

UNIVERZITET CRNE GORE
ELEKTROTEHNIČKI FAKULTET, PODGORICA



MAKSIM KONTIĆ

UNAPRJEĐENJE POGONA SREDNJENAPONSKE
ELEKTRODISTRIBUTIVNE MREŽE PRIMJENOM STRATEGIJA
AKTIVNOG UPRAVLJANJA

MASTER RAD

Podgorica, 2024. godine

PODACI I INFORMACIJE O KANDIDATU

Ime i prezime: Maksim Kontić

Datum i mjesto rođenja: 11.12.1998. godine, Nikšić, Crna Gora

Naziv završenog osnovnog studijskog programa i godina završetka studija: Energetika i automatika, 2021. godine

INFORMACIJE O MASTER RADU

Naziv master studija: Elektroenergetski sistemi

Naslov rada: Unaprjeđenje pogona srednjenačopske elektrodistributivne mreže primjenom strategija aktivnog upravljanja

Fakultet/Akademija na kojem je rad odbranjen: Elektrotehnički fakultet, Podgorica

UDK, OCJENA I ODBRANA MASTER RADA

Datum prijave master rada: 06.11.2023. godine

Datum sjednice Vijeća na kojoj je prihvaćena tema: 21.12.2023. godine

Mentor: Prof. dr Zoran Miljanić

Komisija za ocjenu rada:

1. Prof. dr Vladan Radulović, ETF Podgorica
2. Prof. dr Zoran Miljanić, ETF Podgorica
3. Doc. dr Snežana Vujošević, ETF Podgorica

Komisija za odbranu rada:

1. Prof. dr Vladan Radulović, ETF Podgorica, predsjednik
2. Prof. dr Zoran Miljanić, ETF Podgorica, mentor
3. Doc. dr Snežana Vujošević, ETF Podgorica, član

Datum odbrane: 26.09.2024. godine

Datum promocije: _____

Ime i prezime autora: Maksim Kontić, BSc

ETIČKA IZJAVA

U skladu sa članom 22 Zakona o akademskom integritetu i članom 18 Pravila studiranja na master studijama, pod krivičnom i materijalnom odgovornošću, izjavljujem da je master rad pod naslovom

"Unaprjeđenje pogona srednjenačiske elektro distributivne mreže primjenom strategija aktivnog upravljanja"

moje originalno djelo.

Podnositelj izjave,

Maksim Kontić, BSc

Максим Контић

U Podgorici, dana 28.05.2024. godine

Sažetak

Integracija obnovljivih izvora električne energije u distributivnim mrežama predstavlja značajan korak prema održivijem energetskom modelu. Ipak, ovaj korak sa sobom donosi niz izazova za operatore distributivnih mreža. Varijabilni karakter proizvodnje, zajedno s njenom neusklađenošću sa potrošnjom, često rezultira izraženim fluktuacijama napona i smanjenjem kvaliteta električne energije. Takođe, rapidan rast potrošnje, usred intenzivne elektrifikacije i integracije električnih vozila, dodatno opterećuje mrežne komponente, čime uzrokuje povećane gubitke. Uzimajući u obzir dinamiku i složenost modernih zahtjeva, distributivna mreža se mora kontinualno prilagođavati kako bi mogla da se nosi sa zahtjevima savremenog elektroenergetskog sistema. Međutim, tehnološki napredak otvara mogućnosti za brojne inovacije, pružajući priliku za razvoj inteligentnih sistema upravljanja i alata optimizacije, koji mogu adekvatno odgovoriti na ove izazove i unaprijediti performanse distributivnih mreža.

U radu je predložen pristup koji integriše više tehnika aktivnog upravljanja, uključujući rekonfiguraciju distributivne mreže i upravljanje aktivnom i reaktivnom snagom distribuiranih generatora. Centralni fokus postavljenog optimizacionog problema jeste minimizacija operativnih troškova distributivne mreže, uzimajući u obzir pogonska ograničenja kako same mreže tako i distribuiranih generatora. Za simulaciju i rješavanje ovog problema primijenjen je genetski algoritam kroz njegovu ugrađenu funkciju u MATLAB-u. Takođe, u istom programskom paketu je implementiran *DistFlow* metod za proračun tokova snaga.

Performanse predloženog metoda su testirane na 33-čvornoj IEEE testnoj srednjenjaponskoj elektrodistributivnoj mreži. Kroz komparativnu analizu je pokazana superiornost predložene metode zasnovane na genetskom algoritmu u odnosu na druge metode optimizacije, kako u smislu potrebnog broja iteracija, tako i u postizanju optimalnih vrijednosti kriterijumske funkcije. Detaljnom analizom je potvrđeno da ovaj pristup aktivnog upravljanja pruža bolje rezultate u poređenju s pristupom rekonfiguracije i kombinovanim pristupom rekonfiguracije i upravljanja reaktivnom snagom distribuiranih generatora. Simulacioni rezultati naglašavaju efikasnost predloženog metoda u očuvanju sigurnosti pogona mreže uz minimalne operativne troškove, posebno u situacijama visokih napona koji često predstavljaju izazov u savremenim elektrodistributivnim sistemima.

Ključne riječi: distributivna mreža, rekonfiguracija, distribuirani generatori, genetski algoritam

Abstract:

The integration of renewable energy sources into the distribution grids is an important step towards a more sustainable energy model. However, this step brings with it a number of challenges for distribution system operators. Fluctuating generation, which does not match consumption, often leads to large voltage fluctuations and a poorer quality of electrical energy. Furthermore, the rapid increase in consumption associated with intensive electrification and the integration of electric vehicles places additional strain on grid components and leads to increased losses. Given the dynamics and complexity of modern requirements, the distribution grid must constantly adapt to meet the demands of the modern electricity system. However, technological progress opens up opportunities for numerous innovations and offers the chance to develop intelligent management systems and optimization tools that can overcome these challenges and improve the performance of distribution grids.

The paper proposes an approach that integrates several active management techniques, including reconfiguration of the distribution network and management of active and reactive power from distributed generators. The optimization problem focuses on minimising the operating costs of the distribution network while considering the operating constraints of both the network itself and the distributed generators. A genetic algorithm with its integrated function in MATLAB was used to simulate and solve this problem. In addition, the DistFlow method for calculating power flows was implemented in the same software package.

The performance of the proposed method was tested on an IEEE medium-voltage distribution network with 33 nodes. A comparative analysis demonstrated the superiority of the genetic algorithm over other optimization methods, both in terms of the required number of iterations and in terms of achieving optimal values of the objective function. The detailed analysis confirmed that this approach for active management provides better results than the approach for reconfiguration and the combined approach for reconfiguration and reactive power management of distributed generators. The simulation results underline the efficiency of the proposed method in maintaining grid operational reliability with minimal operational costs, especially in high voltage situations, which are often a challenge in modern electrical distribution systems.

Keywords: distribution network, reconfiguration, distributed generators, genetic algorithm

Sadržaj

1. Uvod.....	1
2. Pregled istraživanja upravljanja distributivnim mrežama.....	4
2.1 Rekonfiguracija elektrodistributivne mreže	4
2.1.1 Primjena klasičnih metoda u rješavanju problema rekonfiguracije distributivnih mreža....	5
2.1.2 Primjena heurističkih metoda optimizacije u rješavanju problema rekonfiguracije distributivnih mreža	7
2.1.3 Primjena metaheurističkih metoda optimizacije u rješavanju problema rekonfiguracije distributivnih mreža	10
2.2 Kompenzacija reaktivne snage	13
2.3 Upravljanje aktivnom snagom distribuiranih generatora	16
2.4 Koordinisano punjenje električnih vozila.....	17
2.5 Upravljanje potrošnjom	19
2.6 Komparativna analiza strategija aktivnog upravljanja elektrodistributivnom mrežom.....	20
3. Predloženi metod za minimizaciju operativnih troškova	22
3.1 Kriterijumska funkcija.....	22
3.2 Ograničenja.....	25
3.3 DistFlow metod za proračun tokova snaga.....	28
3.4 Rješenje optimizacionog problema	30
3.4.1 Genetski algoritam	33
3.4.2 Optimizacija rojem čestica.....	36
3.4.3 Diferencijalna evolucija	38
4. Primjer primjene predloženog metoda	42
4.1 Ulazni podaci.....	42
4.1.1 Podaci o mreži.....	42
4.1.2 Podaci o distribuiranim generatorima	43
4.1.3 Podaci o troškovima pogona	44
4.3 Izbor metoda optimizacije	46
4.4 Rezultati numeričke analize.....	48
4.4.1 Slučaj I	49
4.4.2 Slučaj II.....	54
4.4.3 Slučaj III.....	60
5. Zaključak	72

Literatura	74
Prilog	85

Popis slika

Slika 4.1 Dnevni dijagrami opterećenja.....	43
Slika 4.2 Testna IEEE mreža sa 33 čvora	43
Slika 4.3 Prognoza iradijacije	44
Slika 4.4 Komparacija konvergencija razmatranih metoda	48
Slika 4.5 Slučaj I – Aktivna snaga distribuiranih generatora po satima	51
Slika 4.6 Slučaj I – Vrijednosti napona u čvorovima po satima.....	52
Slika 4.7 Slučaj I – Opsezi vrijednosti napona u mreži po satima.....	53
Slika 4.8 Slučaj I – Gubici aktivne snage u mreži po satima.....	54
Slika 4.9 Slučaj II – Aktivna i reaktivna snaga DG1 po satima	56
Slika 4.10 Slučaj II – Aktivna i reaktivna snaga DG2 po satima	56
Slika 4.11 Slučaj II – Aktivna i reaktivna snaga DG3 po satima	57
Slika 4.12 Slučaj II – Vrijednosti napona u čvorovima po satima	58
Slika 4.13 Slučaj II – Opsezi vrijednosti napona u mreži po satima	59
Slika 4.14 Slučaj II – Gubici aktivne snage u mreži po satima	60
Slika 4.15 Slučaj III – Aktivna i reaktivna snaga DG1 po satima	62
Slika 4.16 Slučaj III – Aktivna i reaktivna snaga DG2 po satima	62
Slika 4.17 Slučaj III – Aktivna i reaktivna snaga DG3 po satima	63
Slika 4.18 Slučaj III – Vrijednosti napona u čvorovima po satima	64
Slika 4.19 Slučaj III – Opsezi vrijednosti napona u mreži po satima	65
Slika 4.20 Slučaj III – Gubici aktivne snage u mreži po satima	66
Slika 4.21 Slučaj kada je napon NTS 1 p.u. – Aktivna i reaktivna snaga DG1 po satima	68
Slika 4.22 Slučaj kada je napon NTS 1 p.u. – Aktivna i reaktivna snaga DG2 po satima	68
Slika 4.23 Slučaj kada je napon NTS 1 p.u. – Aktivna i reaktivna snaga DG3 po satima	69
Slika 4.24 Slučaj kada je napon NTS 1 p.u. – Vrijednosti napona u čvorovima po satima	70
Slika 4.25 Slučaj kada je napon NTS 1 p.u. – Opsezi vrijednosti napona u mreži po satima	71

Popis tabela

Tabela 3.1 Prednosti i nedostaci metaheurističkih metoda	32
Tabela 4.1 Parametri metoda optimizacije	47
Tabela 4.2 Rezultati komparacije razmatranih metoda	48
Tabela 4.3 Slučaj I – Isključeni prekidači po satima.....	50
Tabela 4.4 Slučaj I – Ukupni gubici aktivne snage i operativni troškovi	54
Tabela 4.5 Slučaj II – Isključeni prekidači po satima	55
Tabela 4.6 Slučaj II – Ukupni gubici aktivne snage i operativni troškovi	60
Tabela 4.7 Slučaj III – Isključeni prekidači po satima	61
Tabela 4.8 Slučaj III – Ukupni gubici aktivne snage i operativni troškovi.....	66
Tabela 4.9 Slučaj kada je napon NTS 1 p.u. – Isključeni prekidači po satima	67
Tabela 4.10 Slučaj kada je napon NTS 1 p.u. – Ukupni gubici aktivne snage i operativni troškovi	71
Tabela P.1 Podaci o potrošačima u mreži sa 33 čvora.....	85
Tabela P.2 Podaci o granama mreže sa 33 čvora	86

1. Uvod

Elektrodistributivne mreže predstavljaju vitalni dio elektroenergetskog sistema koji omogućava raspodjelu električne energije od visokonaponskih transformatorskih stanica do krajnjih potrošača. Njihova uloga je od suštinskog značaja za osiguravanje sigurnog snabdijevanja električnom energijom u skladu sa propisanim standardima. Tokom godina, distributivne mreže su neprestano razvijane kako bi pružile što efikasniju i kvalitetniju isporuku električne energije. Tradicionalno, ove mreže su se sastojale isključivo od pasivnih elemenata kao što su vodovi, transformatori i potrošači.

Savremene elektrodistributivne mreže se suočavaju sa sve većom integracijom distribuiranih generatora i stanica za punjenje električnih vozila. Ovaj trend je posljedica postepenog iscrpljivanja resursa fosilnih goriva, potrebe za dekarbonizacijom elektroenergetskog i transportnog sektora, razvoja novih tehnologija i povećanja njihovih efikasnosti. Distribuirani generatori donose mnoge benefite pouzdanosti, održivosti i energetskoj efikasnosti. Proizvodnja električne energije u blizini potrošača može doprinositi poboljšanju naponskih prilika, smanjenju gubitaka i rasterećenju prenosne mreže. Takođe, pružaju dodatne resurse za aktivno upravljanje mrežom, omogućavajući regulaciju napona i frekvencije. Pod određenim uslovima, distribuirani generatori mogu osigurati neprekidno napajanje potrošača u slučaju havarija u elektroenergetskom sistemu. U skladu sa globalnim ekološkim ciljevima, korišćenje ovih generatora doprinosi smanjenju emisija štetnih gasova, podržavajući prelazak ka ekološki održivom energetskom modelu i postepeno ukidanje fosilnih goriva. Pored ekoloških benefita, kontrolisano punjenje električnih vozila može donijeti i pozitivne efekte distributivnim mrežama. Koordinisano punjenje i upravljanje baterijama električnih vozila omogućava prilagođavanje potrošnje u skladu sa trenutnim zahtjevima mreže, što rezultira boljom regulacijom napona i frekvencije. Vremensko raspoređivanje punjenja doprinosi izbjegavanju preopterećenja mreže tokom perioda vršnog opterećenja, smanjujući rizik od prekida napajanja i potrebu za dodatnim investicijama. Pored toga, usklađivanje punjenja sa proizvodnjom distribuiranih generatora omogućava eliminaciju nekih njihovih negativnih efekata na mrežu.

Ovaj trend integracije distribuiranih generatora narušava tradicionalnu paradigmu razvoja pasivnih, radijalno napajanih elektrodistributivnih mreža. Nekontrolisana integracija i neprikladne lokacije distribuiranih generatora predstavljaju izazov za operatore distributivnih mreža. Varijabilnost u proizvodnji, nepouzdana prognoza i neusklađenost sa potrošnjom mogu izazvati pojavu visokih napona, njihovih fluktuacija i preopterećenja elemenata. Upotreba energetskih pretvarača izaziva injektiranje viših harmonika struja i napona, potencijalno oštećujući opremu i smanjujući energetsku efikasnost. Takođe, promjene u tokovima snaga zahtijevaju prilagođavanje sistema relejne zaštite kako bi se osiguralo brzo i efikasno djelovanje.

Nekontrolisano punjenje električnih vozila u slučaju intenzivne integracije stvara brojne izazove i potencijalne štetne efekte. Povećano opterećenje uslijed nekoordinisanog punjenja može uzrokovati pad napona ispod prihvatljivog nivoa i povećanje gubitaka. Centralizovano punjenje velikog broja vozila, posebno putem brzih punjača, može izazvati preopterećenja mreže tokom vršnih perioda opterećenja. Elektronske komponente u punjačima doprinose injektiranju viših harmonika, što

negativno utiče na kvalitet električne energije i rad ostalih uređaja. Osim toga, monofazni punjači, koji se često koriste, mogu izazvati neuravnoteženost faza u mreži.

Kao potencijalno rješenje za ove probleme se nameću strategije aktivnog upravljanja elektrodistributivnom mrežom, čija je primjena zasnovana na naprednim tehnologijama poput senzora, automatizacije i algoritama za analizu podataka. Metode aktivnog upravljanja uključuju:

- Promjenu konfiguracije,
- Promjenu otcjepa regulacionih transformatora,
- Upravljanje baterijama kondenzatora i FACTS uređajima,
- Koordinisano upravljanje reaktivnim snagama distribuiranih generatora,
- Smanjenje aktivne snage distribuiranih generatora (*eng. power curtailment*),
- Koordinisano punjenje električnih vozila i
- Upravljanje potrošnjom.

Raznolikost strategija naglašava složenost i aktuelnost problema s kojima se suočavaju operatori distributivnih mreža. Implementacija ovih strategija omogućava održavanje pogonskih parametara unutar definisanih, bolju integraciju distribuiranih generatora pružajući fleksibilnost mreže u odnosu na varijacije u proizvodnji i potrošnji električne energije. Osim poboljšane sigurnosti, ove strategije doprinose i smanjenju gubitaka u mreži, što je ključno s obzirom na porast potrošnje i opterećenja elemenata.

Shodno aktuelnosti problema aktivnog upravljanja distributivnom mrežom, predmet istraživanja ovog rada jeste razvoj metoda za koordinisanu primjenu rekonfiguracije i upravljanja aktivnom i reaktivnom snagom distribuiranih generatora u cilju postizanja optimalnog pogona distributivne mreže.

Ovaj rad je strukturiran na sljedeći način:

- U drugom poglavlju ovog rada se pruža pregled postojećih metoda aktivnog upravljanja distributivnim mrežama, uzimajući u obzir predložene formulacije problema. Razmatraju se različiti pristupi, uključujući smanjenje aktivnih gubitaka, optimizaciju troškova, poboljšanje naponskog profila i povećanje pouzdanosti sistema.
- U trećem poglavlju su formulisana kriterijumska funkcija i ograničenja za predloženi metod unaprjeđenja pogona distributivne mreže. Ovaj metod obuhvata simultanu primjenu rekonfiguracije i upravljanja aktivnom i reaktivnom snagom distribuiranih generatora s fokusom na smanjenje operativnih troškova. Analizirana su ograničenja vezana za topologiju, napon, opterećenje elemenata, kao i specifična ograničenja distribuiranih generatora. Posebna pažnja je posvećena Distflow metodu za proračun tokova snaga, zbog njegove efikasnosti kod distributivnih mreža. Pored toga, pružena je analiza metoda optimizacije, uz detaljan opis nekih od najučinkovitijih modernih pristupa kao što su genetski algoritam, optimizacija rojem čestica i diferencijalna evolucija.
- U četvrtom poglavlju, analizirana je primjenjivost različitih metoda optimizacije na posmatrani problem, ističući superiornost genetskog algoritma u poređenju s drugim

pristupima. Detaljno su prikazani numerički rezultati primijenjenog metoda, koji su analizirani i upoređeni sa drugim pristupima aktivnog upravljanja.

- U poslednjem poglavlju su iznijeti zaključci sprovedenog istraživanja, dok su u prilogu predstavljeni podaci primijenjene 33-čvorne IEEE testne srednjenačinske distributivne mreže.

2. Pregled istraživanja upravljanja distributivnim mrežama

Aktivno upravljanje distributivnim mrežama postaje značajan faktor u savremenim elektroenergetskim sistemima, naročito s obzirom na sve učestaliju integraciju obnovljivih izvora energije. S obzirom na aktuelnost ovog problema i tehnološki napredak koji omogućava iskorišćavanje različitih resursa, istraživači su poslednjih godina pristupili rješavanju ovog problema sa različitim aspekata, razvijajući značajan broj pristupa i algoritama kako bi se postigao optimalan pogon mreže. Ciljevi aktivnog upravljanja uključuju smanjenje gubitaka, održavanje naponskih prilika u dozvoljenim granicama, rasterećenje vodova, minimizaciju operativnih troškova, smanjenje ekoloških uticaja i druge.

Ovo poglavlje pruža sveobuhvatan pregled različitih pristupa aktivnom upravljanju distributivnim mrežama, kako u normalnim tako i u havarijskim uslovima, ističući njihove prednosti i nedostatke. Struktura ovog pregleda literature je organizovana u nekoliko djelova kako bi se detaljno opisali i uporedili najznačajniji pristupi aktivnog upravljanja:

- Rekonfiguracija distributivne mreže,
- Kompenzacija reaktivne snage,
- Upravljanje aktivnom snagom distribuiranih generatora,
- Koordinisano punjenje električnih automobila i
- Upravljanje potrošnjom.

Takođe, posebna pažnja je posvećena raznovrsnosti alata korišćenih u implementaciji ovih pristupa. Ovo uključuje širok spektar algoritama i metoda optimizacije, uključujući klasične, heurističke i metaheurističke pristupe. Dodatno, razmatrani su i primjeri primjene vještačke inteligencije koja donosi novu dimenziju u rješavanju ovog problema, kao i Monte Karlo simulacije za modelovanje grešaka u prognozi proizvodnje i potrošnje električne energije.

2.1 Rekonfiguracija elektrodistributivne mreže

Promjena konfiguracije distributivne mreže predstavlja modifikaciju njene topologije putem promjene uklopnog stanja prekidača, sa ciljem postizanja određenih operativnih ili optimizacionih rezultata. Rekonfiguracija se sprovodi kako u normalnim radnim uslovima, tako i u havarijskim situacijama, pri čemu njeni glavni ciljevi obuhvataju [1] :

- Obnovu napajanja, kojom se omogućava snabdijevanje korisnika električnom alternativnim putem. To je dio procesa lociranja kvara, izolacije i obnove snabdijevanja,
- Smanjivanje gubitaka električne energije i
- Preraspodjela opterećenja između izvoda distributivne mreže, uz istovremeno poboljšanje naponskih prilika.

Rekonfiguracija distributivne mreže može imati bitnu ulogu kako u pripremi pogona mreže, tako i u upravljanju u realnom vremenu. Proces planiranja rekonfiguracije kao dio pripreme pogona uključuje podjelu određenog vremenskog perioda na segmente, gdje se svakom segmentu pridružuje specifična konfiguracija prema unaprijed definisanim scenarijima. Rekonfiguracija se primjenjuje u realnom vremenu s ciljem prilagođavanja topologije distributivne mreže radi održavanja pouzdanosti i efikasnosti sistema u slučaju kvarova ili neočekivanih promjena opterećenja i proizvodnje distribuiranih generatora. Ovaj pristup se zasniva na stalnom praćenju stanja mreže putem senzora i pametnih sistema, omogućavajući brzu reakciju na promjene i automatsko donošenje odluka radi optimizacije rada sistema.

Uzimajući u obzir tranziciju ka pametnim mrežama i integraciju obnovljivih izvora energije, rekonfiguracija se u savremenim distributivnim mrežama izdvaja kao ekonomična strategija u prilagođavanju globalnim energetskim trendovima. Ova evolucija je podstaknuta naprednim tehnologijama koje uključuju automatizaciju, poboljšanu upravljivost i informaciono-komunikacione tehnologije, što omogućava implementaciju daljinskih upravljaljivih prekidača (*eng. Remote Controlled Switch - RCS*) s dinamičkom primjenom algoritma rekonfiguracije, čak i na satnom nivou. Ovi algoritmi, pružajući visok nivo preciznosti i fleksibilnosti u upravljanju distributivnom mrežom, postaju bitan alat za operatore u ispunjavanju zahtjeva održivosti, pouzdanosti i prilagodljivosti.

Uobičajena praksa u distributivnim mrežama jeste usvajanje radikalne strukture, gdje postoji jedinstvena putanja od napojnog čvora do svakog potrošača. Ovaj pristup omogućava jednostavniju implementaciju relejne zaštite i smanjenja struje kratkog spoja. Usljed toga, prilikom rekonfiguracije distributivne mreže važno je poštovati dva ključna topološka ograničenja. Prvo je potrebno održati radikalnu strukturu kako bi se izbjeglo stvaranje petlji i višestrukih putanja do potrošača. Zatim je u normalnim uslovima neophodno garantovati da nijedan potrošač ne ostane izolovan, obezbjeđujući tako kontinuitet isporuke električne energije. Ova topološka ograničenja, zajedno sa pogonskim ograničenjima mreže kao što su dozvoljene vrijednosti napona čvorova i opterećenja elemenata, značajno usložnjavaju problem rekonfiguracije, kojem je u literaturi posvećena velika pažnja.

Za rješavanje problema rekonfiguracije postoji veliki broj pristupa koji se mogu podijeliti u tri glavne kategorije:

- Klasične [2-10],
- Heurističke [11-25] i
- Metaheurističke metode [26-41].

2.1.1 Primjena klasičnih metoda u rješavanju problema rekonfiguracije distributivnih mreža

Klasične metode karakteriše visoka preciznost, što garantuje pronalazak globalno optimalnog rješenja. Obično se oslanjaju na matematičke tehnike kao što su gradijentna optimizacija, linearna ili nelinearna optimizacija, konveksno programiranje i druge. Kroz iterativni postupak, ove metode konvergiraju ka optimalnom rješenju primjenom matematičkih procedura. Klasične metode često zahtijevaju analitičko izračunavanje gradijenta funkcije cilja. Ovo može predstavljati izazov u

situacijama kada je funkcija cilja kompleksna ili kada njen analitički izraz nije dostupan, što može otežati ili čak onemogućiti primjenu klasičnih metoda u praksi.

Rad [2], objavljen 1975. godine, smatra se prvim radom u oblasti rekonfiguracije distributivne mreže. U ovom istraživanju je predstavljen heuristički pristup baziran na *Branch and Bound* optimizacionoj tehnici. Naime, ovo rješavanje počinje upetljanim distributivnom mrežom kod koje su svi prekidači zatvoreni. Zatim se prekidači otvaraju jedan po jedan kako bi se eliminisale petlje i dobila nova radikalna konfiguracija. Ova metoda se pokazala kao veoma vremenski zahtjevna za optimizaciju s obzirom na to da je broj mogućih konfiguracija 2^n , gdje je n broj grana koje su opremljene prekidačima. I pored ovog suštinskog ograničenja, navedeni rad je poslužio kao osnova za razvoj budućih metoda i strategija. U [3] je predstavljen *Brute-Force* algoritam za pronalaženje optimalnog uklopnog stanja distributivne mreže, pri kojem će postojati minimalni gubici aktivne snage. Predložen je metod koji koristi algoritam iscrpne pretrage (eng. *Exhaustive Search Algorithm*) uz primjenu tehnika grafičke teorije (eng. *Graph-Theoretic Technique*) koje uključuju transformacije matrica osjetljivosti struje. Usljed potrebe za analizom svih mogućih konfiguracija, ovaj metod nije primjenjiv na složenijim mrežama. U [4] se razmatra problem rekonfiguracije distributivne mreže uzimajući u obzir nesigurnost potražnje za električnom energijom. Predložen je dvostepeni model robusne optimizacije, gdje se u prvom koraku sprovodi rekonfiguracija mreže, a u drugom pronalaze optimalni tokovi snaga rekonfigurisane mreže za datu potrošnju. Dvostepeni robusni model se rješava primjenom *Column And Constraint Generation* algoritma, gdje su glavni problem i potproblem formulisani kao mješoviti cjelobrojni problemi drugog reda sa konusnim ograničenjima. Rekonfiguracija mreže se može primjenjivati i s primarnim ciljem smanjenja varijacija napona koji proizilaze iz varijabilne prirode obnovljivih izvora električne energije, što pruža nove uvide u problem regulacije napona [5]. U [5] se na osnovu linearnih *DistFlow* jednačina prvo predlaže novi indeks koji opisuje oscilacije napona svakog čvora u mreži. Ovaj indeks zavisi od parametara distributivne mreže i pokazuje kako struktura mreže utiče na oscilacije napona. Zatim se predstavlja novi model rekonfiguracije koji minimizuje gubitke u mreži i istovremeno ograničava oscilacije napona kroz koordinisanu kontrolu baterija kondenzatora. Da bi se riješio ovaj problem, koristi se pristup baziran na *Benders dekompoziciji* i metodi mješovitog cjelobrojnog kvadratnog programiranja (eng. *Mixed Integer Quadratic Programming - MIQP*). Primjenom ovog metoda je utvrđeno da minimizuje gubitke u mreži kada je proizvodnja distribuiranih generatora u skladu sa prognozama i značajno smanjuje rezik od narušavanja naponskih ograničenja kada proizvodnje generatora odstupaju od prognoziranih. Istraživanje opisano u [6], primjenjuje istu tehniku istražujući dvostepenu optimizaciju rekonfiguracije distributivne mreže radi poboljšanja otpornosti funkcionisanja sistema na vremenske nepogode kao što su oluje i jaki vjetrovi sa ciljem minimizacije neisporučene električne energije. Kako bi se ovaj cilj ostvario, u prvom koraku se primjenom funkcije vjerovatnoće i Monte Karlo simulacije procjenjuje pojava kvarova. Nakon toga, na osnovu predviđenih oštećenja se vrši rekonfiguracija kako bi se minimizovali troškovi uslijed prekida napajanja. U drugom koraku, nakon pojave nevremena, se vrši ponovna rekonfiguracija mreže u svrhu obnavljanja napajanja kod što većeg broja potrošača. U [7] je predložen algoritam za optimalnu rekonfiguraciju u realnom vremenu, koji koristi klasične tehnike nelinearne optimizacije i obezbjeđuje postizanje globalno optimalnog rješenja. Algoritam se temelji na komplementarnoj tehnici koja pretvara diskontinuirane prostore rješenja u kontinuirane, omogućavajući primjenu klasičnih metoda nelinearne optimizacije. Upotreboom komplementarne

tehnike, predstavljena je nelinearna optimizacija i klasična metoda rješavanja kako bi se postigla optimalna rekonfiguracija, uz istovremeno smanjenje gubitaka i postizanje prihvatljivih vrijednosti napona. Takođe, smanjivanje gubitaka aktivne snage je bio cilj i u radu [8]. U njemu su predstavljena dva optimizaciona modela: mješovito cjelobrojno konusno programiranje (*eng. Mixed Integer Conic Programming* - MICP) i mješovito cjelobrojno linearno programiranje (*eng. Mixed Integer Linear Programming* - MILP). MICP model pruža tačne vrijednosti gubitaka u mreži i posjeduje konveksnu strukturu u odnosu na svoje kontinuirane promjenjive. MILP model se zasniva na preciznom poliedarskom prikazu koničnih ograničenja. U oba slučaja se uslovi radikalnosti mreže obezbjeđuju putem ograničenja razgranatog stabla (*eng. Spanning Tree*), koja omogućavaju obrnuti tok energije od distribuiranih generatora. Osim toga, moguće je ograničiti broj operacija prekidača i time postići ravnotežu između minimizacije gubitaka i prekomjernih prekidačkih akcija. U radu [9], takođe je korišćen MILP za minimizaciju gubitaka. Ova implementacija se zasniva na linearном modelu mreže. Tokom simulacija koje su obuhvatile i nelinearne modele, zaključeno je da su proračuni dobijeni linearnim modelom gotovo identični onima dobijenim primjenom nelinearnih modela, sa odstupanjima manjim od 10%. *Minimum Spanning Tree* (MST) algoritam je u [10] primijenjen za optimalnu dinamičku rekonfiguraciju mreže, sa fokusom na smanjivanje gubitaka aktivne snage. Ovaj pristup je detaljno ispitana na testnim mrežama sa 33 i 84 čvora, a zatim je njegova primjena potvrđena na dijelu distributivne mreže u Alžiru.

U istraživanjima [2-10] je razmatrano rješavanje problema rekonfiguracije primjenom klasičnih metoda kao što su gradijentna optimizacija, linearna i nelinearna optimizacija i konveksno programiranje. Radovi su koristili različite tehnike, uključujući *Benders* dekompoziciju, MIQP, MICP, MILP i MST algoritam. Iako klasične metode obezbjeđuju konvergenciju ka globalno optimalnom rješenju, uslijed velike složenosti problema, kao što je rekonfiguracija distributivne mreže često zahtijevaju značajno vrijeme proračuna. Navedena mana postaje posebno izražena i izazovna u praksi kada se klasične metode primjenjuju na realnim sistemima, koje karakterišu velike dimenzije i složenost. S porastom stvarnih dimenzija distributivnih mreža, klasične metode se suočavaju sa rastućim zahtjevima za računarskim resursima i vremenom proračuna, što čini njihovu primjenu u realnom vremenu izazovnom i često neostvarivom. Ovaj nedostatak je otvorio prostor za dominantnu primjenu heurističkih i metaheurističkih metoda koje, iako manje precizne, pokazuju veću prilagodljivost i učinkovitost pri rješavanju ovog problema.

2.1.2 Primjena heurističkih metoda optimizacije u rješavanju problema rekonfiguracije distributivnih mreža

Za razliku od klasičnih metoda koje zahtijevaju detaljnu analizu svih potencijalnih rješenja, heurističke metode se oslanjaju na pojednostavljene pristupe i strategije brzog donošenja odluka. Međutim, zbog ovakvog pristupa, heurističke metode ne garantuju uvijek pronalazak najboljeg mogućeg rješenja.

