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

Marina Dubravac

OPTIMIZACIJSKI MODEL I METODA VREDNOVANJA RAZLIČITIH MEHANIZAMA UPRAVLJANJA ZA PLANIRANJE POGONA NISKONAPONSKE AKTIVNE DISTRIBUCIJSKE MREŽE

Doktorski rad

Osijek, 2025.

Doktorski rad izrađena je na:

Zavodu za elektroenergetiku,

Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek,

Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Mentor: prof. dr. sc. Danijel Topić

Doktorski rad ima XY stranica

Doktorski rad broj: XY

Sadržaj

Stranica

1. Uvod 1

1.1. Temeljni cilj istraživanja 3

1.2. Hipoteza istraživanja 4

1.3. Plan izrade doktorskog rada 5

1.4. Metode istraživanja 6

1.5. Organizacija i struktura doktorskog rada 6

2. Pregled istraživanja u području planiranja pogona aktivne distribucijske mreže 9

2.1. Aktivni kupac 9

2.2. Mogućnosti sudjelovanja aktivnih kupaca u optimizaciji pogona distribucijske mreže 10

2.2.1. Metode lokalnog upravljanja pomoću izmjenjivača fotonaponske elektrane. 11

2.2.2. Volt-var optimizacijske metode 12

2.2.3. Mogućnosti upravljivih potrošača za optimizaciju pogona distribucijske mreže 14

2.2.4. Mogućnosti sustava za pohranu električne energije za optimizaciju pogona distribucijske mreže. 14

2.3. Optimalni tokovi snaga u distribucijskim mrežama 15

2.3.1. Funkcije cilja, varijable i ograničenja 15

2.3.2. Formulacije i metode rješavanja 17

2.3.3. Aproksimacije tokova snaga u distribucijskim mrežama 19

2.4. Planiranje pogona distribucijskih mreža 19

2.4.1. Višestupanjski optimizacijski modeli za planiranje pogona distribucijske mreže 23

2.4.2. Modeli koji uzimaju u obzir naponsku nesimetriju 25
3. Tehnički kriteriji za planiranje pogona aktivne distribucijske mreže 28
3.1. Dopuštene vrijednosti strujno-naponskih prilika u distribucijskoj mreži 28
3.2. Nesimetrija napona 31
4. Optimizacijski okvir za modeliranje planiranja pogona niskonaponske aktivne distribucijske mreže 33
4.1. Strategija istraživanja 33
4.2. Optimizacijski okviri sustava za planiranje pogona aktivne distribucijske mreže 36
4.3. Teorija optimizacije 38
4.3.1. Mješovito cjelobrojno nelinearno programiranje 40
4.3.2. Optimalni tokovi snaga 40
4.4. Optimizacijska metoda i alat primijenjen za modeliranje distribucijske mreže 42
4.4.1. Optimizacija rojem čestica 43
4.4.2. *PyGMO* paket s ugrađenim metodama računalne inteligencije . . 45
4.4.3. Alat primjenjen za modeliranje i analizu distribucijske mreže . . 46
4.4.4. Modeli upotrebljenih elemenata distribucijske mreže u *OpenDSS-u* 47
5. Optimizacijski problemi modela za planiranje pogona niskonaponske aktivne distribucijske mreže 51
5.1. Optimizacijski problem dvostupanjskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže 51
5.1.1. Varijable upravljanja dvostupanjskog optimizacijskog modela za planiranje pogona aktivne distribucijske mreže 52
5.1.2. Ograničenja dvostupanjskog optimizacijskog modela za planiranje pogona aktivne distribucijske mreže 54
5.1.3. Funkcije cilja dvostupanjskog optimizacijskog modela za planiranje pogona aktivne distribucijske mreže 56

5.2. Optimizacijski problem kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže 58
5.2.1. Varijable upravljanja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže 59
5.2.2. Ograničenja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže 63
5.2.3. Funkcije cilja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže 65
5.3. Ispitivanje učinaka mehanizama upravljanja na funkcije cilja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže. 66
6. Vrednovanje razvijenih optimizacijskih modela za planiranje pogona niskonaponske aktivne distribucijske mreže 68
6.1. Postavke optimizacijskog okvira i optimizacijske metode dvostupanjskog modela 68
6.1.1. Model testnog distribucijskog izvoda 70
6.1.2. Opis simulacijskih slučajeva 72
6.2. Rezultati dvostupanjskog modela za planiranje pogona aktivne distribucijske mreže. 73
6.3. Metoda za vrednovanje učinaka mehanizma upravljanja na funkcije cilja kosimulacijskog modela 81
6.3.1. Model distribucijskog izvoda temeljen na javno dostupnim i stvarnim podacima 82
6.3.2. Opis provedenih simulacijskih slučajeva 82
6.4. Rezultati ispitivanja učinaka mehanizama upravljanja na funkcije cilja minimizaciju djelatnih gubitaka, minimizaciju devijacije napona i minimizaciju faktora naponske nesimetrije kosimulacijskog modela 85
7. Zaključak. 120
Literatura. 124
Popis slika 144
Popis tablica 147

Prilozi **148**
Sažetak **157**
Abstract **159**
Životopis **161**

1. Uvod

Od početka uporabe električne energije do danas električna energija predstavlja ključni faktor u razvoju društva, omogućujući napredak u industriji, tehnologiji i svakodnevnom životu. Njezina mogućnost pretvorbe, dostupnost i pouzdanost ključni su za funkcioniranje svih sustava, od proizvodnje i transporta do komunikacija i zdravstvene skrbi. Usprkos globalnim nastojanjima da se koncept energetske učinkovitosti ukorjeni u sve sfere života, potražnja za električnom energijom iz godine u godinu prati rastući trend. Prema izvještaju Međunarodne energetske agencija [1] potrošnja električne energije u 2024. godini porasla je za 4.30 % što je gotovo dvostruko više od prosječnog godišnjeg rasta potrošnje prošlog desetljeća. Očekuje se da će globalna potražnja za električnom energijom rasti po prosječnoj godišnjoj stopi od 3.90 % u sljedeće tri godine. Kako bi se pokrio porast potrošnje električne energije, instaliraju se dodatni proizvodni kapaciteti prvenstveno u obliku obnovljivih izvora energije. Prema posljednjem izvještaju [2] udio proizvodnje iz obnovljivih izvora energije činila je 46 % ukupne proizvodnje električne energije u 2024. godini. Kao jedna od najbrže rastućih tehnologija obnovljivih izvora energije su fotonaponske elektrane koje čine gotovo 42 % svih tehnologija obnovljivih izvora energije.

Zbog klimatskih promjena globalno je prepoznat problem potražnje i visokih investicijskih troškova elektrana na obnovljive izvore energije. Kao odgovor na to došlo je do uvođenja sustava poticaja za njihovu izgradnju, pri čemu je osigurana prihvatljiva cijena. S obzirom na to da je značajan udio obnovljivih izvora smješten unutar distribucijske mreže, ti se izvori nazivaju distribuirani izvori. Smještanjem izvora na potrošačkoj strani mijenja se paradigma tradicionalnog elektroenergetskog sustava koji je temeljen na centraliziranoj proizvodnji od elektrana prema potrošačima. Takve mreže nazivaju se pasivnim mrežama. Osim distribuiranih izvora u distribucijskoj mreži javlja se i koncepti upravljivih potrošača i sustava za pohranu energije koji se često nazivaju aktivnim kupcima i prestavljaju ključne resurse u tranziciji iz pasivne u aktivnu mrežu. Elekrane na obnovljive izvore energije na mjestu potrošnje u distribucijskoj mreži mogu imati pozitivne učinke na distribucijsku mrežu

u uvjetima velike potrošnje poput smanjenja opterećenja elemenata mreže, poboljšanja naponskih prilika i smanjenja gubitaka u mreži. Međutim, u uvjetima niske potrošnje mogu izazvati probleme u mreži poput previsokih napona, povećanog opterećenja elemenata mreže, povećanja gubitaka u mreži, smanjene učinkovitosti zaštitnih uređaja i povećanja struja kratkih spojeva. Osim toga mogu imati i utjecaja na kvalitetu električne energije povećanjem naponske nesimetrije posebice u niskonaponskim mrežama. Stohastička priroda obnovljivih izvora energije može narušiti dinamičku stabilnost sustava i onemogućiti upravljanje djelatnom i jalovom snagom u mreži. Osim distribuiranih izvora negativne utjecaje na mrežu mogu imati i upravljivi potrošači poput električnog vozila koji svojim stohastičkim obrascem punjenja vozila mogu dodatno narušiti pogon mreže i zbog povećanja potrošnje energije uzrokovati preniske napone i povećano opterećenje mreže.

Kao odgovor na moguće probleme i izazove koji se pojavljuju u aktivnoj distribucijskoj mreži, ali i kao ključni pojam u znanstvenoj literaturi koja se bavi aktivnim distribucijskim mrežama, uvodi se koncept napredne ili pametne mreže (*engl. smart grid*). Ovaj koncept temelji se na informacijsko - komunikacijskim tehnologijama u kojima se postojećoj energetskoj infrastrukturi dodaje i komunikacijska infrastruktura. Pomoću tog koncepta omogućuje se učinkovitiji odgovor na zahtjeve potražnje, ali isto tako omogućava dodatne usluge fleksibilnosti koje postaju ključan resurs prilikom planiranja pogona aktivne distribucijske mreže.

U mreži je sve više aktivnih kupaca koji posjeduju pametne invertere koji im omogućavaju pružanje usluga operatoru upravljanjem djelatnom i jalovom snagom. Dosadašnji mehanizmi upravljanja u pasivnim distribucijskim mrežama ograničeni su na promjenu preklopke transformatora, postavljanje kondenzatorske baterije i rekonfiguraciju mrežu. Takvi mehanizmi pokazali su se nedovoljno učinkovitima u aktivnim distribucijskim mrežama, ali u kombinaciji s uslugama koje mogu pružiti aktivni kupci imaju važnu ulogu u procesu planiranja pogona mreže. S obzirom na sve veću integraciju aktivnih kupaca u distribucijskoj mreži, mogućnosti aktivnih kupaca za sudjelovanje u pogonu distribucijske mreže postaje privlačna tema velikom broju istraživača i znanstvenika što se očituje velikim brojem znanstvenih publikacija. U užem smislu razvija se velik broj optimizacijskih modela za planiranje i pogon aktivnih distribucijskih mreža. Do pojave aktivnih kupaca i njihove sve većeg integracije u distribucijskoj mreži, optimalno planiranje pogona distribucijskih mreža u takvom obliku bilo je malo ili gotovo nikako razvijeno. Optimalno planiranje pogona aktivne distribucijske mreže ima za cilj primjenu u sustavima za upravljanje pogonom u budućnosti.

Pogon aktivne distribucijske mreže može se planirati i sagledati s više aspekata: tehničkog, ekonomskog i ekološkog. Sva tri aspekta predstavljaju opsežnu i međusobno povezanu cjelinu koju je potrebno uskladiti kako bi se postigao optimalan rad mreže. S obzirom na kompleksnost područja, ovaj doktorski rad bavi se tehničkim aspektom. Kao što je ranije navedeno, pri planiranju se nastoji svesti na minimum moguće probleme u pogonu koje mogu uzrokovati aktivni kupci, kako bi mreža ostala otporna na takve smetnje. Razvojem računalnih sustava visokih performansi te naprednih optimizacijskih metoda omogućen je razvoj realnijih modela distribucijske mreže, kako bi se dobilo najbolje rješenje za upravljanje pogonom distribucijske mreže.

Istraživanje u sklopu ovoga doktorskog rada usmjereno je na razvoj optimizacijskog modela koji integrira različite mehanizme upravljanja s ciljem poboljšanja tehničkih uvjeta i kvalitete električne energije u niskonaponskoj distribucijskoj mreži. Cilj je razvijenih modela analizirati doprinos dostupnih mehanizama upravljanja ostvarenju ključnih ciljeva operatora distribucijske mreže, s naglaskom na gubitke djelatne snage, devijaciju napona i naponsku nesimetriju. Temeljen opsežnim pregledom znanstvene literature u poglavlju 2, definiran je optimizacijski okvir ovoga doktorskog rada koji je detaljno opisan u poglavlju 4.

1.1. Temeljni cilj istraživanja

Međunarodna znanstvena zajednica prepoznala je probleme koji nastaju velikom integracijom aktivnih kupaca u distribucijskoj mreži. Stoga je došlo i do prepoznavanja potreba i ulaganja napora u razvoj sustava upravljanja pogonom distribucijske mreže. Temeljni je cilj istraživanja razvoj sustava za planiranje optimalnog pogona distribucijske mreže s velikom integracijom aktivnih kupaca koji posjeduju fotonaponske elektrane i upravljive potrošače kao što su primjerice električna vozila. Prilikom modeliranja sustava za optimalan pogon niskonaponske distribucijske mreže potrebno je osim realnih parametara mreže, uzeti u obzir realne profile proizvodnje iz fotonaponskih elektrana, profile punjenja električnih vozila kao i profile potrošnje. Izmjenjivači fotonaponskih elektrana imaju mogućnost upravljanja izlaznom djelatnom i jalovom snagom. Također, upravljivi potrošači poput električnih vozila imaju mogućnost upravljanja snagom punjenja. Kako bi se osiguralo optimalano planiranje pogona niskonaponske distribucijske mreže, potrebno je uključiti mogućnosti aktivnih kupaca, a optimalni tokovi snaga (*engl. Optimal power flows*, OPF) predstavljaju jedan od alata. Matematički opis optimalnih tokova snage u niskonaponskoj distribucijskoj mreži

predstavlja problem mješovitog cjelobrojnog nelinearnog programiranja (*engl. Mixed integer nonlinear programming*, MINLP), stoga se u ovom istraživanju predlaže dvostupanjski model temeljen na OPF-u modeliran kao MINLP. Kako bi se poboljšale naponske prilike i smanjili gubici koriste se tradicionalni mehanizam upravljanja kao što je promjena preklopke transformatora i mogućnosti upravljanja izlaznom snagom izmjenjivača fotonaponskih elektrana. Formulacija OPF-a predstavlja nelinearan i nekonveksan problem definirajući ga pri tome kao problem nedeterminističkog polinomnog vremena (*engl. NP-hard*) čije je ostvarivo rješenje gotovo nemoguće dobiti klasičnom analitičkom metodom. Zato autori koji ih primjenjuju često transformiraju originalni problem kako bi se smanjio stupanj konveksnosti i nelinearnosti. Shodno tome, ovim istraživanjem nastoji se unaprijediti model za optimalno planiranje pogona distribucijske mreže koristeći pri tome potpunim modelom OPF-a bez transformacija u obliku kosimulacijskog pristupa. Takva optimizacija naziva se optimizacija crne kutije (*engl. black-box*) u kojoj su poznati samo ulazni i izlazni parametri. Nadalje, predlaže se optimizacijski model za planiranje pogona niskonaponske mreže s različitim funkcijama cilja u kojima se uzimaju u obzir dodatni zahtjevi. Osim fotonaponskih elektrana, model sadrži i električna vozila s mogućnošću upravljanja obrascem punjenja. S ciljem dobivanja kvalitetnih rezultata problem je modeliran koristeći kosimulacijski pristup u kojem se povezuju metode računalne inteligencije s programskim alatom za proračun tokova snage te modeliranja i rješavanja OPF-a. Kosimulacijski pristup realiziran je u *Python* programskom jeziku pomoću kojeg *OpenDSS* programski alat za analizu mreže i *PyGMO* paket komuniciraju preko sučelja. Naposljetku, razvijen je model za ispitivanje međudjelovanje različitih funkcija cilja: minimizacije djelatnih gubitaka, minimizacije naponskog odstupanja i minimizacije naponske nesimetrije uzimajući pri tome različite mehanizme upravljanja koji se stavljaju na raspolaganje operatoru distribucijskog sustava.

