 381–388, Chicago, USA, November 1999

[85] Syamasree Biswas, Kamal Krishna Manadal, Niladri Chakraborty: *Simulated Annealing Based Real Power Loss Minimization Aspect for a Large Power Network*, Swarm Evalutionary and Memetic Computing, 4th International Conference SEMCCO, pp. 345–353, Chennai, India, December 2013

[86] E. Diaz-Dorado, J. C. Pidre, E. M. Garcia: *Planning of Large Rural Low-Voltage Networks Using Evolution Strategies*, Power Systems, IEEE Transactions, Vol. 18, Issue 4, pp. 1594–1600, November 2003

[87] T. Sugita, D. Lioka, Y. Yokomizu, T. Matsumura: *Low-Voltage Distribution Network Planning Taking Account of Power Loss Cost in Genetic Algorithms*, Future Power Systems, 2005 International Conference IEEE, Amsterdam, November 2005

[88] E. Diaz-Dorado, E. Miguez, J. Cidras: *Design of Large Rural Low-Voltage Networks Using Dynamic Programming Optimization*, Power Systems, IEEE Transactions, Vol. 16, Issue 4, pp. 898–903, November 2001

[89] M. Kolenc, I. Papić, B. Blažić: *Distribution Network Development Based on Stochastic Modeling Approach*, Power Engineering Conference (UPEC), 49th International Universities, pp. 1–6, Cluj-Napoca, September 2014

[90] Danijel Habijan, Marina Čavlović, Dalibor Jakšić: *Problematika nesimetrije u niskonaponskoj mreži*, HO CIRED, 3. savjetovanje, 2012

[91] Ivica Pavić: *Trofazni proračun tokova snaga,* Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu, 2011

[92] International Standard, *IEC 61000-4-30*, Edition 2.0, 2008

POPIS KRATICA

Faktor istodobnosti (*eng. Rusck factor*)	f_i
Upotrebno vrijeme (*eng. consumption time*)	T_{up}
Vrijeme trajanja gubitaka (*eng. loss duration time*)	T_{gub}
Godišnja ostvarena energija (*eng. annual realized energy*)	$W_{uk_{god}}$
Dnevna ostvarena energija (*eng. daily realized energy*)	$W_{uk_{dnev}}$
Promjenjivi gubici (*eng. variable losses*)	P_{var}
Gubici praznog hoda (*eng. unloaded losses*)	P_0
Pad napona (*eng. voltage drop*)	Δu
Faktor ovisan o broju faza (*eng. factor dependent on the number of phases*)	k_f
Faktor težišta opterećenja (*eng. load centre factor*)	k_t
Faktor dopuštenog preopterećenja (*eng. permissible overload factor*)	r_{pre}
Faktor rezerve (*eng. factor of reserve*)	r_{rez}
Cijena snage (*eng. power cost*)	k_s
Cijena energije (*eng. energy cost*)	k_e
Indeks prosječne učestalosti prekida sustava (*eng. System Average Interruption Frequency Indeks*)	SAIFI
Indeks prosječne dužine trajanja prekida sustava (*eng. System Average Interruption Duration Indeks*)	SAIDI
Indeks prosječnog trajanja prekida kupaca (*eng. Customer Average Interruption Duration Indeks*)	CAIDI
Funkcija cilja (*eng. objective function*)	f(x)

Dopustiva skupina rješenja (*eng. permissible solutions group*)	D
Optimalno rješenje (*eng. optimal solution*)	x^* , x_{opt}
Vjerojatnost (*eng. probability*)	P
Analitički hijerarhijski postupak (*eng. Analitic Hierarchy Process*)	AHP
Relativne važnost kriterija (*eng. relative importance of criteria*)	w_i , w_j
Matrica težinskih omjera (*eng. weighted ratios matrix*)	W
Indeks konzistencije (*eng. consistency index*)	CI
Omjer konzistencije (*eng. consistency ratio*)	CR
Slučajni indeks (*eng. random index*)	RI
Prioritet (*eng. priority*)	p_i
Geometrijska sredina (*eng. geometric mean*)	m
Funkcija pripadnosti (*eng. membership function*)	$\mu_A(x)$
Trokutna norma (*eng. triangular norm*)	T_n
Trokutna konorma (*eng. triangular co-norm*)	S_n
Stupanj prekrivanja (stupanj istinitosti premise) (*eng. overlaping degree – premises truthfulness degree*)	β_i
Euklidova razdaljina (*eng. Euclidean distance – straight line distance*)	$d_{Euclidean}$
Menhetn razdaljina (*eng. Manhattan metric – city block distance*)	$d_{City\ block}$
Čebiševljeva razdaljina (*eng. Chebychev distance*)	$d_{Chebychev}$
Tvrdo grupiranja (*eng. Hard c – Means*)	HCM

Neizrazito grupiranja (*eng Fuzzy c – Means*)	FCM
Simulirano kaljenje (*eng. simulated annealing*)	SA
Prostor pretraživanja (*eng. search space*)	S
Temperatura (*eng. temperature*)	T
Faktor normalizacije (*eng. normalization factor*)	Z(T)
Bolcmanova konstanta (*eng. Boltzmann constant*)	k_B
Generaciona matrica vjerojatnosti (*eng. generation probability matrix*)	G(T)
Matrica prihvatljive vjerojatnosti (*eng. acceptable probability matrix*)	A(T)
Tranziciona matrica vjerojatnosti (*eng. transition probability matrix*)	P(T)
Stacionarna razdioba (*eng. stationary distribution*)	q(T)
Gubici radne snage (*eng. active power losses*)	ΔP
Gubici jalove snage (*eng. reactive power losses*)	ΔQ
Fazni kut (*eng. phase angle*)	θ
Aktivna otpornost (*eng. active resistance*)	R
Reaktivna otpornost (*eng. reactive resistance*)	X
Aktivna provodnost (*eng. conductance*)	G
Reaktivna provodnost (*eng. susceptance*)	B
Standardna devijacija (*eng. standard deviation*)	σ

POPIS SLIKA

Slika 2.1. Elektroenergetski sustav
Slika 2.2. Priključak elektrane na prijenosnu (visokonaponsku) mrežu
Slika 2.3. Priključak male elektrane na srednjenaponsku distribucijsku mrežu
Slika 2.4. Priključak male elektrane na niskonaponsku distribucijsku mrežu
Slika 2.5. Distribucijska mreža sa tri srednjenaponske razine (6 kV, 35 kV i 10(20) kV)
Slika 2.6. Distribucijska mreža sa jednom srednjenaponskom razinom (10 kV ili 20 kV)
Slika 2.7. Niskonaponska distribucijska mreža
Slika 2.8. Primjer potrošnje električne energije različitih kućanskih trošila
Slika 2.9. Trokut snaga
Slika 2.10. Dnevni dijagram opterećenja
Slika 3.1. Lokalni i globalni optimum
Slika 3.2. Opći prikaz optimizacijskog procesa
Slika 3.3. Shematski prikaz dekompozicije problema
Slika 3.4. Različiti oblici funkcije pripadnosti
Slika 3.5. Neizraziti sustav
Slika 3.6. Grafički prikaz Mamdani algoritma neizrazitog zaključivanja
Slika 3.7. Primjer Sugeno modela dvije crte
Slika 3.8. Skupine različitog oblika i dimenzija
Slika 3.9. Koraci analize neizrazitog grupiranja
Slika 3.10. Aglomerativno grupiranje i grupiranje dijeljenjem
Slika 3.11. Korelacija između mjera udaljenosti
Slika 3.12. Aglomerativne procedure vezivanja elemenata skupina
Slika 3.13. Dendogram
Slika 3.14. Prihvatljiva vjerojatnost u odnosu na temperaturu i promjene u funkciji cilja
Slika 3.15. Primjer radijalne distribucijske mreže
Slika 3.16. Primjer četiri nepovezana distribucijska sustava
Slika 3.17. Povezani distribucijski sustav
Slika 4.1. Dijagram toka predloženog modela planiranja niskonaponskih distribucijskih mreža
Slika 4.2. Zemljopisne koordinate mjernog mjesta
Slika 4.3. Zemljopisne koordinate mjernih mjesta u .dat datoteci

Slika 4.4. Dijaloški okvir za pronalaženje centra konzuma
Slika 4.5. Lokacija transformatorske stanice – prostorni centar konzuma
Slika 4.6. Niskonaponski izvod sa podskupinama potrošača
Slika 4.7. Prostorni raspored skupina i podskupina potrošača i njihovih centara i podcentara
Slika 4.8. Primjer niskonaponske distribucijske mreže
Slika 4.9. Podaci o opterećenju sabirnica za proračun tokova snaga
Slika 4.10. Podaci o transformatorskoj stanici i vodovima za proračun tokova snaga
Slika 4.11. Rezultati proračuna tokova snaga u Matlab-u (Matpower)
Slika 4.12. Optimalno uklopno stanje niskonaponske distribucijske mreže
Slika 4.13. Usporedni prikaz najboljeg prostornog (a) i optimalnog (b) rješenja niskonaponske distribucijske mreže
Slika 5.1. Prostorni raspored niskonaponskih potrošača
Slika 5.2. Postojeća niskonaponska distribucijska mreža
Slika 5.3. Prikaz zemljopisnih koordinata dijela potrošača razmatranog područja
Slika 5.4. Dnevni dijagram opterećenja transformatorske stanice
Slika 5.5. Dnevni dijagram opterećenja niskonaponskih izvoda
Slika 5.6. Matlab Fuzzy Toolbox za određivanje centra skupine
Slika 5.7. Lokacija transformatorske stanice
Slika 5.8. Razdioba konzuma na 5 skupina
Slika 5.9. Razdioba konzuma na 6 skupina
Slika 5.10. Razdioba konzuma na 7 skupina
Slika 5.11. Razdioba konzuma na 8 skupina
Slika 5.12. Razdioba konzuma na 5 skupina i 4 podskupine
Slika 5.13. Razdioba konzuma na 6 skupina i 4 podskupine
Slika 5.14. Razdioba konzuma na 7 skupina i 4 podskupine
Slika 5.15. Razdioba konzuma na 8 skupina i 4 podskupine
Slika 5.16. Idejno rješenje distribucijske mreže sa 5 niskonaponskih izvoda
Slika 5.17. Idejno rješenje distribucijske mreže sa 6 niskonaponskih izvoda
Slika 5.18. Idejno rješenje distribucijske mreže sa 7 niskonaponskih izvoda
Slika 5.19. Idejno rješenje distribucijske mreže sa 8 niskonaponskih izvoda
Slika 5.20. Naponi na sabirnicama potrošača svih alternativa
Slika 5.21. Uspostavljanje međuveza u niskonaponskoj distribucijskoj mreži

Slika 5.22. Definiranje mrežnih prekidača

Slika 5.23. Kretanje gubitaka radne snage pri procesu simuliranog kaljenja

Slika 5.24. Usporedni prikaz najboljeg prostornog i optimalnog rješenja

Slika 5.25. Razdioba proračunatih vrijednosti nesimetrije

Slika 5.26. Naponska nesimetrija u prvom sedmodnevnom vremenskom intervalu

Slika 5.27. Naponska nesimetrija u drugom sedmodnevnom vremenskom intervalu

Slika 5.28. Ukupno opterećenje potrošača za različito dnevno opterećenje transformatorske stanice

Slika 5.29. Padovi napona kod krajnjih potrošača u postojećoj i optimalnoj mreži pri različitom opterećenju potrošača i vremenskim periodima

Slika 5.30. Padovi napona kod krajnjih potrošača u postojećoj i optimalnoj mreži za slučaj „štufanja“ transformatora, pri različitom opterećenju potrošača i vremenskim periodima

Slika 5.31. Padovi napona kod krajnjih potrošača u postojećoj i optimalnoj mreži za slučaj promjene presjeka vodiča, pri različitom opterećenju potrošača i vremenskim periodima

Slika 5.32. Padovi napona kod krajnjih potrošača u postojećoj i optimalnoj mreži za slučaj dodavanja izvora napajanja, pri različitom opterećenju potrošača i vremenskim periodima

Slika 5.33. Padovi napona kod krajnjih potrošača u svim razmatranim mrežama pri različitom opterećenju potrošača i vremenskim periodima

Slika 5.34. Gubici radne snage postojeće i optimalne distribucijske mreže pri različitom opterećenju potrošača i vremenskim periodima

Slika 5.35. Gubici radne snage postojeće i optimalne distribucijske mreže pri različitom opterećenju potrošača i vremenskim periodima za slučaj „štufanja“ transformatora

Slika 5.36. Gubici radne snage postojeće i optimalne distribucijske mreže pri različitom opterećenju potrošača i vremenskim periodima za slučaj promjene presjeka vodiča

Slika 5.37. Gubici radne snage postojeće i optimalne distribucijske mreže pri različitom opterećenju potrošača i vremenskim periodima za slučaj dodavanja izvora napajanja

Slika 5.38. Gubici radne snage u niskonaponskim vodovima svih razmatranih mreža pri različitom opterećenju potrošača i vremenskim periodima

POPIS TABLICA

Tablica 2.1. Faktor k_f u ovisnosti o broju faza
Tablica 2.2. Primjer proračuna gubitaka po komponentama mreže
Tablica 2.3. Primjer cjenika investicijskih troškova izgradnje mreže
Tablica 3.1. Primjer Saatyjeve skale relativne važnosti
Tablica 3.2. Vrijednosti slučajnog indeksa konzistencije RI
Tablica 3.3. Euclidean matrica udaljenosti
Tablica 3.4. Analogija između simuliranog i fizikalnog kaljenja
Tablica 4.1. Tablica usporedbe kriterija po parovima
Tablica 4.2. Vrijednosti prioriteta i težinskog vektora nakon provođenja AHP metode
Tablica 5.1. Karakteristike niskonaponskih vodova
Tablica 5.2. Karakteristike tipskih SN/NN distribucijskih transformatora
Tablica 5.3. Maksimalne radne snage niskonaponskih izvoda
Tablica 5.4. Ukupne dnevne radne energije niskonaponskih izvoda
Tablica 5.5. Ukupne godišnje radne energije niskonaponskih izvoda
Tablica 5.6. Minimalne vrijednosti upotrebnih vremena pojedinih izvoda
Tablica 5.7. Vrijednosti gubitaka radne snage niskonaponskih izvoda
Tablica 5.8. Vrijednosti potrebnih injektiranih snaga niskonaponskih izvoda
Tablica 5.9. Vrijednosti korekcijskih faktora c niskonaponskih izvoda
Tablica 5.10. Korigirane vrijednosti godišnjih radnih energije niskonaponskih izvoda
Tablica 5.11. Korigirane vrijednosti upotrebnih vremena pojedinih izvoda
Tablica 5.12. Konačne vrijednosti opterećenja niskonaponskih izvoda
Tablica 5.13. Podaci za Matpower o transformatorskoj stanici
Tablica 5.14. Podaci za Matpower o jednom stupnom mjestu
Tablica 5.15. Padovi napona kod krajnjih potrošača
Tablica 5.16. Gubici aktivne snage u niskonaponskim vodovima
Tablica 5.17. Prosječno opterećenje vodova alternative sa 5 niskonaponskih izvoda
Tablica 5.18. Prosječno opterećenje vodova alternative sa 6 niskonaponskih izvoda
Tablica 5.19. Prosječno opterećenje vodova alternative sa 7 niskonaponskih izvoda
Tablica 5.20. Prosječno opterećenje vodova alternative sa 8 niskonaponskih izvoda
Tablica 5.21. Cjenik nabavke i montaže transformatorske stanice
Tablica 5.22. Cjenik nabavke i montaže stupova

Tablica 5.23. Cjenik kabela
Tablica 5.24. Procijenjeni investicijski troškovi idejnog rješenja sa 5 niskonaponskih izvoda
Tablica 5.25. Procijenjeni investicijski troškovi idejnog rješenja sa 6 niskonaponskih izvoda
Tablica 5.26. Procijenjeni investicijski troškovi idejnog rješenja sa 7 niskonaponskih izvoda
Tablica 5.27. Procijenjeni investicijski troškovi idejnog rješenja sa 8 niskonaponskih izvoda
Tablica 5.28. Ocjena važnosti kriterija
Tablica 5.29. Matrica usporedbe kriterija
Tablica 5.30. Normalizirana matrica usporedbe kriterija
Tablica 5.31. Vektor težinskih vrijednosti
Tablica 5.32. Vrijednosti padova napona pojedinih alternativa
Tablica 5.33. Matrica usporedbe alternativa za kriterij 1
Tablica 5.34. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1
Tablica 5.35. Vrijednosti gubitaka radne snage pojedinih alternativa
Tablica 5.36. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2
Tablica 5.37. Vrijednosti prosječnog opterećenja vodova pojedinih alternativa
Tablica 5.38. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3
Tablica 5.39. Vrijednosti investicija pojedinih alternativa
Tablica 5.40. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4
Tablica 5.41. Usporedni rezultati padova napona i gubitaka radne snage
Tablica 5.42. Status dionica (uključen/isključen) nakon provedenog simuliranog kaljenja
Tablica 5.43. Vrijednosti kriterija pri minimalnom opterećenju potrošača
Tablica 5.44. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. opter.)
Tablica 5.45. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (min. opter.)
Tablica 5.46. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (min. opter.)
Tablica 5.47. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (min. opter.)
Tablica 5.48. Vrijednosti kriterija pri opterećenju potrošača u periodu proljeća
Tablica 5.49. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (proljeće)
Tablica 5.50. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (proljeće)
Tablica 5.51. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (proljeće)
Tablica 5.52. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (proljeće)
Tablica 5.53. Vrijednosti kriterija pri opterećenju potrošača u periodu ljeta
Tablica 5.54. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (ljeto)

Tablica 5.55. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (ljeto)
Tablica 5.56. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (ljeto)
Tablica 5.57. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (ljeto)
Tablica 5.58. Vrijednosti kriterija pri opterećenju potrošača u periodu jeseni
Tablica 5.59. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (jesen)
Tablica 5.60. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (jesen)
Tablica 5.61. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (jesen)
Tablica 5.62. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (jesen)
Tablica 5.63. Vrijednosti kriterija pri opterećenju potrošača u periodu zime
Tablica 5.64. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (zima)
Tablica 5.65. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (zima)
Tablica 5.66. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (zima)
Tablica 5.67. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (zima)
Tablica 5.68. Razdioba proračunatih vrijednosti nesimetrije
Tablica 5.69. Vrijednosti kriterija pri opterećenju potrošača u periodu maksimalne nesimetrije
Tablica 5.70. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (max. nesim.)
Tablica 5.71. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (max. nesim.)
Tablica 5.72. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (max. nesim.)
Tablica 5.73. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (max. nesim.)
Tablica 5.74. Vrijednosti kriterija pri opterećenju potrošača u periodu minimalne nesimetrije
Tablica 5.75. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. nesim.)
Tablica 5.76. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (min. nesim.)
Tablica 5.77. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (min. nesim.)
Tablica 5.78. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (min. nesim.)
Tablica 5.79. Vrijednosti kriterija pri opterećenju potrošača u periodu prosječne nesimetrije
Tablica 5.80. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (prosj. nesim.)
Tablica 5.81. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (prosj. nesim.)
Tablica 5.82. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (prosj. nesim.)
Tablica 5.83. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (prosj. nesim.)
Tablica 5.84. Vrijednosti kriterija pri opterećenju potrošača u periodu najvjerojatnije nesim.

Tablica 5.85. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (najvjer. nesim.)

Tablica 5.86. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (najvjer. nesim.)

Tablica 5.87. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (najvjer. nesim.)

Tablica 5.88. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (najvjer. nesim.)

Tablica 5.89. Vrijednosti kriterija pri prosječnom istodobnom opterećenju potrošača

Tablica 5.90. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (prosj. istodob.)

Tablica 5.91. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (prosj. istodob.)

Tablica 5.92. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (prosj. istodob.)

Tablica 5.93. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (prosj. istodob.)

Tablica 5.94. Vrijednosti kriterija pri maksimalnom istodobnom opterećenju potrošača

Tablica 5.95. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (max. istodob.)

Tablica 5.96. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 2 (max. istodob.)

Tablica 5.97. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 3 (max. istodob.)

Tablica 5.98. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 4 (max. istodob.)

Tablica 5.99. Vrijednosti kriterija pri minimalnom istodobnom opterećenju potrošača

Tablica 5.100. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. istodob.)

Tablica 5.101. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. istodob.)

Tablica 5.102. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. istodob.)

Tablica 5.103. Vrijednosti prioriteta matrice usporedbe alternativa za kriterij 1 (min. istodob.)

Tablica 5.104. Padovi napona i gubici radne snage za različite vrijednosti opterećenja potrošača

Tablica 5.105. Padovi napona kod krajnjih potrošača za različite vrijednosti opterećenja potrošača postojeće niskonaponske distribucijske mreže

Tablica 5.106. Padovi napona kod krajnjih potrošača za različite vrijednosti opterećenja potrošača optimalne niskonaponske distribucijske mreže

Tablica 5.107. Usporedba rezultata o padovima napona kod krajnjih potrošača postojeće i optimalne niskonaponske distribucijske mreže

Tablica 5.108. Podaci o transformatorskoj stanici za slučaj maksimalnog štufanja

Tablica 5.109. Padovi napona za različite vrijednosti opterećenja potrošača postojeće i optimalne niskonaponske distribucijske mreže za slučaj „štufanja“ transformatora

Tablica 5.110. Padovi napona za različite vrijednosti opterećenja potrošača postojeće i optimalne niskonaponske distribucijske mreže za slučaj promjene presjeka vodiča magistralnog voda

Tablica 5.111. Padovi napona za različite vrijednosti opterećenja potrošača postojeće i optimalne niskonaponske distribucijske mreže za slučaj implementiranja dodatnog izvora napajanja

Tablica 5.112. Gubici radne snage za različite vrijednosti opterećenja potrošača postojeće i optimalne niskonaponske distribucijske mreže

Tablica 5.113. Gubici radne snage za različite vrijednosti opterećenja potrošača postojeće i optimalne niskonaponske distribucijske mreže u slučaju „štufanja“ transformatora

Tablica 5.114. Gubici radne snage za različite vrijednosti opterećenja potrošača postojeće i optimalne distribucijske mreže za slučaj promjene presjeka vodiča magistralnog voda

Tablica 5.115. Gubici radne snage za različite vrijednosti opterećenja potrošača postojeće i optimalne distribucijske mreže za slučaj implementiranja novog izvora

Tablica 5.116. Prosječni gubici radne snage postojeće i optimalne mreže

Tablica 5.117. Novčane uštede temeljem gubitaka radne snage

Tablica 5.118. Procijenjeni investicijski troškovi postojeće niskonaponske mreže

Tablica 5.119. Procijenjeni investicijski troškovi optimalne niskonaponske mreže

Tablica 5.120. Procijenjeno vrijeme isplate investicije

Tablica 5.121. Ukupni gubici energije realnog distribucijskog sustava

Tablica 5.122. Gubici energije u 10 kV i 0,4 kV distribucijskoj mreži

Tablica 5.123. Procijenjeni gubici energije u 0,4 kV distribucijskoj mreži

Tablica 5.124. Postotni udio gubitaka energije obzirom na naponsku razinu

PRILOZI

Prilog 1. *Zemljopisne koordinate mjernih mjesta*

Rb	Mjerno mjesto	Koordinata		Rb	Mjerno mjesto	Koordinata		Rb	Mjerno mjesto	Koordinata		Rb	Mjerno mjesto	Koordinata	
		X	Y			X	Y			X	Y			X	Y
1	5270812	6551590,49	4931588,55	32	5270480	6551589,17	4931480,56	63	8368910	6551756,17	4931384,18	94	5269601	6551610,94	4931310,47
2	3419703	6551627,72	4931579,66	33	8465967	6551710,00	4931480,10	64	5266203	6551686,38	4931383,90	95	5269792	6551629,79	4931309,95
3	5265126	6551629,16	4931575,71	34	5270308	6551630,07	4931477,54	65	5270057	6551654,27	4931380,94	96	4701720	6551692,09	4931305,15
4	3859533	6551651,23	4931564,77	35	4521943	6551744,68	4931474,27	66	5266815	6551759,15	4931378,19	97	3161250	6551801,92	4931303,43
5	5265215	6551633,31	4931559,64	36	8368821	6551630,07	4931472,51	67	3795853	6551747,32	4931377,64	98	5269717	6551663,56	4931303,41
6	5265282	6551668,80	4931555,78	37	5265657	6551716,85	4931463,79	68	2727145	6551675,75	4931374,44	99	5269660	6551634,24	4931299,74
7	5270731	6551556,32	4931553,26	38	5266084	6551659,73	4931462,14	69	5266920	6551783,29	4931372,48	100	5269547	6551610,94	4931299,74
8	5265258	6551645,83	4931541,64	39	5270383	6551624,03	4931460,45	70	5266483	6551729,41	4931371,28	101	4396529	6551776,32	4931296,16
9	5270693	6551615,30	4931539,96	40	2797690	6551568,38	4931459,45	71	5266785	6551762,37	4931366,03	102	1802917	6551711,17	4931291,79
10	8767181	6551642,31	4931539,93	41	4077067	6551659,73	4931457,19	72	1837044	6551714,48	4931365,29	103	4275977	6551740,45	4931288,92
11	5265347	6551692,22	4931538,84	42	8534365	6551752,70	4931454,76	73	1836978	6551710,06	4931364,18	104	5269490	6551619,06	4931285,09
12	4064976	6551542,91	4931536,85	43	5265711	6551729,67	4931450,10	74	5266572	6551692,45	4931361,70	105	4431197	6551764,11	4931280,53
13	2818612	6551667,59	4931528,05	44	3227987	6551579,11	4931443,36	75	5269997	6551651,65	4931359,34	106	3406482	6551780,89	4931274,05
14	5270650	6551618,67	4931526,79	45	5270251	6551605,26	4931442,69	76	5266963	6551784,58	4931358,39	107	4401921	6551619,06	4931271,22
15	3180840	6551696,67	4931525,23	46	4078071	6551668,03	4931438,70	77	3094669	6551734,05	4931356,99	108	3223647	6551713,66	4931270,44
16	5270537	6551561,34	4931519,76	47	4685431	6551698,63	4931436,81	78	5266726	6551765,14	4931353,32	109	5269385	6551682,98	4931269,24
17	5265932	6551653,02	4931515,05	48	8468419	6551631,14	4931429,52	79	4312163	6551714,60	4931351,10	110	3223566	6551711,75	4931265,70
18	5265878	6551671,97	4931514,94	49	5270189	6551583,81	4931428,62	80	3508978	6551691,16	4931346,01	111	3169707	6551733,51	4931260,81
19	3048578	6551579,11	4931512,39	50	3294110	6551603,23	4931424,12	81	5266653	6551739,30	4931343,17	112	5269423	6551649,07	4931258,81
20	5265495	6551697,14	4931511,63	51	5270146	6551611,69	4931420,81	82	5266599	6551719,95	4931338,29	113	4353064	6551801,88	4931258,80
21	3752941	6551698,07	4931508,77	52	3086585	6551760,04	4931412,77	83	4076451	6551612,60	4931336,71	114	3118908	6551750,89	4931257,33
22	5265568	6551699,07	4931505,48	53	5266130	6551666,86	4931407,05	84	2707667	6551695,03	4931328,41	115	8504504	6551664,54	4931254,73
23	4064496	6551568,05	4931505,35	54	5266432	6551736,90	4931405,95	85	5269954	6551628,12	4931328,02	116	3086461	6551761,62	4931251,06
24	5270596	6551625,38	4931505,02	55	5266386	6551733,49	4931404,94	86	5269903	6551655,27	4931326,92	117	5268443	6551707,50	4931250,59
25	5265819	6551677,21	4931500,24	56	5270103	6551640,86	4931403,39	87	5267005	6551772,95	4931326,73	118	5267978	6551811,69	4931250,36
26	5266025	6551657,54	4931498,74	57	5266319	6551714,78	4931396,28	88	5269849	6551644,80	4931323,52	119	5268419	6551774,97	4931247,35
27	5265614	6551702,57	4931495,39	58	8175179	6551640,86	4931394,34	89	3296962	6551633,72	4931320,68	120	4312260	6551840,13	4931241,47
28	3179192	6551558,33	4931492,95	59	8732515	6551611,69	4931393,34	90	5267048	6551746,29	4931319,24	121	4472446	6551855,90	4931232,69
29	5270421	6551630,07	4931487,93	60	8318328	6551683,61	4931392,93	91	5269741	6551658,85	4931315,45	122	3102424	6551766,84	4931230,99
30	5265770	6551682,31	4931486,70	61	5266254	6551697,62	4931390,56	92	1815342	6551730,99	4931314,82	123	4754840	6551680,44	4931230,59
31	5265991	6551661,77	4931485,79	62	5587220	6551778,96	4931387,68	93	5598664	6551719,84	4931310,67	124	5267935	6551826,43	4931227,31

125	3663892	6551783,92	4931227,04	162	4759494	6551800,83	4931135,66	199	3084604	6551654,89	4931068,78	236	8262276	6551699,55	4930953,09
126	4578848	6551751,76	4931223,91	163	5269091	6551614,33	4931134,74	200	3216829	6551987,59	4931057,56	237	3072398	6551654,40	4930947,42
127	8419574	6551622,42	4931221,99	164	3055310	6551632,10	4931131,47	201	2833786	6551851,86	4931055,51	238	8236097	6551625,39	4930942,15
128	5267838	6551862,24	4931221,04	165	5268524	6551719,78	4931131,42	202	5267323	6551897,34	4931055,00	239	5267234	6552090,22	4930939,63
129	3362493	6551841,07	4931211,26	166	5268133	6551777,56	4931128,59	203	8452466	6551668,59	4931053,79	240	8410755	6551684,25	4930939,28
130	5268346	6551785,31	4931210,36	167	5269296	6551664,95	4931127,30	204	3151743	6551772,40	4931049,33	241	1836943	6552030,08	4930936,63
131	8253943	6551858,32	4931210,05	168	1813498	6551742,70	4931126,47	205	8329494	6551675,32	4931045,97	242	2915227	6551666,74	4930932,13
132	5267862	6551808,06	4931209,14	169	8256055	6551790,34	4931121,98	206	8419582	6552011,94	4931041,99	243	8460728	6551694,12	4930926,21
133	5268494	6551721,90	4931208,68	170	5269156	6551594,65	4931121,63	207	4171292	6551832,55	4931040,43	244	8414246	6551678,82	4930916,10
134	2063654	6551639,62	4931204,91	171	5268559	6551710,33	4931118,91	208	4062779	6551865,30	4931038,63	245	3795993	6552128,49	4930906,54
135	8695911	6551828,76	4931201,19	172	5269199	6551618,67	4931117,69	209	3949885	6551812,24	4931031,39	246	8760179	6551746,17	4930900,81
136	8452547	6551824,10	4931198,68	173	4449959	6551843,92	4931117,00	210	3418340	6551599,02	4931026,56	247	8733376	6551692,64	4930900,81
137	4215710	6551762,78	4931198,53	174	5268184	6551807,68	4931116,96	211	1839551	6551846,63	4931025,76	248	8760187	6551705,71	4930887,25
138	3405702	6551609,24	4931197,24	175	5268648	6551741,76	4931112,06	212	3193780	6551854,30	4931025,76	249	1794612	6552078,72	4930881,92
139	3272125	6551707,25	4931197,11	176	8465436	6551759,31	4931109,90	213	5269032	6551594,07	4931024,78	250	8830428	6552036,53	4930864,03
140	4697006	6551675,38	4931196,51	177	5644836	6551867,27	4931108,98	214	3920364	6551883,77	4931023,36	251	2690160	6552046,28	4930855,52
141	5267765	6551820,74	4931189,92	178	5624339	6551647,18	4931105,45	215	3405796	6552093,72	4931020,44	252	4484029	6551698,42	4930836,55
142	3139271	6551741,28	4931184,83	179	5268109	6551797,64	4931102,83	216	3948986	6551793,94	4931018,93	253	5594065	6551683,97	4930824,33
143	5268273	6551773,44	4931184,83	180	5268826	6551668,98	4931100,71	217	3025217	6551830,34	4931014,91	254	8373515	6552084,13	4930816,45
144	8221146	6551634,89	4931183,44	181	5268702	6551698,45	4931099,55	218	5267277	6551964,90	4931014,81	255	5268869	6551697,51	4930798,67
145	8247307	6551607,77	4931182,56	182	5268672	6551735,85	4931099,31	219	4062639	6551904,64	4931011,66	256	8578907	6552015,60	4930796,82
146	8390711	6551656,14	4931181,85	183	5268060	6551812,24	4931098,27	220	3922723	6551869,53	4931007,15	257	4093623	6551677,88	4930796,62
147	5267722	6551827,18	4931180,55	184	8460558	6551959,61	4931095,43	221	4078144	6551802,79	4931003,26	258	3212661	6551718,94	4930784,47
148	5267684	6551832,03	4931170,12	185	2915154	6551980,54	4931093,23	222	4441893	6552012,58	4930996,61	259	1824961	6552029,25	4930778,18
149	5268230	6551787,59	4931167,28	186	5267366	6551889,60	4931092,75	223	3256839	6552039,78	4930993,27	260	8218323	6552031,29	4930728,98
150	3213501	6551834,08	4931164,99	187	5268729	6551687,05	4931091,53	224	5267137	6551912,11	4930992,22	261	8296553	6552059,60	4930724,30
151	5269342	6551669,62	4931162,31	188	4621859	6551760,52	4931089,60	225	5575672	6551936,47	4930989,60	262	3046621	6551994,14	4930718,61
152	2909359	6551901,62	4931156,90	189	3032612	6552004,78	4931088,82	226	1811487	6551887,72	4930989,26	263	4522028	6551996,26	4930707,02
153	5267609	6551838,38	4931154,15	190	8568995	6551684,51	4931087,28	227	5268583	6552063,40	4930989,26	264	3139751	6552032,96	4930698,52
154	8504431	6551568,19	4931153,79	191	3102254	6551971,51	4931081,34	228	3462765	6551830,48	4930985,60	265	3440028	6552004,95	4930698,52
155	3301222	6551738,92	4931153,38	192	5267404	6551863,21	4931081,25	229	4091132	6552049,36	4930979,01	266	3097161	6552046,79	4930679,03
156	2739925	6551793,98	4931152,00	193	3440893	6551712,93	4931080,43	230	8572941	6551656,38	4930974,05	267	1790625	6552005,53	4930677,72
157	4267060	6551825,70	4931146,32	194	4621794	6551896,30	4931079,31	231	4759435	6551963,95	4930969,75	268	8801770	6552060,97	4930665,92
158	8469679	6551585,08	4931145,13	195	3478076	6551824,69	4931077,27	232	2941090	6551678,82	4930967,14	269	8296588	6552064,50	4930655,26
159	4760999	6551724,27	4931143,23	196	3102165	6551999,71	4931076,94	233	5267161	6551999,41	4930964,26	270	8296561	6552017,25	4930651,03
160	5598745	6551844,61	4931140,66	197	1840703	6551578,92	4931071,25	234	1823132	6552039,33	4930964,09				
161	1816071	6551700,88	4931137,33	198	5268028	6551734,59	4931070,03	235	6189911	6551632,72	4930958,35				

Prilog 2. *Pojedinačna utrošena godišnja energija niskonaponskih potrošača*

Rb	Mjerno mjesto	Ostvarena godišnja energija (kWh)	Rb	Mjerno mjesto	Ostvarena godišnja energija (kWh)	Rb	Mjerno mjesto	Ostvarena godišnja energija (kWh)	Rb	Mjerno mjesto	Ostvarena godišnja energija (kWh)	Rb	Mjerno mjesto	Ostvarena godišnja energija (kWh)	Rb	Mjerno mjesto	Ostvarena godišnja energija (kWh)	Rb	Mjerno mjesto	Ostvarena godišnja energija (kWh)
1	5270812	19.633,93	34	5270308	2.820,51	67	3795853	7.308,67	100	5269547	5.345,55	133	5268494	4.009,32	166	5268133	4.497,06	199	3084604	3.968,72
2	3419703	1.673,75	35	4521943	6.687,12	68	2727145	4.536,40	101	4396529	3.484,03	134	2063654	423,80	167	5269296	2.944,88	200	3216829	7.931,28
3	5265126	5.926,43	36	8368821	3.905,84	69	5266920	3.757,91	102	1802917	5.233,68	135	8695911	3.542,76	168	1813498	2,83	201	2833786	3.916,76
4	3859533	8.452,35	37	5265657	1.788,69	70	5266483	8.323,03	103	4275977	5.852,35	136	8452547	4.374,23	169	8256055	5.183,98	202	5267323	1.064,08
5	5265215	3.240,10	38	5266084	370,38	71	5266785	7.513,03	104	5269490	8.202,31	137	4215710	6.590,84	170	5269156	1.107,97	203	8452466	3.499,31
6	5265282	8.467,33	39	5270383	4.111,60	72	1837044	382,98	105	4431197	3.934,55	138	3405702	6.788,49	171	5268559	5.210,98	204	3151743	5.090,76
7	5270731	4.243,48	40	2797690	2.967,75	73	1836978	6.667,92	106	3406482	0,36	139	3272125	3.229,91	172	5269199	1.357,16	205	8329494	4.772,46
8	5265258	4.837,40	41	4077067	6.315,13	74	5266572	2.361,98	107	4401921	10.477,53	140	4697006	1.468,14	173	4449959	7.138,80	206	8419582	8.879,24
9	5270693	8.700,48	42	8534365	4.677,18	75	5269997	885,28	108	3223647	62,68	141	5267765	978,80	174	5268184	1.806,29	207	4171292	717,29
10	8767181	201,15	43	5265711	3.012,99	76	5266963	1.332,64	109	5269385	4.651,09	142	3139271	3.478,98	175	5268648	6.674,61	208	4062779	4.640,56
11	5265347	4.359,45	44	3227987	7.416,83	77	3094669	3.984,76	110	3223566	6.529,40	143	5268273	2.459,24	176	8465436	3.040,68	209	3949885	3.937,04
12	4064976	4.977,10	45	5270251	4.560,10	78	5266726	3.353,09	111	3169707	3.797,60	144	8221146	6.000,89	177	5644836	3.568,45	210	3418340	2.557,87
13	2818612	344,64	46	4078071	5.389,39	79	4312163	7.012,57	112	5269423	8.750,28	145	8247307	8.770,37	178	5624339	22,01	211	1839551	3.401,03
14	5270650	17.295,00	47	4685431	5.698,12	80	3508978	10.059,34	113	4353064	363,13	146	8390711	7.619,84	179	5268109	2.714,67	212	3193780	3.877,41
15	3180840	815,94	48	8468419	3.825,65	81	5266653	2.109,43	114	3118908	6.027,86	147	5267722	16.776,60	180	5268826	5.496,41	213	5269032	1.579,84
16	5270537	6.662,48	49	5270189	3.837,47	82	5266599	2.503,90	115	8504504	8,13	148	5267684	5.980,46	181	5268702	3.919,15	214	3920364	2.877,84
17	5265932	5.790,26	50	3294110	59,57	83	4076451	3.253,98	116	3086461	1.977,50	149	5268230	4.809,10	182	5268672	3.583,55	215	3405796	1.963,87
18	5265878	8.728,76	51	5270146	1.172,46	84	2707667	5.698,66	117	5268443	3.073,56	150	3213501	3.794,55	183	5268060	6.305,04	216	3948986	5.470,67
19	3048578	503,17	52	3086585	16.832,71	85	5269954	4.227,66	118	5267978	5.509,46	151	5269342	2.445,59	184	8460558	523,57	217	3025217	2.176,37
20	5265495	1,07	53	5266130	2.158,64	86	5269903	0,00	119	5268419	2.411,34	152	2909359	6.119,77	185	2915154	3.727,40	218	5267277	98,52
21	3752941	2.489,78	54	5266432	5.013,43	87	5267005	11.371,54	120	4312260	4.863,74	153	5267609	1.800,52	186	5267366	4.046,90	219	4062639	8.695,28
22	5265568	0,84	55	5266386	7.559,83	88	5269849	2.956,58	121	4472446	6.457,01	154	8504431	3.328,67	187	5268729	960,69	220	3922723	2.420,37
23	4064496	6.729,74	56	5270103	1.900,50	89	3296962	4.281,11	122	3102424	4.742,12	155	3301222	122,45	188	4621859	11.323,89	221	4078144	3.716,40
24	5270596	11.722,90	57	5266319	0,00	90	5267048	3.204,74	123	4754840	877,62	156	2739925	2,20	189	3032612	5.864,36	222	4441893	2.317,96
25	5265819	14.998,17	58	8175179	4.039,06	91	5269741	6.878,02	124	5267935	6.069,62	157	4267060	8.932,57	190	8568995	1.978,21	223	3256839	3.420,86
26	5266025	3.640,55	59	8732515	5.974,85	92	1815342	5.317,75	125	3663892	2.454,52	158	8469679	7.940,48	191	3102254	1.405,02	224	5267137	2.681,06
27	5265614	7.704,26	60	8318328	6.851,89	93	5598664	5.873,44	126	4578848	3.513,48	159	4760999	2.109,24	192	5267404	4.864,77	225	5575672	7.493,74
28	3179192	0,27	61	5266254	5.383,95	94	5269601	4.121,08	127	8419574	4.230,67	160	5598745	86,72	193	3440893	6.488,75	226	1811487	4.568,30
29	5270421	3.329,19	62	5587220	1.673,25	95	5269792	5.558,24	128	5267838	11.615,54	161	1816071	7.437,90	194	4621794	3.325,38	227	5268583	64,36
30	5265770	4.622,78	63	8368910	70,33	96	4701720	2.541,96	129	3362493	3.533,29	162	4759494	3.166,08	195	3478076	8.102,17	228	3462765	6.054,90
31	5265991	0,00	64	5266203	3.852,55	97	3161250	340,53	130	5268346	2.495,27	163	5269091	5.269,95	196	3102165	6.399,04	229	4091132	5.150,33
32	5270480	9.677,86	65	5270057	467,16	98	5269717	3.589,85	131	8253943	8.682,12	164	3055310	1.517,70	197	1840703	2.403,72	230	8572941	842,01
33	8465967	3.734,14	66	5266815	10.074,32	99	5269660	7.361,12	132	5267862	0,00	165	5268524	1.187,38	198	5268028	8,71	231	4759435	9.736,12

232	2941090	0,01	238	8236097	6.377,70	244	8414246	1.749,21	250	8830428	5.340,34	256	8578907	1.229,20	262	3046621	1.558,85	268	8801770	5.112,75
233	5267161	1.955,34	239	5267234	203,42	245	3795993	2.037,58	251	2690160	3.371,53	257	4093623	4.326,24	263	4522028	3.224,14	269	8296588	7.790,50
234	1823132	7.435,74	240	8410755	3.319,53	246	8760179	9.873,37	252	4484029	84,21	258	3212661	1.733,26	264	3139751	705,26	270	8296561	1.608,72
235	6189911	5.873,99	241	1836943	4.560,52	247	8733376	4.816,55	253	5594065	3.058,92	259	1824961	1.133,48	265	3440028	120,31			
236	8262276	4.779,82	242	2915227	7.151,90	248	8760187	1.843,97	254	8373515	4.179,24	260	8218323	3.145,44	266	3097161	6.331,57			
237	3072398	4.257,98	243	8460728	3.596,69	249	1794612	2.582,73	255	5268869	5.753,70	261	8296553	3.575,34	267	1790625	4.003,26			

Prilog 3. *Jednodnevno, satno mjerenje opterećenja transformatorske stanice i niskonaponskih izvoda (period vršnog opterećenja)*

Vrijeme mjerenja (h)	Transformatorska stanica		Niskonaponski izvod 1		Niskonaponski izvod 2		Niskonaponski izvod 3		Niskonaponski izvod 4		Niskonaponski izvod 5	
	Wa (kWh)	Wr (kVArh)	Wa (kWh)	Wr (kVArh)	Wa (kWh)	Wr (kVArh)	Wa (kWh)	Wr (kVArh)	Wa (kWh)	Wr (kVArh)	Wa (kWh)	Wr (kVArh)
1	99,30	32,38	17,90	5,84	18,16	5,92	24,62	8,03	15,27	4,98	23,35	7,61
2	93,68	34,90	16,88	6,29	17,13	6,38	23,23	8,65	14,41	5,37	22,03	8,21
3	78,45	32,81	14,14	5,91	14,34	6,00	19,45	8,14	12,07	5,05	18,45	7,72
4	70,80	32,33	12,76	5,83	12,95	5,91	17,56	8,02	10,89	4,97	16,65	7,60
5	77,26	30,50	13,93	5,50	14,13	5,58	19,16	7,56	11,88	4,69	18,17	7,17
6	88,49	32,84	15,95	5,92	16,18	6,00	21,94	8,14	13,61	5,05	20,81	7,72
7	100,10	31,65	18,04	5,71	18,30	5,79	24,82	7,85	15,40	4,87	23,54	7,44
8	128,83	32,64	23,22	5,88	23,56	5,97	31,94	8,09	19,82	5,02	30,29	7,68
9	156,91	33,12	28,28	5,97	28,69	6,06	38,91	8,21	24,13	5,09	36,90	7,79
10	162,91	33,17	29,36	5,98	29,79	6,06	40,39	8,22	25,06	5,10	38,31	7,80
11	142,94	31,73	25,76	5,72	26,14	5,80	35,44	7,87	19,02	5,32	33,61	7,46
12	131,95	32,93	23,78	5,93	24,13	6,02	32,72	8,16	21,99	4,88	31,03	7,74
13	123,65	34,56	22,29	6,23	42,47	7,58	30,66	8,57	20,30	5,06	29,08	8,13
14	159,84	34,99	28,81	6,31	29,23	6,40	39,63	8,68	24,58	5,38	37,59	8,23
15	232,27	41,47	41,86	7,47	22,61	6,32	57,59	10,28	35,73	6,38	54,62	9,75
16	328,22	59,90	68,04	10,71	60,02	10,95	81,38	14,85	58,07	9,14	77,18	14,09
17	377,53	59,40	59,16	10,80	69,03	10,86	93,61	14,73	50,48	9,21	88,78	13,97
18	262,28	56,63	52,32	9,02	47,96	10,36	65,03	14,04	44,65	7,70	61,68	13,32
19	252,00	53,08	47,27	10,21	46,08	9,71	62,48	13,16	38,76	8,16	59,26	12,48
20	290,28	50,06	45,42	9,57	53,08	9,15	71,98	12,41	40,34	8,71	68,26	11,77
21	238,75	43,55	43,03	7,85	43,66	7,96	59,20	10,80	36,72	6,70	56,14	10,24
22	225,07	44,16	40,56	7,96	41,16	8,07	55,81	10,95	34,62	6,79	52,93	10,38
23	171,55	40,80	30,92	7,35	31,37	7,46	42,54	10,12	26,39	6,28	40,34	9,59
24	133,58	41,23	24,08	7,43	24,43	7,54	33,12	10,22	20,55	6,34	31,41	9,70