U [11] je prikazana računska procedura za smanjenje gubitaka kroz rekonfiguraciju mreže. Izvedena je jednostavna formula na osnovu pojednostavljenih prepostavki kako bi se procijenilo smanjenje gubitaka sa minimalnim računskim naporom. Na ovaj način se vrši filtriranje opcija kojima

se ne smanjuju gubici. Zatvara se prekidač spojnog voda sa najvećom razlikom napona, a susjedna grana u formiranoj petlji se otvara što dovodi do smanjenja gubitaka. Ova procedura je vremenski vrlo zahtjevna i ne garantuje dostizanje rješenja bliskog optimalnom uslijed zavisnosti rješenja od početnog statusa prekidača i zanemarivanja sistemskih ograničenja. U istraživanju [12] je praćena metodologija rješavanja problema iz [11]. Međutim, uvedena su dva pristupa za aproksimaciju toka snage, svaki sa svojim stepenom tačnosti. Korišćen je niz rekurentnih jednačina tokova snaga, razvijenih specifično za radikalne mreže, koje su koristile aktivnu snagu, reaktivnu snagu i napon na početku grane kako bi se izrazile iste veličine na kraju grane. Procjenom ovih veličina u nultom čvoru mreže, iste veličine se određuju i za ostale čvorove mreže korišćenjem razvijenih jednačina. Sličan skup jednačina se koristi i za *backward* smjer, gdje se proračun započinje za poslednje čvorove u mreži i nakon toga se kreće ka nultom. Ono što ovaj rad izdvaja od [11] jeste dodatno uzimanje u obzir preraspodjelu opterećenja između izvoda mreže kao ključnog faktora. Na taj način je razvijen sveobuhvatniji, kvalitetniji i proračunski jednostavniji pristup za rješavanje problema rekonfiguracije distributivne mreže u odnosu na prethodno istraživanje. U [13] je predložen heuristički algoritam izmjene grana (*eng. branch exchange*) za minimizaciju aktivnih gubitaka u distributivnoj mreži, baziran na metodu iz [2], sa razlikom uvođenja sistemskih ograničenja. Algoritam za rješavanje problema prvo zatvara sve prekidače u mreži, pretvrajući je iz radikalne u petljastu. Nakon izvršenog proračuna optimalnih tokova snaga (*eng. optimal power flow*), otvara se prekidač u grani sa najmanjom vrijednosti struje, čime se eliminiše jedna od petlji u mreži. Ovaj proces se ponavlja sve dok mreža ne postane radikalna uz ispunjenje zadatih ograničenja. U radu [14] je razvijena metodologija za minimizaciju gubitaka aktivne snage uz očuvanje radikalnosti mreže i kontinuirano snabdijevanje svih potrošača. Ova metodologija se temelji na pristupu opisanom u radu [2]. Postupak rješavanja počinje zatvaranjem svih prekidača, dobijajući petljastu mrežu. Opterećenja se modeluju kao konstantna, a za izračunavanje napona i strujnih injektiranja se koristi *Fast Voltage Correction Power Flow*. *Fast Voltage Correction Power Flow* se koristi za proračun tokova snaga u slabo upetljanim mrežama [15]. Prvi korak ovog metoda jeste transformacija slabo upetljanih mreža u radikalne, razbijanjem petlji. Zatim se formira matrica impedanse petlji, koja omogućava izračunavanje napona i struja (snaga) u mreži. U prvom koraku (korak unaprijed) se izračunavaju naponske vrijednosti u radikalnom dijelu mreže, dok se u drugom koraku (korak unazad) proračunavaju struje. Ovaj postupak se iterativno nastavlja prvim korakom, koji je prethodno praćen korekcijom napona. Algoritam funkcioniše tako što se u svakoj fazi ovog procesa otvara grana sa najmanjim opterećenjem kako bi se eliminisala jedna od petlji u mreži, obezbjeđujući minimalne poremećaje u *Optimum Flow Pattern*. Ovaj postupak se ponavlja dok se ne postigne radikalna konfiguracija mreže. U [16] je razvijen fleksiblни pristup, koji omogućava procjenu potencijalnih koristi rekonfiguracije mreže, kao i ekonomski opravdanu učestanost prekidačkih akcija. Razvijeni metod se sastoji iz tri zasebna dijela: procjene opterećenja u realnom vremenu, utvrđivanje konfiguracije sa minimalnim gubicima, evaluacija troškova/dobiti. Rad [17] predstavlja heurističku metodu za određivanje konfiguracije sa minimalnim gubicima u neizbalansiranim mrežama. Metoda predstavlja proširenu i unaprijeđenu verziju pristupa primijenjenog na simetričnim mrežama, koji je predstavljen u [14]. U radu [18] je razvijen algoritam koji, pored smanjenja gubitaka, za cilj ima i ponovno uspostavljanje napajanja. Ovaj algoritam koristi indekse prekidača kako bi odabroao optimalnu kombinaciju otvorenih prekidača. Navedeni indeksi su izračunati na osnovu padova napona duž grana i tehničkih ograničenja grana. U normalnom režimu

rada, prekidači sa najvećim vrijednostima indeksa u svakoj petlji se otvaraju, dok se u slučaju ponovnog uspostavljanja napajanja otvaraju oni sa najmanjim indeksom. Za razliku od [2,14,18], u istraživanju [19] se ne poseže za zatvaranjem svih prekidača istovremeno. Naime, prolazeći kroz svaku petlju pojedinačno pažljivo se analizira koji prekidač treba otvoriti kako bi se dobila radikalna konfiguracija sa minimalnim gubicima. U [20] je primijenjen *Discrete Ascent Optimal Programming* (DAOP). Za odabir potencijalno otvorenih prekidača koristi se pojednostavljena formula za proračun gubitaka. Međutim, nakon svakog stvarnog otvaranja prekidača, obavlja se detaljan proračun opterećenja radi preciznijih podataka o gubicima i ograničenjima. Ovakav pristup zahtjeva više računskog vremena, ali rezultira preciznijim modelima za ograničenja i upravljačke akcije. U okviru [21] je predstavljena metoda sekventnog otvaranja prekidača sa ciljem pronalaska konfiguracije sa minimalnim gubicima i poboljšanim profilom napona. Osim toga, istraživanje je prošireno i na uspostavljanje ponovnog napajanja potrošača. Za razliku od metoda koje posmatraju struje u mreži, ovaj pristup rezultira otvaranjem grane u petlji koja prenosi najmanju snagu, čime mreža postaje radikalna. *Single-loop* optimizacija je u [22] primijenjena za rješavanje problema rekonfiguracije. Ovaj rad predstavlja jednostavan i djelotvoran plan za određivanje otvorenog prekidača u petlji, a takođe se predlaže i heuristički plan za kreiranje optimalne šeme otvaranja prekidača sa minimalnim brojem prekidačkih akcija kako bi se postigao prelazak sa početne konfiguracije na optimalnu. U [23] je ispitana kombinacija kompenzacije reaktivne snage putem baterija kondenzatora i rekonfiguracije distributivne mreže. Upoređene su metodologije iz radova [11] i [13] i utvrđeno je da je algoritam iz [11] značajno brži. Istovremeno, primijećeno je da konačno rješenje izrazito zavisi od početne konfiguracije sistema. Radi smanjenja operativnih troškova u realnom vremenu u [24] je predložen još jedan heuristički metod. Ono što ovaj rad čini posebno zanimljivim jeste njegova pažnja na provjeru da li nova konfiguracija mreže može biti adekvatno zaštićenja pomoću relejnih uređaja. Ovaj korak je od suštinskog značaja za obezbjeđivanje sigurnosti i zaštite mreže. U [25] su razvijena dva algoritma za rekonfiguraciju, u svrhu ponovnog uspostavljanja napajanja i balansiranja opterećenja. Njihov pristup kombinuje optimizacione tehnike sa *Fuzzy Logic* tehnikom i heurističkim pravilima kako bi se postigla pouzdana realizacija i poboljšala djelotvornost.

U radovima [11-25] su razmatrane različite heurističke metode za rješavanje problema rekonfiguracije elektrodistributivne mreže. Prednosti metoda opisanih u ovim radovima su brzina i praktičnost koje su postignute korišćenjem aproksimacija i karakteristikom heurističkih metoda da budu prilagodljive različitim uslovima i scenarijima. Ove metode se primjenjuju kada je tačno rješenje teško ili nemoguće pronaći u nekom razumnom vremenskom periodu, što ih čini korisnim za rješavanje problema poput rekonfiguracije distributivnih mreža, gdje su brzina i učinkovitost presudne za uspješno upravljanje sistemom.

Takođe, postoje neki nedostaci heurističkih metoda u rješavanju ovog problema [13]:

- Konačna konfiguracija mreže često zavisi od izbora početnog rješenja,
- Ne garantuju postizanje optimalnog ili čak suboptimalnog rješenja i
- Proračun može postati vremenski zahtjevan u slučaju realnih mreža sa velikim brojem grana i čvorova.

2.1.3 Primjena metaheurističkih metoda optimizacije u rješavanju problema rekonfiguracije distributivnih mreža

Kako problem rekonfiguracije karakteriše nelinerana priroda kriterijumske funkcije i ograničenja, on se može svrstati u grupu nelineranih kombinatornih problema. Javlja se veliki broj mogućih kombinacija, koji se svakim novim elementom eksponencijalno povećava. To otvara veliki prostor pretraživanja, čime tradicionalne (klasične) metode postaju nepraktične i nedovoljno efikasne, zbog nemogućnosti analiziranja svih kombinacija u razumnom vremenskom okviru kako bi se postiglo optimalno rješenje.

Da bi se prevazišao ovaj izazov, često se koriste inovativne metaheurističke metode. Ove metode ne analiziraju sve moguće kombinacije ili rješenja u prostoru pretraživanja, već koriste različite strategije kako bi efikasnije pretražile prostor pretraživanja i pronašle zadovoljavajuća rješenja unutar razumnog vremenskog okvira. Ova prilagodljivost je posebno korisna kod složenih problema kao što je rekonfiguracija distributivne mreže. Inspirisane procesima u prirodi, ove tehnike su našle široku primjenu u različitim oblastima ljudske djelatnosti, kao što su inženjering, ekonomija, medicina, vještačka inteligencija, računarstvo i druge.

U radovima [26,27] je primijenjen algoritam pretrage kukavice (*eng. Cuckoo Search Algorithm - CSA*), inspirisan evolutivnom strategijom kukavica u prirodi, kako bi se riješio problem rekonfiguracije distributivne mreže. Cilj je bio minimizacija gubitaka aktivne snage i devijacije napona koristeći *Voltage Stability Index (VSI)*. Dok se [26] fokusira na pasivnu mrežu, u radu [27] je dodatno razmatrana optimalna lokacija i kapacitet distribuiranih generatora, analizirajući sedam različitih scenarija.

Poslednjih godina, optimizacija rojem čestica (*eng. Particle Swarm Optimization - PSO*) se ističe kao jedna od najkorišćenijih optimizacionih metoda [28-30]. Primjenom diskretne optimizacije rojem čestica (*eng. Discrete Particle Swarm - DPSO*) u [28] je predstavljena komparativna studija za planiranje rekonfiguracije distributivne mreže na satnom, dnevnom, mjesecnom i godišnjem nivou. Ovom analizom se odredio optimalni scenario na osnovu ukupnih ušteda i povrata investicije. Rezultati ukazuju da, čak i pri visokoj učestanosti rada, samo nekoliko prekidača aktivno učestvuje u procesu rekonfiguracije. Stoga, za ekonomičan rad nije neophodno opremiti sve grane automatskim prekidačima. U istraživanju [29] je predstavljena metoda za optimalnu rekonfiguraciju distributivne mreže uz istovremeno razmatranje alokacije distribuiranih generatora. Predložena metoda se sastoji iz dva ključna koraka. Prvo, korišćenjem binarne optimizacije rojem čestica (*eng. Binary Particle Swarm Optimization - BPSO*), se kreira izvodljiva konfiguracija mreže. Nakon toga, primjenom analize osjetljivosti i algoritma pretrage harmonije (*eng. Harmony Search Algorithm - HSA*), rješava se problem alokacije distribuiranih generatora. Istražena su tri optimalna cilja, uključujući minimalne troškove gubitaka aktivne snage, minimizaciju očekivane neisporučene električne energije i minimizaciju troškova prekidačkih akcija. Ovaj višekriterijumski optimizacioni problem je dalje transformisan u jednokriterijumski primjenom faktora ponderisanja. *Decimal Coded Quantum Particle Swarm Optimization (DQPSO)* je u [30] primijenjena za rekonfiguraciju aktivne distributivne mreže sa ciljem minimizacije gubitaka. Distribuirani generatori su kategorizovani u PQ, PV, PQ (V) i PI modele, usklađeno sa njihovim radnim režimima i kontrolnim karakteristikama. Ova metoda se

oslanja na decimalno kodiranje u okviru *Quantum Particle Swarm Optimization* (QPSO), što doprinosi skraćivanju dužine čestice, smanjenju broja neprihvatljivih rješenja i povećanoj djelotvornosti pretrage. Dodatno, uvezši u obzir problem prekoračenja reaktivne snage kod PV modela, u ovom istraživanju su analizirani faktori koji utiču na reaktivnu snagu kao što su nazivna aktivna snaga i nazivni napon.

Prva primjena genetskog algoritma (*eng. Genetic Algorithm* - GA) za rješavanje problema rekonfiguracije distributivne mreže je predstavljena 1992. godine u [31]. U radu [32] je predstavljena optimalna shemu za operativno upravljanje u distributivnom sistemu. Predloženi metod, baziran na genetskom algoritmu, ima za cilj optimalno upravljanje aktivnim elementima mreže, distribuiranim generatorima i upravljivim potrošačima, sa akcentom na minimizaciju ukupnih operativnih troškova. Kao inovativni pristup aktivnom upravljanju, operator distributivne mreže kvalitetno koristi mogućnost rekonfiguracije mreže na satnom nivou, postižući to kroz implementaciju RCS-eva. U razmatranju praktičnih izazova, posebna pažnja se posvećuje maksimalnom broju dnevnih prekidačkih akcija i njihovoj cijeni. U [33] je predstavljen brzi genetski algoritam sa sortiranjem prema nedominaciji (*eng. Fast Nondominated Sorting Genetic Algorithm* - FNSGA), koji se koristi za rješavanje problema dinamičke rekonfiguracije distributivne mreže tokom normalnog rada, zadovoljavajući sva tehnička ograničenja uz relativno mali broj generacija i kratko vrijeme izračunavanja. Osnovni zadaci problema obuhvataju minimizaciju gubitaka aktivne snage, poboljšanje naponskog profila i ravnotežu opterećenja izvoda uz minimalan broj prekidačkih akcija. Umjesto generisanja više rangova iz nedominirajućeg skupa rješenja, ovaj pristup se bavi samo jednim rangom, a zatim se najprikladnije rješenje bira prema izboru operatora. U slučaju da ne postoji izdvajanje i svi ciljevi imaju isti stepen važnosti, najbolje rješenje se određuje putem sumiranja normalizovanih vrijednosti ciljeva. U istraživanju [34] se primjenjuje unaprjeđeni genetski algoritam (*eng. Enhanced Genetic Algorithm* - EGA) za rekonfiguraciju distributivne mreže s fokusom na smanjenje gubitaka i poboljšanja pouzdanosti sistema. Važan doprinos ovog pristupa je unaprjeđenje operacije ukrštanja u okviru GA i izbjegavanje potrebe za identifikacijom fundamentalnih petlji u distributivnoj mreži, može biti izazovno. Osim toga, ova metodologija uzima u obzir faktore koji utiču na pouzdanost distributivnog sistema, omogućavajući bolju ravnotežu između smanjenja gubitaka i poboljšanja pouzdanosti sistema. U prethodnim istraživanjima koja su koristila različite varijacije genetskog algoritma, je pretpostavljeno da bi veličina populacije trebala ostati konstantna tokom procesa pretrage. U [35] je ta pretpostavka otklonjena, pa je predložen novi pristup koji omogućava dinamičko prilagođavanje veličine populacije tokom pretrage. Rezultati ovog istraživanja su pokazali da upotreba promjenjive veličine populacije značajno smanjuje ukupno vrijeme potrebno za proračune.

U radu [36] se koristi kombinacija *fuzzy* višekriterijumske analize i optimizacije kolonijom mrava (*eng. Ant Colony Optimization* - ACO) za rješavanje problema rekonfiguracije i istovremene optimalne alokacije solarnih elektrana i statickih kompenzatora (STATCOM) u distributivnom sistemu. Glavni ciljevi ovog istraživanja obuhvataju smanjenje gubitaka, poboljšanje naponskog profila i ravnotežu opterećenja po izvodima. Rezultati pokazuju da ovakav višekriterijumski pristup donosi mnogo veće benefite u odnosu na odvojenu optimizaciju sa jednim ciljem. Kako bi se izbjegli problemi sa konvergencijom, ulazni i izlazni podaci su normalizovani u istom opsegu na osnovu *fuzzy*

skupova. U [37] je za rješavanje problema rekonfiguracije izbalansiranih i neizbalansiranih distributivnih mreža korišćena prilagodljiva optimizacija kolonijom mrava (*eng. Adaptive Ant Colony Optimization* - AACO). U predloženoj metodi uvedeni su topološki koncepti vektora petli, vektora zajedničkih grana i vektora zabranjenih grupa uz pomoć teorije grafova. Takođe, definisana su pravila koja osiguravaju generisanje isključivo izvodljivih radikalnih topologija tokom cijelog evolutivnog procesa, bez obzira na veličinu distributivnog sistema. Analiza rezultata ukazuje na to da ova pravila postaju sve značajnija kako se dimenzionalnost sistema povećava. Takođe, istraživanje nagovještava mogućnost proširenja ovog pristupa za rješavanje višekriterijumske problema bez značajnog povećanja računskog opterećenja.

U radu [38] je primijenjen metod simuliranog kaljenja (*eng. Simulated Annealing* - SA) algoritam kako bi se odredile grane u distributivnoj mreži gdje treba ugraditi RCS. Ovaj izbor uzima u obzir različite faktore, uključujući investicione troškove, operativne troškove, troškove održavanja i troškove neisporučene električne energije kako bi se dobilo optimalno rješenje za upravljanje mrežom. Sa ciljem smanjenja gubitaka, u [39] primijenjen je modifikovani SA algoritam. Prvo su predstavljene pojednostavljene jednačine za procjenu gubitaka u mreži. Zatim je predložena učinkovita procedura perturbacije i postupak inicijalizacije za određivanje optimalne početne temperature za simulirano kaljenje. Ovo znatno smanjuje vrijeme pretrage, ne narušavajući kvalitet rješenja, i omogućava brzo pronalaženje globalno optimalnog ili suboptimalnog rješenja. Unaprijeđeni algoritam simuliranog kaljenja (*eng. Improved Simulated Annealing Algorithm*) je u [40] primijenjen za rekonfiguraciju velikih distributivnih sistema. Kako bi se poboljšale performasne SA algoritma, korišćen je polinomski mehanizam hlađenja koji se zasniva na statističkim proračunima tokom pretrage. Predloženi mehanizam promjene baziran na topologiji mreže generiše konfiguraciju mreže usklađenu sa topologijom i temperaturom, omogućavajući raznolikost rješenja pri visokim temperaturama i koncentraciju optimalnih rješenja pri nižim temperaturama. Korišćena je kriterijumska funkcija sa strategijom poravnjanja kako bi se izbjegla pojava lokalnih minimuma i brže približavanje optimalnom rješenju. Primjena predložene metode je potvrđena na velikim distributivnim sistemima, pri čemu kapacitet pretrage postaje značajniji sa povećanjem veličine sistema.

U [41] je razvijen pristup za optimizaciju upravljanja budućim pametnim distributivnim mrežama, s obzirom na rastuću prisutnost *plug-in* hibridnih električnih vozila (*eng. Plug-in Hybrid Electric Vehicles* - PHEVs). Stohastičko punjenje PHEV-ova stvara nove izazove za operatore distributivnih mreža, poput preopterećenje grana i povećanje gubitaka. Stoga, u ovom radu se predlaže nova stohastička metodologija rekonfiguracije, koja omogućava ublažavanje uticaja punjenja PHEV-ova putem promjene topologije mreže koristeći RCS. Nesigurnosti vezane za potražnju energije, cijenu energije i nepredvidljivost punjenja PHEV-ova se analizira primjenom Monte Karlo simulacije. Za rješavanje navedenog problema primjenjuje *Krill Herd Optimization Algorithm* (KHOA).

Metaheurističke metode su postale ključni alati za rješavanje kompleksnih problema rekonfiguracije distributivnih mreža, omogućavajući optimizaciju troškova, smanjenje gubitka energije i poboljšavanje sigurnosti distributivne mreže. Njihova primjena, koja uključuje algoritme poput CSA, PSO, GA, ACO, SA i KHOA, donosi značajne prednosti uključujući učinkovitu

integraciju distribuiranih izvora energije i rješavanje višekriterijumske optimizacione problema. Ipak, ove metode se suočavaju s izazovima kao što su visoka računska složenost, nesigurnosti u podacima i potreba za prilagođavanjem specifičnim slučajevima. Uprkos tim izazovima, napredak tehnologije, prilagođavanje operativnih strategija, bolja upravljivost nesigurnostima i primjena višekriterijumskih pristupa mogu omogućiti uspješnu primjenu ovih metoda.

2.2 Kompenzacija reaktivne snage

Kompenzacija reaktivne snage u distributivnim mrežama predstavlja važnu strategiju za očuvanje visokog kvaliteta napajanja i postizanja efikasnog funkcionisanja sistema. Uređaji za kompenzaciju reaktivne snage imaju bitnu ulogu u regulaciji tokova reaktivne snage, omogućavajući održavanje napona unutar propisanih granica, minimizaciju gubitaka i korekciju faktora snage. U tradicionalnim pasivnim mrežama, ovi uređaji su se koristili za rješavanje problema niskih napona. Međutim, u savremenim sistemima sa distribuiranim izvorima, operatori se suočavaju i sa pojmom visokih napona i čestih fluktuacija. Obzirom na dinamiku savremenih distributivnih mreža, postoji potreba za fleksibilnijim uređajima, koji mogu brzo korigovati apsorbovanu i injektiranu reaktivnu snagu, omogućavajući precizne i prilagodljive strategije kompenzacije.

Kompenzacija reaktivne snage u distributivnim mrežama se može postići različitim metodama, gdje odabir odgovarajuće metode zavisi od zahtjeva mreže i željenog stepena kontrole. Korišćenje baterija kondenzatora, naprednih *Flexible AC Transmission Systems* (FACTS) uređaja poput statičkih var kompenzatora (*eng. Static Var Compensators - SVC*) i statičkih sinhronih kompenzatora (*eng. Static Synchronous Compensator - STATCOM*), kao i distribuiranih izvora energije predstavljaju različite pristupe ovom procesu.

Baterije kondenzatora, koje se već decenijama koriste u distributivnoj mreži, unaprjeđuju naponski profil čvorova putem korekcije faktora snage, istovremeno smanjujući gubitke u mreži. Međutim, glavni izazov u primjeni baterija kondenzatora leži u optimalnom određivanju njihovih pozicija i kapaciteta, što zahtijeva temeljnu analizu i pažljivo planiranje kako bi se postigli željeni ishodi. Imajući u vidu značaj i kompleksnost ovog problema, istraživanje u ovoj oblasti je privuklo značajnu pažnju i postignuti su zapaženi rezultati. Godine 1968. je u [42] opisan metod za određivanje optimalnog broja, pozicije i kapaciteta baterija kondenzatora u radikalnoj distributivnoj mreži sa diskretno grupisanim opterećenjima. Cilj je bio maksimizovati ukupne uštede, uključujući i troškove baterija kondenzatora, dok se u istraživanju takođe bavilo i kada primjena baterija kondenzatora nije ekonomski isplativa. Ovaj pristup koristi tehniku dinamičkog programiranja i razvijeni su različiti algoritmi kako bi se postiglo optimalno rješenje, tretirajući optimizacioni proces kao višestepeni sa željenim Markovljevim svojstvom. U radu [43], za rješavanje problema alokacije baterije kondenzatora u neizbalansiranim mrežama, primijenjena je optimizacija rojem čestica (*eng. Hybrid Particle Swarm Optimization - HPSO*). Osnovni cilj je minimiziranje ukupnih troškova gubitaka aktivne snage i kapaciteta baterija kondenzatora potrebnih za instalaciju. U modernim distributivnim mrežama, sve je češći unos harmonika višeg reda, a dodavanje baterija kondenzatora može rezultirati povećanom distorzijom. Kako bi se uzela prisutnost ovih harmonika u obzir, razvijeni HPSO je

integriran sa algoritmom za proračun harmonijskih tokova snage. Takođe, u [44] je predložen hibridni pristup koji uključuje *fuzzy* logiku i *Immune Algorithm* (IA) kako bi se utvrdile optimalne lokacije i kapaciteti baterija kondenzatora u sistemima s prisustvom viših harmonika. Prvi korak u rješavanju ovog problema uključuje primjenu *fuzzy* logike za identifikaciju najboljih lokacija za postavljanje baterija. Nakon toga, kapaciteti baterija na ovim lokacijama se određuju pomoću predloženog algoritma. U distributivnim mrežama, osim baterija sa fiksnim kapacitetom, postoji mogućnost korišćenja baterija koje imaju više kondenzatorskih jedinica. U radu [45], primjenom genetskog algoritma, istraženo je optimalno alociranje ovih baterija. Ovaj rad se ističe po tome što se, za razliku od prethodnih istraživanja, posebno razmatrala i cijena promjene otcjepa kod ovih baterija kondenzatora, budući da ta akcija može uticati na njihov životni vijek.

Pored tradicionalnih baterija kondenzatora, u distributivnim mrežama se mogu koristiti i FACTS uređaji. Ovi uređaji pružaju napredniju kontrolu i bržu reakciju na promjene u mreži, što doprinosi poboljšanju njene sigurnosti i efikasnosti. Ipak, uprkos brojnim prednostima FACTS uređaja, njihova primjena može biti ograničena visokim troškovima instalacije i održavanja. Dodatno, za pravilnu implementaciju i upravljanje ovim uređajima potrebna je specifična tehnička ekspertiza, što može predstavljati izazov za operatore distributivnih mreža. U istraživanju [46] je detaljno analizirana problematika varijacija napona u distributivnoj mreži sa decentralizovanim izvorima koje karakteriše promjenjiva proizvodnja, kao što su fotonaponska i vjetroelektrana. Kako bi se učinkovito riješili izazovi vezani za varijacije napona, istraživači su predložili optimalno postavljanje SVC uređaja. Kroz upotrebu genetskog algoritma, identifikovane su najbolje lokacije i nazivne snage SVC uređaja, s ciljem smanjenja standradne devijacije napona u kritičnom čvoru distributivne mreže. Dvostepena tabu pretraga (eng. *Taboo Search - TS*) je u [47] primijenjena za optimizaciju alokacije i izlazne reaktivne snage SVC uređaja u svrhu kontrole varijacija napona uzrokovanih proizvodnjom vjetrogeneratora u distributivnoj mreži. Prvi korak ovog metoda se fokusira na optimalnu alokaciju SVC uređaja, dok se drugi bavi postizanjem optimalne izlazne snage. Takođe, za uzimanje u obzir nesigurnosti u proizvodnji vjetrogeneratora primijenjena je Monte Karlo simulacija. U [48] je razvijen pristup za optimizaciju lokacije i kapaciteta STATCOM uređaja unutar radijalnih distributivnih mreža. Koristeći *Immune Algorithm* (IA), cilj je bio minimizirati gubitke i troškove instalacije STATCOM uređaja, uz poštovanje unaprijed definisanih ograničenja napona i struja. Ciljna funkcija je formirana na osnovu smanjenja gubitaka snage uzrokovanih prisustvom STATCOM uređaja i povezanih troškova. U [49] je razvijen kaskadna kontrolna strategija za regulaciju napona u distributivnoj mreži uz korišćenje STATCOM uređaja. Ovaj pristup je posebno razvijen za *Pulse Width Modulation* (PWM) kontrolisani *Voltage Source Converter* (VSC). Simulacioni i eksperimentalni rezultati su pokazali da se ovakvom kontrolom postiže stabilan i brz odgovor na različite uslove i pojave u mreži.

U poslednjim godinama, sve veća pažnja se posvećuje kontroli reaktivne snage distribuiranih generatora i njenim efektima na električne mreže. Ovaj porast interesovanja je proistekao iz sve učestalije integracije ovih izvora u distributivne mreže. Fokus istraživanja je usmjeren na razvoj održivih strategija upravljanja ovim resursima u cilju optimizacije naponskih profila i smanjenja gubitaka, čime bi se unaprijedila pouzdanost i ekonomičnost pogona sistema. U radu [50] je razvijen metod koji se oslanja na upotrebu invertora solarnih elektrana kako bi se postigla kontrola napona u

distributivnoj mreži. U okviru ovog istraživanja, izvedeni su analitički izrazi koji omogućavaju procjenu pada napona u mreži sa ravnomjerno raspoređenim opterećenjem i proizvodnjom električne energije. *Droop* karakteristika se primjenjuje kao esencijalni element ovog pristupa kako bi se spriječilo oscilovanje između različitih generatora. Ovaj metod omogućava kvalitetno održavanje napona u mreži, posebno u uslovima promjenjive proizvodnje solarnih elektrana. U istraživanju [51] je analiziran problem rasta napona u distributivnim mrežama uslijed integrisanih distribuiranih generatora. Autori predstavljaju inovativan pristup koji ne zahtijeva direktnu kontrolu napona u čvorovima od strane ovih generatora. Umjesto toga, fokus je na osiguranju da injektiranje snage distribuiranih generatora ne izaziva značajne fluktuacije napona u mreži. Ovaj rad pokazuje da se ovakav koncept može uspješno primijeniti u stvarnim uslovima, koristeći postojeće resurse i jednostavan koncept lokalnog upravljanja reaktivnom snagom od strane distribuiranih generatora, uz povremenu komunikaciju sa operatorom distributivne mreže. U [52] je predložen *Consensus-Based* distribuirani algoritam za kontrolu reaktivne snage distribuiranih generatora unutar mreže. Ovaj algoritam je razvijen s ciljem optimizacije višekriterijumske funkcije koja uzima u obzir gubitke snage, odstupanja napona i troškove generisanja reaktivne snage od strane distribuiranih generatora. Radi efikasnog upravljanja različitim kapacitetima generatora i postizanja uravnoveženog doprinosa generaciji reaktivne snage, uveden je koncept fer upotrebe reaktivne snage. Takođe, konstruisani gradijenți su pojednostavljeni kako bi se olakšalo kvalitetno rješavanje problema. U radu [53] je predstavljen decentralizovani pristup kontroli reaktivne snage iz fotonaponskih pretvarača putem pravila linearog odlučivanja koje se bazira na aktivnoj snazi fotonaponskog sistema. Pravila linearog odlučivanja se izračunavaju koristeći afino prilagodljivu robusnu varijantu formulacije optimalnog toka snage, pri čemu je stvarna proizvodnja aktivne snage fotonaponskog sistema specifirana unutar intervala nesigurnosti. Robusno rješenje, koje se računa putem konveksnog kvadratnog programiranja, garantuje da će odstupanja napona i gubici aktivne snage ostati unutar svojih optimizovanih granica. Greške u prognozi proizvodnje je neophodno uzeti u obzir za procjenu moguće raspodjele reaktivne snage među distribuiranim generatorima radi postizanja optimalnog toka snage i smanjenja gubitaka u mreži. Uzimajući u obzir ovaj bitan faktor, u [54] je predložen *Pre-Coarse-Fine Adjustment* metod za optimizaciju reaktivne snage distribuiranih generatora kao i baterija kondenzatora. Na ovaj način je moguće smanjiti broj uključivanja i isključivanja baterija kondenzatora, što produžava njihov radni vijek i smanjuje troškove. Preliminarna optimizacija pruža početne vrijednosti, dok se kroz višestruke iteracije između grubih i finih optimizacija postiglo koordinisano rješenje. Kao rezultat toga, postignuta je optimalna raspodjela reaktivne snage među generatorima i smanjili su se troškovi gubitaka i uključivanja baterija kondenzatora. U većini slučajeva, kontrola reaktivne snage kod distribuiranih generatora zavisi samo od jedne lokalne varijable, kao što su napon ili aktivna snaga generatora. Međutim, u radu [55] je predstavljen hibridni pristup koji kombinuje PF(P) i Q(V) strategije kako bi precizno regulisao napon i istovremeno poboljšao ekonomičnost sistema. Ovaj novi pristup određuje vrijednost reaktivne snage kao ponderisanu sumu vrijednosti iz oba kontrolera, PF(P) i Q(V). Kontrola reaktivne snage se dinamički prilagođava na osnovu nivoa aktivne snage, tako da PF(P) kontroler dominira pri visokoj aktivnoj snazi, dok Q(V) kontroler preuzima kontrolu kada je aktivna snaga niska, čime se minimiziraju gubici. U istraživanjima [56, 57] su razmatrane različite strategije za kontrolu reaktivne snage distribuiranih generatora. U [56] je predstavljena interakcija transformatora sa mogućnošću regulacije pod

opterećenjem (eng. *On Load Tap Changer* - OLTC) i fotonaponskih invertora kako bi se razvila koordinaciona šema za optimalno upravljanje u različitim operativnim uslovima i promjenjivim nivoima proizvodnje solarnih elektrana. Glavni cilj ovog istraživanja je minimizacija gubitaka aktivne snage i smanjenja učestanosti operacija na OLTC transformatorima, postižući to kroz lokalnu kontrolu reaktivne snage i centralizovanu kontrolu transformatora. Razmatrana su dva pristupa za kontrolu reaktivne snage, poznata kao *PF fixed* i *PF fixed Q*. S druge strane, u [57] je izvršeno poređenje efikasnosti u smanjenju aktivnih gubitaka korišćenjem *Constant Power Factor* (CPF) i *Optimal Reactive Power Dispatch* (ORPD) strategija.

U istraživanjima [42-57] su razmatrane različite metode kompenzacije reaktivne snage u distributivnim mrežama. Baterije kondenzatora poboljšavaju naponski profil i smanjuju gubitke, ali zahtijevaju optimalno pozicioniranje i mogu izazvati harmonijsku distorziju, što se rješava metodama kao što su dinamičko programiranje i HPSO. FACTS uređaji, poput SVC i STATCOM, nude naprednu kontrolu i brzu reakciju, ali su skupi i zahtijevaju tehničku stručnost. Genetski algoritmi i tabu pretraga su se pokazali korisnim u optimizaciji njihove alokacije. Distribuirani izvori energije, kao što su solarne elektrane i vjetroelektrane, izazivaju varijacije napona zbog svoje promjenjive proizvodnje. Lokalno upravljanje reaktivnom snagom, putem *droop* karakteristika i *Consensus-Based* algoritama, omogućavaju stabilizaciju napona. Hibridni pristupi, koji kombinuju PF(P) i Q(V) strategije, pružaju precizniju regulaciju napona i minimizaciju gubitaka, ali zahtijevaju složeniju koordinaciju komponenti. Iako su istraživanja donijela značajne napretke, i dalje je potrebno razvijati efikasnije i ekonomičnije strategije.

2.3 Upravljanje aktivnom snagom distribuiranih generatora

Ograničenje snage (eng. *power curtailment*) distribuiranih generatora označava namjerno smanjenje i kontrolisanje proizvedene električne energije. Primjena ove restrikcije može proizaći iz više razloga, prije svega kako bi se poštovala operativna ograničenja i očuvala stabilnost pogona distributivne mreže. Kada je proizvodnja elektične energije značajno veća od potrošnje, ograničenje snage postaje važna strategija koja omogućava operatorima da sprječe preopterećenje vodova i nestabilnosti napona, čime se povećava pouzdanost sistema. Ovo postaje posebno važno u kontekstu obnovljivih izvora energije, poput solarnih i vjetroelektrana, obzirom na njihovu varijabilnu prirodu proizvodnje omogućavajući prilagodljivost u realnom vremenu. Usljed širenja distribuirane proizvodnje, ograničenje snage distribuiranih generatora postaje sve bitnije za uspješnu integraciju obnovljivih izvora u postojeće elektrodistributivne mreže.

U radu [58] je istražena primjena *droop* metoda za kontrolu proizvodnje električne energije distribuiranih generatora u svrhu prevencije visokih napona u niskonaponskim distributivnim mrežama kao sredstva za povećanje kapaciteta instaliranih fotonaponskih sistema. Testirane su dvije strategije na tipičnoj niskonaponskoj distributivnoj mreži sa rezidencijalnim elektranama. U prvom pristupu, svi PV invertori imaju iste *droop* koeficijente. U drugom pristupu, koeficijenti su različiti kako bi se ukupna ograničena aktivna snaga ravnomjerno rasporedila među svim PV invertorima. Simulacioni rezultati su pokazali da oba pristupa učinkovito sprječavaju pojavu visokih napona, ali u

drugom pristupu dolazi do povećanih troškova, jer je potrebno smanjiti veću snagu uslijed ravnomjerne raspodjele. U istraživanju [59] je predstavljen inovativan pristup lokalnoj regulaciji napona, s ciljem prevencije pojave visokih napona kroz korišćenje kratkoročnih prognoza proizvodnje fotonaponskih elektrana. Metoda kombinuje teoriju Kalmanovog filtera i kratkoročnu prognozu proizvodnje putem mjerena visoke rezolucije. Kada se očekuje kršenje gornjeg limita napona, predloženi algoritam primjenjuje smanjenje aktivne snage na osnovu ovih kratkoročnih prognoza. Naglašeno je da je ovakva intervencija neophodna kada se putem upravljanja reaktivnom snagom ne može postići potrebna regulacija napona unutar definisanih granica faktora snage elektrane. U [60] je predložena nova strategija za regulaciju napona u niskonaponskim distributivnim mrežama sa visokom penetracijom fotonaponskih sistema. Ova strategija kombinuje upravljanje baterijama PHEV-a i smanjenje aktivne snage distribuiranih generatora kako bi se riješili problemi s naponom u mreži. Razvijen je koordinisani pristup korišćenjem *Consesnus-Based* algoritma, u svrhu maksimizacije iskorišćenja kapaciteta dostupnih baterija PHEV-a, uzimajući u obzir njihove kapacitete i trenutno stanje, ali i minimizaciju smanjenja proizvodnje distribuiranih generatora. Ova kontrolna šema spječava brzo zasićenje/praznjenje baterija prilagođavanjem brzine punjenja/praznjenja, istovremeno ravnomjerno raspoređuje potrebno smanjenje snage među PV sistemima. Intermittentna i fluktuirajuća priroda obnovljivih izvora može izazvati probleme sa frekvencijom u mikromrežama, naročito u situacijama kada kapaciteti za skladištenje nisu pristuni ili su smanjeni. U radu [61] se predlaže upotreba *frequency x power droop* kontrole kako bi se smanjila izlazna snaga PV invertora tokom perioda prekomjerne proizvodnje u mikromrežama koje se oslanjaju na dizel generatore, u svrhu smanjenja varijacija frekvencije. Za razliku od prethodnih radova, u [62] fokus je stavljen na smanjenje aktivne snage kod vjetrogeneratora u niskonaponskim distributivnim mrežama. Za postizanje ovog cilja koristi se tehnika promjene nagiba lopatica (*pitch control*). Ključni faktor u ovoj strategiji je proračun potrebnog nagiba lopatica, a to se u ovom slučaju postiže primjenom *voltage-droop* metode.