1.2. Hipoteza istraživanja

Sve većom razinom integracije elektrana na obnovljive izvore energije i upravljivih potrošača poput električnog vozila javljaju se problemi prilikom planiranja pogona niskonaponske distribucijske mreže. Budući da su tradicionalne mreže ograničene na upravljanje isključivo pomoću promjene preklopke transformatora, javlja se potreba za novim načinima upravljanja koji će omogućiti veću integraciju aktivnih kupaca, a da se pritom ispoštuju ograničenja mreže uz što manje ulaganja u dodatnu opremu. Aktivni kupci u svojoj konfi-

guraciji mogu imati izmjenjivač koji svojim načinima rada ima mogućnost pružanja usluga operatoru mreže. Stoga se postavlja pitanje kako optimizirati pogon distribucijske mreže koristeći se pri tome tradicionalnim načinima upravljanja u kombinaciji s mogućnostima koje pružaju aktivni kupci bez dodatnih ulaganja u distribucijsku mrežu. Korištenjem OPF-a kao jednog od načina rješavanja optimizacijskog problema, javlja se i problem detaljnog matematičkog modeliranja problema i davanja dovoljno točnog rješenja. Većina autora pri tome koristi se načinima transformacije i relaksacije kompleksnosti originalnog problema te se pri tome gubi na točnosti modeliranja pa i samog dobivanja optimalnog rješenja. Kako bi problem ostao u originalnoj formulaciji, ovim radom predlaže se kosimulacijski pristup. Također, važno je ispitati utjecaj različitih funkcija cilja na iznose varijabli u mreži uzimajući u obzir različite upravljačke mehanizme.

1.3. Plan izrade doktorskog rada

Istraživanje u sklopu izrade doktorskog rada bilo je planirano u sljedećim koracima:

- istraživanje relevantne znanstvene literature u kojoj se obrađuju mogući načini upravljanja pogonom distribucijske mreže s velikom integracijom aktivnih kupaca sa stajališta operatora distribucijskog sustava te u kojima su naglašeni ključni izazovi koji se stavljaju pred operatora
- istraživanje relevantne znanstvene literature koja se bavi matematičkim modeliranjem optimizacijskog problema povezanog s pogonom aktivne distribucijske mreže i metodama rješavanja takvoga problema
- istraživanje znanstvene literature u kojoj su postavljeni glavni ciljevi koje operator mora postići uz uvjet zadovoljavanja postavljenih normi i uvjeta pogona
- izložiti rješenje problema upravljanja pogonom aktivne distribucijske mreže uz pomoć novih načina upravljanja pri tome koristeći mogućnosti aktivnih kupaca
- izložiti rješenje za problem matematičkog modeliranja optimizacijskog problema
- izložiti rješenje za postizanje temeljnih ciljeva upravljanja pogonom u distribucijskoj mreži na temelju kojih se operatoru daje na izbor kojom se metodom upravljanja koristiti s obzirom na postavljene zahtjeve pogona

- napisati programski kod optimizacijskog modela zasnovanog na optimalnim tokovima snage za upravljanje pogonom aktivne distribucijske mreže temeljem na kosimulacijskom pristupu rješavanja koristeći pri tome parametre mreže te stvarne profile opterećenja i proizvodnje te mogućnosti aktivnih kupaca za pružanje usluga operatoru kao upravljačke varijable
- analizirati kvalitetu optimizacijskog modela pri različitim zahtjevima i ciljevima koji se postavljaju pred operatora distribucijske mreže te na temelju toga vrednovati predloženi optimizacijski model.

1.4. Metode istraživanja

Metodologija istraživanja u okviru istraživanja ovoga doktorskog rada je sljedeća:

- definiranje problema optimizacijskog modela za planiranje pogona aktivne niskonaponske distribucijske mreže uzimajući u obzir mogućnosti upravljanja koje nude aktivni kupci
- definiranje problema razvoja optimizacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže uzimajući u obzir dodatne zahtjeve za pogon
- razvoj predloženog optimizacijskog modela temeljenog na konceptu optimalnih tokova snage deterministčkim pristupom mješovitog cjelobrojnog nelinearnog programiranja i primjenom kosimulacijskog pristupa rješavanja kodiranog u *Python* programskom jeziku, *OpenDSS-u* kao programskom paketu za analizu distribucijske mreže i *PyGMO* paketu koji sadrži metode računalne inteligencije za rješavanje složenih optimizacijskih problema
- razvoj metode za vrednovanje međudjelovanja različitih funkcija cilja i mehanizama upravljanja u *Python* programskom jeziku
- analiza predstavljenog optimizacijskog modela pri različitim zahtjevima i ciljevima koji se postavljaju pred operatora distribucijske mreže.

1.5. Organizacija i struktura doktorskog rada

Doktorski rad podijeljen je u 7 poglavlja:

1. poglavlje daje uvod u koncept aktivne distribucijske mreže s naglaskom na probleme i izazove koji se javljaju prilikom planiranja i pogona iste.

2. poglavlje definira pojam aktivnog kupca i opisuje mogućnosti različitih konfiguracija aktivnog kupca za sudjelovanje u optimizaciji pogona distribucijske mreže. U nastavku je izvršen detaljan pregled literature u području optimalnih tokova snaga i njihove primjene na distribucijskoj mreži. Pregled optimalnih tokova snaga podijeljen je na tri potpoglavlja s obzirom na: 1. funkcije cilja, 2. varijable i ograničenja, formulacije i metode rješavanja te 3. aproksimacija tokova snaga u distribucijskim mrežama. Na kraju poglavlja prikazan je pregled literature koja uključuje višestupanjske optimizacijske modele za planiranje pogona distribucijske mreže i modela koji uzimaju u obzir naponsku nesimetriju.

3. poglavlje opisuje tehničke kriterije i definirana pravila i norme koje se moraju uzeti u obzir prilikom planiranja pogona aktivne distribucijske mreže, a koje je propisao operator distribucijske mreže. Ti kriteriji uključuju dozvoljene vrijednosti strujno-naponskih prilika u distribucijskoj mreži. Također, definiran je faktor naponske nesimetrije kao jedan od pokazatelja kvalitete električne energije koji može biti povezan s problemima koji se javljaju prilikom planiranja pogona aktivne distribucijske mreže.

4. poglavlje predstavlja područje i strategiju istraživanja doktorskog rada, upotrebljen optimizacijski okvir kao i optimizacijske metode primijenjene u optimizacijskim problemima pojedinih modela za planiranje pogona aktivne distribucijske mreže.

5. poglavlje predstavlja središnje poglavlje doktorskoga rada u kojem su detaljno opisani optimizacijski problemi pojedinih modela. Opisan je dvostupanjski model za planiranje pogona aktivne distribucijske mreže s pripadajućim funkcijama cilja, ograničenjima varijabli upravljanja (odluke) i dodatnim mrežnim ograničenjima. Opisan je i kosimulacijski optimizacijski model s pripadajućim funkcijama cilja, ograničenjima i varijablama upravljanja u kojem je u model uključena i naponska nesimetrija i dan je matematički opis predložene metode za vrednovanje učinaka različitih mehanizama upravljanja na funkcije cilja kosimulacijskog modela.

6. poglavlje nastavno na 5. poglavlje na početku definira postavke predloženih optimizacijskih okvira i optimizacijskih metoda. U prvom dijelu opisani su ulazni podaci i ispitivani scenariji višestupanjskog modela za planiranje pogona aktivne distribucijske mreže. Nakon toga prikazani su i analizirani rezultati dobiveni na temelju ispitanih slučajeva. U drugom dijelu opisani su ulazni podaci i postavke varijabli upravljanja (mehanizama upravljanja)

kosimulacijskog modela koji uključuje tri funkcije cilja. Nakon toga predstavljeni su ispitani simulacijski slučajevi. U zadnjem dijelu prikazani su analitički i grafički rezultati.

7. poglavlje donosi sveobuhvatan zaključak doktorskog rada dobiven na temelju provedenoga istraživanja s naglašenim smjerom daljnjeg istraživanja.

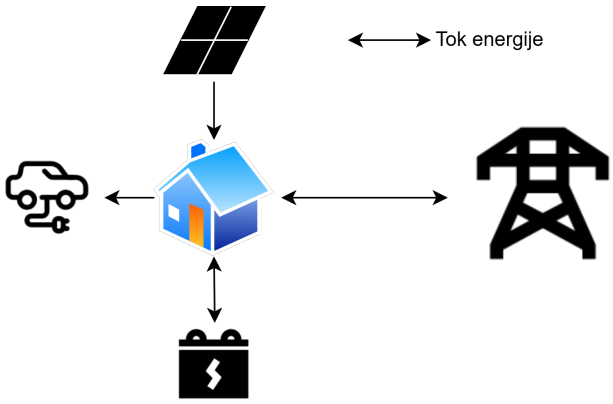
2. Pregled istraživanja u području planiranja pogona aktivne distribucijske mreže

2.1. Aktivni kupac

Izraz aktivni kupac (*engl. prosumer*) prvi je put spomenut 1980. godine u knjizi A. Tofflera Treći val (*engl. The Third Wave*) [3]. U knjizi je opisana tranzicija društvenog poretka iz industrijskog u informatičko doba. Industrijsko doba obilježile su masovna proizvodnja, distribucija i potrošnja robe i dobara, došlo je do društvenog napretka, dostupnijeg obrazovanja, masovnog naoružavanja i slično. U informatičkom je dobu definirano društvo koje ima mogućnost udaljenog rada iz kojeg proizlazi izraz *prosumer* nastao kombinacijom riječi za proizvođača (*engl. producer*) i potrošača (*engl. consumer*). Ubrzo se se izraz aktivni kupac počeo primjenjivati i u drugim sferama djelovanja. Integracijom obnovljivih izvora energije na mjestu potrošača i posjedovanjem upravljivih potrošačkih uređaja ili sustava za pohranu električne energije započela je njegova primjena u elektroenergetici [4]. Shodno tomu, različiti radovi predlažu definicije aktivnog kupca. Prema [5–7] aktivni je kupac krajnji korisnik koji koristi i proizvodi električnu energiju i s viškom energije napaja mrežu i druge krajnje korisnike. U [8] aktivni kupac je ili proizvođač ili potrošač električne energije ovisno o njegovim zahtjevima za električnom energijom i cijeni električne energije. U prethodnim definicijama autori su u fokus stavili krajnje korisnike koji posjeduju izvor električne energije. Međutim, [9, 10] osim izvora električne energije uključuju i sustav za pohranu energije u definiciju aktivnog kupca. Ta je definicija proširena u [11, 12] i uključuje krajnje korisnike s mogućnošću proizvodnje električne energije i koji u svojoj konfiguraciji mogu sadržavati sustav upravljanja energijom u kućanstvu (*engl. Home energy management system, HEMS*), sustav za pohranu električne energije, električno vozilo ili sustav od vozila do mreže (*engl. vehicle-to-grid*, V2G). U [13] aktivni kupac definiran je kao potrošač ili proizvođač električne energije koji pruža usluge fleksibilnosti.

Definicija aktivnog kupca dana je u Direktivi Europskog parlamenta i Vijeća Europe o zajedničkim pravilima za unutarnje tržište električne energije [14] i vrijedi u svim članicama Europske unije pa tako i u Republici Hrvatskoj. Prema [15] aktivni kupac je „krajnji kupac, ili skupina krajnjih kupaca koji djeluju zajedno, koji troši ili skladišti električnu energiju proizvedenu u vlastitom prostoru smještenom unutar definiranih granica ili koji prodaje električnu energiju koju sam proizvodi ili sudjeluje u pružanju fleksibilnosti ili u programima energetske učinkovitosti, uz uvjet da te djelatnosti nisu njegova primarna trgovačka ili profesionalna djelatnost."

Slika 2.1 prikazuje konfiguraciju aktivnog kupca primijenjenog u ovom radu. Fotonaponske elektrane najzastupljeniji su tip distribuiranog izvora priključenog na distribucijsku mrežu [16]. Električna vozila, V2G, HEMS i drugi fleksibilni potrošači predstavljaju upravljive potrošače (*engl. demand-side management*, DSM).



Slika 2.1: *Konfiguracija aktivnog kupca*

2.2. Mogućnosti sudjelovanja aktivnih kupaca u optimizaciji pogona distribucijske mreže

Aktivni su kupci preko komponenata energetske elektronike povezani s distribucijskom mrežom te zbog toga imaju mogućnost pružanja fleksibilnih usluga operatoru distribucijske mreže. U ovom poglavlju prikazan je pregled različitih konfiguracija aktivnih kupaca i njihovih mogućnosti sudjelovanja u optimizaciji pogona distribucijske mreže. Naglasak je stavljen na one mogućnosti koje se koriste za poboljšanje naponskih prilika, smanjenje gubitaka i naponske nesimetrije.

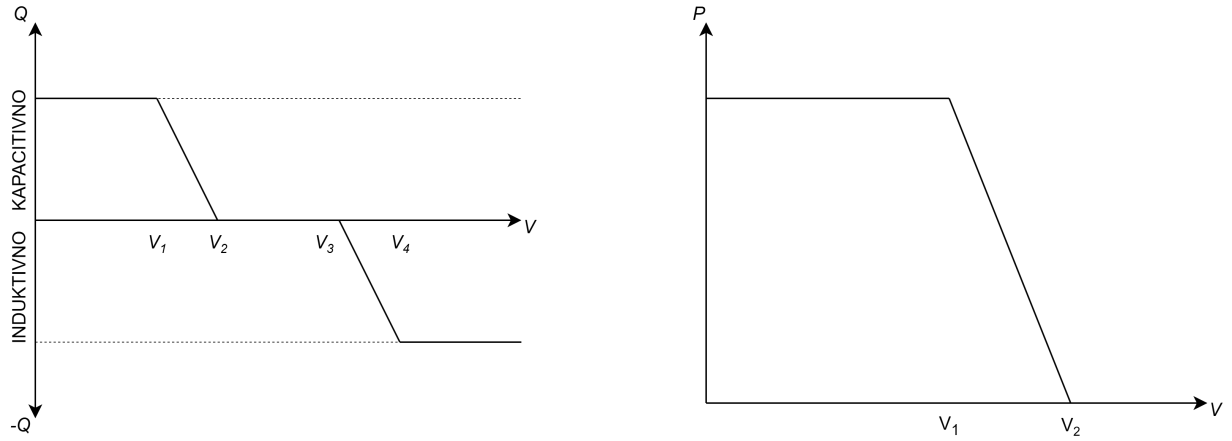
2.2.1. Metode lokalnog upravljanja pomoću izmjenjivača fotonaponske elektrane

Metode lokalnog upravljanja upotrebljavaju veličine dobivene mjerenjem kako bi napon održao unutar dozvoljenih granica [17, 18]. Autori u literaturi [19] podijelili su mogućnosti izmjenjivača fotonaponske elektrane na upravljanje naponskim prilikama promjenom jalove snage (*engl. reactive power control*, RPC) i upravljanje naponskim prilikama promjenom djelatne snage (volt-watt upravljanje ili *engl. active power curtailment*, APC). U kontekstu analize mreža kao bitan faktor spomnji se omjer R/X koji predstavlja omjer ukupnog otpora i ukupne reaktancije mreže. Različite naponske razine imaju različit iznos tog omjera. U prijenosnoj mreži reaktancija dominira u odnosu na otpor, u srednjenaponskoj distribucijskoj mreži otpor i reaktancija su podjednakog iznosa, dok u niskonaponskoj distribucijsoj mreži otpor dominira u odnosu na reaktanciju. Zbog tog omjera R/X niskonaponske distribucijske mreže APC predstavlja učinkovitiji način opravljanja od RPC-a [20]. Prema [19] upravljanje naponskim prilikama promjenom jalove snage može se podijeliti:

- na upravljanje konstantnim faktorom snage
- na volt-var upravljanje
- na watt-var upravljanje
- na upravljanje konstantnom jalovom snagom.