Prilog 4. *Pojedinačno godišnje vršno opterećenje niskonaponskih potrošača*

Mjerno mjesto	Energija (kWh)	P (kW)	Q (kVAr)	Mjerno mjesto	Energija (kWh)	P (kW)	Q (kVAr)	Mjerno mjesto	Energija (kWh)	P (kW)	Q (kVAr)	Mjerno mjesto	Energija (kWh)	P (kW)	Q (kVAr)	Mjerno mjesto	Energija (kWh)	P (kW)	Q (kVAr)
5270812	19.633,93	6,40	1,48	4521943	6.687,12	2,18	0,50	5266920	3.757,91	1,23	0,28	4275977	5.852,35	1,91	0,44	4215710	6.590,84	2,06	0,48
3419703	1.673,75	0,55	0,13	8368821	3.905,84	1,27	0,29	5266483	8.323,03	2,71	0,63	5269490	8.202,31	2,68	0,62	3405702	6.788,49	2,12	0,49
5265126	5.926,43	1,93	0,45	5265657	1.788,69	0,58	0,13	5266785	7.513,03	2,45	0,56	4431197	3.934,55	1,28	0,30	3272125	3.229,91	1,01	0,23
3859533	8.452,35	2,76	0,63	5266084	370,38	0,12	0,03	1837044	382,98	0,12	0,03	3406482	0,36	0,00	0,00	4697006	1.468,14	0,46	0,11
5265215	3.240,10	1,06	0,24	5270383	4.111,60	1,34	0,31	1836978	6.667,92	2,17	0,50	4401921	10.477,53	3,42	0,79	5267765	978,80	0,29	0,07
5265282	8.467,33	2,76	0,64	2797690	2.967,75	0,97	0,22	5266572	2.361,98	0,77	0,18	3223647	62,68	0,02	0,00	3139271	3.478,98	1,09	0,25
5270731	4.243,48	1,38	0,32	4077067	6.315,13	2,06	0,47	5269997	885,28	0,29	0,07	5269385	4.651,09	1,46	0,34	5268273	2.459,24	0,77	0,18
5265258	4.837,40	1,58	0,36	8534365	4.677,18	1,52	0,35	5266963	1.332,64	0,43	0,10	3223566	6.529,40	2,13	0,49	8221146	6.000,89	1,88	0,43
5270693	8.700,48	2,84	0,65	5265711	3.012,99	0,98	0,23	3094669	3.984,76	1,30	0,30	3169707	3.797,60	1,24	0,29	8247307	8.770,37	2,74	0,63
8767181	201,15	0,07	0,02	3227987	7.416,83	2,42	0,56	5266726	3.353,09	1,09	0,25	5269423	8.750,28	2,74	0,63	8390711	7.619,84	2,38	0,55
5265347	4.359,45	1,42	0,33	5270251	4.560,10	1,49	0,34	4312163	7.012,57	2,29	0,53	4353064	363,13	0,12	0,03	5267722	16.776,60	5,02	1,16
4064976	4.977,10	1,62	0,37	4078071	5.389,39	1,76	0,40	3508978	10.059,34	3,28	0,76	3118908	6.027,86	1,97	0,45	5267684	5.980,46	1,79	0,41
2818612	344,64	0,11	0,03	4685431	5.698,12	1,86	0,43	5266653	2.109,43	0,69	0,16	8504504	8,13	0,00	0,00	5268230	4.809,10	1,50	0,35
5270650	17.295,00	5,64	1,30	8468419	3.825,65	1,25	0,29	5266599	2.503,90	0,82	0,19	3086461	1.977,50	0,64	0,15	3213501	3.794,55	1,13	0,26
3180840	815,94	0,27	0,06	5270189	3.837,47	1,25	0,29	4076451	3.253,98	1,06	0,24	5268443	3.073,56	1,00	0,23	5269342	2.445,59	0,77	0,18
5270537	6.662,48	2,17	0,50	3294110	59,57	0,02	0,00	2707667	5.698,66	1,86	0,43	5267978	5.509,46	1,80	0,41	2909359	6.119,77	1,83	0,42
5265932	5.790,26	1,89	0,43	5270146	1.172,46	0,38	0,09	5269954	4.227,66	1,38	0,32	5268419	2.411,34	0,79	0,18	5267609	1.800,52	0,54	0,12
5265878	8.728,76	2,85	0,66	3086585	16.832,71	5,49	1,26	5269903	0,00	0,00	0,00	4312260	4.863,74	1,59	0,37	8504431	3.328,67	1,04	0,24
3048578	503,17	0,16	0,04	5266130	2.158,64	0,70	0,16	5267005	11.371,54	3,71	0,85	4472446	6.457,01	2,11	0,49	3301222	122,45	0,04	0,01
5265495	1,07	0,00	0,00	5266432	5.013,43	1,63	0,38	5269849	2.956,58	0,96	0,22	3102424	4.742,12	1,55	0,36	2739925	2,20	0,00	0,00
3752941	2.489,78	0,81	0,19	5266386	7.559,83	2,46	0,57	3296962	4.281,11	1,40	0,32	4754840	877,62	0,27	0,06	4267060	8.932,57	2,67	0,62
5265568	0,84	0,00	0,00	5270103	1.900,50	0,62	0,14	5267048	3.204,74	1,05	0,24	5267935	6.069,62	1,98	0,46	8469679	7.940,48	2,48	0,57
4064496	6.729,74	2,20	0,51	5266319	0,00	0,00	0,00	5269741	6.878,02	2,24	0,52	3663892	2.454,52	0,80	0,18	4760999	2.109,24	0,66	0,15
5270596	11.722,90	3,82	0,88	8175179	4.039,06	1,32	0,30	1815342	5.317,75	1,73	0,40	4578848	3.513,48	1,15	0,26	5598745	86,72	0,03	0,01
5265819	14.998,17	4,89	1,13	8732515	5.974,85	1,95	0,45	5598664	5.873,44	1,92	0,44	8419574	4.230,67	1,38	0,32	1816071	7.437,90	2,33	0,54
5266025	3.640,55	1,19	0,27	8318328	6.851,89	2,23	0,51	5269601	4.121,08	1,34	0,31	5267838	11.615,54	3,79	0,87	4759494	3.166,08	0,99	0,23
5265614	7.704,26	2,51	0,58	5266254	5.383,95	1,75	0,40	5269792	5.558,24	1,81	0,42	3362493	3.533,29	1,15	0,27	5269091	5.269,95	1,65	0,38
3179192	0,27	0,00	0,00	5587220	1.673,25	0,55	0,13	4701720	2.541,96	0,83	0,19	5268346	2.495,27	0,78	0,18	3055310	1.517,70	0,47	0,11
5270421	3.329,19	1,09	0,25	8368910	70,33	0,02	0,01	3161250	340,53	0,11	0,03	8253943	8.682,12	2,83	0,65	5268524	1.187,38	0,37	0,09
5265770	4.622,78	1,51	0,35	5266203	3.852,55	1,26	0,29	5269717	3.589,85	1,12	0,26	5267862	0,00	0,00	0,00	5268133	4.497,06	1,41	0,32
5265991	0,00	0,00	0,00	5270057	467,16	0,15	0,04	5269660	7.361,12	2,40	0,55	5268494	4.009,32	1,25	0,29	5269296	2.944,88	0,92	0,21
5270480	9.677,86	3,16	0,73	5266815	10.074,32	3,28	0,76	5269547	5.345,55	1,74	0,40	2063654	423,80	0,13	0,03	1813498	2,83	0,00	0,00
8465967	3.734,14	1,22	0,28	3795853	7.308,67	2,38	0,55	4396529	3.484,03	1,14	0,26	8695911	3.542,76	1,06	0,24	8256055	5.183,98	1,62	0,37
5270308	2.820,51	0,92	0,21	2727145	4.536,40	1,48	0,34	1802917	5.233,68	1,71	0,39	8452547	4.374,23	1,31	0,30	5269156	1.107,97	0,35	0,08

5268559	5.210,98	1,63	0,38	3102254	1.405,02	0,42	0,10	1839551	3.401,03	1,02	0,23	4759435	9.736,12	2,91	0,67	2690160	3.371,53	1,01	0,23
5269199	1.357,16	0,42	0,10	5267404	4.864,77	1,45	0,34	3193780	3.877,41	1,16	0,27	2941090	0,01	0,00	0,00	4484029	84,21	0,03	0,01
4449959	7.138,80	2,13	0,49	3440893	6.488,75	2,03	0,47	5269032	1.579,84	0,49	0,11	5267161	1.955,34	0,58	0,13	5594065	3.058,92	0,96	0,22
5268184	1.806,29	0,57	0,13	4621794	3.325,38	0,99	0,23	3920364	2.877,84	0,86	0,20	1823132	7.435,74	2,22	0,51	8373515	4.179,24	1,25	0,29
5268648	6.674,61	2,09	0,48	3478076	8.102,17	2,53	0,58	3405796	1.963,87	0,59	0,14	6189911	5.873,99	1,84	0,42	5268869	5.753,70	1,80	0,41
8465436	3.040,68	0,95	0,22	3102165	6.399,04	1,91	0,44	3948986	5.470,67	1,64	0,38	8262276	4.779,82	1,50	0,34	8578907	1.229,20	0,37	0,08
5644836	3.568,45	1,07	0,25	1840703	2.403,72	0,75	0,17	3025217	2.176,37	0,65	0,15	3072398	4.257,98	1,33	0,31	4093623	4.326,24	1,35	0,31
5624339	22,01	0,01	0,00	5268028	8,71	0,00	0,00	5267277	98,52	0,03	0,01	8236097	6.377,70	2,00	0,46	3212661	1.733,26	0,54	0,12
5268109	2.714,67	0,85	0,20	3084604	3.968,72	1,24	0,29	4062639	8.695,28	2,60	0,60	5267234	203,42	0,06	0,01	1824961	1.133,48	0,34	0,08
5268826	5.496,41	1,72	0,40	3216829	7.931,28	2,37	0,55	3922723	2.420,37	0,72	0,17	8410755	3.319,53	1,04	0,24	8218323	3.145,44	0,94	0,22
5268702	3.919,15	1,23	0,28	2833786	3.916,76	1,17	0,27	4078144	3.716,40	1,11	0,26	1836943	4.560,52	1,36	0,31	8296553	3.575,34	1,07	0,25
5268672	3.583,55	1,12	0,26	5267323	1.064,08	0,32	0,07	4441893	2.317,96	0,69	0,16	2915227	7.151,90	2,24	0,52	3046621	1.558,85	0,47	0,11
5268060	6.305,04	1,97	0,45	8452466	3.499,31	1,09	0,25	3256839	3.420,86	1,02	0,24	8460728	3.596,69	1,13	0,26	4522028	3.224,14	0,96	0,22
8460558	523,57	0,16	0,04	3151743	5.090,76	1,59	0,37	5267137	2.681,06	0,80	0,18	8414246	1.749,21	0,55	0,13	3139751	705,26	0,21	0,05
2915154	3.727,40	1,11	0,26	8329494	4.772,46	1,49	0,34	5575672	7.493,74	2,24	0,52	3795993	2.037,58	0,61	0,14	3440028	120,31	0,04	0,01
5267366	4.046,90	1,21	0,28	8419582	8.879,24	2,65	0,61	1811487	4.568,30	1,37	0,31	8760179	9.873,37	3,09	0,71	3097161	6.331,57	1,89	0,44
5268729	960,69	0,30	0,07	4171292	717,29	0,21	0,05	5268583	64,36	0,02	0,00	8733376	4.816,55	1,51	0,35	1790625	4.003,26	1,20	0,28
4621859	11.323,89	3,54	0,82	4062779	4.640,56	1,39	0,32	3462765	6.054,90	1,81	0,42	8760187	1.843,97	0,58	0,13	8801770	5.112,75	1,53	0,35
3032612	5.864,36	1,75	0,40	3949885	3.937,04	1,18	0,27	4091132	5.150,33	1,54	0,35	1794612	2.582,73	0,77	0,18	8296588	7.790,50	2,33	0,54
8568995	1.978,21	0,62	0,14	3418340	2.557,87	0,80	0,18	8572941	842,01	0,26	0,06	8830428	5.340,34	1,60	0,37	8296561	1.608,72	0,48	0,11

Prilog 5. *Zemljopisne koordinate stupnih mjesta distribucijske mreže sa 5 niskonaponskih izvoda*

Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata	
		X	Y			X	Y			X	Y			X	Y
C1	S1	4931193,24	6551800,76	C1	S14	4931273,53	6551740,23	C1	S27	4931287,21	6551657,18	C2	S130	4930997,46	6551952,50
C1	S2	4931204,97	6551818,71	C1	S15	4931286,57	6551692,72	C1	S28	4931276,08	6551636,42	C2	S131	4930983,66	6551982,03
C1	S3	4931223,29	6551839,71	C1	S16	4931305,48	6551681,08	C1	S29	4931299,10	6551624,08	C2	S132	4930976,84	6552007,62
C1	S4	4931217,21	6551794,73	C1	S17	4931313,89	6551710,72	C1	S30	4931323,69	6551615,15	C2	S133	4930950,72	6552037,52
C1	S5	4931234,10	6551791,24	C1	S18	4931321,37	6551737,14	C1	S31	4931357,81	6551634,62	C2	S134	4930926,87	6552063,23
C1	S6	4931242,07	6551751,65	C1	S19	4931337,50	6551781,29	C1	S32	4931308,04	6551647,86	C2	S135	4930905,14	6552092,46
C1	S7	4931221,11	6551726,71	C1	S20	4931335,87	6551705,50	C2	S123	4931164,35	6551809,70	C2	S136	4930890,99	6552070,11
C1	S8	4931255,42	6551722,45	C1	S21	4931361,92	6551702,02	C2	S124	4931132,31	6551817,82	C2	S137	4930877,42	6552046,26
C1	S9	4931231,72	6551696,46	C1	S22	4931374,90	6551701,17	C2	S125	4931097,07	6551830,94	C2	S138	4930868,44	6552094,93
C1	S10	4931241,19	6551675,07	C1	S23	4931346,93	6551730,41	C2	S126	4931076,29	6551847,93	C2	S139	4930833,50	6552073,53
C1	S11	4931244,59	6551641,01	C1	S24	4931360,15	6551775,85	C2	S127	4931057,75	6551868,92	C2	S140	4930807,99	6552044,69
C1	S12	4931258,35	6551785,85	C1	S25	4931377,30	6551771,34	C2	S128	4931032,85	6551900,67	C2	S141	4930774,40	6552040,75
C1	S13	4931279,04	6551806,59	C1	S26	4931387,50	6551738,37	C2	S129	4931016,64	6551927,38	C2	S142	4930748,88	6552037,05

C2	S143	4930707,42	6552018,44	C3	S78	4931055,98	6551709,09	C4	S103	4931158,79	6551876,59	C5	S38	4931286,23	6551691,54
C2	S144	4930707,42	6552018,44	C3	S79	4931052,82	6551746,05	C4	S104	4931186,81	6551866,35	C5	S39	4931304,69	6551678,64
C2	S145	4930690,08	6552018,96	C3	S80	4931052,77	6551656,10	C4	S105	4931077,33	6551848,63	C5	S40	4931349,72	6551673,91
C2	S146	4930714,80	6552049,14	C3	S81	4931051,42	6551622,94	C4	S106	4931059,16	6551869,11	C5	S41	4931390,64	6551661,88
C2	S147	4930692,40	6552047,39	C3	S82	4931048,04	6551588,32	C4	S107	4931072,78	6551882,12	C5	S42	4931415,06	6551651,48
C2	S148	4930672,03	6552065,70	C3	S83	4931021,77	6551673,29	C4	S108	4931037,65	6551853,81	C5	S43	4931411,41	6551626,96
C2	S149	4930660,87	6552036,14	C3	S84	4930995,65	6551695,87	C4	S109	4931015,30	6551819,62	C5	S44	4931442,74	6551644,39
C3	S60	4931167,25	6551759,02	C3	S85	4930976,45	6551676,01	C4	S110	4931033,74	6551901,58	C5	S45	4931429,43	6551603,79
C3	S61	4931144,94	6551777,61	C3	S86	4930957,19	6551650,97	C4	S111	4931004,92	6551893,21	C5	S46	4931467,05	6551645,86
C3	S62	4931169,62	6551722,29	C3	S87	4930972,02	6551710,12	C4	S112	4931051,22	6551939,48	C5	S47	4931470,74	6551676,95
C3	S63	4931157,54	6551687,20	C3	S88	4930954,38	6551688,29	C4	S113	4931080,66	6551959,99	C5	S48	4931465,34	6551704,30
C3	S64	4931169,95	6551682,17	C3	S89	4930972,02	6551710,12	C4	S114	4931037,87	6551978,56	C5	S49	4931471,46	6551733,76
C3	S65	4931166,11	6551647,73	C3	S90	4930916,91	6551707,27	C4	S115	4931062,29	6552003,44	C5	S50	4931481,84	6551698,87
C3	S66	4931178,21	6551621,16	C3	S91	4930924,13	6551744,31	C4	S116	4931017,44	6551928,19	C5	S51	4931509,78	6551689,19
C3	S67	4931149,64	6551605,15	C3	S92	4930899,57	6551726,28	C4	S117	4930998,57	6551952,80	C5	S52	4931503,15	6551644,40
C3	S68	4931141,48	6551623,12	C3	S93	4930896,54	6551764,46	C4	S118	4930984,66	6551982,10	C5	S53	4931521,57	6551637,59
C3	S69	4931141,00	6551743,59	C3	S94	4930832,10	6551723,06	C4	S119	4930977,90	6552007,58	C5	S54	4931511,11	6551608,30
C3	S70	4931125,55	6551763,34	C3	S95	4930832,10	6551723,06	C4	S120	4930979,23	6552036,72	C5	S55	4931499,26	6551581,68
C3	S71	4931117,22	6551725,45	C3	S96	4930810,15	6551693,80	C4	S121	4930998,72	6552060,62	C5	S56	4931532,64	6551562,77
C3	S72	4931096,16	6551720,00	C3	S97	4930804,95	6551729,21	C4	S122	4931013,47	6552075,66	C5	S57	4931540,51	6551664,86
C3	S73	4931087,01	6551739,71	C4	S98	4931165,53	6551810,69	C5	S33	4931194,46	6551799,55	C5	S58	4931543,18	6551627,60
C3	S74	4931088,43	6551703,22	C4	S99	4931132,35	6551819,41	C5	S34	4931214,90	6551794,24	C5	S59	4931575,62	6551610,61
C3	S75	4931104,37	6551679,49	C4	S100	4931098,08	6551831,78	C5	S35	4931235,62	6551790,11				
C3	S76	4931124,39	6551684,40	C4	S101	4931114,20	6551856,41	C5	S36	4931258,15	6551783,16				
C3	S77	4931072,49	6551678,13	C4	S102	4931133,05	6551883,16	C5	S37	4931272,51	6551740,16				

Prilog 6. *Zemljopisne koordinate stupnih mjesta distribucijske mreže sa 6 niskonaponskih izvoda*

Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata	
		X	Y			X	Y			X	Y			X	Y
C1	S168	4931157,26	6551804,59	C1	S176	4930993,61	6551961,45	C1	S184	4930866,14	6552055,09	C1	S192	4930711,49	6552020,85
C1	S169	4931130,05	6551813,10	C1	S177	4930985,90	6551992,31	C1	S185	4930841,89	6552066,91	C1	S193	4930676,09	6552022,37
C1	S170	4931104,12	6551821,99	C1	S178	4930968,53	6552022,54	C1	S186	4930816,24	6552059,17	C2	S1	4931189,10	6551808,23
C1	S171	4931082,81	6551833,51	C1	S179	4930949,23	6552041,70	C1	S187	4930793,02	6552039,58	C2	S2	4931157,03	6551811,23
C1	S172	4931066,15	6551850,76	C1	S180	4930923,58	6552064,93	C1	S188	4930760,27	6552039,53	C2	S3	4931210,33	6551823,71
C1	S173	4931041,07	6551880,83	C1	S181	4930905,79	6552095,03	C1	S189	4930727,46	6552047,65	C2	S4	4931226,23	6551843,10
C1	S174	4931024,03	6551904,01	C1	S182	4930883,62	6552096,37	C1	S190	4930694,83	6552047,51	C2	S5	4931240,11	6551830,81
C1	S175	4931010,92	6551932,76	C1	S183	4930857,58	6552085,01	C1	S191	4930668,37	6552070,32	C2	S6	4931209,20	6551850,71

C2	S7	4931187,34	6551866,21	C3	S48	4931286,40	6551692,78	C4	S89	4931402,73	6551626,73	C5	S130	4930955,83	6551648,98
C2	S8	4931165,38	6551886,55	C3	S49	4931253,80	6551695,28	C4	S90	4931410,74	6551600,15	C5	S131	4930956,23	6551720,38
C2	S9	4931165,07	6551771,35	C3	S50	4931270,46	6551666,71	C4	S91	4931432,66	6551594,27	C5	S132	4930940,50	6551701,21
C2	S10	4931137,93	6551785,11	C3	S51	4931267,81	6551637,34	C4	S92	4931452,05	6551585,00	C5	S133	4930927,31	6551683,45
C2	S11	4931123,99	6551797,74	C3	S52	4931244,34	6551618,36	C4	S93	4931440,98	6551646,97	C5	S134	4930927,77	6551726,64
C2	S12	4931104,25	6551804,65	C3	S53	4931215,93	6551603,16	C4	S94	4931465,57	6551645,54	C5	S135	4930897,32	6551732,40
C2	S13	4931083,55	6551798,46	C3	S54	4931304,79	6551680,14	C4	S95	4931441,38	6551678,93	C5	S136	4930898,12	6551705,94
C2	S14	4931054,52	6551806,02	C3	S55	4931280,84	6551657,86	C4	S96	4931444,94	6551706,67	C5	S137	4930871,63	6551736,04
C2	S15	4931124,44	6551822,26	C3	S56	4931303,35	6551652,09	C4	S97	4931464,29	6551704,92	C5	S138	4930843,83	6551727,90
C2	S16	4931102,02	6551844,52	C3	S57	4931316,04	6551648,43	C4	S98	4931459,58	6551739,07	C5	S139	4930820,83	6551707,27
C2	S17	4931146,66	6551752,52	C3	S58	4931278,99	6551634,01	C4	S99	4931495,85	6551646,44	C5	S140	4930808,91	6551687,66
C2	S18	4931122,80	6551754,81	C3	S59	4931301,06	6551623,43	C4	S100	4931490,46	6551617,10	C5	S141	4930797,49	6551716,31
C2	S19	4931092,45	6551745,30	C3	S60	4931320,88	6551617,67	C4	S101	4931485,84	6551598,49	C6	S142	4931157,23	6551803,37
C2	S20	4931135,19	6551728,29	C3	S61	4931329,47	6551677,18	C4	S102	4931501,85	6551579,32	C6	S143	4931130,09	6551811,95
C2	S21	4931107,72	6551717,17	C3	S62	4931337,67	6551704,62	C4	S103	4931531,32	6551562,30	C6	S144	4931104,10	6551820,94
C2	S22	4931106,19	6551691,12	C3	S63	4931358,76	6551671,97	C4	S104	4931471,91	6551668,57	C6	S145	4931082,72	6551832,25
C2	S23	4931087,43	6551701,49	C3	S64	4931368,31	6551698,09	C4	S105	4931480,11	6551693,10	C6	S146	4931065,09	6551850,11
C2	S24	4931186,63	6551751,45	C3	S65	4931378,91	6551696,57	C4	S106	4931501,78	6551685,42	C6	S147	4931073,26	6551881,88
C2	S25	4931195,03	6551723,05	C3	S66	4931383,18	6551709,90	C4	S107	4931521,78	6551678,24	C6	S148	4931054,50	6551836,80
C2	S26	4931205,79	6551755,88	C3	S67	4931382,07	6551667,88	C4	S108	4931515,89	6551640,34	C6	S149	4931040,88	6551879,24
C2	S27	4931221,72	6551773,69	C3	S68	4931397,79	6551658,74	C4	S109	4931537,93	6551628,36	C6	S150	4931018,20	6551866,08
C2	S28	4931240,94	6551782,07	C3	S69	4931317,02	6551707,10	C4	S110	4931549,48	6551649,24	C6	S151	4931001,33	6551840,83
C2	S29	4931147,48	6551719,63	C3	S70	4931326,79	6551734,70	C4	S111	4931561,03	6551617,10	C6	S152	4931023,03	6551903,94
C2	S30	4931145,38	6551692,46	C3	S71	4931338,49	6551757,16	C4	S112	4931580,70	6551608,04	C6	S153	4931006,01	6551886,39
C2	S31	4931137,57	6551660,64	C3	S72	4931362,13	6551748,33	C5	S113	4931164,69	6551772,43	C6	S154	4931009,83	6551932,80
C2	S32	4931116,21	6551640,27	C3	S73	4931345,76	6551779,62	C5	S114	4931146,62	6551753,74	C6	S155	4931045,07	6551931,80
C2	S33	4931139,25	6551634,47	C3	S74	4931368,49	6551773,45	C5	S115	4931135,14	6551729,70	C6	S156	4931058,88	6551965,49
C2	S34	4931144,93	6551613,33	C3	S75	4931385,99	6551768,38	C5	S116	4931107,68	6551718,66	C6	S157	4931080,99	6551957,62
C2	S35	4931134,36	6551591,72	C3	S76	4931398,68	6551751,48	C5	S117	4931087,42	6551703,07	C6	S158	4931081,21	6551986,31
C2	S36	4931167,89	6551590,94	C4	S77	4931211,76	6551794,84	C5	S118	4931073,09	6551677,18	C6	S159	4931042,51	6551986,01
C2	S37	4931175,37	6551679,31	C4	S78	4931242,96	6551787,45	C5	S119	4931050,93	6551657,03	C6	S160	4930992,82	6551960,87
C2	S38	4931162,95	6551642,75	C4	S79	4931261,99	6551771,42	C5	S120	4931052,31	6551627,44	C6	S161	4930984,77	6551992,24
C2	S39	4931189,99	6551644,30	C4	S80	4931269,91	6551749,06	C5	S121	4931037,04	6551602,82	C6	S162	4930968,34	6552020,85
C3	S40	4931211,81	6551796,16	C4	S81	4931278,10	6551723,43	C5	S122	4931056,25	6551595,64	C6	S163	4930979,23	6552035,84
C3	S41	4931243,06	6551788,68	C4	S82	4931285,02	6551691,87	C5	S123	4931022,14	6551673,23	C6	S164	4930997,41	6552058,81
C3	S42	4931262,96	6551771,96	C4	S83	4931304,66	6551678,59	C5	S124	4930995,91	6551692,43	C6	S165	4931012,31	6552076,32
C3	S43	4931271,22	6551749,58	C4	S84	4931329,43	6551675,84	C5	S125	4930971,32	6551710,01	C6	S166	4930948,09	6552040,62

C3	S44	4931301,51	6551756,07	C4	S85	4931357,78	6551670,68	C5	S126	4930980,47	6551744,26	C6	S167	4930944,85	6552071,33
C3	S45	4931308,27	6551782,04	C4	S86	4931381,30	6551666,45	C5	S127	4931003,57	6551759,94				
C3	S46	4931279,39	6551722,45	C4	S87	4931396,92	6551657,71	C5	S128	4931007,32	6551789,69				
C3	S47	4931298,17	6551731,61	C4	S88	4931415,67	6551650,81	C5	S129	4930973,75	6551673,19				

Prilog 7. *Zemljopisne koordinate stupnih mjesta distribucijske mreže sa 7 niskonaponskih izvoda*

Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata	
		X	Y			X	Y			X	Y			X	Y
C1	S26	4931217,46	6551795,77	C1	S55	4931389,51	6551767,34	C2	S84	4931495,45	6551583,84	C3	S175	4931082,21	6551956,38
C1	S27	4931246,25	6551786,40	C1	S56	4931399,99	6551751,02	C2	S85	4931518,03	6551570,95	C3	S176	4931076,86	6551981,21
C1	S28	4931264,36	6551771,09	C1	S57	4931335,25	6551676,36	C2	S86	4931537,41	6551561,21	C3	S177	4931091,19	6551994,00
C1	S29	4931273,34	6551741,63	C1	S58	4931359,26	6551673,38	C2	S87	4931474,26	6551677,81	C3	S178	4931015,33	6551934,61
C1	S30	4931280,92	6551714,18	C1	S59	4931370,80	6551690,07	C2	S88	4931471,46	6551701,87	C3	S179	4930998,00	6551955,18
C1	S31	4931289,42	6551688,51	C1	S60	4931380,28	6551710,57	C2	S89	4931447,78	6551709,54	C3	S180	4930985,31	6551980,63
C1	S32	4931274,72	6551659,39	C1	S61	4931384,59	6551666,15	C2	S90	4931454,24	6551722,00	C3	S181	4930978,90	6552007,69
C1	S33	4931261,55	6551632,67	C1	S62	4931405,16	6551656,16	C2	S91	4931459,74	6551736,33	C3	S182	4930968,67	6552022,75
C1	S34	4931237,49	6551620,97	C1	S63	4931367,70	6551648,98	C2	S92	4931494,88	6551693,44	C3	S183	4930980,93	6552037,68
C1	S35	4931277,15	6551635,14	C1	S64	4931383,42	6551627,75	C2	S93	4931510,13	6551688,12	C3	S184	4930997,07	6552058,13
C1	S36	4931295,76	6551624,83	C2	S65	4931217,54	6551794,56	C2	S94	4931515,93	6551640,00	C3	S185	4931015,27	6552076,04
C1	S37	4931310,72	6551618,89	C2	S66	4931246,29	6551785,29	C2	S95	4931527,67	6551659,11	C3	S186	4930948,42	6552041,51
C1	S38	4931323,44	6551617,65	C2	S67	4931263,13	6551770,78	C2	S96	4931540,93	6551675,86	C3	S187	4930927,83	6552062,26
C1	S39	4931293,59	6551654,65	C2	S68	4931272,11	6551741,61	C2	S97	4931536,86	6551628,55	C3	S188	4930903,90	6552082,25
C1	S40	4931314,69	6551647,57	C2	S69	4931279,92	6551714,20	C2	S98	4931551,31	6551644,07	C3	S189	4930903,23	6552110,91
C1	S41	4931305,51	6551681,28	C2	S70	4931288,33	6551687,45	C2	S99	4931559,73	6551617,70	C3	S190	4930884,42	6552067,09
C1	S42	4931313,30	6551707,53	C2	S71	4931305,56	6551680,02	C2	S100	4931580,20	6551608,41	C3	S191	4930866,99	6552050,54
C1	S43	4931322,21	6551735,95	C2	S72	4931335,25	6551674,99	C3	S166	4931111,90	6551827,64	C4	S192	4931156,09	6551804,74
C1	S44	4931304,85	6551742,03	C2	S73	4931359,25	6551672,16	C3	S167	4931092,22	6551837,46	C4	S193	4931127,20	6551814,36
C1	S45	4931295,29	6551760,79	C2	S74	4931384,56	6551664,78	C3	S163	4931174,13	6551808,59	C4	S194	4931100,86	6551823,67
C1	S46	4931317,57	6551692,58	C2	S75	4931405,13	6551654,79	C3	S164	4931157,12	6551813,22	C4	S195	4931092,21	6551836,32
C1	S47	4931324,65	6551715,35	C2	S76	4931427,02	6551647,69	C3	S165	4931133,41	6551819,17	C4	S196	4931073,83	6551851,45
C1	S48	4931331,80	6551735,41	C2	S77	4931450,16	6551643,62	C3	S168	4931074,33	6551852,37	C4	S197	4931058,67	6551868,72
C1	S49	4931348,56	6551729,76	C2	S78	4931433,23	6551618,04	C3	S169	4931059,20	6551869,71	C4	S198	4931043,05	6551886,13
C1	S50	4931362,62	6551725,64	C2	S79	4931433,08	6551593,21	C3	S170	4931043,56	6551886,97	C4	S199	4931027,02	6551912,38
C1	S51	4931339,90	6551761,05	C2	S80	4931454,66	6551584,59	C3	S171	4931028,01	6551913,17	C4	S200	4931014,06	6551933,77
C1	S52	4931363,35	6551754,83	C2	S81	4931470,93	6551646,70	C3	S172	4931048,52	6551936,78	C4	S201	4930996,91	6551954,36
C1	S53	4931345,79	6551779,96	C2	S82	4931496,61	6551644,79	C3	S173	4931058,06	6551964,45	C4	S202	4930983,93	6551981,10
C1	S54	4931367,86	6551773,48	C2	S83	4931489,73	6551614,38	C3	S174	4931040,72	6551987,38	C4	S203	4930978,44	6552006,21

C4	S204	4930967,89	6552021,22	C5	S10	4931147,32	6551774,08	C6	S144	4931025,47	6551834,84	C7	S108	4931135,45	6551592,43
C4	S205	4930948,21	6552039,77	C5	S11	4931135,18	6551787,94	C6	S145	4931012,85	6551814,64	C7	S109	4931169,92	6551645,69
C4	S206	4930927,26	6552060,91	C5	S12	4931133,69	6551753,88	C6	S146	4930988,00	6551813,89	C7	S110	4931172,41	6551622,73
C4	S207	4930902,20	6552082,16	C5	S13	4931133,36	6551820,16	C6	S147	4931056,25	6551837,69	C7	S111	4931197,08	6551625,60
C4	S208	4930870,62	6552094,80	C5	S14	4931140,73	6551834,66	C6	S148	4931064,32	6551852,96	C7	S112	4931139,08	6551711,72
C4	S209	4930848,13	6552072,87	C5	S15	4931199,09	6551788,43	C6	S149	4931067,72	6551884,56	C7	S113	4931112,82	6551724,02
C4	S210	4930819,80	6552056,93	C5	S16	4931206,56	6551756,68	C6	S150	4931037,44	6551854,33	C7	S114	4931112,40	6551699,39
C4	S211	4930795,88	6552039,60	C5	S17	4931196,56	6551731,09	C6	S151	4931013,56	6551877,25	C7	S115	4931112,35	6551668,60
C4	S212	4930767,64	6552039,27	C5	S18	4931207,87	6551697,95	C6	S152	4930993,92	6551902,89	C7	S116	4931097,69	6551681,18
C4	S213	4930745,16	6552038,05	C5	S19	4931231,10	6551698,92	C6	S153	4930968,36	6551789,48	C7	S117	4931071,40	6551672,08
C4	S214	4930726,22	6552048,18	C5	S20	4931219,04	6551801,73	C6	S154	4930948,67	6551762,84	C7	S118	4931070,13	6551701,47
C4	S215	4930730,02	6552019,80	C5	S21	4931238,06	6551796,13	C6	S155	4930920,88	6551748,09	C7	S119	4931066,32	6551724,57
C4	S216	4930710,28	6552011,17	C5	S22	4931257,85	6551782,69	C6	S156	4930898,86	6551728,31	C7	S120	4931085,99	6551640,84
C4	S217	4930691,78	6552017,85	C5	S23	4931278,95	6551803,75	C6	S157	4930867,58	6551728,44	C7	S121	4931077,68	6551605,64
C4	S218	4930674,89	6552034,29	C5	S24	4931238,87	6551763,09	C6	S158	4930839,13	6551714,22	C7	S122	4931056,73	6551593,91
C4	S219	4930656,89	6552027,87	C5	S25	4931238,28	6551739,29	C6	S159	4930822,06	6551695,97	C7	S123	4931035,11	6551589,89
C4	S220	4930658,01	6552050,62	C6	S134	4931156,06	6551803,54	C6	S160	4930803,94	6551685,87	C7	S124	4931050,86	6551657,89
C5	S1	4931197,95	6551806,27	C6	S135	4931127,14	6551813,16	C6	S161	4930814,98	6551711,74	C7	S125	4931022,80	6551672,78
C5	S2	4931174,65	6551809,60	C6	S136	4931100,12	6551823,36	C6	S162	4930794,15	6551711,38	C7	S126	4930999,77	6551691,44
C5	S3	4931157,09	6551814,24	C6	S137	4931103,63	6551852,12	C7	S101	4931173,86	6551761,88	C7	S127	4930973,48	6551672,43
C5	S4	4931212,58	6551828,65	C6	S138	4931093,42	6551869,92	C7	S102	4931166,26	6551728,02	C7	S128	4930950,79	6551645,08
C5	S5	4931186,35	6551849,96	C6	S139	4931081,97	6551814,16	C7	S103	4931155,07	6551700,81	C7	S129	4930967,46	6551695,75
C5	S6	4931173,92	6551882,00	C6	S140	4931083,59	6551789,89	C7	S104	4931151,70	6551670,60	C7	S130	4930943,94	6551675,91
C5	S7	4931228,77	6551841,77	C6	S141	4931057,75	6551816,05	C7	S105	4931135,88	6551648,56	C7	S131	4930946,47	6551713,09
C5	S8	4931218,62	6551851,92	C6	S142	4931051,03	6551791,22	C7	S106	4931141,97	6551623,83	C7	S132	4930928,01	6551710,76
C5	S9	4931176,81	6551781,06	C6	S143	4931033,08	6551825,63	C7	S107	4931151,32	6551594,26	C7	S133	4930913,61	6551692,93

Prilog 8. *Zemljopisne koordinate stupnih mjesta distribucijske mreže sa 8 niskonaponskih izvoda*

Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata		Izvod	Stupno mjesto	Koordinata	
		X	Y			X	Y			X	Y			X	Y
C1	S1	4931170,52	6551810,41	C1	S8	4931220,60	6551851,05	C1	S15	4931270,60	6551748,41	C2	S22	4931233,42	6551791,32
C1	S2	4931159,75	6551822,71	C1	S9	4931233,06	6551837,57	C1	S16	4931217,70	6551772,57	C2	S23	4931255,97	6551783,18
C1	S3	4931145,20	6551807,34	C1	S10	4931217,67	6551800,77	C1	S17	4931206,07	6551742,71	C2	S24	4931262,98	6551768,86
C1	S4	4931136,80	6551787,41	C1	S11	4931242,91	6551795,39	C1	S18	4931186,11	6551756,35	C2	S25	4931269,82	6551748,43
C1	S5	4931189,98	6551807,98	C1	S12	4931259,67	6551787,70	C1	S19	4931220,14	6551726,30	C2	S26	4931279,41	6551724,75
C1	S6	4931206,28	6551821,20	C1	S13	4931286,82	6551792,62	C1	S20	4931235,56	6551709,64	C2	S27	4931285,76	6551697,96
C1	S7	4931218,77	6551835,25	C1	S14	4931263,76	6551768,87	C2	S21	4931209,88	6551796,78	C2	S28	4931285,11	6551672,70

C2	S29	4931261,79	6551658,34	C3	S182	4931044,99	6551885,49	C4	S112	4931222,75	6551667,70	C5	S170	4931015,24	6551819,34
C2	S30	4931291,98	6551653,95	C3	S183	4931029,14	6551911,60	C4	S113	4931192,05	6551638,29	C5	S171	4930996,20	6551832,61
C2	S31	4931314,19	6551648,13	C3	S184	4931047,23	6551934,62	C4	S114	4931200,83	6551618,28	C5	S172	4931037,76	6551883,42
C2	S32	4931282,54	6551631,57	C3	S185	4931053,94	6551963,41	C4	S115	4931182,64	6551710,37	C5	S173	4931020,88	6551870,20
C2	S33	4931302,38	6551621,91	C3	S186	4931039,12	6551988,05	C4	S116	4931133,65	6551678,88	C5	S174	4931005,49	6551887,01
C2	S34	4931322,21	6551619,46	C3	S187	4931078,18	6551982,54	C4	S117	4931135,35	6551648,83	C5	S175	4930999,43	6551898,85
C2	S35	4931304,70	6551680,59	C3	S188	4931092,36	6551994,43	C4	S118	4931142,35	6551623,90	C6	S130	4931169,75	6551768,89
C2	S36	4931313,25	6551709,08	C3	S189	4931013,74	6551935,78	C4	S119	4931122,81	6551618,19	C6	S131	4931151,87	6551752,85
C2	S37	4931326,13	6551712,74	C3	S190	4931000,18	6551952,44	C4	S120	4931109,29	6551590,71	C6	S132	4931127,53	6551756,20
C2	S38	4931322,36	6551734,11	C3	S191	4930985,67	6551972,09	C4	S121	4931088,04	6551585,78	C6	S133	4931110,00	6551751,16
C2	S39	4931326,89	6551678,77	C3	S192	4930982,28	6552001,79	C4	S122	4931153,72	6551594,48	C6	S134	4931089,19	6551744,13
C2	S40	4931349,58	6551674,72	C3	S193	4930968,41	6552021,70	C4	S123	4931115,71	6551667,01	C6	S135	4931077,82	6551725,28
C2	S41	4931314,11	6551709,88	C3	S194	4930981,06	6552037,75	C4	S124	4931094,87	6551654,86	C6	S136	4931053,49	6551718,78
C2	S42	4931324,99	6551713,26	C3	S195	4930998,27	6552059,87	C4	S125	4931068,21	6551641,52	C6	S137	4931027,79	6551703,74
C2	S43	4931331,59	6551734,84	C3	S196	4931013,15	6552075,61	C4	S126	4931050,08	6551657,47	C6	S138	4930997,28	6551694,21
C2	S44	4931346,91	6551730,03	C3	S197	4930947,16	6552041,91	C4	S127	4931050,50	6551618,57	C6	S139	4930974,30	6551673,07
C2	S45	4931361,03	6551725,46	C3	S198	4930945,58	6552071,31	C4	S128	4931035,12	6551598,16	C6	S140	4930956,21	6551647,75
C2	S46	4931339,63	6551760,76	C3	S199	4930926,54	6552062,91	C4	S129	4931084,99	6551672,94	C6	S141	4930966,79	6551688,99
C2	S47	4931345,05	6551778,82	C3	S200	4930904,32	6552081,96	C5	S151	4931156,14	6551804,69	C6	S142	4930938,32	6551693,90
C2	S48	4931369,20	6551773,45	C3	S201	4930902,82	6552111,14	C5	S152	4931130,37	6551812,56	C6	S143	4930924,51	6551682,89
C2	S49	4931388,71	6551767,09	C3	S202	4930885,97	6552065,88	C5	S153	4931127,58	6551837,88	C6	S144	4930900,85	6551701,39
C2	S50	4931393,06	6551745,91	C3	S203	4930866,62	6552049,88	C5	S154	4931103,55	6551821,43	C6	S145	4930900,80	6551731,66
C2	S51	4931414,54	6551750,15	C4	S97	4931170,60	6551768,09	C5	S155	4931109,71	6551794,04	C6	S146	4930871,37	6551699,26
C2	S52	4931442,60	6551743,48	C4	S98	4931151,82	6551751,97	C5	S156	4931095,83	6551769,66	C6	S147	4930846,35	6551710,65
C2	S53	4931351,52	6551703,43	C4	S99	4931127,51	6551755,28	C5	S157	4931082,87	6551833,25	C6	S148	4930816,38	6551711,52
C2	S54	4931377,85	6551666,22	C4	S100	4931110,00	6551750,36	C5	S158	4931090,51	6551862,25	C6	S149	4930807,92	6551685,82
C2	S55	4931372,75	6551641,55	C4	S101	4931089,19	6551743,36	C5	S159	4931106,70	6551882,23	C6	S150	4930793,25	6551711,31
C2	S56	4931394,01	6551628,33	C4	S102	4931077,82	6551724,23	C5	S160	4931092,38	6551903,79	C7	S204	4931166,56	6551809,76
C2	S57	4931399,09	6551674,08	C4	S103	4931135,21	6551729,71	C5	S161	4931094,23	6551936,07	C7	S205	4931148,34	6551812,72
C2	S58	4931418,63	6551690,79	C4	S104	4931139,28	6551710,85	C5	S162	4931127,76	6551883,47	C7	S206	4931128,32	6551820,01
C2	S59	4931398,42	6551700,02	C4	S105	4931116,39	6551719,35	C5	S163	4931140,81	6551901,70	C7	S207	4931103,28	6551829,46
C3	S176	4931166,60	6551810,59	C4	S106	4931100,17	6551709,42	C5	S164	4931064,51	6551852,48	C7	S208	4931080,82	6551844,85
C3	S177	4931148,32	6551813,54	C4	S107	4931167,53	6551740,49	C5	S165	4931051,09	6551828,09	C7	S209	4931059,70	6551867,83
C3	S178	4931128,32	6551821,01	C4	S108	4931163,82	6551714,56	C5	S166	4931039,01	6551809,38	C7	S210	4931044,14	6551884,76
C3	S179	4931103,23	6551830,41	C4	S109	4931157,78	6551690,81	C5	S167	4931033,40	6551783,30	C7	S211	4931028,30	6551910,87
C3	S180	4931081,52	6551845,68	C4	S110	4931173,70	6551673,26	C5	S168	4931048,78	6551869,47	C7	S212	4931012,88	6551935,01
C3	S181	4931060,53	6551868,51	C4	S111	4931194,50	6551662,95	C5	S169	4931032,67	6551845,66	C7	S213	4930999,02	6551952,33

C7	S214	4930984,54	6551972,45	C7	S229	4930729,25	6552019,67	C8	S69	4931349,60	6551673,87	C8	S84	4931473,63	6551671,22
C7	S215	4930981,67	6552000,58	C7	S230	4930708,74	6552008,23	C8	S70	4931378,16	6551665,15	C8	S85	4931479,91	6551692,82
C7	S216	4930967,59	6552020,92	C7	S231	4930690,91	6552016,52	C8	S71	4931400,84	6551657,04	C8	S86	4931465,43	6551707,65
C7	S217	4930947,10	6552040,80	C7	S232	4930673,83	6552038,96	C8	S72	4931422,83	6551648,92	C8	S87	4931474,45	6551731,55
C7	S218	4930926,09	6552061,84	C7	S233	4930656,09	6552026,74	C8	S73	4931423,00	6551620,49	C8	S88	4931500,36	6551691,53
C7	S219	4930903,05	6552081,94	C7	S234	4930659,73	6552055,42	C8	S74	4931433,21	6551594,58	C8	S89	4931524,56	6551683,81
C7	S220	4930885,02	6552066,50	C8	S60	4931209,89	6551795,63	C8	S75	4931453,20	6551583,91	C8	S90	4931515,88	6551640,13
C7	S221	4930857,85	6552075,33	C8	S61	4931233,43	6551790,35	C8	S76	4931443,43	6551643,22	C8	S91	4931527,55	6551646,68
C7	S222	4930834,60	6552062,04	C8	S62	4931254,95	6551782,42	C8	S77	4931465,61	6551644,51	C8	S92	4931540,90	6551663,11
C7	S223	4930810,53	6552058,77	C8	S63	4931262,11	6551768,87	C8	S78	4931496,72	6551645,62	C8	S93	4931537,56	6551628,28
C7	S224	4930794,64	6552038,71	C8	S64	4931269,03	6551748,45	C8	S79	4931490,86	6551616,77	C8	S94	4931552,13	6551642,72
C7	S225	4930767,38	6552039,48	C8	S65	4931278,43	6551725,08	C8	S80	4931486,17	6551596,45	C8	S95	4931559,32	6551618,47
C7	S226	4930744,46	6552037,39	C8	S66	4931285,24	6551696,47	C8	S81	4931500,00	6551578,67	C8	S96	4931580,58	6551608,12
C7	S227	4930727,75	6552046,84	C8	S67	4931304,73	6551679,55	C8	S82	4931523,61	6551568,91				
C7	S228	4930706,78	6552038,08	C8	S68	4931326,94	6551677,85	C8	S83	4931540,96	6551556,04				

Prilog 9. *Duljine i presjeci dionica distribucijske mreže sa 5 niskonaponskih izvoda*

Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)
C1	TS-S1	12,81	70	C1	S6-122	19,03	16	C1	S5-S12	24,88	70	C1	S18-92	8,90	16	C1	S23-72	24,17	16
C1	S1-137	38,28	16	C1	S6-126	18,33	16	C1	S12-S13	29,26	35	C1	S18-S19	46,96	70	C1	S23-77	10,66	16
C1	S1-S2	21,41	35	C1	S6-S7	32,69	35	C1	S13-97	24,84	16	C1	S19-87	13,58	16	C1	S23-81	9,79	16
C1	S2-132	11,35	16	C1	S7-133	13,39	16	C1	S13-101	34,77	16	C1	S17-S20	22,75	35	C1	S19-S24	23,26	35
C1	S2-136	8,42	16	C1	S7-139	30,82	16	C1	S13-113	20,90	16	C1	S20-79	17,76	16	C1	S24-69	14,47	16
C1	S2-135	10,83	16	C1	S6-S8	32,06	35	C1	S13-118	29,31	16	C1	S20-80	17,49	16	C1	S24-71	14,66	16
C1	S2-141	15,32	16	C1	S8-108	17,31	16	C1	S12-106	16,34	16	C1	S20-82	14,72	16	C1	S24-76	9,00	16
C1	S2-S3	27,89	35	C1	S8-110	14,73	16	C1	S12-S14	48,01	70	C1	S20-84	12,85	16	C1	S24-78	12,61	16
C1	S3-129	12,18	16	C1	S8-117	15,75	16	C1	S14-103	15,29	16	C1	S20-S21	26,26	35	C1	S24-S25	17,80	35
C1	S3-124	13,94	16	C1	S7-S9	32,03	35	C1	S14-105	24,91	16	C1	S21-73	8,32	16	C1	S25-62	12,83	16
C1	S3-128	22,71	16	C1	S9-123	15,96	16	C1	S14-S15	49,43	70	C1	S21-74	9,59	16	C1	S25-63	16,64	16
C1	S3-121	18,72	16	C1	S9-S10	23,38	35	C1	S15-96	18,63	16	C1	S21-S22	13,06	35	C1	S25-66	12,18	16
C1	S3-120	18,14	16	C1	S10-109	29,02	16	C1	S15-102	19,41	16	C1	S22-60	25,04	16	C1	S22-S26	39,26	35
C1	S1-S4	24,81	70	C1	S10-112	31,44	16	C1	S15-S16	22,18	70	C1	S22-61	16,07	16	C1	S26-52	33,34	16
C1	S4-130	11,61	16	C1	S10-115	17,01	16	C1	S16-S17	30,83	70	C1	S22-64	17,19	16	C1	S26-54	18,59	16
C1	S4-125	14,37	16	C1	S10-S11	34,20	35	C1	S17-93	9,71	16	C1	S22-68	25,45	16	C1	S26-55	18,14	16
C1	S4-S5	17,27	70	C1	S11-127	29,58	16	C1	S17-S18	27,47	70	C1	S18-S23	26,48	35	C1	S26-57	25,12	16
C1	S5-S6	40,41	35	C1	S11-134	39,53	16	C1	S18-90	9,44	16	C1	S23-70	24,29	16	C1	S26-67	13,31	16