U zaključku, primjena ograničenja snage distributivnih generatora može igrati važnu ulogu u distributivnim mrežama, posebno uz sve veću integraciju obnovljivih izvora energije. *Droop* metode, kako s istim, tako i s različitim koeficijentima, pokazale su se učinkovitima u sprječavanju visokih napona, iako pristup s različitim koeficijentima povećava troškove. Kombinacija upravljanja baterijama PHEV-a i smanjenja aktivne snage generatora omogućava bolje iskorišćenje kapaciteta i precizniju regulaciju napona. *Frequency x power droop* kontrola stabilizuje frekvenciju mikromreža, dok *pitch control* metoda učinkovito smanjuje aktivnu snagu vjetrogeneratora koristeći *voltage-droop* proračune. Iako ove strategije omogućavaju efikasnu i održivu integraciju obnovljivih izvora energije, izazovi poput povećanih troškova i kompleksnosti implementacije ostaju prisutni.

2.4 Koordinisano punjenje električnih vozila

Široka implementacija električnih vozila predstavlja izazov koji zahtijeva pažljiv pristup kako bi se izbjegle potencijalne negativne posljedice. Nedostatak kontrole nad procesom punjenja može dovesti do neželjenih efekata, uključujući prekoračenje naponskih granica, preopterećenje mrežnih elemenata i povećanje gubitaka električne energije. Radi sprječavanja ovih problema, neophodno je

preduzeti preventivne mjere, u vidu koordinisanog punjenja električnih vozila, kako bi se osiguralo da distributivna mreža bez problema podnese povećan broj električnih automobila.

U istraživanju [63] je proučavana povezanost gubitaka, faktora opterećenja i varijacije opterećenja u kontekstu koordinisanog punjenja PHEV-a. Na osnovu tih veza razvijene su tri metode punjenja, čiji je cilj minimiziranje uticaja punjenja PHEV-a na distributivni sistem. Primjenom ovih algoritama na dva slučaja potvrđeno je važenje ovih veza, nezavisno od topologije sistema. Rezultati pokazuju da ove metode postižu bolje performanse kada se fokus stavi na faktor oprerećenja ili varijaciju opterećenja umjesto na gubitke. Metoda varijacije opterećenja se izdvaja svojom svestranošću, pružajući iste rezultate kao minimiziranje gubitaka, ali za mnogo kraće vrijeme. Maksimizacija faktora opterećenja pokazala se kao optimalan izbor u situacijama povećanja vršnog opterećenja, zahtijevajući duplo kraće vrijeme od metode varijacije opterećenja. U radu [64] je predstavljena strategija koordinacije punjenja električnih vozila s ciljem mnimizacije gubitaka energije. Obzirom da je tačno predviđanje opterećenja domaćinstva teško izvodljivo, uvedeno je stohastičko programiranje. Razmatrane su dvije tehnike: kvadratno i dinamičko programiranje. U prvom koraku analize koriste se istorijski podaci kako bi se razumjeli profili opterećenja. U drugom koraku se uvodi stohastičko programiranje kako bi se modelovala greška prognoze. *Multi-agent* sistem je u [65] primijenjen u cilju postizanja koordinisane kontrole punjenja baterija električnih vozila u distributivnim mrežama. Glavni cilj kontrolnog sistema je punjenje PHEV-a u periodima niskih cijena električne, uz poštovanje tehničkih ograničenja distributivne mreže. Odlučivanje agenata je ostvareno korišćenjem neuronskih mreža. Performanse kontrolnog sistema testirane su kako u normalnim uslovima rada mreže, tako i u situacijama gdje dolazi do narušavanja parametara. U radu [66] je predstavljen proširen metod koordinacije zasnovan na prognozi proizvodnje PV generatora i potrošnje električnih vozila u mikromrežama. Glavni cilj jeste poboljšati iskorišćavanje energije iz obnovljivih izvora putem optimalnog punjenja baterija električnih vozila. U ovom pristupu koriste se algoritam klastiranja i neuronske mreže za prognozu proizvodnje i potrošnje električne energije koristeći stvarne podatke. Razvijen je Stakelberg model igre, utemeljen na interakciji između kontrolnog centra i korisnika električnih vozila. Postizanje ravnoteže u Stakelberg modelu je ostvareno upotrebom genetskog algoritma baziranog na prognozi snage. U istraživanju [67] se proučava optimalno upravljanje punjenjem/praznjnjem električnih vozila na punionicama. Koristeći mehanizam transfera energije *vehicle-to-vehicle* (V2V), postavljen je problem raspodjele koristeći MILP s ograničenjem opterećenja punionice i nekoliko ograničenja vezanih za punjenje samih vozila. Uvođenjem dualne komponcije osnovni problem se razlaže na niz potproblema, koje je moguće riješiti za svako vozilo pojedinačno. Zatim se primjenjuje Bandersova dekompozicija kako bi se efikasno riješio svaki od potproblema. Kako se predloženi pristup može primijeniti decentralizovano, uključujući više nezavisnih entiteta, moguća je njegova primjena i u slučaju punionica velikih razmjera koje mogu primiti veliki broj vozila.

Analizirane metode za optimizaciju PHEV-a, uključujući stohastičko programiranje, *multi-agent* sisteme i V2V mehanizme, pokazuju značajan potencijal za smanjenje negativnih uticaja na distributivni sistem. Metode fokusirane na faktore opterećenja i varijacije opterećenja pružaju bolje performanse od pristupa koji se baziraju na minimizaciji gubitaka. Napredne tehnologije, poput neuronskih mreža, dodatno doprinose poboljšanju performansi. Međutim, izazovi kao što su tačno

predviđanje opterećenja, tehnička ograničenja mreže i složenost implementacije ostaju značajne barijere. Decentralizovani pristupi zahtijevaju preciznu koordinaciju, što može biti kompleksno u velikim mrežama.

2.5 Upravljanje potrošnjom

Upravljanje potrošnjom je strategija koja se primjenjuje kada potražnja za električnom energijom premašuje kapacitet mreže. Njen glavni cilj jeste spriječiti preopterećenje elemenata mreže i održavanje napona unutar prihvatljivih granica. Ova strategija uključuje selektivno isključivanje određenih djelova mreže ili grupu potrošača, kao i vremensku preraspodjelu opterećenja.

U radu [68] predstavljena je strategija upravljanja potrošnjom, bazirana na tehniči pomjeranja opterećenja (*eng. load shifting*), koja je namijenjena efikasnom upravljanju potrošnjom u budućim pametnim mrežama. *Day-ahead* tehnika pomjeranja opterećenja je matematički formulisana kao problem minimizacije, a za njegovo rješavanje primjenjuje se evolutivni algoritam. U okviru istraživanja, izvršene su simulacije na pametnoj mreži koja obuhvata tri kategorije potrošača: rezidencijalne, komercijalne i industrijske. Dobijeni rezultati su pokazali da se primjenom ove strategije mogu postići značajne uštede, uz istovremeno smanjenje vršnog opterećenja. U okviru [69] je analizirana primjena upravljanja potrošnjom, odnosno rezidencijalnih fleksibilnih resursa, u neizbalansiranim distributivnim mrežama niskog napona, s naglaskom na rješavanju problema visokih napona. Predstavljen je dvostepeni pristup regulacije napona, gdje se prvo planira optimalno vrijeme rada fleksibilnih resursa dan unaprijed, smanjujući troškove korisnika i vrijeme prekoračenja naponskih granica. Drugi korak je operacija u realnom vremenu, sa predloženim *voltage sensitivity-based* metodom pomjeranja vremena rada fleksibilnih resursa kako bi se očuvala naponska stabilnost. U istraživanju [70] je predložen algoritam za kontrolu napona u realnom vremenu koristeći pravljanje potrošnjom u vanrednim situacijama kao što su ispadi generatora, vodova, i fluktuacija uzrokovane nepouzdanom prognozom potrošnje i proizvodnje obnovljivih izvora. Ova metoda koristi podatke mjerenja u realnom vremenu kako bi odredila položaj prekidača OLTC transformatora i neophodno smanjenje opterećenja kako bi se održao prihvatljiv nivo napona. Takođe, predlaže se nova matrica osjetljivosti na smanjenje opterećenja kako bi se procijenili efekti svake promjene u opterećenju. U radu [71] je predstavljena metodologija za optimalno upravljanje opterećenjem primjenom Hopfield neuronske mreže. Ova strategija, koja se primjenjuje za sprječavanje visokih napona u vandrednim situacijama, se zasniva na analizi osjetljivosti i sastoji se od dva koraka. Prvo se opterećenje smanjuje kako bi se postigla željena vrijednost indikatora u odabranim čvorovima, baziranih na osjetljivosti i operativnim ograničenjima određenog područja. U drugom koraku se opterećenje smanjuje kako bi se naponi svih čvorova vratili unutar dozvoljenih granica. U radu [72], problem smanjenja opterećenja uslijed pojave niskih napona je definisan kao višekriterijumski optimizacioni problem, koji uključuje: gubitke energije, odstupanje napona i troškove smanjenja opterećenja. Za određivanje optimalnog smanjenja opterećenja korišćena je hibridna metoda evolucionarne optimizacije rojem čestica (*eng. Evolutionary Particle Swarm Optimization – EPSO*). U [73] je predstavljena tehnika za predviđanje nivoa smanjenja opterećenja u distributivnom sistemu, koja je nazvana *Quantum-Inspired Evolutionary Programming - Artificial Neural Network* (QIEP-ANN). QUIP je optimizaciona tehnika

zasnovana na konceptu kvantne mehanike u evolutivnom programiranju. Kvantno-inspirisano programiranje je implementirano kroz tri nivoa – kvantne jedinke, kvantne grupe i kvantni univerzum u cilju poboljšanja brzine algoritma. Ova tehnika je razvijena kako bi se pronašli optimalni parametri obuke, uključujući broj neurona u prvom i drugom sakrivenom sloju, stopu učenja i stopu momentuma.

U radovima [68-73] su istražene različite tehnike i algoritmi za aktivno upravljanje potrošnjom i regulaciju napona u distributivnim mrežama. Ovi pristupi obuhvataju efikasno korišćenje resursa, stabilizaciju napona u nepredviđenim situacijama i smanjenje troškova. Metode poput vremenskog pomjeranja opterećenja, dvostepenih pristupa regulaciji, *real-time* kontrole, kao i primjene neuronskih mreža i kvantno-inspirisanih algoritama, pokazuju značajan potencijal za unaprjeđenje efikasnosti i sigurnosti pogona distributivne mreže. Ipak, izazovi kao što su složenost implementacije, potreba za *real-time* podacima, usklađivanje sa regulativama, kao i poznavanje karakteristika različitih tipova potrošača predstavljaju prepreke koje treba prevazići za širu primjenu ovih strategija.

2.6 Komparativna analiza strategija aktivnog upravljanja elektrodistributivnom mrežom

Ovo poglavlje pruža temeljan pregled relevantnih istraživanja u području strategija aktivnog upravljanja distributivnom mrežom. Svaka od razmotrenih strategija ima svoje jedinstvene prednosti i nedostatke, koji značajno utiču na njihovu primjenjivost u praksi.

Rekonfiguracija distributivne mreže se može smatrati jednim od najefikasnijih pristupa jer pravilnim rasporedom prekidača omogućava direktnu kontrolu nad svim segmentima mreže. Ovaj pristup omogućava brzo izolovanje kvarova, što rezultira minimalnim prekidima u snabdijevanju. Mnoge srednjenoske distributivne mreže su već opremljene reklozerima, što značajno umanjuje investicione troškove, budući da se oni svode na troškove implementacije informaciono-komunikacione tehnologije. Dodatno, istraživanja su pokazala da čak i pri visokoj učestanosti rada, samo određeni broj prekidača aktivno učestvuje u procesu rekonfiguracije [28], što prethodno sprovedenom analizom može značajno smanjiti kompleksnost problema i troškove investicije. Međutim, postoji i nekoliko nedostataka ovog pristupa, uključujući povećanu mogućnost otkaza opreme, kao i potrebu za čestim održavanjem i zamjenom prekidača.

Integracija distribuiranih generatora donosi nove resurse i mogućnosti za unaprjeđenje pogona elektrodistributivne mreže. Kontinuirano prilagođavanje reaktivne snage i smanjivanje aktivne snage, uzimajući u obzir fleksibilnost i pogonska ograničenja generatora, omogućava efikasnu kontrolu napona i frekvencije, ali i smanjenje gubitaka. Budući da su distribuirani generatori često uzrok poremećaja u mreži, na ovaj način operatori imaju mogućnost upravljanja samim izvorima problema. Ključna komponenta uspješene primjene ove strategije je implementacija odgovarajućih komunikacionih tehnologija, koje je moguće integrirati tokom faze izgradnje elektrane. Važno je napomenuti da iako operatori distributivne mreže ne snose direktne investicione troškove, imaju obavezu plaćanja proizvođačima za pružene usluge.

Kompenzacija reaktivne snage, pored distribuiranih generatora, uključuje primjenu baterija kondenzatora i FACTS uređaja radi poboljšanja faktora snage, smanjenja gubitaka, rasterećenja mreže i poboljšanja naponskih prilika. Baterije kondenzatora su decenijama korišćene u distributivnim mrežama zbog svoje jednostavnosti i niske cijene, međutim njihova ograničena upravljivost predstavlja značajan nedostatak u slučaju savremenih distributivnih mreža gdje je neophodna brza i precizna kontrola energetskih tokova. S druge strane, iako savremeni FACTS uređaji omogućavaju kontinuiranu kontrolu i brzu reakciju na promjene u mreži u poređenju s baterijama kondenzatora, njihova šira primjena u distributivnim mrežama je i dalje ograničena visokim troškovima instalacije i održavanja. U slučaju integracije velikog broja distribuiranih generatora, korišćenje ovih uređaja za aktivno upravljanje bi zahtijevalo njihovu instalaciju na više lokacija. To bi rezultiralo značajnjim povećanjem troškova i kompleksnosti upravljanja.

Pored gore navedenih strategija, važan aspekt u upravljanju distributivnim mrežama je upravljanje potrošnjom. Ova strategija obuhvata širok spektar potrošača, uključujući industrijska postrojenja, komercijalne potrošače, domaćinstva i električna vozila s njihovim punionicama. Koordinisano punjenje električnih vozila, zajedno s upravljanjem ostalim potrošačima, omogućava preraspodjelu opterećenja tokom određenih vremenskih intervala. Dodatno, aktivno upravljanje baterijama električnih vozila omogućava operatorima mreže da balansiraju potrošnju i proizvodnju električne energije, što olakšava integraciju obnovljivih izvora energije. Međutim, osim većih industrijskih postrojenja, većinu potrošača čine oni manje snage koji su priključeni na niskonaponsku mrežu. Zbog njihove brojnosti se javlja problem u vidu kompleksnih sistema za upravljanje i komunikaciju. Usljed poremećaja aktivnosti potrošača, operatori su obavezni plaćati naknade za ovu uslugu u skladu s regulatornim zahtjevima ili ugovorima sa korisnicima. Takođe, važno je uzeti u obzir da intenzivno punjenje i pražnjenje baterija električnih vozila može ubrzati njihovu degradaciju.

Analizom se dolazi do zaključka da sve metode mogu imati važnu ulogu u održavanju sigurnosti i ekonomičnosti distributivne mreže. Međutim, one donose i dodatne troškove operatorima, uključujući investicije, održavanje i plaćanje naknada za pružene usluge. Takođe, implementacija komunikacionih i upravljačkih sistema nosi rizik od *cyber* napada, što može ozbiljno narušiti funkcionalnost sistema. Stoga je važno ulagati u adekvatnu *cyber* sigurnost kako bi zaštitali sistem od potencijalnih prijetnji.

Nakon razmatranja prednosti i mana različitih pristupa, u ovom radu je, s obzirom na niske investicione troškove i efikasnost, odabrana simultana primjena rekonfiguracije i upravljanja aktivnom i reaktivnom snagom distribuiranih generatora.

3. Predloženi metod za minimizaciju operativnih troškova

Prvi korak u rješavanju problema optimizacije, bez obzira o kojoj metodi se radi, jeste njegova formulacija, koja obuhvata definisanje kriterijumske funkcije i identifikaciju upravljačkih promjenjivih koje treba prilagoditi radi postizanja optimalnog rješenja. Takođe, neophodno je uzeti u obzir i relevantna ograničenja problema, bilo da su izražena u obliku jednakosti ili nejednakosti, kako bi se dobila praktična rješenja koja odgovaraju stvarnim uslovima. Matematički, proizvoljan optimizacioni problem se može formulisati kao [74]:

$$\min f(X), \text{ za } X = [x_1 \ x_2 \ \dots \ x_n] \quad (3.1)$$

uz ograničenja:

$$\begin{aligned} g_i(X) &\leq 0, \quad i=1,2,\dots,m \\ h_j(X) &= 0, \quad j=1,2,\dots,p \end{aligned} \quad (3.2)$$

gdje su:

X – n -dimenzionalni vektor optimizacionih (upravljačkih) promjenjivih,

$f(X)$ – kriterijumska funkcija,

$g_i(X)$ – ograničenja tipa nejednakosti i

$h_j(X)$ – ograničenja tipa jednakosti.

3.1 Kriterijumska funkcija

U domenu primjene optimizacionih metoda, ključni korak ka pronalaženju optimalnih rješenja predstavlja precizno definicije kriterijumske funkcije. Ova funkcija predstavlja osnovni kriterijum za procjenu kvaliteta i rangiranje potencijalnih rješenja. U kontekstu ovog istraživanja, definisanje odgovarajuće kriterijumske funkcije i njenih parametara omogućava usmjeravanje procesa optimizacije prema najpovoljnijim ishodima.

Prilikom unaprijeđenja performansi distributivnih mreža, razmatra se niz kriterijuma koji variraju u skladu sa postavljenim ciljevima. Ovi kriterijumi, između ostalog, obuhvataju smanjenje gubitaka u mreži [2,11-13,41,46], održavanje naponskih profila unutar definisanih granica [44,45,47], minimizaciju ekoloških uticaja [75], i optimizaciju operativnih troškova [16,24,32,41]. Pored jednokriterijumske funkcije, fokusiranih na pojedinačne ciljeve, takođe se primjenjuju i višekriterijumske funkcije kako bi se postigao balans između različitih aspekata optimizacije [27,29,36,50].

U procesu optimizacije aktivnog upravljanja distributivnom mrežom, nužno je razumjeti da se određeni ciljevi mogu međusobno sukobljavati, na taj način stvarajući kompleksnost u odabiru optimalnih rješenja. Upravljanje ovakvim mrežama zahtijeva sveobuhvatan pristup koji obuhvata različite spekte, od tehničkih do ekoloških i ekonomskih faktora, radi postizanja optimalnog funkcionisanja sistema.

U ovom istraživanju, glavni fokus je usmjeren na smanjenje operativnih troškova distributivne mreže u toku jednog dana. Implementacijom tri različite strategije aktivnog upravljanja, rekonfiguracije i upravljanja aktivnom i reaktivnom snagom distribuiranih generatora, operativni troškovi obuhvataju različite komponente koje je neophodno uzeti u obzir:

$$\min_x f = f_{GUB} + f_P + f_{Q_{DG}} + f_{P_{DG}} \quad (3.3)$$

f_{GUB} predstavlja troškove gubitaka aktivne snage u toku posmatranog dana i matematički se formuliše kao:

$$f_{GUB} = K_1 \sum_{i=1}^{N=24} P_{GUB}^i \quad (3.4)$$

gdje su :

K_1 – Koeficijent koji označava cijenu električne energije koju operator distributivne mreže plaća za pokrivanje gubitaka i

P_{GUB}^i – Gubici aktivne snage u i -tom satu.

f_P predstavlja troškove uslijed prekidačkih akcija u toku posmatranog dana i matematički se formuliše kao:

$$f_P = K_2 N_P \quad (3.5)$$

gdje su:

K_2 – Koeficijent koji označava cijenu jedne prekidačke akcije i

N_P – Broj prekidačkih akcija u toku posmatranog dana.

$f_{Q_{DG}}$ predstavlja troškove upravljanja reaktivnom snagom distribuiranih generatora u toku posmatranog dana i matematički se formuliše kao:

$$f_{Q_{DG}} = K_3 \sum_{i=1}^{N=24} \sum_{k=1}^{N_{DG}} Q_{DG,k}^i \quad (3.6)$$

gdje su:

K_3 – Koeficijent koji označava naknadu distribuiranom generatoru za upravljanje reaktivnom snagom,

$Q_{DG,k}^i$ – Reaktivna snaga k -tog distribuiranog generatora u i -tom satu i

N_{DG} – Broj distribuiranih generatora u mreži.

$f_{P_{DG}}$ predstavlja troškova upravljanja aktivnom snagom distribuiranih generatora u toku posmatranog dana i matematički se formuliše kao:

$$f_{P_{DG}} = K_4 \sum_{i=1}^{N=24} \sum_{k=1}^{N_{DG}} P_{DG_{red},k}^i \quad (3.7)$$

gdje su:

K_4 – Koeficijent koji označava naknadu distribuiranom generatoru za upravljanje aktivnom snagom,

$P_{DG_{red},k}^i$ – Smanjenje aktivne snage k -tog distribuiranog generatora u i -tom satu i

N_{DG} – Broj distribuiranih generatora u mreži.

Predstavljanje upravljačkih promjenjivih u ovom istraživanju koristi kombinaciju cjelobrojnog i realnog kodiranja. Realnim brojevima se označavaju vrijednosti reaktivne i aktivne snage distribuiranih generatora na satnom nivou, pružajući precizne informacije o njihovim performansama. Cjelobrojno kodiranje se primjenjuje kako bi se označio redni broj primijenjene kombinacije uklopnih stanja daljinskih upravljaljivih prekidača iz skupa T u posmatranom satu. Svako uklopno stanje u T je predstavljeno binarnim zapisom, gdje vrijednost 0 označava isključeni prekidač, a vrijednost 1 označava uključeni prekidač. Skup T , čija je veličina označena sa N_t , obuhvata samo one topologije koje garantuju radijalnost i povezanost distributivne mreže. Struktura hromozoma svake jedinke se može predstaviti na sledeći način:

$$\mathbf{X} = [T_D, Q_{DG}, P_{DG}] \quad (3.8)$$

gdje su:

T_D skup upravljačkih promjenjivih koje predstavljaju primijenjene topologije po satima u toku posmatranog dana:

$$T_D = [t_1, t_2, \dots, t_i, \dots, t_{24}] \quad (3.9)$$

Q_{DG} skup upravljačkih promjenjivih koje predstavljaju reaktivne snage distribuiranih generatora po satima u toku posmatranog dana:

$$Q_{DG} = [Q_1^1, \dots, Q_1^{24}, \dots, Q_{N_{DG}}^1, \dots, Q_{N_{DG}}^{24}] \quad (3.10)$$

P_{DG} skup upravljačkih promjenjivih koje predstavljaju aktivne snage distribuiranih generatora po satima u toku posmatranog dana:

$$P_{DG} = [P_1^1, \dots, P_1^{24}, \dots, P_{N_{DG}}^1, \dots, P_{N_{DG}}^{24}] \quad (3.11)$$

Tokom proučavanja ovog problema, analizirane su različite strategije kodiranja za prikaz uklopnog stanja distributivne mreže na satnom nivou. Pored primjenjenog pristupa, razmatrani su i alternativni, uključujući binarno kodiranje uklopnog stanja daljinskih upravljaljivih prekidača tokom svakog sata i cijelobrojno kodiranje zasnovano na rednom broju isključenih prekidača u svakoj od potencijalnih petlji mreže na satnom nivou. Bitno je istaći da su ove strategije doprinijele izazovu u vidu značajnog povećanja broja upravljačkih varijabli, što je posebno izraženo u mrežama sa većim brojem elemenata i potencijalnih petlji. S obzirom na prirodu problema, gdje veliki broj potencijalnih rješenja ne ispunjava uslove radijalnosti i povezanosti mreže, dodatno otežava proces pretrage širokog spektra rješenja, čineći pronalažak optimalnih i suboptimalnih rješenja izazovnim zadatkom. Primjera radi, kod binarnog kodiranja postoji 2^n mogućih kombinacija, gdje n predstavlja broj daljinskih upravljaljivih prekidača. Ovako obiman prostor mogućnosti koji dodatno zahtjeva provjeravanje uslova radijalnosti i povezanosti za sve potencijalne kombinacije, dovodi do značajnog produženja vremena izvršavanja algoritma.

U cilju prevazilaženja ovih izazova, predloženi pristup uključuje dodatni korak *prescreening-a* mreže. Tokom ove inicijalne faze, osnovni cilj jeste identifikacija izvodljivih konfiguracija koje zadovoljavaju ograničenja radijalnosti i povezanost. Ovaj proces selekcije služi kao ključan mehanizam za značajno smanjenje prostora pretrage, čime se poboljšava učinkovitost algoritma u pronalaženju boljih rješenja u manjem broju iteracija. Dodatno, efikasnost iteracija se značajno poboljšava kroz izbjegavanje potrebe za ponovnim ispitivanjem radijalnosti i povezanosti za svako potencijalno rješenje unutar svake generacije. U suštini, ova optimizacija ne samo da poboljšava računarsku ekonomičnost već se i usklađuje sa krajnjim ciljem postizanja optimalnih rješenja kroz produktivno korišćenje resursa. Za testni sistem koji je korišćen u ovom istraživanju, primjenjeni pristup je smanjio broj mogućih kombinacija sa 2097152 na 3936.

3.2 Ograničenja

Ograničenja igraju važnu ulogu u optimizacionom procesu, postavljajući realne uslove i restrikcije koje moraju biti zadovoljene kako bi optimizacija rezultirala praktičnim i izvodljivim rješenjima. Ona jasno određuju dopuštene vrijednosti potencijalnih rješenja, usmjeravajući tako istraživanje i osiguravajući da se fokusira na relevantna rješenja.

Za uspješno rješavanje ovog optimizacionog problema, neophodno je pažljivo analizirati i zadovoljiti niz postavljenih ograničenja u toku posmatranog dana, odnosno u svakom satu. Ova ograničenja obuhvataju naponske granice, termička ograničenja, topološka ograničenja, kao i specifična pogonska ograničenja distribuiranih generatora.

- ***Naponska ograničenja***

Naponska ograničenja su veoma bitna u distributivnim mrežama, jer određuju raspon prihvatljivih vrijednosti napona u različitim tačkama. Održavanje naponskih ograničenja unutar definisanih granica je od suštinskog značaja za očuvanje stabilnosti i sigurnosti distributivnog sistema. Ovo naglašava važnost praćenja i upravljanja naponima kako bi se osiguralo da mreža funkcioniše u okviru sigurnih parametara, pružajući pouzdanu isporuku električne energije. Izuzetno visoki i niski naponi mogu izazvati razne probleme, uključujući degradaciju kvaliteta električne energije, oštećenje opreme i smanjenje efikasnosti distributivne mreže. Zbog navedenih razloga, uvjek je nužno osigurati da se naponi svih čvorova održavaju unutar propisanih granica [76]:

$$V_{min} \leq V_i \leq V_{max} \quad (3.12)$$

gdje su:

V_{min} – minimalna dozvoljena vrijednost napona

V_{max} – maksimalna dozvoljena vrijednost napona

- ***Termička ograničenja elemenata mreže***

Termička ograničenja elemenata mreže predstavljaju granice za maksimalna opterećenja koja pojedini elementi, kao što su transformatori i provodnici, mogu podnijeti bez rizika od oštećenja i smanjenja efikasnosti. Za svaki element u mreži ova ograničenja moraju biti zadovoljena:

$$I_i \leq I_{i,n} \quad (3.13)$$

gdje je:

$I_{i,n}$ – naznačena struja i-tog elementa

- ***Topološka ograničenja***

Radijalnost distributivne mreže predstavlja suštinsku karakteristiku koja se odnosi na topološku strukturu mreže. Ova karakteristika podrazumijeva da postoji tačno jedna putanja koja povezuje napojni čvor i svaki drugi čvor u mreži, na taj način izbjegavajući kreiranje petlji u strukturi. Ovakav koncept doprinosi smanjenju struja kratkog spoja i pojednostavljenju podešavanja relejnih zaštita. U ovom istraživanju radijalnost mreže nakon izvršene rekonfiguracije se utvrđuje kroz primjenu matrice

povezanosti (*Connected matrix*) i *Depth First Search (DFS)* algoritma [77]. Polazeći od napojnog čvora DFS algoritam analizira konstruisanu matricu, koja pokazuje međusobnu povezanost čvorova u mreži, kako bi utvrdio postojanje potencijalnih petlji u novoj topološkoj strukturi.

Osim očuvanja radijalne strukture, osiguranje da svaki potrošač bude adekvatno napajan je takođe od izuzetnog značaja prilikom rekonfiguracije distributivne mreže. Ovo garantuje neprekidno snabdijevanje električnom energijom održavajući pouzdanost sistema. Izolacija ili neispravno napajanje bilo kog čvora može prouzrokovati prekide u isporuci električne energije, što se ne smije dozvoliti u slučaju normalnog funkcionisanja sistema. Da bi se ispunilo ovo ograničenje, neophodno je osigurati da svi čvorovi pripadaju istom *subgraph-u*, kao i ispuniti sledeću relaciju:

$$N_{grana} = N_{čvorova} - 1 \quad (3.14)$$

gdje su:

N_{grana} – broj grana u mreži

$N_{čvorova}$ – broj čvorova u mreži

- **Pogonska ograničenja distribuiranih generatora**

Pored mrežnih ograničenja, takođe je neophodno uzeti u obzir i ograničenja izlaznih snaga svih distribuiranih generatora:

$$P_{DG_{min},k} \leq P_{DG,k} \leq P_{DG_{max},k} \quad (3.15)$$

$$Q_{DG_{min},k} \leq Q_{DG,k} \leq Q_{DG_{max},k} \quad (3.16)$$

$$\sqrt{(P_{DG,k})^2 + (Q_{DG,k})^2} \leq S_{DG,k}^{max} \quad (3.17)$$

$$\cos \varphi_{DG} \geq 0.8 \quad (3.18)$$

gdje su :

$k = 1, 2, \dots, N_{DG}$

N_{DG} – broj distribuiranih generatora u mreži

3.3 DistFlow metod za proračun tokova snaga

Za proračun vrijednosti napona, tokova aktivnih i reaktivnih snaga u različitim scenarijima, primjenjuju se metode za proračun tokova snaga. Postoji širok spektar metoda i njihovih varijacija, kao što su Gauss-Seidelova, Newton-Raphsonova, Shirmohammadijeva i *Distflow* metoda.

Gauss-Seidelova i Newton-Raphsonova metoda, iako spadaju u tradicionalne i najčešće korišćene metode kod petljastih mreža, često se suočavaju sa izazovima pri analizi radijalnih mreža, kakve su elektrodistributivne. Gauss-Seidelov metod se zasniva na matrici admitansi. U slučaju radijalnih mreža, ova matrica je dijagonalna, što negativno utiče na konvergenciju proračuna. S druge strane, Newton-Raphsonov metod koristi matricu Jakobijana, čiji elementi predstavljaju parcijalne izvode aktivnih i reaktivnih snaga u čvorove po faznom stavu i modulu napona. Kod radijalnih mreža matrica Jakobijana je rijetka, što može dovesti do problema s numeričkom stabilnošću proračuna prilikom inverzije ove matrice u svakoj iteraciji.

Za prevazilaženje ovih izazova, razvijeni su Shirmohammadijev i *Distflow* metod, posebno prilagođeni za upotrebu na radijalnim mrežama. Dok se Shirmohammadijev metod oslanja na Prvi i Drugi Kirhofov zakon i primjenjiv je na slabo upetljanim mrežama, *Distflow* metod se bazira na jednačini za pad napona na kratkom vodu i koristi se isključivo u radijalnim mrežama. Ova dva pristupa osiguravaju tačnost rezultata, brzu i pouzdanu konvergenciju, što je od suštinskog značaja za optimizaciju performansi radijalnih mreža. U ovom istraživanju, za proračun tokova snaga odabran je *Distflow* metod koji pokazuje bržu konvergenciju i zahtijeva manji broj iteracija u poređenju sa Shirmohammadijevim metodom [78].

DistFlow metoda predstavlja efikasan pristup za proračun tokova snaga u elektroenergetskim sistemima, posebno prilagođen za radijalne distributivne mreže [12]. Često korišćen zbog svoje jednostavnosti, ovaj metod omogućava brze analize bez potrebe za kompleksnim matematičkim formulama. U suštini, *DistFlow* metoda koristi princip teorije grafova i Kirhofovih zakona za proračun tokova snaga. Njegova osnova se zasniva na izvođenju jednačina koje proizilaze iz osnovne jednačine za pad napona na kratkom vodu [12]:

$$\underline{V}_i = \underline{V}_{i+1} + (R_i + jX_i)\underline{I}_i \quad (3.19)$$

Za proračun tokova snaga u radijalnoj distributivnoj mreži, gdje su impedanse vodova definisane kao $\underline{Z}_l = R_l + jX_l$, a opterećenja kao konstantna snaga, $\underline{S}_L = P_L + jQ_L$, koristi se niz rekurzivnih jednačina poznatih kao *DistFlow* jednačine. Ove jednačine se oslanjaju na aktivnu snagu (P_i), reaktivnu snagu (Q_i) i vrijednost napona (V_i) na početku grane kako bi se precizno odredili isti parametri na kraju grane.

$$\underline{V}_{i+1} = V_i - \frac{R_i P_i + X_i Q_i}{V_i} - j \frac{X_i P_i - R_i Q_i}{V_i} \quad (3.20)$$

Usvajajući da je fazni napon u i-tom čvoru $V_i = V_i | 0^\circ$, moguće je predstaviti kvadrat modula napona u $(i+1)$ -om čvoru pomoću jednačine:

$$V_{i+1}^2 = V_i^2 - 2(R_i P_i + X_i Q_i) + (R_i^2 + X_i^2) \frac{P_i^2 + Q_i^2}{V_i^2} \quad (3.21)$$

Injectiranja aktivne i reaktivne snage na kraju grane se mogu odrediti pomoću jednačina [12]:

$$P_{i+1} = P_i - R_i \frac{P_i^2 + Q_i^2}{V_i^2} - P_{L_{i+1}} \quad (3.22)$$

$$Q_{i+1} = Q_i - X_i \frac{P_i^2 + Q_i^2}{V_i^2} - Q_{L_{i+1}} \quad (3.23)$$

Dakle, ukoliko su P_o , Q_o i V_o poznate ili procijenjene vrijednosti u nultom čvoru, tada se te iste veličine na ostalim čvorovima mogu izračunati primjenom navedenih jednačina. Ovaj postupak se može nazvati *forward update*.

Takođe, *DistFlow* jednačine grana mogu biti formulisane i unazad, što znači da koriste aktivnu snagu, reaktivnu snagu i napon na prijemnom kraju (čvoru) grane (P_i , Q_i i V_i) kako bi se izrazili isti parametri čvora na početku grane. To, takođe, dovodi do niza rekurzivnih jednačina koje se nazivaju *backward branch equations* [12]:

$$P_{i-1} = P_i + R_i \frac{P_i'^2 + Q_i'^2}{V_i^2} + P_{L_{i-1}} \quad (3.24)$$

$$Q_{i-1} = Q_i + X_i \frac{P_i'^2 + Q_i'^2}{V_i^2} + Q_{L_{i-1}} \quad (3.25)$$

$$V_{i-1}^2 = V_i^2 + 2(R_i P_i' + X_i Q_i') + (R_i^2 + X_i^2) \frac{P_i'^2 + Q_i'^2}{V_i^2} \quad (3.26)$$

gdje P'_i i Q'_i predstavljaju zbir snage i-te grane i potrošača u i-tom čvoru, odnosno $P'_i = P_i + P_{L_i}$ i $Q'_i = Q_i + Q_{L_i}$.