Operator distribucijske mreže definira raspon faktora snage koji fotonaponska elektrana može održavati prilikom rada i priključenja na distribucijsku mrežu. Kod volt-var upravljanja upravlja se izlaznom jalovom snagom kao funkcijom napona prateći pri tome krivulju napon-jalova snaga prikazanu na Slici 2.2a. Kada napon padne ispod određene granice (V_2), tada se izmjenjivač ponaša kao naduzbuđeni generator i daje jalovu snagu u mrežu. Kada napon prijeđe iznad određene granice (V_3), izmjenjivač se ponaša kao poduzbuđeni generator i uzima jalovu snagu iz mreže. Prilikom volt-watt upravljanja izmjenjivač fotonaponske elektrane aktivno upravlja jalovom snagom kao funkcijom djelatne snage prateći pri tome krivulju djelatna-jalova snaga bez kašnjenja u odzivu. Kod volt-watt upravljanja (Slika 2.2b) izmjenjivač fotonaponske elektrane isporučuje u mrežu trenutnu djelatnu snagu sve dok se napon održava unutar zadanih granica. Ako napon prijeđe definiranu granicu, djelatna snaga se smanjuje [21]. Izmjenjivač fotonaponske elektrane može održavati konstantnu jalovu snagu koju je definirao operator. Autori u literaturi [22] osim klasične podjele način

upravljanja definiraju i mogućnost izmjenjivača fotonaponske elektrane za upravljanje naponskom nesimetrijom. Prema literaturi [23] izmjenjivač fotonaponske elektrane može raditi kao statički sinkroni kompenzator kada nema proizvodnje i osigurati jalovu snagu sustavu.



(a) *Volt-var metoda upravljanja* **(b)** *Volt-watt metoda upravljanja*

Slika 2.2: *Metode lokalnog upravljanja.*

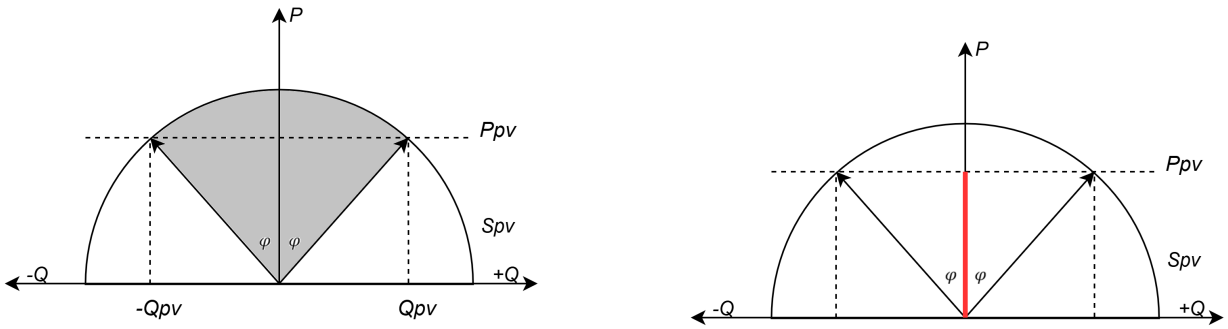
S jedne strane, metode lokalnog upravljanja ne zahtijevaju razvijenu komunikacijsku mrežu i zbog toga predstavljaju jednostavan i jeftin način upravljanja. S druge strane, takve metode ne uključuju upravljanje čitavom mrežom već isključivo na pripadajućem čvoru, one su pogodne samo za upravljanje naponskim prilikama. Unatoč velikom broju istraživanja koja uključuju lokalnu koordinaciju različitih izmjenjivača za minimizaciju gubitaka, nije sigurno da će takav pristup omogućiti dobivanje optimalnog rješenja [17].

2.2.2. Volt-var optimizacijske metode

Prema [24] volt-var optimizacija općeniti je naziv za metode kojima se reguliraju naponske prilike i minimiziraju gubici u distribucijskoj mreži korištenjem volt-var upravljačkih komponenti poput transformatora s regulacijskom preklopkom, regulatora napona, kondenzatorske baterija i drugih volt-var komponenti koje su dostupne operatoru distribucijske mreže. Zbog izrazitog utjecaja na učinkovitost mreže volt-var optimizacija smatra se dijelom sustava za upravljanje distribucijskom mrežom. Kako bi se dodatno povećala, učinkovitost razvijaju se volt-var optimizacijske metode povezane s tehnologijama naprednih mreža i obuhvaćaju distribuirane izvore energije, električna vozila, sustave za pohranu energije i napredne sustave mjerenja. Volt-var optimizacijske metode predstavljaju integrirani proces upravljanja naponskim prilikama i jalovom snagom što rezultira srednjeročnom/dugoročnom

optmizacijom pogona mreže. Autori u literaturi [24–26] podijelili su volt-var optimizacijske metode na očuvanje smanjenja napona (*engl. conservation voltage reduction*) i var optimizaciju.

Mogućnosti fotonaponskog izmjenjivača za volt-var optimizaciju detaljno su obradili autori u literaturi [27–29]. Iznos jalove snage koju izmjenjivač fotonaponske elektrane ima na raspolaganju za sudjelovanje u optimizaciji ovisi o dozvoljenom faktoru snage, prividnoj i djelatnoj snazi izmjenjivača. Na Slici 2.3a sivom bojom označeno je područje rada izmjenjivača za upravljanje jalovom snagom. Detaljan matematički opis dan je u sljedećem poglavlju. Osim za volt-var optimizaciju izmjenjivač fotonaponske elektrane može sudjelovati u optimizaciji pogona upravljanjem djelatnom snagom čiji je opseg djelovanja prikazan crvenom linijom na Slici 2.3b. Autori u literaturi često primjenjuju takav oblik upravljanja [21,22,30–32]. APC se primjenjuje kod problema previsokih napona uzrokovanih velikom proizvodnjom iz fotonaponskih elektrana [33]. Međutim, konvencionalni APC može dovesti do neujednačenog smanjenja proizvodnje među vlasnicima fotonaponskih elektrana. Zbog radijalne topologije mreže potrošači udaljeniji od transformatorske stanice mogu se susresti s većim smanjenjem proizvodnje, što može rezultirati penalizacijom i nezadovoljstvom vlasnika elektrane. Zbog toga autori u literaturi često predlažu metode za poboljšanje pravednosti i zadovoljstva krajnjih korisnika [22,30–32,34,35].



(a) *RPC izmjenjivača fotonaponske elektrane*

(b) *APC izmjenjivača fotonaponske elektrane*

Slika 2.3: *Mogućnosti izmjenjivača fotonaponske elektrane za optimizaciju pogona distribucijske mreže*

2.2.3. Mogućnosti upravljivih potrošača za optimizaciju pogona distribucijske mreže

Predstavnik upravljivih potrošača je električno vozilo koje obrascem punjenja i V2G tehnologijom može pružiti fleksibilnost i sudjelovati u optimizaciji pogona distribucijske mreže [36]. Prema [37] prilikom optimizacije pogona koriste se različite strategije punjenja električih vozila kao varijabla upravljanja kako bi se postiglo optimalno pogonsko stanje mreže. Primjerice, strategija punjenja može uključiti minimizaciju troškova punjenja, a da se pri tome održi minimalno stanje napunjenosti baterije na kraju procesa punjenja uzimajući u obzir različita ograničenja mreže. Optimizacija u kojoj je strategija punjenja varijabla upravljanja može se promatrati za dan unaprijed unutardnevno tržište. Različitim strategijama punjenja i načinima priključivanja električnih vozila nastoji se postići simetriranje mreže, smanjivanje vršne proizvodnje/potrošnje da bi se poboljšala kvaliteta električne energije i smanjili gubici u mreži [38]. Osim toga autori u [24,39,40] predlažu korištenje mogućnosti jalove snage izmjenjivača za upravljanje naponskim prilikama u distribucijskoj mreži u sklopu V2G koncepta. Takav način upravljanja temeljen je na principu rada izmjenjivača fotonaponske elektrane.

2.2.4. Mogućnosti sustava za pohranu električne energije za optimizaciju pogona distribucijske mreže

Primjena mogućnosti sustava za pohranu energije najčešće se u literaturi spominje u kontekstu pružanja usluga uravnoteženja [41–44]. Mogućnosti sustava se pohranu energije često se kombiniraju s mogućnostima distribuiranih izvora poput vjetroagregata [45] i fotonaponskih elektrana [33,46–48]. Kako bi se maksimalno iskoristile mogućnosti sustava za pohranu energije, važno je prvo odrediti njihovu optimalnu veličinu i lokaciju u mreži [41, 49, 50]. Upravljanje punjenjem i praženjenjem sustava za pohranu energije osigurava se uravnoteženje proizvodnje i potrošnje i prilagođavaju se tokovi snaga u mreži te se tako smanjuju gubici djelatne snage [46,47,51]. Osim na smanjenje gubitaka djelatne snage upravljanje punjenjem i pražnjenjem može se utjecati na poboljšanje naponskih prilika i kvalitete električne energije, pouzdanost sustava i smanjenje zagušenja u distribucijskoj mreži [41,52]. Sustav za pohranu energijom može se koristiti za upravljanje izmjenom djelatne i jalove snage u čvoru kako bi se naponska nesimetrija održala unutar dozvoljenih granica [53]. Osim upravljanja punjenjem i pražnjenjem autori u literaturi [54] predlažu metodu lokalnog upravljanja jalovom snagom

izmjenjivača sustava za pohranu energijom za poboljšanje naponskih prilika. Autori u [55] koriste jalovu snagu pretvarača sustava za pohranu energije kao varijablu upravljanja za minimizaciju gubitaka u distribucijskoj mreži. Takav način upravljanja temeljen je na principu rada izmjenjivača fotonaponske elektrane prikazanog na Slici 2.3a.

2.3. Optimalni tokovi snaga u distribucijskim mrežama

Koncept optimalnih tokova snaga predložen je u ranim šezdesetim godinama 20. stoljeća [56] kao proširenje ekonomskog dispečiranja. OPF predstavlja općeniti pojam za probleme povezane s optimizacijom mreže. Može se definirati kao pronalaženje optimalnih postavki varijabli upravljanja uzimajući u obzir različita ograničenja [57–61]. Izvorno je koncept OPF-a modeliran za primjenu na prijenosnim mrežama na koje su povezane velike proizvodne jedinice. Osim temeljnih komponenata mreže OPF model može sadržavati i dodatne proizvodne jedinice i dodatne komponente za postizanje optimalnog rješenja. OPF se koristi u većini današnjih sustava za upravljanje energijom (*engl. energy management systems*, EMS) za upravljanje u stvarnom vremenu, planiranje pogona i planiranje mreže [62–65].

Prijenosne i distribucijske mreža imaju različitu topologiju, električne parametre, iznose tokova snaga i upravljačke uređaje. Distribucijske su mreže u odnosu na prijenosne mreže inherentno nesimetrične i složenije [66]. Nesimetrija se javlja zbog velikog broja jednofazno povezanih potrošača i zbog nejednakog prostora vodiča trofaznog segmenta [67,68]. Za razlike od distribucijskih mreža, prijenosne mreže imaju mali broj izravno povezanih potrošača. Kod prijenosnih mreža omjer R/X jer izrazito nizak, dok je kod distribucijskih mreža taj omjer izrazito visok. Jednostavan način upravljanja i dobro razvijena komunikacijska infrastruktura glavni su preduvjeti primjene OPF-a samo u prijenosnim mrežama. Sve većom integracijom distribuiranih izvora i fleksibilnih potrošača javlja se potreba za korištenjem OPF-a u optimizaciji distribucijskih mreža. Kako bi se iskoristio potencijal za pružanje fleksibilnosti različitih tipova aktivnih kupaca, OPF postaju neizbježan alat za optimizaciju [69]. Iako ne postoji službeni zapis o početku primjene OPF u distribucijskim mrežama, može se reći da je započelo s integracijom različitih tipova aktivnih kupaca [66].

2.3.1. Funkcije cilja, varijable i ograničenja

Općenito se OPF predstavlja kao minimiziranje funkcije cilja $F(\mathbf{x},\mathbf{u})$ uz poštivanje ograničenja jednakosti $g(\mathbf{x},\mathbf{u})$ i ograničenja nejednakosti $h(\mathbf{x},\mathbf{u})$. Ograničenja jednakosti predstavljaju

tokovi snage. Vektor **x** predstavlja kontinuirane varijable stanja koje uključuju ovisne varijable poput iznosa napona i kuta na sabirnicama i jalove snage generatora za upravljanje naponskim prilikama i fiksne parametre poput iznosa referentnog napona i iznosa parametara vodova. Vektor **u** predstavlja vektor varijabli upravljanja kojem pripadaju podskupovi varijabli stanja poput djelatne i jalove snage proizvodnih jedinica i postavke upravljačkih mehanizama poput promjene regulacijske preklopke transformatora. Varijable upravljanja mogu biti kontinuirane i diskretne [66, 70, 71].

Funkcije cilja OPF modela u distribucijskim mrežama mogu biti ekonomske, tehničke, ekološke i kombinirane. Formulacija OPF-a može biti s jednom ili više funkcija cilja. Ekonomske funkcije cilja odnose se na minimiziranje pogonskih troškova [22, 72], minimiziranje troškova smanjivanja djelatne snage (*engl. active power curtailment*, APC) [34, 73, 74] te minimiziranje kupljene energije [75]. Tehničke jednociljne funkcije u distribucijskim mrežama koje se pojavljuju u literaturi su: minimiziranje naponske devijacije [76–80], minimiziranje gubitaka djelatne snage [81, 82], minimiziranje faktora naponske nesimetrije [83, 84] i minimiziranje APC-a [85, 86]. Autori u literaturi često kombiniraju više ciljeva: minimiziranje naponske devijacije i gubitaka djelatne snage [87–92], minimiziranje gubitaka i APC [93, 94], minimiziranje gubitaka djelatne snage, APC i naponske devijacije [34, 95, 96], minimiziranje gubitaka djelatne snage, faktora naponske nesimetrije i naponske devijacije [52, 97, 98]. Osim prethodno spomenutih funkcija cilja, autori često uključuju i minimiziranje broja promjena regulacijske preklopke transformatora i kondenzatora [86, 88, 99–101], minimiziranje indeksa naponske stabilnosti [102], minimiziranje injekcija i apsorbcija jalove snage [103–105]. Nadalje, autori u radovima često kombiniraju tehničke i ekonomske funkcije cilja poput minimiziranja gubitaka, naponske devijacije i troškova APC-a i pogonskih troškova [72, 74, 75, 106]. Ekološke se funkcije cilja ne pojavljaju u radovima koji promatraju OPF u distribucijskoj mreži. Većina autora optimizacijski problem ne rješava kao višeciljni, već ga transformiraju u jednociljni zbrajanjem/oduzimanjem pojedinih funkcija pridijeljujući im pri tome težinske koeficijente [74, 88, 90, 93, 95, 96, 101, 103, 107].