C1	S16-S27	29,96	35	C2	S135-S136	26,46	35	C3	S61-169	26,24	16	C3	S74-S75	28,63	35	C3	S88-242	30,87	16
C1	S27-S28	23,60	35	C2	S136-249	12,58	16	C3	S60-S62	36,81	35	C3	S75-178	32,29	16	C3	S87-S89	34,48	70
C1	S28-104	19,52	16	C2	S136-S137	27,36	35	C3	S62-142	24,37	16	C3	S75-180	11,15	16	C3	S89-S90	34,40	35
C1	S28-107	18,02	16	C2	S137-250	16,67	16	C3	S62-S63	37,07	35	C3	S75-S76	20,55	35	C3	S90-243	16,01	16
C1	S28-S29	26,21	35	C2	S137-251	22,09	16	C3	S63-151	18,18	16	C3	S76-161	21,01	16	C3	S90-244	28,36	16
C1	S29-94	17,23	16	C2	S135-S138	36,83	70	C3	S63-S64	13,38	35	C3	S76-167	19,60	16	C3	S90-247	21,67	16
C1	S29-95	12,18	16	C2	S138-S139	40,75	70	C3	S64-140	27,27	16	C3	S74-181	12,00	16	C3	S89-S91	24,56	70
C1	S29-99	10,27	16	C2	S139-254	20,02	16	C3	S64-S65	34,62	35	C3	S74-187	16,45	16	C3	S91-S92	30,40	35
C1	S29-100	13,11	16	C2	S139-S140	38,78	70	C3	S65-146	17,80	16	C3	S74-190	18,72	16	C3	S92-246	19,87	16
C1	S29-S30	26,10	35	C2	S140-256	31,10	16	C3	S65-S66	29,24	35	C3	S74-193	12,68	16	C3	S92-248	24,06	16
C1	S30-83	13,10	16	C2	S140-S141	33,67	70	C3	S66-138	22,41	16	C3	S74-S77	29,77	70	C3	S91-S93	34,10	35
C1	S30-85	13,75	16	C2	S141-259	11,99	16	C3	S66-144	14,79	16	C3	S77-S78	35,08	35	C3	S93-S94	42,43	35
C1	S30-89	18,97	16	C2	S141-S142	25,82	70	C3	S66-145	14,00	16	C3	S78-S79	37,10	35	C3	S94-S95	34,17	35
C1	S30-S31	39,20	35	C2	S142-S143	32,47	35	C3	S66-S67	32,69	35	C3	S79-198	20,66	16	C3	S95-252	25,00	16
C1	S31-65	30,32	16	C2	S143-260	19,54	16	C3	S67-154	37,21	16	C3	S79-204	26,58	16	C3	S95-S96	36,48	35
C1	S31-75	17,08	16	C2	S143-262	20,18	16	C3	S67-158	20,61	16	C3	S77-S80	29,52	70	C3	S96-253	17,14	16
C1	S27-S32	22,86	35	C2	S143-S144	22,17	35	C3	S67-170	30,00	16	C3	S80-199	15,99	16	C3	S96-255	12,12	16
C1	S32-86	20,21	16	C2	S144-263	22,21	16	C3	S67-S68	19,69	35	C3	S80-203	12,56	16	C3	S96-257	20,86	16
C1	S32-88	15,76	16	C2	S144-265	16,18	16	C3	S68-163	11,01	16	C3	S80-205	20,43	16	C3	S95-S97	27,93	35
C1	S32-91	13,18	16	C2	S144-S145	17,34	35	C3	S68-164	13,58	16	C3	S80-S81	33,30	35	C3	S97-258	22,77	16
C1	S32-98	16,42	16	C2	S145-264	16,28	16	C3	S68-172	24,21	16	C3	S81-S82	34,74	35	C4	TS-S98	24,09	70
C2	TS-S123	24,09	70	C2	S145-267	18,27	16	C3	S60-S69	30,51	70	C3	S82-197	24,96	16	C4	S98-147	22,31	16
C2	S123-S124	34,25	70	C2	S142-S146	36,13	35	C3	S69-155	13,22	16	C3	S82-210	24,05	16	C4	S98-148	21,83	16
C2	S124-S125	36,41	70	C2	S146-261	14,17	16	C3	S69-159	19,49	16	C3	S82-213	23,93	16	C4	S98-150	23,42	16
C2	S125-S126	26,73	70	C2	S146-S147	22,53	35	C3	S69-S70	25,10	35	C3	S80-S83	35,51	70	C4	S98-S99	34,25	70
C2	S126-S127	27,42	70	C2	S147-266	13,37	16	C3	S70-166	14,52	16	C3	S83-S84	34,51	70	C4	S99-153	28,89	16
C2	S127-S128	41,26	70	C2	S147-S148	27,41	35	C3	S70-176	16,07	16	C3	S84-S85	27,44	35	C4	S99-157	15,35	16
C2	S128-S129	31,25	70	C2	S148-268	7,77	16	C3	S69-S71	29,87	70	C3	S85-230	19,68	16	C4	S99-160	26,49	16
C2	S129-S130	30,98	70	C2	S148-269	16,84	16	C3	S71-165	15,32	16	C3	S85-232	9,79	16	C4	S99-S100	36,41	70
C2	S130-S131	32,32	70	C2	S148-S149	31,59	35	C3	S71-168	19,55	16	C3	S85-S86	31,59	35	C4	S100-174	30,56	16
C2	S131-S132	26,40	70	C2	S149-270	21,28	16	C3	S71-171	15,25	16	C3	S86-235	18,31	16	C4	S100-179	34,49	16
C2	S132-S133	39,75	70	C3	TS-S60	37,88	70	C3	S71-175	17,07	16	C3	S86-237	10,37	16	C4	S100-183	19,67	16
C2	S133-241	15,92	16	C3	S60-143	22,67	16	C3	S71-S72	21,66	70	C3	S86-238	29,62	16	C4	S100-S101	29,51	35
C2	S133-S134	35,02	70	C3	S60-S61	29,05	35	C3	S72-S73	21,76	35	C3	S84-S87	27,54	70	C4	S101-173	12,81	16
C2	S134-239	29,91	16	C3	S61-149	24,47	16	C3	S73-182	12,92	16	C3	S87-S88	28,05	35	C4	S101-177	12,08	16
C2	S134-S135	36,42	70	C3	S61-156	17,87	16	C3	S73-188	20,90	16	C3	S88-236	11,44	16	C4	S101-S102	32,67	35
C2	S135-245	35,99	16	C3	S61-162	25,08	16	C3	S72-S74	18,50	70	C3	S88-240	15,59	16	C4	S102-152	30,13	16

C4	S102-S103	26,59	35	C4	S111-224	22,73	16	C4	S121-S122	21,07	35	C5	S47-41	21,90	16	C5	S52-29	20,97	16
C4	S103-S104	29,79	35	C4	S111-226	16,63	16	C4	S122-215	19,32	16	C5	S47-46	19,51	16	C5	S52-S53	19,63	70
C4	S104-131	24,53	16	C4	S110-S112	41,65	35	C5	TS-S33	12,81	70	C5	S47-S48	27,93	35	C5	S53-S54	31,07	35
C4	S100-S105	26,73	70	C4	S112-S113	35,91	35	C5	S33-S34	24,81	70	C5	S48-47	29,02	16	C5	S54-9	29,60	16
C4	S105-192	15,06	16	C4	S113-184	14,72	16	C5	S34-S35	17,27	70	C5	S48-S49	30,11	35	C5	S54-14	18,77	16
C4	S105-195	23,89	16	C4	S113-185	24,06	16	C5	S35-S36	24,88	70	C5	S49-35	11,30	16	C5	S54-S55	29,16	35
C4	S105-S106	27,42	70	C4	S113-191	11,55	16	C5	S36-S37	48,01	70	C5	S49-37	18,59	16	C5	S55-19	32,84	16
C4	S106-S107	18,90	35	C4	S112-S114	41,33	35	C5	S37-S38	49,43	70	C5	S49-42	25,21	16	C5	S55-23	14,99	16
C4	S107-186	21,23	16	C4	S114-200	21,66	16	C5	S38-S39	22,18	70	C5	S49-43	21,81	16	C5	S55-28	24,27	16
C4	S107-194	15,56	16	C4	S114-206	33,64	16	C5	S39-S40	45,33	70	C5	S48-S50	17,40	35	C5	S55-32	20,28	16
C4	S107-202	23,56	16	C4	S114-S115	34,88	35	C5	S40-S41	42,69	70	C5	S50-27	13,96	16	C5	S55-40	42,00	16
C4	S106-S108	26,35	35	C4	S115-189	26,54	16	C5	S41-53	17,10	16	C5	S50-33	11,26	16	C5	S55-S56	38,37	35
C4	S108-201	17,86	16	C4	S115-196	15,07	16	C5	S41-56	24,38	16	C5	S50-S51	29,51	35	C5	S56-7	21,57	16
C4	S108-207	21,39	16	C4	S110-S116	31,25	70	C5	S41-58	21,19	16	C5	S51-15	17,16	16	C5	S56-12	20,25	16
C4	S108-208	11,51	16	C4	S116-S117	30,98	70	C5	S41-S42	26,42	70	C5	S51-20	8,18	16	C5	S56-16	12,97	16
C4	S108-211	14,06	16	C4	S117-218	20,23	16	C5	S42-S43	24,76	35	C5	S51-21	8,91	16	C5	S53-S57	33,12	35
C4	S108-212	11,92	16	C4	S117-225	18,75	16	C5	S43-48	18,53	16	C5	S51-22	10,84	16	C5	S57-6	15,82	16
C4	S108-S109	40,98	35	C4	S117-S118	32,32	35	C5	S43-51	17,86	16	C5	S50-30	17,27	16	C5	S57-11	27,51	16
C4	S109-209	17,68	16	C4	S118-231	23,50	16	C5	S43-59	23,66	16	C5	S51-25	15,32	16	C5	S57-13	12,70	16
C4	S109-216	25,87	16	C4	S118-S119	26,40	35	C5	S42-S44	28,57	70	C5	S46-31	24,52	16	C5	S53-S58	23,80	35
C4	S109-217	10,85	16	C4	S119-222	19,32	16	C5	S44-S45	42,71	35	C5	S46-34	18,94	16	C5	S58-4	31,89	16
C4	S109-221	20,59	16	C4	S119-233	15,90	16	C5	S45-44	28,34	16	C5	S46-36	16,70	16	C5	S58-5	17,37	16
C4	S109-228	31,60	16	C4	S119-S120	29,15	35	C5	S45-45	13,29	16	C5	S46-39	22,79	16	C5	S58-8	18,24	16
C4	S106-S110	41,26	70	C4	S120-223	14,42	16	C5	S45-49	19,99	16	C5	S46-S52	36,15	70	C5	S58-10	14,98	16
C4	S110-S111	29,99	35	C4	S120-229	12,72	16	C5	S45-50	5,40	16	C5	S52-17	14,67	16	C5	S58-S59	36,48	35
C4	S111-214	20,65	16	C4	S120-234	15,28	16	C5	S44-S46	24,34	70	C5	S52-18	29,88	16	C5	S59-1	16,86	16
C4	S111-219	13,15	16	C4	S120-S121	30,89	35	C5	S46-S47	31,25	35	C5	S52-24	19,17	16	C5	S59-2	17,55	16
C4	S111-220	23,83	16	C4	S121-227	9,93	16	C5	S47-38	19,21	16	C5	S52-26	13,78	16	C5	S59-3	18,46	16

Prilog 10. *Duljine i presjeci dionica distribucijske mreže sa 6 niskonaponskih izvoda*

Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)
C1	TS-S168	27,05	70	C1	S172-S173	37,93	70	C1	S177-S178	33,00	70	C1	S181-S182	22,14	70	C1	S184-251	13,79	16
C1	S168-S169	28,46	70	C1	S173-S174	30,40	70	C1	S178-S179	28,23	70	C1	S182-249	17,78	16	C1	S183-S185	23,95	70
C1	S169-S170	27,64	70	C1	S174-S175	31,75	70	C1	S179-S180	34,48	70	C1	S182-S183	28,44	70	C1	S185-S186	26,93	70
C1	S170-S171	24,04	70	C1	S175-S176	32,85	70	C1	S180-S181	35,07	70	C1	S183-S184	31,25	35	C1	S186-254	24,94	16
C1	S171-S172	25,09	70	C1	S176-S177	32,35	70	C1	S181-245	33,51	16	C1	S184-250	18,64	16	C1	S186-S187	30,32	70

C1	S187-256	24,24	16	C2	S4-S6	18,57	35	C2	S19-182	11,63	16	C2	S32-172	21,60	16	C3	S46-S47	20,92	35
C1	S187-259	18,04	16	C2	S6-129	9,90	16	C2	S19-188	15,51	16	C2	S32-178	12,74	16	C3	S47-92	16,65	16
C1	S187-S188	32,72	70	C2	S6-131	7,65	16	C2	S19-198	24,77	16	C2	S31-S33	26,24	35	C3	S47-93	17,11	16
C1	S188-S189	33,74	70	C2	S6-S7	26,77	35	C2	S17-S20	26,79	35	C2	S33-164	8,14	16	C3	S47-103	12,80	16
C1	S189-260	16,45	16	C2	S7-S8	30,01	35	C2	S20-159	8,89	16	C2	S33-S34	21,89	35	C3	S46-S48	30,46	70
C1	S189-261	12,32	16	C2	S8-152	17,33	16	C2	S20-161	27,51	16	C2	S34-163	10,22	16	C3	S48-96	18,74	16
C1	S189-S190	32,73	35	C2	TS-S9	28,34	70	C2	S20-165	9,34	16	C2	S34-S35	24,09	35	C3	S48-102	19,18	16
C1	S190-264	15,01	16	C2	S9-149	16,48	16	C2	S20-S21	29,63	35	C2	S35-158	12,53	16	C3	S48-S49	32,61	35
C1	S190-266	15,80	16	C2	S9-S10	30,53	35	C2	S21-171	13,07	16	C2	S35-170	13,04	16	C3	S49-117	12,65	16
C1	S190-S191	34,91	35	C2	S10-156	16,67	16	C2	S21-S22	26,20	35	C2	S35-S36	31,93	35	C3	S49-123	27,52	16
C1	S191-268	9,59	16	C2	S10-162	15,94	16	C2	S22-180	22,74	16	C2	S36-145	22,18	16	C3	S48-S50	30,61	35
C1	S191-269	14,31	16	C2	S10-166	11,95	16	C2	S22-181	10,02	16	C2	S36-154	26,75	16	C3	S50-109	16,43	16
C1	S189-S192	31,30	35	C2	S10-S11	18,78	35	C2	S21-S23	25,61	35	C2	S30-S37	32,70	35	C3	S50-115	15,82	16
C1	S192-262	27,62	16	C2	S11-169	7,60	16	C2	S23-187	15,04	16	C2	S37-140	21,49	16	C3	S50-S51	29,52	35
C1	S192-263	24,99	16	C2	S11-174	12,23	16	C2	S23-190	16,98	16	C2	S37-151	16,17	16	C3	S51-107	18,51	16
C1	S192-265	20,38	16	C2	S11-S12	20,87	35	C2	S23-193	13,47	16	C2	S31-S38	30,91	35	C3	S51-112	14,81	16
C1	S192-S193	35,39	35	C2	S12-179	7,13	16	C2	S9-S24	29,31	35	C2	S38-S39	27,21	35	C3	S51-S52	30,12	35
C1	S193-267	16,98	16	C2	S12-183	9,72	16	C2	S24-142	10,29	16	C2	S39-134	15,56	16	C3	S52-S53	32,11	35
C1	S193-270	25,63	16	C2	S12-S13	21,51	35	C2	S24-S25	29,62	35	C2	S39-144	11,48	16	C3	S53-127	20,23	16
C2	TS-S1	15,90	35	C2	S13-S14	30,09	35	C2	S25-133	13,70	16	C2	S39-146	14,48	16	C3	S53-138	19,82	16
C2	S1-141	12,58	16	C2	S14-195	29,38	16	C2	S25-139	15,82	16	C3	TS-S40	29,39	70	C3	S48-S54	22,37	70
C2	S1-147	20,79	16	C2	S14-204	33,94	16	C2	S24-S26	19,62	35	C3	S40-S41	32,14	70	C3	S48-S55	35,34	35
C2	S1-S2	32,08	35	C2	S14-209	24,04	16	C2	S26-126	18,52	16	C3	S41-S42	26,02	70	C3	S55-S56	23,29	35
C2	S2-148	24,52	16	C2	S11-S15	24,53	35	C2	S26-137	10,14	16	C3	S42-105	19,18	16	C3	S56-98	11,48	16
C2	S2-150	24,08	16	C2	S15-157	22,11	16	C2	S26-S27	23,90	35	C3	S42-106	14,22	16	C3	S56-S57	13,17	35
C2	S2-153	27,29	16	C2	S15-160	27,65	16	C2	S27-122	11,47	16	C3	S42-S43	23,68	70	C3	S57-86	12,86	16
C2	S1-S3	26,31	35	C2	S15-S16	31,64	35	C2	S27-125	11,54	16	C3	S43-111	19,13	16	C3	S57-88	8,28	16
C2	S3-132	15,69	16	C2	S16-173	14,96	16	C2	S27-130	16,27	16	C3	S43-114	13,87	16	C3	S57-91	10,44	16
C2	S3-135	10,43	16	C2	S16-177	23,78	16	C2	S27-S28	21,03	35	C3	S43-S44	31,03	35	C3	S55-S58	23,93	35
C2	S3-136	11,62	16	C2	S9-143	19,74	16	C2	S28-113	26,62	16	C3	S44-90	20,26	16	C3	S58-104	16,15	16
C2	S3-S4	25,03	35	C2	S9-S17	26,29	70	C2	S28-116	22,71	16	C3	S44-S45	26,79	35	C3	S58-S59	24,54	35
C2	S4-121	14,41	16	C2	S17-155	15,15	16	C2	S28-119	9,39	16	C3	S45-87	20,54	16	C3	S59-94	15,59	16
C2	S4-128	19,81	16	C2	S17-S18	23,98	35	C2	S17-S29	32,96	70	C3	S45-97	20,59	16	C3	S59-95	10,97	16
C2	S4-S5	18,65	35	C2	S18-168	12,78	16	C2	S29-S30	27,23	70	C3	S45-101	13,28	16	C3	S59-99	10,99	16
C2	S5-118	21,55	16	C2	S18-175	17,00	16	C2	S30-S31	32,77	70	C3	S43-S46	28,48	70	C3	S59-100	12,47	16
C2	S5-120	9,51	16	C2	S18-176	13,91	16	C2	S31-167	11,22	16	C3	S46-108	12,46	16	C3	S59-S60	20,59	35
C2	S5-124	13,49	16	C2	S18-S19	31,98	35	C2	S31-S32	29,52	35	C3	S46-110	17,29	16	C3	S60-83	16,59	16

C3	S60-85	12,72	16	C3	S73-S74	23,55	35	C4	S93-S94	24,73	70	C4	S106-20	15,28	16	C5	S120-S121	28,95	35
C3	S60-89	16,08	16	C3	S74-69	10,68	16	C4	S94-34	19,57	16	C4	S106-21	14,43	16	C5	S121-210	11,12	16
C3	S54-S61	24,73	70	C3	S74-71	11,26	16	C4	S94-36	16,93	16	C4	S106-22	14,15	16	C5	S121-213	15,04	16
C3	S61-S62	28,57	35	C3	S74-S75	18,25	35	C4	S94-38	14,59	16	C4	S106-25	8,39	16	C5	S120-S122	32,02	35
C3	S62-79	16,82	16	C3	S75-62	10,83	16	C4	S94-39	22,08	16	C4	S106-S107	21,20	35	C5	S122-197	22,33	16
C3	S62-80	15,87	16	C3	S75-63	12,31	16	C4	S94-41	16,53	16	C4	S107-11	21,98	16	C5	S119-S123	33,12	70
C3	S62-82	15,39	16	C3	S75-66	12,07	16	C4	S93-S95	31,97	35	C4	S107-13	12,41	16	C5	S123-S124	32,46	70
C3	S62-84	13,13	16	C3	S75-S76	21,10	35	C4	S95-S96	27,98	35	C4	S107-15	18,71	16	C5	S124-S125	30,29	70
C3	S61-S63	29,84	70	C3	S76-52	16,46	16	C4	S96-47	11,39	16	C4	S107-18	9,27	16	C5	S125-S126	35,36	35
C3	S63-75	20,31	16	C3	S76-54	16,24	16	C4	S96-S97	19,44	35	C4	S99-S108	21,00	70	C5	S126-S127	27,89	35
C3	S63-S64	27,85	35	C3	S76-55	19,03	16	C4	S97-33	16,61	16	C4	S108-17	12,72	16	C5	S127-S128	30,01	35
C3	S64-72	16,63	16	C4	TS-S77	29,39	70	C4	S97-37	11,99	16	C4	S108-14	18,49	16	C5	S128-216	12,38	16
C3	S64-73	12,69	16	C4	S77-S78	32,14	70	C4	S96-S98	35,51	35	C4	S108-S109	25,13	35	C5	S128-221	13,72	16
C3	S64-74	8,76	16	C4	S78-S79	26,02	70	C4	S98-35	15,71	16	C4	S109-9	13,20	16	C5	S124-S129	29,38	35
C3	S64-S65	10,69	35	C4	S79-S80	23,68	70	C4	S98-42	14,47	16	C4	S109-10	14,08	16	C5	S129-230	16,83	16
C3	S65-64	11,27	16	C4	S80-S81	28,48	70	C4	S98-43	13,26	16	C4	S109-14	14,77	16	C5	S129-232	8,72	16
C3	S65-68	21,24	16	C4	S81-S82	30,46	70	C4	S94-S99	30,19	70	C4	S109-S110	23,81	35	C5	S129-S130	30,09	35
C3	S65-S66	14,03	35	C4	S82-S83	22,37	70	C4	S99-26	11,47	16	C4	S110-4	15,39	16	C5	S130-235	16,48	16
C3	S66-57	13,92	16	C4	S83-S84	24,73	70	C4	S99-S100	29,85	35	C4	S110-6	20,55	16	C5	S130-237	10,00	16
C3	S66-61	14,25	16	C4	S84-S85	29,84	70	C4	S100-29	13,26	16	C4	S110-8	8,54	16	C5	S130-238	27,33	16
C3	S63-S67	23,73	35	C4	S85-S86	23,73	70	C4	S100-S101	19,17	35	C4	S109-S111	25,67	35	C5	S125-S131	18,34	70
C3	S67-60	19,07	16	C4	S86-S87	18,06	70	C4	S101-32	10,71	16	C4	S111-3	18,90	16	C5	S131-S132	24,82	35
C3	S67-65	13,51	16	C4	S87-S88	19,95	70	C4	S101-S102	24,92	35	C4	S111-5	16,33	16	C5	S132-236	12,70	16
C3	S67-S68	18,06	35	C4	S88-S89	27,26	35	C4	S102-19	31,68	16	C4	S111-S112	21,62	35	C5	S132-S133	22,08	35
C3	S68-53	12,29	16	C4	S89-56	14,11	16	C4	S102-23	11,79	16	C4	S112-1	17,01	16	C5	S133-240	11,99	16
C3	S68-58	18,14	16	C4	S89-59	17,75	16	C4	S102-28	22,89	16	C4	S112-2	19,67	16	C5	S133-242	17,38	16
C3	S54-S69	29,60	35	C4	S89-S90	27,76	35	C4	S102-S103	34,06	35	C5	TS-S113	28,34	70	C5	S133-243	10,76	16
C3	S69-S70	29,29	35	C4	S90-51	15,31	16	C4	S103-7	22,65	16	C5	S113-S114	26,29	70	C5	S133-244	12,08	16
C3	S70-S71	25,34	35	C4	S90-S91	22,73	35	C4	S103-12	20,10	16	C5	S114-S115	26,79	70	C5	S131-S134	29,04	70
C3	S71-81	18,42	16	C4	S91-45	14,91	16	C4	S103-16	11,58	16	C5	S115-S116	29,63	70	C5	S134-S135	31,02	70
C3	S71-S72	25,18	35	C4	S91-49	11,15	16	C4	S94-S104	23,87	35	C5	S116-S117	25,61	70	C5	S135-246	14,19	16
C3	S72-67	15,54	16	C4	S91-50	12,36	16	C4	S104-31	15,38	16	C5	S117-S118	29,65	70	C5	S135-S136	26,46	35
C3	S72-70	21,00	16	C4	S91-S92	21,47	35	C4	S104-46	24,30	16	C5	S118-S119	29,96	70	C5	S136-247	13,59	16
C3	S72-77	16,22	16	C4	S92-40	18,15	16	C4	S104-S105	25,84	35	C5	S119-199	17,94	16	C5	S136-248	10,94	16
C3	S71-S73	23,63	35	C4	S92-44	10,40	16	C4	S105-27	17,98	16	C5	S119-203	12,02	16	C5	S135-S137	25,84	35
C3	S73-76	13,54	16	C4	S88-S93	25,59	70	C4	S105-30	12,61	16	C5	S119-205	19,04	16	C5	S137-S138	29,06	35
C3	S73-78	16,37	16	C4	S93-48	19,41	16	C4	S105-S106	22,97	35	C5	S119-S120	29,56	35	C5	S138-S139	30,80	35

C5	S139-252	17,94	16	C6	S147-192	20,41	16	C6	S149-S152	30,40	70	C6	S156-S158	30,63	35	C6	S162-S163	18,59	35
C5	S139-S140	23,02	35	C6	S147-194	15,53	16	C6	S152-S153	24,45	35	C6	S158-185	13,25	16	C6	S163-223	14,50	16
C5	S140-253	15,80	16	C6	S146-S148	16,95	35	C6	S153-214	17,36	16	C6	S158-189	19,95	16	C6	S163-229	13,54	16
C5	S140-255	14,28	16	C6	S148-201	15,14	16	C6	S153-219	19,18	16	C6	S158-196	14,14	16	C6	S163-S164	29,34	35
C5	S140-257	15,65	16	C6	S148-207	14,73	16	C6	S153-220	16,83	16	C6	S156-S159	26,20	35	C6	S164-227	9,38	16
C5	S139-S141	25,16	35	C6	S146-S149	37,93	70	C6	S153-226	16,90	16	C6	S159-200	15,12	16	C6	S164-S165	23,02	35
C5	S141-258	13,28	16	C6	S149-208	14,20	16	C6	S152-S154	31,75	70	C6	S159-206	26,00	16	C6	S165-215	19,13	16
C6	TS-S142	27,05	70	C6	S149-S150	26,20	35	C6	S154-224	27,14	16	C6	S154-S160	32,85	70	C6	S162-S166	28,23	35
C6	S142-S143	28,46	70	C6	S150-211	20,85	16	C6	S154-225	20,59	16	C6	S160-218	22,27	16	C6	S166-234	15,94	16
C6	S143-S144	27,64	70	C6	S150-212	13,99	16	C6	S152-S155	35,56	35	C6	S160-231	23,29	16	C6	S166-241	15,63	16
C6	S144-S145	24,04	70	C6	S150-S151	30,52	35	C6	S155-S156	36,26	35	C6	S160-S161	32,35	70	C6	S166-S167	30,86	35
C6	S145-S146	25,09	70	C6	S151-217	17,13	16	C6	S156-S157	23,48	35	C6	S161-222	23,65	16	C6	S167-239	19,63	16
C6	S146-S147	32,88	35	C6	S151-228	18,84	16	C6	S157-184	14,54	16	C6	S161-233	21,77	16				
C6	S147-186	20,97	16	C6	S149-202	22,84	16	C6	S157-191	13,94	16	C6	S161-S162	33,00	35				

Prilog 11. *Duljine i presjeci dionica distribucijske mreže sa 7 niskonaponskih izvoda*

Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)
C1	TS-S26	34,94	70	C1	S35-107	17,10	16	C1	S41-S42	27,41	35	C1	S50-72	11,49	16	C1	S41-S57	30,10	70
C1	S26-S27	30,29	70	C1	S35-S36	21,27	35	C1	S42-84	19,53	16	C1	S48-S51	27,02	35	C1	S57-80	18,26	16
C1	S27-S28	23,73	70	C1	S36-99	10,17	16	C1	S42-93	12,60	16	C1	S51-78	13,95	16	C1	S57-S58	24,16	70
C1	S28-S29	30,77	70	C1	S36-100	14,38	16	C1	S42-S43	29,70	35	C1	S51-87	17,71	16	C1	S58-S59	20,31	35
C1	S29-103	15,66	16	C1	S36-S37	16,09	35	C1	S43-82	22,49	16	C1	S51-S52	24,25	35	C1	S59-64	13,57	16
C1	S29-S30	28,51	70	C1	S37-94	8,03	16	C1	S43-90	10,81	16	C1	S52-66	15,30	16	C1	S59-68	14,77	16
C1	S30-102	11,25	16	C1	S37-95	10,94	16	C1	S43-92	8,87	16	C1	S52-67	15,96	16	C1	S59-74	9,41	16
C1	S30-108	10,51	16	C1	S37-S38	12,73	35	C1	S43-S44	18,47	35	C1	S52-71	8,02	16	C1	S59-S60	22,62	35
C1	S30-110	15,42	16	C1	S38-83	14,20	16	C1	S44-S45	20,97	35	C1	S51-S53	19,66	35	C1	S60-57	16,46	16
C1	S30-S31	27,02	70	C1	S38-85	11,44	16	C1	S45-101	15,64	16	C1	S53-S54	22,88	35	C1	S60-61	16,45	16
C1	S31-96	16,11	16	C1	S38-89	16,31	16	C1	S41-S46	16,45	35	C1	S54-69	10,83	16	C1	S60-73	16,14	16
C1	S31-S32	32,58	35	C1	S32-S39	19,25	35	C1	S46-S47	23,93	35	C1	S54-76	14,59	16	C1	S58-S61	26,30	35
C1	S32-112	18,99	16	C1	S39-98	13,28	16	C1	S47-S48	21,29	35	C1	S54-S55	22,48	35	C1	S61-60	19,44	16
C1	S32-115	20,87	16	C1	S39-S40	22,33	35	C1	S48-81	11,90	16	C1	S55-62	11,78	16	C1	S61-65	12,32	16
C1	S32-S33	29,79	35	C1	S40-86	14,44	16	C1	S48-S49	17,57	35	C1	S55-63	12,34	16	C1	S61-S62	22,89	35
C1	S33-S34	26,87	35	C1	S40-88	9,20	16	C1	S49-77	9,45	16	C1	S55-S56	19,42	35	C1	S62-53	10,82	16
C1	S34-127	15,45	16	C1	S40-91	11,35	16	C1	S49-79	15,40	16	C1	S56-52	15,57	16	C1	S62-56	15,45	16
C1	S32-S35	24,35	35	C1	S31-109	20,96	16	C1	S49-S50	14,69	35	C1	S56-54	18,20	16	C1	S58-S63	25,80	35
C1	S35-104	17,81	16	C1	S31-S41	17,74	70	C1	S50-70	9,38	16	C1	S56-55	15,29	16	C1	S63-75	8,91	16

C1	S63-S64	26,39	35	C2	S84-32	15,87	16	C2	S95-S96	21,36	35	C3	S177-196	15,35	16	C4	S197-S198	23,32	70
C1	S64-58	17,03	16	C2	S84-S85	25,99	35	C2	S96-6	16,31	16	C3	S171-S178	24,86	70	C4	S198-S199	30,43	70
C1	S64-59	18,81	16	C2	S85-16	9,78	16	C2	S96-11	16,55	16	C3	S178-S179	26,92	70	C4	S199-S200	24,86	70
C2	TS-S65	34,94	70	C2	S85-19	28,94	16	C2	S94-S97	23,82	35	C3	S179-218	19,44	16	C4	S200-S201	26,92	70
C2	S65-S66	30,29	70	C2	S85-23	13,04	16	C2	S97-9	13,71	16	C3	S179-225	20,39	16	C4	S201-S202	28,44	70
C2	S66-S67	23,73	70	C2	S85-S86	21,64	35	C2	S97-10	14,06	16	C3	S179-S180	28,44	70	C4	S202-S203	27,87	70
C2	S67-S68	30,77	70	C2	S86-7	16,52	16	C2	S97-14	14,00	16	C3	S180-231	22,73	16	C4	S203-S204	18,17	70
C2	S68-S69	28,51	70	C2	S86-12	18,31	16	C2	S97-S98	21,23	35	C3	S180-S181	27,87	70	C4	S204-S205	27,64	70
C2	S69-S70	27,02	70	C2	S81-S87	31,37	35	C2	S98-4	15,19	16	C3	S181-222	18,32	16	C4	S205-S206	29,15	70
C2	S70-S71	17,74	70	C2	S87-30	13,18	16	C2	S98-5	13,59	16	C3	S181-233	16,79	16	C4	S206-S207	31,20	70
C2	S71-S72	30,10	70	C2	S87-31	19,75	16	C2	S98-8	9,82	16	C3	S181-S182	18,17	70	C4	S207-S208	33,95	70
C2	S72-S73	24,16	70	C2	S87-46	22,29	16	C2	S97-S99	25,41	35	C3	S182-S183	19,26	35	C4	S208-S209	31,46	70
C2	S73-S74	26,30	70	C2	S87-S88	24,21	35	C2	S99-3	19,55	16	C3	S183-223	12,55	16	C4	S209-S210	32,51	70
C2	S74-S75	22,89	70	C2	S88-33	11,94	16	C2	S99-S100	22,48	35	C3	S183-229	11,87	16	C4	S210-254	27,41	16
C2	S75-S76	23,02	70	C2	S88-S89	24,83	35	C2	S100-1	17,05	16	C3	S183-S184	23,12	35	C4	S210-S211	29,52	70
C2	S76-48	16,69	16	C2	S89-47	15,44	16	C2	S100-2	19,38	16	C3	S184-227	9,38	16	C4	S211-256	24,01	16
C2	S76-S77	23,41	70	C2	S89-S90	13,90	35	C3	TS-S163	17,68	70	C3	S184-S185	25,49	35	C4	S211-S212	28,27	70
C2	S77-S78	30,50	35	C2	S90-37	10,74	16	C3	S163-S164	18,23	70	C3	S185-215	18,46	16	C4	S212-259	14,46	16
C2	S78-50	17,44	16	C2	S90-43	8,82	16	C3	S164-S165	24,45	70	C3	S182-S186	27,64	70	C4	S212-S213	22,48	70
C2	S78-51	13,98	16	C2	S90-S91	15,44	35	C3	S165-S166	23,06	70	C3	S186-234	15,70	16	C4	S213-S214	21,44	35
C2	S78-S79	24,92	35	C2	S91-35	16,71	16	C3	S166-S167	22,02	70	C3	S186-241	16,45	16	C4	S214-261	11,66	16
C2	S79-45	15,32	16	C2	S91-42	17,05	16	C3	S167-S168	23,29	70	C3	S186-S187	29,15	70	C4	S213-S215	23,72	70
C2	S79-49	10,41	16	C2	S88-S92	24,93	35	C3	S168-S169	23,00	70	C3	S187-239	30,30	16	C4	S215-260	11,51	16
C2	S79-S80	23,30	35	C2	S92-22	12,01	16	C3	S169-S170	23,32	70	C3	S187-S188	31,20	35	C4	S215-S216	21,51	70
C2	S80-40	16,87	16	C2	S92-25	17,13	16	C3	S170-S171	30,43	70	C3	S188-S189	28,71	35	C4	S216-262	18,89	16
C2	S80-44	12,65	16	C2	S92-27	9,17	16	C3	S171-S172	31,25	35	C3	S189-245	17,92	16	C4	S216-263	15,28	16
C2	S77-38	20,12	16	C2	S92-S93	16,11	35	C3	S172-S173	29,34	35	C3	S188-S190	24,58	35	C4	S216-265	13,34	16
C2	S77-39	22,02	16	C2	S93-15	17,36	16	C3	S173-S174	28,67	35	C3	S190-249	11,90	16	C4	S216-S217	19,72	35
C2	S77-41	17,63	16	C2	S93-18	16,88	16	C3	S174-200	16,85	16	C3	S190-S191	24,04	35	C4	S217-264	16,59	16
C2	S77-S81	21,03	70	C2	S93-20	9,17	16	C3	S174-206	24,69	16	C3	S191-250	14,36	16	C4	S217-267	18,62	16
C2	S81-34	17,82	16	C2	S93-21	10,00	16	C3	S173-S175	25,41	35	C3	S191-251	12,32	16	C4	S217-S218	23,46	35
C2	S81-36	16,63	16	C2	S82-26	13,05	16	C3	S175-184	13,66	16	C4	TS-S192	28,09	70	C4	S218-266	13,18	16
C2	S81-S82	25,72	70	C2	S82-S94	19,90	70	C3	S173-S176	25,14	35	C4	S192-S193	30,52	70	C4	S218-S219	19,09	35
C2	S82-29	16,99	16	C2	S94-17	12,96	16	C3	S176-191	10,74	16	C4	S193-S194	28,92	70	C4	S219-270	12,12	16
C2	S82-S83	31,10	35	C2	S94-24	18,24	16	C3	S176-S177	19,22	35	C4	S194-S195	15,29	70	C4	S219-S220	23,62	35
C2	S83-S84	31,04	35	C2	S94-S95	22,42	35	C3	S177-185	13,62	16	C4	S195-S196	23,29	70	C4	S220-268	13,02	16
C2	S84-28	25,65	16	C2	S95-13	8,51	16	C3	S177-189	11,05	16	C4	S196-S197	23,00	70	C4	S220-269	14,10	16

C5	TS-S1	19,80	70	C5	S14-153	13,94	16	C6	S135-S136	28,92	70	C6	S151-214	11,79	16	C7	S108-170	13,96	16
C5	S1-132	11,32	16	C5	S14-157	10,57	16	C6	S136-183	11,25	16	C6	S151-220	9,95	16	C7	S104-S109	30,73	35
C5	S1-S2	23,47	70	C5	S14-160	9,93	16	C6	S136-S137	28,95	35	C6	S151-S152	32,27	35	C7	S109-144	17,34	16
C5	S2-141	18,94	16	C5	S1-S15	17,86	35	C6	S137-173	15,49	16	C6	S152-219	17,68	16	C7	S109-146	15,90	16
C5	S2-147	18,65	16	C5	S15-S16	32,64	35	C6	S137-177	16,14	16	C6	S152-224	9,45	16	C7	S109-S110	23,15	35
C5	S2-S3	18,23	70	C5	S16-137	10,11	16	C6	S137-S138	20,42	35	C6	S152-226	15,82	16	C7	S110-145	17,93	16
C5	S3-148	22,15	16	C5	S16-S17	27,35	35	C6	S138-186	19,87	16	C6	S146-S153	31,36	35	C7	S110-S111	24,79	35
C5	S3-150	21,37	16	C5	S17-133	15,22	16	C6	S138-192	13,90	16	C6	S153-S154	33,14	35	C7	S111-134	16,06	16
C5	S3-S4	26,83	35	C5	S17-142	15,58	16	C6	S136-S139	20,35	70	C6	S154-S155	31,44	35	C7	S111-138	16,33	16
C5	S4-124	14,85	16	C5	S17-S18	35,06	35	C6	S139-195	11,43	16	C6	S155-S156	29,54	35	C7	S102-S112	31,67	70
C5	S4-129	12,47	16	C5	S18-139	14,24	16	C6	S139-S140	24,33	35	C6	S156-246	17,90	16	C7	S112-159	13,15	16
C5	S4-135	11,42	16	C5	S18-140	25,32	16	C6	S140-179	20,51	16	C6	S156-248	25,45	16	C7	S112-161	10,99	16
C5	S4-136	14,65	16	C5	S18-S19	23,25	35	C6	S140-188	29,95	16	C6	S156-S157	31,38	35	C7	S112-165	11,17	16
C5	S4-S5	33,78	35	C5	S19-117	21,35	16	C6	S139-S141	24,27	70	C6	S157-S158	31,81	35	C7	S112-S113	29,00	35
C5	S5-S6	34,40	35	C5	S19-123	18,28	16	C6	S141-S142	25,68	35	C6	S158-252	15,98	16	C7	S113-175	17,88	16
C5	S6-152	25,94	16	C5	S1-S20	21,66	70	C6	S142-204	18,92	16	C6	S158-S159	24,92	35	C7	S113-182	17,99	16
C5	S4-S7	20,79	35	C5	S20-125	19,46	16	C6	S141-S143	26,48	70	C6	S159-253	12,27	16	C7	S112-S114	29,48	70
C5	S7-120	12,79	16	C5	S20-130	18,55	16	C6	S143-207	10,11	16	C6	S159-S160	20,71	35	C7	S114-171	12,68	16
C5	S7-121	14,71	16	C5	S20-S21	19,76	70	C6	S143-209	13,45	16	C6	S160-255	12,78	16	C7	S114-181	12,82	16
C5	S7-S8	14,38	35	C5	S21-113	21,56	16	C6	S143-S144	11,96	35	C6	S160-257	10,88	16	C7	S114-S115	30,72	35
C5	S8-128	10,60	16	C5	S21-118	19,80	16	C6	S144-211	11,81	16	C6	S158-S161	24,19	35	C7	S115-167	15,38	16
C5	S8-131	10,69	16	C5	S21-S22	24,01	35	C6	S144-217	11,45	16	C6	S161-S162	20,88	35	C7	S115-180	11,63	16
C5	S2-S9	28,57	35	C5	S22-105	29,35	16	C6	S143-S145	22,93	70	C6	S162-258	12,34	16	C7	S114-S116	23,28	70
C5	S9-143	10,94	16	C5	S22-106	16,31	16	C6	S145-216	21,58	16	C7	TS-S101	33,01	70	C7	S116-187	8,45	16
C5	S9-149	11,59	16	C5	S22-S23	29,81	35	C6	S145-221	15,37	16	C7	S101-S102	34,70	70	C7	S116-190	10,92	16
C5	S9-S10	30,37	35	C5	S23-97	24,52	16	C6	S145-S146	24,81	70	C7	S102-S103	29,40	35	C7	S116-S117	27,82	70
C5	S10-156	20,50	16	C5	S21-S24	33,04	35	C6	S146-228	16,76	16	C7	S103-S104	30,42	35	C7	S117-S118	29,41	35
C5	S10-S11	18,43	35	C5	S24-116	12,26	16	C6	S141-S147	21,61	35	C7	S104-151	10,67	16	C7	S118-193	15,32	16
C5	S11-162	12,92	16	C5	S24-119	14,57	16	C6	S147-S148	17,38	35	C7	S104-S105	26,94	35	C7	S118-S119	23,43	35
C5	S11-166	12,25	16	C5	S24-122	8,77	16	C6	S148-201	8,91	16	C7	S105-S106	25,61	35	C7	S119-198	10,72	16
C5	S11-169	13,44	16	C5	S24-S25	23,82	35	C6	S148-S149	31,69	35	C7	S106-163	11,90	16	C7	S117-S120	34,51	35
C5	S10-S12	24,31	35	C5	S25-111	23,15	16	C6	S149-194	16,50	16	C7	S106-164	13,37	16	C7	S120-178	20,53	16
C5	S12-155	24,62	16	C5	S25-114	22,15	16	C6	S149-202	18,06	16	C7	S106-172	24,66	16	C7	S120-S121	36,02	35
C5	S12-168	13,32	16	C5	S25-126	19,16	16	C6	S147-S150	25,11	35	C7	S106-S107	31,01	35	C7	S121-197	27,58	16
C5	S12-176	24,44	16	C6	TS-S134	28,09	70	C6	S150-208	11,13	16	C7	S107-154	26,17	16	C7	S121-S122	24,07	35
C5	S3-S13	24,45	35	C6	S134-S135	30,52	70	C6	S150-212	11,74	16	C7	S107-S108	16,05	35	C7	S122-S123	22,04	35
C5	S13-S14	16,35	35	C6	S135-174	11,59	16	C6	S150-S151	33,09	35	C7	S108-158	12,20	16	C7	S123-210	12,55	16

C7	S123-213	11,18	16	C7	S124-S125	31,73	35	C7	S127-S128	35,55	35	C7	S129-S130	30,75	35	C7	S131-S132	18,46	35
C7	S117-S124	24,95	70	C7	S125-S126	29,76	35	C7	S128-235	14,48	16	C7	S130-240	9,55	16	C7	S132-S133	22,94	35
C7	S124-199	17,98	16	C7	S126-S127	32,35	35	C7	S128-237	9,85	16	C7	S130-242	14,81	16	C7	S133-243	12,61	16
C7	S124-203	10,98	16	C7	S127-230	16,06	16	C7	S128-238	21,61	16	C7	S129-S131	27,34	35	C7	S133-244	14,34	16
C7	S124-205	18,03	16	C7	S127-232	8,97	16	C7	S126-S129	32,51	35	C7	S131-236	15,30	16	C7	S133-247	12,82	16

Prilog 12. *Duljine i presjeci dionica distribucijske mreže sa 8 niskonaponskih izvoda*

Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)	Izvod	Dionica	Duljina (m)	Presjek (mm^2)
C1	TS-S1	20,40	70	C1	S10-132	11,26	16	C1	S19-S20	22,75	35	C2	S33-94	13,53	16	C2	S45-72	11,73	16
C1	S1-147	19,65	16	C1	S10-S11	25,79	70	C1	S20-117	15,08	16	C2	S33-95	10,96	16	C2	S45-79	14,67	16
C1	S1-148	21,75	16	C1	S11-118	17,96	16	C2	TS-S21	27,61	70	C2	S33-99	12,58	16	C2	S43-S46	27,11	35
C1	S1-149	22,87	16	C1	S11-S12	18,43	35	C2	S21-S22	24,13	70	C2	S33-100	11,25	16	C2	S46-87	17,70	16
C1	S1-S2	16,46	70	C1	S12-106	15,81	16	C2	S22-S23	23,96	70	C2	S33-S34	20,02	35	C2	S46-S47	18,88	35
C1	S2-150	12,46	16	C1	S12-113	14,28	16	C2	S23-S24	15,94	70	C2	S34-83	15,92	16	C2	S47-76	14,46	16
C1	S2-153	16,64	16	C1	S12-S13	27,64	35	C2	S24-S25	21,53	70	C2	S34-85	10,49	16	C2	S47-78	15,94	16
C1	S2-157	13,82	16	C1	S13-97	18,97	16	C2	S25-S26	25,57	70	C2	S34-89	14,43	16	C2	S47-S48	24,71	35
C1	S2-S3	21,21	35	C1	S13-101	18,69	16	C2	S26-103	18,38	16	C2	S27-S35	25,69	70	C2	S48-69	10,40	16
C1	S3-156	14,92	16	C1	S12-S14	19,30	35	C2	S26-108	14,22	16	C2	S35-96	11,55	16	C2	S48-71	11,53	16
C1	S3-162	11,58	16	C1	S14-116	14,59	16	C2	S26-110	18,91	16	C2	S35-S36	29,74	35	C2	S48-S49	20,48	35
C1	S3-S4	21,67	35	C1	S14-119	17,62	16	C2	S26-S27	27,52	70	C2	S36-93	11,13	16	C2	S49-62	11,90	16
C1	S4-166	12,78	16	C1	S14-S15	21,53	35	C2	S27-102	14,51	16	C2	S36-S37	13,41	35	C2	S49-63	11,81	16
C1	S1-S5	19,65	70	C1	S15-105	18,55	16	C2	S27-109	22,34	16	C2	S37-82	17,78	16	C2	S49-66	13,05	16
C1	S5-141	12,83	16	C1	S15-111	17,76	16	C2	S27-S28	25,27	35	C2	S37-84	14,06	16	C2	S49-S50	21,65	35
C1	S5-S6	20,93	35	C1	S15-114	13,46	16	C2	S28-S29	27,23	35	C2	S36-S38	26,66	35	C2	S50-54	17,12	16
C1	S6-135	9,13	16	C1	S10-S16	28,18	35	C2	S29-112	9,89	16	C2	S38-90	12,59	16	C2	S50-55	15,67	16
C1	S6-136	8,13	16	C1	S16-122	14,36	16	C2	S29-115	9,39	16	C2	S38-92	8,12	16	C2	S50-67	15,46	16
C1	S6-S7	18,86	35	C1	S16-125	14,74	16	C2	S28-S30	19,97	35	C2	S35-S39	22,26	70	C2	S50-S51	21,88	35
C1	S7-124	12,12	16	C1	S16-130	14,61	16	C2	S30-98	14,90	16	C2	S39-S40	23,08	70	C2	S51-52	10,09	16
C1	S7-129	9,60	16	C1	S16-S17	32,10	35	C2	S30-S31	22,99	35	C2	S35-S41	29,74	35	C2	S51-S52	28,78	35
C1	S7-S8	15,95	35	C1	S17-126	19,91	16	C2	S31-86	14,57	16	C2	S41-S42	13,41	35	C2	S52-42	15,28	16
C1	S8-121	12,95	16	C1	S17-133	20,88	16	C2	S31-88	9,82	16	C2	S42-S43	22,64	35	C2	S52-43	15,72	16
C1	S8-128	11,18	16	C1	S17-S18	24,21	35	C2	S31-91	10,87	16	C2	S43-S44	16,11	35	C2	S40-S53	28,76	35
C1	S8-131	12,84	16	C1	S18-137	13,97	16	C2	S30-S32	24,29	35	C2	S44-77	10,91	16	C2	S53-73	14,19	16
C1	S7-S9	14,41	35	C1	S18-142	15,10	16	C2	S32-104	12,77	16	C2	S44-81	9,97	16	C2	S53-74	14,87	16
C1	S9-120	8,75	16	C1	S18-143	17,11	16	C2	S32-107	16,81	16	C2	S44-S45	14,86	35	C2	S53-80	13,44	16
C1	S5-S10	28,56	70	C1	S17-S19	21,53	35	C2	S32-S33	22,13	35	C2	S45-70	10,99	16	C2	S40-S54	29,52	35