Kao i kod *forward update*, može se definisati *backward update* počevši od poslednjeg čvora u mreži uz pretpostavku da su vrijednosti parametara P_n , Q_n i V_n na tom čvoru poznate. Zatim se postepeno kreće unazad računajući iste veličine na ostalim čvorovima. Ovaj proces se završava na nultom čvoru proračunavajući snage injektiranja u posmatranu mrežu.

Naizmjeničnom primjenom *backward* i *forward update*-a, omogućava proračun vrijednosti napona, kao i aktivnih i reaktivnih snaga po granama razgranate radikalne mreže. Ovaj iterativni

postupak se kontinuirano izvodi sve dok apsolutna vrijednost promjene napona u istom čvoru uzastopnih iteracija ne postane manja od unaprijed definisane tačnosti.

3.4 Rješenje optimizacionog problema

Optimizacija je proces identifikacije najboljeg mogućeg rješenja unutar skupa različitih mogućnosti za rješavanje specifičnog problema. Ovaj proces se primjenjuje u velikom broju disciplina, uključujući matematiku, inženjeringu, ekonomiju, računarstvo i mnoge druge. U osnovi, optimizacija zahtijeva pronalaženje vrijednosti upravljačkih promjenjivih koje minimiziraju ili maksimiziraju ciljnu funkciju, uz poštovanje postavljenih ograničenja. S obzirom na raznolikost problema optimizacije, razvijeno je mnoštvo različitih metoda kako bi se prilagodili specifičnim zahtjevima pojedinih problema.

Postojanje metoda optimizacije se može pratiti unazad do vremena Njutna, Lagranža i Košija. Zasluge za razvoj metoda baziranih na diferencijalnom računu pripadaju Njutnu i Lajbnicu. Osnove računa varijacija, oblasti koja se bavi minimizacijom funkcionala, postavljene su od strane Bernulija, Ojlera, Lagranža i Vajerštrasa. Lagranžova metoda je zaslužna za napredak u optimizaciji sa ograničenjima, uvodeći koncept multiplikatora. *Steepest descent* metod za rješavanje problema minimizacije bez ograničenja je prvi put primijenjen od strane Košija. Uprkos ovim ranim dostignućima, malo napretka je postignuto do sredine dvadesetog vijeka, kada su brzi računari omogućili sprovođenje postupka optimizacije i podstakli dalja istraživanja na ovom polju [74, 79].

U radu [80], istraživanje o neophodnim i dovoljnim uslovima za optimalno programiranje postavilo je osnovne principe nelinearnog programiranja. Dalji napredak u optimizaciji obuhvata pojavu *simplex* metode za rješavanje problema linearнog programiranja i objavlјivanje principa optimalnosti 1957. godine u kontekstu dinamičkog programiranja [81, 82]. U istraživanju [83] je prvi put objavljen pojam cjelobrojnog programiranja, koji predstavlja jedano od najbrže rastućih područja optimizacije, s obizrom na to da mnoge praktične primjene pripadaju ovoj kategoriji [79].

Ove klasične metode optimizacije se mogu klasifikovati na dvije osnovne kategorije: direktnе i gradijentne [84]. U direktnim metodama, akcenat je na analizi kriterijumske funkcije i njenih ograničenja bez korišćenja gradijenta, odnosno pravca opadanja njene vrijednosti. Nasuprot tome, gradijentne metode koriste prvi ili drugi parcijalni izvod ciljne funkcije za vršenje pretrage potencijalnih rješenja. Direktni pristupi, iako mogu sporije konvergirati i zahtijevati više evaluacija funkcije, često su prilagodljiviji različitim problemima s minimalnim modifikacijama. Gradijentne metode pružaju bržu konvergenciju, ali mogu naići na izazove prilikom rješavanja nediferencijabilnih problema.

Iako ove metode, oslanjajući se na matematičke principe, osiguravaju preciznost u procesu optimizacije i dolaze do optimalnog rješenja, važno je imati na umu da njihova primjena može biti izuzetno ograničena. Klasične metode kao što su *steepest descent* ili metoda najmanjih kvadrata su lokalne prirode i temelje se na linearizaciji problema. Koriste iterativni proces s parcijalnim izvodima za poboljšanje početnog rješenja. Važno je istaknuti da ovakva priroda pretrage može, uslijed prisutne

nelinearnosti i kompleksne zavisnosti među upravljačkim promjenjivim, dovesti do zavisnosti od početnih rješenja i "zaglavljivanja" u lokalnom optimumu. Takođe, izračunavanje izvoda može biti zahtjevno i dodatno doprinosi nesigurnosti, posebno ako se koriste numeričke aproksimacije. S druge strane, globalne prirode se baziraju na principu slučajnog pretraživanja. Međutim, ove metode zahtijevaju dugo vrijeme proračuna uslijed pretraživanja nepovoljnih djelova prostora pretrage [85].

U ovom radu, definisani optimizacioni problem je izrazito nelinearan i kombinatorni s upravljačkim vektorom koji predstavlja kombinaciju cijelih i realnih brojeva. Klasične metode nailaze na brojne poteškoće u rješavanju ovakvih problema, kao što je istaknuto literaturi. Zbog toga su za rješavanje sličnih problema razvijene nove metaheurističke metode optimizacije koje su konceptualno drugačije od tradicionalnih tehnika matematičkog programiranja. Iako ne garantuju optimalnost, ove metode su postale ključan pristup za rješavanje kompleksnih inženjerskih problema posljednjih godina.

Nastanak metaheurističkih metoda predstavlja značajnu prekretnicu u oblasti optimizacije. Ovi inovativni pristupi rješavanju optimizacionih problema predstavljaju odstupanje od klasičnih metoda, često suočenih sa izazovima u rješavanju kompleksnih problema uslijed nemogućnosti pronalaska tačnih rješenja u realnom vremenskom periodu. Umjesto potrage za idealno optimalnim rješenjem, metaheuristike se fokusiraju na pronalaženje zadovoljavajućih rješenja u prihvatljivom vremenskom okviru. Suštinska karakteristika ovih pristupa je njihova prilagodljivost. Ovi metodi se lako prilagođavaju raznim problemima optimizacije, prilagodavajući se varijacijama očekivanog kvaliteta rješenja i prihvatljivog vremena proračuna. Takođe, djeluju bez strogih zahtjeva za formulacijom problema, kao što su linearni izrazi za ograničenja ili ciljne funkcije. Ove iterativne metode koriste stohastičke operacije tokom procesa pretrage, prilagodavajući jedno ili više početnih rješenja generisanih nasumično iz prostora pretrage. Sposobnost metaheurističkih metoda da se učinkovito nose s različitim nivoima složenosti praktičnih problema i pruže kvalitetna rješenja čini ih nezamjenjivim alatima u savremenoj praksi.

Osnovna karakteristika svih metaheuristika jeste pažljiva kombinacija dva ključna aspekta: pretraživanja i eksploracije. Istraživanje se odnosi na sposobnost algoritma da pronalazi nova rješenja u širokom prostoru pretrage, pružajući globalni pristup. Eksploracija, s druge strane, istražuje kako algoritmi mogu koristiti informacije iz prethodnih koraka kako bi dublje istraživali i koncentrisali se na lokalno poboljšanje. Ovaj balans omogućava metaheuristikama da kombinuju globalni i lokalni pristup pretrazi. Različite metode postavljaju različite akcente na ova dva aspekta. Na primjer, *random search* metoda, jednostavna strategija slučajnog izbora rješenja tokom određenog broja iteracija, predstavlja apsolutno istraživački pristup [86]. S druge strane, pristup nazvan *hill climbing*, gdje se trenutno rješenje modifikuje korak po korak u nastojanju da se postigne bolja vrijednost, predstavlja tipičan primjer potpune eksploracije [87]. Bitno je napomenuti da metaheurističke metode često omogućavaju korisnicima prilagođavanje ovog odnosa kroz različite parametra.

Prednosti metaheurističkih u odnosu na klasične metode [88]:

- Pružaju adekvatna rješenja za računski jednostavne probleme sa velikom složenošću ulaznih podataka, što može predstavljati prepreku za klasične metode.
- Omogućavaju pronalaženje zadovoljavajućih rješenja za kompleksne probleme u razumnom vremenskom okviru.

- Ne zahtijevaju informacije o gradijentu ciljne funkcije, što ih čini pogodnim za situacije bez analitičkog izraza funkcije koja se opisuje.
- Posjeduju sposobnost da izbjegnu lokalne optimume.
- Učinkovito se nose s nesigurnostima ciljnih funkcija zahvaljujući sposobnosti adaptacije i oporavka od lokalnih optimuma.
- Većina ovih metoda je pogodna za rješavanje višekriterijumske problema.

Metaheurističke metode crpe inspiraciju iz fizičkih, prirodnih i bioloških procesa, s ciljem da njihove mehanizme imitiraju kroz različite operatore. Iako ove metode u opštem slučaju pružaju visokokvalitetna rješenja i mogu se prilagoditi različitim tipovima problema, njihove specifične strategije pretraživanja prostora rješenja često rezultiraju specifičnim prednostima ali i nedostacima kao što su spora konvergencija, visoki zahtjevi za podešavanjem parametara i osjetljivost pretrage na početna rješenja.

Među značajnijim metaheurističkim metodama se izdvajaju GA, PSO, CSA, Differential Evolution (DE), SA, ACO, Artificial Bee Algorithm (ABC). Prednosti i mane ovih pristupa su istaknute u Tabeli 3.1 kako bi se bolje razumjelo njihovo područje primjene i ograničenja [89,90]. Budući da se u literaturi često koriste za rješavanje širokog spektra problema, GA, PSO i DE su odabrani za dalje detaljnije razmatranje u ovom radu.

Tabela 3.1 Prednosti i nedostaci metaheurističkih metoda

Algoritam	Prednosti	Nedostaci
CSA [91]	<ul style="list-style-type: none"> - Posjeduje sposobnost da konvergira ka pravom globalnom optimumu, - Ima mogućnost da vrši i lokalnu i globalnu pretragu. 	<ul style="list-style-type: none"> - Postiže nisku tačnost u rješavanju problema klasifikacije, - Ima nisku stopu konvergencije.
DE [92]	<ul style="list-style-type: none"> - Efikasno rješava probleme čije su fitness funkcije nediferencijabilne, multimodalne ili nelinearne, - Može da se nosi sa fitness funkcijama visoke računske složenosti, - Jednostavan, ima mali broj parametara. 	<ul style="list-style-type: none"> - Nema stabilnu konvergenciju, - Lako se “zaglavljuje” u lokalnom optimumu. - Zahtijeva podešavanje parametara. - Korišćenje istih podešavanja parametara možda neće dovesti do globalnog optimuma.
GA [93]	<ul style="list-style-type: none"> - Mogućnost rješavanja različitih vrsta optimizacionih problema, - Ima jednostavne parametre - Jednostavno kombinovanje sa drugim algoritmima, - Mogućnost primjene za realni i binarni prostor pretraživanja. 	<ul style="list-style-type: none"> - Niska stopa konvergencije, - Stabilnost konvergencije zavisi od stopa mutacije i ukrštanja, - Mogućnost “zaglavljivanja” u lokalnom optimumu i postizanja suboptimalnih rješenja, - Slaba lokalna pretraga.

Algoritam	Prednosti	Nedostaci
PSO [94]	<ul style="list-style-type: none"> - Lak za implementaciju i jednostavna struktura, - Mali broj parametara, - Mala zavisnost od inicijalnih rješenja, 	<ul style="list-style-type: none"> - Slaba lokalna pretraga, - “Zaglavljivanje” u lokalne optimume prilikom rješavanja multimodalnih problema
ACO [95]	<ul style="list-style-type: none"> - Nema preuranjenu konvergenciju, - Robustan i fleksibilan u dinamičkim okruženjima, - Prikidan za probleme zasnovane na grafu. 	<ul style="list-style-type: none"> - Raspodjela vjerovatnoće za izbor puteva se mijenja sa iteracijama, - Složen za kodiranje, - Složen za teorijsku analizu.
ABC [96]	<ul style="list-style-type: none"> - Robustan, - Brzo konvergira, - Zahtijeva malo parametara, - Fleksibilan. 	<ul style="list-style-type: none"> - Ima preuranjenu konvergenciju u kasnijim fazama pretrage, - Najbolja vrijednost koju pronađe algoritam možda nije dovoljno precizna za rešavanje problema.
SA [97]	<ul style="list-style-type: none"> - Kratko vrijeme izvršavanja, - Otporan na “zaglavljivanje” u lokalnom optimumu, - Jednostavna implementacija, 	<ul style="list-style-type: none"> - Zavisnost rješenja od broja iteracija (brzine hlađenja), - Zavisnost rješenja od početne temperature.

3.4.1 Genetski algoritam

Genetski algoritam, kreiran od strane John Hollanda i njegovih saradnika tokom šezdesetih i sedamdesetih godina prošlog vijeka [93,98], predstavlja model biološke evolucije zasnovan na principima prirodne selekcije Čarlsa Darvina. U prirodi, organizmi najbolje prilagođeni svojoj okolini imaju veće šanse za preživljavanje i reprodukciju, što rezultira prenošenjem njihovih karakteristika na potomstvo. Ovaj proces selekcije omogućava populaciji da postepeno evoluira i prilagodi se promjenjivim uslovima okoline. Slično tome, genetski algoritam simulira ovaj proces kroz iterativno pretraživanje prostora rješenja. Počinje s populacijom slučajno generisanih rješenja, koja se zatim ocjenjuju na osnovu njihove prilagođenosti rješavanju problema. Rješenja koja su bolja imaju veću šansu da budu odabrana za reprodukciju, gdje se kombinuju djelovi reprezentacije rješenja kako bi se generisala nova populacija. Ovaj proces se sprvodi kroz generacije sve dok se ne postigne željeno rješenje, primjenjujući operatore selekcije, ukrštanja, mutacije i elitizma.

- **Selekcija**

Selekcija predstavlja prvi korak gdje se jedinke iz trenutne populacije odabiraju kako bi formirale parove za sljedeću fazu - mutaciju. Ovaj korak ima za svrhu identifikaciju i odabir jedinki sa većom prilagođenošću, osiguravajući da se korisne karakteristike nasleđuju u sledećoj generaciji. Najčešće korišćen operator selekcije omogućava da se jedinke biraju iz populacije s vjerovatnoćom koja je proporcionalna njihovoј prilagođenosti, koja se mjeri *fitness* funkcijom. Analogija s ruletom

se često koristi za ilustraciju ovog procesa, gdje segmenti na ruletu predstavljaju jedinke, a veličina svakog segmenta odražava njihovu prilagođenost [74].

Pored rulet selekcije, često se koriste i drugi pristupi kao što je turnirska selekcija i selekcija rangiranjem. U turnirskoj selekciji, nasumično se odabere određeni broj jedinki, a zatim se među njima bira ona sa najboljom prilagođenošću. S druge strane, kod selekcije rangiranjem, jedinke se rangiraju prema svojoj prilagođenosti, pri čemu se bolje rangirane jedinke biraju za reprodukciju.

- **Ukrštanje**

Nakon procesa selekcije, slijedi primjena operatora ukrštanja. Ovaj korak ima za cilj kombinovanje informacija izabranih jedinki (roditelja) kako bi se formirale nove jedinke (potomstvo). U literaturi su predloženi različiti operatori ukrštanja. Najčešće korišćeni je *single-point crossover* (ukrštanje u jednoj tački) koji podrazumijeva nasumični izbor tačke ukrštanja duž hromozoma jedinke, pri čemu se geni sa desne strane te tačke razmjenjuju između te dvije jedinke. Operator ukrštanja kombinuje gene visoko prilagođenih roditelja, što bi trebalo rezultirati potomstvom s poboljšanom prilagođenošću. Međutim, budući da se tačka ukrštanja odabira nasumično, karakteristike novonastalih jedinke često variraju u odnosu na njihove roditelje. Ako su ove nove jedinke jednako ili bolje prilagođene od roditelja, doprinijeće bržem poboljšanju prosječne *fitness* vrijednosti nove populacije. Pored *single-point* ukrštanja, često se koriste i *uniform-crossover*, *two-point crossover*, *multi-point crossover* i druge. U praksi, odabir odgovarajućeg operatora ukrštanja zavisi od prirode problema, pa se često sprovode eksperimenti kako bi se odabrala optimalna tehnika za datu situaciju.

- **Mutacija**

Nakon ukrštanja, genetski algoritam primjenjuje operator mutacije kako bi unaprijedio genetsku raznolikost. Mutacija, koja predstavlja završni korak formiranja nove generacije, uključuje nasumičnu modifikaciju jednog ili više gena unutar jedinke. Ova promjena osigurava raznolikost unutar populacije, omogućavajući istraživanje različitih djelova prostora rješenja. Mutacija pomaže izbjegavanju lokalnih minimuma, doprinoseći sposobnosti algoritma da istraži šire oblasti pretrage, ali i da povrati izgubljeni genetski materijal koji bi inače bio izgubljen tokom selekcije i ukrštanja.

- **Elitizam**

Selekcija zasnovana na prilagođenosti nije garancija da će uvijek odabrati najprilagodeniju jedniku, posebno kada nema značajne razlike u prilagođenosti jedinki. To može dovesti do propuštanja najbojih rješenja. Zbog toga se uvodi elitizam, kao dodatni nivo selekcije, koji prepoznaje i čuva najbolje jedinke u populaciji, direktno ih prenoseći u narednu generaciju bez ikakvih izmjena. Uvođenjem elitizma se osigurava očuvanje najboljih rješenja i genetskog materijala koji je već visoko prilagođen, što ubrzava konvergenciju algoritma prema optimalnom rješenju.

U genetskom algoritmu, svako potencijalno rješenje se predstavlja kao hromozom, koji se sastoji od gena, osnovnih komponenti tog rješenja. Glavna svrha hromozoma je čuvanje informacije o rješenju koje predstavlja. Takva reprezentacija omogućava algoritmu da efikasno istražuje različite

kombinacije gena kako bi pronašao optimalno rješenje za postavljeni problem. Kodiranje je proces reprezentacije pojedinačnih gena, gdje način kodiranja varira u odnosu na specifičnost problema. Kodiranje ima ključnu ulogu u omogućavanju genetskom algoritmu da pravilno interpretira i manipuliše potencijalnim rješenjima. Genetski algoritam koristi različite vrste kodiranja, prilagođavajući se specifičnostima problema, uključujući binarno kodiranje, kodiranje permutacije i vrijednosno kodiranje.

Uslovi zaustavljanja su važan dio optimizacionog pristupa, obezbijedjući ograničenje trajanja procesa optimizacije. Njihova uloga je osigurati dovoljno vremena za istraživanje prostora rješenja, ali istovremeno spriječiti beskonačno ponavljanje. Odabir odgovarajućih uslova zaustavljanja za specifičan problem zahtijeva detaljnu analizu i testiranje performansi algoritma. Česti kriterijumi zaustavljanja uključuju maksimalan broj iteracija, ograničenje trajanja algoritma, mala promjena fitness funkcije tokom generacija, odstupanje fitness vrijednosti jedinke od srednje vrijednosti populacije ili njihovu kombinaciju.

Kao i većina optimizacionih metoda, genetski algoritam uzima u obzir ograničenja tipa jednakosti $h(x)$ i nejednakosti $g(x)$. U literaturi je razvijeno više metode za uvažavanje ovih ograničenja i podsticanje pretrage rješenja unutar dopuštenih granica [79]:

- Metode bazirane na očuvanju dopustivnosti rješenja,
- Metode bazirane na penalizacionim funkcijama,
- Metode zasnovane na uticaju dopustivih na nedopustiva rješenja,
- Metode bazirane na dekodiranju i
- Hibridne metode.

Za postizanje optimalnog rezultata primjenom genetskog algoritma neophodno je pravilno podešavanje njegovih parametara. Ovi parametri igraju važnu ulogu u dinamici samog algoritma, utičući na njegovu sposobnost pronaalaženja najboljih rješenja. Među najbitnijim parametrima se izdvajaju: veličina populacije, stopa ukrštanja i stopa mutacije.

- **Veličina populacije** predstavlja ukupan broj jedinki koje se generišu u svakoj iteraciji. U slučaju male populacije, postoji rizik od nepotpunog pretraživanja prostora rješenja i dostizanja lokalnog optimuma. S druge strane, veći broj jedinki omogućava bolje pretraživanje, ali istovremeno povećava računsku složenost algoritma.
- **Stopa ukrštanja** predstavlja vjerovatnoću ukrštanja dvije jedinke unutar populacije. Visoka vjerovatnoća ukrštanja može dovesti do brže konvergencije ka optimalnom rješenju. Međutim, previsoka stopa ukrštanja može rezultirati gubitkom raznolikosti populacije. S druge strane, niska stopa ukrštanja može otežati pretragu prostora rješenja, čime se usporava konvergencije. Obično se vrijednosti stope ukrštanja kreću između 0.6 i 0.9.
- **Stopa mutacije** određuje vjerovatnoću mutacije genetskog materijala jedinki u populaciji tokom svake generacije. Ako je stopa mutacije previsoka, postoji veća vjerovatnoća intenzivnijeg nasumičnog pretraživanja prostora rješenja. S druge strane, preniska stopa mutacije može uzrokovati sporu konvergenciju i zaglavljivanje u lokalnim optimumima.

Obično se vrijednosti ovog parametra postavljaju na niže vrijednosti, u opsegu između 0.01 i 0.1.

Pored ovih ključnih parametara, javljaju se i drugi kao što su izbor mehanizma selekcije, maksimalni broj iteracija, kriterijum zaustavljanja i drugi. Izbor parametara genetskog algoritma varira u zavisnosti od prirode specifičnog optimizacionog problema, i često zahtijeva prilagođavanje kako bi se postigao optimalni balans između brzine i kvaliteta konvergencije. Ovo prilagođavanje može biti iskustveno, uzimajući u obzir karakteristike problema.

Kao i ostali metaheuristički metodi optimizacije, genetski algoritam je pronašao primjenu u različitim oblastima. U energetici, genetski algoritam se koristi za rješavanje mnogih optimizacionih problema, uključujući pronalaženje optimalne lokacije baterija kondenzatora i distribuiranih generatora, rekonfiguraciju, optimizaciju troškova ugradnje opreme [79]. Osim toga, široku primjenu ima i u drugim sferama ljudskog života kao što su robotika, ekonomija, računarstvo, medicina, logistika i druge.

3.4.2 Optimizacija rojem čestica

Algoritam optimizacije rojem čestica (*eng. Particle Swarm Optimization – PSO*) predstavlja metod za rješavanje složenih nelinearnih optimizacionih problema koji je 1995. godine prvi put predstavljen u radu [94]. Inspiracija za PSO proizilazi iz prirodnih sposobnosti jata ptica, riba i krda životinja da koordinisano djeluju u svojoj okolini, pronalazeći hranu i izbjegavajući potencijalne opsanosti. Suština PSO-a leži u simulaciji grupnog ponašanja: svaka čestica, ili član roja, djeluje na osnovu informacija koje prikuplja iz svoje neposredne okoline. Ako jedna čestica otkrije optimalan put, ostale čestice prate ovaj put, koristeći lokalne informacije o kretanju svojih bližih čestica. Ovaj kolektivni pristup istraživanja i prilagođavanja okolini koristi socijalne mehanizme kako bi roj postigao globalno optimalno rješenje.

PSO počinje formiranjem inicijalnog jata, gdje je svaka čestica postavljena pomoću dva vektora: vektor pozicije x_i i vektor promjene pozicije (brzine) v_i . Ovi vektori zajedno definisu stanje svake čestice unutar prostora pretrage. Bitno je istaknuti da svaka pozicija x_i predstavlja jedno od mogućih rješenja za problem optimizacije koji se proučava. U svakoj iteraciji, dinamika kretanja čestica se može opisati na sljedeći način [99]:

$$x_i(t) = x_i(t - 1) + v_i(t - 1) \quad (3.27)$$

Srž ove metode leži u izboru v_i nakon svake iteracije. Kretanje jedinki zavisi od njihovih prethodnih ponašanja, kao i ponašanja njihovih najbližih susjeda. Na osnovu toga, određivanje pozicija jedinki zavisi od njihovog pravca kretanja, brzine, njihove prethodno najbolje pozicije p_i i najbolje pozicije među najbližim jedinkama p_g :

$$x_i(t) = f(x_i(t - 1), v_i(t - 1), p_i, p_g) \quad (3.28)$$

Promjena pozicije, u svakoj iteraciji, se ostvaruje prema:

$$\begin{cases} v_i(t) = v_i(t-1) + \varphi_1(p_i - x_i(t-1)) + \varphi_2(p_g - x_i(t-1)) \\ x_i(t) = x_i(t-1) + v_i(t-1) \end{cases} \quad (3.29)$$

gdje su:

φ_1 – težinski koeficijent individualnog iskustva

φ_2 – težinski koeficijent društvene komunikacije

Iz prethodnog izraza se zaključuje da je brzina čestice razložena na tri komponente. Prva komponenta, nazvana komponentom inercije, zadržava sjećanje čestice o njenom prethodnom pravcu kretanja, sprječavajući naglu promjenu smjera. Druga komponenta, komponenta kognicije, ocjenjuje performansu čestice na osnovu njenih prethodnih najboljih pozicija, podstičući je da se usmjeri prema prethodno identifikovanim najboljim rješenjima. Treća komponenta, komponenta društvene interakcije, ocjenjuje uspjeh čestice u odnosu na njene susjedne čestice, usmjeravajući je prema pozicijama koje su otkrivene od strane njenih susjeda.

Kao i kod genetskog algoritma, kriterijum zaustavljanja ima veliki značaj i u slučaju PSO algoritma. Postoje različiti kriterijumi zaustavljanja, ali se među najčešćim izdvajaju: zaustavljanje proračuna čim se rješenje dovoljno približi optimalnom, dostizanje ograničenja vremenskog trajanja ili maksimalnog broja iteracija, nedostatak poboljšanja fitness funkcije tokom određenog broja uzastopnih iteracija (stagnacija konvergencije), ili njihova kombinacija.

Kod PSO algoritma je moguće primijeniti sve metode za uvažavanje ograničenja kao i kod genetskog algoritma. Međutim, u ovom slučaju najčešći metod za uvažavanje ograničenja jeste penalizacija. U literaturi se često izdvajaju dva pristupa penalizacije [79]:

Kod prvog pristupa penalizaciona funkcija se formira na sljedeći način:

$$f_p(x) = f(x) + h(t)H(x) \quad (3.30)$$

gdje je $f(x)$ kriterijumska funkcija, $h(t)$ penalizaciona vrijednost koja se mijenja sa brojem iteracija i $H(x)$ penalizacioni faktor koji se definiše na sljedeći način:

$$H(x) = \sum_{i=1}^k \theta(q_i(x)) q_i(x)^{\gamma(q_i(x))} \quad (3.31)$$

gdje je k broj ograničenja, $\theta(q_i(x))$ višestepena funkcija, $q_i(x)$ maksimalna vrijednost narušenog ograničenja, koja i predstavlja ključnu veličinu koju penalizaciona funkcija uzima u obzir, obuhvatajući sva ograničenja. Svako ograničenje je podložno nezavisnoj manipulaciji, bez obzira na njegovu važnost. Dodatno, vrijednost $h(t)$ omogućava dinamičnu prilagodljivost nivoa penalizacije tokom proces optimizacije.

Kod drugog pristupa se penalizaciona funkcija formira na sljedeći način:

$$f_p(x) = f(x) + H(x) \quad (3.32)$$

$$H(x) = w_1 H_{NOG}(x) + w_2 H_{SOG}(x) \quad (3.33)$$

gdje je $H_{NOG}(x)$ broj narušenih ograničenja, a H_{SOG} suma narušenih ograničenja. Težinski koeficijenti w_1 i w_2 omogućavaju određivanje stepena važnosti $H_{NOG}(x)$ i $H_{SOG}(x)$.

Kako bi PSO efikasno pretraživao prostor rješenja neophodno je pažljivo podešavanja njegovih parametara. Pored veličine populacije, oni obuhvataju i koeficijente individualnog iskustva i socijalne komunikacije koji određuju ponašanje individualnih čestica tokom pretrage.

- **Veličina populacije** određuje broj čestica koje će biti korišćene za pretragu prostora rješenja. Veće populacije imaju tendenciju da pruže bolje rezultate, jer omogućavaju veću raznolikost u pretrazi i pokrivanje šireg prostora rješenja. Međutim, veće populacije zahtijevaju više računarskih resursa i mogu dovesti do sporijih iteracija algoritma.
- **Koeficijent individualnog iskustva** određuje stepen povjerenja čestice u vlastito najbolje pronađeno rješenje (poziciju) u odnosu na globalno najbolje rješenje prilikom ažuriranja svoje brzine i pozicije. Povećanje koeficijenta individualnog iskustva znači da će se čestice prilikom pretrage više oslanjati na svoje prethodno iskustvo i instuiciju.
- **Koeficijent socijalne komunikacije** određuje koliko će čestice uzeti u obzir informacije o najboljim rješenjima susjednih čestica tokom ažuriranja svoje brzine i pozicije. Veći koeficijent socijalne komunikacije označava veću interakciju između čestica, što znači da će više pažnje posvetiti informacijama dobijenim od susjednih čestica tokom pretrage. Odnosno, koristiće kolektivno znanje kako bi usmjerile svoje kretanje ka boljim područjima pretrage.

Važno je naglasiti da ne postoji univerzalno idealan set parametara koji bi odgovarao svakom problemu. Optimalne vrijednosti parametara variraju u skladu s problemom koji se rješava. Stoga je neophodno eksperimentisati s različitim vrijednostima i pažljivo pratiti performanse algoritma na konkretnom problemu.

U literaturi je PSO algoritam postao bitan alat za rješavanje različitih optimizacionih problema u mnogim naučnim oblastima. U energetici se primjenjuje za rješavanje problema: optimalnog lociranja baterija kondenzatora, optimizaciju sistema za skladištenje energije, optimalno alociranje distribuiranih generatora, rekonfiguraciju. Osim energetike, PSO je široko korišćen i u drugim disciplinama poput građevinarstva, robotike, obrade signala i drugih [79].

3.4.3 Diferencijalna evolucija

Diferencijalna evolucija (eng. Differential Evolution - DE) se ubraja među najznačajnije evolutivne algoritme, koji je prvi put predstavljen 1995. godine u radu [92]. Slično genetskom algoritmu, diferencijalna evolucija je inspirisana procesom genetske varijacije i selekcije, i vrši

iterativno poboljšanje kandidatskih rešenja kroz proces mutacije, rekombinacije i selekcije, oponašajući evolutivnu dinamiku u biološkim populacijama.

Inicijalna populacija se bira s ciljem što ravnomernijeg pokrivanja prostora primjenom uniformne raspodjele. Proces generisanja novih jedinki u DE uključuje kombinovanje ponderisane razlike između dva nasumično odabrana člana sa trećim članom populacije. Mutirani vektor potom prolazi kroz fazu ukrštanja s cilnjim vektorom, stvarajući tako probni vektor. Nakon toga, tokom faze selekcije, ako probno rješenje ima veću vrijednost *fitness* funkcije, ono zamjenjuje ciljni vektor u narednoj generaciji. Ovaj iterativni ciklus mutacije, ukrštanja i selekcije se nastavlja kroz svaku generaciju, omogućavajući DE da adaptivno istražuje rješenja u potrazi za najboljim.

Za svaki ciljni vektor x_{r1} se generiše mutirani vektor v_i na osnovu relacije [92]:

$$v_i = x_{r1} + F(x_{r2} - x_{r3}) \quad (3.34)$$

gdje su r_1, r_2, r_3 nasumično odabrani indeksi iz skupa $\{1, 2, \dots, N_{jedinki}\}$, pri čemu je neophodno obezbijediti njihovu različitost. Takođe, važno je napomenuti da se ovi indeksi biraju tako da budu različiti od trenutnog indeksa i . F predstavlja faktor skaliranja koje se uzima iz opsega $(0, 1)$, i igra bitnu ulogu u određivanju detaljnosti i brzine pretrage.

U sljedećem koraku, kombinuju se komponente mutiranog i ciljnog vektora kako bi se dobio probni vektor u_i . Ovaj proces omogućava cilnjom rješenju da preuzme određene karakteristike mutiranog rješenja. Uniformno ukrštanje se kontroliše faktorom ukrštanja C_r , koji uzima vrijednosti iz opsega $(0, 1)$. Određivanje j -toga elementa probnog vektora u_i se postiže primjenom sledeće relacije:

$$u_{i,j} = \begin{cases} v_{i,j} & \text{rand}(0,1) \leq C_r \text{ ili } j = i \\ x_{i,j} & \text{rand}(0,1) > C_r \end{cases} \quad (3.35)$$

Da bi se odredilo da li će probni vektor u_i postati dio sledeće generacije, vrši se upoređivanje sa cilnjim vektorom x_i . Ako probni vektor rezultira manjom vrijednošću kriterijumske funkcije u odnosu na ciljni vektor, onda se ciljni vektor za narednu generaciju preuzima vrijednost probnog vektora. Suprotno tome, ukoliko probni vektor nije bolji od ciljnog, ciljni vektor ostaje nepromijenjen u sljedećoj generaciji. Ovaj proces obezbjeđuje odabir vektora koji doprinose poboljšanju prilagođenosti, u skladu sa ciljem optimizacije.

U diferencijalnoj evoluciji, ograničenja upravljačkih promjenjivih mogu biti narušena tokom mutacije. Provjeru ograničenja se obavlja prilikom dodavanja diferencijalne razlike u probni vektor. Različite metode za rješavanje ovog problema uključuju dodavanje visokih vrijednosti fitness funkcije osiguravajući da taj vektor ne bude izabran (*Brick Wall Penalty*), povećanje fitness funkcije proporcionalno broju prekoračenih ograničenja (Adaptivna penalizacija), biranje novih vrijednosti za parametre koji su van opsega (Proizvoljna reinicijalizacija), ili zamjena svih prekoračenih parametara odgovarajućim vrijednostima (Povratak granice) [79].

Za uvažavanje ograničenja, kod diferencijalne evolucije je moguće koristiti sve metode kao i kod genetskog algoritma. Međutim, specijalno za diferencijalnu evoluciju je razvijena metoda

uvažavanja ograničenja tipa nejednakosti kao što je Lampinenova tehnika, koja ubrzava proces konvergencije u prisustvu ograničenja. U ovom pristupu, svakom vektoru se, pored vrijednosti *fitness* funkcije, pridlužuju i vrijednosti individualnih ograničenja $g_m(x)$. Nakon izvršavanja mutacije i ukrštanja, vrši se poređenje probnog vektora u_i sa ciljnim x_i . Probni vektor u_i biće izabran ako ispunjava sljedeće uslove [79]:

- u_i zadovoljava sva ograničenja i ima manju ili jednaku vrijednost objektivne funkcije kao i ciljni vektor x_i ,
- u_i je izvodljiv, a x_i nije, ili
- u_i i x_i su neizvodljivi, ali u_i narušava manje ograničenja.

Za uvažavanje ograničenja tipa jednakosti, često se koristi pristup pretvaranja tih ograničenja u nejednakosti i uvođenja minimalne vrijednosti ε za svako od njih, što omogućava fleksibilniji pristup rješavanju problema sa ovim ograničenjima [79]:

$$|h_n(x)| < \varepsilon \quad (3.36)$$

Progresivno podešavanje ε tokom pretrage može efikasnije usmjeriti pretragu ka području optimalnog vektora, dok istovremeno smanjuje narušenost ograničenja jednakosti. Korišćenje $\varepsilon = 0$ povećava rizik od toga da diferencijalna evolucija neće generisati nijedan vektor koji tačno zadovoljava sva ograničenja jednakosti. Takođe, i kod rješavanja ovog problema je moguće koristiti Lampinenov pristup.

Kod diferencijalne evolucije se kao parametri javljaju veličina populacije, stopa ukrštanja i faktor skaliranja.