U konvencionalnim distribucijski mrežama s jednosmjernim tokovima snage uglavnom se nastoje smanjiti gubici djelatne snage i poboljšati naponske prilike. Konvencionalni upravljački mehanizmi koji se koriste za minimiziranje gubitaka iscrpno su opisani u [108]. Autori su detaljno pregledali radove koji uključuju rekonfiguraciju mreže [109], postavljanje kondenzatorskih baterija [110] i alokaciju distribuiranih izvora u distribucijskom izvodu [111]. Ko-

nvencionalni upravljački mehanizmi za poboljšanje naponskih prilika uključuju poboljšanje izvoda distribucijske mreže zamjenom postojećih kabela novima [112], korištenje kondenzatorskih baterija [113] i transformatora s regulacijskom preklopkom [114]. Međutim, konvencionalni kontrolni mehanizmi imaju spori odziv i pokazali su se nedovoljno učinkovitim u aktivnim distribucijskim mrežama [115, 116]. Autori se sve češće okreću novim upravljačkim mehanizmima. Aktivni kupci u svojoj konfiguraciji sadrže izmjenjivač čijom se djelatnom i jalovom snagom može upravljati. U literaturi se upravljanje djelatnom snagom često naziva APC ili volt-watt upravljanje [22, 34, 85]. Pod upravljanjem djelatnom snagom smatra se i upravljanje punjenjem i pražnjenjem električnog vozila i sustava za pohranu energije [53, 73, 117–119]. Upravljanje jalovom snagom (*engl. reactive power control*, RPC) ili volt-var upravljanje može biti korištenjem izmjenjivača aktivnog kupca [74, 84, 98, 103, 105, 120–123] i/ili upravljanjem FACTS (*engl. flexible alternating current transmission system*) uređajima [79, 81, 91, 102]. Autori često kombiniraju APC i RPC izmjenjivača aktivnog kupca [94, 96, 104, 106, 124, 125]. Autori često kombiniraju konvencionalne i nove upravljačke mehanizme poput transformatora s regulacijskom preklopkom i kondenzatorskih baterija s APC i RPC [35, 81, 88, 95, 97, 99, 101, 126]. Postavke upravljačkih mehanizama predstavljaju varijable upravljanje u OPF modelu.

U primjeni OPF modela ograničenja jednakosti predstavljaju jednadžbe tokova snaga ili druga ograničenja koja osiguravaju ravnotežu. Konvencionalni tokovi snaga predstavlju numeričku analizu povezanih elektroenergetskih sustava u stacionarnom stanju [127] te predstavljaju nelinearan i nekonveksan problem. Detaljan matematički zapis tokova snaga naziva se AC tokovi snaga i matematički se zapisuju polarnim zapisom [70, 128]. Osim AC tokova snaga koriste se još dvije formulacije: razdvojeni AC tokovi snaga [67] i DC tokovi snaga [68]. U razdvojenim tokovima snaga djelatna snaga je formulirana kao funkcija kuta napona, a jalova snaga kao funkcija iznosa napona. DC tokovi snaga temeljeni su na sljedećim pretpostavkama: elementi matrice admitancije $\mathbf{Y}$ su čisto imaginarni i razlika između iznosa i kutova napona susjednih sabirnica je jako mala. Iznosi napona na sabirnicama su 1 p.u. Ograničenja nejednakosti se dijele na ograničenja varijabli upravljanja i ograničenja mreže [66, 70, 129].

2.3.2. Formulacije i metode rješavanja

Složenost OPF modela određena je načinom formulacije funkcije cilja i ograničenja. Funkcija cilja može biti modelirana kao polinom prvog stupnja odnosno kao linearna i kao neli-

nearna. Ako se koriste potpuni AC tokovi snaga, onda je problem nelinearan i nekonveksan i definiran kao *NP-hard* problem. Za takve je probleme globalno optimalno rješenje gotovo nemoguće dobiti klasičnom analitičkom metodom [130], stoga autori nastoje pojednostavniti formulaciju OPF-a kako bi bilo izvedivo dobiti globalni optimum. Prema [70], OPF se može formulirati:

- nelinearnim programiranjem (*engl. nonlinear programming*, NLP)
- linearnim programiranjem (*engl. linear programming*, LP)
- kvadratnim programiranjem (*engl. quadratic programming*, QP)
- mješovito cjelobrojno nelinearnim programiranjem (*engl. mixed integer nonlinear programming*, MINLP)
- mješovito cjelobrojno linearnim programiranjem (*engl. mixed integer linear programming*, MILP).

NLP formulacija uključuje nelinearne funkcije cilja i nelinearna ograničenja dok su sve diskretne varijable aproksimirane kao kontinuirane. Kod LP su i funkcije cilja i ograničenja linearna. Ograničenja jednakosti su DC tokovi snage. Zbog jednostavnosti modeliranja, robusnosti, brzine rješavanja i dobro razvijenih metoda rješavanja ovakva formulacija OPF-a našla je svoju primjenu u industriji [69]. Međutim, ovakva formulacija nije pogodna za formuliranje problema koji uključuju minimiziranje gubitaka zbog pretpostavki modela. QP predstavlja poseban oblik NLP-a s kvadratnom funkcijom cilja i linearnim ograničenjima. Uključivanje diskretnih varijabli u NLP formulaciju rezultira MINLP formulaciji. Takva formulacije predstavlja realan model fizičkog sustava, ali je istovremeno matematički kompleksan i teško izvediv za rješavanje. Stoga je teško pronaći kompromis (*engl. trade-off*) između realnog modela fizičkog sustava i traktabilnosti problema. MILP predstavlja linearizirani MINLP [70, 131].

Primjena metode rješavanja ovisi o načinu formuliranja OPF-a. Osnovna kategorizacija metoda rješavanja je podijeljena na analitičke metode i metode računalne inteligencije. Dobro razvijene metode za linearne OPF-modele su simplex metode [85], sekvencijalno linearno programiranja [76] i metoda unutarnje točke [90]. Analitičke metode koje se koriste za rješavanje nelinearnih OPF modela su gradijentne metode [132], sekvencijalno kvadratno programiranje [96], metoda unutarnje točke [80] i metoda izmjeničnog smjera množitelja koja

pripada skupini Langrangianovih metoda [22, 73, 90]. Analitičke metode zahtijevaju striktno matematičku formulaciju OPF problema kako bi problem mogao biti riješen te autori u radovima često lineariziraju i relaksiraju originalni problem. Metode računalne inteligencije mogu dati rješenje problema bez obzira na matematičku formulaciju. One uključuju umjetne neuronske mreže [133], genetske algoritme [103, 134], optimizaciju roja čestica [87, 133], optimizaciju sivog vuka [35], neizrazitu logiku [72], simulirano kaljenje i tabu pretraživanje.

2.3.3. Aproksimacije tokova snaga u distribucijskim mrežama

Kako je spomenuto u Potpoglavlju 2.3.2., potpuni AC tokovi snage predstavljaju nelinearan i nekonveksan problem i u prijenosnoj i u distribucijskoj mreži. Autori u literaturi nastoje transformirati problem kako bi dobivanje optimalnog rješenja bilo izvedivo. Na primjeru prijenosne mreže često se koriste DC tokovi snaga. Primjena takve aproksimacije na primjeru distribucijske mreže predstavlja problem [130, 135]. Otpor je reda veličine jednakog ili većeg reaktanciji te on ne može biti zanemariv. Zbog radijalne topologije padovi napona su značajni te iznosi ne mogu biti pretpostavljeni na 1 p.u. Na temelju tih pretpostavki DC tokovi snaga koji se primjenjuju u prijenosnoj mreži ne mogu biti primijenjeni na distribucijskoj mreži. Kako bi nekonveksan problem transformirali u konveksan, autori često primjenjuju metode relaksacije [130, 136]. Često upotrebljavane relaksacije u literaturi su programiranje stošca drugog reda (*engl. second order cone programming*, SOCP) za radijalne mreže i semidefinitno programiranje (*engl. semidefinite programming*, SDP) za opću primjenu [130]. Postoji dva modela za formuliranje tokova snaga u distribucijskoj mreži *branch flow model* i *bus injection model*. Rješenje proračuna tokova snaga oba modela je isto, ali se za modeliranje koriste različite varijable [135]. *Branch flow model* koristi se samo za modeliranje radijalnih mreža. Temeljen je na kvadratnim vrijednostima Ohmovog zakona i često se u literaturi naziva DistFlow model [137]. Linearizirani oblik DistFlow modela naziva se LinDistFlow [138]. *Bus injection model* je općeniti model za tokove snaga u elektroenergetskom sustavu temeljen na formulaciji neto snage svakog čvora i Kirchoffovim zakonima [139].

2.4. Planiranje pogona distribucijskih mreža

Distribucijske mreže su generalno dimenzionirane na temelju najgoreg mogućeg scenarija u smislu opterećenja, padova napona, zagušenja i određenih sigurnosnih ograničenja za danu

potrošnju konstruirajući dovoljno jaku mrežu. Zbog radijalne topologije, jednosmjernih tokova snaga i niske razine dinamičnosti u takvim mrežama konvencionalan način planiranja pogona fokusiran je na modeliranje robusnih i pouzdanih elemenata koji će u potpunosti zadovoljiti sva mrežna stanja bez značajnih ljudskih intervencija. Stoga je potrebna minimalna ili nikakva strategija vođenja [135, 140–142]. Takvo načelo naziva se *fit and forget* provodi se na deterministički način bez uzimanja u obzir stohastičnog ponašanja potrošača [143]. *Fit and forget* načelo se primijenjuje i prilikom integracije distribuiranih izvora uzimajući u obzir scenarij *maksimalna proizvodnja-minimalna potrošnja* što ograničava veću integraciju distribuiranih izvora i nekonvencionalnih potrošača [144]. Takav pristup s vremenom je postao neekonomičan i javlja se potreba za odgovarajućim alatima koji će se moći uskladiti s osnovnim zadaćama povezanim s tržištem, politikom transparentnositi i nediskriminacije kao i sa sigurnošću i kvalitetom napajanja u mrežama. Uz nadogradnju postojeće mreže potrebno je uključiti obje stane – mrežu i kupca. Metodologije planiranja, pristup, povezivanje i pogon nužno je revidirati i osigurati tehnički razvoj koji će podržati te procese [145]. Stoga se razvija sustav za upravljanje aktivnom distribucijskom mrežom (*engl. active distribution network management*, ADNM) koji uz pomoć naprednih mrežnih tehnologija upravlja pristupom uslugama fleksibilnosti aktivnih kupaca kako bi se postigla pouzdana, robusna, ekonomična i optimalna mreža. Autori u literaturi [146] definiraju ADNM kao centraliziranu software-sku platformu koja ima mogućnost primjene različitih optimizacijskih shema i integracije i upravljanja potrošačima, distribuiranim izvorima i drugim fleksibilnim uređajima u distribucijskoj mreži u fazi planiranja i u stvarnom vremenu. Sustavi za upravljanje u pasivnim i aktivnim mrežama s obzirom na planiranje i razvoj, pogon, razmjenu informacija i tehnički razvoj prikazani su i uspoređeni u Tablici 2.1 [145].

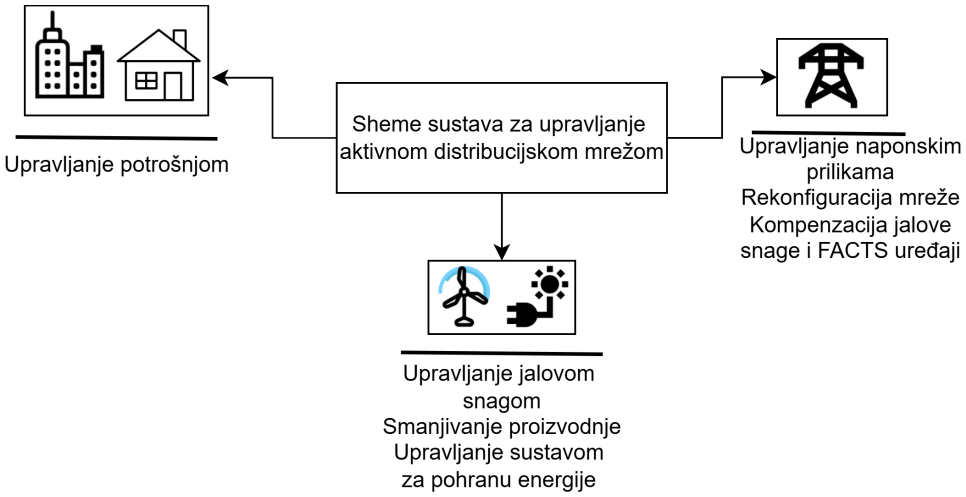
Tablica 2.1: *Sustavi za upravljanje u pasivnim i aktivnim mrežama s obzirom na različite aspekte promatranja*

Aspekti promatranja	**Upravljanje pasivnim distribucijskim mrežama**	**Upravljanje aktivnim distribucijskim mrežama**

Planiranje i razvoj mreže	*fit and forget* načelo svi aspekti riješeni u fazi planiranja	kombinacija planiranja i pogona: sustav upravljanja za povećanje kapaciteta mreže i upravljanje gubicima i interakcija s tržišnim sudionicima, prodaja usluga fleksibilnosti
Pogon mreže	konvencionalni načini upravljanja (koriste se vrlo rijetko) nema nadzora i mogućnosti upravljanja aktivnim kupcima nedostatak pravila za veću integraciju aktivnih kupaca i mogućnosti korištenja njihovih usluga	kombinacija konvencionalnih i novih upravljačkih mehanizama pružanje fleksibilnosti operatoru prijenosne mreže prilagođavanje tržišta pomoćnih usluga i mrežnih pravila
Razmjena informacija	nema razmjene informacija	organizirano *offline* i po potrebi mogućnost razmjene informacija u stvarnom vremenu
Tehnički razvoj – mreža	ograničen nadzor i ograničene mogućnosti upravljanja (uglavnom na strani višeg napona) nema SCADA sučelja	nadzor, simulacija i upravljanje prema mreži nižeg napona SCADA i napredno upravljanje mrežom
Tehnički razvoj – aktivni kupac	distribuirani izvori s konstantnim faktorom snage sustavi za pohranu energijom i električna vozila nisu uključeni	mogućnosti izmjenjivača aktivnih kupaca prisutnost i upravljanje sustavima za pohranu energijom i električnim vozilima upravljanje potrošnjom

Strategija ADNM sastoji se od shema čiji je zadatak poboljšati učinkovitost pogona mreže, povećati iskoristivost opreme, smanjiti dodatna ulaganja u infrastrukturu, omogućiti

veći kapacitet za integraciju aktivnih kupaca u postojeću mrežu, smanjiti gubitke i poboljšati naponski profil. Autori u [147] podijelili su te sheme s obzirom na razine na kojima oni djeluju: sheme povezane s proizvodnjom, povezane s potrošnjom i povezane s mrežom. Sheme povezane s proizvodnjom uključuju RPC, APC i sustav za pohranu energije. Sheme povezane s potrošnjom uključuju sustave za upravljanje potrošnjom. Sheme povezane s mrežom sastoje se od uređaja za upravljanje naponskim prilikama, rekonfiguracije mreže i uređaja za kompenzaciju jalove snage i FACTS uređaja. Sheme ADNM su sažete na Slici 2.4.