C2	S54-64	21,01	16	C3	S189-S190	21,41	70	C4	S100-176	8,15	16	C4	S118-163	12,39	16	C5	S155-174	15,46	16
C2	S54-68	10,14	16	C3	S190-218	19,22	16	C4	S100-S101	21,98	35	C4	S118-164	13,64	16	C5	S155-179	7,77	16
C2	S54-S55	25,16	35	C3	S190-225	19,13	16	C4	S101-182	12,58	16	C4	S118-S119	20,33	35	C5	S155-S156	28,06	35
C2	S55-65	15,00	16	C3	S190-S191	24,45	70	C4	S101-S102	22,26	35	C4	S119-172	5,28	16	C5	S156-188	11,02	16
C2	S55-75	16,82	16	C3	S191-231	17,90	16	C4	S102-193	11,58	16	C4	S119-S120	30,76	35	C5	S154-S157	23,79	70
C2	S55-S56	25,00	35	C3	S191-S192	29,86	70	C4	S102-198	12,98	16	C4	S120-170	13,00	16	C5	S157-195	10,17	16
C2	S56-56	15,60	16	C3	S192-233	18,13	16	C4	S98-S103	27,69	35	C4	S120-S121	21,69	35	C5	S157-S158	30,03	35
C2	S56-58	12,56	16	C3	S192-222	17,89	16	C4	S103-159	9,68	16	C4	S121-197	18,17	16	C5	S158-192	9,29	16
C2	S56-59	16,63	16	C3	S192-S193	24,26	70	C4	S103-165	10,69	16	C4	S118-S122	31,60	35	C5	S158-S159	25,78	35
C2	S54-S57	22,67	35	C3	S193-S194	20,51	35	C4	S103-S104	19,36	35	C4	S122-154	26,23	16	C5	S159-177	15,04	16
C2	S57-53	10,65	16	C3	S194-223	12,37	16	C4	S104-161	10,16	16	C4	S122-158	12,70	16	C5	S159-S160	25,93	35
C2	S57-60	11,38	16	C3	S194-229	11,73	16	C4	S103-S105	21,50	35	C4	S116-S123	21,60	70	C5	S160-186	14,15	16
C2	S57-S58	25,74	35	C3	S194-S195	27,98	35	C4	S105-171	9,47	16	C4	S123-167	11,66	16	C5	S160-194	15,03	16
C2	S58-47	19,68	16	C3	S195-227	9,82	16	C4	S105-S106	19,02	35	C4	S123-S124	24,09	35	C5	S160-S161	32,31	35
C2	S57-S59	25,94	35	C3	S195-S196	21,63	35	C4	S106-181	10,96	16	C4	S124-178	13,10	16	C5	S161-184	23,56	16
C2	S59-57	14,93	16	C3	S196-215	19,57	16	C4	S97-S107	27,78	70	C4	S124-180	15,17	16	C5	S159-S162	21,05	35
C2	S59-61	8,14	16	C3	S193-S197	29,36	70	C4	S107-S108	26,16	70	C4	S124-S125	29,78	35	C5	S162-S163	22,39	35
C3	TS-S176	23,16	70	C3	S197-234	17,16	16	C4	S108-S109	24,59	70	C4	S125-199	13,38	16	C5	S163-152	16,07	16
C3	S176-S177	18,53	70	C3	S197-241	15,72	16	C4	S109-S110	23,51	35	C4	S125-S126	24,16	35	C5	S157-S164	26,63	70
C3	S177-S178	21,28	70	C3	S197-S198	29,47	35	C4	S110-151	11,86	16	C4	S126-203	11,72	16	C5	S164-201	9,01	16
C3	S178-S179	26,81	70	C3	S198-239	19,80	16	C4	S110-S111	23,31	35	C4	S126-205	18,33	16	C5	S164-S165	27,78	35
C3	S179-S180	26,58	70	C3	S197-S199	29,40	35	C4	S111-140	12,65	16	C4	S125-S127	29,09	35	C5	S165-207	11,66	16
C3	S180-S181	31,01	70	C3	S199-S200	29,30	35	C4	S111-146	14,25	16	C4	S127-S128	25,48	35	C5	S165-S166	22,30	35
C3	S181-S182	22,99	70	C3	S200-S201	29,20	35	C4	S111-S112	28,70	35	C4	S128-210	8,59	16	C5	S166-209	8,22	16
C3	S182-S183	30,55	70	C3	S201-245	17,75	16	C4	S112-123	14,93	16	C4	S128-213	11,16	16	C5	S166-S167	26,69	35
C3	S183-S184	29,35	35	C3	S200-S202	24,39	35	C4	S111-S113	24,76	35	C4	S124-S129	20,59	35	C5	S167-204	19,34	16
C3	S184-S185	29,50	35	C3	S202-249	13,48	16	C4	S113-134	12,97	16	C4	S129-187	15,59	16	C5	S167-216	17,94	16
C3	S185-S186	28,69	35	C3	S202-S203	25,05	35	C4	S113-144	9,23	16	C4	S129-190	11,91	16	C5	S164-S168	23,12	70
C3	S186-200	18,42	16	C3	S203-250	13,68	16	C4	S113-S114	21,85	35	C5	TS-S151	28,57	70	C5	S168-S169	28,66	35
C3	S186-206	24,08	16	C3	S203-251	11,65	16	C4	S114-127	21,42	16	C5	S151-S152	26,81	70	C5	S169-211	7,03	16
C3	S185-S187	30,89	35	C4	TS-S97	28,22	70	C4	S114-138	9,72	16	C5	S152-S153	25,54	35	C5	S169-212	11,06	16
C3	S187-191	11,43	16	C4	S97-S98	24,78	35	C4	S114-145	21,01	16	C5	S153-160	14,70	16	C5	S169-S170	31,51	35
C3	S187-196	17,25	16	C4	S98-155	13,11	16	C4	S108-S115	19,23	35	C5	S153-173	12,17	16	C5	S170-217	11,03	16
C3	S187-S188	18,55	35	C4	S98-S99	24,50	35	C4	S115-139	14,87	16	C5	S152-S154	28,32	70	C5	S170-221	20,58	16
C3	S188-185	13,90	16	C4	S99-168	12,59	16	C4	S109-S116	26,84	70	C5	S154-183	10,64	16	C5	S170-S171	23,27	35
C3	S188-189	10,95	16	C4	S99-S100	18,26	35	C4	S116-S117	30,15	35	C5	S154-S155	28,10	35	C5	S171-228	10,89	16
C3	S183-S189	28,70	70	C4	S100-175	8,85	16	C4	S117-S118	25,89	35	C5	S155-169	12,77	16	C5	S168-208	10,96	16

C5	S168-S172	17,77	35	C6	S144-248	14,30	16	C7	S224-259	18,90	16	C8	S73-48	12,46	16	C8	S85-S86	20,64	35
C5	S172-202	22,09	16	C6	S144-S145	30,31	35	C7	S224-S225	27,26	70	C8	S73-51	9,12	16	C8	S86-33	14,79	16
C5	S172-S173	21,43	35	C6	S145-246	14,47	16	C7	S225-S226	22,98	70	C8	S73-S74	27,84	35	C8	S86-37	9,40	16
C5	S173-214	13,82	16	C6	S144-S146	29,46	35	C7	S226-S227	19,17	35	C8	S74-45	14,22	16	C8	S86-S87	25,64	35
C5	S173-220	13,66	16	C6	S146-S147	27,56	35	C7	S227-260	15,62	16	C8	S74-49	11,76	16	C8	S87-35	13,05	16
C5	S173-S174	22,73	35	C6	S147-252	15,63	16	C7	S227-261	13,22	16	C8	S74-50	12,49	16	C8	S85-S88	20,49	35
C5	S174-S175	13,38	35	C6	S147-S148	29,97	35	C7	S227-S228	22,76	35	C8	S74-S75	22,64	35	C8	S88-20	12,60	16
C5	S175-219	13,46	16	C6	S148-S149	27,06	35	C7	S228-264	9,66	16	C8	S75-40	16,76	16	C8	S88-21	10,64	16
C5	S175-224	15,11	16	C6	S149-253	16,47	16	C7	S226-S229	23,35	70	C8	S75-44	10,95	16	C8	S88-22	9,08	16
C5	S175-226	15,05	16	C6	S149-255	14,87	16	C7	S229-S230	23,50	70	C8	S72-S76	21,33	70	C8	S88-25	14,32	16
C6	TS-S130	28,22	70	C6	S149-257	13,80	16	C7	S230-262	17,15	16	C8	S76-S77	22,23	70	C8	S88-27	12,09	16
C6	S130-S131	24,78	70	C6	S148-S150	23,15	35	C7	S230-263	12,12	16	C8	S77-34	18,62	16	C8	S88-S89	25,36	35
C6	S131-S132	24,50	70	C6	S150-258	11,63	16	C7	S230-S231	19,60	70	C8	S77-36	15,94	16	C8	S89-11	16,59	16
C6	S132-S133	18,26	70	C7	TS-S204	23,16	70	C7	S231-265	13,81	16	C8	S77-38	15,64	16	C8	S89-15	12,85	16
C6	S133-S134	21,98	70	C7	S204-S205	18,53	70	C7	S231-267	17,20	16	C8	S77-39	21,10	16	C8	S89-18	15,26	16
C6	S134-S135	22,26	70	C7	S205-S206	21,28	70	C7	S231-S232	28,18	35	C8	S77-41	17,42	16	C8	S78-S90	19,96	70
C6	S135-S136	25,17	70	C7	S206-S207	26,81	70	C7	S232-266	9,42	16	C8	S77-S78	31,01	70	C8	S90-17	12,91	16
C6	S136-S137	29,70	70	C7	S207-S208	26,58	70	C7	S232-S233	21,51	35	C8	S78-29	17,69	16	C8	S90-24	18,21	16
C6	S137-S138	32,08	70	C7	S208-S209	31,01	70	C7	S233-270	10,77	16	C8	S78-S79	29,42	35	C8	S90-S91	13,43	35
C6	S138-S139	31,19	35	C7	S209-S210	22,99	70	C7	S232-S234	21,70	35	C8	S79-S80	20,85	35	C8	S91-8	14,05	16
C6	S139-230	16,64	16	C7	S210-S211	30,55	70	C7	S234-268	8,31	16	C8	S80-32	9,18	16	C8	S91-10	13,06	16
C6	S139-S140	31,10	35	C7	S211-S212	28,70	70	C7	S234-269	10,06	16	C8	S80-S81	22,56	35	C8	S91-S92	21,18	35
C6	S140-235	15,17	16	C7	S212-S213	21,41	70	C8	TS-S60	27,61	70	C8	S81-23	11,82	16	C8	S92-6	15,92	16
C6	S140-237	11,08	16	C7	S213-S214	24,45	70	C8	S60-S61	24,13	70	C8	S81-28	21,42	16	C8	S92-13	13,63	16
C6	S140-238	26,43	16	C7	S214-S215	29,86	70	C8	S61-S62	23,96	70	C8	S81-S82	25,51	35	C8	S90-S93	24,71	35
C6	S138-S141	30,90	70	C7	S215-S216	24,26	70	C8	S62-S63	15,94	70	C8	S82-16	8,43	16	C8	S93-9	13,25	16
C6	S141-232	10,19	16	C7	S216-S217	29,36	70	C8	S63-S64	21,53	70	C8	S82-19	31,09	16	C8	S93-14	14,40	16
C6	S141-S142	28,88	70	C7	S217-S218	29,40	70	C8	S64-S65	25,69	70	C8	S82-S83	21,57	35	C8	S93-S94	20,46	35
C6	S142-236	15,80	16	C7	S218-S219	29,30	70	C8	S65-S66	27,52	70	C8	S83-7	12,33	16	C8	S94-4	15,27	16
C6	S142-240	9,69	16	C7	S219-S220	24,39	70	C8	S66-S67	25,69	70	C8	S83-12	13,71	16	C8	S94-5	12,08	16
C6	S142-S143	17,64	70	C7	S220-S221	28,54	70	C8	S67-S68	22,26	70	C8	S78-26	12,18	16	C8	S93-S95	23,87	35
C6	S143-242	17,83	16	C7	S221-S222	26,77	70	C8	S68-S69	23,08	70	C8	S77-S84	27,88	35	C8	S95-3	19,51	16
C6	S143-243	11,34	16	C7	S222-S223	24,35	70	C8	S69-S70	29,52	70	C8	S84-31	15,34	16	C8	S95-S96	23,65	35
C6	S143-244	9,35	16	C7	S223-254	25,97	16	C8	S70-S71	24,07	70	C8	S84-46	24,24	16	C8	S96-1	16,90	16
C6	S143-S144	30,05	70	C7	S223-S224	25,68	70	C8	S71-S72	23,51	70	C8	S84-S85	22,55	35	C8	S96-2	19,55	16
C6	S144-247	8,71	16	C7	S224-256	23,19	16	C8	S72-S73	28,38	35	C8	S85-30	12,50	16				

Prilog 13. *Godišnje vršno opterećenje potrošača – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	34	1	0.00092006	0.00021199	68	1	0.00147870	0.00034071	102	1	0.00170684	0.00039328	136	1	0.00130784	0.00030134
1	1	0.00640462	0.00147571	35	1	0.00217975	0.00050224	69	1	0.00122556	0.00028238	103	1	0.00190861	0.00043977	137	1	0.00206183	0.00047507
2	1	0.00054558	0.00012571	36	1	0.00127409	0.00029357	70	1	0.00271299	0.00062511	104	1	0.00267561	0.00061650	138	1	0.00212367	0.00048932
3	1	0.00193179	0.00044511	37	1	0.00058305	0.00013434	71	1	0.00245020	0.00056456	105	1	0.00128316	0.00029566	139	1	0.00101042	0.00023281
4	1	0.00275515	0.00063482	38	1	0.00012073	0.00002782	72	1	0.00012484	0.00002876	106	1	0.00000012	0.00000003	140	1	0.00045928	0.00010582
5	1	0.00105615	0.00024335	39	1	0.00134121	0.00030903	73	1	0.00217349	0.00050080	107	1	0.00341779	0.00078750	141	1	0.00029265	0.00006743
6	1	0.00276003	0.00063595	40	1	0.00096809	0.00022306	74	1	0.00076992	0.00017740	108	1	0.00001874	0.00000432	142	1	0.00108834	0.00025077
7	1	0.00138423	0.00031894	41	1	0.00205849	0.00047430	75	1	0.00028878	0.00006654	109	1	0.00145502	0.00033525	143	1	0.00076933	0.00017726
8	1	0.00157681	0.00036332	42	1	0.00152458	0.00035128	76	1	0.00043461	0.00010014	110	1	0.00212941	0.00049064	144	1	0.00187728	0.00043255
9	1	0.00283811	0.00065394	43	1	0.00098212	0.00022629	77	1	0.00129954	0.00029943	111	1	0.00123850	0.00028537	145	1	0.00274366	0.00063218
10	1	0.00006557	0.00001511	44	1	0.00241938	0.00055746	78	1	0.00109353	0.00025196	112	1	0.00273738	0.00063073	146	1	0.00238374	0.00054924
11	1	0.00142102	0.00032742	45	1	0.00148751	0.00034274	79	1	0.00228699	0.00052695	113	1	0.00011843	0.00002729	147	1	0.00501600	0.00115575
12	1	0.00162354	0.00037408	46	1	0.00175674	0.00040478	80	1	0.00328062	0.00075590	114	1	0.00196585	0.00045296	148	1	0.00178808	0.00041200
13	1	0.00011234	0.00002588	47	1	0.00185737	0.00042796	81	1	0.00068794	0.00015851	115	1	0.00000254	0.00000059	149	1	0.00150445	0.00034664
14	1	0.00564166	0.00129991	48	1	0.00124793	0.00028754	82	1	0.00081659	0.00018815	116	1	0.00064492	0.00014860	150	1	0.00113452	0.00026141
15	1	0.00026597	0.00006128	49	1	0.00125179	0.00028843	83	1	0.00106145	0.00024457	117	1	0.00100237	0.00023096	151	1	0.00076506	0.00017628
16	1	0.00217331	0.00050076	50	1	0.00001943	0.00000448	84	1	0.00185849	0.00042822	118	1	0.00179678	0.00041400	152	1	0.00182974	0.00042159
17	1	0.00188741	0.00043488	51	1	0.00038246	0.00008812	85	1	0.00137907	0.00031776	119	1	0.00078640	0.00018120	153	1	0.00053833	0.00012404
18	1	0.00284525	0.00065558	52	1	0.00548683	0.00126424	86	1	0.00000000	0.00000000	120	1	0.00158620	0.00036548	154	1	0.00104132	0.00023993
19	1	0.00016413	0.00003782	53	1	0.00070364	0.00016213	87	1	0.00370856	0.00085450	121	1	0.00210580	0.00048520	155	1	0.00003831	0.00000883
20	1	0.00000035	0.00000008	54	1	0.00163419	0.00037654	88	1	0.00096444	0.00022222	122	1	0.00154653	0.00035634	156	1	0.00000069	0.00000016
21	1	0.00081157	0.00018700	55	1	0.00246422	0.00056779	89	1	0.00139651	0.00032177	123	1	0.00027455	0.00006326	157	1	0.00267073	0.00061537
22	1	0.00000027	0.00000006	56	1	0.00061995	0.00014284	90	1	0.00104515	0.00024082	124	1	0.00197947	0.00045609	158	1	0.00248405	0.00057236
23	1	0.00219525	0.00050582	57	1	0.00000000	0.00000000	91	1	0.00224362	0.00051696	125	1	0.00080048	0.00018444	159	1	0.00065984	0.00015204
24	1	0.00382403	0.00088111	58	1	0.00131755	0.00030358	92	1	0.00173426	0.00039960	126	1	0.00114584	0.00026402	160	1	0.00002593	0.00000597
25	1	0.00488884	0.00112645	59	1	0.00194901	0.00044908	93	1	0.00191549	0.00044135	127	1	0.00138005	0.00031798	161	1	0.00232682	0.00053613
26	1	0.00118668	0.00027343	60	1	0.00223346	0.00051462	94	1	0.00134430	0.00030975	128	1	0.00378814	0.00087284	162	1	0.00099046	0.00022821
27	1	0.00251130	0.00057864	61	1	0.00175496	0.00040437	95	1	0.00181311	0.00041776	129	1	0.00115230	0.00026551	163	1	0.00164862	0.00037986
28	1	0.00000009	0.00000002	62	1	0.00054569	0.00012573	96	1	0.00082900	0.00019101	130	1	0.00078060	0.00017986	164	1	0.00047479	0.00010940
29	1	0.00108599	0.00025023	63	1	0.00002292	0.00000528	97	1	0.00011106	0.00002559	131	1	0.00283147	0.00065241	165	1	0.00037145	0.00008559
30	1	0.00150685	0.00034720	64	1	0.00125579	0.00028935	98	1	0.00112302	0.00025876	132	1	0.00000000	0.00000000	166	1	0.00140683	0.00032415
31	1	0.00000000	0.00000000	65	1	0.00015239	0.00003511	99	1	0.00240121	0.00055327	133	1	0.00125425	0.00028900	167	1	0.00092126	0.00021227
32	1	0.00315694	0.00072740	66	1	0.00328385	0.00075664	100	1	0.00174373	0.00040178	134	1	0.00013258	0.00003055	168	1	0.00000089	0.00000020
33	1	0.00121719	0.00028046	67	1	0.00238235	0.00054892	101	1	0.00113624	0.00026180	135	1	0.00105924	0.00024406	169	1	0.00162172	0.00037367

170	1	0.00034661	0.00007986	191	1	0.00042008	0.00009679	212	1	0.00115930	0.00026712	233	1	0.00058462	0.00013470	254	1	0.00124954	0.00028791
171	1	0.00163017	0.00037561	192	1	0.00145451	0.00033514	213	1	0.00049423	0.00011388	234	1	0.00222319	0.00051225	255	1	0.00179995	0.00041473
172	1	0.00042456	0.00009783	193	1	0.00202990	0.00046771	214	1	0.00086044	0.00019826	235	1	0.00183758	0.00042340	256	1	0.00036752	0.00008468
173	1	0.00213441	0.00049180	194	1	0.00099425	0.00022909	215	1	0.00058717	0.00013529	236	1	0.00149529	0.00034453	257	1	0.00135339	0.00031184
174	1	0.00056507	0.00013020	195	1	0.00253463	0.00058401	216	1	0.00163566	0.00037688	237	1	0.00133204	0.00030692	258	1	0.00054222	0.00012493
175	1	0.00208804	0.00048111	196	1	0.00191323	0.00044083	217	1	0.00065071	0.00014993	238	1	0.00199516	0.00045971	259	1	0.00033890	0.00007809
176	1	0.00095123	0.00021917	197	1	0.00075196	0.00017326	218	1	0.00002946	0.00000679	239	1	0.00006082	0.00001401	260	1	0.00094045	0.00021669
177	1	0.00106692	0.00024583	198	1	0.00000272	0.00000063	219	1	0.00259978	0.00059902	240	1	0.00103846	0.00023927	261	1	0.00106898	0.00024631
178	1	0.00000689	0.00000159	199	1	0.00124155	0.00028607	220	1	0.00072366	0.00016674	241	1	0.00136354	0.00031418	262	1	0.00046608	0.00010739
179	1	0.00084924	0.00019568	200	1	0.00237135	0.00054639	221	1	0.00111116	0.00025603	242	1	0.00223735	0.00051552	263	1	0.00096398	0.00022211
180	1	0.00171946	0.00039619	201	1	0.00117106	0.00026983	222	1	0.00069304	0.00015969	243	1	0.00112516	0.00025925	264	1	0.00021086	0.00004859
181	1	0.00122604	0.00028250	202	1	0.00031815	0.00007331	223	1	0.00102279	0.00023567	244	1	0.00054721	0.00012608	265	1	0.00003597	0.00000829
182	1	0.00112105	0.00025831	203	1	0.00109470	0.00025223	224	1	0.00080160	0.00018470	245	1	0.00060921	0.00014037	266	1	0.00189306	0.00043619
183	1	0.00197243	0.00045447	204	1	0.00159256	0.00036695	225	1	0.00224054	0.00051625	246	1	0.00308872	0.00071168	267	1	0.00119693	0.00027579
184	1	0.00015654	0.00003607	205	1	0.00149298	0.00034400	226	1	0.00136587	0.00031471	247	1	0.00150678	0.00034718	268	1	0.00152865	0.00035222
185	1	0.00111445	0.00025678	206	1	0.00265478	0.00061170	227	1	0.00001924	0.00000443	248	1	0.00057686	0.00013291	269	1	0.00232926	0.00053669
186	1	0.00120997	0.00027879	207	1	0.00021446	0.00004941	228	1	0.00181034	0.00041713	249	1	0.00077220	0.00017793	270	1	0.00048099	0.00011083
187	1	0.00030054	0.00006925	208	1	0.00138747	0.00031969	229	1	0.00153989	0.00035481	250	1	0.00159670	0.00036790				
188	1	0.00354249	0.00081624	209	1	0.00117713	0.00027123	230	1	0.00026341	0.00006069	251	1	0.00100805	0.00023227				
189	1	0.00175337	0.00040400	210	1	0.00080019	0.00018437	231	1	0.00291098	0.00067073	252	1	0.00002634	0.00000607				
190	1	0.00061885	0.00014259	211	1	0.00101687	0.00023430	232	1	0.00000000	0.00000000	253	1	0.00095693	0.00022049				

Prilog 14. *Dionice distribucijske mreže sa 5 niskonaponskih izvoda – podaci za Matpower*

From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)
999	1000	0.035640	0.006006	1002	120	0.216510	0.009861	1006	133	0.159843	0.007280	1009	115	0.203037	0.009248	1013	103	0.182582	0.008316
1000	137	0.457016	0.020816	1000	1003	0.069008	0.011630	1006	139	0.367942	0.016759	1009	1010	0.172719	0.017314	1013	105	0.297351	0.013544
1000	1001	0.108100	0.010836	1003	130	0.138535	0.006310	1006	1007	0.161926	0.016232	1010	127	0.353064	0.016082	1013	1014	0.137476	0.023170
1001	132	0.135512	0.006172	1003	125	0.171512	0.007812	1007	108	0.206683	0.009414	1010	134	0.471871	0.021493	1014	96	0.222383	0.010129
1001	136	0.100483	0.004577	1003	1004	0.048045	0.008097	1007	110	0.175803	0.008007	1004	1011	0.069207	0.011664	1014	102	0.231691	0.010553
1001	135	0.129301	0.005889	1004	1005	0.204064	0.020456	1007	111	0.147021	0.006696	1011	1012	0.147787	0.014815	1014	1015	0.061687	0.010396
1001	141	0.182868	0.008329	1005	114	0.180567	0.008224	1007	117	0.187988	0.008562	1012	97	0.296543	0.013507	1015	1016	0.085743	0.014451
1001	1002	0.140823	0.014117	1005	116	0.160449	0.007308	1006	1008	0.161762	0.016216	1012	101	0.415101	0.018907	1016	93	0.115947	0.005281
1002	129	0.145425	0.006624	1005	119	0.286122	0.013032	1008	123	0.190512	0.008677	1012	113	0.249551	0.011366	1016	1017	0.076409	0.012878
1002	124	0.166406	0.007579	1005	122	0.227187	0.010348	1008	1009	0.118067	0.011835	1012	118	0.349916	0.015938	1017	90	0.112722	0.005134
1002	128	0.271131	0.012349	1005	126	0.218804	0.009966	1009	109	0.346370	0.015777	1011	106	0.195055	0.008884	1017	92	0.106279	0.004841
1002	121	0.223453	0.010178	1005	1006	0.165074	0.016548	1009	112	0.375319	0.017095	1011	1013	0.133540	0.022506	1017	1018	0.130615	0.022013

1018	87	0.162083	0.007382	1027	107	0.215160	0.009800	1136	250	0.198965	0.009062	1061	1062	0.187213	0.018767	1074	1075	0.103760	0.010401
1016	1019	0.114897	0.011518	1027	1028	0.132375	0.013270	1136	251	0.263701	0.012011	1062	151	0.216979	0.009883	1075	161	0.250862	0.011426
1019	79	0.211975	0.009655	1028	94	0.205679	0.009368	1134	1137	0.102429	0.017263	1062	1063	0.067573	0.006774	1075	167	0.233934	0.010655
1019	80	0.208778	0.009509	1028	95	0.145402	0.006623	1137	1138	0.113335	0.019101	1063	140	0.325573	0.014829	1073	181	0.143289	0.006526
1019	82	0.175739	0.008004	1028	99	0.122589	0.005583	1138	254	0.239044	0.010888	1063	1064	0.174810	0.017524	1073	187	0.196339	0.008943
1019	84	0.153358	0.006985	1028	100	0.156497	0.007128	1138	1139	0.107845	0.018176	1064	146	0.212506	0.009679	1073	190	0.223443	0.010177
1019	1020	0.132629	0.013295	1028	1029	0.131813	0.013213	1139	256	0.371302	0.016912	1064	1065	0.147667	0.014803	1073	193	0.151316	0.006892
1020	73	0.099324	0.004524	1029	83	0.156399	0.007123	1139	1140	0.093640	0.015782	1065	138	0.267502	0.012184	1073	1076	0.082790	0.013953
1020	74	0.114515	0.005216	1029	85	0.164148	0.007476	1140	259	0.143119	0.006519	1065	144	0.176606	0.008044	1076	1077	0.177146	0.017758
1020	1021	0.065959	0.006612	1029	89	0.226504	0.010317	1140	1141	0.071814	0.012103	1065	145	0.167179	0.007615	1077	1078	0.187368	0.018783
1021	60	0.298932	0.013616	1029	1030	0.197975	0.019846	1141	1142	0.163980	0.016438	1065	1066	0.165087	0.016549	1078	198	0.246571	0.011231
1021	61	0.191827	0.008737	1030	65	0.361899	0.016484	1142	260	0.233293	0.010626	1066	154	0.444230	0.020234	1078	204	0.317344	0.014454
1021	64	0.205199	0.009346	1030	75	0.203871	0.009286	1142	262	0.240842	0.010970	1066	158	0.245991	0.011204	1076	1079	0.082101	0.013837
1021	68	0.303795	0.013837	1026	1031	0.115443	0.011572	1142	1143	0.111983	0.011226	1066	170	0.358157	0.016313	1079	199	0.190934	0.008697
1017	1022	0.133742	0.013407	1031	86	0.241246	0.010988	1143	263	0.265099	0.012075	1066	1067	0.099416	0.009966	1079	203	0.149936	0.006829
1022	70	0.289955	0.013207	1031	88	0.188191	0.008572	1143	265	0.193185	0.008799	1067	163	0.131456	0.005987	1079	205	0.243825	0.011106
1022	72	0.288475	0.013139	1031	91	0.157278	0.007164	1143	1144	0.087581	0.008779	1067	164	0.162087	0.007383	1079	1080	0.168141	0.016855
1022	77	0.127225	0.005795	1031	98	0.195957	0.008925	1144	264	0.194322	0.008851	1067	172	0.288954	0.013161	1080	1081	0.175417	0.017585
1022	81	0.116851	0.005322	999	1122	0.066989	0.011290	1144	267	0.218105	0.009934	1059	1068	0.084861	0.014302	1081	197	0.297921	0.013570
1018	1023	0.117443	0.011773	1122	1123	0.095268	0.016056	1141	1145	0.182480	0.018293	1068	155	0.157763	0.007186	1081	210	0.287041	0.013074
1023	69	0.172776	0.007869	1123	1124	0.101269	0.017067	1145	261	0.169143	0.007704	1068	159	0.232628	0.010596	1081	213	0.285689	0.013013
1023	71	0.175059	0.007973	1124	1125	0.074332	0.012527	1145	1146	0.113776	0.011405	1068	1069	0.126764	0.012707	1079	1082	0.098772	0.016647
1023	76	0.107447	0.004894	1125	1126	0.076251	0.012851	1146	266	0.159641	0.007271	1069	166	0.173328	0.007895	1082	1083	0.095985	0.016177
1023	78	0.150561	0.006858	1126	1127	0.114756	0.019341	1146	1147	0.138404	0.013874	1069	176	0.191848	0.008738	1083	1084	0.138561	0.013890
1023	1024	0.089907	0.009013	1127	1128	0.086910	0.014647	1147	268	0.092768	0.004225	1068	1070	0.083084	0.014003	1084	230	0.234961	0.010702
1024	62	0.153139	0.006975	1128	1129	0.086175	0.014524	1147	269	0.201043	0.009157	1070	165	0.182901	0.008331	1084	232	0.116893	0.005324
1024	63	0.198665	0.009049	1129	1130	0.089881	0.015148	1147	1148	0.159553	0.015994	1070	168	0.233434	0.010632	1084	1085	0.159541	0.015993
1024	66	0.145404	0.006623	1130	1131	0.073423	0.012374	1148	270	0.254030	0.011571	1070	171	0.182036	0.008291	1085	235	0.218523	0.009953
1021	1025	0.198272	0.019876	1131	1132	0.110546	0.018631	999	1059	0.105358	0.017757	1070	175	0.203787	0.009282	1085	237	0.123772	0.005637
1025	52	0.397968	0.018127	1132	241	0.190060	0.008657	1059	143	0.270618	0.012326	1070	1071	0.060247	0.010154	1085	238	0.353642	0.016108
1025	54	0.221922	0.010108	1132	1133	0.097400	0.016415	1059	1060	0.146699	0.014706	1071	1072	0.109894	0.011016	1083	1086	0.076589	0.012908
1025	55	0.216570	0.009864	1133	239	0.357086	0.016265	1060	149	0.292153	0.013307	1072	182	0.154179	0.007022	1086	1087	0.141655	0.014200
1025	57	0.299860	0.013658	1133	1134	0.101282	0.017070	1060	156	0.213332	0.009717	1072	188	0.249454	0.011362	1087	236	0.136611	0.006222
1025	67	0.158834	0.007234	1134	245	0.429590	0.019567	1060	162	0.299381	0.013636	1071	1073	0.051460	0.008673	1087	240	0.186059	0.008474
1015	1026	0.151309	0.015168	1134	1135	0.133634	0.013396	1060	169	0.313291	0.014270	1073	1074	0.144602	0.014496	1087	242	0.368528	0.016786
1026	1027	0.119157	0.011945	1135	249	0.150178	0.006840	1059	1061	0.185904	0.018636	1074	178	0.385449	0.017557	1086	1088	0.095885	0.016160
1027	104	0.233040	0.010614	1135	1136	0.138147	0.013848	1061	142	0.290925	0.013251	1074	180	0.133054	0.006060	1088	1089	0.173738	0.017416

1089	243	0.191165	0.008707	1102	1103	0.150455	0.015082	1113	200	0.258537	0.011776	1041	1042	0.125019	0.012532	1045	39	0.272084	0.012393
1089	244	0.338585	0.015422	1103	131	0.292769	0.013335	1113	206	0.401603	0.018292	1042	48	0.221254	0.010078	1045	1051	0.100554	0.016947
1089	247	0.258649	0.011781	1099	1104	0.074332	0.012527	1113	1114	0.176146	0.017658	1042	51	0.213171	0.009709	1051	17	0.175083	0.007975
1088	1090	0.068300	0.011511	1104	192	0.179729	0.008186	1114	189	0.316771	0.014428	1042	59	0.282499	0.012867	1051	18	0.356703	0.016247
1090	1091	0.153506	0.015388	1104	195	0.285227	0.012992	1114	196	0.179925	0.008195	1041	1043	0.079450	0.013390	1051	24	0.228838	0.010423
1091	246	0.237196	0.010804	1104	1105	0.076251	0.012851	1109	1115	0.086910	0.014647	1043	1044	0.215688	0.021622	1051	26	0.164458	0.007491
1091	248	0.287166	0.013080	1105	1106	0.095469	0.009570	1115	1116	0.086175	0.014524	1044	44	0.338264	0.015407	1051	29	0.250285	0.011400
1090	1092	0.172225	0.017265	1106	186	0.253452	0.011544	1116	218	0.241487	0.010999	1044	45	0.158681	0.007227	1051	1052	0.054597	0.009201
1092	1093	0.214266	0.021479	1106	194	0.185782	0.008462	1116	225	0.223770	0.010192	1044	49	0.238689	0.010872	1052	1053	0.156899	0.015728
1093	1094	0.172540	0.017296	1106	202	0.281288	0.012812	1116	1117	0.163200	0.016360	1044	50	0.064420	0.002934	1053	9	0.353371	0.016095
1094	252	0.298427	0.013593	1105	1107	0.133084	0.013341	1117	231	0.280565	0.012779	1043	46	0.286581	0.013053	1053	14	0.224021	0.010204
1094	1095	0.184232	0.018468	1107	201	0.213151	0.009708	1117	1118	0.133316	0.013364	1043	1045	0.067703	0.011410	1053	1054	0.147278	0.014764
1095	253	0.204556	0.009317	1107	207	0.255367	0.011631	1118	222	0.230636	0.010505	1045	1046	0.157826	0.015821	1054	19	0.159407	0.007260
1095	255	0.144657	0.006589	1107	208	0.137451	0.006260	1118	233	0.189826	0.008646	1046	38	0.229338	0.010446	1054	23	0.178957	0.008151
1095	257	0.248998	0.011341	1107	211	0.167805	0.007643	1118	1119	0.147195	0.014756	1046	41	0.261449	0.011908	1054	28	0.289698	0.013195
1094	1096	0.141070	0.014141	1107	212	0.142312	0.006482	1119	223	0.172098	0.007839	1046	1047	0.141025	0.014137	1054	32	0.242049	0.011025
1096	258	0.271797	0.012380	1107	1108	0.206942	0.020745	1119	229	0.151878	0.006918	1047	47	0.346416	0.015779	1054	40	0.501360	0.022836
999	1097	0.066989	0.011290	1108	209	0.211020	0.009611	1119	234	0.182394	0.008308	1047	1048	0.152035	0.015241	1054	1055	0.193751	0.019423
1097	147	0.266336	0.012131	1108	216	0.308830	0.014067	1119	1120	0.155995	0.015638	1048	35	0.134847	0.006142	1055	7	0.257482	0.011728
1097	148	0.260648	0.011872	1108	217	0.129478	0.005897	1120	227	0.118551	0.005399	1048	37	0.221946	0.010109	1055	12	0.241718	0.011010
1097	150	0.279618	0.012736	1108	221	0.245834	0.011197	1120	1121	0.106392	0.010665	1048	42	0.300924	0.013707	1055	16	0.154773	0.007049
1097	1098	0.095268	0.016056	1108	228	0.377258	0.017184	1121	215	0.230677	0.010507	1048	43	0.260378	0.011860	1052	1056	0.167276	0.016769
1098	153	0.344837	0.015707	1105	1109	0.114756	0.019341	999	1032	0.035640	0.006006	1047	1049	0.087873	0.008809	1056	6	0.188906	0.008604
1098	157	0.183266	0.008347	1109	1110	0.151441	0.015181	1032	1033	0.069008	0.011630	1049	27	0.166676	0.007592	1056	11	0.328392	0.014958
1098	160	0.316168	0.014401	1110	214	0.246538	0.011229	1033	1034	0.048045	0.008097	1049	33	0.134404	0.006122	1056	13	0.151636	0.006906
1098	1099	0.101269	0.017067	1110	219	0.156949	0.007149	1034	1035	0.069207	0.011664	1049	1050	0.149004	0.014937	1052	1057	0.120212	0.012050
1099	174	0.364807	0.016616	1110	220	0.284469	0.012957	1035	1036	0.133540	0.022506	1050	15	0.204854	0.009331	1057	4	0.380627	0.017337
1099	179	0.411763	0.018755	1110	224	0.271302	0.012357	1036	1037	0.137476	0.023170	1050	20	0.097639	0.004447	1057	5	0.207410	0.009447
1099	183	0.234833	0.010696	1110	226	0.198488	0.009041	1037	1038	0.061687	0.010396	1050	21	0.106360	0.004844	1057	8	0.217737	0.009917
1099	1100	0.149039	0.014940	1109	1111	0.210329	0.021085	1038	1039	0.126084	0.021250	1050	22	0.129384	0.005893	1057	10	0.178832	0.008145
1100	173	0.152912	0.006965	1111	1112	0.181329	0.018177	1039	1040	0.118720	0.020009	1049	30	0.206182	0.009391	1057	1058	0.184219	0.018467
1100	177	0.144179	0.006567	1112	184	0.175706	0.008003	1040	53	0.204143	0.009298	1050	25	0.182872	0.008329	1058	1	0.287068	0.013075
1100	1101	0.164990	0.016539	1112	185	0.287188	0.013081	1040	56	0.291008	0.013255	1045	31	0.292760	0.013335	1058	2	0.209450	0.009540
1101	152	0.359655	0.016382	1112	191	0.137892	0.006280	1040	58	0.252958	0.011522	1045	34	0.226139	0.010300	1058	3	0.220379	0.010038
1101	1102	0.134285	0.013461	1111	1113	0.208723	0.020923	1040	1041	0.073480	0.012384	1045	36	0.199383	0.009081				

Prilog 15. *Dionice distribucijske mreže sa 6 niskonaponskih izvoda – podaci za Matpower*

From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)
999	1000	0.080319	0.008051	1011	179	0.085067	0.003874	1022	187	0.179581	0.008179	1035	145	0.264796	0.012061	1047	1048	0.164686	0.016509
1000	141	0.150124	0.006838	1011	183	0.115995	0.005283	1022	190	0.202684	0.009232	1035	154	0.319342	0.014545	1048	117	0.151029	0.006879
1000	147	0.248202	0.011305	1011	1012	0.108639	0.010890	1022	193	0.160761	0.007322	1029	1036	0.165132	0.016554	1048	123	0.328475	0.014961
1000	1001	0.162004	0.016240	1012	1013	0.151929	0.015230	1008	1023	0.148008	0.014837	1036	140	0.256553	0.011685	1047	1049	0.154555	0.015493
1001	148	0.292660	0.013330	1013	195	0.350714	0.015974	1023	142	0.122861	0.005596	1036	151	0.193084	0.008794	1049	109	0.196084	0.008931
1001	150	0.287409	0.013091	1013	204	0.405113	0.018452	1023	1024	0.149572	0.014994	1030	1037	0.156120	0.015650	1049	115	0.188793	0.008599
1001	153	0.325737	0.014837	1013	209	0.286987	0.013072	1024	133	0.163490	0.007446	1037	1038	0.137397	0.013773	1049	1050	0.149079	0.014944
1000	1002	0.132861	0.013319	1010	1014	0.123867	0.012417	1024	139	0.188864	0.008602	1038	134	0.185751	0.008460	1050	107	0.220976	0.010065
1002	132	0.187239	0.008528	1014	157	0.263909	0.012021	1023	1025	0.099102	0.009934	1038	144	0.137060	0.006243	1050	112	0.176823	0.008054
1002	135	0.124518	0.005671	1014	160	0.330082	0.015035	1025	126	0.221119	0.010071	1038	146	0.172903	0.007875	1050	1051	0.152123	0.015249
1002	136	0.138660	0.006315	1014	1015	0.159758	0.016015	1025	137	0.121104	0.005516	999	1039	0.081752	0.013778	1051	1052	0.162161	0.016256
1002	1003	0.126384	0.012669	1015	173	0.178568	0.008133	1025	1026	0.120698	0.012099	1039	1040	0.089384	0.015064	1052	127	0.241552	0.011002
1003	121	0.172042	0.007836	1015	177	0.283901	0.012931	1026	122	0.136898	0.006235	1040	1041	0.072360	0.012195	1052	138	0.236547	0.010774
1003	128	0.236529	0.010773	1008	143	0.235672	0.010734	1026	125	0.137795	0.006276	1041	105	0.228923	0.010427	1047	1053	0.062207	0.010484
1003	1004	0.094197	0.009443	1008	1016	0.073114	0.012322	1026	130	0.194218	0.008846	1041	106	0.169714	0.007730	1047	1054	0.178450	0.017889
1004	118	0.257311	0.011720	1016	155	0.180820	0.008236	1026	1027	0.106203	0.010646	1041	1042	0.065854	0.011099	1054	1055	0.117638	0.011792
1004	120	0.113524	0.005171	1016	1017	0.121087	0.012138	1027	113	0.317730	0.014472	1042	111	0.228344	0.010401	1055	98	0.137013	0.006240
1004	124	0.161081	0.007337	1017	168	0.152599	0.006950	1027	116	0.271044	0.012346	1042	114	0.165521	0.007539	1055	1056	0.066512	0.006667
1003	1005	0.093791	0.009402	1017	175	0.202900	0.009242	1027	119	0.112044	0.005103	1042	1043	0.156676	0.015706	1056	86	0.153501	0.006991
1005	129	0.118147	0.005381	1017	176	0.166023	0.007562	1016	1028	0.091671	0.015450	1043	90	0.241804	0.011014	1056	88	0.098859	0.004503
1005	131	0.091288	0.004158	1017	1018	0.161493	0.016189	1028	1029	0.075744	0.012765	1043	1044	0.135307	0.013564	1056	91	0.124656	0.005678
1005	1006	0.135179	0.013551	1018	182	0.138858	0.006324	1029	1030	0.091128	0.015358	1044	87	0.245184	0.011168	1054	1057	0.120827	0.012112
1006	1007	0.151531	0.015190	1018	188	0.185191	0.008435	1030	167	0.133916	0.006099	1044	97	0.245765	0.011194	1057	104	0.192828	0.008783
1007	152	0.206837	0.009421	1018	198	0.295724	0.013470	1030	1031	0.149057	0.014942	1044	101	0.158479	0.007218	1057	1058	0.123943	0.012425
999	1008	0.078827	0.013285	1016	1019	0.135307	0.013564	1031	172	0.257889	0.011746	1042	1045	0.079207	0.013349	1058	94	0.186117	0.008477
1008	149	0.196690	0.008959	1019	159	0.106139	0.004834	1031	178	0.152132	0.006929	1045	108	0.148704	0.006773	1058	95	0.130993	0.005966
1008	1009	0.154174	0.015455	1019	161	0.328442	0.014960	1030	1032	0.132509	0.013283	1045	110	0.206456	0.009404	1058	99	0.131218	0.005976
1009	156	0.199023	0.009065	1019	165	0.111540	0.005080	1032	164	0.097199	0.004427	1045	1046	0.105637	0.010589	1058	100	0.148870	0.006780
1009	162	0.190273	0.008666	1019	1020	0.149638	0.015000	1032	1033	0.110536	0.011081	1046	92	0.198731	0.009052	1058	1059	0.103963	0.010422
1009	166	0.142634	0.006496	1020	171	0.156013	0.007106	1033	163	0.121979	0.005556	1046	93	0.204213	0.009301	1059	83	0.198063	0.009021
1009	1010	0.094820	0.009505	1020	1021	0.132296	0.013262	1033	1034	0.121635	0.012193	1046	103	0.152759	0.006958	1059	85	0.151800	0.006914
1010	169	0.090673	0.004130	1021	180	0.271504	0.012366	1034	158	0.149610	0.006814	1045	1047	0.084707	0.014276	1059	89	0.191964	0.008743
1010	174	0.145961	0.006648	1021	181	0.119635	0.005449	1034	170	0.155665	0.007090	1047	96	0.223656	0.010187	1053	1060	0.068787	0.011593
1010	1011	0.105376	0.010563	1020	1022	0.129352	0.012967	1034	1035	0.161237	0.016163	1047	102	0.228929	0.010427	1060	1061	0.144281	0.014463

1061	79	0.200797	0.009146	1074	62	0.129309	0.005890	1093	39	0.263591	0.012006	1105	1106	0.107080	0.010734	1121	197	0.266544	0.012141
1061	80	0.189457	0.008629	1074	63	0.146893	0.006690	1093	41	0.197301	0.008987	1106	11	0.262430	0.011953	1118	1122	0.092115	0.015525
1061	82	0.183699	0.008367	1074	66	0.144029	0.006560	1092	1094	0.161446	0.016184	1106	13	0.148170	0.006749	1122	1123	0.090270	0.015214
1061	84	0.156760	0.007140	1074	1075	0.106542	0.010680	1094	1095	0.141318	0.014166	1106	15	0.223380	0.010174	1123	1124	0.084240	0.014197
1060	1062	0.082999	0.013988	1075	52	0.196518	0.008951	1095	47	0.135934	0.006191	1106	18	0.110719	0.005043	1124	1125	0.178554	0.017899
1062	75	0.242399	0.011041	1075	54	0.193836	0.008829	1095	1096	0.098170	0.009841	1098	1107	0.058403	0.009843	1125	1126	0.140823	0.014117
1062	1063	0.140646	0.014099	1075	55	0.227200	0.010348	1096	33	0.198262	0.009030	1107	17	0.151809	0.006914	1126	1127	0.151569	0.015194
1063	72	0.198569	0.009044	999	1076	0.081752	0.013778	1096	37	0.143187	0.006522	1107	24	0.220694	0.010052	1127	216	0.147727	0.006728
1063	73	0.151525	0.006901	1076	1077	0.089384	0.015064	1095	1097	0.179316	0.017976	1107	1108	0.126895	0.012720	1127	221	0.163823	0.007462
1063	74	0.104617	0.004765	1077	1078	0.072360	0.012195	1097	35	0.187538	0.008542	1108	9	0.157576	0.007177	1123	1128	0.148355	0.014872
1063	1064	0.054008	0.005414	1078	1079	0.065854	0.011099	1097	42	0.172735	0.007868	1108	10	0.168088	0.007656	1128	230	0.200902	0.009151
1064	64	0.134594	0.006130	1079	1080	0.079207	0.013349	1097	43	0.158340	0.007212	1108	14	0.176316	0.008031	1128	232	0.104141	0.004743
1064	68	0.253581	0.011550	1080	1081	0.084707	0.014276	1093	1098	0.083970	0.014152	1108	1109	0.120222	0.012051	1128	1129	0.151946	0.015232
1064	1065	0.070832	0.007100	1081	1082	0.062207	0.010484	1098	26	0.136926	0.006236	1109	4	0.183683	0.008366	1129	235	0.196670	0.008958
1065	57	0.166137	0.007567	1082	1083	0.068787	0.011593	1098	1099	0.150742	0.015111	1109	6	0.245351	0.011175	1129	237	0.119366	0.005437
1065	61	0.170111	0.007748	1083	1084	0.082999	0.013988	1099	29	0.158339	0.007212	1109	8	0.101896	0.004641	1129	238	0.326239	0.014860
1062	1066	0.119837	0.012013	1084	1085	0.065999	0.011123	1099	1100	0.096821	0.009706	1108	1110	0.129635	0.012995	1124	1130	0.051000	0.008595
1066	60	0.227638	0.010368	1085	1086	0.050238	0.008467	1100	32	0.127821	0.005822	1110	3	0.225656	0.010278	1130	1131	0.125344	0.012565
1066	65	0.161312	0.007347	1086	1087	0.055494	0.009352	1100	1101	0.125825	0.012613	1110	5	0.194972	0.008880	1131	236	0.151631	0.006906
1066	1067	0.091219	0.009144	1087	1088	0.137677	0.013801	1101	19	0.378150	0.017224	1110	1111	0.109186	0.010945	1131	1132	0.111507	0.011178
1067	53	0.146708	0.006682	1088	56	0.168411	0.007671	1101	23	0.140706	0.006409	1111	1	0.203067	0.009249	1132	240	0.143150	0.006520
1067	58	0.216567	0.009864	1088	59	0.211883	0.009651	1101	28	0.273196	0.012444	1111	2	0.234778	0.010694	1132	242	0.207414	0.009447
1053	1068	0.149501	0.014987	1088	1089	0.140166	0.014051	1101	1102	0.172008	0.017243	999	1112	0.078827	0.013285	1132	243	0.128402	0.005848
1068	1069	0.147935	0.014830	1089	51	0.182819	0.008327	1102	7	0.270430	0.012318	1112	1113	0.073114	0.012322	1132	244	0.144225	0.006569
1069	1070	0.127974	0.012829	1089	1090	0.114788	0.011507	1102	12	0.239966	0.010930	1113	1114	0.074519	0.012559	1130	1133	0.080774	0.013613
1070	81	0.219851	0.010014	1090	45	0.177951	0.008105	1102	16	0.138285	0.006298	1114	1115	0.082412	0.013889	1133	1134	0.086276	0.014540
1070	1071	0.127180	0.012749	1090	49	0.133070	0.006061	1093	1103	0.120541	0.012084	1115	1116	0.071239	0.012006	1134	246	0.169359	0.007714
1071	67	0.185492	0.008449	1090	50	0.147509	0.006719	1103	31	0.183646	0.008365	1116	1117	0.082472	0.013899	1134	1135	0.133614	0.013394
1071	70	0.250707	0.011419	1090	1091	0.108404	0.010867	1103	46	0.290047	0.013211	1117	1118	0.083337	0.014045	1135	247	0.162170	0.007386
1071	77	0.193611	0.008818	1091	40	0.216706	0.009870	1103	1104	0.130513	0.013083	1118	199	0.214116	0.009752	1135	248	0.130614	0.005949
1070	1072	0.119316	0.011961	1091	44	0.124207	0.005657	1104	27	0.214608	0.009775	1118	203	0.143546	0.006538	1134	1136	0.130477	0.013080
1072	76	0.161680	0.007364	1087	1092	0.071165	0.011994	1104	30	0.150565	0.006858	1118	205	0.227295	0.010353	1136	1137	0.146767	0.014713
1072	78	0.195384	0.008899	1092	48	0.231661	0.010552	1104	1105	0.115996	0.011628	1118	1119	0.149289	0.014965	1137	1138	0.155518	0.015590
1072	1073	0.118940	0.011923	1092	1093	0.068786	0.011593	1105	20	0.182455	0.008310	1119	1120	0.146191	0.014655	1138	252	0.214155	0.009754
1073	69	0.127524	0.005808	1093	34	0.233616	0.010641	1105	21	0.172293	0.007847	1120	210	0.132748	0.006046	1138	1139	0.116226	0.011651
1073	71	0.134456	0.006124	1093	36	0.202097	0.009205	1105	22	0.168872	0.007692	1120	213	0.179517	0.008176	1139	253	0.188565	0.008589
1073	1074	0.092167	0.009239	1093	38	0.174194	0.007934	1105	25	0.100189	0.004563	1119	1121	0.161723	0.016212	1139	255	0.170484	0.007765