- **Veličina populacije** ima značajan uticaj na performanse DE i ponašanje konvergencije. Veća populacija omogućava raznovrsnija rješenja i širu pretragu prostora što vodi ka bržoj konvergenciji i izbjegavanju lokalnih optimuma. Međutim, s druge strane zahtijeva više računarskih resursa i duže vrijeme proračuna.
- **Stopa ukrštanja** uzima vrijednosti u opsegu od 0 do 1. Niska stopa ukrštanja, rezultuje pretraživanjem koje se bazira na finom poboljšanju već postojećih rješenja. Ova niska vrijednost omogućava algoritmu da ostane blizu trenutnio najboljih rješenja. S druge strane, visoka stopa ukrštanja omogućava algoritmu da istražuje širi spektar prostora pretrage, pružajući raznovrsnost u generisanim rješenjima.
- **Faktor skaliranja** određuje korak operacije mutacije i uzima vrijednosti u opsegu od 0 do 1. Veći faktor skaliranja omogućava brže pretraživanje šireg spektra potencijalnih rješenja, što pomaže u izbjegavanju lokalnih optimuma, ali može dovesti do nestabilnosti u konvergenciji zbog mogućih preskakanja boljih rješenja. S druge strane, manje vrijednosti faktora skaliranja doprinose stabilnijoj i preciznijoj pretrazi, ali postoji rizik od zaglavljivanja u lokalnom optimumu jer algoritam ne može istražiti šire prostore rješenja.

Kao i kod većine metaheurističkih metoda, vrijednosti ovih parametara zavise od konkretnе primjene algoritma diferencijalne evolucije. Prilagođavanje ovih parametara često zahtijeva eksperimentalno ispitivanje kako bi se postigle optimalne performanse algoritma za određeni problem.

DE je našla široku primjenu u različitim oblastima nauke i inženjeringu. Različite varijante ovog algoritma su proučavane i primijenjene u mnogim radovima iz oblasti: hemijskog inženjeringu, energetike, elektronike, mašinskog inženjeringu, obrade slike, neuronskih mreža, industrijskog inženjeringu i drugih [100].

4. Primjer primjene predloženog metoda

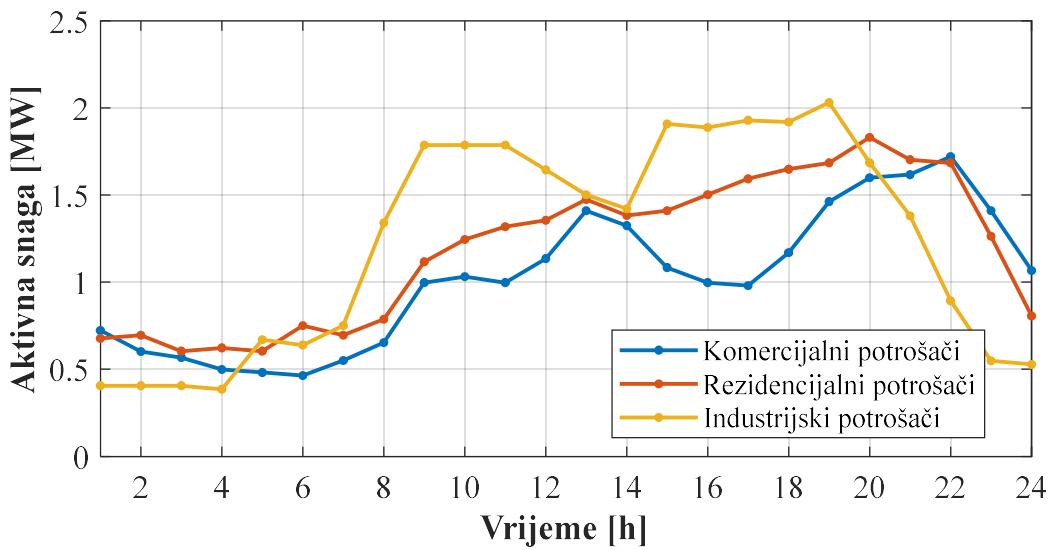
4.1 Ulagni podaci

Za uspješnu primjenu predloženog metoda u praksi, od suštinske važnosti je precizno odrediti ulazne podatke, koji se mogu podijeliti tri kategorije: podaci o mreži, informacije o distribuiranim generatorima i troškovima pogona. Svaka od ovih grupa zahtijeva pažljivo definisanje kako bi je algoritam mogao adekvatno obraditi i generisati relevantne rezultate.

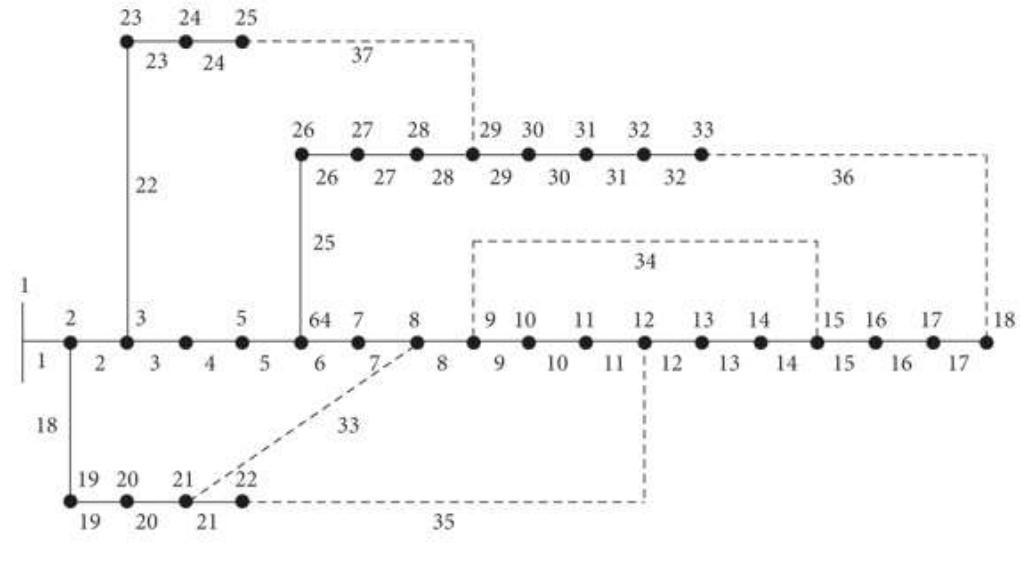
4.1.1 Podaci o mreži

Jedan od ključnih setova podataka neophodnih za implementaciju predloženog pristupa uključuje informacije koje se odnose na same elektrodistributivne mreže. Ova grupa podataka obuhvata širok spektar, uključujući konfiguraciju mreže, što obuhvata međusobnu povezanost i raspored elemenata sistema kao što su dionice vodova, transformatori i prekidači. Osim toga, ovi podaci sadrže informacije o fizičkim karakteristikama samih vodova, kao što su dužine, impedanse i reaktanse, što je od suštinskog značaja za pravilno modelovanje energetskih sistema. Takođe, u ovu grupu podataka spadaju i informacije o potrošačima, uključujući njihov broj, tipove i dnevne dijagrame opterećenja.

Rezultati predloženog metoda analizirani su koristeći testnu IEEE srednjenaopnsku elektrodistributivnu mrežu, naponskog nivoa 12.66kV, sa 33 čvora i 37 grana (Slika 4.1). Relevantni podaci o ovoj mreži dostupni su u Prilogu 1. Solarne elektrane snage 3 MVA, 1.5 MVA i 4.5 MVA su povezane na čvorove 30, 17 i 24. Kako bi se što vjerodostojnije prikazalo ponašanje potrošača tokom dana, potrošački čvorovi su klasifikovani kao rezidencijalni, komercijalni i industrijski, svaki sa specifičnim dijagramima opterećenja u satnoj rezoluciji [101]. Dnevni dijagrami opterećenja su prikazani na Slici 4.1. Dodatno, pretpostavlja se da rezidencijalni i komercijalni potrošači imaju konstantan faktor snage od 0.95 induktivno, dok industrijski potrošači imaju faktor snage od 0.85 induktivno.



Slika 4.1 Dnevni dijagrami opterećenja

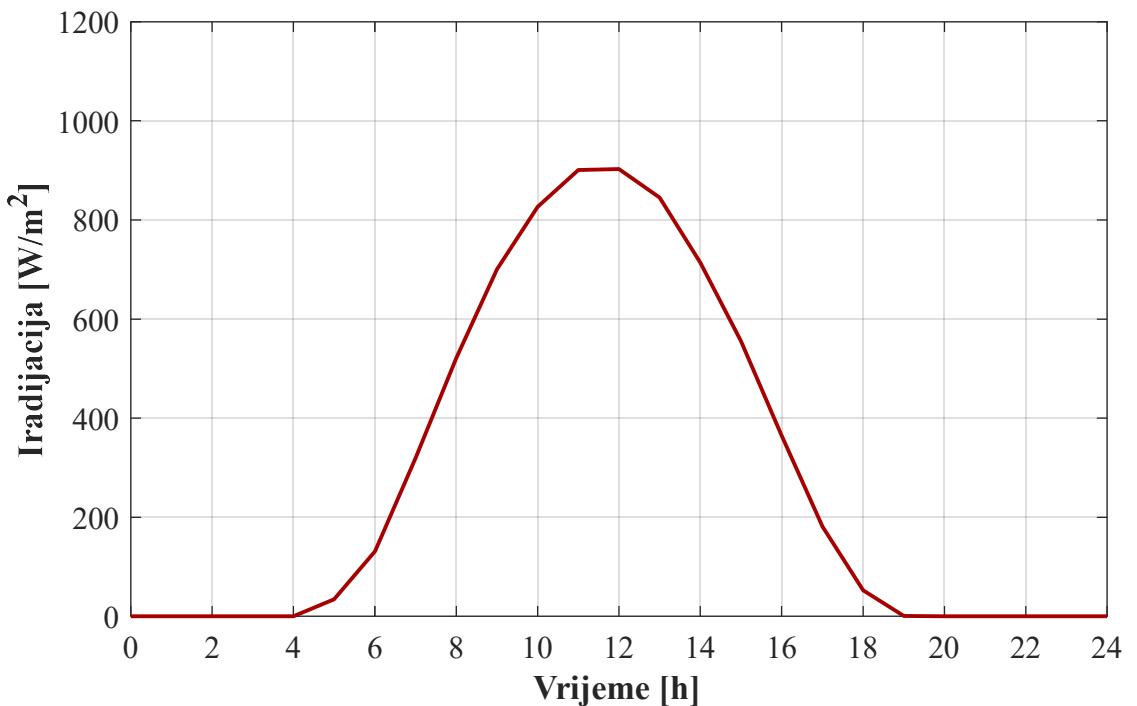


Slika 4.2 Testna IEEE mreža sa 33 čvora

4.1.2 Podaci o distribuiranim generatorima

Druga grupa informacija, neophodnih za sprovođenje ovog metoda, obuhvata podatke o pogonu distribuiranih generatora. Pored tehničkih karakteristika, kao što su pogonska ograničenja i sposobnost prilagođavanja zahtjevima operatora mreže, ističe se potreba za prognozom proizvodnje, koja u slučaju obnovljivih izvora mogu biti nepouzdane. Prognozna proizvodnje distribuiranih generatora ima važnu ulogu u planiranju njihovog optimalnog upravljanja, ali i u koordinaciji sa distributivnom mrežom. U okviru ovog istraživanja, fokus je bio na analizi distributivne mreže koja

uključuje solarne elektrane, prepoznate kao dominantan izvor energije u savremenim distributivnim mrežama. Kada se razmotri geografska bliskost solarnih elektrana povezanih na istu srednjenaopšku distributivnu mrežu, može se smatrati da se njihova proizvodnja u toku dana mijenja po istom zakonu. Za implementaciju predloženog algoritma, korišćena je prognoza solarne radijacije za sunčani julski dan u Podgorici (Slika 4.2), dobijena pomoću PVGIS softvera [102].



Slika 4.3 Prognoza iradijacije

4.1.3 Podaci o troškovima pogona

Bitan ulazni podatak je cijena električne energije koja se koristi za pokrivanje gubitaka, budući da ova stavka predstavlja značajan dio operativnih troškova distributivne mreže. U tom kontekstu, regulatorne institucije su ključne za osiguranje stabilnosti i održivosti kompanija koje rukovode distributivnim mrežama. Njihova uloga je da precizno odrede opravdane troškove gubitaka koji se mogu prenijeti na krajnje korisnike distributivne mreže. Obzirom da operatori ne mogu direktno uticati na tržišne cijene, regulatori imaju izazov da pažljivo postave prikladnu cijenu, a metode za takvo određivanje mogu varirati od države do države.

Operatori distributivne mreže, kao subjekti pod strogom regulativom, su obavezni da nabavljaju električnu energiju za pokrivanje očekivanih gubitaka na transparentan, nediskriminoran i tržišno orjentisan način. Postoji nekoliko pristupa za nabavku električne energije [103]:

- Na energetskim berzama, kroz *day-ahead* ili dugoročne ugovore, uključujući i fjučerse,

- Bilateralnim ugovorima, što podrazumijeva direktno pregovaranje između relevantnih strana i
- Korišćenje aukcija ili tendera, gdje proizvođači ili trgovci dostavljaju svoje ponude

U praksi, ovi pristupi se često kombinuju u cilju osiguravanja najefikasnije nabavke. Za potrebe ovog istraživanja, kao primjer je uzeta cijena postignuta na aukciji za nabavku električne energije za pokrivanje gubitaka u distributivnom sistemu Crne Gore za mjesec jul na Crnogorskoj berzi električne energije (BELEN), i ta cijena iznosi 97.21 €/MWh [104].

Sljedeći podatak koji je neophodno definisati jeste cijena prekidačke akcije. Ova informacija se uvodi s ciljem procjene potencijalnog raubovanja opreme zbog učestalije upotrebe prekidača, odnosno ocjene ekonomske opravdanosti promjene uklopnog stanja u posmatranom trenutku. Proces definisanja cijene prekidačke akcije se oslanja na analizu troškova održavanja i zamjene opreme, pri čemu se u obzir uzimaju očekivani radni vijek prekidača i broj prekidačkih akcija koji su specifirani u tehničkim karakteristikama uređaja. Kako bi se ovi troškovi adekvatno procijenili, korišćen je pristup koji je opisan u [105]. Ova metodologija osigurava preciznu analizu troškova, uzimajući u obzir troškove angažovanja radnika, materijala, opreme i neisporučene energije. Važno je napomenuti da su u ovom slučaju troškovi neisporučene električne energije zanemareni, uzimajući u obzir mogućnost promjene uklopnog stanja, uslijed čega potrošači neće ostati bez napajanja. Zatim su, uz pretpostavku da se održavanje vrši jednom godišnje, proračunati ukupni troškovi održavanja i zamjene u toku radnog vijeka prekidača. Dobijena vrijednost je podijeljena sa očekivanim brojem prekidačkih akcija u toku radnog vijeka. Nakon sprovođenja ovog proračuna procijenjeno je da cijena jedne prekidačke akcije iznosi 1.3 €. U okviru predložene metode, koja obuhvata upravljanje aktivnom i reaktivnom snagom distribuiranih, važno je adekvatno definisati cijenu koju operator mora platiti proizvođačima za pružene pomoćne usluge. Naplata ovih usluga nije univerzalna i podložna je promjenama u skladu s regulatornim okvirom, tržišnim uslovima i dogovorima između operatora i proizvođača.

Za razliku od tržišta aktivne snage koje ima utvrđene mehanizme za cijene, tržište reaktivne snage trenutno nije jasno definisano, već varira od države do države. S obzirom na nedostatak jasnog mehanizma, u ovom radu je trošak usluga reaktivne snage pružen od strane solarnih elektrana definisan na osnovu istraživanja [106], koje se bavi procjenom odnosa troškova i benefita za slučaj kontrole raktivne snage pomoću pametnih invertora. Prema ovom istraživanju, cijena je određena na osnovu tarife koju je postavila kompanija *National grid*, koja gazduje mrežama u Engleskoj, za avgust 2020. godine i iznosi 2.67 €/MVarh. Za razliku od distribuiranih generatora, regulatorna agencija za energetiku u Crnoj Gori određuje cijenu za prekomjernu potrošnju reaktivne energije potrošačima. Naime, ako krajnji korisnik preuzme više reaktivne energije nego što je previđeno prosječnim faktorom snage ($\cos \varphi = 0.95$), mora platiti dodatne troškove u skladu sa važećim pravilnikom [76].

Radi očuvanja sigurnost pogona, nekada je potrebno da proizvođači privremeno umanje ili čak zaustave proizvodnju. Različiti pristupi distribuiranih generatora prodaji električne energije znače da ne postoji univerzalni pristup plaćanja naknade za gubitak prihoda koji proizvođači mogu pretrpjeti zbog smanjenja proizvodnje. Neki mali proizvođači poput solarnih i vjetroelektrana imaju ugovor sa operatorom tržišta koji garantuje određenu cijenu za svu proizvedenu električnu energiju. U takvim

slučajevima, operator distributivne mreže bi trebao platiti umanjenu proizvodnju po toj cijeni. S druge strane, proizvođači koji učestvuju na tržištu, a čija dobit zavisi od tržišne cijene, trebalo bi da budu plaćeni za umanjenu proizvodnju po cijeni sa spot tržišta kako ne bi pretrjepli gubitak dobiti. Takođe, male elektrane ili industrijska postrojenja koja proizvode električnu energiju za spostvene potrebe trebalo bi da budu plaćeni po višoj tarifi u slučaju smanjenja proizvodnje. Imajući u vidu trend ukidanja garantovanih cijena i sve veći broj malih proizvođača koji učestvuju na tržištu, u ovom radu se kao referentna cijena koristi cijena električne energije na BELEN-u za 22.07.2023. i iznosi 112.66 €/MWh [107].

4.3 Izbor metoda optimizacije

Za objektivnu procjenu efikasnosti genetskog algoritma neophodno je sprovesti poređenje njegovih performansi s drugim optimizacionim tehnikama. U okviru ovog istraživanja, detaljno su analizirane performanse genetskog algoritma u odnosu na optimizaciju rojem čestica (PSO) i diferencijalnu evoluciju (DE), pri čemu su sve tri metode kategorizovane kao populacione metaheurističke metode.

Da bi rezultati bili relevantni i pouzdani, izvršena je optimizacija parametara za svaku od navedenih metoda. U konkretnom slučaju, parametri su određeni primjenom metode slučajnog pretraživanja (*eng. random search*) [86], koja evaluacijom nasumično generisanih skupova parametara unutar određenih granica pronalazi najbolje rješenje. Ovaj pristup osigurava statističku pouzdanost i omogućava precizno identifikovanje optimalnih setova parametara za svaki algoritam. Konačno, optimalni setovi parametara, odabrani iz unaprijed definisanih domena i koji su doveli do minimalnih vrijednosti kriterijumske funkcije, su prikazani u Tabeli 4.1

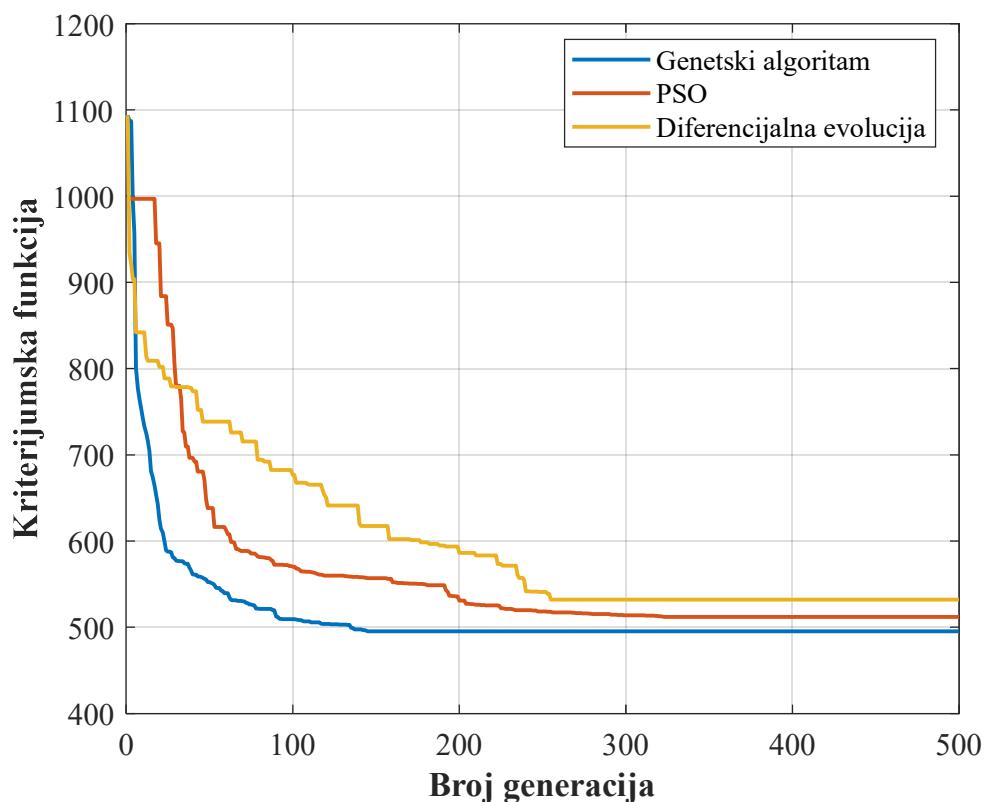
Tabela 4.1 Parametri metoda optimizacije

Parametar	Opseg	Korak	Najbolja vrijednost
Genetski algoritam (GA)			
Veličina populacije	50 – 500	50	450
Veličina turnira	2 – 50	1	18
Stopa mutacije	0 – 0.15	0.005	0.01
Stopa selekcije	0.5 – 1	0.05	0.8
Optimizacija rojem čestica (PSO)			
Veličina populacije	50 – 500	50	500
Koeficijent individualnog iskustva	0.5 – 2.5	0.05	1.1
Koeficijent socijalne komunikacije	0.5 – 2.5	0.05	1.95
Diferencijalna evolucija (DE)			
Veličina populacije	50 – 500	50	450
Stopa ukrštanja	0 – 1	0.05	0.05
Faktor skaliranja	0 – 1	0.05	0.20

Za postizanje optimalnih vrijednosti parametara, optimizacioni metod je pokrenut 200 puta. Svi algoritmi su uspješno konvergirali u skladu sa Slikom 4.3, dok je poređenje vrijednosti kriterijumske funkcije i brzine proračuna prikazano u Tabeli 4.2. Analiza rezultata ukazuje na superiornost genetskog algoritma u postizanju najboljih rješenja u značajno kraćem vremenskom periodu u poređenju sa ostalim metodama.

Tabela 4.2 Rezultati komparacije razmatranih metoda

Metod	Broj iteracija	Trajanje prorauna[s] ¹	Kriterijumska funkcija
Genetski algoritam	178	735.14	495.2
PSO	323	1124.04	512.1
Diferencijalna evolucija	257	1852.97	538.7



Slika 4.4 Komparacija konvergencija razmatranih metoda

4.4 Rezultati numeričke analize

U ovom poteglavlju razmatraju se simulacioni rezultati za tri slučaja aktivnog upravljanja distributivnom mrežom:

¹ Svi proračuni su sprovedeni na računaru koji je opremljen Intel i5-8250U procesorom i 8GB DDR4 RAM memorijom radnog takta 2400MHz.

- 1) Slučaj I – Rekonfiguracija distributivne mreže
- 2) Slučaj II – Rekonfiguracija distributivne mreže uz upravljanje reaktivnom snagom distribuiranih generatora
- 3) Slučaj III – Rekonfiguracija distributivne mreže uz upravljanje aktivnom i reaktivnom snagom distribuiranih generatora

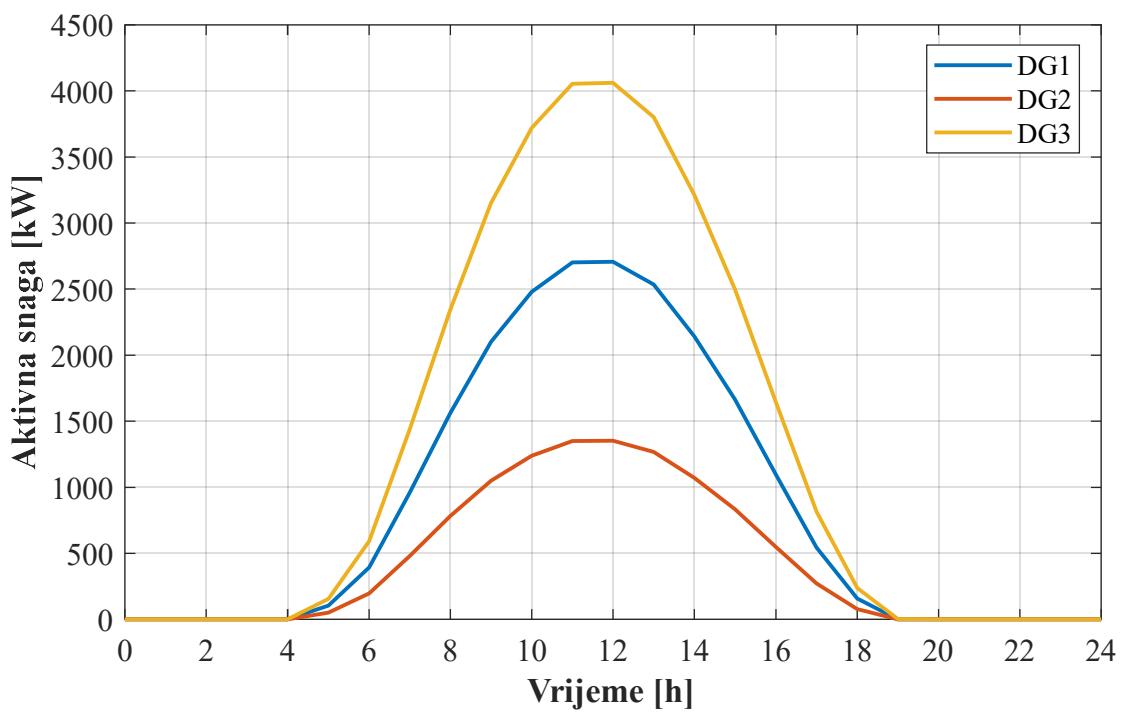
Obzirom da je integracija obnovljivih izvora u distributivnim mrežama praćena povećanjem napona kao jednom od glavnih prepreka, centralni fokus ove analize je usresređen na najkritičniji scenario, odnosno situaciju u kojoj se napon u napojnom čvoru održava na konstantnoj vrijednosti od 110% nominalnog napona, koja predstavlja gornju granicu dozvoljenog naponskog opsega. Takođe, važno je napomenuti da su početni uslovi za sve tri analizirane situacije identični. Konkretno, u početnom trenutku su isključeni prekidači sa indeksima 6, 9, 14, 26 i 34. U ovom dijelu istraživanja, kroz analizu naponskih prilika, gubitaka aktivne snage i operativnih troškova u toku posmatranog dana je sprovedena sveobuhvatna tehnoekonomska analiza koja doprinosi ekonomičnjem upravljanju distributivnom mrežom.

4.4.1 Slučaj I

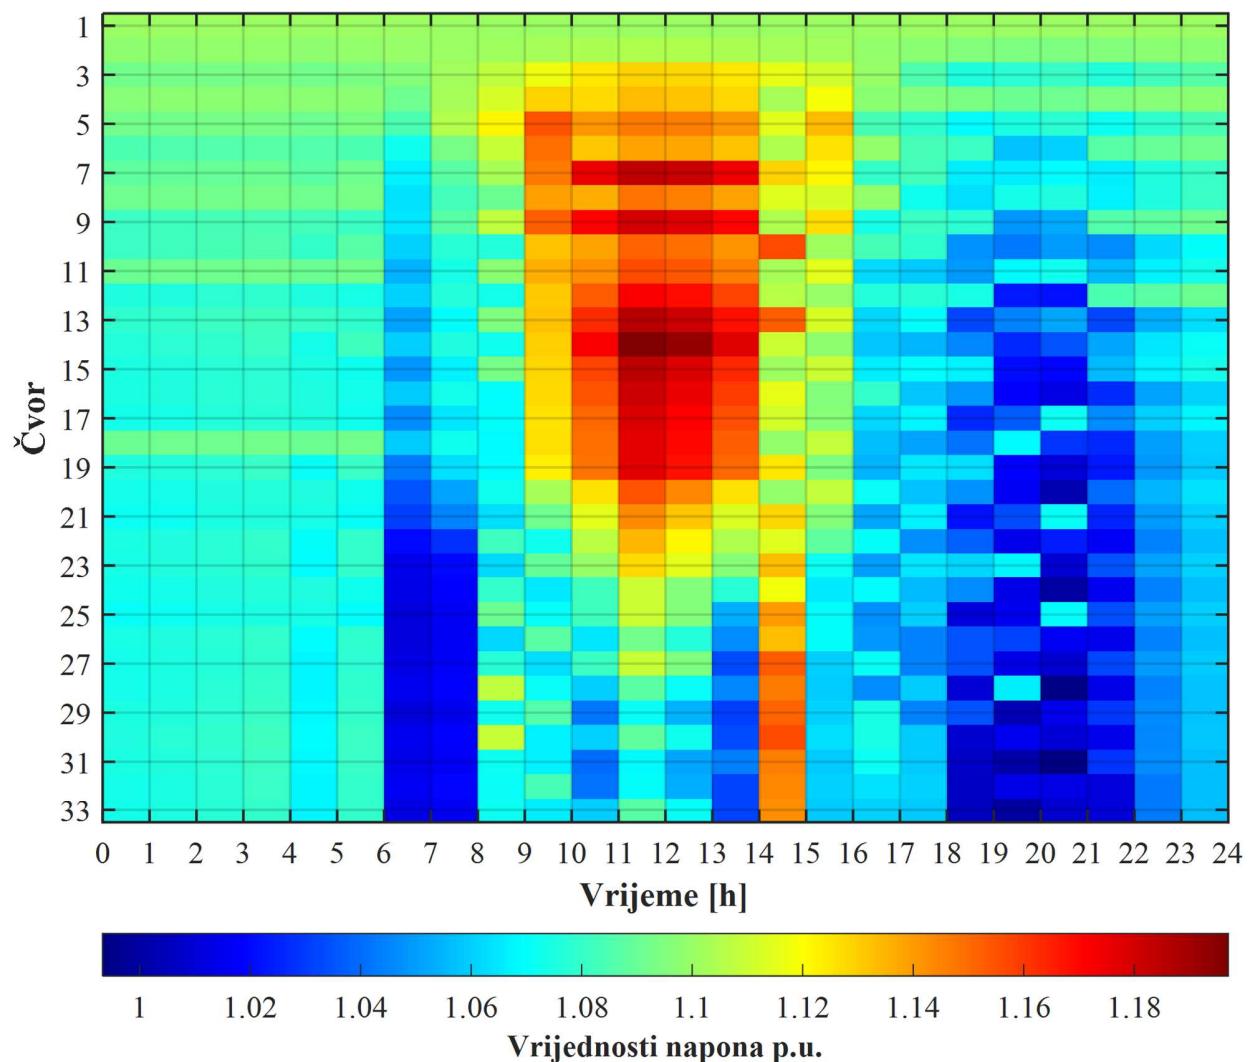
U tabeli 4.5 su prikazani satni podaci o isključenim prekidačima za posmatrani dan, dok se na slici 4.4 nalaze satne vrijednosti aktivnih snaga distribuiranih generatora. Pretpostavljeno je da generatori radi pri konstantnom faktoru snage 1 i da ostvarena proizvodnja odgovara prognoziranoj.

Tabela 4.3 Slučaj I – Isključeni prekidači po satima

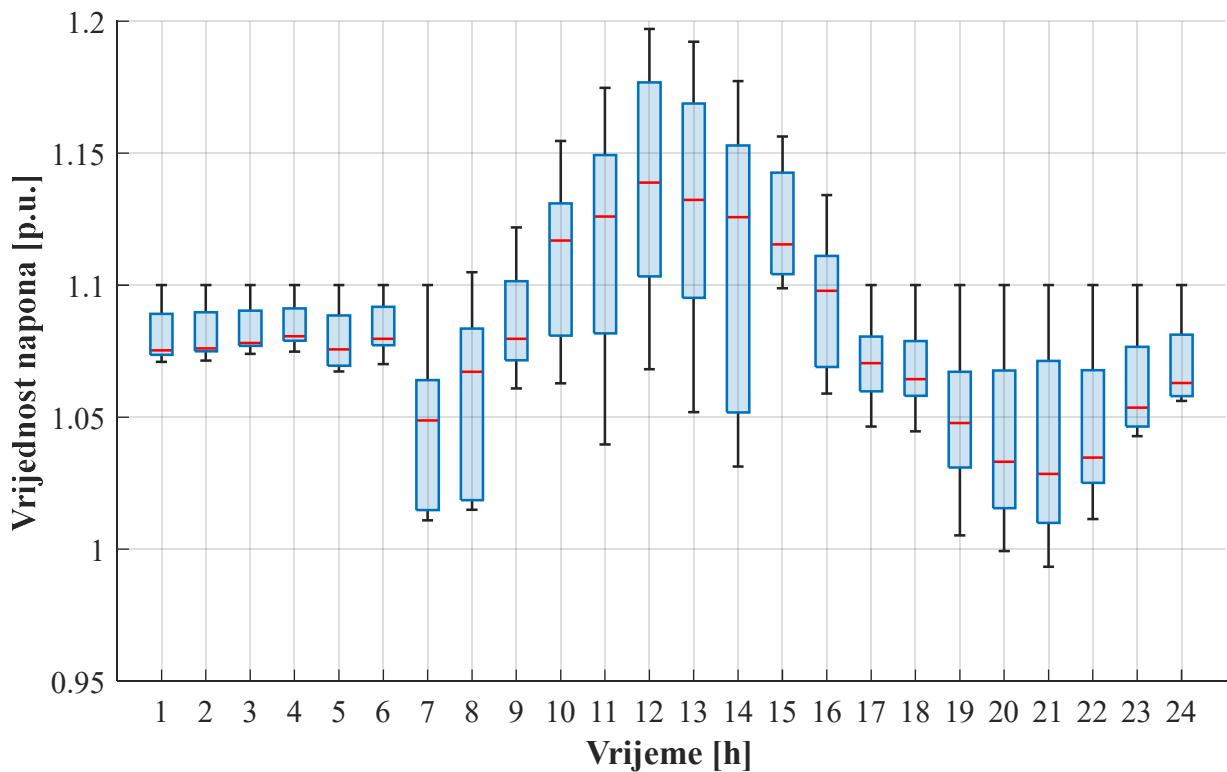
Period	Isključeni prekidači
00:00 – 01:00	6 – 9 – 14 – 26 – 34
01:00 – 02:00	6 – 9 – 14 – 26 – 34
02:00 – 03:00	6 – 9 – 14 – 26 – 34
03:00 – 04:00	6 – 9 – 14 – 26 – 34
04:00 – 05:00	6 – 9 – 14 – 26 – 34
05:00 – 06:00	6 – 9 – 14 – 26 – 34
06:00 – 07:00	3 – 6 – 9 – 14 – 18
07:00 – 08:00	3 – 6 – 9 – 14 – 18
08:00 – 09:00	3 – 9 – 18 – 21 – 36
09:00 – 10:00	3 – 6 – 11 – 18 – 21
10:00 – 11:00	6 – 9 – 18 – 34 – 37
11:00 – 12:00	6 – 9 – 18 – 34 – 37
12:00 – 13:00	6 – 9 – 18 – 34 – 37
13:00 – 14:00	6 – 11 – 18 – 34 – 37
14:00 – 15:00	5 – 11 – 34 – 36 – 37
15:00 – 16:00	3 – 7 – 11 – 14 – 18
16:00 – 17:00	3 – 7 – 9 – 14 – 33
17:00 – 18:00	11 – 14 – 15 – 28 – 33
18:00 – 19:00	11 – 14 – 15 – 28 – 33
19:00 – 20:00	6 – 11 – 14 – 28 – 36
20:00 – 21:00	6 – 14 – 28 – 35 – 36
21:00 – 22:00	14 – 26 – 33 – 34 – 35
22:00 – 23:00	14 – 26 – 33 – 34 – 35
23:00 – 24:00	14 – 26 – 33 – 34 – 35



Slika 4.5 Slučaj I – Aktivna snaga distribuiranih generatora po satima



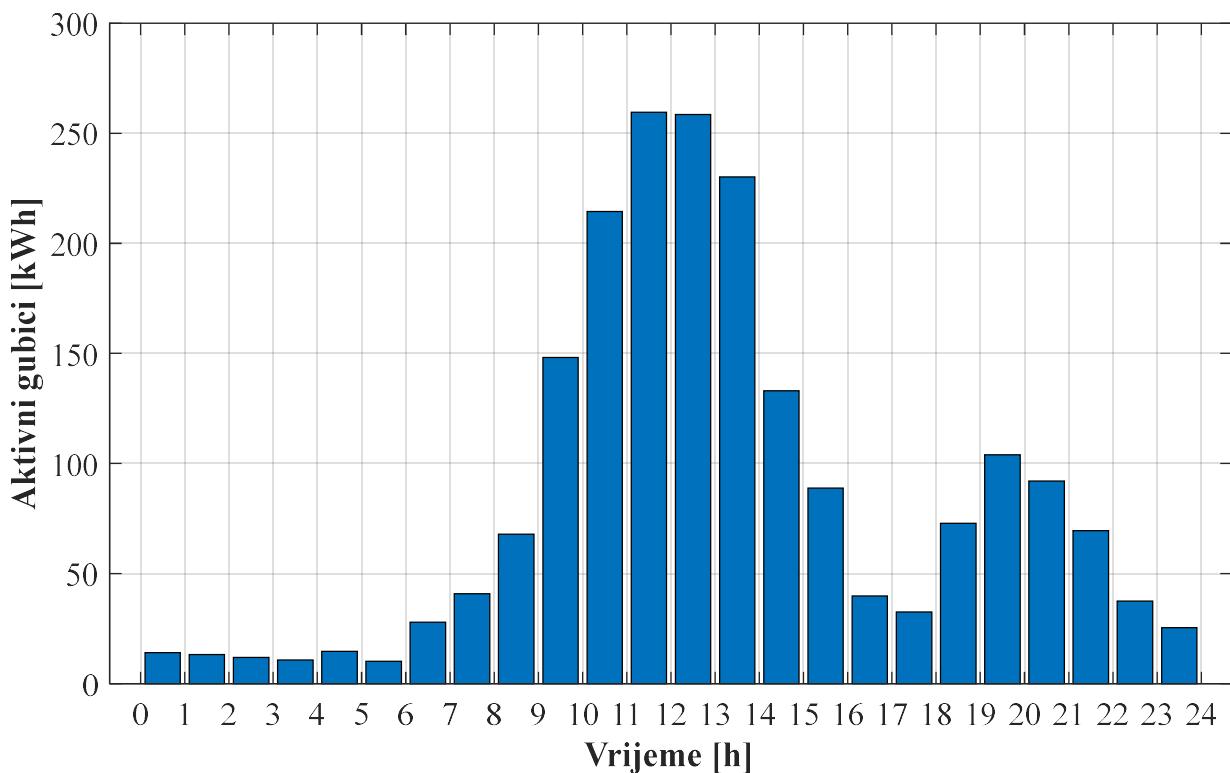
Slika 4.6 Slučaj I – Vrijednosti napona u čvorovima po satima



Slika 4.7 Slučaj I – Opsezi vrijednosti napona u mreži po satima

Naponske prilike u distributivnoj mreži, prikazane na Slikama 4.5 i 4.6, pokazuju da primjenom rekonfiguracije, u ovom slučaju naponi nisu održani unutar dozvoljenog opsega u toku čitavog dana. Naime, u ovom slučaju, napon u svim čvorovima mreže je 62.5% vremena u propisanim granicama. Najgori slučaj je kod čvorova 2,3,4,5, gdje je napon u dozvoljenim granicama isti procenat vremena. Vrijednosti napona koje izlaze iz dozvoljenog opsega se javljaju u periodu između osmog i šesnaestog sata, s maksimalnom vrijednošću od čak $U_{max} = 1.197$ p.u. u dvanaestom satu. S obzirom na to da je sigurnost mreže uvijek prioritet, algoritam u ovom periodu zanemaruje ekonomičnost pogona s težnjom da stabilizuje napone, što rezultira češćim prekidačkim akcijama što je prikazano u Tabeli 4.5.