Slika 2.4: *Sheme sustava upravljanja aktivnom distribucijskom mrežom*

Sheme povezane s proizvodnjom odnose se na upravljanje distribuiranim izvorom i sustavima za pohranu energije. RPC s mogućnošću injektiranja i apsorbiranja imaju važnu ulogu u rješavanju problema povezanih s naponskim prilikama i naponskom nesimetrijom. U slučaju da problemi s naponskim prilikama ne mogu biti riješeni primjenom RPC-a, APC može biti jedna od opcija [148]. Autori u literaturi [149] dijele APC na potpuno smanjivanje proizvodnje koje uključuje potpuno odvajanje generatora i postepeno smanjivanje u kojem se smanji dio proizvodnje. Prema [150] prednosti sustava za pohranu energije kao djelom ADNM su: smanjivanje vršne proizvodnje, zaglađivanje proizvodnje distribuiranih izvora, maksimizacija kapaciteta distribuiranih izvora, smanjenje emisija stakleničkih plinova, smanjivanje mrežnih troškova razmjenom energije i pohrana energije. Sheme povezane s mrežom odnose se na mrežne komponente kojima se može upravljati. Distribucijske mreže su dizajnirane kao prstenaste, ali su u pogonu radijalne. Rekonfiguracijom mreže modificira se topologija mreže. Promjenom uklopnih stanja sklopki mogu se smanjiti gubici, poboljšati

kvaliteta usluge te minimizirati troškovi pogona [151]. Uređaji za kompenzaciju jalove snage koji se koriste u distribucijskim mrežama su kondenzatorske baterije, statički VAR kompenzatori i DSTATCOM (*engl. distributed static compensator*). Prilikom planiranja pogona aktivne distribucijske mreže kondenzatorske baterije se modeliraju tako da se odredi broj instaliranih po čvoru i koliko će ih biti u pogonu u svakom trenutku čineći ih pri tome diskretnim varijablama. Uređaji za upravljanje naponskih prilika koji se spominju u [147] su transformator s regulacijskom preklopkom pod opterećenjem i regulatori napona. Za razliku od pasivnih mreža u kojima transformator s regulacijskom preklopkom pod opterećenjem predstavlja fiksni parametar u aktivnoj distribucijskoj mreži on postaje varijabla upravljanja [152]. Sheme povezane s potrošnjom uključuju sustav za upravljanje potrošnjom koji daje potrošačima mogućnost sudjelovanja u pogonu mreže čime se može smanjiti vršna potrošnja i osigurati učinkovitiji pogon [153].

2.4.1. Višestupanjski optimizacijski modeli za planiranje pogona distribucijske mreže

Autori u literaturi [95] predlažu relaksirni MISOCP model s DistFlow jednadžbama za tokove snaga za poboljšanje naponskih prilika u aktivnoj distribucijskoj mreži. Predloženi model sastoji se od dvije faze planiranja pogona. Prva faza odnosi se na dan unaprijed planiranje gdje se na temelju lokalnih mjerenja napona optimalno postavljaju položaj regulacijske preklopke transformatora, kondenzatorska baterija i pogonska karta distribuiranih izvora. U drugoj se fazi izmjenjivači distribuiranih izvora koriste APC i RPC u unutardnevnom periodu za postizanje optimalnog pogona aktivne distribucijske mreže. Optimizacijskim modelom utječe se na više ciljeva: minimiziranje gubitaka, naponske devijacije i APC-a, ali se problem rješava kao jednociljni. Osim fotonaponskih elektrana kao distribuirani izvor koriste se i vjetroturbine te je model primijenjen na srednjenaponsku distribucijsku mrežu. Kombinirano centralizirano i lokalno APC i RPC upravljanje predloženo je u literaturi [93]. Predloženi model temeljen je na OPF-u i podjeljen je u dvije faze. U prvoj fazi se minimiziraju gubici i APC promatrani u 15-minutnom periodu. Druga faza odnosi se se na stabilizaciju sustava nakon fluktuacija. Potpun AC OPF relaksiran je u SOCP model i korist se DistFlow model tokova snaga. Model je testiran na srednjenaponskoj IEEE 33-sabirničkoj mreži. Autori u literaturi [154] predlažu trostupanjski model za minimiziranje naponskog odstupanja i gubitaka. U prvom stupnju određuju se položaji regulacijske preklopke tran-

sformatora i kondenzatorske baterije za svaki sat, dok se u drugom stupnju koristi RPC za unutarsatni period i naposlijetku jalova snaga izmjenjivača koristi u stvarnom vremenu. Potpuno linearizirani DistFlow model koristi se za proračun tokova snaga te se kao testna mreža koristi srednjenaponska IEEE 33-sabirnička mreža. Dvostupanjski adaptivni model za planiranje pogona aktivne distribucijske mreže predložen je u literaturi [88]. U prvom stupnju se određuju položaji regulacijske preklopke transformatora i kondenzatorske baterije za dan unaprijed. U drugom stupnju koristi se RPC u unutardnevnom periodu s ciljem minimizacije naponske devijacije i gubitaka. Originalni optimizacijski problem relaksiran je pomoću SOCP, dok je model testiran na IEEE 123-sabirničkoj mreži. Autori u literaturi [81] predlažu dvostupanjski optimizacijsi model s ciljem minimiziranja gubitaka. Kao i u [88, 95, 154] u prvom stupnju optimalno se postavljaju položaji regulacijske preklopke transformatora i uklopna stanja kondenzatorske baterije na satnoj razini nazivajući ih pri tome sporo upravljivim uređajima za upravljanje naponskim prilikama. U drugom stupnju koriste se takozvani brzo upravljivi uređaji DSTATCOM i RPC fotonaponskog izmjenjivača na unutarsatnoj razini. Osim samog modela autori predlažu unaprijeđeni model optimizacije jata kitova i uspoređuju njegove performanse s drugim metodama računalne inteligencije poput genetskog algoritma, optimizacije sivog vuka, optimizacije jata kitova, optimizacije roja čestica i umjetnog algoritma jata kolibrića. Model je validiran na srednjenaponskim IEEE 33-sabirničkoj i 69-sabirničkoj mreži. U literaturi [155] autori su predložili dvostupanjski optimizacijski model u kojem su problemi planiranja i pogona odvojeni u zasebne stupnjeve. Cilj modela je minimizirati investicijske troškove, troškove održavanja i upravljanja energijom povezane s porastom distribuiranih izvora i broja komponenata mreže. U prvom stupnju određuje se optimalna lokacija i instalacija komponente mreže uzimajući u obzir stohastičnost distribuiranih izvora i sustava za pohranu energije. U drugom stupnju koriste se mogućnosti aktivnih kupaca za pružanje fleksibilnosti za rješavanje različitih pogonskih problema. Predloženi model definiran je kao MILP i testiran na 24-sabirničkoj srednjenaponskoj mreži. Autori u literaturi [87] predlažu višestupanjski višeciljni pristup s ciljem za minimiziranje potrošnje, gubitaka i održavanje naponske stabilnosti. Prvi stupanj predstavlja fazu planiranja u kojem se predviđa sunčevo zračenje, potrošnja za svaki sat te postavke uređaja za upravljanje naponskim prilikama koji imaju spori odziv poput regulacijske preklopke transformatora i kondenzatorske baterije. U drugom stupnju upravlja se pogonom u stvarnom vremenu pomoću izmjenjivača fotonaponske elektrane. U trećem stupnju ispituje

se učinkovitost predloženog modela s obzirom na smanjivanje vršnog opterećenja, djelatne snage i uštede. Model je testiran na IEEE 123-sabirničkoj srednjenaponskoj mreži. Kao i u [87, 155] planiranje i pogon mreže se u [156] odvijaju se odvojeno. U prvom stupnju funkcija cilja predstavlja minimiziranje ukupnih investicijskih i pogonskih povezanih sa zamjenom postojećih vodova i povezivanje distribuiranih izvora. U drugoj fazi upravlja se uklopnim stanjima sklopke i izmjenjivačem distribuiranog izvora. Optimizacijski problem predstavljen je kao MILP i testiran na 18-sabirničkoj srednjenaponskoj mreži. Autori u literaturi [153] predlažu višeciljni hijerarhijski optimizacijski model za planiranje pogona aktivne distribucijske mreže. U prvom stupnju određuje se optimalno planiranje mrežne infrastrukture s funkcijom cilja minimiziranja ukupnih troškova koji uključuju troškove gubitaka, konstrukcije, kupnje električne energije, emisija štetnih plinova, isključenja i upravljanja potrošnjom. Drugi stupanj predstavlja optimalnu raspodjelu distribuiranih izvora s ciljem povećanja kapaciteta za njihovu integraciju.

2.4.2. Modeli koji uzimaju u obzir naponsku nesimetriju

Autori u literaturi [157] napravili su opsežnu analizu utjecaja aktivnih kupaca na faktor naponske nesimetrije. Analiza je podijeljena u nekoliko slučaja: kada su promatrane samo fotonaponske elektrane, kombinacija fotonaponskih elektrana i električnih vozila te kombinacija fotonaponskih elektrana, električnih vozila i baterija. Za svaki slučaj definirana su tri scenarija. Analizirani scenariji uključuju priključivanje aktivnih kupaca u istu fazu, u fazu odabranu slučajnim odabirom i trofazni priključak. Kao testna mreža korištena je stvarna niskonaponska mreža. Na temeljem dobivenih rješenja prednost se daje trofaznom priključku koji osim što smanjuje faktor naponske nesimetrije omogućava instalaciju više djelatne snage u mreži. Autori u literaturi [53] predlažu koordiniranu strategiju za kompenzaciju naponske nesimetrije koristeći fleksibilnosti jednofazno priključenih baterija. Prvo je ispitan utjecaj različitog stupanja integracije fotonaponskih elektrana i električnih vozila na faktor naponske nesimetrije. Predloženo rješenje uključuje upravljanje djelatnom i jalovom snagom izmjenjivača baterijskog sustava. Predložena strategija testirana je na modelu 20-sabirničkog niskonaponskog izvoda. Volt-var strategija upravljanja za regulaciju napona i smanjivanje naponske nesimetrije predložena je u [121]. Cilj ove strategije je osigurati da se iznosi napona i faktor naponske nesimetrije nalaze unutar dozvoljenih granica, da se minimizira broj promjena regulacijske preklopke transformatora, da se maksimizira proizvodnja

iz fotonaponske elektrane i da se minimizira broj uzastopnih ponavljanja jednog uređaja za regulaciju napona. Volt-var uređaji koji se koriste u ovom radu su regulacijska preklopka transformatora, kondenzatorska baterija i jalova snaga izmjenjivača fotonaponske elektrane. Predložena strategija je testirana na srednjenaponskim i niskonaponskoj mreži modeliranim na temelju stvarnih podataka. Za razliku od prethodnih radova u kojima se predlažu različite strategije za poboljšanje faktora naponske nesimetrije u aktivnim distribucijskim mrežama, sljedeći radovi taj problem nastoje riješiti pomoću optimizacijskih modela. U [52] predlaže se model temeljen na OPF-u u kojem se upravljanjem jalovom snagom fotonaponskog izmjenjivača, punjenjem i pražnjenjem te upravljanjem stanjem napunjenosti baterijskog spremnika energije nastoje minimizirati gubici, faktor naponske nesimetrije i naponska devijacija. Višeciljni problem pretvoren je u jednociljni metodom težinskih suma. Originalni problem je relaksiran i riješen metodom grananja i ograđivanja i metodom sjecišta ravnine. Kao testna mreža korišten je model 21-sabirničke niskonaponske mreže. Autori u literaturi [97] predlažu trostupanjski model u kojem se minimiziraju gubici, nesimetrične struje i broj promjena položaja regulatora napona. U prvom stupnju se obrađuje topologija mreže za svaki vremenski tenutak. U drugom stupnju određuje se optimalna topologija za svaki trenutak, optimalna raspodjela opterećenja i optimalne radne točke izmjenjivača fotonaponskih elektrana. U trećem stupnju se određuje optimalni položaj naponskog regulatora s minimalnim brojem promjena preklopke. Optimizacijski model testiran je na IEEE 123-sabirničkoj srednjenaponskoj mreži. U [35] autori predlažu optimizacijski model za poboljšanje naponskih prilika i naponske nesimetrije s ciljem povećanja kapaciteta za veću integraciju fotonaponskih elektrana. Model je podijeljen hijerarhijski u dva stupnja – u prvom stupnju predstavljeno je dan unaprijed planiranje punjenja električnih vozila, dok je u drugom stupnju predstavljeno upravljanje u stvarnom vremenu pomoću volt-var krivulje i prijenosa snage punjenja s jedne faze na drugu. Originalni model je relaksiran i lineariziran i primijenjen na modificiranu srednjenaponsku IEEE 34-sabirničku mrežu. Autori u literaturi [122] uspoređuju dva pristupa za minimizaciju faktora naponske nesimetrije – centralizirani model temeljen na OPF-u i distribuiranu metodu temeljenu na Steinmezovom dizajnu. U optimizacijskoj metodi jalova snaga izmjenjivača fotonaponske elektrane koristi se kao varijabla upravljanja te je model lineariziran. Steinmetzova metoda zahtjeva razvijenu komunikacijsku infrastrukturi. U prvom koraku određuju se kritični čvorovi. Zatim se računa injekcije jalove snage u tim čvorovima za upravljanje naponom i naponskom nesimetrijom. Usporedba

tih dvaju pristupa pokazuje da model temeljen na OPF-u daje optimalno rješenje, ali njegova je praktična primjena teško izvediva u sustavima s limitiranim mjerenjima i mrežnim podacima te slabo razvijenom komunikacijskom infrastrukturom. Steinmetzova metoda je jednostavnija za primjenu, međutim, uzorkuje značajno narušavanje naponskih prilika jer u svojoj primjeni ne sadržava ograničenja. Autori u literaturi [34] predlažu MISOCP model za minimiziranje strujne nesimetrije pomoću optimalne raspodjele uređaja za raspodjelu opterećenja po fazama i statičkih var kompenzatora. Preloženi model testiran je na modificiranoj 13-sabirničkoj mreži, europskom niskonaponskom distribucijskom izvodu i australskoj niskonaponskoj mreži modeliranoj na temelju stvarnih podataka.

3. Tehnički kriteriji za planiranje pogona aktivne distribucijske mreže

U ovom poglavlju opisani su tehnički kriteriji koji se moraju ispuniti prilikom planiranja pogona distribucijske mreže. Opisane su dopuštene vrijednosti opterećenja elemenata mreže, naponske devijacije i pada napona te su ukratko opisani gubici u distribucijskoj mreži. Dana je definicija i opis faktora naponske nesimetrije i normi koje se primjenjuju u distribucijskoj mreži. Podaci za ovo poglavlje proizašli su iz [16] čiji su tehnički kriteriji uzeti u obzir prilikom izrade ovoga doktorskoga rada.

3.1. Dopuštene vrijednosti strujno-naponskih prilika u distribucijskoj mreži

Kriteriji planiranja pogona primjenjuju se na sve objekte i postrojenja unutar elektroenergetskog sustava, neovisno o njihovom vlasništvu. Dopuštene vrijednosti opterećenja vodova i transformatora za planiranje pogona distribucijske mreže prikazane su u Tablici 3.1. Prilikom vršnog opterećenja (potrošnje) trajno dopušteno opterećenje elemenata mreže u normalnom pogonu može biti 100 % u odnosu na njihovu nazivnu vrijednost. U slučaju neplaniranog poremećaja u mreži, opterećenje nadzemnog voda i transformatora može biti 20 % zimi odnosno 10 % ljeti veće u odnosu na normalni pogon.

Dopuštena naponska devijacija u srednjenaponskoj i niskonaponskoj distribucijskoj mreži prema normi *Naponske karakteristike električne energije iz javnih distribucijskih mreža (EN 50160:2022)* [158] iznosi:

- trajno dopuštena naponska devijacija na mjestu priključka krajnjih korisnika na distribucijsku mrežu u normalnom pogonu iznosi ± 10 % u odnosu na nazivni napon
- dopuštena naponska devijacija na mjestu priključka krajnjih korisnika na distribucijsku

Tablica 3.1: *Dopuštena opterećenja vodova i transformatora za planiranje pogona distribucijske mreže [16].*

Element mreže	**Trajno dopušteno opterećenje**	**Dopušteno opterećenje za vrijeme trajanja neplaniranog poremećaja**
nadzemni vod	100 %, maksimalna struja koja može proticati u normalnom pogonu	120 % zimi 110 % ljeti maksimalna struja koja može proticati u poremećenom pogonu
kabel	100 %, maksimalna struja koja može proticati u normalnom pogonu	100 %
transformator	100 %, maksimalna struja koja može proticati u normalnom pogonu	120 % zimi 110 % ljeti maksimalna struja koja može proticati u poremećenom pogonu

mrežu u vrijeme trajanja poremećenog pogona iznosi + 10 %/ − 15 % u odnosu na nazivni napon.