1139	257	0.186780	0.008507	1150	228	0.224885	0.010243	1158	206	0.310367	0.014137	1168	1169	0.076886	0.012958	1185	1186	0.084322	0.014211
1138	1140	0.127038	0.012735	1148	202	0.272619	0.012417	1153	1159	0.091355	0.015396	1169	1170	0.066851	0.011267	1186	256	0.289335	0.013179
1140	258	0.158472	0.007218	1148	1151	0.084554	0.014250	1159	218	0.265850	0.012109	1170	1171	0.069778	0.011760	1186	259	0.215338	0.009808
999	1141	0.075238	0.012680	1151	1152	0.123450	0.012375	1159	231	0.277977	0.012661	1171	1172	0.105481	0.017777	1186	1187	0.091005	0.015337
1141	1142	0.079151	0.013340	1152	214	0.207176	0.009436	1159	1160	0.089983	0.015165	1172	1173	0.084554	0.014250	1187	1188	0.093848	0.015817
1142	1143	0.076886	0.012958	1152	219	0.228988	0.010430	1160	222	0.282367	0.012861	1173	1174	0.088303	0.014882	1188	260	0.196320	0.008942
1143	1144	0.066851	0.011267	1152	220	0.200868	0.009149	1160	233	0.259893	0.011838	1174	1175	0.091355	0.015396	1188	261	0.147080	0.006699
1144	1145	0.069778	0.011760	1152	226	0.201758	0.009190	1160	1161	0.166655	0.016706	1175	1176	0.089983	0.015165	1188	1189	0.165306	0.016571
1145	1146	0.166047	0.016645	1151	1153	0.088303	0.014882	1161	1162	0.093856	0.009408	1176	1177	0.091784	0.015469	1189	264	0.179168	0.008161
1146	186	0.250365	0.011404	1153	224	0.323961	0.014756	1162	223	0.173080	0.007883	1177	1178	0.078502	0.013230	1189	266	0.188555	0.008588
1146	192	0.243686	0.011099	1153	225	0.245800	0.011196	1162	229	0.161595	0.007360	1178	1179	0.095898	0.016162	1189	1190	0.176293	0.017672
1146	194	0.185339	0.008442	1151	1154	0.179566	0.018001	1162	1163	0.148153	0.014852	1179	1180	0.097545	0.016440	1190	268	0.114467	0.005213
1145	1147	0.085601	0.008581	1154	1155	0.183131	0.018358	1163	227	0.111994	0.005101	1180	245	0.399973	0.018218	1190	269	0.170873	0.007783
1147	201	0.180740	0.008232	1155	1156	0.118591	0.011888	1163	1164	0.116272	0.011656	1180	1181	0.061590	0.010380	1188	1191	0.158055	0.015844
1147	207	0.175790	0.008007	1156	184	0.173627	0.007908	1164	215	0.228330	0.010400	1181	249	0.212263	0.009668	1191	262	0.329769	0.015020
1145	1148	0.105481	0.017777	1156	191	0.166359	0.007577	1161	1165	0.142539	0.014289	1181	1182	0.079087	0.013329	1191	263	0.298296	0.013587
1148	208	0.169530	0.007722	1155	1157	0.154685	0.015506	1165	234	0.190326	0.008669	1182	1183	0.157820	0.015821	1191	265	0.243230	0.011079
1148	1149	0.132315	0.013264	1157	185	0.158155	0.007203	1165	241	0.186583	0.008498	1183	250	0.222562	0.010137	1191	1192	0.178723	0.017916
1149	211	0.248941	0.011339	1157	189	0.238156	0.010847	1165	1166	0.155839	0.015622	1183	251	0.164587	0.007496	1192	267	0.202696	0.009232
1149	212	0.166947	0.007604	1157	196	0.168771	0.007687	1166	239	0.234322	0.010673	1182	1184	0.066603	0.011225	1192	270	0.305925	0.013934
1149	1150	0.154149	0.015453	1155	1158	0.132315	0.013264	999	1167	0.075238	0.012680	1184	1185	0.074905	0.012624				
1150	217	0.204508	0.009315	1158	200	0.180512	0.008222	1167	1168	0.079151	0.013340	1185	254	0.297774	0.013563				

Prilog 16. *Dionice distribucijske mreže sa 7 niskonaponskih izvoda – podaci za Matpower*

From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)
999	1000	0.055070	0.009281	1003	135	0.136357	0.006211	1001	1008	0.144256	0.014461	1011	168	0.159038	0.007244	1016	133	0.181676	0.008275
1000	132	0.135085	0.006153	1003	136	0.174837	0.007963	1008	143	0.130623	0.005949	1011	176	0.291732	0.013288	1016	142	0.186005	0.008472
1000	1001	0.065286	0.011003	1003	1004	0.170575	0.017099	1008	149	0.138371	0.006302	1002	1012	0.123486	0.012379	1016	1017	0.177058	0.017749
1001	141	0.226047	0.010296	1004	1005	0.173739	0.017416	1008	1009	0.153373	0.015375	1012	1013	0.082549	0.008275	1017	139	0.170015	0.007744
1001	147	0.222627	0.010140	1005	152	0.309714	0.014107	1009	156	0.244711	0.011146	1013	153	0.166449	0.007581	1017	140	0.302206	0.013765
1001	1002	0.050715	0.008547	1003	1006	0.105009	0.010526	1009	1010	0.093070	0.009330	1013	157	0.126137	0.005745	1017	1018	0.117423	0.011771
1002	148	0.264419	0.012044	1006	120	0.152620	0.006951	1010	162	0.154243	0.007025	1013	160	0.118546	0.005399	1018	117	0.254819	0.011606
1002	150	0.255110	0.011620	1006	121	0.175643	0.008000	1010	166	0.146218	0.006660	1000	1014	0.090175	0.009039	1018	123	0.218253	0.009941
1002	1003	0.135476	0.013581	1006	1007	0.072605	0.007278	1010	169	0.160412	0.007306	1014	1015	0.164838	0.016524	1000	1019	0.060243	0.010153
1003	124	0.177322	0.008076	1007	128	0.126495	0.005761	1009	1011	0.122761	0.012306	1015	137	0.120680	0.005496	1019	125	0.232362	0.010584
1003	129	0.148884	0.006781	1007	131	0.127642	0.005814	1011	155	0.293857	0.013385	1015	1016	0.138128	0.013847	1019	130	0.221425	0.010085

1019	1020	0.054968	0.009264	1035	99	0.121386	0.005529	1047	1050	0.136443	0.013678	1062	1063	0.133291	0.013362	1083	28	0.306227	0.013948
1020	113	0.257428	0.011725	1035	100	0.171651	0.007818	1050	78	0.166568	0.007587	1063	58	0.203345	0.009262	1083	32	0.189413	0.008627
1020	118	0.236416	0.010768	1035	1036	0.081241	0.008144	1050	87	0.211365	0.009627	1063	59	0.224582	0.010229	1083	1084	0.131268	0.013159
1020	1021	0.121242	0.012154	1036	94	0.095824	0.004364	1050	1051	0.122445	0.012274	999	1064	0.097185	0.016379	1084	16	0.116689	0.005315
1021	105	0.350408	0.015961	1036	95	0.130577	0.005947	1051	66	0.182646	0.008319	1064	1065	0.084250	0.014199	1084	19	0.345498	0.015737
1021	106	0.194651	0.008866	1036	1037	0.064301	0.006446	1051	67	0.190502	0.008677	1065	1066	0.065987	0.011121	1084	23	0.155715	0.007092
1021	1022	0.150547	0.015091	1037	83	0.169465	0.007719	1051	71	0.095770	0.004362	1066	1067	0.085588	0.014425	1084	1085	0.109290	0.010956
1022	97	0.292702	0.013332	1037	85	0.136574	0.006220	1050	1052	0.099291	0.009953	1067	1068	0.079302	0.013365	1085	7	0.197237	0.008984
1020	1023	0.166865	0.016727	1037	89	0.194755	0.008871	1052	1053	0.115529	0.011581	1068	1069	0.075142	0.012664	1085	12	0.218567	0.009955
1023	116	0.146303	0.006664	1031	1038	0.097221	0.009746	1053	69	0.129293	0.005889	1069	1070	0.049331	0.008314	1080	1086	0.158434	0.015882
1023	119	0.173901	0.007921	1038	98	0.158491	0.007219	1053	76	0.174133	0.007931	1070	1071	0.083718	0.014109	1086	30	0.157373	0.007168
1023	122	0.104713	0.004769	1038	1039	0.112765	0.011304	1053	1054	0.113526	0.011380	1071	1072	0.067195	0.011325	1086	31	0.235807	0.010740
1023	1024	0.120309	0.012060	1039	86	0.172339	0.007850	1054	62	0.140667	0.006407	1072	1073	0.073150	0.012328	1086	46	0.266083	0.012120
1024	111	0.276353	0.012587	1039	88	0.109851	0.005003	1054	63	0.147275	0.006708	1073	1074	0.063673	0.010731	1086	1087	0.122247	0.012254
1024	114	0.264457	0.012045	1039	91	0.135488	0.006171	1054	1055	0.098062	0.009830	1074	1075	0.064032	0.010791	1087	33	0.142545	0.006492
1024	126	0.228739	0.010419	1030	109	0.250158	0.011394	1055	52	0.185864	0.008466	1075	48	0.199257	0.009076	1087	1088	0.125397	0.012570
999	1025	0.097185	0.016379	1030	1040	0.049331	0.008314	1055	54	0.217206	0.009893	1075	1076	0.065120	0.010975	1088	47	0.184348	0.008397
1025	1026	0.084250	0.014199	1040	1041	0.138397	0.013873	1055	55	0.182553	0.008315	1076	1077	0.154041	0.015442	1088	1089	0.070202	0.007037
1026	1027	0.065987	0.011121	1041	84	0.233116	0.010618	1040	1056	0.083718	0.014109	1077	50	0.208156	0.009481	1089	37	0.128245	0.005841
1027	1028	0.085588	0.014425	1041	93	0.150375	0.006849	1056	80	0.218018	0.009930	1077	51	0.166869	0.007600	1089	43	0.105244	0.004793
1028	103	0.186917	0.008514	1041	1042	0.149978	0.015034	1056	1057	0.067195	0.011325	1077	1078	0.125843	0.012615	1089	1090	0.077984	0.007817
1028	1029	0.079302	0.013365	1042	82	0.268419	0.012226	1057	1058	0.102572	0.010282	1078	45	0.182926	0.008332	1090	35	0.199481	0.009086
1029	102	0.134321	0.006118	1042	90	0.129040	0.005877	1058	64	0.161978	0.007378	1078	49	0.124262	0.005660	1090	42	0.203591	0.009273
1029	108	0.125428	0.005713	1042	92	0.105908	0.004824	1058	68	0.176374	0.008033	1078	1079	0.117644	0.011793	1087	1091	0.125875	0.012618
1029	110	0.184052	0.008383	1042	1043	0.093298	0.009352	1058	74	0.112333	0.005116	1079	40	0.201342	0.009171	1091	22	0.143329	0.006528
1029	1030	0.075142	0.012664	1043	1044	0.105912	0.010617	1058	1059	0.114227	0.011451	1079	44	0.151045	0.006880	1091	25	0.204492	0.009314
1030	96	0.192315	0.008759	1044	101	0.186646	0.008501	1059	57	0.196501	0.008950	1076	38	0.240122	0.010937	1091	27	0.109514	0.004988
1030	1031	0.164542	0.016494	1040	1045	0.083065	0.008327	1059	61	0.196380	0.008945	1076	39	0.262806	0.011970	1091	1092	0.081369	0.008157
1031	112	0.226664	0.010324	1045	1046	0.120851	0.012115	1059	73	0.192701	0.008777	1076	41	0.210485	0.009587	1092	15	0.207226	0.009439
1031	115	0.249083	0.011345	1046	1047	0.107501	0.010776	1057	1060	0.132821	0.013315	1076	1080	0.058483	0.009856	1092	18	0.201518	0.009179
1031	1032	0.150448	0.015082	1047	81	0.142099	0.006472	1060	60	0.232111	0.010572	1080	34	0.212671	0.009687	1092	20	0.109476	0.004986
1032	1033	0.135676	0.013601	1047	1048	0.088720	0.008894	1060	65	0.147036	0.006697	1080	36	0.198548	0.009043	1092	21	0.119355	0.005436
1033	127	0.184454	0.008401	1048	77	0.112822	0.005139	1060	1061	0.115613	0.011589	1080	1081	0.071527	0.012055	1081	1093	0.055338	0.009326
1031	1034	0.122980	0.012328	1048	79	0.183869	0.008375	1061	53	0.129215	0.005885	1081	29	0.202865	0.009240	1093	17	0.154745	0.007048
1034	104	0.212622	0.009684	1048	1049	0.074178	0.007436	1061	56	0.184451	0.008401	1081	26	0.153548	0.006994	1093	24	0.217748	0.009918
1034	107	0.204132	0.009298	1049	70	0.111960	0.005099	1057	1062	0.130296	0.013061	1081	1082	0.157034	0.015742	1093	1094	0.113203	0.011348
1034	1035	0.107433	0.010769	1049	72	0.137102	0.006244	1062	75	0.106364	0.004844	1082	1083	0.156765	0.015715	1094	13	0.101606	0.004628

1094	1095	0.107843	0.010811	1110	134	0.191772	0.008735	1125	1126	0.163383	0.016378	1140	1142	0.073658	0.012414	1158	253	0.146510	0.006673
1095	6	0.194676	0.008867	1110	138	0.194927	0.008878	1126	230	0.191736	0.008733	1142	207	0.120640	0.005495	1158	1159	0.104581	0.010484
1095	11	0.197521	0.008997	1101	1111	0.088080	0.014845	1126	232	0.107075	0.004877	1142	209	0.160540	0.007312	1159	255	0.152598	0.006950
1093	1096	0.120298	0.012059	1111	159	0.156920	0.007147	1126	1127	0.179541	0.017998	1142	1143	0.060377	0.006052	1159	257	0.129884	0.005916
1096	9	0.163630	0.007453	1111	161	0.131193	0.005975	1127	235	0.172881	0.007874	1143	211	0.140962	0.006420	1157	1160	0.122177	0.012247
1096	10	0.167810	0.007643	1111	165	0.133363	0.006074	1127	237	0.117630	0.005358	1143	217	0.136692	0.006226	1160	1161	0.105462	0.010572
1096	14	0.167179	0.007615	1111	1112	0.146425	0.014678	1127	238	0.258019	0.011752	1142	1144	0.063778	0.010749	1161	258	0.147294	0.006709
1096	1097	0.107214	0.010747	1112	175	0.213419	0.009721	1125	1128	0.164196	0.016460	1144	216	0.257570	0.011732	999	1162	0.049180	0.008288
1097	4	0.181337	0.008259	1112	182	0.214784	0.009783	1128	1129	0.155301	0.015568	1144	221	0.183436	0.008355	1162	1163	0.050715	0.008547
1097	5	0.162236	0.007389	1111	1113	0.081997	0.013819	1129	240	0.114034	0.005194	1144	1145	0.069013	0.011631	1163	1164	0.068009	0.011462
1097	8	0.117247	0.005340	1113	171	0.151368	0.006894	1129	242	0.176777	0.008052	1145	228	0.200028	0.009111	1164	1165	0.064130	0.010808
1096	1098	0.128345	0.012866	1113	181	0.153018	0.006969	1128	1130	0.138083	0.013842	1140	1146	0.109155	0.010942	1165	1166	0.061230	0.010319
1098	3	0.233347	0.010628	1113	1114	0.155120	0.015550	1130	236	0.182681	0.008321	1146	1147	0.087765	0.008798	1166	1167	0.064770	0.010916
1098	1099	0.113542	0.011382	1114	167	0.183545	0.008360	1130	1131	0.093235	0.009346	1147	201	0.106344	0.004843	1167	1168	0.063975	0.010782
1099	1	0.203564	0.009272	1114	180	0.138824	0.006323	1131	1132	0.115868	0.011615	1147	1148	0.160056	0.016045	1168	1169	0.064872	0.010933
1099	2	0.231389	0.010539	1113	1115	0.064757	0.010914	1132	243	0.150562	0.006858	1148	194	0.196950	0.008971	1169	1170	0.084621	0.014262
999	1100	0.091798	0.015471	1115	187	0.100862	0.004594	1132	244	0.171178	0.007797	1148	202	0.215538	0.009817	1170	1171	0.157817	0.015820
1100	1101	0.096502	0.016264	1115	190	0.130297	0.005935	1132	247	0.153086	0.006973	1146	1149	0.126804	0.012711	1171	1172	0.148181	0.014854
1101	1102	0.148489	0.014885	1115	1116	0.077374	0.013040	999	1133	0.078124	0.013167	1149	208	0.132875	0.006052	1172	1173	0.144769	0.014512
1102	1103	0.153614	0.015399	1116	1117	0.148507	0.014887	1133	1134	0.084887	0.014306	1149	212	0.140116	0.006382	1173	200	0.201091	0.009159
1103	151	0.127381	0.005802	1117	193	0.182888	0.008330	1134	174	0.138393	0.006303	1149	1150	0.167126	0.016753	1173	206	0.294758	0.013426
1103	1104	0.136043	0.013638	1117	1118	0.118315	0.011860	1134	1135	0.080435	0.013556	1150	214	0.140798	0.006413	1172	1174	0.128305	0.012862
1104	1105	0.129340	0.012966	1118	198	0.127924	0.005826	1135	183	0.134305	0.006117	1150	220	0.118767	0.005409	1174	184	0.163110	0.007429
1105	163	0.142114	0.006473	1116	1119	0.174264	0.017469	1135	1136	0.146218	0.014658	1150	1151	0.162974	0.016337	1172	1175	0.126962	0.012727
1105	164	0.159592	0.007269	1119	178	0.245062	0.011162	1136	173	0.184879	0.008421	1151	219	0.211023	0.009612	1175	191	0.128263	0.005842
1105	172	0.294335	0.013406	1119	1120	0.181905	0.018235	1136	177	0.192701	0.008777	1151	224	0.112778	0.005137	1175	1176	0.097060	0.009730
1105	1106	0.156614	0.015700	1120	197	0.329212	0.014995	1136	1137	0.103103	0.010335	1151	226	0.188792	0.008599	1176	185	0.162620	0.007407
1106	154	0.312427	0.014230	1120	1121	0.121561	0.012186	1137	186	0.237254	0.010806	1145	1152	0.158371	0.015876	1176	189	0.131909	0.006008
1106	1107	0.081028	0.008122	1121	1122	0.111278	0.011155	1137	192	0.165922	0.007557	1152	1153	0.167371	0.016778	1176	196	0.183245	0.008346
1107	158	0.145687	0.006636	1122	210	0.149795	0.006823	1135	1138	0.056590	0.009537	1153	1154	0.158760	0.015915	1170	1177	0.069140	0.011652
1107	170	0.166602	0.007588	1122	213	0.133409	0.006076	1138	195	0.136415	0.006213	1154	1155	0.149155	0.014952	1177	1178	0.074862	0.012617
1103	1108	0.155204	0.015558	1116	1123	0.069388	0.011694	1138	1139	0.122860	0.012316	1155	246	0.213733	0.009735	1178	218	0.232113	0.010572
1108	144	0.206981	0.009427	1123	199	0.214694	0.009779	1139	179	0.244893	0.011154	1155	248	0.303804	0.013838	1178	225	0.243349	0.011084
1108	146	0.189753	0.008643	1123	203	0.131101	0.005971	1139	188	0.357566	0.016287	1155	1156	0.158464	0.015885	1178	1179	0.079103	0.013332
1108	1109	0.116928	0.011721	1123	205	0.215241	0.009804	1138	1140	0.067492	0.011375	1156	1157	0.160627	0.016102	1179	231	0.271339	0.012359
1109	145	0.213991	0.009747	1123	1124	0.160226	0.016062	1140	1141	0.129660	0.012998	1157	252	0.190768	0.008689	1179	1180	0.077507	0.013063
1109	1110	0.125178	0.012548	1124	1125	0.150275	0.015064	1141	204	0.225908	0.010290	1157	1158	0.125835	0.012614	1180	222	0.218720	0.009962

1180	233	0.200456	0.009130	1186	239	0.361647	0.016472	1194	1195	0.064770	0.010916	1207	1208	0.087504	0.014747	1215	262	0.225456	0.010269
1180	1181	0.050527	0.008515	1186	1187	0.157553	0.015794	1195	1196	0.063975	0.010782	1208	1209	0.090404	0.015236	1215	263	0.182456	0.008310
1181	1182	0.097249	0.009749	1187	1188	0.144997	0.014535	1196	1197	0.064872	0.010933	1209	254	0.327223	0.014904	1215	265	0.159290	0.007255
1182	223	0.149797	0.006823	1188	245	0.213912	0.009743	1197	1198	0.084621	0.014262	1209	1210	0.082100	0.013837	1215	1216	0.099563	0.009981
1182	229	0.141747	0.006456	1187	1189	0.124105	0.012441	1198	1199	0.069140	0.011652	1210	256	0.286645	0.013056	1216	264	0.198093	0.009023
1182	1183	0.116763	0.011705	1189	249	0.142007	0.006468	1199	1200	0.074862	0.012617	1210	1211	0.078639	0.013253	1216	267	0.222308	0.010126
1183	227	0.111982	0.005100	1189	1190	0.121403	0.012170	1200	1201	0.079103	0.013332	1211	259	0.172573	0.007860	1216	1217	0.118456	0.011874
1183	1184	0.128726	0.012904	1190	250	0.171440	0.007809	1201	1202	0.077507	0.013063	1211	1212	0.062528	0.010538	1217	266	0.157301	0.007165
1184	215	0.220375	0.010038	1190	251	0.147124	0.006701	1202	1203	0.050527	0.008515	1212	1213	0.108289	0.010855	1217	1218	0.096397	0.009663
1181	1185	0.076867	0.012955	999	1191	0.078124	0.013167	1203	1204	0.076867	0.012955	1213	261	0.139235	0.006342	1218	270	0.144671	0.006589
1185	234	0.187453	0.008538	1191	1192	0.084887	0.014306	1204	1205	0.081077	0.013664	1212	1214	0.065960	0.011116	1218	1219	0.119269	0.011956
1185	241	0.196416	0.008946	1192	1193	0.080435	0.013556	1205	1206	0.086771	0.014624	1214	260	0.137459	0.006261	1219	268	0.155427	0.007079
1185	1186	0.081077	0.013664	1193	1194	0.042537	0.007169	1206	1207	0.094422	0.015913	1214	1215	0.059818	0.010081	1219	269	0.168339	0.007667

Prilog 17. *Dionice distribucijske mreže sa 8 niskonaponskih izvoda – podaci za Matpower*

From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)
999	1000	0.056746	0.009564	1006	129	0.114654	0.005222	1013	1014	0.108724	0.010899	1021	1022	0.066637	0.011231	1029	1031	0.122656	0.012296
1000	147	0.234525	0.010682	1006	1007	0.080555	0.008075	1014	105	0.221383	0.010083	1022	1023	0.044335	0.007472	1031	104	0.152402	0.006941
1000	148	0.259609	0.011825	1007	121	0.154641	0.007043	1014	111	0.211975	0.009655	1023	1024	0.059879	0.010092	1031	107	0.200664	0.009140
1000	149	0.273007	0.012435	1007	128	0.133420	0.006077	1014	114	0.160737	0.007321	1024	1025	0.071127	0.011987	1031	1032	0.111751	0.011202
1000	1001	0.045787	0.007717	1007	131	0.153273	0.006981	1009	1015	0.142304	0.014265	1025	103	0.219375	0.009992	1032	94	0.161503	0.007356
1001	150	0.148755	0.006775	1006	1008	0.072773	0.007295	1015	122	0.171452	0.007809	1025	108	0.169696	0.007729	1032	95	0.130880	0.005961
1001	153	0.198583	0.009045	1008	120	0.104398	0.004755	1015	125	0.176002	0.008016	1025	110	0.225782	0.010284	1032	99	0.150136	0.006838
1001	157	0.164985	0.007515	1004	1009	0.079441	0.013389	1015	130	0.174465	0.007946	1025	1026	0.076527	0.012897	1032	100	0.134332	0.006118
1001	1002	0.107099	0.010736	1009	132	0.134373	0.006120	1015	1016	0.162080	0.016248	1026	102	0.173159	0.007887	1032	1033	0.101093	0.010134
1002	156	0.178062	0.008110	1009	1010	0.071732	0.012089	1016	126	0.237617	0.010823	1026	109	0.266712	0.012148	1033	83	0.190004	0.008654
1002	162	0.138233	0.006296	1010	118	0.214446	0.009767	1016	133	0.249244	0.011353	1026	1027	0.127636	0.012795	1033	85	0.125267	0.005705
1002	1003	0.109447	0.010971	1010	1011	0.093087	0.009331	1016	1017	0.122266	0.012256	1027	1028	0.137499	0.013783	1033	89	0.172282	0.007847
1003	166	0.152509	0.006946	1011	106	0.188790	0.008599	1017	137	0.166825	0.007598	1028	112	0.118091	0.005379	1026	1034	0.071440	0.012040
1000	1004	0.054664	0.009213	1011	113	0.170504	0.007766	1017	142	0.180197	0.008207	1028	115	0.112125	0.005107	1034	96	0.137843	0.006278
1004	141	0.153144	0.006975	1011	1012	0.139579	0.013992	1017	143	0.204276	0.009304	1027	1029	0.100833	0.010108	1034	1035	0.150181	0.015055
1004	1005	0.105680	0.010594	1012	97	0.226505	0.010317	1016	1018	0.108738	0.010900	1029	98	0.177852	0.008101	1035	93	0.132842	0.006050
1005	135	0.109038	0.004966	1012	101	0.223102	0.010162	1018	1019	0.114879	0.011516	1029	1030	0.116098	0.011638	1035	1036	0.067696	0.006786
1005	136	0.097000	0.004418	1011	1013	0.097440	0.009768	1019	117	0.180070	0.008202	1030	86	0.173904	0.007921	1036	82	0.212202	0.009665
1005	1006	0.095244	0.009547	1013	116	0.174183	0.007934	999	1020	0.076794	0.012942	1030	88	0.117250	0.005340	1036	84	0.167896	0.007647
1006	124	0.144666	0.006589	1013	119	0.210368	0.009582	1020	1021	0.067114	0.011311	1030	91	0.129734	0.005909	1035	1037	0.134629	0.013496

1037	90	0.150325	0.006847	1052	74	0.177539	0.008086	1073	45	0.169707	0.007730	1086	35	0.155818	0.007097	1099	175	0.105605	0.004810
1037	92	0.096985	0.004417	1052	80	0.160426	0.007307	1073	49	0.140418	0.006396	1084	1087	0.103461	0.010371	1099	176	0.097318	0.004432
1034	1038	0.061921	0.010436	1039	1053	0.149053	0.014942	1073	50	0.149050	0.006789	1087	20	0.150454	0.006853	1099	1100	0.110983	0.011125
1038	1039	0.064190	0.010818	1053	64	0.250849	0.011426	1073	1074	0.114329	0.011461	1087	21	0.126977	0.005783	1100	182	0.150189	0.006841
1034	1040	0.150181	0.015055	1053	68	0.121074	0.005514	1074	40	0.200125	0.009115	1087	22	0.108406	0.004937	1100	1101	0.112390	0.011266
1040	1041	0.067696	0.006786	1053	1054	0.127045	0.012735	1074	44	0.130708	0.005953	1087	25	0.170978	0.007788	1101	193	0.138251	0.006297
1041	1042	0.114311	0.011459	1054	65	0.179092	0.008157	1071	1075	0.059321	0.009998	1087	27	0.144330	0.006574	1101	198	0.154896	0.007055
1042	1043	0.081359	0.008156	1054	75	0.200797	0.009146	1075	1076	0.061825	0.010419	1087	1088	0.128051	0.012836	1097	1102	0.139825	0.014017
1043	77	0.130226	0.005931	1054	1055	0.126244	0.012655	1076	34	0.222324	0.010126	1088	11	0.198019	0.009019	1102	159	0.115572	0.005264
1043	81	0.118973	0.005419	1055	56	0.186198	0.008481	1076	36	0.190277	0.008667	1088	15	0.153393	0.006987	1102	165	0.127659	0.005814
1043	1044	0.075057	0.007524	1055	58	0.149883	0.006827	1076	38	0.186642	0.008501	1088	18	0.182176	0.008298	1102	1103	0.097764	0.009800
1044	70	0.131174	0.005974	1055	59	0.198540	0.009043	1076	39	0.251864	0.011472	1077	1089	0.055515	0.009356	1103	161	0.121305	0.005525
1044	72	0.139994	0.006376	1053	1056	0.114482	0.011476	1076	41	0.207975	0.009473	1089	17	0.154102	0.007019	1102	1104	0.108594	0.010886
1044	79	0.175068	0.007974	1056	53	0.127133	0.005790	1076	1077	0.086245	0.014535	1089	24	0.217429	0.009903	1104	171	0.112989	0.005146
1042	1045	0.136911	0.013725	1056	60	0.135801	0.006185	1077	29	0.211139	0.009617	1089	1090	0.067830	0.006799	1104	1105	0.096057	0.009629
1045	87	0.211308	0.009625	1056	1057	0.129985	0.013030	1077	1078	0.148588	0.014895	1090	8	0.167670	0.007637	1105	181	0.130784	0.005957
1045	1046	0.095331	0.009556	1057	47	0.234955	0.010702	1078	1079	0.105268	0.010552	1090	10	0.155962	0.007104	1096	1106	0.077253	0.013020
1046	76	0.172618	0.007862	1056	1058	0.130973	0.013129	1079	32	0.109543	0.004989	1090	1091	0.106959	0.010722	1106	1107	0.072756	0.012262
1046	78	0.190270	0.008666	1058	57	0.178244	0.008119	1079	1080	0.113909	0.011419	1091	6	0.190102	0.008659	1107	1108	0.068388	0.011526
1046	1047	0.124792	0.012510	1058	61	0.097216	0.004428	1080	23	0.141153	0.006429	1091	13	0.162681	0.007410	1108	1109	0.118724	0.011901
1047	69	0.124102	0.005652	999	1059	0.076794	0.012942	1080	28	0.255655	0.011645	1089	1092	0.124797	0.012510	1109	151	0.141558	0.006447
1047	71	0.137648	0.006269	1059	1060	0.067114	0.011311	1080	1081	0.128838	0.012915	1092	9	0.158143	0.007203	1109	1110	0.117735	0.011802
1047	1048	0.103432	0.010368	1060	1061	0.066637	0.011231	1081	16	0.100674	0.004585	1092	14	0.171925	0.007831	1110	140	0.151034	0.006879
1048	62	0.142051	0.006470	1061	1062	0.044335	0.007472	1081	19	0.371129	0.016904	1092	1093	0.103313	0.010356	1110	146	0.170102	0.007748
1048	63	0.140991	0.006422	1062	1063	0.059879	0.010092	1081	1082	0.108934	0.010920	1093	4	0.182340	0.008305	1110	1111	0.144918	0.014527
1048	66	0.155817	0.007097	1063	1064	0.071440	0.012040	1082	7	0.147140	0.006702	1093	5	0.144152	0.006566	1111	123	0.178177	0.008115
1048	1049	0.109307	0.010957	1064	1065	0.076527	0.012897	1082	12	0.163718	0.007457	1092	1094	0.120532	0.012083	1110	1112	0.125014	0.012532
1049	54	0.204362	0.009308	1065	1066	0.071440	0.012040	1077	26	0.145435	0.006624	1094	3	0.232863	0.010606	1112	134	0.154883	0.007054
1049	55	0.187003	0.008517	1066	1067	0.061921	0.010436	1076	1083	0.140774	0.014112	1094	1095	0.119433	0.011972	1112	144	0.110223	0.005020
1049	67	0.184596	0.008408	1067	1068	0.064190	0.010818	1083	31	0.183108	0.008340	1095	1	0.201727	0.009188	1112	1113	0.110346	0.011061
1049	1050	0.110471	0.011074	1068	1069	0.082089	0.013835	1083	46	0.289367	0.013180	1095	2	0.233398	0.010631	1113	127	0.255738	0.011648
1050	52	0.120491	0.005488	1069	1070	0.066934	0.011281	1083	1084	0.113863	0.011414	999	1096	0.078493	0.013229	1113	138	0.116024	0.005284
1050	1051	0.145347	0.014570	1070	1071	0.065373	0.011018	1084	30	0.149180	0.006795	1096	1097	0.125137	0.012544	1113	145	0.250760	0.011422
1051	42	0.182367	0.008306	1071	1072	0.143343	0.014369	1084	1085	0.104230	0.010448	1097	155	0.156450	0.007126	1107	1114	0.097119	0.009735
1051	43	0.187694	0.008549	1072	48	0.148714	0.006773	1085	33	0.176571	0.008042	1097	1098	0.123718	0.012402	1114	139	0.177529	0.008086
1039	1052	0.145258	0.014561	1072	51	0.108922	0.004961	1085	37	0.112217	0.005111	1098	168	0.150272	0.006844	1108	1115	0.074658	0.012582
1052	73	0.169333	0.007713	1072	1073	0.140589	0.014093	1085	1086	0.129502	0.012982	1098	1099	0.092191	0.009241	1115	1116	0.152248	0.015262

1116	1117	0.130720	0.013104	1136	1137	0.089224	0.015037	1153	183	0.127034	0.005786	1169	1170	0.117489	0.011778	1190	231	0.213721	0.009734
1117	163	0.147896	0.006736	1137	1138	0.157487	0.015787	1153	1154	0.141903	0.014225	1170	228	0.129952	0.005919	1190	1191	0.083047	0.013996
1117	164	0.162835	0.007417	1138	230	0.198687	0.009050	1154	169	0.152394	0.006941	1167	208	0.130848	0.005960	1191	233	0.216455	0.009859
1117	1118	0.102643	0.010289	1138	1139	0.157030	0.015741	1154	174	0.184597	0.008408	1167	1171	0.089727	0.008994	1191	222	0.213601	0.009729
1118	172	0.063024	0.002870	1139	235	0.181102	0.008249	1154	179	0.092778	0.004226	1171	202	0.263712	0.012012	1191	1192	0.067473	0.011371
1118	1119	0.155329	0.015571	1139	237	0.132244	0.006023	1154	1155	0.141714	0.014206	1171	1172	0.108198	0.010846	1192	1193	0.103560	0.010381
1119	170	0.155222	0.007070	1139	238	0.315508	0.014371	1155	188	0.131591	0.005993	1172	214	0.165034	0.007517	1193	223	0.147721	0.006728
1119	1120	0.109532	0.010980	1137	1140	0.085949	0.014485	1153	1156	0.066155	0.011149	1172	220	0.163096	0.007428	1193	229	0.140007	0.006377
1120	197	0.216900	0.009879	1140	232	0.121686	0.005542	1156	195	0.121433	0.005531	1172	1173	0.114774	0.011505	1193	1194	0.141275	0.014162
1117	1121	0.159568	0.015996	1140	1141	0.080314	0.013536	1156	1157	0.151635	0.015201	1173	1174	0.067589	0.006775	1194	227	0.117270	0.005341
1121	154	0.313155	0.014264	1141	236	0.188604	0.008590	1157	192	0.110869	0.005050	1174	219	0.160733	0.007321	1194	1195	0.109239	0.010950
1121	158	0.151581	0.006904	1141	240	0.115719	0.005271	1157	1158	0.130173	0.013049	1174	224	0.180431	0.008218	1195	215	0.233588	0.010639
1115	1122	0.060070	0.010124	1141	1142	0.049056	0.008267	1158	177	0.179590	0.008180	1174	226	0.179635	0.008182	1192	1196	0.081657	0.013762
1122	167	0.139222	0.006341	1142	242	0.212889	0.009697	1158	1159	0.130966	0.013129	999	1175	0.064422	0.010857	1196	234	0.204882	0.009332
1122	1123	0.121671	0.012197	1142	243	0.135422	0.006168	1159	186	0.168927	0.007694	1175	1176	0.051537	0.008686	1196	241	0.187609	0.008545
1123	178	0.156351	0.007121	1142	244	0.111594	0.005083	1159	194	0.179452	0.008174	1176	1177	0.059192	0.009976	1196	1197	0.148811	0.014918
1123	180	0.181144	0.008251	1142	1143	0.083571	0.014085	1159	1160	0.163162	0.016356	1177	1178	0.074564	0.012567	1197	239	0.236409	0.010768
1123	1124	0.150401	0.015077	1143	247	0.103995	0.004736	1160	184	0.281206	0.012808	1178	1179	0.073939	0.012461	1196	1198	0.148455	0.014882
1124	199	0.159685	0.007273	1143	248	0.170679	0.007774	1158	1161	0.106311	0.010657	1179	1180	0.086239	0.014534	1198	1199	0.147948	0.014831
1124	1125	0.122024	0.012232	1143	1144	0.153053	0.015343	1161	1162	0.113051	0.011333	1180	1181	0.063929	0.010774	1199	1200	0.147464	0.014782
1125	203	0.139938	0.006374	1144	246	0.172761	0.007869	1162	152	0.191864	0.008739	1181	1182	0.084975	0.014321	1200	245	0.211832	0.009648
1125	205	0.218841	0.009968	1143	1145	0.148795	0.014916	1156	1163	0.074068	0.012483	1182	1183	0.148202	0.014856	1199	1201	0.123171	0.012347
1124	1126	0.146880	0.014724	1145	1146	0.139195	0.013954	1163	201	0.107549	0.004898	1183	1184	0.148951	0.014931	1201	249	0.160897	0.007328
1126	1127	0.128678	0.012899	1146	252	0.186525	0.008496	1163	1164	0.140298	0.014064	1184	1185	0.144903	0.014526	1201	1202	0.126518	0.012683
1127	210	0.102580	0.004672	1146	1147	0.151355	0.015172	1164	207	0.139196	0.006340	1185	200	0.219864	0.010014	1202	250	0.163282	0.007437
1127	213	0.133279	0.006070	1147	1148	0.136662	0.013700	1164	1165	0.112596	0.011287	1185	206	0.287438	0.013092	1202	251	0.139021	0.006332
1123	1128	0.103972	0.010423	1148	253	0.196669	0.008958	1165	209	0.098096	0.004468	1184	1186	0.156019	0.015640	999	1203	0.064422	0.010857
1128	187	0.186061	0.008475	1148	255	0.177496	0.008084	1165	1166	0.134774	0.013510	1186	191	0.136400	0.006212	1203	1204	0.051537	0.008686
1128	190	0.142126	0.006473	1148	257	0.164700	0.007502	1166	204	0.230923	0.010518	1186	196	0.205935	0.009380	1204	1205	0.059192	0.009976
999	1129	0.078493	0.013229	1147	1149	0.116907	0.011719	1166	216	0.214168	0.009755	1186	1187	0.093696	0.009392	1205	1206	0.074564	0.012567
1129	1130	0.068918	0.011615	1149	258	0.138782	0.006321	1163	1167	0.064304	0.010837	1187	185	0.165938	0.007558	1206	1207	0.073939	0.012461
1130	1131	0.068137	0.011483	999	1150	0.079456	0.013391	1167	1168	0.144732	0.014509	1187	189	0.130659	0.005951	1207	1208	0.086239	0.014534
1131	1132	0.050773	0.008557	1150	1151	0.074563	0.012566	1168	211	0.083902	0.003821	1182	1188	0.079821	0.013453	1208	1209	0.063929	0.010774
1132	1133	0.061123	0.010301	1151	1152	0.128992	0.012931	1168	212	0.132013	0.006013	1188	1189	0.059543	0.010035	1209	1210	0.084975	0.014321
1133	1134	0.061898	0.010432	1152	160	0.175425	0.007990	1168	1169	0.159147	0.015954	1189	218	0.229389	0.010448	1210	1211	0.079821	0.013453
1134	1135	0.069998	0.011797	1152	173	0.145286	0.006617	1169	217	0.131664	0.005997	1189	225	0.228366	0.010402	1211	1212	0.059543	0.010035
1135	1136	0.082614	0.013923	1151	1153	0.078755	0.013273	1169	221	0.245692	0.011191	1189	1190	0.067990	0.011459	1212	1213	0.067990	0.011459

1213	1214	0.083047	0.013996	1220	1221	0.074466	0.012550	1224	1225	0.063908	0.010771	1228	1229	0.065371	0.011017	1231	266	0.112444	0.005121
1214	1215	0.067473	0.011371	1221	1222	0.067730	0.011415	1225	1226	0.096811	0.009705	1229	262	0.204699	0.009324	1231	1232	0.108646	0.010891
1215	1216	0.081657	0.013762	1222	254	0.310024	0.014121	1226	260	0.186416	0.008491	1229	263	0.144703	0.006591	1232	270	0.128624	0.005858
1216	1217	0.081760	0.013779	1222	1223	0.071420	0.012037	1226	261	0.157773	0.007186	1229	1230	0.054518	0.009188	1231	1233	0.109570	0.010984
1217	1218	0.081481	0.013732	1223	256	0.276846	0.012610	1226	1227	0.114943	0.011522	1230	265	0.164810	0.007507	1233	268	0.099249	0.004520
1218	1219	0.067835	0.011432	1223	259	0.225609	0.010276	1227	264	0.115317	0.005252	1230	267	0.205351	0.009353	1233	269	0.120115	0.005471
1219	1220	0.079385	0.013379	1223	1224	0.075808	0.012776	1225	1228	0.064954	0.010947	1230	1231	0.142287	0.014263				

Prilog 18. *Opterećenje potrošača (sabirnica) – podaci za metodu simuliranog kaljenja*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
1	3	0.00000000	0.00000000	27	1	0.00000000	0.00000000	53	1	0.00000000	0.00000000	79	1	0.00000000	0.00000000	105	1	0.00000000	0.00000000
2	1	0.00000000	0.00000000	28	1	0.00158620	0.00036548	54	1	0.00206183	0.00047507	80	1	0.00096444	0.00022222	106	1	0.00000000	0.00000000
3	1	0.00501600	0.00115575	29	1	0.00000000	0.00000000	55	1	0.00108834	0.00025077	81	1	0.00224362	0.00051696	107	1	0.00000000	0.00000000
4	1	0.00178808	0.00041200	30	1	0.00000000	0.00000000	56	1	0.00076933	0.00017726	82	1	0.00000000	0.00000000	108	1	0.00129954	0.00029943
5	1	0.00150445	0.00034664	31	1	0.00000000	0.00000000	57	1	0.00000000	0.00000000	83	1	0.00267561	0.00061650	109	1	0.00068794	0.00015851
6	1	0.00000000	0.00000000	32	1	0.00179678	0.00041400	58	1	0.00000000	0.00000000	84	1	0.00341779	0.00078750	110	1	0.00000000	0.00000000
7	1	0.00113452	0.00026141	33	1	0.00000000	0.00000000	59	1	0.00100237	0.00023096	85	1	0.00000000	0.00000000	111	1	0.00271299	0.00062511
8	1	0.00053833	0.00012404	34	1	0.00000012	0.00000003	60	1	0.00000000	0.00000000	86	1	0.00134430	0.00030975	112	1	0.00012484	0.00002876
9	1	0.00267073	0.00061537	35	1	0.00011843	0.00002729	61	1	0.00000000	0.00000000	87	1	0.00181311	0.00041776	113	1	0.00228699	0.00052695
10	1	0.00000000	0.00000000	36	1	0.00000000	0.00000000	62	1	0.00000000	0.00000000	88	1	0.00240121	0.00055327	114	1	0.00000000	0.00000000
11	1	0.00000069	0.00000016	37	1	0.00011106	0.00002559	63	1	0.00000000	0.00000000	89	1	0.00174373	0.00040178	115	1	0.00370856	0.00085450
12	1	0.00099046	0.00022821	38	1	0.00113624	0.00026180	64	1	0.00000000	0.00000000	90	1	0.00000000	0.00000000	116	1	0.00000000	0.00000000
13	1	0.00000000	0.00000000	39	1	0.00000000	0.00000000	65	1	0.00000000	0.00000000	91	1	0.00106145	0.00024457	117	1	0.00043461	0.00010014
14	1	0.00140683	0.00032415	40	1	0.00064492	0.00014860	66	1	0.00190861	0.00043977	92	1	0.00137907	0.00031776	118	1	0.00109353	0.00025196
15	1	0.00000000	0.00000000	41	1	0.00078640	0.00018120	67	1	0.00001874	0.00000432	93	1	0.00139651	0.00032177	119	1	0.00000000	0.00000000
16	1	0.00029265	0.00006743	42	1	0.00000000	0.00000000	68	1	0.00212941	0.00049064	94	1	0.00000000	0.00000000	120	1	0.00122556	0.00028238
17	1	0.00000000	0.00000000	43	1	0.00128316	0.00029566	69	1	0.00000000	0.00000000	95	1	0.00082900	0.00019101	121	1	0.00245020	0.00056456
18	1	0.00105924	0.00024406	44	1	0.00123850	0.00028537	70	1	0.00170684	0.00039328	96	1	0.00000000	0.00000000	122	1	0.00000000	0.00000000
19	1	0.00130784	0.00030134	45	1	0.00196585	0.00045296	71	1	0.00145502	0.00033525	97	1	0.00191549	0.00044135	123	1	0.00054569	0.00012573
20	1	0.00000000	0.00000000	46	1	0.00000000	0.00000000	72	1	0.00000000	0.00000000	98	1	0.00000000	0.00000000	124	1	0.00002292	0.00000528
21	1	0.00197947	0.00045609	47	1	0.00154653	0.00035634	73	1	0.00000000	0.00000000	99	1	0.00081659	0.00018815	125	1	0.00328385	0.00075664
22	1	0.00115230	0.00026551	48	1	0.00080048	0.00018444	74	1	0.00273738	0.00063073	100	1	0.00185849	0.00042822	126	1	0.00000000	0.00000000
23	1	0.00000000	0.00000000	49	1	0.00078060	0.00017986	75	1	0.00000254	0.00000059	101	1	0.00000000	0.00000000	127	1	0.00163419	0.00037654
24	1	0.00210580	0.00048520	50	1	0.00000000	0.00000000	76	1	0.00000000	0.00000000	102	1	0.00104515	0.00024082	128	1	0.00246422	0.00056779
25	1	0.00378814	0.00087284	51	1	0.00114584	0.00026402	77	1	0.00112302	0.00025876	103	1	0.00173426	0.00039960	129	1	0.00238235	0.00054892
26	1	0.00283147	0.00065241	52	1	0.00125425	0.00028900	78	1	0.00000000	0.00000000	104	1	0.00000000	0.00000000	130	1	0.00000000	0.00000000