U okviru analize, na Slici 4.7 su kroz bar dijagram predstavljeni satni gubici aktivne snage, čiji je zbir za analizirani dan nešto veći od 2 MWh (kao što je navedeno u Tabeli 4.6). Dodatno, Tabela 4.6. predstavlja ukupne operativne troškove za slučaj I, obuhvatajući troškove gubitaka aktivne snage i troškove povezane s brojem prekidačkih akcija, čiji je iznos 266 €.



Slika 4.8 Slučaj I – Gubici aktivne snage u mreži po satima

Tabela 4.4 Slučaj I – Ukupni gubici aktivne snage i operativni troškovi

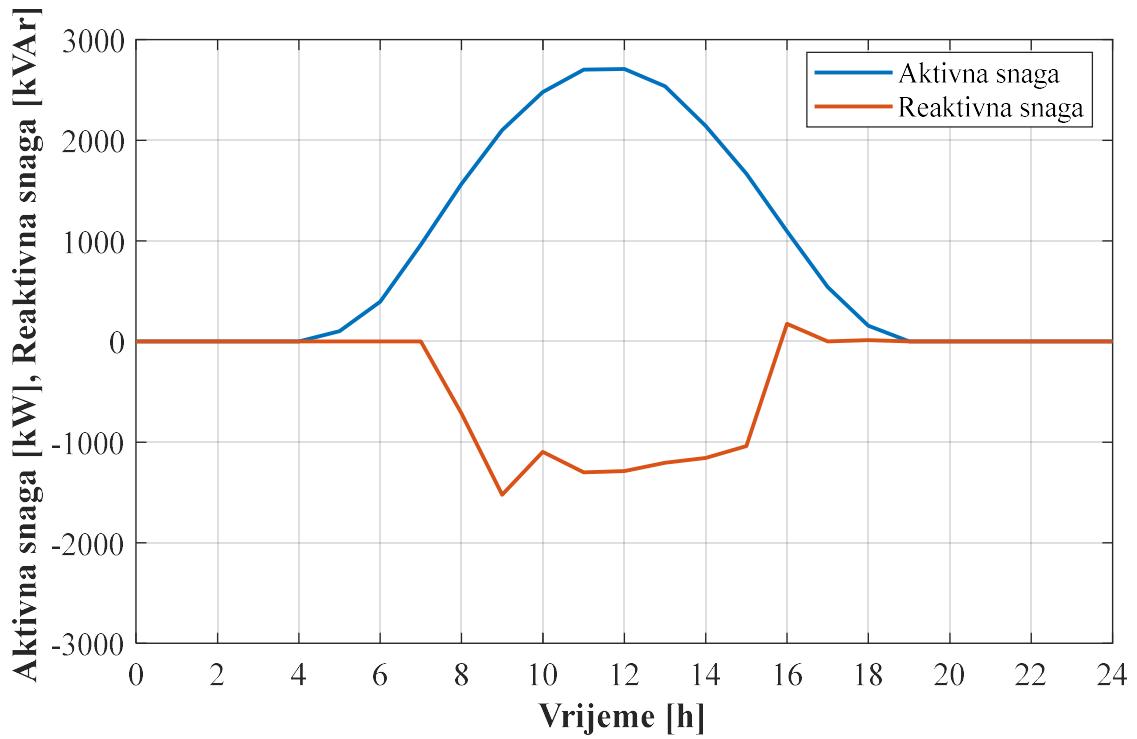
Ukupni gubici [kWh]	2017
Ukupni operativni troškovi [€]	266.31

4.4.2 Slučaj II

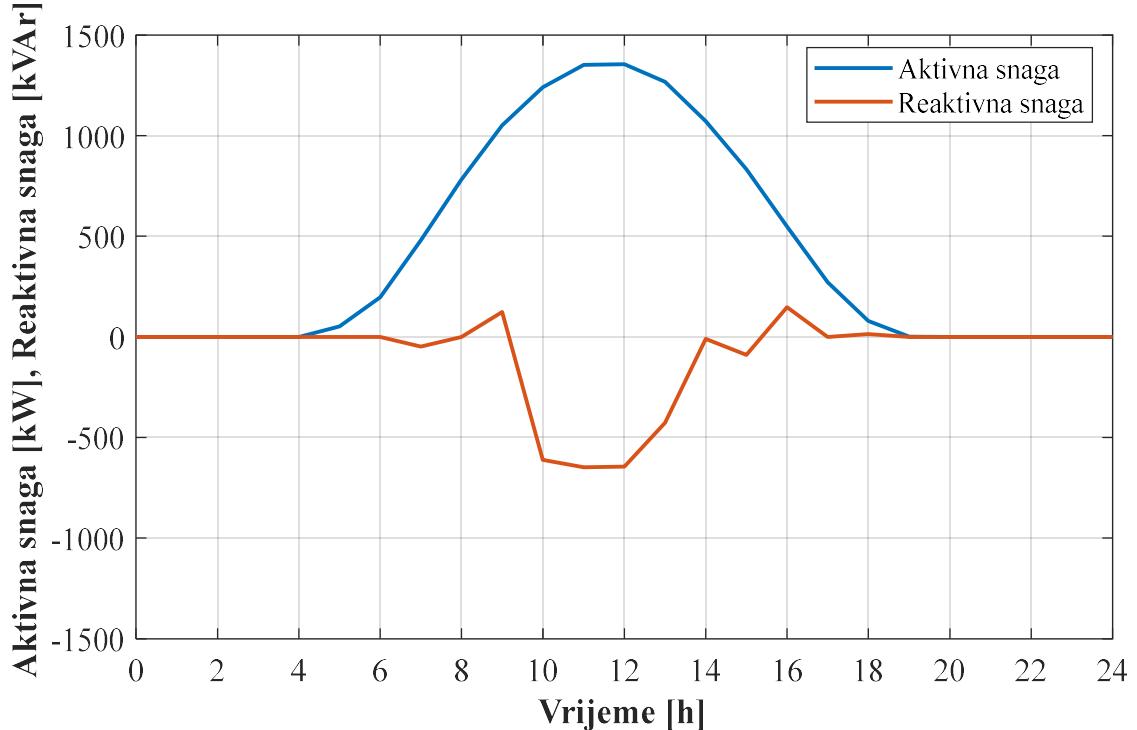
U Tabeli 4.7 su navedeni satni podaci o isključenim prekidačima za analizirani dan, dok su na Slikama 4.8, 4.9 i 4.10 prikazane satne vrijednosti aktivnih i reaktivnih snaga distribuiranih generatora. U skladu sa prethodno analiziranim slučajem, prepostavljeno je da ostvarena proizvodnja aktivne snage odgovara prognoziranim vrijednostima. U periodima intenzivnije proizvodnje aktivne snage, generatori, djelujući unutar svojih tehničkih ograničenja, apsorbiraju reaktivnu snagu radi stabilizacije napona. Dodatno, prvi i drugi generator koji su smješteni u čvorovima 30 i 17, tokom perioda s nižom proizvodnjom i bez problema visokih napona, injektiraju reaktivnu snagu u mrežu kako bi je kompenzovali i time pozitivno uticali na gubitke u mreži.

Tabela 4.5 Slučaj II – Isključeni prekidači po satima

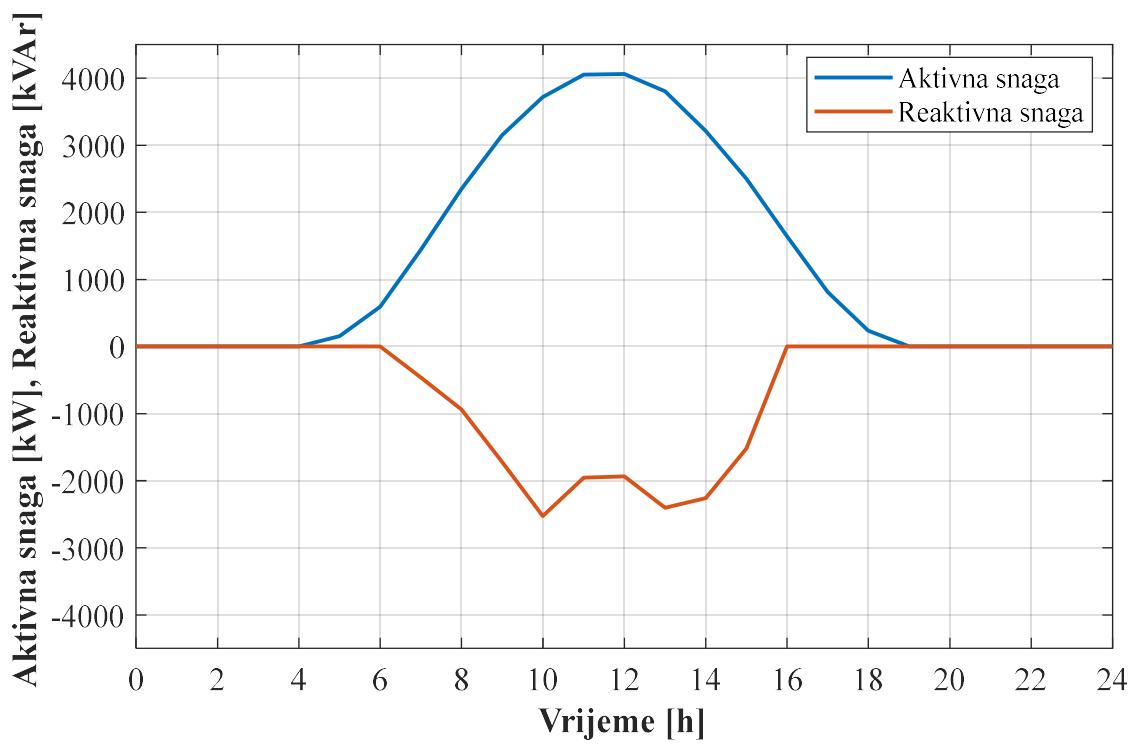
Period	Isključeni prekidači
00:00 – 01:00	6 – 9 – 14 – 26 – 34
01:00 – 02:00	6 – 9 – 14 – 26 – 34
02:00 – 03:00	6 – 9 – 14 – 26 – 34
03:00 – 04:00	6 – 9 – 14 – 26 – 34
04:00 – 05:00	6 – 9 – 14 – 26 – 34
05:00 – 06:00	6 – 9 – 14 – 26 – 34
06:00 – 07:00	6 – 14 – 18 – 21 – 26
07:00 – 08:00	5 – 11 – 18 – 21 – 26
08:00 – 09:00	5 – 7 – 11 – 18 – 33
09:00 – 10:00	5 – 11 – 29 – 33 – 34
10:00 – 11:00	3 – 7 – 14 – 29 – 33
11:00 – 12:00	3 – 7 – 9 – 29 – 35
12:00 – 13:00	3 – 7 – 9 – 29 – 35
13:00 – 14:00	3 – 7 – 9 – 29 – 35
14:00 – 15:00	3 – 7 – 9 – 29 – 35
15:00 – 16:00	7 – 18 – 26 – 34 – 35
16:00 – 17:00	2 – 11 – 26 – 34 – 35
17:00 – 18:00	3 – 11 – 14 – 26 – 34
18:00 – 19:00	3 – 11 – 14 – 26 – 34
19:00 – 20:00	7 – 11 – 28 – 34 – 36
20:00 – 21:00	7 – 11 – 15 – 28 – 34
21:00 – 22:00	7 – 11 – 15 – 28 – 34
22:00 – 23:00	7 – 11 – 14 – 28 – 34
23:00 – 24:00	7 – 11 – 15 – 28 – 34



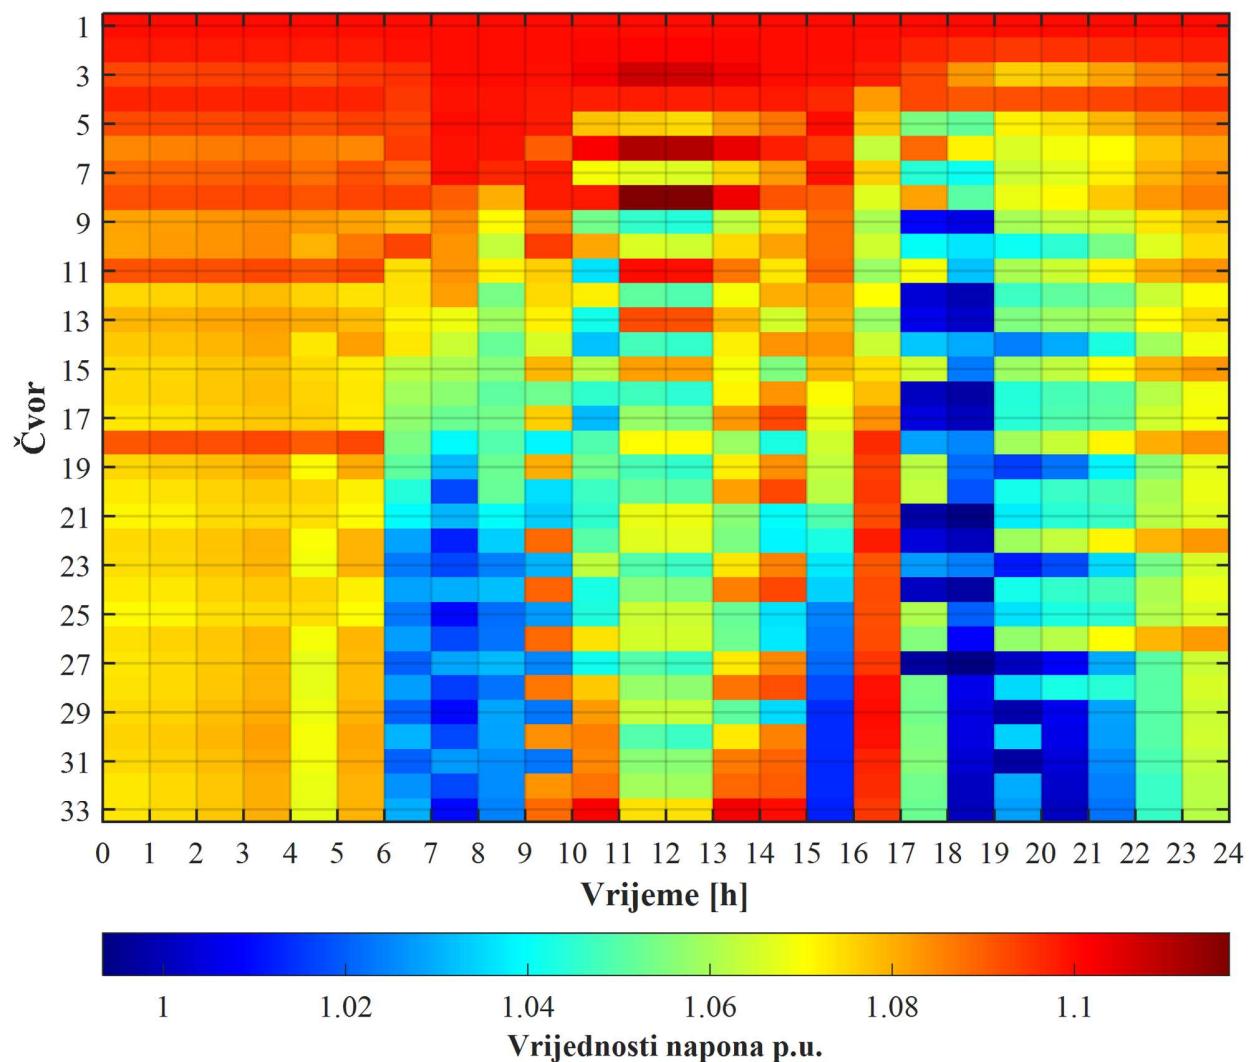
Slika 4.9 Slučaj II – Aktivna i reaktivna snaga DG1 po satima



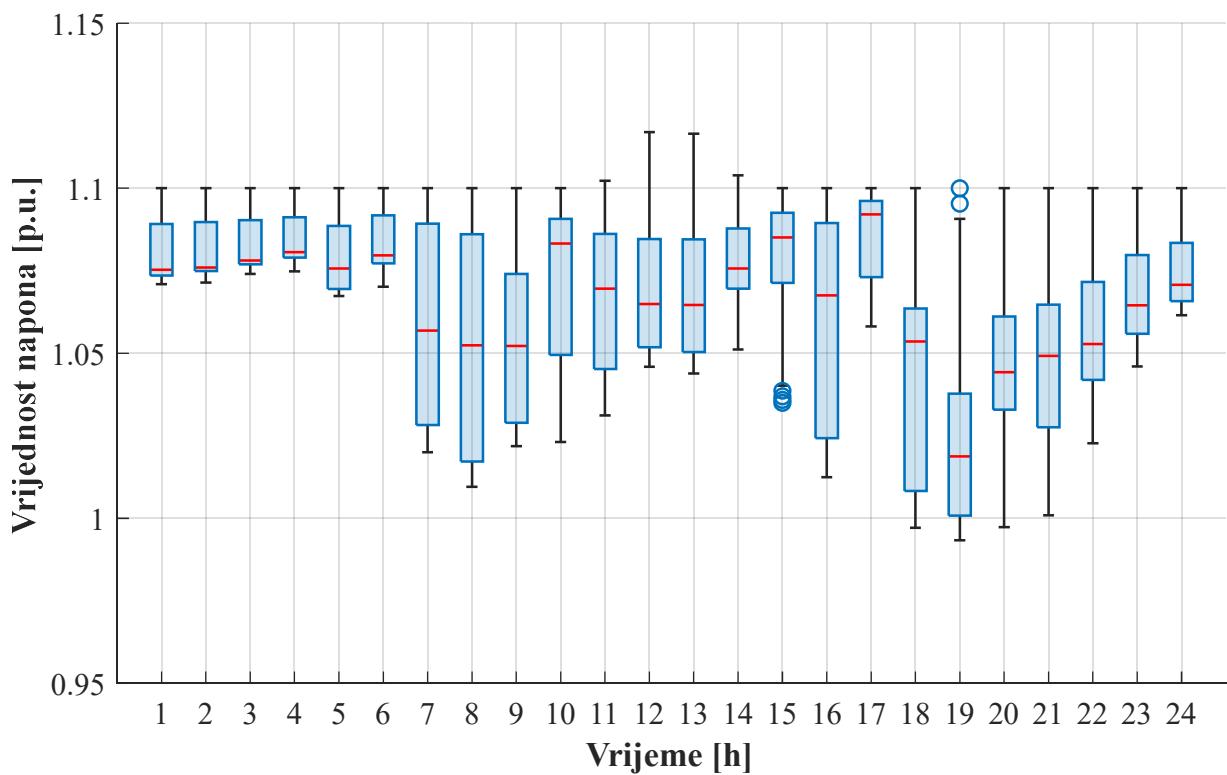
Slika 4.10 Slučaj II – Aktivna i reaktivna snaga DG2 po satima



Slika 4.11 Slučaj II – Aktivna i reaktivna snaga DG3 po satima



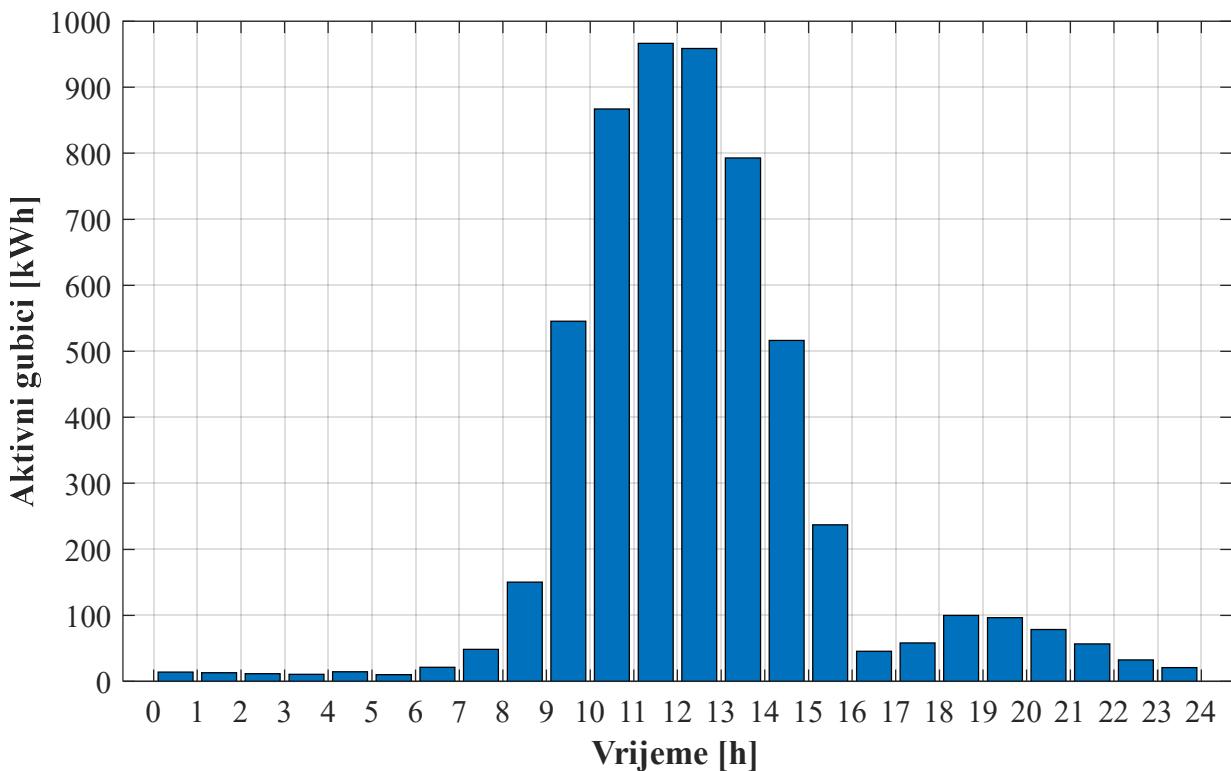
Slika 4.12 Slučaj II – Vrijednosti napona u čvorovima po satima



Slika 4.13 Slučaj II – Opsezi vrijednosti napona u mreži po satima

Na Slikama 4.11 i 4.12 su prikazane naponske prilike za posmatrani slučaj. Naponi u svim čvorovima mreže su 83.3% vremena u dozvoljenom opsegu, što predstavlja poboljšanje od 20.8% u odnosu na prethodni slučaj. Najkritičnija situacija je kod čvorova 2,3 i 6, gdje je napon u dozvoljenom opsegu takođe 83.3% vremena. Iako je u intervalu od jedanaestog do četrnaestog sata došlo do prekoračenja dozvoljenih granica napona, uočava se značajno poboljšanje obzirom da je maksimalna vrijednost napona dostizala $U_{max} = 1.117$ p.u. u dvanaestom satu.

Slika 4.13 pruža uvid u satne vrijednosti gubitaka aktivne snage. Kada se uporedi sa prethodnim slučajem, uočava se izraženiji porast gubitaka tokom perioda intenzivne proizvodnje distribuiranih generatora. Ova pojava proizilazi iz intenzivnog apsorbovanja reaktivne snage od strane distribuiranih generatora, što kao posljedicu ima dodatno opterećenje vodova u mreži. Konkretno, ukupni gubici aktivne snage za posmatrani dan, kako se vidi iz Tabele 4.8, iznose gotovo 5.7 MWh. Kada se ova činjenica uzme u obzir, primjećuje se da primjenom ove strategije upravljanja distributivnom mrežom dolazi do rasta operativnih troškova uslijed potrebe za postizanjem sigurnog pogona mreže. U tom kontekstu, ukupni operativni troškovi, koji za razliku od prethodnog slučaja uključuju i naknadu distribuiranim generatorima za upravljanje reaktivnom snagom, se procjenjuju na 698 €.



Slika 4.14 Slučaj II – Gubici aktivne snage u mreži po satima

Tabela 4.6 Slučaj II – Ukupni gubici aktivne snage i operativni troškovi

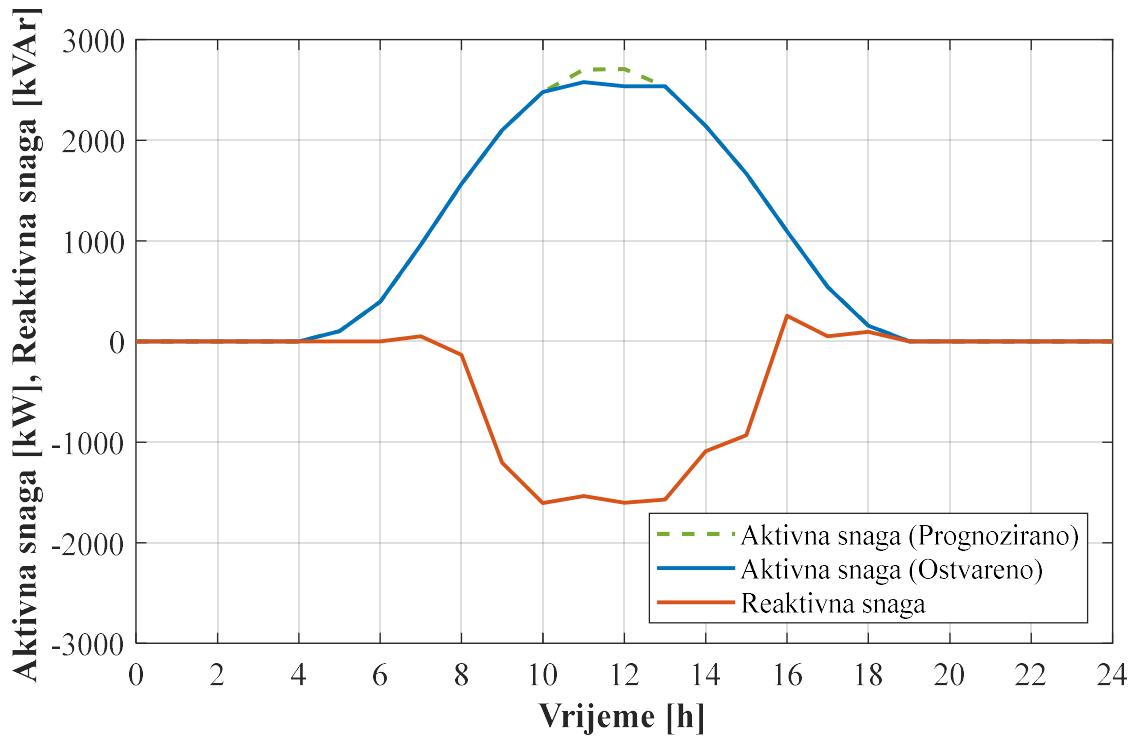
Ukupni gubici [kWh]	5668
Ukupni operativni troškovi [€]	692.88

4.4.3 Slučaj III

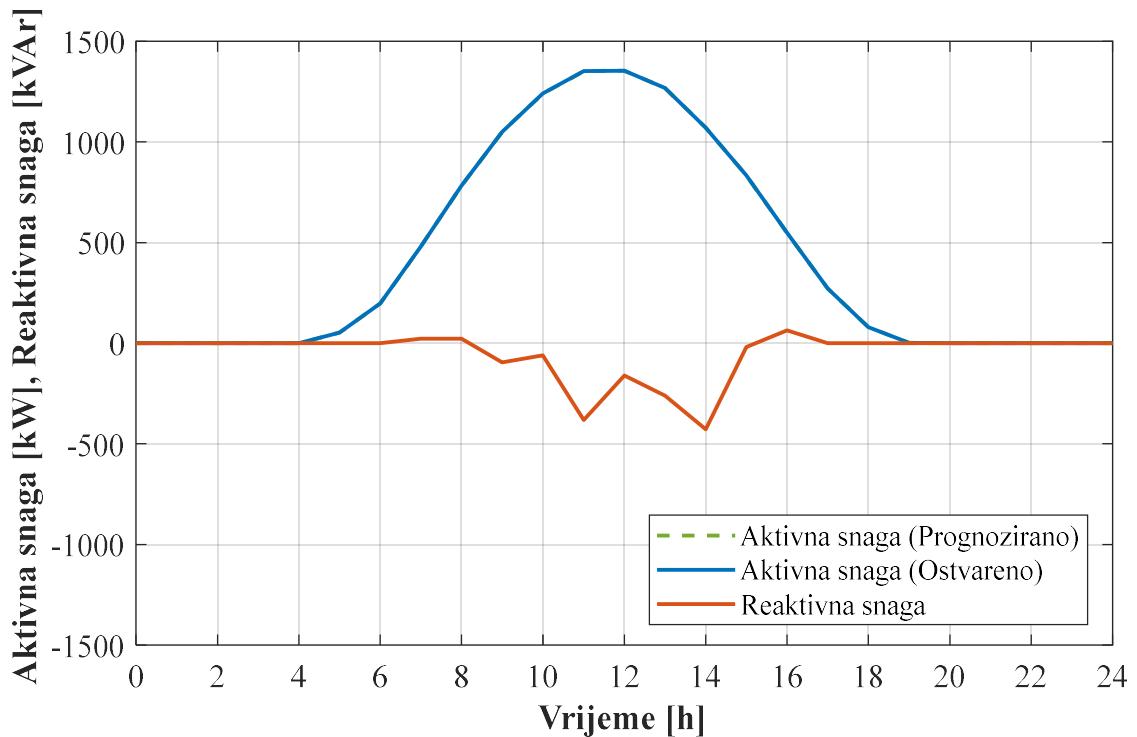
U tabeli 4.9 su predstavljeni satni podaci o isključenim prekidačima u mreži. S druge strane, na Slikama 4.14, 4.15 i 4.16 se mogu vidjeti satne vrijednosti aktivnih i reaktivnih snaga distribuiranih generatora. Jedan od ključnih elemenata u ovom slučaju jeste integracija upravljanja aktivnom snagom distribuiranih generatora kao jedne od tehnika aktivnog upravljanja distributivnom mrežom. Implementacija ovog pristupa je dovela do smanjenja proizvodnje aktivne snage kod prvog i trećeg distribuiranog generatora, smještenih u 30. i 24. čvoru, tokom najkritičnijih perioda. Ovaj korak je preduzet sa jasnim ciljem očuvanja napona unutar definisanih granica. Paralelno sa tim, kao i u prethodnom slučaju II, generatori tokom visoke proizvodnje aktivne snage apsorbuju reaktivnu snagu radi snižavanja napona. Takođe, u periodima niže proizvodnje, prvi i drugi generator injektiraju reaktivnu snagu kako bi se postiglo smanjenje gubitaka u mreži.