U postupku planiranja pogona dopušteni pad napona odstupa od norme i u srednjenaponskoj mreži iznose:

- 8 % u normalnim pogonskim prilikama
- 12 % u poremećenim pogonskim prilikama.

Gubici električne energije se prema [16] dijele na tehničke gubitke i netehničke gubitke. Tehnički gubici proizlaze iz pogonskog stanja distribucijske mreže i tehničkih karakteristika njezinih elemenata i uključuju gubitke uslijed magnetiziranja jezgri transformatora i toplinske gubitke koje nastaju na vodovima i transformatorima. Netehnički gubici električne energije rezultat su neizmjerene i neobračunate potrošnje električne energije kod krajnjih korisnika. Tehnički gubici najčešće nastaju zbog velikog udjela vodiča s presjecima manjim od optimalnih, značajnog broja starih ili podopterećenih transformatora, velike razlike u opterećenju mreže (od preopterećenja ljeti do podopterećenja zimi) i neoptimalne alokacije distribuiranih izvora u mreži. Prema [16] distribuirani izvori mogu imati utjecaja na gubitke u mreži u slučaju kada se proizvodnja distribuiranog izvora vremenski podudara s potrošnjom (smanjuju se tokovi snaga kroz mrežu) i gubici se smanjuju te u slučaju kada

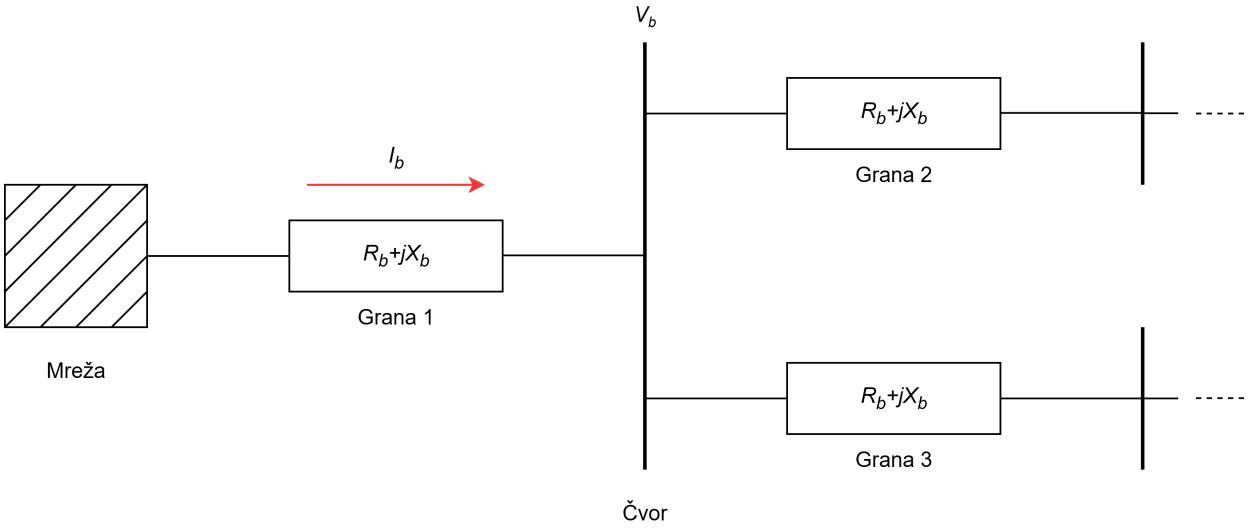
kada se proizvodnja distribuiranog izvora vremenski ne podudara s potrošnjom (povećavaju se tokovi snaga kroz mrežu) i gubici rastu. Također, ne moraju imati utjecaje na gubitke ako se ukupni utjecaji dobivaju kombinacijom prethodna dva slučaja. Posljednjih godina to se prvenstveno odnosi na netehničke gubitke koji su u porastu. Kod smanjivanja gubitaka prednost se daje mjerama i mehanizmima koje ne zahtijevaju značajnije investicijske aktivnosti poput provjere i kontrola priključaka i ispravnosti mjerenja, zamjena starih transformatora onima iz pričuva te optimiziranje mreže.

Prema [159] najčešće se koriste dvije formulacije za gubitke djelatne snage u elektroenergetskom sustavu: formulacija temeljena na snagama u granama i formulacija temeljena na toku struje u granama. Formulacija temeljena na snagama u granama prikazana je izrazom (3-1), dok je formulacija temeljena na toku struje u granama prikazana izrazom (3-2):

$$P_{gub} = \sum_{b=1}^{N} (R_b \cdot (\frac{P_b^2 + Q_b^2}{V_b^2})) \tag{3-1}$$

$$P_{gub} = \sum_{b=1}^{M} (R_b \cdot |I_b|^2) \tag{3-2}$$

gdje P_{gub} predstavlja ukupne gubitke djelatne snage u distribucijskoj mreži, R_b označava otpor grane, I_b je struja koja teče granom, P_b i Q_b su djelatna i jalova snaga grane, V_b predstavlja fazni napon čvora, N je ukupni broj čvorova, a M ukupni broj broj grana u distribucijskoj mreži. Jednopolna shema distribucijske mreže prikazana je na Slici 3.1.



Slika 3.1: *Jednopolna shema distribucijske mreže*

Ovaj doktorski rad usmjeren je na analizu tehničkih gubitaka koji nastaju u aktivnoj

distribucijskoj mreži. Osim na analizu gubitaka doktorski rad usmjeren je na pronalaženje mehanizma upravljanja za reduciranje gubitaka uzrokovanih integracijom aktivnih kupaca uzimajući u obzire tehničke kriterije i zahtjevi koje se stavljaju pred operatora distribucijske mreže.

3.2. Nesimetrija napona

Nesimetrija napona u trofaznom sustavu pojavljuje se kada se fazni ili linijski naponi razlikuju po iznosu, kada kutovi između faza nisu 120° ili oboje [160]. Primjer naponske nesimetrije s različim iznosima faznih napona i kutovima napona prikazan je na Slici 3.2 gdje je valni oblik napona svake faze prikazan drugom bojom. Nesimetrija napona numerički se može izratiti pomoću faktora naponske nesimetrije (*engl. voltage unbalance factor*, VUF). Faktor naponske nesimetrije definiran je kao omjer inverzne i direktne komponente napona i izražava se u postotcima [160]. Izraz za faktor naponske nesimetrije opisan je izrazom (3-3):

$$VUF[\%] = |\frac{V^-}{V^+}| \cdot 100 \tag{3-3}$$

gdje V^- predstavlja inverznu, a V^+ direktnu komponentu napona. Direktna i inverzna komponenta računaju se iz iznosa nesimetričnih faznih napona ($\overline{V_a}$, $\overline{V_b}$, $\overline{V_c}$) i inverzne matrice transformacije prema izrazima (3-4) i (3-5):

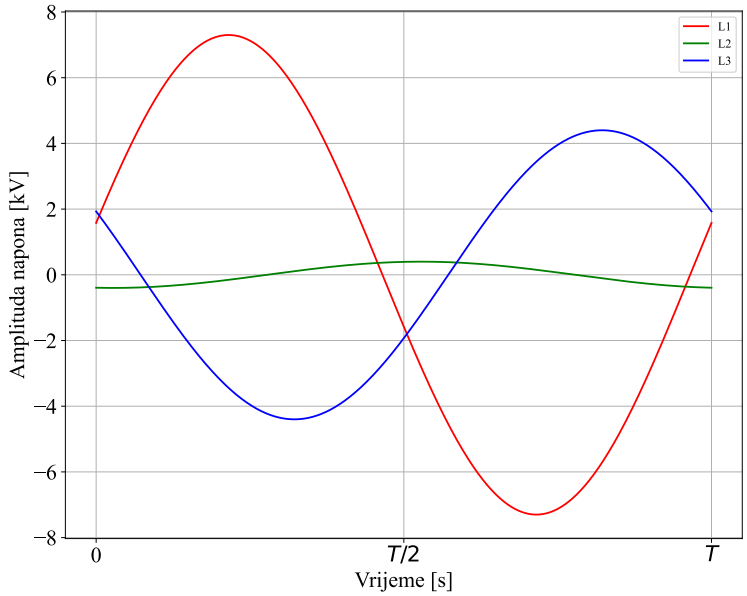
$$\overline{V}^+ = \frac{1}{3} \cdot (\overline{V_a} + \overline{a} \cdot \overline{V_b} + \overline{a}^2 \cdot \overline{V_c}) \tag{3-4}$$

$$\overline{V}^- = \frac{1}{3} \cdot (\overline{V_a} + \overline{a}^2 \cdot \overline{V_b} + \overline{a} \cdot \overline{V_c}) \tag{3-5}$$

gdje $\overline{a}$ predstavlja simetrični operator (Steinmezov operator) prikazan jediničnim vektorom zakrenutim za 120°, to jest $\overline{a} = 1\angle 120°$, $\overline{a}^2 = 1\angle 240°$.

Naponska nesimetrija smatra se jednim od gorućih problema kvalitete električne energije u niskonaponskim distribucijskim mrežama [161]. Iako su naponi na strani proizvodnje i prijenosa relativno simetrični, na razini distribucijske mreže može doći do naponske nesimetrije kao posljedica neujednačene impedancije sustava te neujednačene raspodjele jednofaznih opterećenja. Porast naponske nesimetrije može dovesti do pregrijavanja i smanjenja nazivnog kapaciteta distribucijskih transformatora i motora [161]. Osim nejednake raspodjele

opterećenja dodatni problem mogu stvarati i jednofazne fotonaponske elektrane, baterijski spremnici energije, punionice za električna vozila i slično.



Slika 3.2: *Primjer naponske nesimetrije u elektroenergetskom sustavu*

Prema normi *Naponske karakteristike električne energije iz javnih distribucijskih mreža (EN 50160:2022)* [158] dozvoljeni ukupni faktor naponske nesimetrije ne smije prelaziti 2 % tijekom 95 % 10-minutnih prosjeka efektivnih vrijednosti inverzne komponente napona za razdoblje od tjedan dana.

4. Optimizacijski okvir za modeliranje planiranja pogona niskonaponske aktivne distribucijske mreže

U ovom poglavlju opisani su istraživačko područje i strategija istraživanja. Prikazan je detaljan opis optimizacijskih okvira predloženih modela za planiranje pogona niskonaponske mreže te primijenjenih optimizacijskih metoda i simulacijskih alata.

4.1. Strategija istraživanja

Iscrpni pregled literature u 2. poglavlju definira i obuhvaća uže područje ovog doktorskog rada. Na temelju analizirane literature može se donijeti nekoliko općih zaključaka o dijelu koji je do sada najmanje istražen i gdje postoji potencijal za ostvarivanje doprinosa. Velik broj pregledanih znanstvenih radova koji uključuju dvostupanjski model za planiranje pogona distribucijske mreže uključuju dodavanje novih upravljivih komponenata u distribucijsku mrežu ne uzimajući u obzir povećanje investicijskih troškova mreže i činjenicu da većina mreža nema dobro razvijenu komunikacijsku infrastrukturu koja bi omogućila decentralizirani pogon. Detaljnim istraživanjem postojeće literature utvrđeno je kako se primjena i evaluacija optimizacijskog modela ostvaruje na primjeru srednjenaponske distribucijske mreže degradirajući i zapostavljajući pri tome probleme pogona koji se javljaju u niskonaponskoj mreži i mogućnosti upravljanja na primjeru takve mreže. Prema tome, predlaže se model koji će uzeti u obzir konvencionalan način upravljanja koji se nalazi na raspolaganju operatoru distribucijske mreže u kombinaciji s mogućnostima koje nude izmjenjivači aktivnih kupaca. Temeljni ciljevi na koje se želi utjecati tehničke su prirode i povezani su s naponskim prilikama i gubicima. Centraliziranim planiranjem pogona operator prvo vlastitim resursima nastoji riješiti tehničke probleme u mreži. Budući da se uzima u obzir niskonaponska distribucijska mreža kao upravljačka komponenta, uzima se transformator s mogućnošću promjene položaja regulacijske preklopke. Budući da se promjena položaja regulacijske preklopke transformatora predstavlja komponentu sa sporim odzivom, a djelovanje

aktivnih kupaca je stohastičko i vremenski ovisno, potrebno je uzeti u obzir komponentu s brzim odzivom - mogućnosti izmjenjivača aktivnih kupaca.

Kako je prikazano u pregledu literature, OPF je izrazito upotrebljavan alat za pronalaženje optimalnih postavki upravljačkih varijabli i postizanje optimalnih prilika u distribucijskim mrežama. OPF pripada skupini *NP hard* i izvedivo rješenje je gotovo nemoguće dobiti klasičnom analitičkom metodom. Jedan je od načina u literaturi često korištena konveksna relaksacija kojom se *NP hard* problem s velikim brojem lokalnih optimuma svodi na problem u kojem se garantira globalni optimum. Svaka relaksacija predstavlja aproksimaciju originalnog problema i udaljavanje od realnog modela. Osim analitičkih metoda, u literaturi su u manjem opsegu prisutne i metode računalne inteligencije (metode približavanja globalnom optimumu). Prednost ovakvih metoda je mogućnost nepoznavanja karakteristika optimizacijskog problema (formulacije funkcije cilja i ograničenja), realnije modeliranje bez transformacija, smanjena vjerojatnost zapinjanja u lokalnom optimumu i pronalazak rješenja bliskog globalnom optimumu. Nedostatak ovakvih metoda računalna je kompleksnost i utjecaj odabira parametara metode na kvalitetu rješenja. Gledajući sa stajališta planiranja pogona aktivne distribucijske mreže, primjena ovih metoda za rješavanje OPF-a stvara uvjete za korištenje stvarnih ograničenja mreže bez aproksimacija.

Prilikom planiranja pogona aktivne distribucijske niskonaponske mreže autori u literaturi uključuju i tehničke parametre kvalitete električne energije važne za pogon mreže. Prvenstveno se to odnosi na nesimetriju napona čiji je indikator faktor naponske nesimetrije. Problem naponske nesimetrije najčešće se spominje kao karakteristika povezana s niskonaponskim mrežama, međutim, autori u pregledanoj literaturi često svoje modele testiraju i na primjerima srednjenaponskih mreža. Pregledom literature utvrđeno je da predlažu različite strategije za smanjivanje naponske nesimetrije u jednakom opsegu kao i optimizacijske modele. Minimiziranje naponske nesimetrije rijetko se pojavljuje kao samostalna funkcija cilja u optimizacijskim modelima, već se nastoji neizravno utjecati na nju. Pri tome se upravlja svim mogućim resursima koji su na raspolaganju operatoru distribucijske mreže - upravljanje djelatnom i jalovom snagom aktivnih kupaca, optimalnim rasporedom punjenja baterijskih sustava za pohranu električne energije i električnih vozila, FACTS uređajima i slično.