131	1	0.00548683	0.00126424	168	1	0.00000000	0.00000000	205	1	0.00000000	0.00000000	242	1	0.00640462	0.00147571	279	1	0.00013258	0.00003055
132	1	0.00000000	0.00000000	169	1	0.00000000	0.00000000	206	1	0.00142102	0.00032742	243	1	0.00054558	0.00012571	280	1	0.00187728	0.00043255
133	1	0.00152458	0.00035128	170	1	0.00000000	0.00000000	207	1	0.00026597	0.00006128	244	1	0.00000000	0.00000000	281	1	0.00000000	0.00000000
134	1	0.00098212	0.00022629	171	1	0.00000000	0.00000000	208	1	0.00284525	0.00065558	245	1	0.00000000	0.00000000	282	1	0.00138005	0.00031798
135	1	0.00000000	0.00000000	172	1	0.00000000	0.00000000	209	1	0.00000000	0.00000000	246	1	0.00003831	0.00000883	283	1	0.00212367	0.00048932
136	1	0.00000000	0.00000000	173	1	0.00124793	0.00028754	210	1	0.00118668	0.00027343	247	1	0.00000000	0.00000000	284	1	0.00274366	0.00063218
137	1	0.00000000	0.00000000	174	1	0.00038246	0.00008812	211	1	0.00108599	0.00025023	248	1	0.00000089	0.00000020	285	1	0.00000000	0.00000000
138	1	0.00217349	0.00050080	175	1	0.00000000	0.00000000	212	1	0.00000000	0.00000000	249	1	0.00000000	0.00000000	286	1	0.00000000	0.00000000
139	1	0.00076992	0.00017740	176	1	0.00148751	0.00034274	213	1	0.00000000	0.00000000	250	1	0.00208804	0.00048111	287	1	0.00000000	0.00000000
140	1	0.00328062	0.00075590	177	1	0.00125179	0.00028843	214	1	0.00315694	0.00072740	251	1	0.00095123	0.00021917	288	1	0.00164862	0.00037986
141	1	0.00000000	0.00000000	178	1	0.00001943	0.00000448	215	1	0.00000000	0.00000000	252	1	0.00000000	0.00000000	289	1	0.00047479	0.00010940
142	1	0.00125579	0.00028935	179	1	0.00000000	0.00000000	216	1	0.00219525	0.00050582	253	1	0.00112105	0.00025831	290	1	0.00000000	0.00000000
143	1	0.00147870	0.00034071	180	1	0.00096809	0.00022306	217	1	0.00000009	0.00000002	254	1	0.00000000	0.00000000	291	1	0.00104132	0.00023993
144	1	0.00000000	0.00000000	181	1	0.00241938	0.00055746	218	1	0.00000000	0.00000000	255	1	0.00202990	0.00046771	292	1	0.00248405	0.00057236
145	1	0.00015239	0.00003511	182	1	0.00000000	0.00000000	219	1	0.00217331	0.00050076	256	1	0.00075196	0.00017326	293	1	0.00000000	0.00000000
146	1	0.00028878	0.00006654	183	1	0.00000000	0.00000000	220	1	0.00016413	0.00003782	257	1	0.00000000	0.00000000	294	1	0.00042456	0.00009783
147	1	0.00000000	0.00000000	184	1	0.00092006	0.00021199	221	1	0.00000000	0.00000000	258	1	0.00065984	0.00015204	295	1	0.00000000	0.00000000
148	1	0.00061995	0.00014284	185	1	0.00127409	0.00029357	222	1	0.00138423	0.00031894	259	1	0.00037145	0.00008559	296	1	0.00034661	0.00007986
149	1	0.00131755	0.00030358	186	1	0.00012073	0.00002782	223	1	0.00162354	0.00037408	260	1	0.00000000	0.00000000	297	1	0.00000000	0.00000000
150	1	0.00194901	0.00044908	187	1	0.00134121	0.00030903	224	1	0.00000000	0.00000000	261	1	0.00232682	0.00053613	298	1	0.00000272	0.00000063
151	1	0.00000000	0.00000000	188	1	0.00205849	0.00047430	225	1	0.00188741	0.00043488	262	1	0.00000000	0.00000000	299	1	0.00000000	0.00000000
152	1	0.00070364	0.00016213	189	1	0.00000000	0.00000000	226	1	0.00382403	0.00088111	263	1	0.00163017	0.00037561	300	1	0.00092126	0.00021227
153	1	0.00223346	0.00051462	190	1	0.00000000	0.00000000	227	1	0.00000000	0.00000000	264	1	0.00000000	0.00000000	301	1	0.00000000	0.00000000
154	1	0.00000000	0.00000000	191	1	0.00175674	0.00040478	228	1	0.00157681	0.00036332	265	1	0.00122604	0.00028250	302	1	0.00000689	0.00000159
155	1	0.00185737	0.00042796	192	1	0.00000000	0.00000000	229	1	0.00006557	0.00001511	266	1	0.00000000	0.00000000	303	1	0.00171946	0.00039619
156	1	0.00000000	0.00000000	193	1	0.00150685	0.00034720	230	1	0.00000000	0.00000000	267	1	0.00000000	0.00000000	304	1	0.00000000	0.00000000
157	1	0.00000000	0.00000000	194	1	0.00000000	0.00000000	231	1	0.00276003	0.00063595	268	1	0.00000000	0.00000000	305	1	0.00030054	0.00006925
158	1	0.00175496	0.00040437	195	1	0.00121719	0.00028046	232	1	0.00011234	0.00002588	269	1	0.00101042	0.00023281	306	1	0.00061885	0.00014259
159	1	0.00000000	0.00000000	196	1	0.00058305	0.00013434	233	1	0.00000000	0.00000000	270	1	0.00000000	0.00000000	307	1	0.00000000	0.00000000
160	1	0.00000000	0.00000000	197	1	0.00000000	0.00000000	234	1	0.00283811	0.00065394	271	1	0.00000000	0.00000000	308	1	0.00124155	0.00028607
161	1	0.00000000	0.00000000	198	1	0.00217975	0.00050224	235	1	0.00564166	0.00129991	272	1	0.00076506	0.00017628	309	1	0.00000000	0.00000000
162	1	0.00000000	0.00000000	199	1	0.00000000	0.00000000	236	1	0.00000000	0.00000000	273	1	0.00000000	0.00000000	310	1	0.00109470	0.00025223
163	1	0.00000000	0.00000000	200	1	0.00000035	0.00000008	237	1	0.00275515	0.00063482	274	1	0.00045928	0.00010582	311	1	0.00149298	0.00034400
164	1	0.00000000	0.00000000	201	1	0.00081157	0.00018700	238	1	0.00105615	0.00024335	275	1	0.00238374	0.00054924	312	1	0.00000000	0.00000000
165	1	0.00000000	0.00000000	202	1	0.00000027	0.00000006	239	1	0.00000000	0.00000000	276	1	0.00000000	0.00000000	313	1	0.00000000	0.00000000
166	1	0.00000000	0.00000000	203	1	0.00488884	0.00112645	240	1	0.00193179	0.00044511	277	1	0.00027455	0.00006326	314	1	0.00080019	0.00018437
167	1	0.00000000	0.00000000	204	1	0.00251130	0.00057864	241	1	0.00000000	0.00000000	278	1	0.00000000	0.00000000	315	1	0.00049423	0.00011388

316	1	0.00000000	0.00000000	353	1	0.00000000	0.00000000	390	1	0.00163566	0.00037688	427	1	0.00000000	0.00000000	464	1	0.00000000	0.00000000
317	1	0.00000000	0.00000000	354	1	0.00054222	0.00012493	391	1	0.00000000	0.00000000	428	1	0.00111445	0.00025678	465	1	0.00000000	0.00000000
318	1	0.00000000	0.00000000	355	1	0.00000000	0.00000000	392	1	0.00138747	0.00031969	429	1	0.00175337	0.00040400	466	1	0.00000000	0.00000000
319	1	0.00000000	0.00000000	356	1	0.00000000	0.00000000	393	1	0.00000000	0.00000000	430	1	0.00000000	0.00000000	467	1	0.00000000	0.00000000
320	1	0.00000000	0.00000000	357	1	0.00000000	0.00000000	394	1	0.00101687	0.00023430	431	1	0.00000000	0.00000000	468	1	0.00000000	0.00000000
321	1	0.00000000	0.00000000	358	1	0.00002593	0.00000597	395	1	0.00115930	0.00026712	432	1	0.00002946	0.00000679	469	1	0.00000000	0.00000000
322	1	0.00000000	0.00000000	359	1	0.00213441	0.00049180	396	1	0.00000000	0.00000000	433	1	0.00224054	0.00051625	470	1	0.00000000	0.00000000
323	1	0.00000000	0.00000000	360	1	0.00000000	0.00000000	397	1	0.00065071	0.00014993	434	1	0.00000000	0.00000000	471	1	0.00000000	0.00000000
324	1	0.00000000	0.00000000	361	1	0.00197243	0.00045447	398	1	0.00111116	0.00025603	435	1	0.00291098	0.00067073	472	1	0.00000000	0.00000000
325	1	0.00000000	0.00000000	362	1	0.00000000	0.00000000	399	1	0.00000000	0.00000000	436	1	0.00000000	0.00000000	473	1	0.00000000	0.00000000
326	1	0.00026341	0.00006069	363	1	0.00162172	0.00037367	400	1	0.00181034	0.00041713	437	1	0.00058462	0.00013470	474	1	0.00000000	0.00000000
327	1	0.00000000	0.00000000	364	1	0.00056507	0.00013020	401	1	0.00000000	0.00000000	438	1	0.00069304	0.00015969	475	1	0.00000000	0.00000000
328	1	0.00183758	0.00042340	365	1	0.00084924	0.00019568	402	1	0.00031815	0.00007331	439	1	0.00000000	0.00000000	476	1	0.00000000	0.00000000
329	1	0.00133204	0.00030692	366	1	0.00000000	0.00000000	403	1	0.00000000	0.00000000	440	1	0.00000000	0.00000000	477	1	0.00000000	0.00000000
330	1	0.00199516	0.00045971	367	1	0.00354249	0.00081624	404	1	0.00086044	0.00019826	441	1	0.00102279	0.00023567	478	1	0.00000000	0.00000000
331	1	0.00000000	0.00000000	368	1	0.00000000	0.00000000	405	1	0.00072366	0.00016674	442	1	0.00153989	0.00035481	479	1	0.00000000	0.00000000
332	1	0.00000000	0.00000000	369	1	0.00253463	0.00058401	406	1	0.00000000	0.00000000	443	1	0.00000000	0.00000000	480	1	0.00000000	0.00000000
333	1	0.00000000	0.00000000	370	1	0.00000000	0.00000000	407	1	0.00000000	0.00000000	444	1	0.00001924	0.00000443	481	1	0.00124954	0.00028791
334	1	0.00149529	0.00034453	371	1	0.00145451	0.00033514	408	1	0.00259978	0.00059902	445	1	0.00000000	0.00000000	482	1	0.00000000	0.00000000
335	1	0.00103846	0.00023927	372	1	0.00000000	0.00000000	409	1	0.00080160	0.00018470	446	1	0.00058717	0.00013529	483	1	0.00036752	0.00008468
336	1	0.00000000	0.00000000	373	1	0.00106692	0.00024583	410	1	0.00136587	0.00031471	447	1	0.00000000	0.00000000	484	1	0.00033890	0.00007809
337	1	0.00223735	0.00051552	374	1	0.00000000	0.00000000	411	1	0.00000000	0.00000000	448	1	0.00222319	0.00051225	485	1	0.00000000	0.00000000
338	1	0.00112516	0.00025925	375	1	0.00120997	0.00027879	412	1	0.00000000	0.00000000	449	1	0.00136354	0.00031418	486	1	0.00000000	0.00000000
339	1	0.00054721	0.00012608	376	1	0.00099425	0.00022909	413	1	0.00000000	0.00000000	450	1	0.00000000	0.00000000	487	1	0.00000000	0.00000000
340	1	0.00000000	0.00000000	377	1	0.00000000	0.00000000	414	1	0.00000000	0.00000000	451	1	0.00006082	0.00001401	488	1	0.00094045	0.00021669
341	1	0.00150678	0.00034718	378	1	0.00015654	0.00003607	415	1	0.00000000	0.00000000	452	1	0.00000000	0.00000000	489	1	0.00106898	0.00024631
342	1	0.00057686	0.00013291	379	1	0.00000000	0.00000000	416	1	0.00000000	0.00000000	453	1	0.00000000	0.00000000	490	1	0.00000000	0.00000000
343	1	0.00000000	0.00000000	380	1	0.00000000	0.00000000	417	1	0.00000000	0.00000000	454	1	0.00000000	0.00000000	491	1	0.00021086	0.00004859
344	1	0.00308872	0.00071168	381	1	0.00182974	0.00042159	418	1	0.00000000	0.00000000	455	1	0.00060921	0.00014037	492	1	0.00000000	0.00000000
345	1	0.00000000	0.00000000	382	1	0.00000000	0.00000000	419	1	0.00000000	0.00000000	456	1	0.00000000	0.00000000	493	1	0.00000000	0.00000000
346	1	0.00000000	0.00000000	383	1	0.00117106	0.00026983	420	1	0.00000000	0.00000000	457	1	0.00077220	0.00017793	494	1	0.00046608	0.00010739
347	1	0.00002634	0.00000607	384	1	0.00000000	0.00000000	421	1	0.00000000	0.00000000	458	1	0.00000000	0.00000000	495	1	0.00096398	0.00022211
348	1	0.00000000	0.00000000	385	1	0.00021446	0.00004941	422	1	0.00237135	0.00054639	459	1	0.00159670	0.00036790	496	1	0.00000000	0.00000000
349	1	0.00000000	0.00000000	386	1	0.00000000	0.00000000	423	1	0.00265478	0.00061170	460	1	0.00100805	0.00023227	497	1	0.00003597	0.00000829
350	1	0.00095693	0.00022049	387	1	0.00117713	0.00027123	424	1	0.00000000	0.00000000	461	1	0.00000000	0.00000000	498	1	0.00119693	0.00027579
351	1	0.00179995	0.00041473	388	1	0.00000000	0.00000000	425	1	0.00042008	0.00009679	462	1	0.00000000	0.00000000	499	1	0.00000000	0.00000000
352	1	0.00135339	0.00031184	389	1	0.00159256	0.00036695	426	1	0.00191323	0.00044083	463	1	0.00000000	0.00000000	500	1	0.00189306	0.00043619

501	1	0.00000000	0.00000000	502	1	0.00048099	0.00011083	503	1	0.00000000	0.00000000	504	1	0.00152865	0.00035222	505	1	0.00232926	0.00053669

Prilog 19. *Dionice najbolje prostorne distribucijske mreže – podaci za metodu simuliranog kaljenja*

From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)	From bus	To bus	R (p.u.)	X (p.u.)
1	2	0.056746	0.009564	33	34	0.188790	0.008599	65	67	0.169696	0.007729	98	100	0.167896	0.007647	94	135	0.061921	0.010436
2	3	0.234525	0.010682	33	35	0.170504	0.007766	65	68	0.225782	0.010284	96	101	0.134629	0.013496	135	136	0.064190	0.010818
2	4	0.259609	0.011825	33	36	0.139579	0.013992	65	69	0.076527	0.012897	101	102	0.150325	0.006847	136	137	0.145258	0.014561
2	5	0.273007	0.012435	36	37	0.226505	0.010317	69	70	0.173159	0.007887	101	103	0.096985	0.004417	137	138	0.169333	0.007713
2	6	0.045787	0.007717	36	38	0.223102	0.010162	69	71	0.266712	0.012148	94	104	0.150181	0.015055	137	139	0.177539	0.008086
6	7	0.148755	0.006775	33	39	0.097440	0.009768	72	73	0.137499	0.013783	104	105	0.067696	0.006786	137	140	0.160426	0.007307
6	8	0.198583	0.009045	39	40	0.174183	0.007934	73	74	0.118091	0.005379	106	107	0.081359	0.008156	136	141	0.149053	0.014942
6	9	0.164985	0.007515	39	41	0.210368	0.009582	73	75	0.112125	0.005107	107	108	0.130226	0.005931	141	142	0.250849	0.011426
6	10	0.107099	0.010736	39	42	0.108724	0.010899	72	76	0.100833	0.010108	107	109	0.118973	0.005419	141	143	0.121074	0.005514
10	11	0.178062	0.008110	42	43	0.221383	0.010083	76	77	0.177852	0.008101	107	110	0.075057	0.007524	144	145	0.179092	0.008157
10	12	0.138233	0.006296	42	44	0.211975	0.009655	76	78	0.116098	0.011638	110	111	0.131174	0.005974	144	146	0.200797	0.009146
10	13	0.109447	0.010971	42	45	0.160737	0.007321	78	79	0.173904	0.007921	110	112	0.139994	0.006376	144	147	0.126244	0.012655
13	14	0.152509	0.006946	46	47	0.171452	0.007809	78	80	0.117250	0.005340	110	113	0.175068	0.007974	147	148	0.186198	0.008481
2	15	0.054664	0.009213	46	48	0.176002	0.008016	78	81	0.129734	0.005909	114	115	0.211308	0.009625	147	149	0.149883	0.006827
15	16	0.153144	0.006975	46	49	0.174465	0.007946	76	82	0.122656	0.012296	114	116	0.095331	0.009556	147	150	0.198540	0.009043
15	17	0.105680	0.010594	46	50	0.162080	0.016248	82	83	0.152402	0.006941	116	117	0.172618	0.007862	141	151	0.114482	0.011476
17	18	0.109038	0.004966	50	51	0.237617	0.010823	82	84	0.200664	0.009140	116	118	0.190270	0.008666	151	152	0.127133	0.005790
17	19	0.097000	0.004418	50	52	0.249244	0.011353	82	85	0.111751	0.011202	116	119	0.124792	0.012510	151	153	0.135801	0.006185
17	20	0.095244	0.009547	50	53	0.122266	0.012256	85	86	0.161503	0.007356	119	120	0.124102	0.005652	151	154	0.129985	0.013030
20	21	0.144666	0.006589	53	54	0.166825	0.007598	85	87	0.130880	0.005961	119	121	0.137648	0.006269	154	155	0.234955	0.010702
20	22	0.114654	0.005222	53	55	0.180197	0.008207	85	88	0.150136	0.006838	119	122	0.103432	0.010368	151	156	0.130973	0.013129
20	23	0.080555	0.008075	53	56	0.204276	0.009304	85	89	0.134332	0.006118	122	123	0.142051	0.006470	156	157	0.178244	0.008119
23	24	0.154641	0.007043	50	57	0.108738	0.010900	85	90	0.101093	0.010134	122	124	0.140991	0.006422	156	158	0.097216	0.004428
23	25	0.133420	0.006077	57	58	0.114879	0.011516	90	91	0.190004	0.008654	122	125	0.155817	0.007097	1	159	0.076794	0.012942
23	26	0.153273	0.006981	58	59	0.180070	0.008202	90	92	0.125267	0.005705	126	127	0.204362	0.009308	159	160	0.067114	0.011311
20	27	0.072773	0.007295	1	60	0.076794	0.012942	90	93	0.172282	0.007847	126	128	0.187003	0.008517	160	161	0.066637	0.011231
27	28	0.104398	0.004755	60	61	0.067114	0.011311	69	94	0.071440	0.012040	126	129	0.184596	0.008408	161	162	0.044335	0.007472
15	29	0.079441	0.013389	61	62	0.066637	0.011231	94	95	0.137843	0.006278	126	130	0.110471	0.011074	162	163	0.059879	0.010092
29	30	0.134373	0.006120	62	63	0.044335	0.007472	94	96	0.150181	0.015055	130	131	0.120491	0.005488	163	164	0.071440	0.012040
29	31	0.071732	0.012089	63	64	0.059879	0.010092	96	97	0.132842	0.006050	130	132	0.145347	0.014570	164	165	0.076527	0.012897
31	32	0.214446	0.009767	64	65	0.071127	0.011987	96	98	0.067696	0.006786	132	133	0.182367	0.008306	165	166	0.071440	0.012040
31	33	0.093087	0.009331	65	66	0.219375	0.009992	98	99	0.212202	0.009665	132	134	0.187694	0.008549	166	167	0.061921	0.010436

167	168	0.064190	0.010818	205	208	0.182176	0.008298	247	248	0.150272	0.006844	285	286	0.152248	0.015262	325	326	0.198687	0.009050
168	169	0.082089	0.013835	183	209	0.086245	0.014535	247	249	0.092191	0.009241	287	288	0.147896	0.006736	325	327	0.157030	0.015741
169	170	0.066934	0.011281	209	210	0.145435	0.006624	249	250	0.105605	0.004810	287	289	0.162835	0.007417	327	328	0.181102	0.008249
170	171	0.065373	0.011018	209	211	0.211139	0.009617	249	251	0.097318	0.004432	287	290	0.159568	0.015996	327	329	0.132244	0.006023
172	173	0.148714	0.006773	209	212	0.148588	0.014895	249	252	0.110983	0.011125	290	291	0.313155	0.014264	327	330	0.315508	0.014371
172	174	0.108922	0.004961	213	214	0.109543	0.004989	252	253	0.150189	0.006841	290	292	0.151581	0.006904	324	331	0.085949	0.014485
175	176	0.169707	0.007730	213	215	0.113909	0.011419	252	254	0.112390	0.011266	287	293	0.102643	0.010289	331	332	0.121686	0.005542
175	177	0.140418	0.006396	215	216	0.141153	0.006429	254	255	0.138251	0.006297	293	294	0.063024	0.002870	331	333	0.080314	0.013536
175	178	0.149050	0.006789	215	217	0.255655	0.011645	254	256	0.154896	0.007055	293	295	0.155329	0.015571	333	334	0.188604	0.008590
175	179	0.114329	0.011461	215	218	0.128838	0.012915	245	257	0.139825	0.014017	295	296	0.155222	0.007070	333	335	0.115719	0.005271
179	180	0.200125	0.009115	218	219	0.100674	0.004585	257	258	0.115572	0.005264	295	297	0.109532	0.010980	333	336	0.049056	0.008267
179	181	0.130708	0.005953	218	220	0.371129	0.016904	257	259	0.127659	0.005814	297	298	0.216900	0.009879	336	337	0.212889	0.009697
171	182	0.059321	0.009998	218	221	0.108934	0.010920	257	260	0.097764	0.009800	299	300	0.139222	0.006341	336	338	0.135422	0.006168
182	183	0.061825	0.010419	221	222	0.147140	0.006702	260	261	0.121305	0.005525	299	301	0.121671	0.012197	336	339	0.111594	0.005083
183	184	0.222324	0.010126	221	223	0.163718	0.007457	257	262	0.108594	0.010886	301	302	0.156351	0.007121	336	340	0.083571	0.014085
183	185	0.190277	0.008667	209	224	0.055515	0.009356	262	263	0.112989	0.005146	301	303	0.181144	0.008251	340	341	0.103995	0.004736
183	186	0.186642	0.008501	224	225	0.154102	0.007019	262	264	0.096057	0.009629	301	304	0.103972	0.010423	340	342	0.170679	0.007774
183	187	0.251864	0.011472	224	226	0.217429	0.009903	264	265	0.130784	0.005957	304	305	0.186061	0.008475	340	343	0.153053	0.015343
183	188	0.207975	0.009473	227	228	0.167670	0.007637	244	266	0.077253	0.013020	304	306	0.142126	0.006473	343	344	0.172761	0.007869
183	189	0.140774	0.014112	227	229	0.155962	0.007104	266	267	0.072756	0.012262	301	307	0.150401	0.015077	340	345	0.148795	0.014916
189	190	0.183108	0.008340	227	230	0.106959	0.010722	267	268	0.097119	0.009735	307	308	0.159685	0.007273	345	346	0.139195	0.013954
189	191	0.289367	0.013180	230	231	0.190102	0.008659	268	269	0.177529	0.008086	307	309	0.122024	0.012232	346	347	0.186525	0.008496
192	193	0.149180	0.006795	230	232	0.162681	0.007410	267	270	0.068388	0.011526	309	310	0.139938	0.006374	346	348	0.151355	0.015172
192	194	0.104230	0.010448	224	233	0.124797	0.012510	271	272	0.141558	0.006447	309	311	0.218841	0.009968	348	349	0.136662	0.013700
194	195	0.176571	0.008042	233	234	0.158143	0.007203	271	273	0.117735	0.011802	307	312	0.146880	0.014724	349	350	0.196669	0.008958
194	196	0.112217	0.005111	233	235	0.171925	0.007831	273	274	0.151034	0.006879	312	313	0.128678	0.012899	349	351	0.177496	0.008084
194	197	0.129502	0.012982	233	236	0.103313	0.010356	273	275	0.170102	0.007748	313	314	0.102580	0.004672	349	352	0.164700	0.007502
197	198	0.155818	0.007097	236	237	0.182340	0.008305	273	276	0.144918	0.014527	313	315	0.133279	0.006070	348	353	0.116907	0.011719
192	199	0.103461	0.010371	236	238	0.144152	0.006566	276	277	0.178177	0.008115	1	316	0.078493	0.013229	353	354	0.138782	0.006321
199	200	0.150454	0.006853	233	239	0.120532	0.012083	273	278	0.125014	0.012532	316	317	0.068918	0.011615	1	355	0.079456	0.013391
199	201	0.126977	0.005783	239	240	0.232863	0.010606	278	279	0.154883	0.007054	317	318	0.068137	0.011483	355	356	0.074563	0.012566
199	202	0.108406	0.004937	239	241	0.119433	0.011972	278	280	0.110223	0.005020	318	319	0.050773	0.008557	356	357	0.128992	0.012931
199	203	0.170978	0.007788	241	242	0.201727	0.009188	278	281	0.110346	0.011061	319	320	0.061123	0.010301	357	358	0.175425	0.007990
199	204	0.144330	0.006574	241	243	0.233398	0.010631	281	282	0.255738	0.011648	320	321	0.061898	0.010432	357	359	0.145286	0.006617
199	205	0.128051	0.012836	1	244	0.078493	0.013229	281	283	0.116024	0.005284	322	323	0.082614	0.013923	356	360	0.078755	0.013273
205	206	0.198019	0.009019	244	245	0.125137	0.012544	281	284	0.250760	0.011422	323	324	0.089224	0.015037	360	361	0.127034	0.005786
205	207	0.153393	0.006987	245	246	0.156450	0.007126	270	285	0.074658	0.012582	324	325	0.157487	0.015787	362	363	0.152394	0.006941

362	364	0.184597	0.008408	401	403	0.108198	0.010846	440	441	0.147721	0.006728	477	478	0.079385	0.013379	57	273	0.356363	0.035725
362	365	0.092778	0.004226	403	404	0.165034	0.007517	440	442	0.140007	0.006377	478	479	0.074466	0.012550	297	307	0.298772	0.029951
362	366	0.141714	0.014206	403	405	0.163096	0.007428	440	443	0.141275	0.014162	479	480	0.067730	0.011415	323	309	0.287079	0.028778
366	367	0.131591	0.005993	403	406	0.114774	0.011505	443	444	0.117270	0.005341	480	481	0.310024	0.014121	322	388	0.342279	0.034312
360	368	0.066155	0.011149	406	407	0.067589	0.006775	443	445	0.109239	0.010950	480	482	0.071420	0.012037	357	379	0.230264	0.023083
368	369	0.121433	0.005531	407	408	0.160733	0.007321	445	446	0.233588	0.010639	482	483	0.276846	0.012610	316	53	0.104102	0.010435
370	371	0.110869	0.005050	407	409	0.180431	0.008218	439	447	0.081657	0.013762	482	484	0.225609	0.010276	249	366	0.120625	0.012092
370	372	0.130173	0.013049	407	410	0.179635	0.008182	447	448	0.204882	0.009332	482	485	0.075808	0.012776	377	420	0.246089	0.024669
372	373	0.179590	0.008180	1	411	0.064422	0.010857	447	449	0.187609	0.008545	485	486	0.063908	0.010771	421	440	0.386598	0.038755
372	374	0.130966	0.013129	411	412	0.051537	0.008686	447	450	0.148811	0.014918	486	487	0.096811	0.009705	469	407	0.194754	0.019523
374	375	0.168927	0.007694	412	413	0.059192	0.009976	450	451	0.236409	0.010768	487	488	0.186416	0.008491	478	458	0.135723	0.013605
374	376	0.179452	0.008174	413	414	0.074564	0.012567	452	453	0.147948	0.014831	487	489	0.157773	0.007186	224	227	0.067830	0.006799
374	377	0.163162	0.016356	414	415	0.073939	0.012461	453	454	0.147464	0.014782	487	490	0.114943	0.011522	189	192	0.113863	0.011414
377	378	0.281206	0.012808	415	416	0.086239	0.014534	454	455	0.211832	0.009648	490	491	0.115317	0.005252	212	213	0.105268	0.010552
372	379	0.106311	0.010657	416	417	0.063929	0.010774	453	456	0.123171	0.012347	486	492	0.064954	0.010947	172	175	0.140589	0.014093
379	380	0.113051	0.011333	417	418	0.084975	0.014321	456	457	0.160897	0.007328	492	493	0.065371	0.011017	122	126	0.109307	0.010957
380	381	0.191864	0.008739	419	420	0.148951	0.014931	456	458	0.126518	0.012683	493	494	0.204699	0.009324	171	172	0.143343	0.014369
368	382	0.074068	0.012483	420	421	0.144903	0.014526	458	459	0.163282	0.007437	493	495	0.144703	0.006591	141	144	0.127045	0.012735
382	383	0.107549	0.004898	421	422	0.219864	0.010014	458	460	0.139021	0.006332	493	496	0.054518	0.009188	105	106	0.114311	0.011459
384	385	0.139196	0.006340	421	423	0.287438	0.013092	1	461	0.064422	0.010857	496	497	0.164810	0.007507	106	114	0.136911	0.013725
384	386	0.112596	0.011287	420	424	0.156019	0.015640	461	462	0.051537	0.008686	496	498	0.205351	0.009353	69	72	0.127636	0.012795
386	387	0.098096	0.004468	424	425	0.136400	0.006212	462	463	0.059192	0.009976	496	499	0.142287	0.014263	270	271	0.118724	0.011901
386	388	0.134774	0.013510	424	426	0.205935	0.009380	463	464	0.074564	0.012567	499	500	0.112444	0.005121	29	46	0.142304	0.014265
388	389	0.230923	0.010518	424	427	0.093696	0.009392	464	465	0.073939	0.012461	499	501	0.108646	0.010891	286	287	0.130720	0.013104
388	390	0.214168	0.009755	427	428	0.165938	0.007558	465	466	0.086239	0.014534	501	502	0.128624	0.005858	285	299	0.060070	0.010124
382	391	0.064304	0.010837	427	429	0.130659	0.005951	466	467	0.063929	0.010774	499	503	0.109570	0.010984	321	322	0.069998	0.011797
391	392	0.130848	0.005960	418	430	0.079821	0.013453	467	468	0.084975	0.014321	503	504	0.099249	0.004520	382	384	0.140298	0.014064
391	393	0.144732	0.014509	430	431	0.059543	0.010035	468	469	0.079821	0.013453	503	505	0.120115	0.005471	368	370	0.151635	0.015201
393	394	0.083902	0.003821	431	432	0.229389	0.010448	469	470	0.059543	0.010035	205	230	0.133806	0.013414	360	362	0.141903	0.014225
393	395	0.132013	0.006013	431	433	0.228366	0.010402	470	471	0.067990	0.011459	179	213	0.177855	0.017830	245	247	0.123718	0.012402
393	396	0.159147	0.015954	431	434	0.067990	0.011459	471	472	0.083047	0.013996	194	132	0.248035	0.024864	418	419	0.148202	0.014856
396	397	0.131664	0.005997	434	435	0.213721	0.009734	472	473	0.067473	0.011371	147	172	0.151515	0.015189	439	440	0.103560	0.010381
396	398	0.245692	0.011191	434	436	0.083047	0.013996	473	474	0.081657	0.013762	110	126	0.251951	0.025257	391	401	0.089727	0.008994
396	399	0.117489	0.011778	436	437	0.216455	0.009859	474	475	0.081760	0.013779	101	106	0.046779	0.004689	447	452	0.148455	0.014882
399	400	0.129952	0.005919	436	438	0.213601	0.009729	475	476	0.081481	0.013732	36	114	0.322029	0.032282				
401	402	0.263712	0.012012	436	439	0.067473	0.011371	476	477	0.067835	0.011432	73	276	0.203123	0.020362				

Prilog 20. *Minimalno godišnje opterećenje potrošača – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	34	1	0.00051660	0.00014630	68	1	0.00083089	0.00023531	102	1	0.00095872	0.00027150	136	1	0.00075205	0.00021298
1	1	0.00359612	0.00101841	35	1	0.00122482	0.00034686	69	1	0.00068838	0.00019495	103	1	0.00107204	0.00030360	137	1	0.00116829	0.00033085
2	1	0.00030657	0.00008682	36	1	0.00071539	0.00020259	70	1	0.00152446	0.00043172	104	1	0.00150232	0.00042545	138	1	0.00120332	0.00034078
3	1	0.00108549	0.00030741	37	1	0.00032762	0.00009278	71	1	0.00137625	0.00038975	105	1	0.00072074	0.00020411	139	1	0.00057253	0.00016214
4	1	0.00154814	0.00043843	38	1	0.00006784	0.00001921	72	1	0.00007015	0.00001987	106	1	0.00000007	0.00000002	140	1	0.00026024	0.00007370
5	1	0.00059346	0.00016807	39	1	0.00075307	0.00021327	73	1	0.00122130	0.00034587	107	1	0.00191905	0.00054347	141	1	0.00016828	0.00004766
6	1	0.00155089	0.00043920	40	1	0.00054357	0.00015394	74	1	0.00043262	0.00012252	108	1	0.00001078	0.00000305	142	1	0.00061668	0.00017464
7	1	0.00077723	0.00022011	41	1	0.00115669	0.00032757	75	1	0.00016215	0.00004592	109	1	0.00082445	0.00023348	143	1	0.00043592	0.00012345
8	1	0.00088602	0.00025092	42	1	0.00085668	0.00024261	76	1	0.00024412	0.00006913	110	1	0.00119607	0.00033872	144	1	0.00106372	0.00030124
9	1	0.00159357	0.00045129	43	1	0.00055186	0.00015629	77	1	0.00072994	0.00020671	111	1	0.00069565	0.00019701	145	1	0.00155463	0.00044026
10	1	0.00003684	0.00001043	44	1	0.00135846	0.00038471	78	1	0.00061423	0.00017395	112	1	0.00155107	0.00043926	146	1	0.00135069	0.00038251
11	1	0.00079848	0.00022613	45	1	0.00083522	0.00023653	79	1	0.00128458	0.00036379	113	1	0.00006652	0.00001884	147	1	0.00288437	0.00081684
12	1	0.00091160	0.00025816	46	1	0.00098713	0.00027955	80	1	0.00184269	0.00052184	114	1	0.00110419	0.00031270	148	1	0.00102821	0.00029118
13	1	0.00006312	0.00001788	47	1	0.00104367	0.00029556	81	1	0.00038641	0.00010943	115	1	0.00000144	0.00000041	149	1	0.00085246	0.00024141
14	1	0.00316773	0.00089709	48	1	0.00070070	0.00019844	82	1	0.00045867	0.00012989	116	1	0.00036224	0.00010259	150	1	0.00065239	0.00018475
15	1	0.00014945	0.00004232	49	1	0.00070287	0.00019905	83	1	0.00059599	0.00016878	117	1	0.00056302	0.00015944	151	1	0.00043350	0.00012277
16	1	0.00122029	0.00034558	50	1	0.00001091	0.00000309	84	1	0.00104389	0.00029563	118	1	0.00100923	0.00028581	152	1	0.00105216	0.00029797
17	1	0.00106055	0.00030034	51	1	0.00021475	0.00006082	85	1	0.00077433	0.00021929	119	1	0.00044171	0.00012509	153	1	0.00030956	0.00008767
18	1	0.00159877	0.00045276	52	1	0.00308310	0.00087312	86	1	0.00000000	0.00000000	120	1	0.00089095	0.00025231	154	1	0.00059004	0.00016710
19	1	0.00009216	0.00002610	53	1	0.00039538	0.00011197	87	1	0.00208306	0.00058991	121	1	0.00118281	0.00033497	155	1	0.00002171	0.00000615
20	1	0.00000020	0.00000006	54	1	0.00091827	0.00026005	88	1	0.00054152	0.00015336	122	1	0.00086867	0.00024600	156	1	0.00000039	0.00000011
21	1	0.00045603	0.00012915	55	1	0.00138467	0.00039213	89	1	0.00078412	0.00022206	123	1	0.00015557	0.00004406	157	1	0.00153576	0.00043492
22	1	0.00000015	0.00000004	56	1	0.00034809	0.00009858	90	1	0.00058705	0.00016625	124	1	0.00111184	0.00031487	158	1	0.00140753	0.00039861
23	1	0.00123261	0.00034907	57	1	0.00000000	0.00000000	91	1	0.00125977	0.00035676	125	1	0.00044962	0.00012733	159	1	0.00037388	0.00010588
24	1	0.00214715	0.00060806	58	1	0.00073979	0.00020950	92	1	0.00097412	0.00027587	126	1	0.00064361	0.00018227	160	1	0.00001491	0.00000422
25	1	0.00274708	0.00077796	59	1	0.00109434	0.00030991	93	1	0.00107591	0.00030469	127	1	0.00077488	0.00021944	161	1	0.00131844	0.00037338
26	1	0.00066681	0.00018884	60	1	0.00125500	0.00035541	94	1	0.00075481	0.00021376	128	1	0.00212776	0.00060257	162	1	0.00056122	0.00015893
27	1	0.00141112	0.00039962	61	1	0.00098613	0.00027927	95	1	0.00101804	0.00028830	129	1	0.00064723	0.00018329	163	1	0.00093415	0.00026455
28	1	0.00000005	0.00000001	62	1	0.00030651	0.00008680	96	1	0.00046564	0.00013187	130	1	0.00044231	0.00012526	164	1	0.00026903	0.00007619
29	1	0.00060977	0.00017268	63	1	0.00001288	0.00000365	97	1	0.00006238	0.00001767	131	1	0.00159041	0.00045040	165	1	0.00021047	0.00005961
30	1	0.00084671	0.00023979	64	1	0.00070564	0.00019983	98	1	0.00063634	0.00018021	132	1	0.00000000	0.00000000	166	1	0.00079715	0.00022575
31	1	0.00000000	0.00000000	65	1	0.00008556	0.00002423	99	1	0.00134825	0.00038182	133	1	0.00071069	0.00020126	167	1	0.00052201	0.00014783
32	1	0.00177258	0.00050199	66	1	0.00184523	0.00052256	100	1	0.00097908	0.00027727	134	1	0.00007512	0.00002127	168	1	0.00000050	0.00000014
33	1	0.00068395	0.00019369	67	1	0.00133867	0.00037910	101	1	0.00063821	0.00018074	135	1	0.00060910	0.00017249	169	1	0.00091891	0.00026023

170	1	0.00019640	0.00005562	191	1	0.00024156	0.00006841	212	1	0.00066664	0.00018879	233	1	0.00033618	0.00009520	254	1	0.00071853	0.00020348
171	1	0.00092370	0.00026159	192	1	0.00083639	0.00023686	213	1	0.00028004	0.00007931	234	1	0.00127841	0.00036204	255	1	0.00101990	0.00028883
172	1	0.00024057	0.00006813	193	1	0.00115019	0.00032573	214	1	0.00049478	0.00014012	235	1	0.00104122	0.00029487	256	1	0.00021133	0.00005985
173	1	0.00122736	0.00034758	194	1	0.00057173	0.00016191	215	1	0.00033764	0.00009562	236	1	0.00084727	0.00023994	257	1	0.00076687	0.00021717
174	1	0.00032018	0.00009067	195	1	0.00143619	0.00040672	216	1	0.00094056	0.00026636	237	1	0.00075477	0.00021375	258	1	0.00030724	0.00008701
175	1	0.00118314	0.00033506	196	1	0.00110018	0.00031157	217	1	0.00037418	0.00010597	238	1	0.00113051	0.00032016	259	1	0.00019488	0.00005519
176	1	0.00053899	0.00015264	197	1	0.00042608	0.00012066	218	1	0.00001694	0.00000480	239	1	0.00003497	0.00000990	260	1	0.00054079	0.00015315
177	1	0.00061352	0.00017375	198	1	0.00000154	0.00000044	219	1	0.00149496	0.00042337	240	1	0.00058842	0.00016664	261	1	0.00061470	0.00017408
178	1	0.00000390	0.00000110	199	1	0.00070349	0.00019923	220	1	0.00041613	0.00011785	241	1	0.00078408	0.00022205	262	1	0.00026801	0.00007590
179	1	0.00048120	0.00013627	200	1	0.00136361	0.00038617	221	1	0.00063895	0.00018095	242	1	0.00126774	0.00035902	263	1	0.00055432	0.00015698
180	1	0.00097429	0.00027592	201	1	0.00067340	0.00019070	222	1	0.00039852	0.00011286	243	1	0.00063755	0.00018055	264	1	0.00012125	0.00003434
181	1	0.00069471	0.00019674	202	1	0.00018295	0.00005181	223	1	0.00058814	0.00016656	244	1	0.00031006	0.00008781	265	1	0.00002068	0.00000586
182	1	0.00063522	0.00017989	203	1	0.00062029	0.00017566	224	1	0.00046095	0.00013054	245	1	0.00035032	0.00009921	266	1	0.00108858	0.00030828
183	1	0.00111763	0.00031651	204	1	0.00090239	0.00025555	225	1	0.00128839	0.00036487	246	1	0.00175015	0.00049563	267	1	0.00068827	0.00019492
184	1	0.00009002	0.00002549	205	1	0.00084596	0.00023957	226	1	0.00078542	0.00022243	247	1	0.00085378	0.00024179	268	1	0.00087903	0.00024894
185	1	0.00064085	0.00018148	206	1	0.00152659	0.00043232	227	1	0.00001107	0.00000313	248	1	0.00032686	0.00009257	269	1	0.00133941	0.00037931
186	1	0.00069578	0.00019704	207	1	0.00012332	0.00003492	228	1	0.00104101	0.00029481	249	1	0.00044404	0.00012575	270	1	0.00027658	0.00007833
187	1	0.00017029	0.00004823	208	1	0.00079784	0.00022595	229	1	0.00088549	0.00025077	250	1	0.00091816	0.00026002				
188	1	0.00200727	0.00056845	209	1	0.00067689	0.00019169	230	1	0.00014925	0.00004227	251	1	0.00057966	0.00016416				
189	1	0.00100825	0.00028553	210	1	0.00045341	0.00012840	231	1	0.00167391	0.00047405	252	1	0.00001493	0.00000423				
190	1	0.00035066	0.00009930	211	1	0.00058473	0.00016559	232	1	0.00000000	0.00000000	253	1	0.00054222	0.00015356				

Prilog 21. *Vršno opterećenje potrošača u periodu proljeća – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	12	1	0.00134824	0.00018276	24	1	0.00325893	0.00044176	36	1	0.00180411	0.00024455	48	1	0.00126693	0.00017174
1	1	0.00751658	0.00101890	13	1	0.00031192	0.00004228	25	1	0.00354398	0.00048040	37	1	0.00051681	0.00007005	49	1	0.00124874	0.00016927
2	1	0.00046333	0.00006281	14	1	0.00480082	0.00065077	26	1	0.00097107	0.00013163	38	1	0.00013947	0.00001891	50	1	0.00000539	0.00000073
3	1	0.00160894	0.00021810	15	1	0.00020432	0.00002770	27	1	0.00158789	0.00021524	39	1	0.00111962	0.00015177	51	1	0.00023023	0.00003121
4	1	0.00243275	0.00032977	16	1	0.00184728	0.00025040	28	1	0.00000020	0.00000003	40	1	0.00100591	0.00013635	52	1	0.00405197	0.00054926
5	1	0.00110625	0.00014996	17	1	0.00176536	0.00023930	29	1	0.00067662	0.00009172	41	1	0.00137386	0.00018623	53	1	0.00056633	0.00007677
6	1	0.00226576	0.00030713	18	1	0.00201009	0.00027247	30	1	0.00085573	0.00011600	42	1	0.00179076	0.00024274	54	1	0.00153837	0.00020853
7	1	0.00121957	0.00016532	19	1	0.00000542	0.00000073	31	1	0.00000000	0.00000000	43	1	0.00000000	0.00000000	55	1	0.00224363	0.00030413
8	1	0.00146930	0.00019917	20	1	0.00000094	0.00000013	32	1	0.00382739	0.00051881	44	1	0.00235426	0.00031913	56	1	0.00046325	0.00006280
9	1	0.00239100	0.00032411	21	1	0.00069947	0.00009481	33	1	0.00103856	0.00014078	45	1	0.00112021	0.00015185	57	1	0.00000000	0.00000000
10	1	0.00004095	0.00000555	22	1	0.00000000	0.00000000	34	1	0.00076392	0.00010355	46	1	0.00149318	0.00020241	58	1	0.00097266	0.00013185
11	1	0.00122407	0.00016593	23	1	0.00168427	0.00022831	35	1	0.00189198	0.00025646	47	1	0.00153090	0.00020752	59	1	0.00172229	0.00023346

60	1	0.00211401	0.00028656	97	1	0.00016070	0.00002178	134	1	0.00021226	0.00002877	171	1	0.00154839	0.00020989	208	1	0.00145151	0.00019676
61	1	0.00153370	0.00020790	98	1	0.00087588	0.00011873	135	1	0.00095040	0.00012883	172	1	0.00039073	0.00005296	209	1	0.00116749	0.00015826
62	1	0.00037632	0.00005101	99	1	0.00208225	0.00028226	136	1	0.00126689	0.00017173	173	1	0.00179087	0.00024276	210	1	0.00061106	0.00008283
63	1	0.00000055	0.00000008	100	1	0.00273891	0.00037127	137	1	0.00176268	0.00023894	174	1	0.00050783	0.00006884	211	1	0.00093970	0.00012738
64	1	0.00077550	0.00010512	101	1	0.00129022	0.00017489	138	1	0.00190097	0.00025768	175	1	0.00201184	0.00027271	212	1	0.00096504	0.00013081
65	1	0.00007019	0.00000951	102	1	0.00139207	0.00018870	139	1	0.00084735	0.00011486	176	1	0.00072143	0.00009779	213	1	0.00040223	0.00005452
66	1	0.00203425	0.00027575	103	1	0.00169017	0.00022911	140	1	0.00038923	0.00005276	177	1	0.00088678	0.00012021	214	1	0.00082207	0.00011143
67	1	0.00168353	0.00022821	104	1	0.00173397	0.00023505	141	1	0.00000000	0.00000000	178	1	0.00000782	0.00000106	215	1	0.00058217	0.00007892
68	1	0.00125474	0.00017008	105	1	0.00118626	0.00016080	142	1	0.00089890	0.00012185	179	1	0.00069143	0.00009373	216	1	0.00157303	0.00021323
69	1	0.00109469	0.00014839	106	1	0.00000010	0.00000001	143	1	0.00065372	0.00008861	180	1	0.00143670	0.00019475	217	1	0.00057629	0.00007812
70	1	0.00219437	0.00029745	107	1	0.00280266	0.00037991	144	1	0.00178350	0.00024176	181	1	0.00106790	0.00014476	218	1	0.00003230	0.00000438
71	1	0.00219954	0.00029815	108	1	0.00002191	0.00000297	145	1	0.00210889	0.00028587	182	1	0.00110788	0.00015018	219	1	0.00214987	0.00029142
72	1	0.00005076	0.00000688	109	1	0.00127129	0.00017233	146	1	0.00209607	0.00028413	183	1	0.00164296	0.00022271	220	1	0.00076357	0.00010350
73	1	0.00201854	0.00027362	110	1	0.00176762	0.00023961	147	1	0.00459000	0.00062219	184	1	0.00024738	0.00003353	221	1	0.00090194	0.00012226
74	1	0.00093390	0.00012659	111	1	0.00105588	0.00014313	148	1	0.00170145	0.00023064	185	1	0.00110639	0.00014998	222	1	0.00065462	0.00008874
75	1	0.00021534	0.00002919	112	1	0.00215840	0.00029258	149	1	0.00118055	0.00016003	186	1	0.00109157	0.00014797	223	1	0.00096380	0.00013065
76	1	0.00022596	0.00003063	113	1	0.00024425	0.00003311	150	1	0.00098275	0.00013321	187	1	0.00026467	0.00003588	224	1	0.00074871	0.00010149
77	1	0.00000000	0.00000000	114	1	0.00147940	0.00020054	151	1	0.00068108	0.00009232	188	1	0.00279221	0.00037849	225	1	0.00204571	0.00027730
78	1	0.00088121	0.00011945	115	1	0.00000391	0.00000053	152	1	0.00165576	0.00022444	189	1	0.00146215	0.00019820	226	1	0.00108161	0.00014662
79	1	0.00190400	0.00025809	116	1	0.00045655	0.00006189	153	1	0.00035752	0.00004846	190	1	0.00060640	0.00008220	227	1	0.00000000	0.00000000
80	1	0.00274746	0.00037243	117	1	0.00080736	0.00010944	154	1	0.00084397	0.00011440	191	1	0.00042628	0.00005778	228	1	0.00164955	0.00022360
81	1	0.00061610	0.00008351	118	1	0.00153367	0.00020789	155	1	0.00000000	0.00000000	192	1	0.00131786	0.00017864	229	1	0.00151777	0.00020574
82	1	0.00065227	0.00008842	119	1	0.00064640	0.00008762	156	1	0.00000000	0.00000000	193	1	0.00179160	0.00024286	230	1	0.00058307	0.00007904
83	1	0.00086355	0.00011706	120	1	0.00127470	0.00017279	157	1	0.00235863	0.00031972	194	1	0.00000000	0.00000000	231	1	0.00302530	0.00041009
84	1	0.00160094	0.00021701	121	1	0.00179241	0.00024297	158	1	0.00213392	0.00028926	195	1	0.00209203	0.00028358	232	1	0.00000000	0.00000000
85	1	0.00107047	0.00014511	122	1	0.00129413	0.00017542	159	1	0.00053943	0.00007312	196	1	0.00165632	0.00022452	233	1	0.00048610	0.00006589
86	1	0.00000000	0.00000000	123	1	0.00004035	0.00000547	160	1	0.00001081	0.00000147	197	1	0.00060427	0.00008191	234	1	0.00220436	0.00029881
87	1	0.00288845	0.00039154	124	1	0.00167106	0.00022652	161	1	0.00185190	0.00025103	198	1	0.00000622	0.00000084	235	1	0.00158093	0.00021430
88	1	0.00082060	0.00011124	125	1	0.00068085	0.00009229	162	1	0.00085189	0.00011548	199	1	0.00110455	0.00014973	236	1	0.00115861	0.00015705
89	1	0.00108790	0.00014747	126	1	0.00096986	0.00013147	163	1	0.00152552	0.00020679	200	1	0.00213606	0.00028955	237	1	0.00120221	0.00016296
90	1	0.00084154	0.00011407	127	1	0.00115928	0.00015714	164	1	0.00046566	0.00006312	201	1	0.00105505	0.00014301	238	1	0.00163160	0.00022117
91	1	0.00134757	0.00018267	128	1	0.00270455	0.00036661	165	1	0.00029076	0.00003941	202	1	0.00047105	0.00006385	239	1	0.00001685	0.00000228
92	1	0.00135653	0.00018388	129	1	0.00112981	0.00015315	166	1	0.00108656	0.00014729	203	1	0.00074722	0.00010129	240	1	0.00080886	0.00010964
93	1	0.00159772	0.00021658	130	1	0.00076220	0.00010332	167	1	0.00078757	0.00010676	204	1	0.00138639	0.00018793	241	1	0.00112747	0.00015283
94	1	0.00112135	0.00015200	131	1	0.00206292	0.00027964	168	1	0.00000010	0.00000001	205	1	0.00141160	0.00019135	242	1	0.00199333	0.00027020
95	1	0.00160348	0.00021736	132	1	0.00000000	0.00000000	169	1	0.00123523	0.00016744	206	1	0.00211592	0.00028682	243	1	0.00098819	0.00013395
96	1	0.00071760	0.00009727	133	1	0.00083580	0.00011330	170	1	0.00032610	0.00004420	207	1	0.00018034	0.00002445	244	1	0.00041932	0.00005684