Tabela 4.7 Slučaj III – Isključeni prekidači po satima

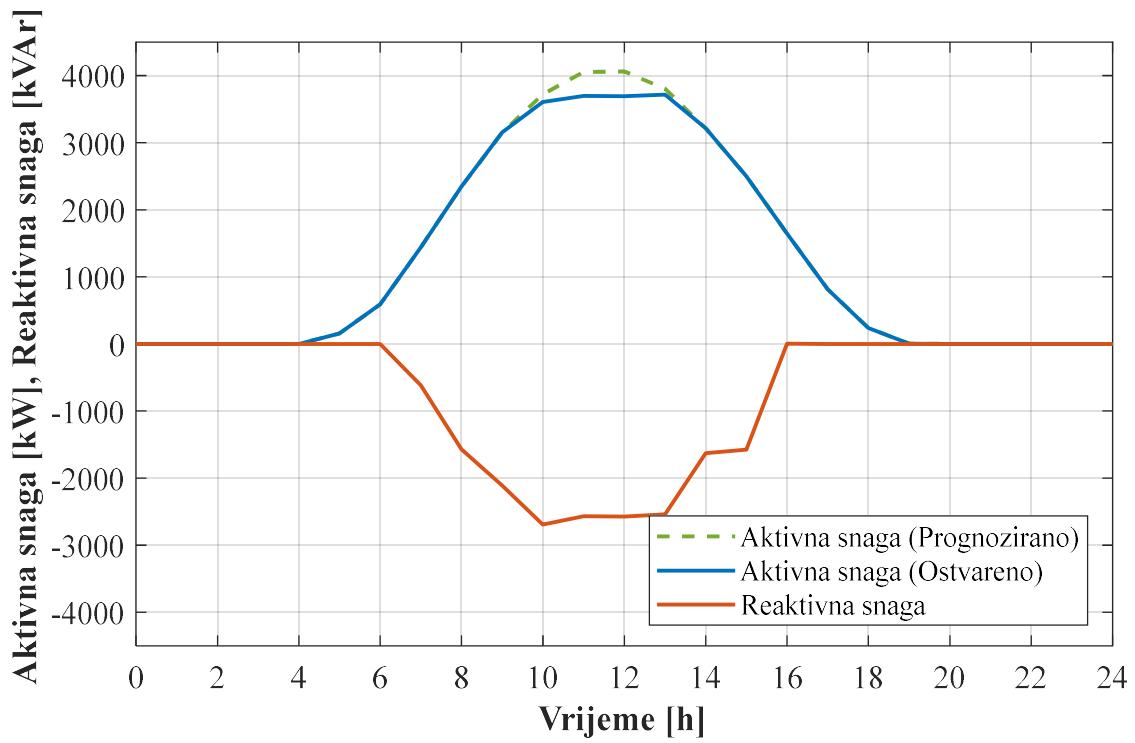
Period	Isključeni prekidači
00:00 – 01:00	6 – 9 – 14 – 26 – 34
01:00 – 02:00	6 – 9 – 14 – 26 – 34
02:00 – 03:00	6 – 9 – 14 – 26 – 34
03:00 – 04:00	6 – 9 – 14 – 26 – 34
04:00 – 05:00	7 – 9 – 14 – 26 – 34
05:00 – 06:00	6 – 9 – 14 – 26 – 33
06:00 – 07:00	6 – 9 – 14 – 26 – 33
07:00 – 08:00	3 – 7 – 9 – 18 – 21
08:00 – 09:00	3 – 7 – 9 – 18 – 21
09:00 – 10:00	3 – 7 – 9 – 29 – 34
10:00 – 11:00	3 – 9 – 29 – 33 – 34
11:00 – 12:00	5 – 11 – 29 – 33 – 34
12:00 – 13:00	3 – 9 – 29 – 33 – 34
13:00 – 14:00	3 – 11 – 29 – 33 – 34
14:00 – 15:00	3 – 11 – 29 – 33 – 34
15:00 – 16:00	3 – 11 – 18 – 33 – 36
16:00 – 17:00	3 – 11 – 33 – 35 – 36
17:00 – 18:00	11 – 28 – 33 – 34 – 36
18:00 – 19:00	11 – 28 – 33 – 34 – 36
19:00 – 20:00	7 – 11 – 28 – 34 – 36
20:00 – 21:00	7 – 11 – 28 – 34 – 36
21:00 – 22:00	7 – 11 – 28 – 31 – 34
22:00 – 23:00	7 – 11 – 28 – 31 – 35
23:00 – 24:00	7 – 11 – 28 – 31 – 35



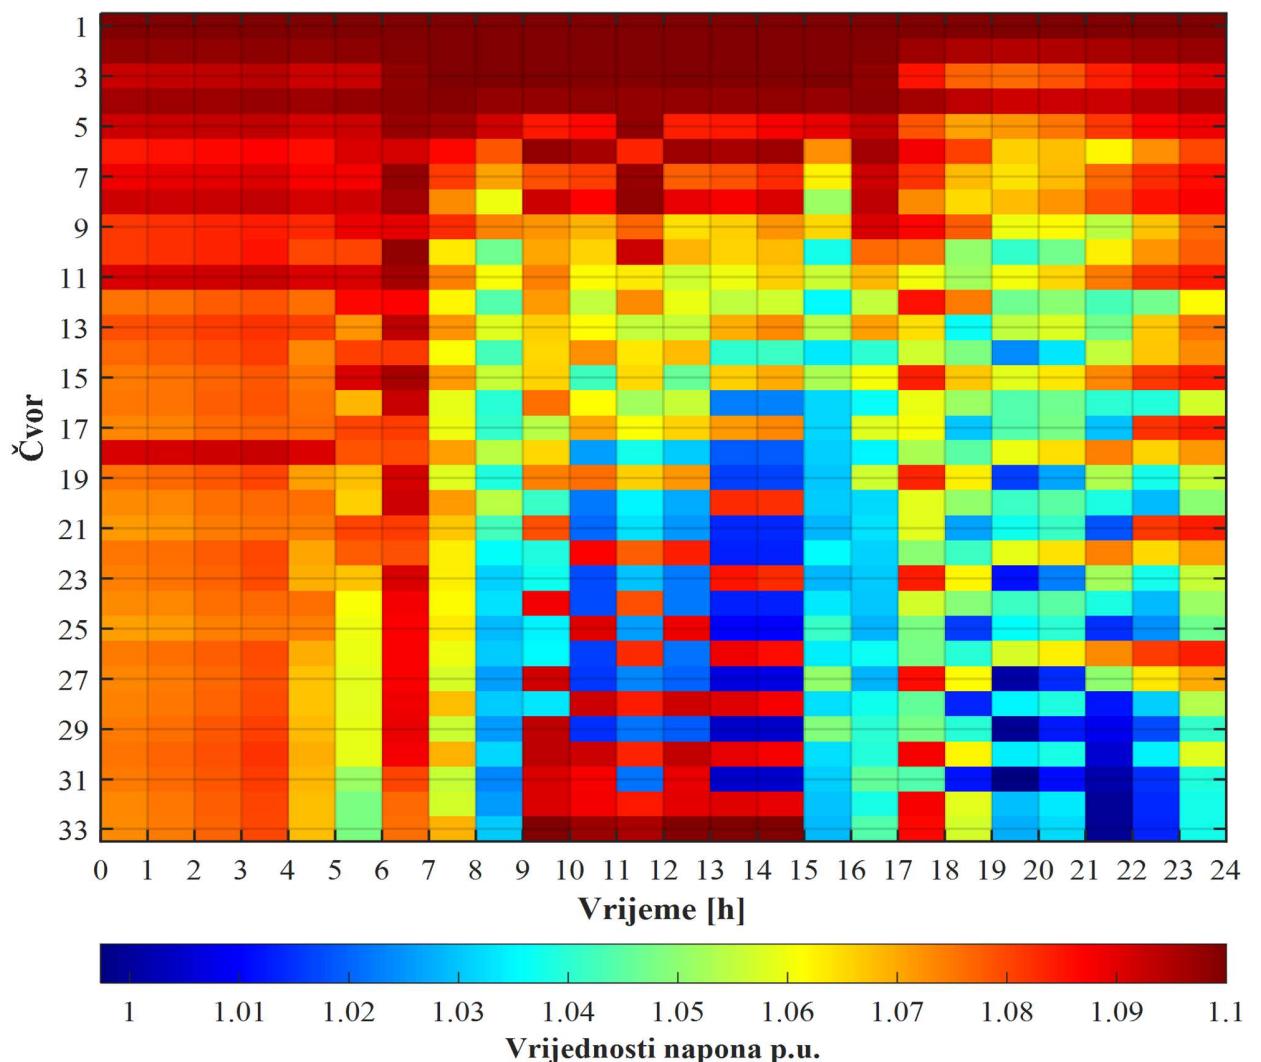
Slika 4.15 Slučaj III – Aktivna i reaktivna snaga DG1 po satima



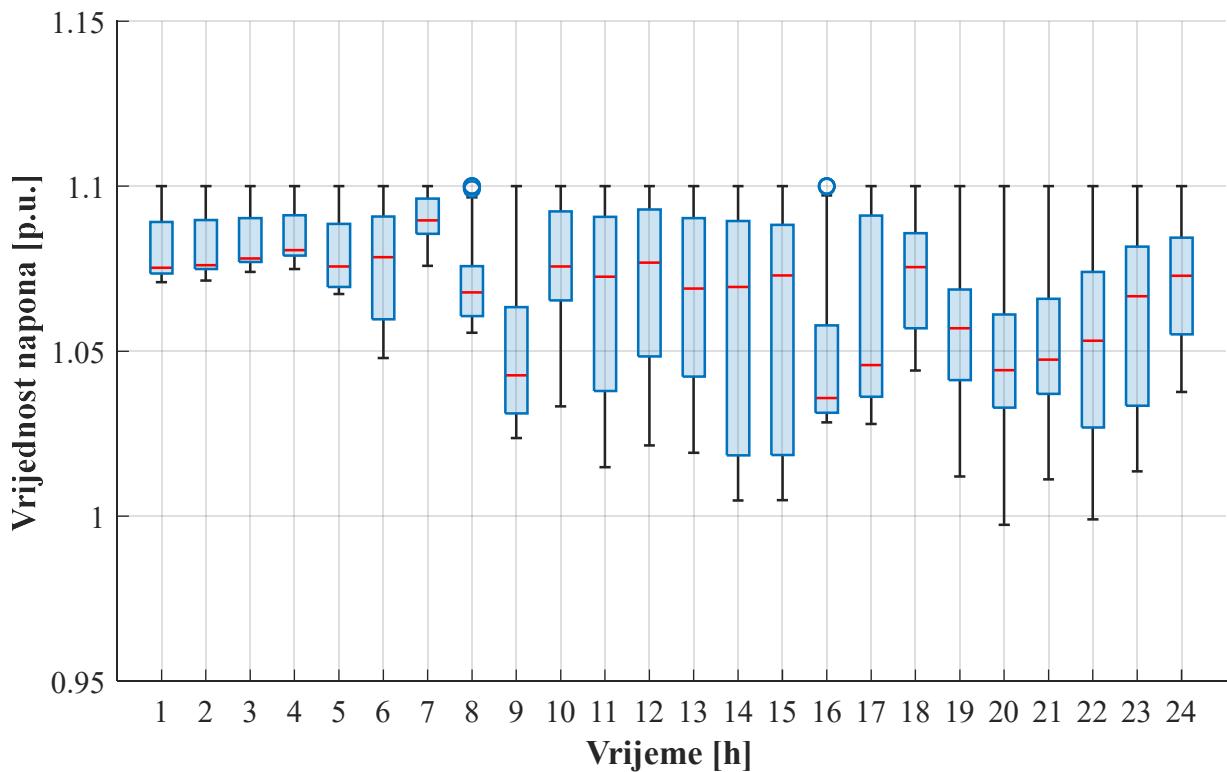
Slika 4.16 Slučaj III – Aktivna i reaktivna snaga DG2 po satima



Slika 4.17 Slučaj III – Aktivna i reaktivna snaga DG3 po satima



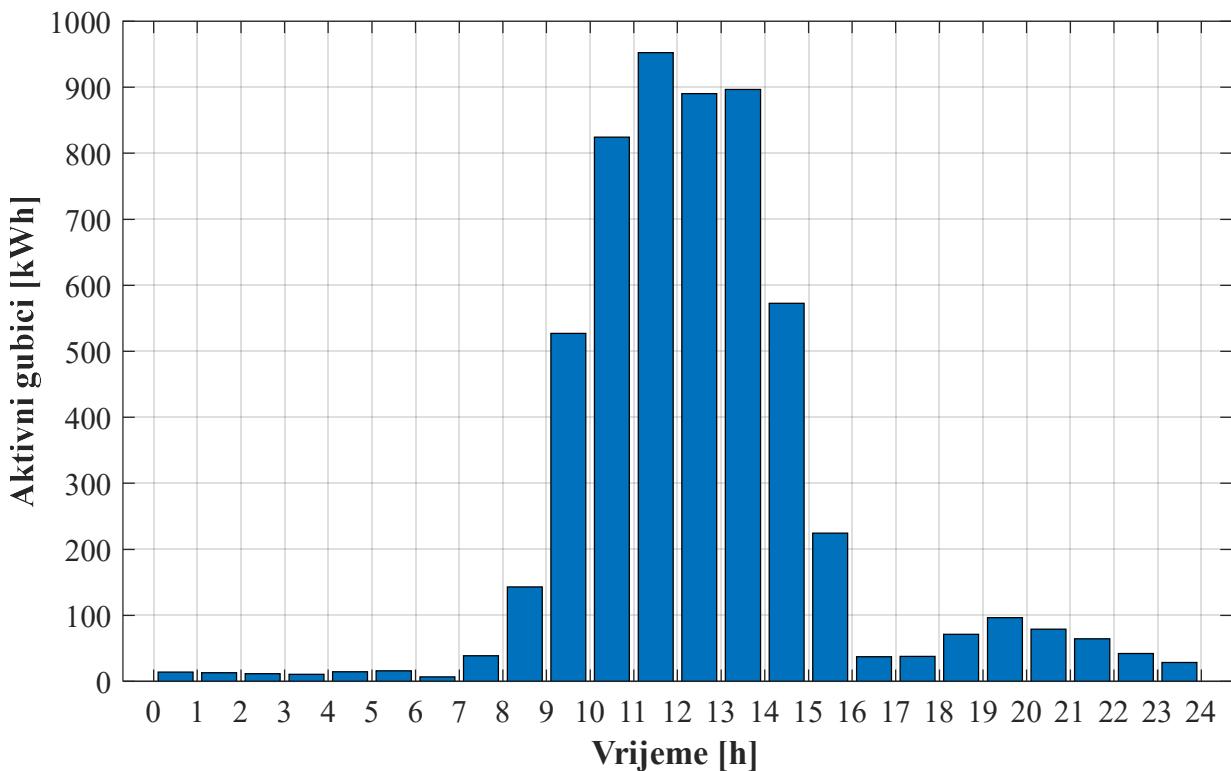
Slika 4.18 Slučaj III – Vrijednosti napona u čvorovima po satima



Slika 4.19 Slučaj III – Opsezi vrijednosti napona u mreži po satima

Na Slikama 4.17 i 4.18 su prikazane naponske prilike za posmatrani slučaj III. U ovom scenariju, sve naponske vrijednosti se nalaze unutar dozvoljenih granica, pri čemu je maksimalna vrijednost $U_{max} = 1.1$ p.u. Ovo predstavlja značajno poboljšanje u odnosu na prethodno prikazane slučajeve i ukazuje na efikasnost ove metode u održavanju sigurnog pogona distributivne mreže u kritičnim scenarijima.

Slika 4.19 prikazuje satne gubitke, koji su u periodima visoke proizvodnje distribuiranih generatora povećani, kao i u slučaju II. Porast gubitaka proizilazi iz većeg opterećenja vodova mreže uslijed apsorpcije reaktivne snage od strane distribuiranih generatora. Konkretno, ukupni gubici za posmatrani dan iznose 5.6 MWh, kako je prikazano u Tabeli 4.10. Uključujući smanjenje proizvodnje prvog i trećeg generatora za 1.225 MWh, ovdje je za razliku od slučaja II neophodno uzeti u obzir i naknadu generatorima za upravljanje aktivnom snagom, što rezultira ukupnim operativnim troškovima od 817 €.



Slika 4.20 Slučaj III – Gubici aktivne snage u mreži po satima

Tabela 4.8 Slučaj III – Ukupni gubici aktivne snage i operativni troškovi

Ukupni gubici [kWh]	5613
Ukupni troškovi [€]	817.24

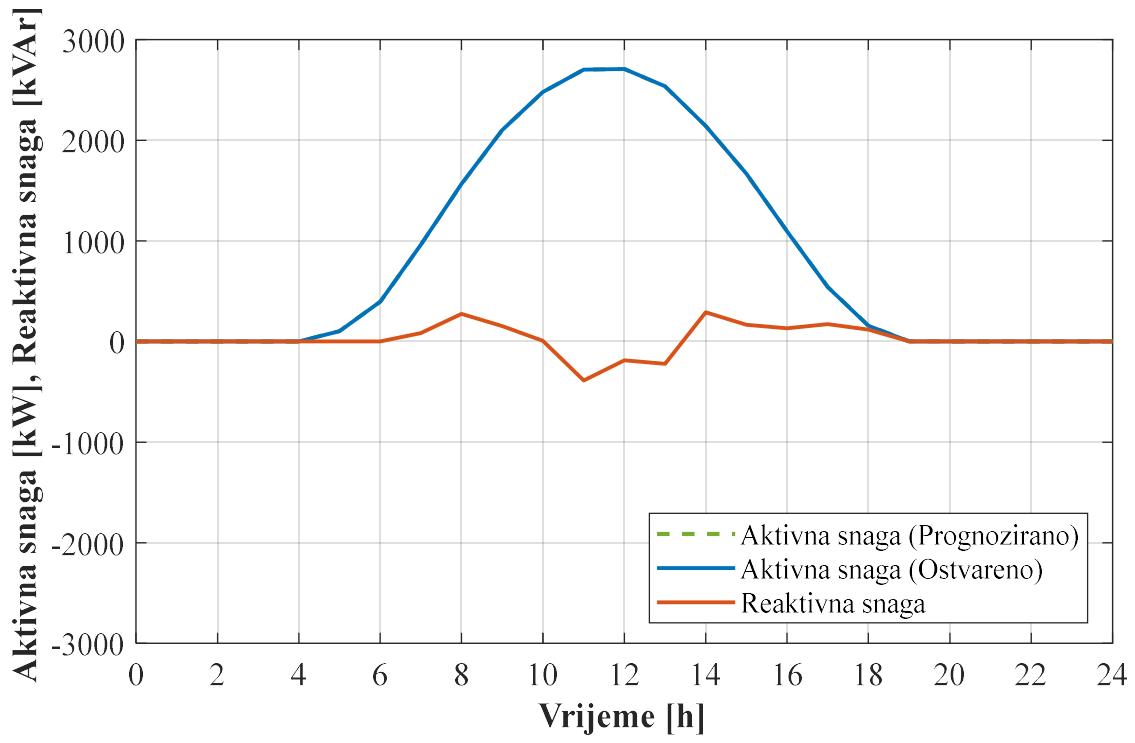
U prethodnim analizama je razmatran najkritičniji scenario, pri čemu je napon napojne trafostanice (NTS) iznosio 1.1 p.u. Međutim, u praksi, ove trafostanice obično imaju mogućnost regulacije napona putem regulacionih sklopki, što omogućava održavanje napuna unutar uskog opsega oko nominalne vrijednosti od 1 p.u. Iz tog razloga, za potrebe poređenja, u nastavku će biti analiziran slučaj kada je napon NTS 1 p.u., kako bi se prikazale razlike u potrebama za strategijama aktivnog upravljanja mrežom i njihovoj efikasnosti.

U tabeli 4.9 su prikazani satni podaci o isključenim prekidačima, gdje se bilježi znatno manji broj prekidačkih akcija u poređenju sa prethodnim scenarijima. Slike 4.21, 4.22 i 4.23 ilustruju satne vrijednosti aktivnih i reaktivnih snaga distribuiranih generatora. Za razliku od prethodnih analiza, u ovoj nije bilo potrebe za smanjenjem aktivne snage nijednog generatora, dok je angažovanje reaktivne snage bilo znatno manje. Sa Slike 4.22 se može primjetiti da generator u čvoru 17, čak i u periodima

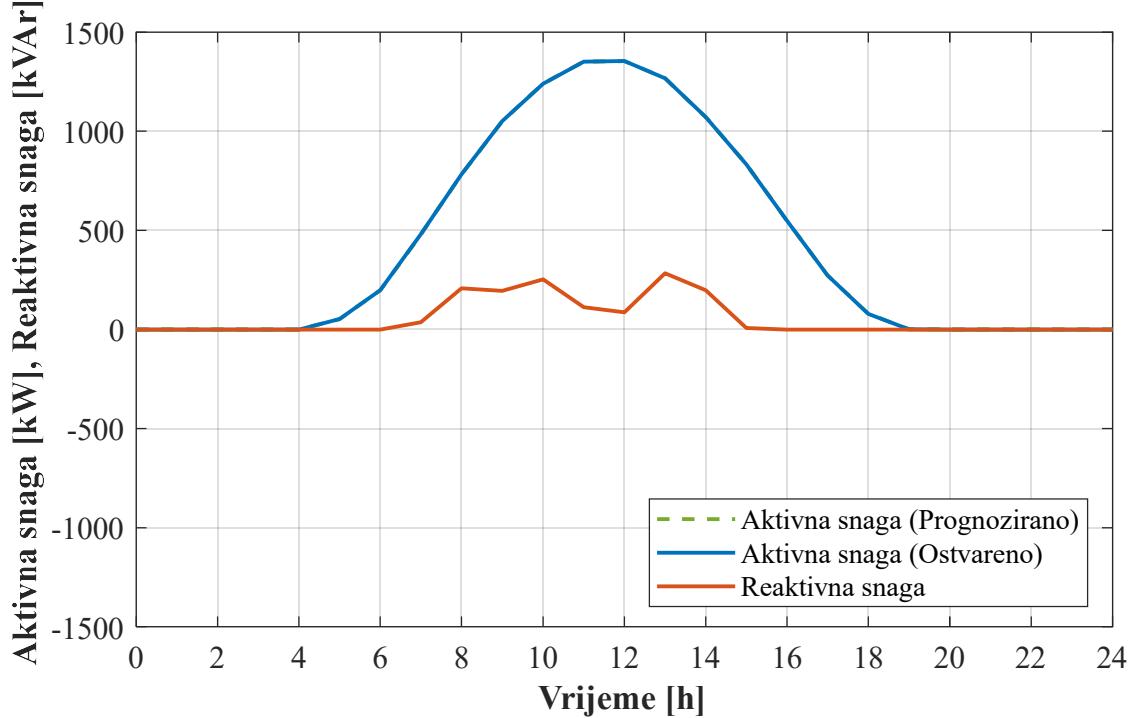
visoke proizvodnje, ima mogućnost injektiranja reaktivne snage u mrežu, što pozitivno doprinosi smanjenju gubitaka i povećanju ekonomičnosti rada distributivne mreže (Tabela 4.10). Na Slikama 4.24 i 4.25 su prikazane naponske prilike u posmatranom slučaju. Satni opsezi napona se nalaze unutar dozvoljenih granica, što potvrđuje da je u ovom slučaju uz manju potrebu za angažovanjem metoda aktivnog upravljanja moguće održati sigurnost i ekonomičnost pogona.

Tabela 4.9 Slučaj kada je napon NTS 1 p.u. – Isključeni prekidači po satima

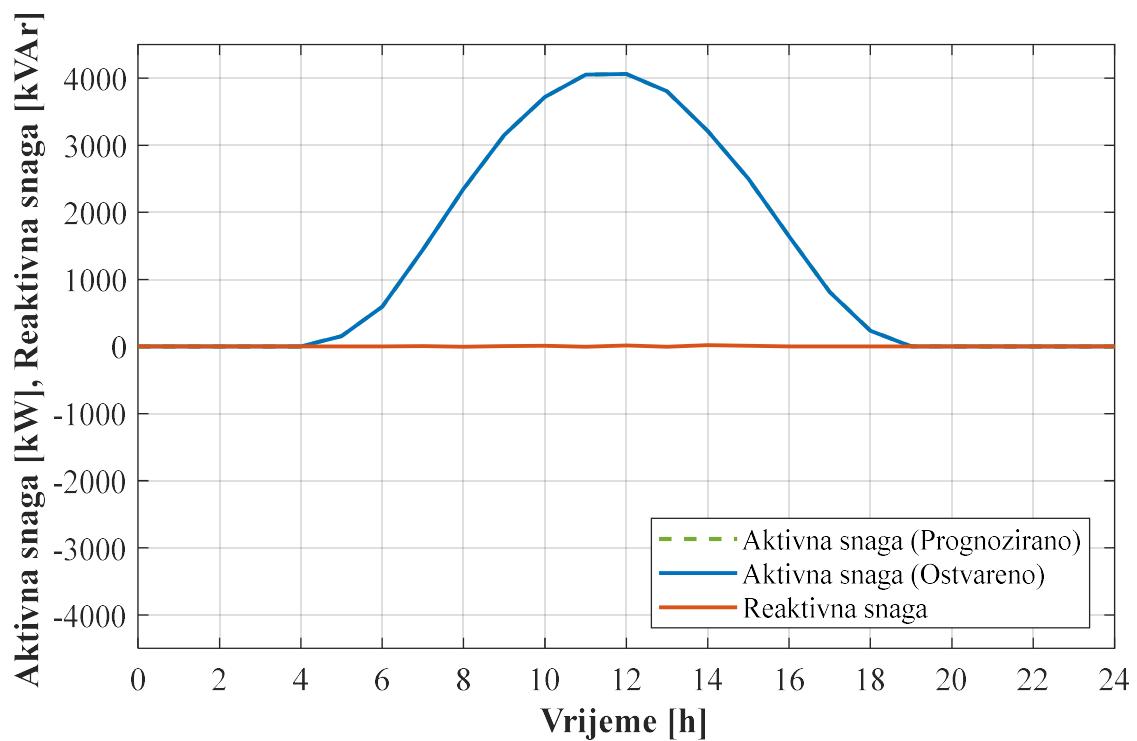
Period	Isključeni prekidači
00:00 – 01:00	6 – 9 – 14 – 26 – 34
01:00 – 02:00	6 – 9 – 14 – 26 – 34
02:00 – 03:00	6 – 9 – 14 – 26 – 34
03:00 – 04:00	6 – 9 – 14 – 26 – 34
04:00 – 05:00	6 – 9 – 14 – 26 – 34
05:00 – 06:00	6 – 9 – 14 – 26 – 34
06:00 – 07:00	3 – 7 – 9 – 14 – 34
07:00 – 08:00	3 – 7 – 9 – 18 – 21
08:00 – 09:00	3 – 7 – 9 – 18 – 21
09:00 – 10:00	7 – 9 – 18 – 21 – 37
10:00 – 11:00	7 – 9 – 18 – 34 – 37
11:00 – 12:00	9 – 18 – 21 – 36 – 37
12:00 – 13:00	9 – 18 – 21 – 36 – 37
13:00 – 14:00	3 – 9 – 21 – 36 – 37
14:00 – 15:00	3 – 9 – 21 – 36 – 37
15:00 – 16:00	21 – 33 – 34 – 36 – 37
16:00 – 17:00	18 – 28 – 33 – 34 – 36
17:00 – 18:00	11 – 28 – 33 – 34 – 36
18:00 – 19:00	11 – 28 – 33 – 34 – 36
19:00 – 20:00	7 – 11 – 28 – 34 – 36
20:00 – 21:00	7 – 11 – 15 – 28 – 34
21:00 – 22:00	7 – 11 – 28 – 31 – 34
22:00 – 23:00	7 – 11 – 28 – 31 – 34
23:00 – 24:00	7 – 11 – 28 – 31 – 34



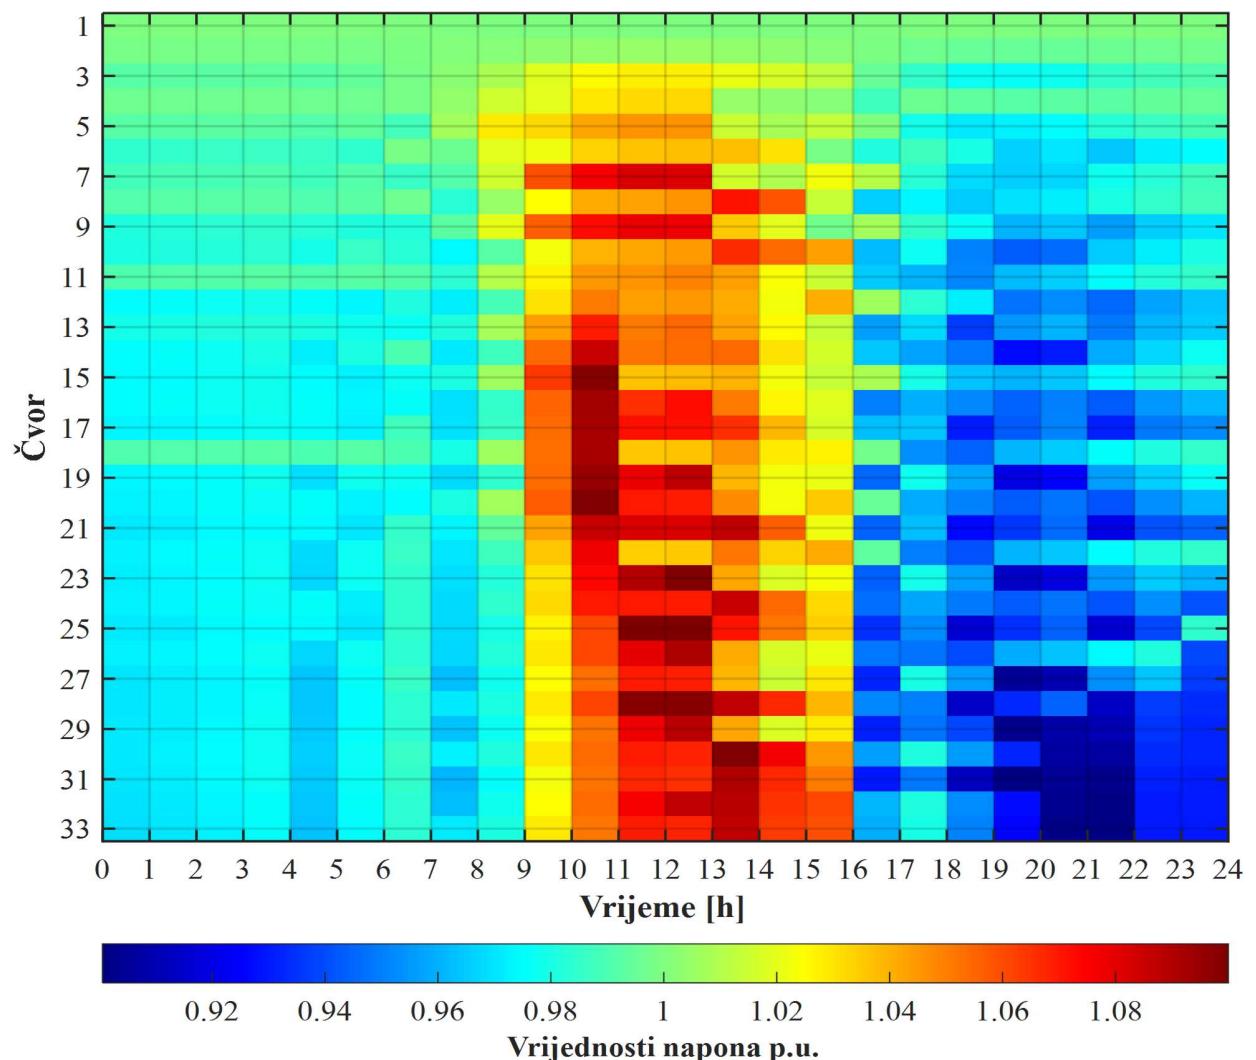
Slika 4.21 Slučaj kada je napon NTS I p.u. – Aktivna i reaktivna snaga DG1 po satima



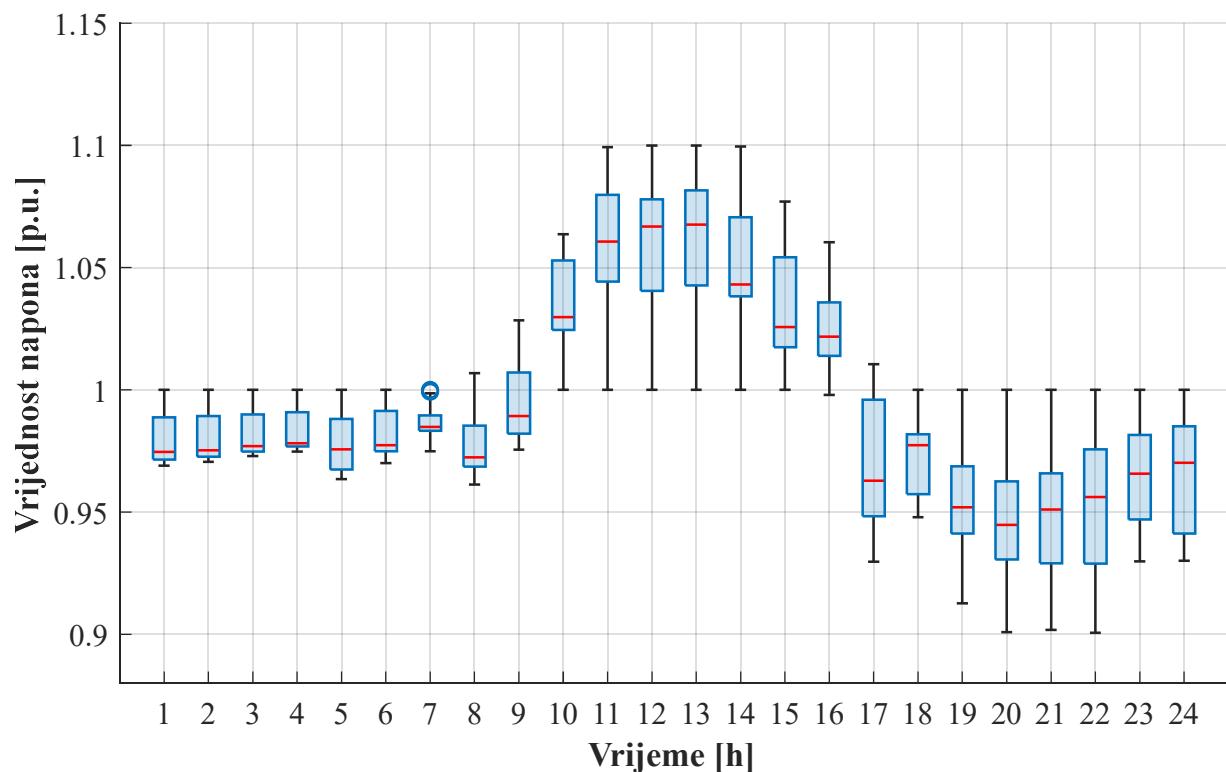
Slika 4.22 Slučaj kada je napon NTS I p.u. – Aktivna i reaktivna snaga DG2 po satima



Slika 4.23 Slučaj kada je napon NTS I p.u. – Aktivna i reaktivna snaga DG3 po satima



Slika 4.24 Slučaj kada je napon NTS 1 p.u. – Vrijednosti napona u čvorovima po satima



Slika 4.25 Slučaj kada je napon NTS 1 p.u. – Opsezi vrijednosti napona u mreži po satima

Tabela 4.10 Slučaj kada je napon NTS 1 p.u. – Ukupni gubici aktivne snage i operativni troškovi

Ukupni gubici [kWh]	2163
Ukupni operativni troškovi [€]	270.3

5. Zaključak

U savremenim elektroenergetskim sistemima, elektrodistributivne mreže postaju centralna tačka intenzivnih transformacija. Usljed decentralizacije, javlja se sve učestalija integracija obnovljivih izvora električne energije, dok paralelno sa tim dolazi do značajnog porasta potrošnje. Odsustvo korelacije između proizvodnje i potrošnje često uzrokuje fluktuacije napona i povećane gubitke u mreži. Međutim, zahvaljujući napretku digitalnih tehnologija i automatizaciji, pružaju se mogućnosti za nova unaprjeđenja. Otvara se prostor za razvoj naprednih sistema za monitoring i upravljanje, pružajući operatorima distributivnih mreža alate za kvalitetno suočavanje s aktuelnim izazovima. Kroz ove inovacije, primjena metoda aktivnog upravljanja distributivnom mrežom postaje sve značajnija, omogućavajući korišćenje resursa unutar mreže.

U ovom radu je sprovedeno istraživanje optimalne koordinacije rekonfiguracije distributivne mreže i upravljanja, kako reaktivnom, tako i aktivnom snagom distribuiranih generatora na satnom nivou, kreirajući tako sveobuhvatniju strategiju aktivnog upravljanja. Kao alat za rješavanje ovog optimizacionog zadatka, korišćen je genetski algoritam s primarnim ciljem minimizacije operativnih troškova distributivne mreže za posmatrani dan, uz zadovoljenje pogonskih ograničenja mreže i distribuiranih generatora. Za proračun tokova snaga korišćen je *DistFlow* metod, specijalno prilagođen za radijalne distributivne mreže. Problem je modelovan primjenom programskog paketa MATLAB, a metod je testiran na IEEE 33-čvornoj testnoj srednjenačanskoj distributivnoj mreži.