Autori u pregledanim znanstvenim radovima često uzimaju u obzir tri funkcije cilja: minimizaciju djelatnih gubitaka, minimizaciju naponske devijacije i minimizaciju naponske nesimetrije. Ove tri funkcije cilja obično se prikazuju kao jedna funkcija cilja, koja je rezultat

zbroja svake funkcije pomnožene s odgovarajućim težinskim faktorom, čime se daje veća važnost jednom cilju u odnosu na druge. Također, dimenzijski je problematično zbrajati gubitke, napone i faktor naponske nesimetrije. Niti jedno istraživanje ne uključuje analizu utjecaja jedne od tih triju funkcija cilja na preostale dvije, koje predstavljaju varijable stanja u takvom modelu. Štoviše, autori ne uključuju učinke različitih mehanizama upravljanja koji su na raspolaganju operatoru i njihove kombinacije na funkcije cilja. Na temelju toga predložit će se metoda za vrednovanje utjecaja tih mehanizama na funkcije cilja, koja će poslužiti kao pokazatelj kada je koji cilj najbolje primijeniti te koje mehanizme koristiti u različitim uvjetima kako bi se postigao optimalan pogon.

S obzirom na cjelovitu analizu i obradu literature utvrđeni su nedostaci pojedinih znanstvenih istraživanja, stoga je istraživanje za ovaj doktorski rad usmjereno na realizaciju sljedećih znanstvenih doprinosa:

- dvostupanjski optimizacijski model za planiranje pogona niskonaponske aktivne distribucijske mreže s ciljem poboljšanja naponskih prilika i smanjivanja gubitaka koristeći kombinaciju tradicionalnog mehanizma upravljanja i mogućnosti izmjenjivača
- kosimulacijski model za planiranje pogona niskonaponske aktivne distribucijske mreže s funkcijama cilja smanjenja naponskih odstupanja, naponske nesimetrije i djelatnih gubitaka
- metoda za vrednovanje učinaka mehanizama upravljanja na funkcije cilja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže.

Znanstveni članci u kojima su sadržani doprinosi objavljeni u međunarodnim znanstvenim časopisima su sljedeći:

- M. Dubravac, K. Fekete, D. Topić i M. Barukčić, *Voltage Optimization in PV-Rich Distribution Networks—A Review* [162]
- M. Dubravac, M. Žnidarec, K. Fekete i D. Topić, *Multi-Stage Operation Optimization of PV-Rich Low-Voltage Distribution Networks* [163]
- M. Dubravac, M. Žnidarec, K. Fekete i D. Topić, *Multi-Stage Operation Optimization of PV-Rich Low-Voltage Distribution Networks* [163].

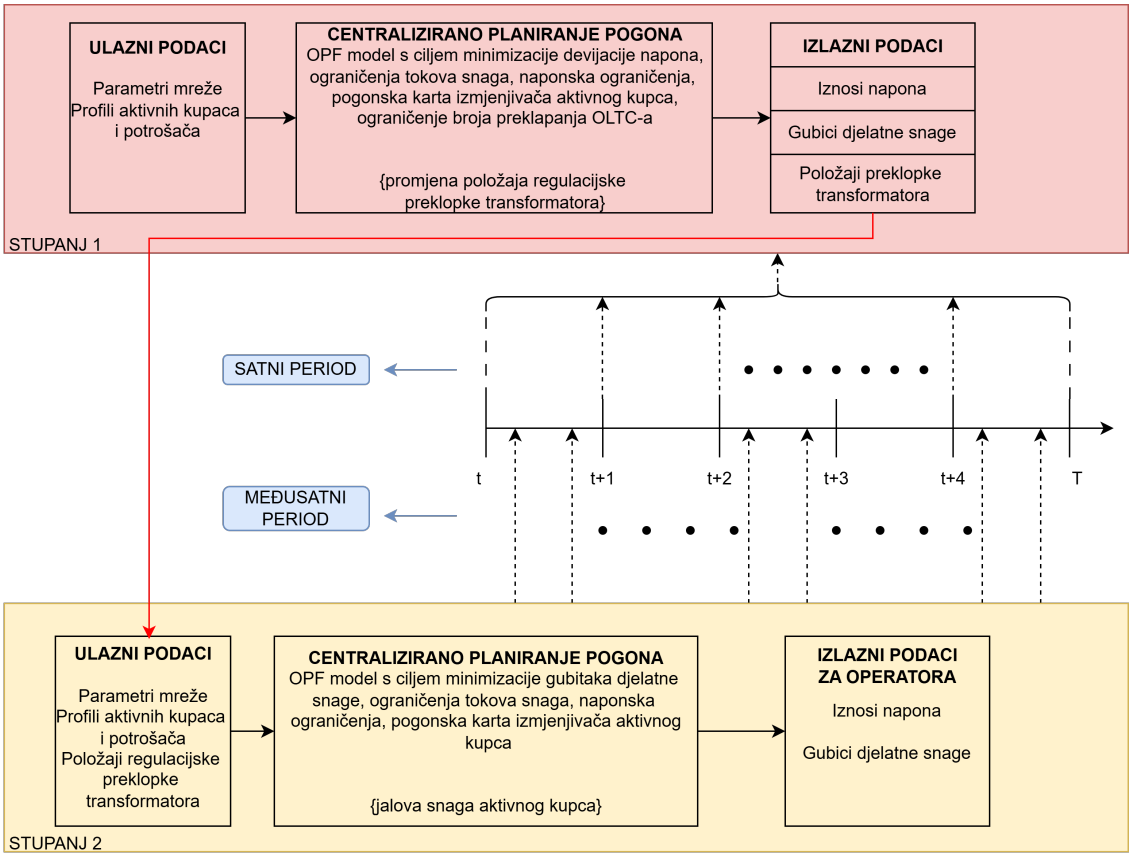
Dijelovi doprinosa koji su objavljeni u zbornicima međunarodnih znanstvenih konferencija su sljedeći:

- M. Dubravac, Z. Šimić, D. Topić, G. Knežević i K.Fekete, *Analysis of PV and EV Chargers Integration Impact on Radial LV Distribution Network* [164]
- M. Dubravac, M. Žnidarec, K. Fekete i D. Topić, *A new co-simulation approach of active power curtailment for voltage optimization in PV-rich distribution networks* [165]
- M. Dubravac, D. Topić, K. Fekete, Z. Šimić, R. Prenc i M. Rojnić, *Active Power Curtailment and Reactive Power Control in PV-Rich Low-Voltage Distribution Network* [166].

4.2. Optimizacijski okviri sustava za planiranje pogona aktivne distribucijske mreže

Slika 4.1 predstavlja vizualni prikaz predloženog dvostupanjskog modela za planiranje pogona aktivne distribucijske mreže koji uključuju dva mehanizma za upravljanje naponskim prilikama i gubicima u aktivnoj distribucijskoj mreži. Sustav za planiranje pogona realiziran je kao dvostupanjski model u kojem svaki stupanj predstavlja jedan optimizacijski problem, a optimizacijski problemi međusobno su povezani varijablama. Izlazni podatak jednog optimizacijskog problema predstavlja ulazni podatak drugog optimizacijskog problema. U prvom stupnju funkciju cilja predstavlja minimiziranje naponske devijacije nastale kao posljedica velike integracije aktivnih kupaca u niskonaponsku distribucijsku mrežu. Budući da je pogon centraliziran, operator nastoji postojećim mehanizmima riješiti problem naponskih prilika bez ulaganja u dodatnu opremu, a to je korištenje transformatora s regulacijskom preklopkom. Iako su za konvencionalnu distribucijsku mrežu karakteristični transformatori s ručnom preklopkom, velika integracija aktivnih kupaca zahtjeva veću fleksibilnost, upravljivost i kapacitet za njihovu integraciju. Stoga operatori diljem Europe mijenjaju konvencionalne transformatore s ručnom preklopkom novim s automatskom preklopkom. Regulacijska preklopka transformatora predstavlja mehanizam sa sporim odzivom i nije prikladan za brze i dinamične promjene što rezultira upravljanjem na satnoj razini. Ograničenja u prvom stupnju predstavljaju jednadžbe tokova snaga, ograničenja napona na

čvorovima, pogonska karta izmjenjivača aktivnog kupca i ograničenje promjena preklopke transformatora. Ulazni podatak za drugi stupanja predstavljaju položaji preklopke transformatora za svaki sat. U drugom stupnju minimiziraju se gubici u distribucijskoj mreži koji se zbog promjena položaja preklopke transformatora i upravljanja naponskim prilikama mogu dodatno povećati. Kao odgovor na dinamičnu prirodu aktivnih kupaca u drugom stupnju se upravlja jalovom snagu izmjenjivača aktivnih kupaca promatrano za unutarsatni period. U drugom stupnju ograničenja predstavljaju jednadžbe tokova snaga, ograničenje napona na čvorovima i pogonska karta izmjenjivača aktivnog kupca.



Slika 4.1: *Blokovska shema dvostupanjskog modela za planiranje pogona aktivne distribucijske mreže*

Blokovska shema kosimulacijskog modela s uključenom metodom vrednovanja učinaka mehanizama upravljanja na funkcije cilja za planiranje pogona aktivne distribucijske mreže prikazana je na Slici 4.2. Kosimulacijski optimizacijski model sastoji se od triju funkcija cilja: minimizacija naponske devijacije, minimizacija gubitaka djelatne snage i minimizacija faktora naponske nesimetrije (na slici označene s OF1, OF2 i OF3). Mehanizmi upravljanja označeni su na slici s MU, a uključuju upravljanje regulacijskom preklopkom transformatora, djelatnom i jalovom snagom aktivnih kupaca te njihove kombinacije. Optimizacijski model

realiziran je kao problem optimalnih tokova snaga te sadrži sljedeća ograničenja: jednadžbe tokova snaga, ograničenje napona na čvorovima, termičko ograničenje vodova, ograničenje faktora naponske nesimetrije, ograničenje mehanizama upravljanja i pogonsku kartu aktivnih kupaca. Nakon svake optimizacije spremaju se iznosi napona, gubitaka i faktora naponske nesimetrije. Nakon izvršenih svih optimizacija izlazni podataci su iznosi napona, faktora naponske nesimetrije i djelatnih gubitaka za različite funkcije cilja i mehanizme upravljanja.

4.3. Teorija optimizacije

Teorija optimizacije (još se naziva i matematičko programiranje) predstavlja granu matematike koja se bavi minimizacijom ili maksimizacijom funkcije definirane setom izvedivih rješenja [167]. Općenito se optimizacijski problem može zapisati kako slijedi (4-1):

$$\text{minimiziraj} \quad f(x), \tag{4-1a}$$

$$\text{uz uvjet da} \quad x \in \mathcal{X}. \tag{4-1b}$$

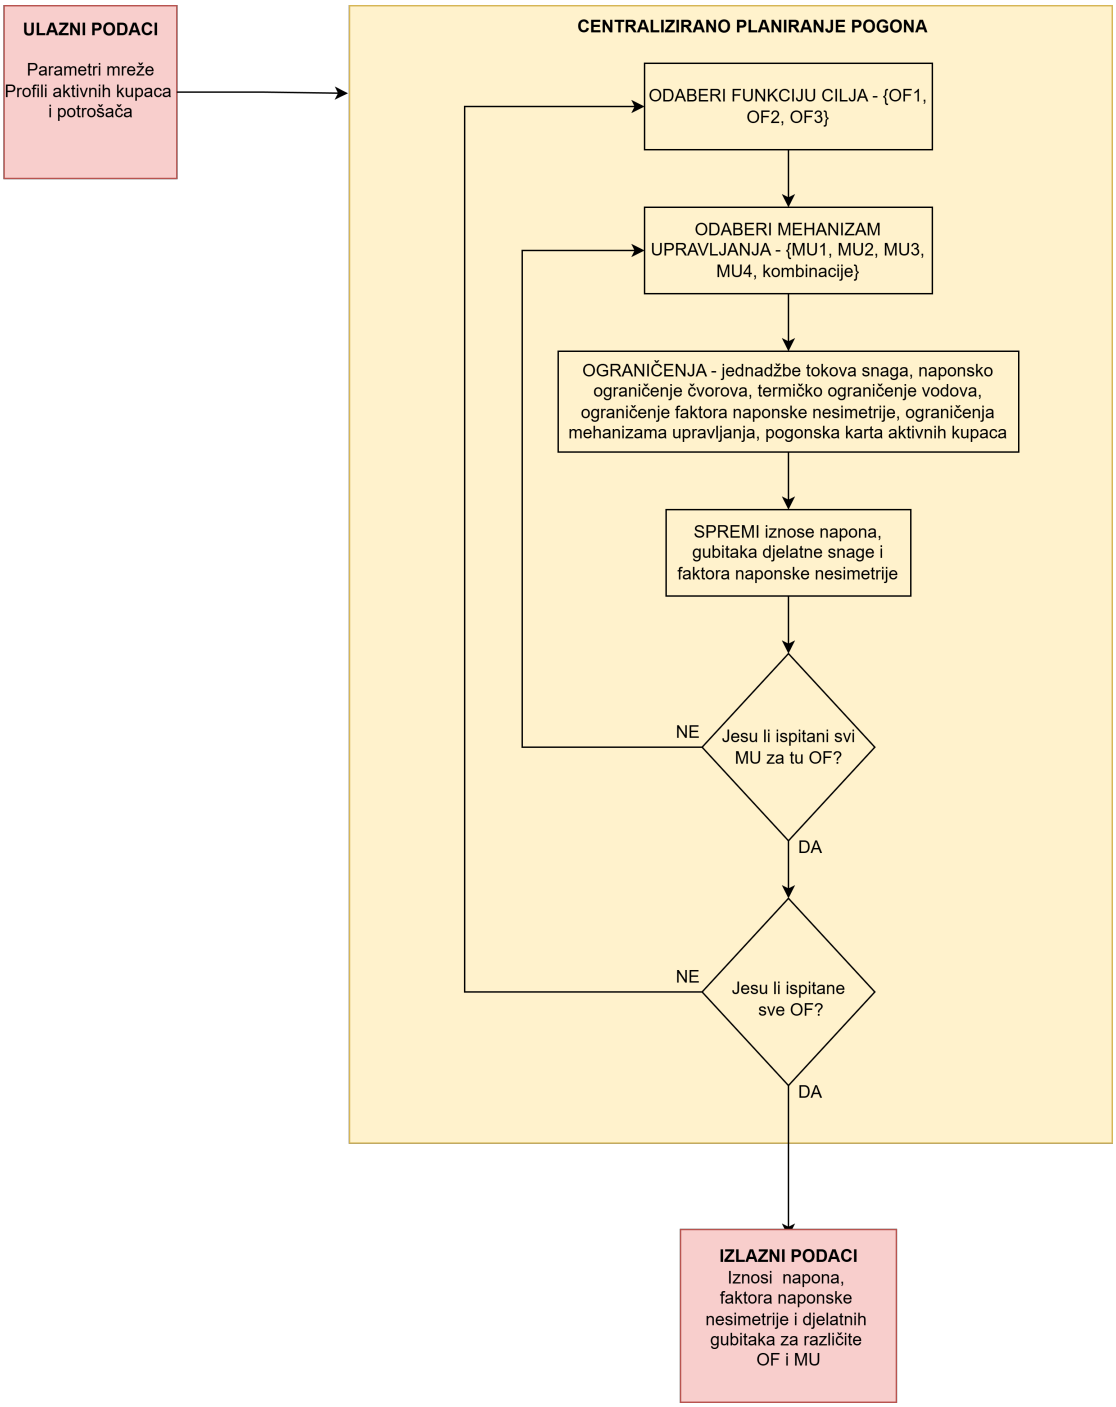
Funkcija koja se minimizira $f(x)$ predstavlja funkciju cilja. Varijable koje se pojavljuju prilikom rješavanja optimizacijskog problema i koje mogu imati vrijednosti određene dopuštenim područjem, koje predstavlja skup svih mogućih rješenja optimizacijskog problema u skladu s postavljenim ograničenjima nazivaju se optimizacijske varijable i označene su vektorom x. Spomenuti skup označen je kao $\mathcal{X}$. Postoje dvije vrste ograničenja funkcijska ograničenja i ograničenja varijabli (limiti varijabli). Funkcijska ograničenja mogu se zapisati prema (4-2):

$$g(x) \leq b, \tag{4-2}$$

gdje je $g(x)$ vektor funkcija $g(x) = [g_1(x), ...g_M(x)]^T$ a b je vektor konstanti. Ograničenja mogu biti jednadžbe (ograničenja jednakosti) i nejednadžbe (ograničenja nejednakosti). Ograničenja varijabli mogu se zapisati prema (4-3):

$$\underline{x} \leq x \leq \overline{x}, \tag{4-3}$$

gdje su $\underline{x}$ i $\overline{x}$ vektori konstanti i predstavljaju donju i gornju granicu vektora x.