245	1	0.00061767	0.00008373	251	1	0.00095085	0.00012889	257	1	0.00096043	0.00013019	263	1	0.00091265	0.00012371	269	1	0.00221083	0.00029969
246	1	0.00256963	0.00034832	252	1	0.00000000	0.00000000	258	1	0.00050586	0.00006857	264	1	0.00014704	0.00001993	270	1	0.00076616	0.00010385
247	1	0.00128110	0.00017366	253	1	0.00000000	0.00000000	259	1	0.00000000	0.00000000	265	1	0.00008908	0.00001207				
248	1	0.00057963	0.00007857	254	1	0.00108574	0.00014718	260	1	0.00085285	0.00011561	266	1	0.00172512	0.00023384				
249	1	0.00066736	0.00009046	255	1	0.00156245	0.00021179	261	1	0.00057488	0.00007793	267	1	0.00028986	0.00003929				
250	1	0.00138037	0.00018711	256	1	0.00032303	0.00004379	262	1	0.00047979	0.00006504	268	1	0.00109025	0.00014779				

Prilog 22. *Vršno opterećenje potrošača u periodu ljeta – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	27	1	0.00330517	0.00076156	54	1	0.00167274	0.00038542	81	1	0.00063458	0.00014622	108	1	0.00000799	0.00000184
1	1	0.00533071	0.00122827	28	1	0.00000000	0.00000000	55	1	0.00273075	0.00062920	82	1	0.00079858	0.00018400	109	1	0.00154829	0.00035675
2	1	0.00025908	0.00005969	29	1	0.00130727	0.00030121	56	1	0.00076078	0.00017529	83	1	0.00103399	0.00023824	110	1	0.00198755	0.00045796
3	1	0.00211723	0.00048784	30	1	0.00164642	0.00037936	57	1	0.00000000	0.00000000	84	1	0.00170300	0.00039239	111	1	0.00139387	0.00032117
4	1	0.00261309	0.00060209	31	1	0.00000000	0.00000000	58	1	0.00128660	0.00029645	85	1	0.00033528	0.00007725	112	1	0.00276623	0.00063738
5	1	0.00122911	0.00028320	32	1	0.00175319	0.00040396	59	1	0.00185948	0.00042845	86	1	0.00000000	0.00000000	113	1	0.00000161	0.00000037
6	1	0.00255013	0.00058758	33	1	0.00114832	0.00026459	60	1	0.00185749	0.00042799	87	1	0.00386598	0.00089077	114	1	0.00174617	0.00040234
7	1	0.00143105	0.00032973	34	1	0.00100525	0.00023162	61	1	0.00191086	0.00044029	88	1	0.00095242	0.00021945	115	1	0.00000323	0.00000074
8	1	0.00133642	0.00030793	35	1	0.00208710	0.00048089	62	1	0.00051189	0.00011795	89	1	0.00150449	0.00034665	116	1	0.00064488	0.00014859
9	1	0.00256014	0.00058989	36	1	0.00126494	0.00029146	63	1	0.00003377	0.00000778	90	1	0.00090518	0.00020857	117	1	0.00098606	0.00022720
10	1	0.00005286	0.00001218	37	1	0.00040693	0.00009376	64	1	0.00140305	0.00032328	91	1	0.00252091	0.00058085	118	1	0.00174738	0.00040262
11	1	0.00235446	0.00054250	38	1	0.00013958	0.00003216	65	1	0.00017475	0.00004026	92	1	0.00175694	0.00040482	119	1	0.00068459	0.00015774
12	1	0.00137317	0.00031640	39	1	0.00131750	0.00030357	66	1	0.00364252	0.00083928	93	1	0.00203566	0.00046904	120	1	0.00157042	0.00036184
13	1	0.00000000	0.00000000	40	1	0.00095854	0.00022086	67	1	0.00232025	0.00053462	94	1	0.00120066	0.00027665	121	1	0.00212106	0.00048872
14	1	0.00556868	0.00128310	41	1	0.00207839	0.00047889	68	1	0.00158141	0.00036438	95	1	0.00166197	0.00038294	122	1	0.00153113	0.00035279
15	1	0.00030205	0.00006960	42	1	0.00151793	0.00034975	69	1	0.00112819	0.00025995	96	1	0.00077722	0.00017908	123	1	0.00033641	0.00007751
16	1	0.00227619	0.00052446	43	1	0.00000000	0.00000000	70	1	0.00290023	0.00066825	97	1	0.00000956	0.00000220	124	1	0.00207878	0.00047898
17	1	0.00169102	0.00038963	44	1	0.00233718	0.00053852	71	1	0.00252960	0.00058285	98	1	0.00107231	0.00024707	125	1	0.00081084	0.00018683
18	1	0.00193102	0.00044493	45	1	0.00145650	0.00033560	72	1	0.00012559	0.00002894	99	1	0.00243759	0.00056165	126	1	0.00116741	0.00026899
19	1	0.00023215	0.00005349	46	1	0.00184594	0.00042533	73	1	0.00190030	0.00043785	100	1	0.00094555	0.00021787	127	1	0.00162858	0.00037525
20	1	0.00000004	0.00000001	47	1	0.00189099	0.00043571	74	1	0.00041826	0.00009637	101	1	0.00130084	0.00029973	128	1	0.00397098	0.00091496
21	1	0.00074511	0.00017168	48	1	0.00086752	0.00019989	75	1	0.00015266	0.00003518	102	1	0.00187802	0.00043272	129	1	0.00119538	0.00027543
22	1	0.00000000	0.00000000	49	1	0.00110638	0.00025493	76	1	0.00038764	0.00008932	103	1	0.00170613	0.00039311	130	1	0.00072374	0.00016676
23	1	0.00226086	0.00052093	50	1	0.00000851	0.00000196	77	1	0.00267854	0.00061717	104	1	0.00334936	0.00077174	131	1	0.00244686	0.00056379
24	1	0.00367950	0.00084780	51	1	0.00046001	0.00010599	78	1	0.00127418	0.00029359	105	1	0.00125892	0.00029007	132	1	0.00000000	0.00000000
25	1	0.00516990	0.00119121	52	1	0.00557604	0.00128479	79	1	0.00227036	0.00052312	106	1	0.00000001	0.00000000	133	1	0.00108850	0.00025080
26	1	0.00104191	0.00024007	53	1	0.00065912	0.00015187	80	1	0.00324983	0.00074880	107	1	0.00311407	0.00071752	134	1	0.00006874	0.00001584

135	1	0.00096400	0.00022212	163	1	0.00168405	0.00038803	191	1	0.00089995	0.00020736	219	1	0.00258041	0.00059456	247	1	0.00153337	0.00035331
136	1	0.00110052	0.00025357	164	1	0.00034546	0.00007960	192	1	0.00124352	0.00028652	220	1	0.00065770	0.00015154	248	1	0.00057350	0.00013214
137	1	0.00212076	0.00048865	165	1	0.00035436	0.00008165	193	1	0.00195350	0.00045011	221	1	0.00123369	0.00028426	249	1	0.00081101	0.00018687
138	1	0.00211100	0.00048640	166	1	0.00148321	0.00034175	194	1	0.00173377	0.00039948	222	1	0.00074512	0.00017169	250	1	0.00142640	0.00032866
139	1	0.00110883	0.00025549	167	1	0.00074388	0.00017140	195	1	0.00269050	0.00061993	223	1	0.00094322	0.00021733	251	1	0.00088684	0.00020434
140	1	0.00044243	0.00010194	168	1	0.00000011	0.00000003	196	1	0.00198004	0.00045623	224	1	0.00086004	0.00019816	252	1	0.00000000	0.00000000
141	1	0.00044407	0.00010232	169	1	0.00162636	0.00037473	197	1	0.00073268	0.00016882	225	1	0.00223848	0.00051577	253	1	0.00128973	0.00029717
142	1	0.00106671	0.00024578	170	1	0.00031343	0.00007222	198	1	0.00000040	0.00000009	226	1	0.00119227	0.00027471	254	1	0.00132171	0.00030454
143	1	0.00085655	0.00019736	171	1	0.00173007	0.00039863	199	1	0.00119559	0.00027548	227	1	0.00000058	0.00000013	255	1	0.00174784	0.00040273
144	1	0.00174886	0.00040296	172	1	0.00043279	0.00009972	200	1	0.00205590	0.00047371	228	1	0.00175755	0.00040496	256	1	0.00043738	0.00010078
145	1	0.00272213	0.00062721	173	1	0.00236037	0.00054386	201	1	0.00132671	0.00030569	229	1	0.00151592	0.00034929	257	1	0.00160106	0.00036890
146	1	0.00245735	0.00056621	174	1	0.00053839	0.00012405	202	1	0.00034825	0.00008024	230	1	0.00000612	0.00000141	258	1	0.00054677	0.00012598
147	1	0.00521879	0.00120248	175	1	0.00183578	0.00042299	203	1	0.00105656	0.00024344	231	1	0.00290343	0.00066899	259	1	0.00059486	0.00013706
148	1	0.00186478	0.00042967	176	1	0.00105171	0.00024233	204	1	0.00185964	0.00042849	232	1	0.00000000	0.00000000	260	1	0.00095799	0.00022073
149	1	0.00166925	0.00038462	177	1	0.00107179	0.00024695	205	1	0.00143207	0.00032997	233	1	0.00063692	0.00014675	261	1	0.00110666	0.00025499
150	1	0.00102325	0.00023577	178	1	0.00000287	0.00000066	206	1	0.00284959	0.00065658	234	1	0.00208215	0.00047976	262	1	0.00032717	0.00007538
151	1	0.00074185	0.00017093	179	1	0.00092535	0.00021321	207	1	0.00025253	0.00005819	235	1	0.00174666	0.00040245	263	1	0.00108976	0.00025109
152	1	0.00207636	0.00047842	180	1	0.00181980	0.00041931	208	1	0.00126302	0.00029102	236	1	0.00195611	0.00045071	264	1	0.00001275	0.00000294
153	1	0.00050349	0.00011601	181	1	0.00121984	0.00028107	209	1	0.00108495	0.00024999	237	1	0.00106351	0.00024505	265	1	0.00000165	0.00000038
154	1	0.00109471	0.00025223	182	1	0.00083931	0.00019339	210	1	0.00076269	0.00017573	238	1	0.00228405	0.00052628	266	1	0.00199888	0.00046057
155	1	0.00005883	0.00001356	183	1	0.00165781	0.00038198	211	1	0.00101612	0.00023413	239	1	0.00002966	0.00000683	267	1	0.00260760	0.00060082
156	1	0.00000000	0.00000000	184	1	0.00004144	0.00000955	212	1	0.00110947	0.00025564	240	1	0.00110330	0.00025422	268	1	0.00111534	0.00025699
157	1	0.00274067	0.00063149	185	1	0.00099311	0.00022883	213	1	0.00047525	0.00010950	241	1	0.00129903	0.00029931	269	1	0.00313925	0.00072332
158	1	0.00229430	0.00052864	186	1	0.00114313	0.00026339	214	1	0.00079078	0.00018221	242	1	0.00209885	0.00048360	270	1	0.00058877	0.00013566
159	1	0.00063616	0.00014658	187	1	0.00033256	0.00007663	215	1	0.00052273	0.00012044	243	1	0.00108328	0.00024960				
160	1	0.00000656	0.00000151	188	1	0.00382890	0.00088223	216	1	0.00166652	0.00038399	244	1	0.00054440	0.00012544				
161	1	0.00280868	0.00064716	189	1	0.00154604	0.00035623	217	1	0.00068420	0.00015765	245	1	0.00045741	0.00010539				
162	1	0.00108051	0.00024896	190	1	0.00063806	0.00014702	218	1	0.00002721	0.00000627	246	1	0.00319980	0.00073728				

Prilog 23. *Vršno opterećenje potrošača u periodu jeseni – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	5	1	0.00093078	0.00016743	10	1	0.00004250	0.00000765	15	1	0.00022369	0.00004024	20	1	0.00000009	0.00000002
1	1	0.00412459	0.00074196	6	1	0.00250078	0.00044986	11	1	0.00084820	0.00015258	16	1	0.00193288	0.00034770	21	1	0.00053287	0.00009586
2	1	0.00053851	0.00009687	7	1	0.00111175	0.00019999	12	1	0.00143514	0.00025816	17	1	0.00157731	0.00028374	22	1	0.00000000	0.00000000
3	1	0.00164610	0.00029611	8	1	0.00135757	0.00024421	13	1	0.00005607	0.00001009	18	1	0.00270804	0.00048714	23	1	0.00171566	0.00030862
4	1	0.00219006	0.00039396	9	1	0.00251236	0.00045194	14	1	0.00492799	0.00088648	19	1	0.00007480	0.00001345	24	1	0.00296476	0.00053332

25	1	0.00416156	0.00074861	62	1	0.00048773	0.00008774	99	1	0.00203590	0.00036623	136	1	0.00120241	0.00021630	173	1	0.00175214	0.00031519
26	1	0.00105964	0.00019061	63	1	0.00003106	0.00000559	100	1	0.00118491	0.00021315	137	1	0.00166101	0.00029879	174	1	0.00050458	0.00009077
27	1	0.00215036	0.00038682	64	1	0.00106327	0.00019127	101	1	0.00108550	0.00019527	138	1	0.00170095	0.00030598	175	1	0.00198760	0.00035754
28	1	0.00000010	0.00000002	65	1	0.00016182	0.00002911	102	1	0.00140802	0.00025328	139	1	0.00080839	0.00014542	176	1	0.00091006	0.00016371
29	1	0.00083722	0.00015060	66	1	0.00316468	0.00056928	103	1	0.00150676	0.00027105	140	1	0.00041418	0.00007451	177	1	0.00096384	0.00017338
30	1	0.00138268	0.00024873	67	1	0.00202960	0.00036510	104	1	0.00265059	0.00047681	141	1	0.00037848	0.00006808	178	1	0.00000967	0.00000174
31	1	0.00000000	0.00000000	68	1	0.00077558	0.00013952	105	1	0.00090068	0.00016202	142	1	0.00098401	0.00017701	179	1	0.00077766	0.00013989
32	1	0.00106205	0.00019105	69	1	0.00107523	0.00019342	106	1	0.00000028	0.00000005	143	1	0.00058054	0.00010443	180	1	0.00139809	0.00025150
33	1	0.00098778	0.00017769	70	1	0.00212693	0.00038261	107	1	0.00306705	0.00055172	144	1	0.00146554	0.00026363	181	1	0.00093812	0.00016876
34	1	0.00062873	0.00011310	71	1	0.00199956	0.00035969	108	1	0.00002360	0.00000425	145	1	0.00260605	0.00046879	182	1	0.00070819	0.00012739
35	1	0.00172939	0.00031109	72	1	0.00021241	0.00003821	109	1	0.00112621	0.00020259	146	1	0.00171428	0.00030838	183	1	0.00162366	0.00029207
36	1	0.00064578	0.00011617	73	1	0.00170368	0.00030647	110	1	0.00179298	0.00032253	147	1	0.00386212	0.00069475	184	1	0.00015219	0.00002738
37	1	0.00053678	0.00009656	74	1	0.00069040	0.00012419	111	1	0.00094231	0.00016951	148	1	0.00148375	0.00026691	185	1	0.00095885	0.00017249
38	1	0.00004898	0.00000881	75	1	0.00032056	0.00005766	112	1	0.00226933	0.00040822	149	1	0.00120334	0.00021647	186	1	0.00104982	0.00018885
39	1	0.00112494	0.00020236	76	1	0.00037086	0.00006671	113	1	0.00001232	0.00000222	150	1	0.00114525	0.00020602	187	1	0.00024768	0.00004455
40	1	0.00087713	0.00015778	77	1	0.00150172	0.00027014	114	1	0.00184764	0.00033237	151	1	0.00057958	0.00010426	188	1	0.00313455	0.00056386
41	1	0.00192315	0.00034595	78	1	0.00083047	0.00014939	115	1	0.00000100	0.00000018	152	1	0.00138398	0.00024896	189	1	0.00148350	0.00026686
42	1	0.00119059	0.00021417	79	1	0.00184509	0.00033191	116	1	0.00050277	0.00009044	153	1	0.00056554	0.00010173	190	1	0.00047330	0.00008514
43	1	0.00249345	0.00044854	80	1	0.00278656	0.00050127	117	1	0.00083751	0.00015066	154	1	0.00079253	0.00014257	191	1	0.00007088	0.00001275
44	1	0.00188990	0.00033997	81	1	0.00053259	0.00009581	118	1	0.00149900	0.00026965	155	1	0.00003599	0.00000647	192	1	0.00134917	0.00024270
45	1	0.00118804	0.00021371	82	1	0.00066454	0.00011954	119	1	0.00068513	0.00012325	156	1	0.00000001	0.00000000	193	1	0.00159846	0.00028754
46	1	0.00122191	0.00021981	83	1	0.00094807	0.00017054	120	1	0.00138966	0.00024998	157	1	0.00221540	0.00039852	194	1	0.00128877	0.00023183
47	1	0.00151228	0.00027204	84	1	0.00165905	0.00029844	121	1	0.00188835	0.00033969	158	1	0.00201162	0.00036186	195	1	0.00201610	0.00036267
48	1	0.00100670	0.00018109	85	1	0.00217154	0.00039063	122	1	0.00127785	0.00022987	159	1	0.00056361	0.00010139	196	1	0.00145594	0.00026190
49	1	0.00108428	0.00019505	86	1	0.00000000	0.00000000	123	1	0.00000201	0.00000036	160	1	0.00000000	0.00000000	197	1	0.00066382	0.00011941
50	1	0.00002929	0.00000527	87	1	0.00311009	0.00055946	124	1	0.00159254	0.00028648	161	1	0.00199048	0.00035806	198	1	0.00000029	0.00000005
51	1	0.00031863	0.00005732	88	1	0.00068586	0.00012338	125	1	0.00061324	0.00011031	162	1	0.00084294	0.00015163	199	1	0.00101976	0.00018344
52	1	0.00492773	0.00088643	89	1	0.00124964	0.00022479	126	1	0.00098727	0.00017760	163	1	0.00127799	0.00022989	200	1	0.00198725	0.00035748
53	1	0.00059803	0.00010758	90	1	0.00090785	0.00016331	127	1	0.00094117	0.00016930	164	1	0.00040254	0.00007241	201	1	0.00097430	0.00017526
54	1	0.00109731	0.00019739	91	1	0.00230822	0.00041522	128	1	0.00342264	0.00061569	165	1	0.00035403	0.00006369	202	1	0.00000000	0.00000000
55	1	0.00196341	0.00035319	92	1	0.00146334	0.00026324	129	1	0.00095633	0.00017203	166	1	0.00130887	0.00023545	203	1	0.00093164	0.00016759
56	1	0.00053908	0.00009697	93	1	0.00157278	0.00028292	130	1	0.00081935	0.00014739	167	1	0.00082929	0.00014918	204	1	0.00174544	0.00031398
57	1	0.00000000	0.00000000	94	1	0.00123766	0.00022264	131	1	0.00227837	0.00040985	168	1	0.00000003	0.00000001	205	1	0.00110347	0.00019850
58	1	0.00090646	0.00016306	95	1	0.00156988	0.00028240	132	1	0.00000000	0.00000000	169	1	0.00138609	0.00024934	206	1	0.00230500	0.00041464
59	1	0.00168653	0.00030338	96	1	0.00068645	0.00012348	133	1	0.00126600	0.00022774	170	1	0.00029736	0.00005349	207	1	0.00020645	0.00003714
60	1	0.00194345	0.00034960	97	1	0.00014868	0.00002675	134	1	0.00011002	0.00001979	171	1	0.00102445	0.00018428	208	1	0.00106953	0.00019239
61	1	0.00160277	0.00028832	98	1	0.00102736	0.00018481	135	1	0.00103735	0.00018661	172	1	0.00033152	0.00005964	209	1	0.00103644	0.00018644

210	1	0.00072799	0.00013096	223	1	0.00091392	0.00016440	236	1	0.00123079	0.00022140	249	1	0.00069496	0.00012501	262	1	0.00042416	0.00007630
211	1	0.00084544	0.00015208	224	1	0.00063684	0.00011456	237	1	0.00113931	0.00020495	250	1	0.00164745	0.00029635	263	1	0.00066655	0.00011990
212	1	0.00091651	0.00016487	225	1	0.00180109	0.00032399	238	1	0.00153414	0.00027597	251	1	0.00085761	0.00015427	264	1	0.00022735	0.00004090
213	1	0.00043859	0.00007890	226	1	0.00132748	0.00023880	239	1	0.00011654	0.00002096	252	1	0.00000000	0.00000000	265	1	0.00003712	0.00000668
214	1	0.00080408	0.00014464	227	1	0.00001836	0.00000330	240	1	0.00090137	0.00016214	253	1	0.00165822	0.00029829	266	1	0.00158201	0.00028458
215	1	0.00051912	0.00009338	228	1	0.00152294	0.00027396	241	1	0.00128431	0.00023103	254	1	0.00095638	0.00017204	267	1	0.00115999	0.00020867
216	1	0.00126453	0.00022747	229	1	0.00121382	0.00021835	242	1	0.00185792	0.00033421	255	1	0.00148048	0.00026632	268	1	0.00240925	0.00043339
217	1	0.00055658	0.00010012	230	1	0.00001345	0.00000242	243	1	0.00091602	0.00016478	256	1	0.00030720	0.00005526	269	1	0.00174199	0.00031336
218	1	0.00002052	0.00000369	231	1	0.00231366	0.00041620	244	1	0.00049567	0.00008916	257	1	0.00121235	0.00021809	270	1	0.00020579	0.00003702
219	1	0.00211316	0.00038013	232	1	0.00000001	0.00000000	245	1	0.00058413	0.00010508	258	1	0.00038532	0.00006931				
220	1	0.00061300	0.00011027	233	1	0.00053847	0.00009686	246	1	0.00218736	0.00039348	259	1	0.00046409	0.00008348				
221	1	0.00088466	0.00015914	234	1	0.00284651	0.00051205	247	1	0.00100767	0.00018127	260	1	0.00072416	0.00013027				
222	1	0.00059041	0.00010621	235	1	0.00143159	0.00025752	248	1	0.00039410	0.00007089	261	1	0.00112894	0.00020308				

Prilog 24. *Vršno opterećenje potrošača u periodu zime – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	20	1	0.00000011	0.00000001	40	1	0.00058533	0.00007031	60	1	0.00201618	0.00024219	80	1	0.00294029	0.00035320
1	1	0.00577103	0.00069325	21	1	0.00093923	0.00011283	41	1	0.00200473	0.00024082	61	1	0.00120988	0.00014534	81	1	0.00067510	0.00008110
2	1	0.00066631	0.00008004	22	1	0.00000103	0.00000012	42	1	0.00089971	0.00010808	62	1	0.00057999	0.00006967	82	1	0.00081034	0.00009734
3	1	0.00154171	0.00018520	23	1	0.00222546	0.00026733	43	1	0.00085767	0.00010303	63	1	0.00001784	0.00000214	83	1	0.00094305	0.00011328
4	1	0.00261116	0.00031367	24	1	0.00378538	0.00045472	44	1	0.00204082	0.00024515	64	1	0.00128874	0.00015481	84	1	0.00165645	0.00019898
5	1	0.00048434	0.00005818	25	1	0.00468080	0.00056228	45	1	0.00157500	0.00018920	65	1	0.00014165	0.00001702	85	1	0.00118294	0.00014210
6	1	0.00252560	0.00030339	26	1	0.00115923	0.00013925	46	1	0.00175588	0.00021093	66	1	0.00295272	0.00035470	86	1	0.00000000	0.00000000
7	1	0.00118678	0.00014256	27	1	0.00203020	0.00024388	47	1	0.00171867	0.00020646	67	1	0.00251858	0.00030255	87	1	0.00343020	0.00041206
8	1	0.00144196	0.00017322	28	1	0.00000000	0.00000000	48	1	0.00128076	0.00015385	68	1	0.00174055	0.00020908	88	1	0.00100290	0.00012047
9	1	0.00265045	0.00031839	29	1	0.00110961	0.00013329	49	1	0.00099924	0.00012003	69	1	0.00106478	0.00012791	89	1	0.00115452	0.00013869
10	1	0.00010104	0.00001214	30	1	0.00154510	0.00018561	50	1	0.00002545	0.00000306	70	1	0.00251811	0.00030249	90	1	0.00107654	0.00012932
11	1	0.00073647	0.00008847	31	1	0.00000000	0.00000000	51	1	0.00037326	0.00004484	71	1	0.00202433	0.00024317	91	1	0.00186563	0.00022411
12	1	0.00162791	0.00019555	32	1	0.00464379	0.00055784	52	1	0.00509465	0.00061200	72	1	0.00005012	0.00000602	92	1	0.00163616	0.00019655
13	1	0.00000664	0.00000080	33	1	0.00117724	0.00014142	53	1	0.00069276	0.00008322	73	1	0.00212949	0.00025581	93	1	0.00165334	0.00019861
14	1	0.00483071	0.00058029	34	1	0.00091452	0.00010986	54	1	0.00155241	0.00018648	74	1	0.00065345	0.00007850	94	1	0.00122547	0.00014721
15	1	0.00022485	0.00002701	35	1	0.00208748	0.00025076	55	1	0.00187718	0.00022550	75	1	0.00033077	0.00003973	95	1	0.00162213	0.00019486
16	1	0.00169887	0.00020408	36	1	0.00080268	0.00009642	56	1	0.00046358	0.00005569	76	1	0.00058417	0.00007017	96	1	0.00077889	0.00009357
17	1	0.00168510	0.00020242	37	1	0.00060707	0.00007292	57	1	0.00000000	0.00000000	77	1	0.00060888	0.00007314	97	1	0.00005775	0.00000694
18	1	0.00349076	0.00041933	38	1	0.00010667	0.00001281	58	1	0.00158564	0.00019048	78	1	0.00094793	0.00011387	98	1	0.00108131	0.00012989
19	1	0.00030229	0.00003631	39	1	0.00123174	0.00014796	59	1	0.00167664	0.00020141	79	1	0.00216836	0.00026048	99	1	0.00201745	0.00024235

100	1	0.00120536	0.00014480	135	1	0.00094207	0.00011317	170	1	0.00031064	0.00003732	205	1	0.00145363	0.00017462	240	1	0.00094773	0.00011385
101	1	0.00033254	0.00003995	136	1	0.00124364	0.00014939	171	1	0.00162365	0.00019504	206	1	0.00255197	0.00030656	241	1	0.00131644	0.00015814
102	1	0.00144013	0.00017300	137	1	0.00192089	0.00023075	172	1	0.00038013	0.00004566	207	1	0.00015017	0.00001804	242	1	0.00212767	0.00025559
103	1	0.00191353	0.00022986	138	1	0.00196523	0.00023607	173	1	0.00200237	0.00024054	208	1	0.00134599	0.00016169	243	1	0.00107997	0.00012973
104	1	0.00186926	0.00022455	139	1	0.00089843	0.00010792	174	1	0.00048376	0.00005811	209	1	0.00104802	0.00012589	244	1	0.00051956	0.00006241
105	1	0.00125045	0.00015021	140	1	0.00041033	0.00004929	175	1	0.00164399	0.00019749	210	1	0.00079111	0.00009503	245	1	0.00057750	0.00006937
106	1	0.00000000	0.00000000	141	1	0.00025752	0.00003093	176	1	0.00075309	0.00009047	211	1	0.00095767	0.00011504	246	1	0.00328051	0.00039407
107	1	0.00320139	0.00038457	142	1	0.00097794	0.00011748	177	1	0.00101698	0.00012217	212	1	0.00131010	0.00015738	247	1	0.00166440	0.00019994
108	1	0.00001425	0.00000171	143	1	0.00070253	0.00008439	178	1	0.00000362	0.00000044	213	1	0.00046925	0.00005637	248	1	0.00054038	0.00006491
109	1	0.00132693	0.00015940	144	1	0.00177925	0.00021373	179	1	0.00067223	0.00008075	214	1	0.00074829	0.00008989	249	1	0.00067615	0.00008122
110	1	0.00206071	0.00024754	145	1	0.00246640	0.00029628	180	1	0.00157462	0.00018915	215	1	0.00053909	0.00006476	250	1	0.00140630	0.00016893
111	1	0.00105352	0.00012656	146	1	0.00238629	0.00028665	181	1	0.00121714	0.00014621	216	1	0.00155235	0.00018648	251	1	0.00102727	0.00012340
112	1	0.00272984	0.00032792	147	1	0.00492137	0.00059118	182	1	0.00140616	0.00016892	217	1	0.00058755	0.00007058	252	1	0.00010074	0.00001210
113	1	0.00015344	0.00001843	148	1	0.00155608	0.00018693	183	1	0.00220901	0.00026536	218	1	0.00002910	0.00000350	253	1	0.00049693	0.00005969
114	1	0.00194101	0.00023316	149	1	0.00141155	0.00016956	184	1	0.00012719	0.00001528	219	1	0.00279350	0.00033557	254	1	0.00127280	0.00015290
115	1	0.00000102	0.00000012	150	1	0.00101667	0.00012213	185	1	0.00105122	0.00012628	220	1	0.00063230	0.00007595	255	1	0.00171648	0.00020619
116	1	0.00071746	0.00008619	151	1	0.00076852	0.00009232	186	1	0.00118380	0.00014220	221	1	0.00110194	0.00013237	256	1	0.00029149	0.00003502
117	1	0.00095693	0.00011495	152	1	0.00167021	0.00020063	187	1	0.00024198	0.00002907	222	1	0.00056812	0.00006825	257	1	0.00113822	0.00013673
118	1	0.00163977	0.00019698	153	1	0.00055575	0.00006676	188	1	0.00306364	0.00036802	223	1	0.00094906	0.00011401	258	1	0.00052726	0.00006334
119	1	0.00078947	0.00009484	154	1	0.00105238	0.00012642	189	1	0.00199894	0.00024012	224	1	0.00072127	0.00008664	259	1	0.00018727	0.00002250
120	1	0.00143503	0.00017238	155	1	0.00004772	0.00000573	190	1	0.00051687	0.00006209	225	1	0.00220854	0.00026530	260	1	0.00095156	0.00011431
121	1	0.00170834	0.00020522	156	1	0.00000262	0.00000031	191	1	0.00019342	0.00002323	226	1	0.00143234	0.00017206	261	1	0.00113438	0.00013627
122	1	0.00142871	0.00017162	157	1	0.00256642	0.00030829	192	1	0.00144757	0.00017389	227	1	0.00005327	0.00000640	262	1	0.00048320	0.00005804
123	1	0.00067351	0.00008091	158	1	0.00254535	0.00030576	193	1	0.00200135	0.00024041	228	1	0.00176132	0.00021158	263	1	0.00091311	0.00010969
124	1	0.00174702	0.00020986	159	1	0.00064732	0.00007776	194	1	0.00064504	0.00007749	229	1	0.00144820	0.00017397	264	1	0.00038903	0.00004673
125	1	0.00076416	0.00009180	160	1	0.00008295	0.00000996	195	1	0.00239381	0.00028756	230	1	0.00032885	0.00003950	265	1	0.00000001	0.00000000
126	1	0.00096863	0.00011636	161	1	0.00178368	0.00021427	196	1	0.00200915	0.00024135	231	1	0.00250974	0.00030148	266	1	0.00169173	0.00020322
127	1	0.00124326	0.00014935	162	1	0.00080497	0.00009670	197	1	0.00071728	0.00008616	232	1	0.00000000	0.00000000	267	1	0.00039391	0.00004732
128	1	0.00348113	0.00041817	163	1	0.00147403	0.00017707	198	1	0.00000268	0.00000032	233	1	0.00049517	0.00005948	268	1	0.00088488	0.00010630
129	1	0.00082093	0.00009861	164	1	0.00049158	0.00005905	199	1	0.00116516	0.00013997	234	1	0.00091883	0.00011037	269	1	0.00153919	0.00018490
130	1	0.00047913	0.00005756	165	1	0.00034046	0.00004090	200	1	0.00259034	0.00031117	235	1	0.00189681	0.00022786	270	1	0.00022276	0.00002676
131	1	0.00337151	0.00040500	166	1	0.00120482	0.00014473	201	1	0.00097382	0.00011698	236	1	0.00108953	0.00013088				
132	1	0.00000000	0.00000000	167	1	0.00095732	0.00011500	202	1	0.00038458	0.00004620	237	1	0.00139301	0.00016734				
133	1	0.00133868	0.00016081	168	1	0.00000313	0.00000038	203	1	0.00124320	0.00014934	238	1	0.00179967	0.00021619				
134	1	0.00007442	0.00000894	169	1	0.00163063	0.00019588	204	1	0.00070856	0.00008512	239	1	0.00005461	0.00000656				

Prilog 25. *Opterećenje potrošača pri maksimalnoj vrijednosti nesimetrije – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	34	1	0.00064110	0.00009135	68	1	0.00103114	0.00014693	102	1	0.00118985	0.00016954	136	1	0.00094944	0.00013529
1	1	0.00446280	0.00063591	35	1	0.00152001	0.00021659	69	1	0.00085434	0.00012174	103	1	0.00133051	0.00018959	137	1	0.00146409	0.00020862
2	1	0.00038045	0.00005421	36	1	0.00088780	0.00012650	70	1	0.00189185	0.00026957	104	1	0.00186439	0.00026566	138	1	0.00150800	0.00021488
3	1	0.00134710	0.00019195	37	1	0.00040658	0.00005793	71	1	0.00170805	0.00024338	105	1	0.00089450	0.00012746	139	1	0.00071749	0.00010224
4	1	0.00192125	0.00027376	38	1	0.00008419	0.00001200	72	1	0.00008705	0.00001240	106	1	0.00000008	0.00000001	140	1	0.00032613	0.00004647
5	1	0.00073649	0.00010494	39	1	0.00093457	0.00013317	73	1	0.00151564	0.00021597	107	1	0.00238155	0.00033935	141	1	0.00021245	0.00003027
6	1	0.00192465	0.00027425	40	1	0.00067457	0.00009612	74	1	0.00053689	0.00007650	108	1	0.00001360	0.00000194	142	1	0.00077282	0.00011012
7	1	0.00096454	0.00013744	41	1	0.00143545	0.00020454	75	1	0.00020122	0.00002867	109	1	0.00103320	0.00014722	143	1	0.00054630	0.00007784
8	1	0.00109956	0.00015668	42	1	0.00106314	0.00015149	76	1	0.00030297	0.00004317	110	1	0.00148443	0.00021152	144	1	0.00133304	0.00018995
9	1	0.00197762	0.00028180	43	1	0.00068486	0.00009759	77	1	0.00090592	0.00012909	111	1	0.00086337	0.00012302	145	1	0.00194826	0.00027761
10	1	0.00004572	0.00000652	44	1	0.00168585	0.00024022	78	1	0.00076231	0.00010862	112	1	0.00194379	0.00027698	146	1	0.00169268	0.00024119
11	1	0.00099092	0.00014120	45	1	0.00103651	0.00014770	79	1	0.00159428	0.00022717	113	1	0.00008256	0.00001176	147	1	0.00364142	0.00051887
12	1	0.00113130	0.00016120	46	1	0.00122503	0.00017456	80	1	0.00228695	0.00032587	114	1	0.00137041	0.00019527	148	1	0.00129808	0.00018497
13	1	0.00007834	0.00001116	47	1	0.00129520	0.00018456	81	1	0.00047957	0.00006833	115	1	0.00000181	0.00000026	149	1	0.00106830	0.00015222
14	1	0.00393116	0.00056016	48	1	0.00086957	0.00012391	82	1	0.00056925	0.00008111	116	1	0.00044958	0.00006406	150	1	0.00082362	0.00011736
15	1	0.00018547	0.00002643	49	1	0.00087226	0.00012429	83	1	0.00073963	0.00010539	117	1	0.00069876	0.00009957	151	1	0.00054327	0.00007741
16	1	0.00151438	0.00021579	50	1	0.00001354	0.00000193	84	1	0.00129556	0.00018461	118	1	0.00125255	0.00017848	152	1	0.00132832	0.00018927
17	1	0.00131615	0.00018754	51	1	0.00026650	0.00003797	85	1	0.00096095	0.00013693	119	1	0.00054821	0.00007812	153	1	0.00039081	0.00005569
18	1	0.00198408	0.00028272	52	1	0.00382613	0.00054519	86	1	0.00000000	0.00000000	120	1	0.00110575	0.00015756	154	1	0.00073943	0.00010536
19	1	0.00011437	0.00001630	53	1	0.00049067	0.00006992	87	1	0.00258527	0.00036838	121	1	0.00146797	0.00020917	155	1	0.00002720	0.00000388
20	1	0.00000024	0.00000003	54	1	0.00113957	0.00016238	88	1	0.00067203	0.00009576	122	1	0.00107810	0.00015362	156	1	0.00000049	0.00000007
21	1	0.00056594	0.00008064	55	1	0.00171838	0.00024486	89	1	0.00097310	0.00013866	123	1	0.00019496	0.00002778	157	1	0.00193884	0.00027627
22	1	0.00000019	0.00000003	56	1	0.00043198	0.00006155	90	1	0.00072858	0.00010382	124	1	0.00137990	0.00019663	158	1	0.00176390	0.00025134
23	1	0.00152967	0.00021797	57	1	0.00000000	0.00000000	91	1	0.00156338	0.00022277	125	1	0.00055802	0.00007951	159	1	0.00046855	0.00006676
24	1	0.00266462	0.00037969	58	1	0.00091808	0.00013082	92	1	0.00120897	0.00017227	126	1	0.00079877	0.00011382	160	1	0.00001882	0.00000268
25	1	0.00340914	0.00048578	59	1	0.00135809	0.00019352	93	1	0.00133530	0.00019027	127	1	0.00096163	0.00013703	161	1	0.00165226	0.00023543
26	1	0.00082751	0.00011791	60	1	0.00155746	0.00022193	94	1	0.00093672	0.00013348	128	1	0.00264074	0.00037629	162	1	0.00070332	0.00010022
27	1	0.00175120	0.00024953	61	1	0.00122379	0.00017438	95	1	0.00126339	0.00018002	129	1	0.00080328	0.00011446	163	1	0.00117067	0.00016681
28	1	0.00000006	0.00000001	62	1	0.00038041	0.00005420	96	1	0.00057790	0.00008235	130	1	0.00055430	0.00007898	164	1	0.00033714	0.00004804
29	1	0.00075673	0.00010783	63	1	0.00001599	0.00000228	97	1	0.00007742	0.00001103	131	1	0.00197384	0.00028126	165	1	0.00026377	0.00003758
30	1	0.00105077	0.00014973	64	1	0.00087570	0.00012478	98	1	0.00079745	0.00011363	132	1	0.00000000	0.00000000	166	1	0.00099898	0.00014235
31	1	0.00000000	0.00000000	65	1	0.00010619	0.00001513	99	1	0.00167319	0.00023842	133	1	0.00089063	0.00012691	167	1	0.00065418	0.00009322
32	1	0.00219978	0.00031345	66	1	0.00228993	0.00032630	100	1	0.00121505	0.00017313	134	1	0.00009414	0.00001341	168	1	0.00000063	0.00000009
33	1	0.00084878	0.00012095	67	1	0.00166129	0.00023672	101	1	0.00079208	0.00011287	135	1	0.00076897	0.00010957	169	1	0.00115157	0.00016409

170	1	0.00024613	0.00003507	191	1	0.00030496	0.00004346	212	1	0.00084160	0.00011992	233	1	0.00042441	0.00006048	254	1	0.00090712	0.00012926
171	1	0.00115757	0.00016494	192	1	0.00105591	0.00015046	213	1	0.00035095	0.00005001	234	1	0.00161395	0.00022998	255	1	0.00127813	0.00018212
172	1	0.00030148	0.00004296	193	1	0.00144142	0.00020539	214	1	0.00062464	0.00008901	235	1	0.00130485	0.00018593	256	1	0.00026680	0.00003802
173	1	0.00154950	0.00022079	194	1	0.00072178	0.00010285	215	1	0.00042626	0.00006074	236	1	0.00106179	0.00015130	257	1	0.00096103	0.00013694
174	1	0.00040125	0.00005718	195	1	0.00179982	0.00025646	216	1	0.00118743	0.00016920	237	1	0.00094587	0.00013478	258	1	0.00038503	0.00005486
175	1	0.00148270	0.00021127	196	1	0.00138893	0.00019791	217	1	0.00047239	0.00006731	238	1	0.00141675	0.00020188	259	1	0.00024603	0.00003506
176	1	0.00067546	0.00009625	197	1	0.00053396	0.00007609	218	1	0.00002138	0.00000305	239	1	0.00004415	0.00000629	260	1	0.00068273	0.00009728
177	1	0.00077454	0.00011037	198	1	0.00000193	0.00000028	219	1	0.00188734	0.00026893	240	1	0.00073740	0.00010507	261	1	0.00077604	0.00011058
178	1	0.00000489	0.00000070	199	1	0.00088161	0.00012562	220	1	0.00052535	0.00007486	241	1	0.00098988	0.00014105	262	1	0.00033835	0.00004821
179	1	0.00060304	0.00008593	200	1	0.00172151	0.00024530	221	1	0.00080666	0.00011494	242	1	0.00158873	0.00022638	263	1	0.00069981	0.00009972
180	1	0.00122098	0.00017398	201	1	0.00085015	0.00012114	222	1	0.00050312	0.00007169	243	1	0.00079897	0.00011385	264	1	0.00015308	0.00002181
181	1	0.00087060	0.00012405	202	1	0.00023096	0.00003291	223	1	0.00074251	0.00010580	244	1	0.00038857	0.00005537	265	1	0.00002611	0.00000372
182	1	0.00079605	0.00011343	203	1	0.00077734	0.00011076	224	1	0.00058193	0.00008292	245	1	0.00044226	0.00006302	266	1	0.00137429	0.00019583
183	1	0.00140061	0.00019958	204	1	0.00113087	0.00016114	225	1	0.00162654	0.00023177	246	1	0.00219328	0.00031253	267	1	0.00086892	0.00012381
184	1	0.00011364	0.00001619	205	1	0.00106016	0.00015106	226	1	0.00099156	0.00014129	247	1	0.00106995	0.00015246	268	1	0.00110974	0.00015813
185	1	0.00080904	0.00011528	206	1	0.00192727	0.00027462	227	1	0.00001397	0.00000199	248	1	0.00040962	0.00005837	269	1	0.00169095	0.00024095
186	1	0.00087839	0.00012516	207	1	0.00015569	0.00002218	228	1	0.00131424	0.00018727	249	1	0.00056059	0.00007988	270	1	0.00034918	0.00004976
187	1	0.00021341	0.00003041	208	1	0.00100725	0.00014353	229	1	0.00111790	0.00015929	250	1	0.00115914	0.00016517				
188	1	0.00251550	0.00035844	209	1	0.00085455	0.00012177	230	1	0.00018704	0.00002665	251	1	0.00073180	0.00010428				
189	1	0.00127288	0.00018138	210	1	0.00056821	0.00008097	231	1	0.00211326	0.00030112	252	1	0.00001871	0.00000267				
190	1	0.00043944	0.00006262	211	1	0.00073820	0.00010519	232	1	0.00000000	0.00000000	253	1	0.00067951	0.00009683				

Prilog 26. *Opterećenje potrošača pri minimalnoj vrijednosti nesimetrije – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	12	1	0.00119381	0.00018510	24	1	0.00281187	0.00043598	36	1	0.00093686	0.00014526	48	1	0.00091763	0.00014228
1	1	0.00470942	0.00073020	13	1	0.00008264	0.00001281	25	1	0.00359651	0.00055764	37	1	0.00042892	0.00006650	49	1	0.00092046	0.00014272
2	1	0.00040136	0.00006223	14	1	0.00414841	0.00064321	26	1	0.00087299	0.00013536	38	1	0.00008882	0.00001377	50	1	0.00001429	0.00000222
3	1	0.00142114	0.00022035	15	1	0.00019566	0.00003034	27	1	0.00184746	0.00028645	39	1	0.00098621	0.00015291	51	1	0.00028123	0.00004360
4	1	0.00202685	0.00031426	16	1	0.00159807	0.00024778	28	1	0.00000006	0.00000001	40	1	0.00071185	0.00011037	52	1	0.00403643	0.00062585
5	1	0.00077697	0.00012047	17	1	0.00138849	0.00021529	29	1	0.00079854	0.00012381	41	1	0.00151435	0.00023480	53	1	0.00051763	0.00008026
6	1	0.00203044	0.00031482	18	1	0.00209313	0.00032454	30	1	0.00110853	0.00017188	42	1	0.00112157	0.00017390	54	1	0.00120220	0.00018640
7	1	0.00101785	0.00015782	19	1	0.00012069	0.00001871	31	1	0.00000000	0.00000000	43	1	0.00072250	0.00011202	55	1	0.00181282	0.00028108
8	1	0.00115999	0.00017986	20	1	0.00000026	0.00000004	32	1	0.00232135	0.00035993	44	1	0.00177901	0.00027584	56	1	0.00045586	0.00007068
9	1	0.00208691	0.00032358	21	1	0.00059704	0.00009257	33	1	0.00089543	0.00013884	45	1	0.00109379	0.00016959	57	1	0.00000000	0.00000000
10	1	0.00004824	0.00000748	22	1	0.00000020	0.00000003	34	1	0.00067653	0.00010490	46	1	0.00129236	0.00020038	58	1	0.00096882	0.00015022
11	1	0.00104538	0.00016209	23	1	0.00161421	0.00025028	35	1	0.00160355	0.00024863	47	1	0.00136639	0.00021186	59	1	0.00143314	0.00022221