U okviru rezultata je sprovedena komparacija genetskog algoritma, optimizacije rojem čestica i diferencijalne evolucije. Kako bi se osigurala pouzdanost poređenja i dobijanje relevantnih rezultata, bilo je neophodno sprovesti nasumično određivanje setova parametara kroz više simulacija u cilju identifikacije optimalnih parametara za svaku od pomenutih metoda. Analiza je pokazala da genetski algoritam pruža mnogo bolje performanse, kako sa aspekta broja iteracija gdje je njegova upotreba zahtijevala značajno manje koraka, tako i u postizanju niže vrijednosti kriterijumske funkcije. U rezultatima ovog istraživanja analizirana su tri scenarija aktivnog upravljanja distributivnom mrežom: rekonfiguracija, rekonfiguracija uz upravljanje reaktivnom snagom distribuiranih generatora i rekonfiguracija uz upravljanje aktivnom i reaktivnom snagom distribuiranih generatora. Simulacija je izvedena za kritičan slučaj za aktivne distributivne mreže, gdje napon napojnog čvora iznosi 110% nominalne vrijednosti. Najbolji rezultati, u smislu osiguranja stabilnosti mreže, odnosno naponskih ograničenja, postignuti su u trećem slučaju kada su kombinovane sve tri metode. Ipak, uslјed troškova korišćenja više metoda i povećanih gubitaka dolazi do povećanih operativnih troškova. U prvom scenariju, gdje se javljaju niži operativni troškovi, naponska ograničenja su ozbiljno narušena. U drugom slučaju, iako su naponi poboljšani u odnosu na prvi, i dalje dolazi do prekoračenja naponskih granica. Takođe, sprovedena je i komparacija sa slučajem kada je napon NTS 1 p.u., što je pokazalo smanjenu potrebu za primjenom metoda aktivnog upravljanja u tom scenariju.

Važno je naglasiti izazove pri implementaciji ovog pristupa. Rekonfiguracija distributivne mreže na satnom nivou predstavlja složen kombinatorni zadatak, zbog brojnih rješenja koje treba analizirati. Uvođenjem novih elemenata, složenost problema se eksponencijalno povećava. Stoga je algoritam za proračun tokova snaga potrebno često pozivati, a brzina izračunavanja je direktno

povezana sa mrežnom kompleksnošću. Dodatni izazov predstavlja pristup preciznim ulaznim podacima, poput mrežnih parametara, pogonskih ograničenja i prognoza potrošnje i proizvodnje distribuiranih generatora. Pored toga, cijena električne energije, regulativni okviri i modeli naplate pomoćnih usluga koje pružaju distribuirani generatori dodatno komplikuju ovaj zadatak.

Buduća istraživanja će biti usmjerena na razvoj sveobuhvatnijih strategija upravljanja distributivnom mrežom koje će obuhvatiti različite tehnološke inovacije i pristupe. U periodu koji je obilježen rastućom dinamičnošću distributivnih mreža i tehnološkom evolucijom prema konceptu pametnih mreža, nužno je razmotriti sofisticirane metode aktivnog upravljanja. To uključuje upravljanje punjenjem električnih vozila, potrošnjom električne energije, uređajima za skladištenje energije, regulacionim transformatorima i ostalim komponentama. Primarni cilj jeste razviti alate i pristupe koji će osigurati stabilnost, efikasnost i održivost distributivnih mreža, istovremeno poštujući zahtjeve tržišta, ekološke principe i regulatorne standarde.

Literatura

- [1] J. Ekanayake, K. Liyanage, J. Wu, A. Yokoyama and N. Jenkins, “Smart Grid: Technology and Applications”, *John Wiley & Sons, Inc*, 2012.
- [2] Merlin A, Back H. “Search for a minimal loss operating spanning tree configuration in an urban power distribution system”, *Proceeding in 5th power system computation conf (PSCC)*, vol. 5, no. 1, pp. 1-18, 1975.
- [3] A.B. Morton, I.M.Y. Mareels, “An efficient brute-force solution to the network reconfiguration problem”, *IEEE Transactions on Power Delivery*, vol. 15, no. 3, pp. 996-1000, 2000, doi: 10.1109/61.871365.
- [4] C. Lee, C. Liu, S. Mehrotra, Z. Bie, “Robust Distribution Network Reconfiguration”, *IEEE Transactions on Smart Grid*, vol. 6, no. 2, pp. 836-842, 2015, doi: 10.1109/TSG.2014.2375160.
- [5] Y. Song, Y. Zheng, T. Liu, S. Lei, D.J. Hill, “A New Formulation of Distribution Network Reconfiguration for Reducing the Voltage Volatility Induced by Distributed Generation”, *IEEE Transactions on Power Systems*, vol. 35, no. 1, 2020, doi: 10.1109/TPWRS.2019.2926317.
- [6] M.S. Khomami, K. Jalilpoor, M. T. Kenari, M. S. Sepasian, “Bi-level network reconfiguration model to improve the resilience of distribution systems against extreme weather events”, *IET Generation, Transmission & Distribution*, vol. 13, no. 15, pp. 3302-3310, 2019, doi: <https://doi.org/10.1049/iet-gtd.2018.6971>.
- [7] K. Masteri, B. Vankatesh, “Real-time smart distribution system reconfiguration using complementarity”, *Electric Power Systems Research*, vol. 134, pp. 97-104, 2016, doi: <https://doi.org/10.1016/j.epsr.2016.01.004>.
- [8] R.A. Jabr, R. Singh, B.C. Pal, “Minimum Loss Network Reconfiguration Using Mixed-Integer Convex Programming”, *IEEE Transactions on Power Systems*, vol. 27, no. 2, 2012, doi: 10.1109/TPWRS.2011.2180406.
- [9] A. Ajaja, F.D. Galiana, “Distribution network reconfiguration for loss reduction using MILP”, *2012 IEEE PES Innovative Smart Grid Technologies (ISGT)*, 2012, doi: 10.1109/ISGT.2012.6175611.
- [10] M. Mosbah, S. Arif, R.D. Mohammedi, A. Hellal, “Optimum dynamic distribution network reconfiguration using minimum spanning tree algorithm”, *2017 5th International Conference on Electrical Engineering - Boumerdes (ICEE-B)*, 2017, doi: 10.1109/ICEE-B.2017.8192170.

- [11] S. Civanlar, J.J. Grainger, H. Yin, S.S.H. Lee, “Distribution feeder reconfiguration for loss reduction”, *IEEE Transactions on Power Delivery*, vol. 3, no. 3, pp. 1217-1223, 1988, doi: 10.1109/61.193906.
- [12] M.E. Baran, F.F. Wu, “Network reconfiguration in distribution systems for loss reduction and load balancing”, *IEEE Transactions on Power Delivery*, vol. 4, no. 2, pp. 1401-1407, 1989, doi: 10.1109/61.25627.
- [13] D. Shirmohammadi, H. W. Hong, “Reconfiguration of electric distribution networks for resistive line losses reduction”, *IEEE Transactions on Power Delivery*, vol. 4, no. 2, pp. 1492–1498, 1989, doi: 10.1109/61.25637.
- [14] V. Borozan, D. Rajicic, R. Ackovski, “Improved method for loss minimization in distribution networks”, *IEEE Transactions on Power Systems*, vol. 10, no. 3, 1995, pp. 1420-1425, doi: 10.1109/59.466509.
- [15] D. Rajicic, R. Ackovski, R. Taleski, “Voltage correction power flow”, *IEEE Transactions on Power Delivery*, vol. 9, no. 2, pp. 1056-1062, 1994, doi: 10.1109/61.296308.
- [16] V. Borozan, N. Rajakovic, “Application assessments of distribution network minimum loss reconfiguration”, *IEEE Transactions on Power Delivery*, vol. 12, no. 4, pp. 1786-1792, 1997, doi: 10.1109/61.634206.
- [17] V. Borozan, D. Rajicic, R. Ackovski, “Minimum loss reconfiguration of unbalanced distribution networks”, *IEEE Transactions on Power Delivery*, vol. 12, no. 1, pp. 435-442, 1997, doi: 10.1109/61.568268.
- [18] W.-M. Lin, H.-C. Chin, “A new approach for distribution feeder reconfiguration for loss reduction and service restoration”, *IEEE Transactions on Power Delivery*, vol. 13, no. 3, pp. 870-875, 1998, doi: 10.1109/61.686986.
- [19] S.K. Goswami, S.K. Basu, “A new algorithm for the reconfiguration of distribution feeders for loss minimization”, *IEEE Transactions on Power Delivery*, vol. 7, no. 3, pp. 1484-1491, 1992, doi: 10.1109/61.141868.
- [20] T.E. McDermott, I. Drezga, R.P. Broadwater, “A heuristic nonlinear constructive method for distribution system reconfiguration”, *IEEE Transactions on Power Systems*, vol. 14, no. 2, pp. 478-483, 1999, doi: 10.1109/59.761869.

- [21] S.P. Singh, G.S. Raju, G.K. Rao, M. Afsari, “A heuristic method for feeder reconfiguration and service restoration in distribution networks”, *International Journal of Electrical Power & Energy Systems*, vol. 31, no. 7-8, pp. 309-314, 2009, doi: <https://doi.org/10.1016/j.ijepes.2009.03.013>.
- [22] J.-Y. Fan, L. Zhang, J.D. McDonald, “Distribution network reconfiguration: single loop optimization”, *IEEE Transactions on Power Systems*, vol. 11, no. 3, pp. 1643-1647, 1996, doi: 10.1109/59.535709.
- [23] G.J. Peponis, M.P. Papadopoulos, N.D. Hatziargyriou, “ Distribution network reconfiguration to minimize resistive line losses”, *IEEE Transactions on Power Delivery*, vol. 10, no. 3, pp. 1338-1342, 1995, doi: 10.1109/61.400914.
- [24] Q. Zhou, D. Shirmohammadi, W.-H.E. Liu, “Distribution feeder reconfiguration for operation cost reduction”, *IEEE Transactions on Power Systems*, vol. 12, no. 2, pp. 730-735, 1997, doi: 10.1109/59.589665.
- [25] Q. Zhou, D. Shirmohammadi, W.-H.E. Liu, “Distribution feeder reconfiguration for service restoration and load balancing”, *IEEE Transactions on Power Systems*, vol. 12, no. 2, pp. 724-729, 1997, doi: 10.1109/59.589664.
- [26] T.T. Nguyen, A.V. Truong, “Distribution network reconfiguration for power loss minimization and voltage profile improvement using cuckoo search algorithm”, *International Journal of Electrical Power & Energy Systems*, vol. 68, pp. 233-242, 2015, doi: <https://doi.org/10.1016/j.ijepes.2014.12.075>.
- [27] T.T. Nguyen, A.V. Truong, T.A. Phung, “A novel method based on adaptive cuckoo search for optimal network reconfiguration and distributed generation allocation in distribution network”, *International Journal of Electrical Power & Energy Systems*, vol. 78, pp. 801-815, 2016, doi: <https://doi.org/10.1016/j.ijepes.2015.12.030>.
- [28] Z. Li, S. Jazebi, F. de Leon, “Determination of the Optimal Switching Frequency for Distribution System Reconfiguration”, *IEEE Transactions on Power Delivery*, vol. 32, no. 4, pp. 2060-2069, 2017, doi: 10.1109/TPWRD.2016.2594385.
- [29] K. Liu, W. Sheng, Y. Liu, X. Meng, “A Network Reconfiguration Method Considering Data Uncertainties in Smart Distribution Networks”, *Energies* 2017, vol. 10, no. 5, pp. 1-17, 2017, doi: <https://doi.org/10.3390/en10050618>.
- [30] W. Guan, Y. Tan, H. Zhang, J. Song, “Distribution system feeder reconfiguration considering different model of DG sources”, *International Journal of Electrical Power & Energy Systems*, vol. 86, pp. 210-221, 2015, doi: <https://doi.org/10.1016/j.ijepes.2014.12.023>.

- [31] K. Nara, A. Shiose, M. Kitagawa, T. Ishinara, “Implementation of genetic algorithm for distribution systems loss minimum re-configuration”, *IEEE Transactions on Power Systems*, vol. 7, no. 3, pp. 1044-1051, 1992, doi: 10.1109/59.207317.
- [32] S. Golshannavaz, S. Afsharnia, F. Aminifar, “Smart Distribution Grid: Optimal Day-Ahead Scheduling With Reconfigurable Topology”, *IEEE Transactions on Smart Grid*, vol. 5, no. 5, pp. 2402-2411, 2014, doi: 10.1109/TSG.2014.2335815.
- [33] A.M. Eldurassi, R.M. O'Connell, “A Fast Nondominated Sorting Guided Genetic Algorithm for Multi-Objective Power Distribution System Reconfiguration Problem”, *IEEE Transactions on Power Systems*, vol. 30, no. 2, pp. 593-601, 2015, doi: 10.1109/TPWRS.2014.2332953.
- [34] D.-L. Duan, X.-D. Ling, X.-Y. Wu, B. Zhong, “Reconfiguration of distribution network for loss reduction and reliability improvement based on an enhanced genetic algorithm”, *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 88-95, 2015, doi: <https://doi.org/10.1016/j.ijepes.2014.07.036>.
- [35] M. Abdelaziz, “Distribution network reconfiguration using a genetic algorithm with varying population size”, *Electric Power Systems Research*, vol. 142, pp. 9-11, 2017, doi: <https://doi.org/10.1016/j.epsr.2016.08.026>.
- [36] H.B. Tolabi, M.H. Ali, M.Rizwan, “Simultaneous Reconfiguration, Optimal Placement of DSTATCOM, and Photovoltaic Array in a Distribution System Based on Fuzzy-ACO Approach”, *IEEE Transactions on Sustainable Energy*, vol. 6, no. 1, pp. 210-218, 2015, doi: 10.1109/TSTE.2014.2364230.
- [37] A. Swarnkar, N. Gupta, K.R. Niazi, “ Adapted ant colony optimization for efficient reconfiguration of balanced and unbalanced distribution systems for loss minimization”, *Swarm and Evolutionary Computation*, vol. 1, no. 3, pp. 129-137, 2011, doi: <https://doi.org/10.1016/j.swevo.2011.05.004>.
- [38] R. Billinton, S. Jonnavithula, “Optimal switching device placement in radial distribution systems”, *IEEE Transactions on Power Delivery*, vol. 11, no. 3, pp. 1646-1651, 1996, doi: 10.1109/61.517529.
- [39] H.-C. Chang, C.-C. Kuo, “Network reconfiguration in distribution systems using simulated annealing”, *Electric Power Systems Research*, vol. 29, no. 3, pp. 227-238, 1994, doi: [https://doi.org/10.1016/0378-7796\(94\)90018-3](https://doi.org/10.1016/0378-7796(94)90018-3).

- [40] Y.-J. Jeon, J.-C. Kim, J.-O. Kim, J.-R. Shin, K.Y. Lee, “An efficient simulated annealing algorithm for network reconfiguration in large-scale distribution systems”, *IEEE Transactions on Power Delivery*, vol. 17, no. 4, pp. 1070-1078, 2002, doi: 10.1109/TPWRD.2002.803823.
- [41] M.-A. Rostami, A. Kavousi-Ford, T. Niknam, “Expected Cost Minimization of Smart Grids With Plug-In Hybrid Electric Vehicles Using Optimal Distribution Feeder Reconfiguration”, *IEEE Transactions on Industrial Informatics*, vol. 11, no. 2, pp. 388-397, 2015, doi: 10.1109/TII.2015.2395957.
- [42] H. Dura, “Optimum Number, Location, and Size of Shunt Capacitors in Radial Distribution Feeders A Dynamic Programming Approach”, *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-87, no. 9, pp. 1769-1774, 1968, doi: 10.1109/TPAS.1968.291982.
- [43] A. A. Ejaj, M.E. El-Hawary, “Optimal Capacitor Placement and Sizing in Unbalanced Distribution Systems With Harmonics Consideration Using Particle Swarm Optimization”, *IEEE Transactions on Power Delivery*, vol. 25, no. 3, pp. 1734-1741, 2010, doi: 10.1109/TPWRD.2009.2035425.
- [44] G.W. Chang, W.-C. Chang, C.-S. Chuang, D.-Y. Shih, “Fuzzy Logic and Immune-Based Algorithm for Placement and Sizing of Shunt Capacitor Banks in a Distorted Power Network”, *IEEE Transactions on Power Delivery*, vol. 26, no. 4, pp. 2145-2153, 2011, doi: 10.1109/TPWRD.2011.2167246.
- [45] J.Y. Park, J.-M. Sohn, J.-K. Park, “Optimal Capacitor Allocation in a Distribution System Considering Operation Costs”, *IEEE Transactions on Power Systems*, vol. 24, no. 1, pp. 462-468, 2009, doi: 10.1109/TPWRS.2008.2009489.
- [46] A. Savić, Ž. Đurišić, “Optimal sizing and location of SVC devices for improvement of voltage profile in distribution network with dispersed photovoltaic and wind power plants”, *Applied Energy*, vol. 134, pp. 114-124, 2014, doi: <https://doi.org/10.1016/j.apenergy.2014.08.014>.
- [47] H. Mori, H. Tani, “Two-staged tabu search for determining optimal allocation of D-FACTS in radial distribution systems with distributed generation”, *IEEE/PES Transmission and Distribution Conference and Exhibition*, 2002, doi: 10.1109/TDC.2002.1178260.
- [48] S.A. Taher, S.A. Afsari, “Optimal location and sizing of DSTATCOM in distribution systems by immune algorithm”, *International Journal of Electrical Power & Energy Systems*, vol. 60, pp. 34-44, 2014, doi: <https://doi.org/10.1016/j.ijepes.2014.02.020>.
- [49] E. Twining, M.J. Newman, P.C. Loh, D.G. Holmes, “Voltage compensation in weak distribution networks using a D-STATCOM”, *The Fifth International Conference on Power Electronics and Drive Systems*, 2003. PEDS 2003, 2003, doi: 10.1109/PEDS.2003.1282749.

- [50] M.H.J. Bollen, A. Sannino, “Voltage control with inverter-based distributed generation”, *IEEE Trans. Power Delivery*, vol. 20, no. 1, pp. 519–520, 2005, doi: 10.1109/TPWRD.2004.834679.
- [51] P.M.S. Carvalho, P.F. Correia, L.A.F.M. Ferreira, “Distributed Reactive Power Generation Control for Voltage Rise Mitigation in Distribution Networks”, *IEEE Transactions on Power Systems*, vol. 23, no. 2, pp. 766-772, 2008, doi: 10.1109/TPWRS.2008.919203.
- [52] I. Khan, Y. Xu, H. Sun, V. Bhattacharjee, “Distributed Optimal Reactive Power Control of Power Systems”, *IEEE Access*, vol. 6, pp. 7100-7111, 2017, doi: 10.1109/ACCESS.2017.2779806.
- [53] R. A. Jabr, “Linear Decision Rules for Control of Reactive Power by Distributed Photovoltaic Generators”, *IEEE Transactions on Power Systems*, vol.33, no. 2, pp. 2165-2174, 2017, doi: 10.1109/TPWRS.2017.2734694.
- [54] L. Zhang, W. Tang, J. Liang, P. Cong, Y. Cai, “Coordinated Day-Ahead Reactive Power Dispatch in Distribution Network Based on Real Power Forecast Errors”, *IEEE Transactions on Power Systems*, vol. 31, no. 3, pp. 2472-2480, 2015, doi: 10.1109/TPWRS.2015.2466435.
- [55] S.B. Kim, S.H. Song, “A Hybrid Reactive Power Control Method of Distributed Generation to Mitigate Voltage Rise in Low-Voltage Grid“, *Energies 2020*, vol. 13, no. 8, pp. 2078, 2020, doi: 10.3390/en13082078.
- [56] A.R. Malekpour, A. Pahwa, “Reactive power and voltage control in distribution systems with photovoltaic generation”, *2012 North American Power Symposium (NAPS)*, 2012, doi: 10.1109/NAPS.2012.6336354.
- [57] K. Daroj, W. Limpananwadi, “Reactive Power Dispatch scheme evaluation for synchronous based distributed generators to reduce real power loss in distribution systems”, *2008 IEEE International Conference on Sustainable Energy Technologies*, 2008, doi: 10.1109/ICSET.2008.4747185.
- [58] R. Tonkoski, L. A.C. Lopes, T.H.M. El-Fouly, “Coordinated Active Power Curtailment of Grid Connected PV Inverters for Overvoltage Prevention”, *IEEE Transactions on Sustainable Energy*, vol. 2, no. 2, pp. 139-147, 2011, doi: 10.1109/TSTE.2010.2098483.
- [59] S. Gosh, S. Rahman, M. Pipattanasomporn, “Distribution Voltage Regulation Through Active Power Curtailment With PV Inverters and Solar Generation Forecasts”, *IEEE Transactions on Sustainable Energy*, vol. 8, no. 1, pp. 13-22, 2017, doi: 10.1109/TSTE.2016.2577559.

- [60] M. Zeraati, M.E. Hamedani, J.M. Guerrero, “A Consensus-Based Cooperative Control of PEV Battery and PV Active Power Curtailment for Voltage Regulation in Distribution Networks”, *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 670-680, 2019, doi: 10.1109/TSG.2017.2749623.
- [61] R. Tonkoski, L.A.C. Lopes, D. Turcotte, “Active power curtailment of PV inverters in diesel hybrid mini-grids”, *2009 IEEE Electrical Power & Energy Conference (EPEC)*, 2009, doi: 10.1109/EPEC.2009.5420964.
- [62] S. Chalise, H.R. Atia, B. Poudel, R. Tonkoski, “Impact of Active Power Curtailment of Wind Turbines Connected to Residential Feeders for Ovvervoltage Prevention”, *IEEE Transactions on Sustainable Energy*, vol. 7, no. 2, pp. 471-479, 2016, doi: 10.1109/TSTE.2015.2499775.
- [63] E. Sortomme, M. M. Hindi, S. D. J. MacPherson, S. S. Venkata, “Coordinated Charging of Plug-In Hybrid Electric Vehicles to Minimize Distribution System Losses”, *IEEE Transactions on Smart Grid*, vol. 2, no. 1, pp. 198-205, 2011, doi: 10.1109/TSG.2010.2090913.
- [64] K. Clement-Nyns, E. Haesen, J. Driesen, “The Impact of Charging Plug-In Hybrid Electric Vehicles on a Residential Distribution Grid”, *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 371-380, 2010, doi: 10.1109/TPWRS.2009.2036481.
- [65] P. Papadopoulos, N. Jenkins, L. M. Cipcigan, I. Grau, E. Zabala, “Coordination of the Charging of Electric Vehicles Using a Multi-Agent System”, *IEEE Transactions on Smart Grid*, vol. 4, no. 4, 2013, doi: 10.1109/TSG.2013.2274391.
- [66] Y. Hao, L. Dong, J. Liang, X. Liao, L. Wang, L. Shi, “Power forecasting-based coordination dispatch of PV power generation and electric vehicles charging in microgrid”, *Renewable Energy*, vol. 155, pp. 1191-1210, 2020, doi: <https://doi.org/10.1016/j.renene.2020.03.169>.
- [67] P. You, Z. Yang; M. -Y. Chow, Y. Sun, “Optimal Cooperative Charging Strategy for a Smart Charging Station of Electric Vehicles”, *IEEE Transactions on Power Systems*, vol. 31, no. 4, pp. 2946-2956, 2016, doi: 10.1109/TPWRS.2015.2477372.
- [68] T. Logenthiran, D. Srinivasan, T. Z. Shun, “Demand Side Management in Smart Grid Using Heuristic Optimization”, *IEEE Transactions on Smart Grid*, vol. 3, no. 3, pp. 1244-1252, 2012, doi: 10.1109/TSG.2012.2195686.
- [69] Q. Xie, H. Hui, Y. Ding, C. Ye, “Use of Demand Response for Voltage Regulation in Power Distribution Systems with Flexible Resources”, *IET Generation, Transmission & Distribution*, vol. 14, no. 5, pp. 883-892, 2020, doi: 10.1049/iet-gtd.2019.1170.

- [70] A. Zakariazadeh, O. Homae, S. Jadid, P. Siano, “A new approach for real time voltage control using demand response in an automated distribution system”, *Applied Energy*, vol. 117, pp. 157-166, 2014, doi: <https://doi.org/10.1016/j.apenergy.2013.12.004>.
- [71] L. D. Arya, V. S. Pande, D. P. Kothari, “A technique for load-shedding based on voltage stability consideration”, *International Journal of Electrical Power & Energy Systems*, vol. 27, no. 7, pp. 506-517, 2005, doi: <https://doi.org/10.1016/j.ijepes.2005.05.001>.
- [72] M. Usman, A. Amin, M. M. Azam, H. Mokhlis, “Optimal under voltage load shedding scheme for a distribution network using EPSO algorithm”, *2018 1st International Conference on Power, Energy and Smart Grid (ICPESG)*, 2018, doi: [10.1109/ICPESG.2018.8384525](https://doi.org/10.1109/ICPESG.2018.8384525).
- [73] Z. M. Yasin, T. K. A. Rahman, Z. Zakaria, “Quantum-Inspired Evolutionary Programming Artificial Neural Network for Prediction of Undervoltage Load Shedding”, *2013 IEEE 8th Conference on Industrial Electronics and Applications (ICIEA)*, 2013, doi: [10.1109/ICIEA.2013.6566436](https://doi.org/10.1109/ICIEA.2013.6566436).
- [74] S.S. Rao, “Engineering Optimization: Theory and Practice, Fourth Edition”, *John Wiley & Sons, Inc*, 2009, doi: [10.1002/9780470549124](https://doi.org/10.1002/9780470549124).
- [75] M.A. Mejia, L.H. Macedo, G. Muñoz-Delgado, J. Contreras, A. Padilha-Feltrin, “Medium-term planning of active distribution systems considering voltage-dependent loads, network reconfiguration, and CO₂ emissions”, *International Journal of Electrical Power & Energy Systems*, vol. 135, pp. 1-14, 2022, doi: <https://doi.org/10.1016/j.ijepes.2021.107541>.
- [76] “Pravila za funkcionisanje distributivnog sistema električne energije,” 2016
- [77] D.Sarkar, S. Goswami, A. De, C.K. Chanda, A.K. Mukhopadhyay, “Improvement of Voltage Stability Margin in a Reconfigured Radial Power Network using Graph Theory”, *Canadian Journal on Electrical and Electronics Engineering*, vol. 2, no. 9, pp. 454-462, 2011.
- [78] U. Eminoglu, M. H. Hocaoglu, “Distribution Systems Forward/Backward Sweep-based Power Flow Algorithms: A Review and Comparison Study”, *Electric Power Components and Systems*, vol. 37, no.1, pp. 91-110, 2008, doi: <https://doi.org/10.1080/15325000802322046>.
- [79] Aleksandar Savić, Darko Šošić, Goran Dobrić, Mileta Žarković, “Metode optimizacije: Primena u elektroenergetici”, *Akademска мисао*, 2018.
- [80] H.W. Kuhn, A.W. Tucker, “ Nonlinear Programming”, *Proceedings of the second Berkeley Symposium on Mathematical Statistics and Probability*, pp. 481-492, 1951.
- [81] G.B. Dantzig, “Origins of the simplex method”, *A history of scientific computing*, pp. 141-151, 1990, doi: <https://doi.org/10.1145/87252.88081>.

- [82] R.E. Bellman, “Dynamic programming”, *Princeton University Press*, 1957.
- [83] R.E. Gomory, W.J. Baumol, “Integer Programming and Pricing”, *Econometrica*, vol. 28, no. 3, pp. 521-550, 1960, doi: <https://doi.org/10.2307/1910130>.
- [84] D.K. Pratihar, “Computational Optimization and Applications: Traditional vs. non-traditional optimization tools”, *Narosa Publishing House Pvt. Ltd.*, pp. 25-33, 2012.
- [85] K. Gallagher, M. Sambridge, “Genetic algorithms: A powerful tool for large-scale nonlinear optimization problems”, *Computers & Geosciences*, vol. 20, no. 7, pp. 1229-1236, 1994, doi: [https://doi.org/10.1016/0098-3004\(94\)90072-8](https://doi.org/10.1016/0098-3004(94)90072-8).
- [86] J. Bergstra, Y. Bengio, “Random Search for Hyper-Parameter Optimization”, *Journal of Machine Learning Research*, vol. 13, pp. 281-305, 2012.
- [87] B. Selman, C. P. Gomes, “Hill-climbing Search”, *Encyclopedia of Cognitive Science*, 2006, doi: <https://doi.org/10.1002/0470018860.s00015>.
- [88] S. Bandaru and K. Deb, “Metaheuristic Techniques”, 2016.
- [89] A. E. Ezugwu, O. J. Adeleke, A. A. Akinyelu, and S. Viriri, “A conceptual comparison of several metaheuristic algorithms on continuous optimisation problems”, *Neural Computing and Applications*, vol. 32, no. 10, pp. 6207–6251, 2020, doi: 10.1007/s00521-019-04132-w.
- [90] Z. Beheshti and S. M. H. Shamsuddin, “A review of population-based meta-heuristic algorithms”, *International Journal of Advances in Soft Computing and Its Applications*, vol. 5, no. 1, pp. 1–35, 2013, doi: 10.1155/2023/3961336.
- [91] X.-S. Yang, S. Deb, “Cuckoo Search via Lévy flights”, *2009 World Congress on Nature & Biologically Inspired Computing (NaBIC)*, 2009, doi: 10.1109/NABIC.2009.5393690.
- [92] R. Storn, K. Price, “Differential Evolution – A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces”, *Journal of Global Optimization*, vol. 11, pp. 341–359, 1997, doi: <https://doi.org/10.1023/A:1008202821328>.
- [93] J.H. Holland, “Adaptation in Natural and Artificial Systems”, *University of Michigan Press*, 1975.
- [94] J. Kennedy, R. Eberhart, “Particle swarm optimization”, *Proceedings of ICNN'95 - International Conference on Neural Networks*, 1995, doi: 10.1109/ICNN.1995.488968.

- [95] M. Dorigo, V. Maniezzo, A. Colomi, “Ant system: optimization by a colony of cooperating agents”, *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 26, no. 1, pp. 29-41, 1996, doi: 10.1109/3477.484436.
- [96] D. Karaboga, B. Basturk, “Artificial Bee Colony (ABC) Optimization Algorithm for Solving Constrained Optimization Problems”, *Foundations of Fuzzy Logic and Soft Computing, 12th International Fuzzy Systems Association World Congress*, 2007, doi: https://doi.org/10.1007/978-3-540-72950-1_77.
- [97] S. Kirkpatrick, C. D. Gelatt, M. P. Vecchi, “Optimization by Simulated Annealing”, *Science*, vol. 220, no. 4598, pp. 671-680, 1983, doi: 10.1126/science.220.4598.671.
- [98] J.H. Holland, “Genetic Algorithms”, *Scientific American*, vol. 267, no. 1, pp. 66-73, 1992, doi: <http://www.jstor.org/stable/24939139>.
- [99] J. Dreo, A. Petrowski, P. Siarry, E. Taillard, “Metaheuristics for Hard Optimization”, *Springer*, 2006, doi: 10.1007/3-540-30966-7.
- [100] Bilal, M. Pant, H. Zaheer, L. Garcia-Hernandez, A. Abraham, “Differential Evolution: A review of more than two decades of research”, *Engineering Applications of Artificial Intelligence*, vol. 90, doi: <https://doi.org/10.1016/j.engappai.2020.103479>.
- [101] L. Oi, K. Wu, Y. Wang, X. Jing, C. Cui, R. Zhao, “Research on Dynamic Optimized Operation Strategy of Distribution Network Considering Demand Response”, *2020 5th Asia Conference on Power and Electrical Engineering (ACPEE)*, 2020, doi: 10.1109/ACPEE48638.2020.9136397.
- [102] “PHOTOVOLTAIC GEOGRAPHICAL INFORMATION SYSTEM”, https://re.jrc.ec.europa.eu/pvg_tools/en/ (accessed Jan. 03, 2024).
- [103] “Treatment of Losses bz Network Operators”, *ERGEG Position Paper for public consultation*, 2008.
- [104] “Crnogorska berza električne energije”, <https://belen-spot.me/rezultati-aukcija-za-nabavku-elektricne-energije-za-pokrivanje-gubitaka-u-distributivnom-sistemu-za-jun-jul-i-avgust-2023/> (accessed Jan. 03, 2024).
- [105] D. A. Stevanović, “Određivanje preostalog životnog veka i strategije zamene malougljnih prekidača na osnovu dinamičke analize rizika”, *Elektronski fakultet Univerziteta u Nišu*, 2021.

- [106] M. N. Acosta, F. Gonzalez-Longatt, M. A. Andrade, J. L. R. Torres, H. R. Chamorro, “Assessment of Daily Cost of Reactive Power Procurement by Smart Inverters”, *Energies* 2021, vol. 14, no. 16, 2021, doi: <https://doi.org/10.3390/en14164834>.
- [107] “Crnogorska berza električne energije”, <https://belen-spot.me/day-ahead/> (accessed Jan. 03, 2024).

Prilog

Podaci o IEEE testnoj mreži od 33 čvora

Tabela P.1 Podaci o potrošačima u mreži sa 33 čvora

Čvor	$P_p [kW]$	$Q_p [kVAr]$	Tip potrošača
1	0	0	0
2	100	32.8	1
3	90	29.5	1
4	120	74.3	3
5	60	19.7	1
6	60	19.7	1
7	200	124	3
8	200	65.7	2
9	60	19.7	1
10	90	29.6	2
11	45	14.8	2
12	60	19.7	1
13	60	19.7	2
14	120	39.5	2
15	60	19.7	2
16	60	19.7	1
17	60	19.7	1
18	150	49.3	2
19	90	29.5	1
20	90	29.5	1
21	120	39.5	1
22	90	29.5	2
23	90	29.5	2
24	420	138	1
25	300	98.6	2
26	60	37.2	3
27	60	37.2	3
28	60	37.2	3
29	120	74.4	3
30	80	49.5	3
31	150	93	3
32	120	74.3	3
33	160	99.1	3

Treća kolona predstavlja tip potrošača: 1- rezidencijalni, 2- komercijalni, 3- industrijski.

Tabela P.2 Podaci o granama mreže sa 33 čvora

Redni broj grane	Početni čvor	Krajnji čvor	$R[\Omega]$	$X[\Omega]$	Posjeduje prekidač
1	1	2	0.0922	0.0470	Ne
2	2	3	0.4930	0.2511	Da
3	3	4	0.3660	0.1864	Da
4	4	5	0.3811	0.1941	Ne
5	5	6	0.8190	0.7070	Da
6	6	7	0.1872	0.6188	Da
7	7	8	0.7114	0.2351	Da
8	8	9	1.0300	0.7400	Ne
9	9	10	1.0440	0.7400	Da
10	10	11	0.1966	0.0650	Ne
11	11	12	0.3744	0.1238	Da
12	12	13	1.4680	1.1550	Ne
13	13	14	0.5416	0.7129	Ne
14	14	15	0.5910	0.5260	Da
15	15	16	0.7463	0.5450	Da
16	16	17	1.2890	1.7210	Ne
17	17	18	0.7320	0.5740	Ne
18	2	19	0.1640	0.1565	Da
19	19	20	1.5042	1.3554	Ne
20	20	21	0.4095	0.4784	Ne
21	21	22	0.7089	0.9373	Da
22	3	23	0.4512	0.3083	Da
23	23	24	0.8980	0.7091	Ne
24	24	25	0.8960	0.7011	Ne
25	6	26	0.2030	0.1034	Ne
26	26	27	0.2842	0.1447	Da
27	27	28	1.0590	0.9337	Ne
28	28	29	0.8042	0.7006	Da
29	29	30	0.5075	0.2585	Da
30	30	31	0.9744	0.9630	Ne
31	31	32	0.3105	0.3619	Da
32	32	33	0.3410	0.5302	Ne
33	21	8	2.0000	2.0000	Da
34	9	15	2.0000	2.0000	Da
35	12	22	2.0000	2.0000	Da
36	18	33	0.5000	0.5000	Da
37	25	29	0.5000	0.5000	Da