60	1	0.00164306	0.00025476	97	1	0.00008167	0.00001266	134	1	0.00009929	0.00001540	171	1	0.00122090	0.00018930	208	1	0.00106146	0.00016458
61	1	0.00129105	0.00020018	98	1	0.00084108	0.00013041	135	1	0.00081035	0.00012565	172	1	0.00031797	0.00004930	209	1	0.00090054	0.00013963
62	1	0.00040129	0.00006222	99	1	0.00176565	0.00027377	136	1	0.00100054	0.00015513	173	1	0.00163289	0.00025318	210	1	0.00059929	0.00009292
63	1	0.00001686	0.00000261	100	1	0.00128219	0.00019880	137	1	0.00154420	0.00023943	174	1	0.00042320	0.00006562	211	1	0.00077793	0.00012062
64	1	0.00092383	0.00014324	101	1	0.00083556	0.00012955	138	1	0.00159050	0.00024661	175	1	0.00156382	0.00024247	212	1	0.00088690	0.00013751
65	1	0.00011205	0.00001737	102	1	0.00125517	0.00019462	139	1	0.00075675	0.00011733	176	1	0.00071241	0.00011046	213	1	0.00037015	0.00005739
66	1	0.00241579	0.00037457	103	1	0.00140355	0.00021762	140	1	0.00034398	0.00005333	177	1	0.00081623	0.00012656	214	1	0.00065826	0.00010206
67	1	0.00175259	0.00027174	104	1	0.00196742	0.00030505	141	1	0.00022389	0.00003471	178	1	0.00000516	0.00000080	215	1	0.00044921	0.00006965
68	1	0.00108781	0.00016867	105	1	0.00094361	0.00014631	142	1	0.00081510	0.00012638	179	1	0.00063603	0.00009862	216	1	0.00125133	0.00019402
69	1	0.00090124	0.00013974	106	1	0.00000009	0.00000001	143	1	0.00057619	0.00008934	180	1	0.00128778	0.00019967	217	1	0.00049781	0.00007719
70	1	0.00199583	0.00030946	107	1	0.00251316	0.00038967	144	1	0.00140597	0.00021800	181	1	0.00091823	0.00014237	218	1	0.00002253	0.00000349
71	1	0.00180182	0.00027937	108	1	0.00001434	0.00000222	145	1	0.00205485	0.00031861	182	1	0.00083960	0.00013018	219	1	0.00198891	0.00030838
72	1	0.00009184	0.00001424	109	1	0.00108972	0.00016896	146	1	0.00178528	0.00027681	183	1	0.00147723	0.00022905	220	1	0.00055362	0.00008584
73	1	0.00159894	0.00024792	110	1	0.00156592	0.00024280	147	1	0.00383739	0.00059499	184	1	0.00011976	0.00001857	221	1	0.00085007	0.00013180
74	1	0.00056639	0.00008782	111	1	0.00091076	0.00014121	148	1	0.00136794	0.00021210	185	1	0.00085259	0.00013219	222	1	0.00053020	0.00008221
75	1	0.00021234	0.00003292	112	1	0.00205014	0.00031788	149	1	0.00112674	0.00017470	186	1	0.00092567	0.00014353	223	1	0.00078247	0.00012132
76	1	0.00031960	0.00004955	113	1	0.00008709	0.00001350	150	1	0.00086795	0.00013458	187	1	0.00022508	0.00003490	224	1	0.00061325	0.00009509
77	1	0.00095565	0.00014817	114	1	0.00144564	0.00022415	151	1	0.00057299	0.00008884	188	1	0.00265312	0.00041137	225	1	0.00171408	0.00026577
78	1	0.00080416	0.00012469	115	1	0.00000190	0.00000030	152	1	0.00139980	0.00021704	189	1	0.00134138	0.00020798	226	1	0.00104493	0.00016202
79	1	0.00168180	0.00026076	116	1	0.00047426	0.00007353	153	1	0.00041184	0.00006386	190	1	0.00046348	0.00007186	227	1	0.00001472	0.00000228
80	1	0.00241249	0.00037406	117	1	0.00073712	0.00011429	154	1	0.00077989	0.00012092	191	1	0.00032138	0.00004983	228	1	0.00138497	0.00021474
81	1	0.00050590	0.00007844	118	1	0.00132131	0.00020487	155	1	0.00002869	0.00000445	192	1	0.00111274	0.00017253	229	1	0.00117806	0.00018266
82	1	0.00060050	0.00009311	119	1	0.00057830	0.00008967	156	1	0.00000052	0.00000008	193	1	0.00152028	0.00023572	230	1	0.00019728	0.00003059
83	1	0.00078050	0.00012102	120	1	0.00116645	0.00018086	157	1	0.00204319	0.00031680	194	1	0.00076063	0.00011794	231	1	0.00222699	0.00034530
84	1	0.00136669	0.00021191	121	1	0.00154856	0.00024011	158	1	0.00186041	0.00028846	195	1	0.00189829	0.00029433	232	1	0.00000000	0.00000000
85	1	0.00101405	0.00015723	122	1	0.00113728	0.00017634	159	1	0.00049418	0.00007662	196	1	0.00146368	0.00022695	233	1	0.00044725	0.00006935
86	1	0.00000000	0.00000000	123	1	0.00020562	0.00003188	160	1	0.00001984	0.00000308	197	1	0.00056318	0.00008732	234	1	0.00170081	0.00026371
87	1	0.00272719	0.00042285	124	1	0.00145565	0.00022570	161	1	0.00174266	0.00027020	198	1	0.00000204	0.00000032	235	1	0.00137624	0.00021339
88	1	0.00070917	0.00010996	125	1	0.00058866	0.00009127	162	1	0.00074179	0.00011502	199	1	0.00092985	0.00014417	236	1	0.00111988	0.00017364
89	1	0.00102687	0.00015922	126	1	0.00084262	0.00013065	163	1	0.00123472	0.00019144	200	1	0.00181416	0.00028129	237	1	0.00099762	0.00015468
90	1	0.00076858	0.00011917	127	1	0.00101477	0.00015734	164	1	0.00035559	0.00005513	201	1	0.00089590	0.00013891	238	1	0.00149426	0.00023169
91	1	0.00164977	0.00025580	128	1	0.00278571	0.00043193	165	1	0.00027820	0.00004313	202	1	0.00024339	0.00003774	239	1	0.00004653	0.00000721
92	1	0.00127534	0.00019774	129	1	0.00084738	0.00013139	166	1	0.00105363	0.00016337	203	1	0.00081987	0.00012712	240	1	0.00077775	0.00012059
93	1	0.00140860	0.00021840	130	1	0.00058463	0.00009065	167	1	0.00068997	0.00010698	204	1	0.00119274	0.00018493	241	1	0.00104315	0.00016174
94	1	0.00098849	0.00015327	131	1	0.00208220	0.00032285	168	1	0.00000066	0.00000010	205	1	0.00111816	0.00017337	242	1	0.00167565	0.00025981
95	1	0.00133321	0.00020671	132	1	0.00000000	0.00000000	169	1	0.00121458	0.00018832	206	1	0.00203099	0.00031491	243	1	0.00084268	0.00013066
96	1	0.00060963	0.00009452	133	1	0.00093936	0.00014565	170	1	0.00025959	0.00004025	207	1	0.00016407	0.00002544	244	1	0.00040983	0.00006354

245	1	0.00046607	0.00007226	251	1	0.00077119	0.00011957	257	1	0.00101361	0.00015716	263	1	0.00073747	0.00011435	269	1	0.00178196	0.00027629
246	1	0.00231327	0.00035867	252	1	0.00001973	0.00000306	258	1	0.00040609	0.00006296	264	1	0.00016132	0.00002501	270	1	0.00036797	0.00005705
247	1	0.00112849	0.00017497	253	1	0.00071669	0.00011112	259	1	0.00025927	0.00004020	265	1	0.00002752	0.00000427				
248	1	0.00043203	0.00006699	254	1	0.00095594	0.00014822	260	1	0.00071947	0.00011155	266	1	0.00144825	0.00022455				
249	1	0.00059076	0.00009160	255	1	0.00134806	0.00020902	261	1	0.00081780	0.00012680	267	1	0.00091568	0.00014198				
250	1	0.00122152	0.00018940	256	1	0.00028116	0.00004359	262	1	0.00035656	0.00005529	268	1	0.00116946	0.00018133				

Prilog 27. *Opterećenje potrošača pri prosječnoj vrijednosti nesimetrije – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	27	1	0.00201221	0.00028453	54	1	0.00130942	0.00018515	81	1	0.00055104	0.00007792	108	1	0.00001563	0.00000221
1	1	0.00512795	0.00072509	28	1	0.00000007	0.00000001	55	1	0.00197449	0.00027919	82	1	0.00065409	0.00009249	109	1	0.00118680	0.00016781
2	1	0.00043715	0.00006181	29	1	0.00086951	0.00012295	56	1	0.00049637	0.00007019	83	1	0.00084987	0.00012017	110	1	0.00170567	0.00024118
3	1	0.00154787	0.00021887	30	1	0.00120738	0.00017072	57	1	0.00000000	0.00000000	84	1	0.00148866	0.00021050	111	1	0.00099204	0.00014027
4	1	0.00220760	0.00031215	31	1	0.00000000	0.00000000	58	1	0.00105491	0.00014916	85	1	0.00110417	0.00015613	112	1	0.00223278	0.00031571
5	1	0.00084625	0.00011966	32	1	0.00252765	0.00035741	59	1	0.00156050	0.00022065	86	1	0.00000000	0.00000000	113	1	0.00009486	0.00001341
6	1	0.00221151	0.00031271	33	1	0.00097529	0.00013791	60	1	0.00178959	0.00025305	87	1	0.00297058	0.00042004	114	1	0.00157465	0.00022266
7	1	0.00110830	0.00015671	34	1	0.00073666	0.00010416	61	1	0.00140619	0.00019883	88	1	0.00077219	0.00010919	115	1	0.00000207	0.00000029
8	1	0.00126344	0.00017865	35	1	0.00174655	0.00024696	62	1	0.00043710	0.00006181	89	1	0.00111813	0.00015810	116	1	0.00051658	0.00007304
9	1	0.00227237	0.00032131	36	1	0.00102012	0.00014424	63	1	0.00001837	0.00000260	90	1	0.00083717	0.00011838	117	1	0.00080290	0.00011353
10	1	0.00005254	0.00000743	37	1	0.00046717	0.00006606	64	1	0.00100621	0.00014228	91	1	0.00179639	0.00025401	118	1	0.00143923	0.00020351
11	1	0.00113861	0.00016100	38	1	0.00009674	0.00001368	65	1	0.00012201	0.00001725	92	1	0.00138915	0.00019643	119	1	0.00062991	0.00008907
12	1	0.00129991	0.00018381	39	1	0.00107386	0.00015184	66	1	0.00263123	0.00037205	93	1	0.00153431	0.00021695	120	1	0.00127055	0.00017966
13	1	0.00009001	0.00001273	40	1	0.00077511	0.00010960	67	1	0.00190889	0.00026992	94	1	0.00107634	0.00015219	121	1	0.00168676	0.00023851
14	1	0.00451708	0.00063871	41	1	0.00164939	0.00023322	68	1	0.00118482	0.00016753	95	1	0.00145169	0.00020527	122	1	0.00123878	0.00017516
15	1	0.00021311	0.00003013	42	1	0.00122159	0.00017273	69	1	0.00098168	0.00013881	96	1	0.00066403	0.00009389	123	1	0.00022394	0.00003166
16	1	0.00174009	0.00024605	43	1	0.00078694	0.00011127	70	1	0.00217382	0.00030738	97	1	0.00008896	0.00001258	124	1	0.00158556	0.00022420
17	1	0.00151231	0.00021384	44	1	0.00193711	0.00027391	71	1	0.00196262	0.00027751	98	1	0.00091601	0.00012952	125	1	0.00064119	0.00009066
18	1	0.00227979	0.00032236	45	1	0.00119100	0.00016841	72	1	0.00010003	0.00001414	99	1	0.00192256	0.00027185	126	1	0.00091782	0.00012978
19	1	0.00013142	0.00001858	46	1	0.00140761	0.00019904	73	1	0.00174154	0.00024625	100	1	0.00139614	0.00019741	127	1	0.00110496	0.00015624
20	1	0.00000028	0.00000004	47	1	0.00148824	0.00021044	74	1	0.00061691	0.00008723	101	1	0.00091013	0.00012869	128	1	0.00303432	0.00042905
21	1	0.00065028	0.00009195	48	1	0.00099918	0.00014128	75	1	0.00023122	0.00003269	102	1	0.00136719	0.00019332	129	1	0.00092300	0.00013051
22	1	0.00000022	0.00000003	49	1	0.00100226	0.00014172	76	1	0.00034812	0.00004922	103	1	0.00152880	0.00021617	130	1	0.00063671	0.00009003
23	1	0.00175766	0.00024853	50	1	0.00001556	0.00000220	77	1	0.00104094	0.00014719	104	1	0.00214226	0.00030292	131	1	0.00226802	0.00032070
24	1	0.00306176	0.00043293	51	1	0.00030622	0.00004330	78	1	0.00087592	0.00012386	105	1	0.00102782	0.00014533	132	1	0.00000000	0.00000000
25	1	0.00391724	0.00055390	52	1	0.00439639	0.00062165	79	1	0.00183189	0.00025903	106	1	0.00000009	0.00000001	133	1	0.00102304	0.00014466
26	1	0.00095084	0.00013445	53	1	0.00056380	0.00007972	80	1	0.00262779	0.00037157	107	1	0.00273650	0.00038694	134	1	0.00010814	0.00001529

135	1	0.00088315	0.00012488	163	1	0.00134471	0.00019014	191	1	0.00035025	0.00004953	219	1	0.00216759	0.00030650	247	1	0.00122902	0.00017378
136	1	0.00109042	0.00015419	164	1	0.00038727	0.00005476	192	1	0.00121271	0.00017148	220	1	0.00060336	0.00008531	248	1	0.00047052	0.00006653
137	1	0.00168176	0.00023780	165	1	0.00030298	0.00004284	193	1	0.00165571	0.00023412	221	1	0.00092644	0.00013100	249	1	0.00064383	0.00009104
138	1	0.00173219	0.00024493	166	1	0.00114750	0.00016226	194	1	0.00082896	0.00011722	222	1	0.00057783	0.00008170	250	1	0.00133126	0.00018824
139	1	0.00082416	0.00011654	167	1	0.00075143	0.00010625	195	1	0.00206740	0.00029233	223	1	0.00085276	0.00012058	251	1	0.00084047	0.00011884
140	1	0.00037462	0.00005297	168	1	0.00000072	0.00000010	196	1	0.00159517	0.00022556	224	1	0.00066834	0.00009450	252	1	0.00002149	0.00000304
141	1	0.00024400	0.00003450	169	1	0.00132278	0.00018704	197	1	0.00061335	0.00008673	225	1	0.00186806	0.00026414	253	1	0.00078053	0.00011037
142	1	0.00088772	0.00012552	170	1	0.00028272	0.00003998	198	1	0.00000222	0.00000031	226	1	0.00113880	0.00016103	254	1	0.00104181	0.00014731
143	1	0.00062752	0.00008873	171	1	0.00132967	0.00018801	199	1	0.00101268	0.00014319	227	1	0.00001604	0.00000227	255	1	0.00146815	0.00020760
144	1	0.00153123	0.00021652	172	1	0.00034630	0.00004897	200	1	0.00197714	0.00027957	228	1	0.00150939	0.00021343	256	1	0.00030642	0.00004333
145	1	0.00223790	0.00031644	173	1	0.00177958	0.00025163	201	1	0.00097638	0.00013806	229	1	0.00128389	0.00018154	257	1	0.00110391	0.00015609
146	1	0.00194433	0.00027493	174	1	0.00046090	0.00006517	202	1	0.00026526	0.00003751	230	1	0.00021485	0.00003038	258	1	0.00044227	0.00006254
147	1	0.00418213	0.00059135	175	1	0.00170314	0.00024082	203	1	0.00089291	0.00012626	231	1	0.00242705	0.00034318	259	1	0.00028256	0.00003995
148	1	0.00149083	0.00021080	176	1	0.00077588	0.00010971	204	1	0.00129899	0.00018368	232	1	0.00000000	0.00000000	260	1	0.00078411	0.00011087
149	1	0.00122712	0.00017351	177	1	0.00088956	0.00012578	205	1	0.00121777	0.00017219	233	1	0.00048743	0.00006892	261	1	0.00089127	0.00012603
150	1	0.00094592	0.00013375	178	1	0.00000562	0.00000079	206	1	0.00221345	0.00031298	234	1	0.00185361	0.00026210	262	1	0.00038860	0.00005495
151	1	0.00062403	0.00008824	179	1	0.00069269	0.00009795	207	1	0.00017881	0.00002528	235	1	0.00149885	0.00021194	263	1	0.00080372	0.00011365
152	1	0.00152556	0.00021571	180	1	0.00140250	0.00019831	208	1	0.00115681	0.00016357	236	1	0.00121965	0.00017246	264	1	0.00017581	0.00002486
153	1	0.00044884	0.00006347	181	1	0.00100004	0.00014140	209	1	0.00098144	0.00013878	237	1	0.00108649	0.00015363	265	1	0.00002999	0.00000424
154	1	0.00084936	0.00012010	182	1	0.00091440	0.00012930	210	1	0.00065268	0.00009229	238	1	0.00162738	0.00023011	266	1	0.00157836	0.00022318
155	1	0.00003125	0.00000442	183	1	0.00160883	0.00022749	211	1	0.00084782	0.00011988	239	1	0.00005071	0.00000717	267	1	0.00099795	0.00014111
156	1	0.00000056	0.00000008	184	1	0.00013052	0.00001846	212	1	0.00096657	0.00013667	240	1	0.00084703	0.00011977	268	1	0.00127452	0.00018022
157	1	0.00222674	0.00031486	185	1	0.00092918	0.00013139	213	1	0.00040312	0.00005700	241	1	0.00113686	0.00016075	269	1	0.00194204	0.00027460
158	1	0.00202614	0.00028650	186	1	0.00100882	0.00014265	214	1	0.00071740	0.00010144	242	1	0.00182492	0.00025804	270	1	0.00040103	0.00005671
159	1	0.00053821	0.00007610	187	1	0.00024514	0.00003466	215	1	0.00048956	0.00006922	243	1	0.00091775	0.00012977				
160	1	0.00002162	0.00000306	188	1	0.00288948	0.00040857	216	1	0.00136375	0.00019283	244	1	0.00044634	0.00006311				
161	1	0.00189790	0.00026836	189	1	0.00146189	0.00020671	217	1	0.00054253	0.00007671	245	1	0.00050793	0.00007182				
162	1	0.00080788	0.00011423	190	1	0.00050477	0.00007137	218	1	0.00002456	0.00000347	246	1	0.00251935	0.00035624				

Prilog 28. *Opterećenje potrošača pri najvjerojatnijoj vrijednosti nesimetrije – podaci za Matpower*

Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)	Bus	Type	Pd (MW)	Qd (MVAr)
999	3	0.00000000	0.00000000	5	1	0.00070201	0.00009922	10	1	0.00004358	0.00000616	15	1	0.00017678	0.00002498	20	1	0.00000023	0.00000003
1	1	0.00425515	0.00060138	6	1	0.00183457	0.00025928	11	1	0.00094454	0.00013349	16	1	0.00144392	0.00020407	21	1	0.00053945	0.00007624
2	1	0.00036264	0.00005125	7	1	0.00091967	0.00012998	12	1	0.00107866	0.00015245	17	1	0.00125454	0.00017730	22	1	0.00000018	0.00000003
3	1	0.00128404	0.00018147	8	1	0.00104809	0.00014813	13	1	0.00007467	0.00001055	18	1	0.00189121	0.00026728	23	1	0.00145850	0.00020613
4	1	0.00183132	0.00025882	9	1	0.00188561	0.00026649	14	1	0.00374825	0.00052974	19	1	0.00010905	0.00001541	24	1	0.00254064	0.00035907

25	1	0.00324956	0.00045926	62	1	0.00036258	0.00005124	99	1	0.00159533	0.00022547	136	1	0.00090514	0.00012792	173	1	0.00147719	0.00020877
26	1	0.00078878	0.00011148	63	1	0.00001524	0.00000215	100	1	0.00115851	0.00016373	137	1	0.00139547	0.00019722	174	1	0.00038244	0.00005405
27	1	0.00166924	0.00023591	64	1	0.00083471	0.00011797	101	1	0.00075496	0.00010670	138	1	0.00143731	0.00020314	175	1	0.00141320	0.00019973
28	1	0.00000006	0.00000001	65	1	0.00010124	0.00001431	102	1	0.00113409	0.00016028	139	1	0.00068386	0.00009665	176	1	0.00064380	0.00009099
29	1	0.00072152	0.00010197	66	1	0.00218274	0.00030849	103	1	0.00126815	0.00017923	140	1	0.00031085	0.00004393	177	1	0.00073840	0.00010436
30	1	0.00100159	0.00014155	67	1	0.00158353	0.00022380	104	1	0.00177764	0.00025123	141	1	0.00020254	0.00002862	178	1	0.00000466	0.00000066
31	1	0.00000000	0.00000000	68	1	0.00098287	0.00013891	105	1	0.00085258	0.00012050	142	1	0.00073660	0.00010410	179	1	0.00057477	0.00008123
32	1	0.00209743	0.00029643	69	1	0.00081431	0.00011509	106	1	0.00000008	0.00000001	143	1	0.00052069	0.00007359	180	1	0.00116374	0.00016447
33	1	0.00080905	0.00011434	70	1	0.00180330	0.00025486	107	1	0.00227074	0.00032092	144	1	0.00127056	0.00017957	181	1	0.00082979	0.00011727
34	1	0.00061127	0.00008639	71	1	0.00162801	0.00023009	108	1	0.00001297	0.00000183	145	1	0.00185693	0.00026244	182	1	0.00075874	0.00010723
35	1	0.00144886	0.00020477	72	1	0.00008298	0.00001173	109	1	0.00098477	0.00013918	146	1	0.00161333	0.00022801	183	1	0.00133495	0.00018867
36	1	0.00084649	0.00011963	73	1	0.00144470	0.00020418	110	1	0.00141486	0.00019996	147	1	0.00347149	0.00049063	184	1	0.00010834	0.00001531
37	1	0.00038754	0.00005477	74	1	0.00051176	0.00007233	111	1	0.00082291	0.00011630	148	1	0.00123750	0.00017490	185	1	0.00077129	0.00010901
38	1	0.00008025	0.00001134	75	1	0.00019186	0.00002712	112	1	0.00185268	0.00026184	149	1	0.00101822	0.00014391	186	1	0.00083740	0.00011835
39	1	0.00089108	0.00012594	76	1	0.00028877	0.00004081	113	1	0.00007869	0.00001112	150	1	0.00078519	0.00011097	187	1	0.00020341	0.00002875
40	1	0.00064318	0.00009090	77	1	0.00086346	0.00012203	114	1	0.00130619	0.00018460	151	1	0.00051780	0.00007318	188	1	0.00239759	0.00033885
41	1	0.00136826	0.00019338	78	1	0.00072659	0.00010269	115	1	0.00000172	0.00000024	152	1	0.00126633	0.00017897	189	1	0.00121348	0.00017150
42	1	0.00101338	0.00014322	79	1	0.00151956	0.00021476	116	1	0.00042851	0.00006056	153	1	0.00037257	0.00005266	190	1	0.00041884	0.00005920
43	1	0.00065281	0.00009226	80	1	0.00217977	0.00030807	117	1	0.00066601	0.00009413	154	1	0.00070477	0.00009961	191	1	0.00029073	0.00004109
44	1	0.00160741	0.00022717	81	1	0.00045710	0.00006460	118	1	0.00119385	0.00016873	155	1	0.00002593	0.00000366	192	1	0.00100664	0.00014227
45	1	0.00098828	0.00013967	82	1	0.00054257	0.00007668	119	1	0.00052252	0.00007385	156	1	0.00000047	0.00000007	193	1	0.00137385	0.00019417
46	1	0.00116769	0.00016503	83	1	0.00070522	0.00009967	120	1	0.00105393	0.00014895	157	1	0.00184837	0.00026123	194	1	0.00068810	0.00009725
47	1	0.00123458	0.00017448	84	1	0.00123485	0.00017452	121	1	0.00139918	0.00019775	158	1	0.00168122	0.00023761	195	1	0.00171546	0.00024245
48	1	0.00082911	0.00011718	85	1	0.00091624	0.00012949	122	1	0.00102758	0.00014523	159	1	0.00044659	0.00006312	196	1	0.00132412	0.00018714
49	1	0.00083167	0.00011754	86	1	0.00000000	0.00000000	123	1	0.00018582	0.00002626	160	1	0.00001794	0.00000254	197	1	0.00050894	0.00007193
50	1	0.00001291	0.00000182	87	1	0.00246411	0.00034825	124	1	0.00131523	0.00018588	161	1	0.00157481	0.00022257	198	1	0.00000184	0.00000026
51	1	0.00025410	0.00003591	88	1	0.00064076	0.00009056	125	1	0.00053187	0.00007517	162	1	0.00067035	0.00009474	199	1	0.00084029	0.00011876
52	1	0.00364704	0.00051544	89	1	0.00092782	0.00013113	126	1	0.00076134	0.00010760	163	1	0.00111580	0.00015770	200	1	0.00164118	0.00023195
53	1	0.00046770	0.00006610	90	1	0.00069444	0.00009815	127	1	0.00091689	0.00012958	164	1	0.00032134	0.00004541	201	1	0.00081047	0.00011454
54	1	0.00108623	0.00015352	91	1	0.00149063	0.00021067	128	1	0.00251699	0.00035573	165	1	0.00025140	0.00003553	202	1	0.00022018	0.00003112
55	1	0.00163794	0.00023149	92	1	0.00115231	0.00016286	129	1	0.00076563	0.00010821	166	1	0.00095215	0.00013457	203	1	0.00074090	0.00010471
56	1	0.00041188	0.00005821	93	1	0.00127272	0.00017987	130	1	0.00052832	0.00007467	167	1	0.00062351	0.00008812	204	1	0.00107786	0.00015233
57	1	0.00000000	0.00000000	94	1	0.00089314	0.00012623	131	1	0.00188134	0.00026589	168	1	0.00000060	0.00000008	205	1	0.00101046	0.00014281
58	1	0.00087536	0.00012371	95	1	0.00120461	0.00017025	132	1	0.00000000	0.00000000	169	1	0.00109759	0.00015512	206	1	0.00183733	0.00025967
59	1	0.00129490	0.00018301	96	1	0.00055082	0.00007785	133	1	0.00084889	0.00011997	170	1	0.00023459	0.00003315	207	1	0.00014842	0.00002098
60	1	0.00148456	0.00020981	97	1	0.00007379	0.00001043	134	1	0.00008973	0.00001268	171	1	0.00110331	0.00015593	208	1	0.00096025	0.00013571
61	1	0.00116651	0.00016486	98	1	0.00076007	0.00010742	135	1	0.00073308	0.00010361	172	1	0.00028735	0.00004061	209	1	0.00081467	0.00011514

210	1	0.00054157	0.00007654	223	1	0.00070786	0.00010004	236	1	0.00101202	0.00014303	249	1	0.00053443	0.00007553	262	1	0.00032256	0.00004559
211	1	0.00070376	0.00009946	224	1	0.00055478	0.00007841	237	1	0.00090153	0.00012741	250	1	0.00110505	0.00015618	263	1	0.00066715	0.00009429
212	1	0.00080233	0.00011339	225	1	0.00155064	0.00021915	238	1	0.00135034	0.00019084	251	1	0.00069765	0.00009860	264	1	0.00014594	0.00002063
213	1	0.00033450	0.00004727	226	1	0.00094529	0.00013360	239	1	0.00004209	0.00000595	252	1	0.00001783	0.00000252	265	1	0.00002490	0.00000352
214	1	0.00059550	0.00008416	227	1	0.00001332	0.00000188	240	1	0.00070284	0.00009933	253	1	0.00064766	0.00009153	266	1	0.00131016	0.00018516
215	1	0.00040637	0.00005743	228	1	0.00125291	0.00017707	241	1	0.00094368	0.00013337	254	1	0.00086479	0.00012222	267	1	0.00082837	0.00011707
216	1	0.00113202	0.00015999	229	1	0.00106573	0.00015062	242	1	0.00151426	0.00021401	255	1	0.00121822	0.00017217	268	1	0.00105795	0.00014952
217	1	0.00045034	0.00006365	230	1	0.00017828	0.00002520	243	1	0.00076152	0.00010763	256	1	0.00025435	0.00003595	269	1	0.00161205	0.00022783
218	1	0.00002039	0.00000288	231	1	0.00201464	0.00028473	244	1	0.00037036	0.00005234	257	1	0.00091599	0.00012946	270	1	0.00033288	0.00004705
219	1	0.00179927	0.00025429	232	1	0.00000000	0.00000000	245	1	0.00042163	0.00005959	258	1	0.00036698	0.00005187				
220	1	0.00050083	0.00007078	233	1	0.00040461	0.00005718	246	1	0.00209047	0.00029545	259	1	0.00023454	0.00003315				
221	1	0.00076901	0.00010868	234	1	0.00153864	0.00021746	247	1	0.00101980	0.00014413	260	1	0.00065087	0.00009199				
222	1	0.00047964	0.00006779	235	1	0.00124369	0.00017577	248	1	0.00039042	0.00005518	261	1	0.00073983	0.00010456				

ŽIVOTOPIS

Amir Softić je rođen 30. siječnja 1964.godine u Tuzli, Bosna i Hercegovina. Osnovnu školu i matematičku gimnaziju završio je u Tuzli. Na Fakultetu elektrotehnike i mašinstva, Sveučilišta u Tuzli, obranio je diplomski rad pod nazivom "Selektivnost relejne zaštite u rudničkim jamskim mrežama", u ožujku 1996. godine. U periodu 2000–2005. godine bio je stalno uposlen u JU Mješovita srednja elektrotehnička škola u Tuzli, na mjestu profesora elektrotehničke skupine predmeta. Od 2005. godine pa sve do danas radi u JP Elektroprivreda BiH, Podružnica „Elektrodistribucija" Tuzla, Sektor Operatora distribucije, u Službi za energetske analize i kvalitetu električne energije, na mjestu Inženjera za poslove pristupa distribucijskoj mreži. Na poslijediplomskom znanstvenom studiju Fakulteta elektrotehnike u Tuzli, na odsjeku Energetska elektrotehnika, usmjeravajući modul Elektroenergetske mreže i sustavi, obranio je magistarski rad pod nazivom "Rekonfiguracija distributivnih mreža primjenom metoda stohastičke optimizacije" i stekao zvanje Magistra tehničkih znanosti iz područja elektrotehnike, 30. siječnja 2009. godine. Kao autor ili koautor učestvovao je u izradi više znanstvenih i stručnih radova objavljenih u različitim međunarodnim časopisima i konferencijama. Objavljeni znanstveni i stručni radovi su slijedeći:

1. Marinko Stojkov, Amir Softić, Mirza Atić: *„Optimizacija uklopnog stanja u distribucijskom elektroenergetskom sustavu",* Tehnički vjesnik–Technical Gazzete, Vol. 22, No 5, pp. 1297– 1303, Croatia, October 2015
2. Šeila Gruhonjić Ferhabegović, Amir Softić, Zlatan Jerković, Almira Kukavica, Aladin Subašić: *„Tretman neutralne tačke srednjenaponske distributivne mreže sa osvrtom na stanje u Podružnici Elektrodistribucija Tuzla",* BHK CIGRÉ, XII Savjetovanje Bosanskohercegovačkog komiteta, Neum, BiH, 04–08.10.2015
3. Amir Softić, Marinko Stojkov, Admir Jahić: *„Planning of Low–Voltage Distribution Networks Using Hierarchical Methods",* International Review of Electrical Engineering (IREE), Vol. 10, No 1, pp. 62–70, Italy, January–February 2015
4. Hidajet Salkić, Amir Softić: *„Nejonizirajuće zračenje u okolini elektroenergetskih postrojenja",* Deveto regionalno savjetovanje o elektrodistributivnim mrežama, CIRED, Vrnjačka Banja, Srbija, 2014
5. Hidajet Salkić, Nerdina Mehinović, Amir Softić: *„Elimination of the Influence of Electromagnetic Radiation in Transformer Station Located in the Facility",* International Review of Electrical Engineering (IREE), Vol. 8, No 1, pp. 216–226, Italy, 2013
6. Amir Softić, Šeila Gruhonjić Ferhatbegović, Hidajet Salkić, Ivo Divković, Husnija Imamović: *„Analiza uticaja solarne elektrane na distributivnu mrežu",* BHK CIGRÉ, XI Savjetovanje Bosanskohercegovačkog komiteta, Neum, BiH, 15.09–19.09.2013
7. Šeila Gruhonjić Ferhatbegović, Amir Softić: *„Provjera zone djelovanja zaštite niskonaponskih distributivnih izlaza",* BHK CIGRÉ, XI Savjetovanje Bosanskohercegovačkog komiteta, Neum, BiH, 15.09–19.09.2013

8. Šeila Gruhonjić Ferhatbegović, Amir Softić: *„Uvođenje 20 kV naponskog nivoa u distributivnoj mreži općine Gračanica“*, BHK CIGRÉ, XI Savjetovanje Bosanskohercegovačkog komiteta, Neum, BiH, 15.09–19.09.2013
9. Šeila Gruhonjić Ferhatbegović, Amir Softić, Almira Kukavica: *„Mogući koncept prelaska na direktnu transformaciju na području općine Tuzla“*, BHK CIGRÉ, XI Savjetovanje Bosanskohercegovačkog komiteta, Neum, BiH, 15.09–19.09.2013
10. Amir Softić, Ana Mikulić: *„Organizacija plana mjera za smanjenje broja prekida u elektrodistributivnoj mreži“,* 22. znanstveno–stručni skup OTO 2013, pp. 59–68, Osijek, Croatia, 25.04–26.04.2013
11. Marinko Stojkov, Mirza Atić, Amir Softić: *„Primjena neizrazite logike za kompenzaciju reaktivne energije sinkronim motorima s promjenjivim opterećenjem“,* Tehnički vjesnik–Technical Gazzete, Vol. 19, No 4, pp. 753–758, Croatia, Prosinac 2012
12. Hidajet Salkić, Amir Softić, Adnan Muharemović, Irfan Turković, Mario Klarić: *„Calculation and Measurement of Electromagnetic Fields“,* Electromagnetic Radiation, ISBN: 978–953–51–0639–5, Intech, Chapter 9, pp. 195–224, 05.06.2012
13. Hidajet Salkić, Adnan Muharemović, Amir Softić, Aida Muharemović, Omer Hadžić: *„Distribution Calculation of Wind Turbine Low Frequency Electromagnetic Fields“,* Electrotehnical Conference (MELECON), 16th IEEE Mediterranean, Yasmine Hammamet, Tunisia, 25–28. March 2012
14. Izet Džananović, Ivo Divković, Nusret Kurtalić, Šeila Gruhonjić Ferhatbegović, Amir Softić*: „Aktivnosti u pogledu dostizanja norme EN 50160 u Podružnici Elektrodistribucija Tuzla“,* BHK CIGRÉ, X Savjetovanje Bosanskohercegovačkog komiteta, Sarajevo, BiH, 25.09–29.09.2011
15. Hidajet Salkić, Zehrudin Sikira, Zlatko Salkić, Amir Softić, Dino Bačinović: *„Elimination of Electromagnetic Interference in Transformer Station“*, 19th Expert Meeting „KOMUNALNA ENERGETIKA/POWER ENGINEERING“, Maribor, Slovenia, 2010
16. Izet Džananović, Sabahudin Salihović, Amir Softić, Dženana Malkočević: *„Uticaj nerazvijenosti prenosne mreže na kvalitet električne energije na području Elektrodistribucije Tuzla“,* BHK CIGRÉ, VIII Savjetovanje Bosanskohercegovačkog komiteta, Neum, BiH, 21.10–25.10.2007
17. Izet Džananović, Sabahudin Salihović, Ivo Divković, Amir Softić: *„Ograničenje struja zemljospoja u SN mrežama na područjima Poslovnih jedinica distribucije Tuzla i Gračanica“,* BHK CIGRÉ, VIII Savjetovanje Bosanskohercegovačkog komiteta, Neum, BiH, 21.10–25.10.2007
18. Hidajet Salkić, Amir Softić, Elmir Mujkanović: *„Gasna CHP postrojenja“,* Drugo regionalno savjetovanje o elektrodistributivnim mrežama, CIRED, Zlatibor, Srbija, 17.10–20.10.2006

PROGRAMSKI KOD

```
%%ALGORITAM NEIZRAZITOG GRUPIRANJA

function [createfigure]=Kuzici_Clusteri

%Ucitavanje podataka
   load Kuzici.dat
   load Centar.dat

%Pronalazenje centra konzuma
   findcluster
   pause;

%Graficki prikaz podataka
   figure plot(Kuzici(:,1),Kuzici(:,2),'o','markersize',2,'color','r','LineWidth',1);
   hold on
   plot(Centar(1,1),Centar(1,2),'o','markersize',10,'color','black','LineWidth',2);
   H='  TS';
   text(Centar(1,1),Centar(1,2),H,'FontSize',12);
   xlabel('koordinata x');
   ylabel('koordinata y');
   title('Centar konzuma');
   pause;

%Pronalazenje clustera
   n=input('Unesi broj clustera:');
   figure
   [center,U]=fcm(Kuzici,n);
   maxU=max(U);
   l=0;
   for i=1:n
     indexi=find(U(i,:)==maxU);
     [X]=Kuzici(indexi,1);
     [Y]=Kuzici(indexi,2);
     Clusteri=[X Y];
     A=['Cluster',num2str(i),'.dat'];
     save(A,'Clusteri','-ascii','-tabs');
     [C]=dec2binvec(i-1,3);
       if i>7
          [C]=dec2binvec(i-8,3);
       end
     line(X,Y,'linestyle','none','marker','o','markersize',2,'color',[C]);
     hold on
     plot(center(i,1),center(i,2),'kx','markersize',10,'LineWidth',2);
     hold on
     G=['  ','C',num2str(i)];
     text(center(i,1),center(i,2),G,'FontSize',12);
     [P]=center(i,1);
     [Q]=center(i,2);
     Centri=[P Q];
     B=['Centar',num2str(i),'.dat'];
```

```
    save(B,'Centri','-ascii','-tabs');
    plot(Centar(1,1),Centar(1,2),'ko','markersize',10,'color','black','LineWidth',2);
    hold on
    H='  TS';
    text(Centar(1,1),Centar(1,2),H,'FontSize',12);
    xdata=[Centar(1,1),center(i,1)];
    ydata=[Centar(1,2),center(i,2)];
    line(xdata,ydata,'color','black','LineWidth',1);
    hold on
    l=l+1;
  end
  xlabel('koordinata x');
  ylabel('koordinata y');
  title('Centri clustera');
  hold on
  pause;

%Pronalazenje podclustera
   k=input('Unesi broj podclustera:');
   for m=1:l
     A=['Cluster',num2str(m),'.dat'];
     load (A,'-ascii')
     B=['Centar',num2str(m),'.dat'];
     load (B,'-ascii')
     if m==1
       D=Cluster1;
       E=Centar1;
     else
       if m==2
         D=Cluster2;
         E=Centar2;
       else
         if m==3
           D=Cluster3;
           E=Centar3;
         else
           if m==4
             D=Cluster4;
             E=Centar4;
           else
             if m==5
               D=Cluster5;
               E=Centar5;
             else
               if m==6
                 D=Cluster6;
                 E=Centar6;
               else
                 if m==7
                   D=Cluster7;
                   E=Centar7;
```

```
                    else
                        if m==8
                            D=Cluster8;
                            E=Centar8;
                        else
                            if m==9
                                D=Cluster9;
                                E=Centar9;
                            else
                                if m==10
                                    D=Cluster10;
                                    E=Centar10;
                                else
                                    if m==11
                                        D=Cluster11;
                                        E=Centar11;
                                    else
                                        if m==12
                                            D=Cluster12;
                                            E=Centar12;
                                        else
                                            if m==13
                                                D=Cluster13;
                                                E=Centar13;
                                            else
                                                if m==14
                                                    D=Cluster14;
                                                    E=Centar14;
                                                end
                                            end
                                        end
                                    end
                                end
                            end
                        end
                    end
                end
            end
        end
    end
[center,U]=fcm(D,k);
maxU=max(U);
figure
for i=1:k
    indexi=find(U(i,:)==maxU);
    [X]=D(indexi,1);
    [Y]=D(indexi,2);
    [C]=dec2binvec(i-1,3);
```

```
        line(X,Y,'linestyle','none','marker','o','markersize',2,'color',[C]);
        hold on
        plot(center(i,1),center(i,2),'kx','markersize',5,'LineWidth',2);
        hold on
        Z=['  C',num2str(m),num2str(i)];
        text(center(i,1),center(i,2),Z,'FontSize',8);
        [R]=center(i,1);
        [V]=center(i,2);
        PodCentri=[R V];
        W=['PodCentar',num2str(m),num2str(i),'.dat'];
        save(W,'PodCentri','-ascii','-tabs');
        plot(E(1,1),E(1,2),'kx','markersize',10,'color','black','LineWidth',2);
        hold on
        R=['  C',num2str(m)];
        text(E(1,1),E(1,2),R,'FontSize',10);
        xdata=[E(1,1),center(i,1)];
        ydata=[E(1,2),center(i,2)];
        line(xdata,ydata,'linestyle','--','color','black','LineWidth',1);
        hold on
        plot(Centar(1,1),Centar(1,2),'ko','markersize',10,'color','black','LineWidth',2);
        hold on
        H='  TS';
        text(Centar(1,1),Centar(1,2),H,'FontSize',12);
        xdata=[Centar(1,1),E(1,1)];
        ydata=[Centar(1,2),E(1,2)];
        line(xdata,ydata,'color','black','LineWidth',2);
        hold on
    end
end
xlabel('koordinata x');
ylabel('koordinata y');
title('Centri podclustera');
hold on
pause;

%Clusteri i podclusteri zajedno
    figure
    for m=1:l
      A=['Cluster',num2str(m),'.dat'];
      load (A,'-ascii')
      B=['Centar',num2str(m),'.dat'];
      load (B,'-ascii')
      if m==1
        D=Cluster1;
        E=Centar1;
      else
         if m==2
           D=Cluster2;
           E=Centar2;
         else
            if m==3
```

```
  D=Cluster3;
  E=Centar3;
else
   if m==4
     D=Cluster4;
     E=Centar4;
  else
      if m==5
        D=Cluster5;
        E=Centar5;
      else
         if m==6
           D=Cluster6;
           E=Centar6;
         else
            if m==7
              D=Cluster7;
              E=Centar7;
            else
               if m==8
                 D=Cluster8;
                 E=Centar8;
               else
                  if m==9
                    D=Cluster9;
                    E=Centar9;
                  else
                     if m==10
                       D=Cluster10;
                       E=Centar10;
                     else
                        if m==11
                          D=Cluster11;
                          E=Centar11;
                        else
                           if m==12
                             D=Cluster12;
                             E=Centar12;
                           else
                              if m==13
                                D=Cluster13;
                                E=Centar13;
                              else
                                 if m==14
                                   D=Cluster14;
                                   E=Centar14;
                                 end
                              end
                           end
                        end
```

```
                                end
                            end
                        end
                    end
                end
            end
        end
    end
  end
  [center,U]=fcm(D,k);
  maxU=max(U);
  for i=1:k
     indexi=find(U(i,:)==maxU);
     [X]=D(indexi,1);
     [Y]=D(indexi,2);
     [C]=dec2binvec(i-1,3);
     line(X,Y,'linestyle','none','marker','o','markersize',2,'color',[C]);
     hold on
     PodClusteri=[X Y];
     W=['PodCluster',num2str(m),num2str(i),'.dat'];
     save(W,'PodClusteri','-ascii','-tabs');
     plot(center(i,1),center(i,2),'kd','markersize',5,'MarkerFaceColor','r','LineWidth',1);
     hold on
     Z=['  C',num2str(m),num2str(i)];
     text(center(i,1),center(i,2),Z,'FontSize',8);
     [R]=center(i,1);
     [V]=center(i,2);
     PodCentri=[R V];
     W=['PodCentar',num2str(m),num2str(i),'.dat'];
     save(W,'PodCentri','-ascii','-tabs');
     plot(E(1,1),E(1,2),'kx','markersize',10,'color','black','LineWidth',2);
     hold on
     R=['  C',num2str(m)];
     text(E(1,1),E(1,2),R,'FontSize',10);
     hold on
     plot(Centar(1,1),Centar(1,2),'ko','markersize',10,'color','black','LineWidth',2);
     hold on
     H='  TS';
     text(Centar(1,1),Centar(1,2),H,'FontSize',12);
     hold on
  end
end
xlabel('koordinata x');
ylabel('koordinata y');
title('Centri clustera i podclustera');
hold on
pause;
```

```
%%ALGORITAM SIMULIRANOG KALJENJA

function[gubici,uklj,isklj,cv_uklj,cv_isklj,isim,branch,broj_pokusaja,vrijeme]=
Softic(casename,n_prek,n_uklj)

%Podaci za algoritam simuliranog kaljenja
  T=1000;

%Read data
  [baseMVA, bus, gen, branch] = feval(casename);
  pr_baseMVA=baseMVA;
  pr_bus=bus;
  pr_gen=gen;
  pr_branch=branch;

  gubici=[];
  uspj_korak=0;
  broj_pokusaja=[];
  vrijeme=[];
  pokusaj=0;
  uklj=[];
  isklj=[];
  cv_uklj=[];
  cv_isklj=[];

  korak=0;

%Start simulacije
  t0 = clock;
  isim=0;

while 1

  isim=isim+1;

%isim
  if isim>2 && brojacp < n_prek-n_uklj
    break
  end

%Read data
  baseMVA=pr_baseMVA;
  bus=pr_bus;
  gen=pr_gen;
  branch=pr_branch;

 if isim>1
   if korak>0
     for ii=1:korak
       branch(uklj(ii),11)=1;
       branch(isklj(ii),11)=0;
     end
   end
```

```
end

n_branch=size(branch,1);
n_bus=size(bus,1);

%Formiranje matrice za nalazenje puta
  matrica_put=zeros(n_bus);
  for ii=1:n_bus
    for jj=1:n_bus
      matrica_put(ii,jj)=inf;
    end
  end
  for ii=1:n_bus
    matrica_put(ii,ii)=0;
  end
  for kk=1:n_branch
    if branch(kk,11)==1
      matrica_put(branch(kk,1),branch(kk,2))=1;
      matrica_put(branch(kk,2),branch(kk,1))=1;
    end
  end

%Nalazenje grane koja ce se ukljuciti: grana1 izmedju cvor1 i cvor2
  nadji=ceil((n_prek-n_uklj)*rand);

%nadji
  brojacp=0;
  nasao=0;
  for ii=(n_branch - n_prek + 1):n_branch
    if branch(ii,11)==0
      brojacp=brojacp+1;

     %brojacp
      if brojacp==nadji
        nasao=1;
        cvor1=branch(ii,1);
        cvor2=branch(ii,2);
        grana1=ii;
      end
    end
  end

%nasao

%Nalazenje puta izmedju cvor1 i cvor2 preko ukljucenih grana
  [sp, spcost] = dijkstra(matrica_put, cvor1, cvor2);

%cvor1
%cvor2
%sp

 %Broj prekidaca u nadjenom putu
   brojac=0;
```

```
  put=size(sp,2)-1;

%put
  for ii=(n_branch-n_prek+1):n_branch
    if branch(ii,11)==1
      for jj=1:put
        if (branch(ii,1)==sp(jj)) && (branch(ii,2)==sp(jj+1))
          brojac=brojac+1;
        end
        if (branch(ii,1)==sp(jj+1)) && (branch(ii,2)==sp(jj))
          brojac=brojac+1;
        end
      end
    end
  end

%brojacp

%Nalazenje slucajnog prekidaca izmedju nadjenih u putu
  nadji=ceil(brojac*rand);

%nadji
  brojac=0;
 for ii=(n_branch-n_prek+1):n_branch
  if branch(ii,11)==1
    for jj=1:put
      if (branch(ii,1)==sp(jj)) && (branch(ii,2)==sp(jj+1))
        brojac=brojac+1;
        if brojac==nadji
          cvor3=branch(ii,1);
          cvor4=branch(ii,2);
          grana2=ii;
        end
      end
      if (branch(ii,1)==sp(jj+1)) && (branch(ii,2)==sp(jj))
        brojac=brojac+1;
        if brojac==nadji
          cvor3=branch(ii,1);
          cvor4=branch(ii,2);
          grana2=ii;
        end
      end
    end
  end
 end

%cvor3
%cvor4
%grana2

 korak=korak+1;
 uklj(korak)=grana1;
```

```
   isklj(korak)=grana2;
   cv_uklj(korak,1)=cvor1;
   cv_uklj(korak,2)=cvor2;
   cv_isklj(korak,1)=cvor3;
   cv_isklj(korak,2)=cvor4;
   branch(grana1,11)=1;
   branch(grana2,11)=0;
end

[MVAbase, bus, gen, branch, success, et] = runpf(baseMVA, bus, gen, branch)
if success==1
   uspj_korak=uspj_korak+1;
   gubici(uspj_korak)=sum(abs(branch(:,12)+branch(:,14)));
   if uspj_korak>1
      pokusaj=pokusaj+1;
      razlika=gubici(uspj_korak)-gubici(uspj_korak-1);
      if razlika>0
         prihvatanje=exp(-razlika/T);
         granica_prihv=rand;
         if prihvatanje<granica_prihv
            korak=korak-1;
            uspj_korak=uspj_korak-1;
         else
            broj_pokusaja(uspj_korak-1)=pokusaj;
            vrijeme(uspj_korak-1)=etime(clock,t0);
            pokusaj=0;
         end
      else
         broj_pokusaja(uspj_korak-1)=pokusaj;
         vrijeme(uspj_korak-1)=etime(clock,t0);
         pokusaj=0;
      end
   end
else
   korak=korak-1;
end

%T=0.95*T
   T=0.95*T;

if T<1.e-06
   break
end
end
return;
```