Slika 4.2: *Blokovska shema kosimulacijskog modela s uključenom metodom vrednovanja učinaka mehanizama upravljanja na funkcije cilja za planiranje pogona aktivne distribucijske mreže*

Varijable se mogu podijeliti u četiri kategorije: varijable odluke (varijable upravljanja), varijable stanja, izlazne varijable i varijable radne točke. Varijable se mogu promatrati sa stajališta ulazno-izlaznih podataka. Ulazne varijable su varijable odluke, dok poveznicu između ulaznih i izlaznih varijabli čine varijable stanja. Varijable stanja su ključne veličine optimizacijskog problema čije se vrijednosti određuju kako bi se postigao optimum, pri čemu one čine rješenje problema. Vrijednost funkcije cilja predstavljena je izlaznim varijablama. Varijable radne točke predstavljaju varijable iz okoline optimizacijskog problema na koje se odnosi dobiveno rješenje.

4.3.1. Mješovito cjelobrojno nelinearno programiranje

Formulacija mješovitog cjelobrojnog nelinearnog programiranja predstavlja oblik nelinearnog programiranja koje je opisano nelinearnom funkcijom cilja i nelinearnim ograničenjima. Problem mješovitog cjelobrojnog nelinearnog programiranja može se zapisati prema izrazu (4-5) [168]:

$$\text{minimiziraj} \quad f(x,y), \tag{4-4a}$$

$$\text{uz uvjet da} \quad g_j(x,y) \leq 0, \forall j = 1, ...l \tag{4-4b}$$

$$Ax + By \leq b,\ x \in \mathbb{R}^n, y \in \mathbb{Z}^m, \tag{4-4c}$$

gdje x predstavlja kontinuirane varijable, y predstavlja diskretne varijable, $f, g_1, ..., g_l$ predstavlja nelinearne funkcije cilja i ograničenja, a $(Ax + By) \leq b$ linearna ograničenja. Optimizacijski problem minimizacije može se transformirati u problem maksimizacije promjenom predznaka funkcije cilja. Razlika između klasičnog nelinearnog programiranja i mješovito cjelobrojnog nelinearnog programiranja je u vrijednostima koje varijable mogu poprimiti. Kako i sam naziv kaže, kod mješovitog cjelobrojnog programiranja neke varijable mogu biti cjelobrojne (diskretne). Primjena ovakvog načina modeliranja optimizacijskog problema omogućava uključivanje cjelobrojnih varijabli, na primjer, kod upravljačkog mehanizma promjene broja zavoja transformatora.

4.3.2. Optimalni tokovi snaga

Optimalni tokovi snaga općenito se mogu zapisati prema izrazu (4-5) [70]:

$$\text{minimiziraj} \quad f(u, x), \tag{4-5a}$$

$$\text{uz uvjet da} \quad g(x, y) = 0, \tag{4-5b}$$

$$h(u, x) \leq 0. \tag{4-5c}$$

Funkcija cilja predstavljena je izrazom $f(u, x)$. f uglavnom predstavlja skalarnu funkciju, međutim, kada se radi o višeciljnoj formulaciji može se interpretirati kao vektorska funkcija. Vektorske funkcije $g(u, x)$ i $h(u, x)$ označavaju ograničenja jednakosti (jednadžbe) i ograničenja nejednakosti (nejednadžbe). U ovom zapisu vektori u i x su varijable stanja, odnosno varijable upravljanja. S obzirom na karakteristike f, g i h optimizacijski problem može biti formuliran kao problem linearnog programiranja, nelinearnog programiranja, mješovito cjelobrojnog linearnog programiranja i mješovito cjelobrojno linearnog programiranja. Problemi nelinearnog programiranja najčešće su i nekonveksni zbog jednadžbi tokova snaga koje predstavljaju ograničenja jednakosti. Detaljan opis dan je u Potpoglavlju 2.3.2. Računalni izazov rješavanja problema optimalnih tokova snaga znatno se povećava s točnošću prikaza stvarnog modela elektroenergetske mreže. Svojstvo nekonveksnosti koje se može pojaviti kod funkcije cilja i ograničenja doprinosi složenosti problemu optimalnih tokova snaga čineći ga posebno zahtjevnim i računalno i teorijski.

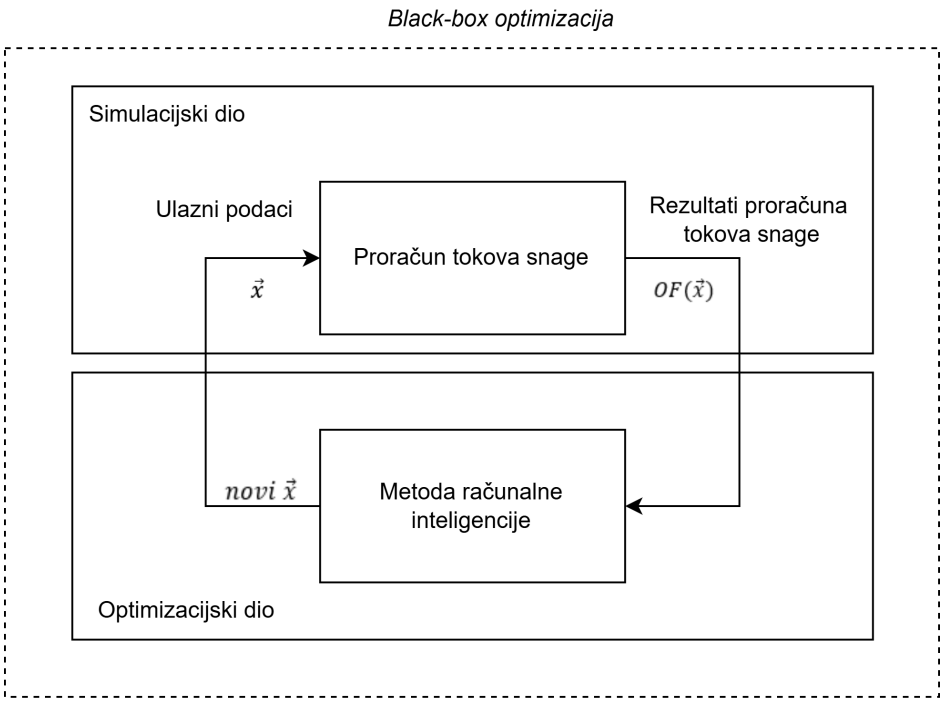
Optimalni tokovi snaga formulirani kao mješovito cjelobrojno nelinearno programiranje pružaju najtočniji i najsloženiji način matematičkog prikaza elektroenergetske mreže koji uzima u obzir diskretne vrijednosti koje mogu poprimiti neki upravljački uređaji. Osim promjene broja zavoja transformatora diskretni uređaji mogu biti i uklapanje/isklapanje kondenzatorskih baterija, uklapanje/isklapanje sklopne opreme kod rekonfiguracije mreže, uključivanje/isključivanje generatora i upravljivih potrošača i slično. Ovakav način modeliranja optimizacijskog problema predstavlja najteži tip optimizacijskog problema, stoga postoji sukob (*engl. tradeoff*) između točnog modeliranja elektroenergetskog sustava i rješivosti (*engl. tractability*) optimizacijskog problema.

4.4. Optimizacijska metoda i alat primijenjen za modeliranje distribucijske mreže

Optimizacijski problem planiranja pogona aktivne distribucijske mreže definiran kao MINLP problem realiziran je optimizacijom crne kutije (*engl. black-box optimization*) u kosimulacijskom okruženju koje se sastoji od dva dijela nadređenog optimizacijskog i simulacijskog dijela. Ta dva dijela nastala su povezivanjem simulacijskog alata za modeliranje i analizu distribucijske mreže i metode računalne inteligencije (metode inteligentnog pretraživanja prostora) preko sučelja. Takav pristup omogućava realno modeliranje distribucijske mreže s uključenim svim elementima stvarnog sustava bez aproksimacija. Korišteni alati imaju ugrađene jednadžbe tokova snaga s pomoću kojih se može razviti mreža s električnim ograničenjima. Budući da se optimizacijski problem ne transformira na razinu na kojoj analitička metoda može biti primijenjena, potrebno je koristiti metodu računalne inteligencije za rješavanje. Prednost metode računalne inteligencije je mogućnost rješavanja optimizacijskog problema bez poznavanja karakteristika funkcije cilja i ograničenja s obzirom na linearnost, eksplicitnost, derivabilnost i slično. Kao ulazne podatke metoda računalne inteligencije zahtjeva samo brojčanu vrijednost funkcije cilja i ograničenja dobivenu koja se dobije od simulacijskog alata. Nedostatak metoda računalne inteligencije je računalna zahtjevnost (duže vrijeme rješavanja procesa) i činjenica da se iznosi funkcije cilja i ograničenja dobiju simulacijom. Odabir ovakvog pristupa prikladan je za implementaciju u ovom doktorskom radu jer se radi o planiranju pogona koje nije osjetljivo na trajanje procesa kao vođenje u stvarnom vremenu.

Blokovska shema kosimulacijskog optimizacijskog okvira sustava za planiranje pogona aktivne distribucijske mreže prikazana je na Slici 4.3. Kosimulacijsko optimizacijsko okruženje započinje generiranjem vektora varijabli odluke (varijabli upravljanja) s pomoću metaheurističke metode. Vektor varijabli odluke zatim predstavlja ulazni podatak za simulacijski alat za proračun tokova snaga koji sadrži model promatrane distribucijske mreže. Izlazni podatak simulacijskog alata predstavlja iznos funkcije cilja u ovisnosti o vektoru varijabli odluke. Ovim se procesom zatvara krug razmjene informacija u kosimulacijskom okruženju.

U ovome doktorskom radu korištena metoda rješavanja je optimizacija rojem čestica (*engl. particle swarm optimization*, PSO) kao metoda računalne inteligencije. PSO predložena je u [169] i predstavlja stohastičku optimizacijsku metodu svrstanu u metode inteligencije



Slika 4.3: *Blokovska shema kosimulacijskog optimizacijskog okruženja sustava za planiranje pogona aktivne distribucijske mreže*

roja (*engl. Swarm intelligence*). Ideja i formulacija PSO metode zasnovana je na promatranju društvenog ponašanja jata ptica i jata riba. Naime, jato ptica u prirodi leti u prostoru za vodećom pticom koja ima najbližu poziciju pronalasku hrane. U sljedećem potpoglavlju dan je detaljniji opis PSO-a.

4.4.1. Optimizacija rojem čestica

U PSO-u roj čestica giba se u D-dimenzionalnom prostoru pretraživanja u potrazi za optimalnim rješenjem. Svaka čestica i definirana je trenutnim vektorom brzine $V_i = [v_{i1}, v_{i2}, ..., v_{iD}]$ i trenutnim vektorom pozicije $X_i = [x_{i1}, x_{i2}, ..., x_{iD}]$, gdje D predstavlja broj dimenzija. Čitavi proces započinje nasumičnom inicijalizacijom vektora V_i i X_i. Nakon toga traži se najbolji položaj čestice i definiran vektorom $Pbest_i = [Pbest_{i1}, Pbest_{i2}, ..., Pbest_{iD}]$ i najbolji položaj čestice u roju (populaciji) $Gbest = [Gbest_1, Gbest_2, ..., Gbest_D]$ navodeći česticu i da ažurira brzinu i položaj prema (4-6) i (4-7):

$$v_{id}(t+1) = v_{id}(t) + c_1 r_1 (Pbest_{id}(t) - x_{id}(t)) + c_2 r_2 (Gbest_d(t) - x_{id}(t)), \qquad (4\text{-}6)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1), \tag{4-7}$$

gdje c_1 i c_2 predstavljaju kognitivni i društveni koeficijent. Kognitivni koefcijent predstavlja stupanja uvažavanja individualnog iskustva, dok društveni kocijent predstavlja stupanj uvažavanja znanja čestica u okolini ili unutar čitavog roja. Koeficijenti r_1 i r_2 dvije su slučajne varijable dobivene uniformnom distribucijom iz intervala $[0, 1]$ [170]. PSO algoritam za rješavanje optimizacijskog problema s funkcijom cilja minimizacije prikazan je Algoritmom 1.

Algoritam 1 PSO algoritam za rješavanje problema s funkcijom cilja minimizacije

Inicijalizacija
Definiraj veličinu roja (populacije) S i broj dimenzija D
for svaku česticu $i \in [1..S]$ **do**
    Nasumično generiraj X_i i V_i, te izračunaj funkciju dobrote (cilja) $f(X_i)$
    Postavi $Pbest_i = X_i$ i $f(Pbest_i) = f(X_i)$
end for
Postavi $Gbest = Pbest_1$ i $f(Gbest) = f(Pbest_1)$
for svaku česticu $i \in [1..S]$ **do**
    if $f(Pbest_i) < f(Gbest)$ **then**
        $Gbest = Pbest_i$
        $f(Gbest) = f(Pbest_i)$
    end if
end for
while $t <$ maksimalan broj iteracija **do**
    for svaku česticu $i \in [1..S]$ **do**
        Izračunaj brzinu $v_{id}(t+1)$ koristeći 4-6
        Ažuriraj poziciju $x_{id}(t+1)$ čestice koristeći 4-7
        if $f(x_i(t+1)) < f(Pbest_i)$ **then**
            $Pbest_i = x_i(t+1)$
            $f(Pbest_i) = f(x_i(t+1))$
        end if
        if $f(Pbest_i) < f(Gbest)$ **then**
            $Gbest = Pbest_i$
            $f(Gbest) = f(Pbest_i)$
        end if
    end for
    $t = t + 1$
end while
return $Gbest$

Parametri kojima se definira PSO su ograničavanje brzine čestica, veličina populacije i kriterij zaustavljanja procesa. Ograničavanje brzine čestica definira se maksimalnom brzinom V_{max} kojom se čestica može kretati u prostoru pretraživanja. Ako čestica prekorači

dozvoljenu brzinu V_{max}, tada se ona postavlja prema (4-8):

$$v_{id}(t+1) = \min\left(v_{id}(t+1), V_{max}\right) \tag{4-8}$$

Ograničavanje brzine čestica pomaže u sprječavanju tzv. eksplozije brzine kako ona ne bi izašla iz prostora pretrage i ono se može podesiti prema (4-9):

$$V_{max} = \delta(x_{max} - x_{min}) \tag{4-9}$$

gdje su x_{max} i x_{min} maksimalne i minimalne granice postora pretraživanja, a $\delta \in [0, 1]$.

Veličina populacije predstavlja broj čestica u populaciji i predstavlja presudni parametar koji karakterizira uspješnost konvergencije PSO-a. U literaturi se najčešće postavlja veličina populacije od 20 do 50 čestica [170]. U literaturi postoje dva kriterija za zaustavljanje procesa - prvi se završava kada se izvrši predefinirani broj iteracija, drugi se odnosi na broj evaluacija funkcije (FE) koji se računa prema (4-10):

$$FE = S \cdot T \tag{4-10}$$

gdje je S veličina populacije, a T maksimalni broj iteracija.

Postoje tri parametra kojima se može upravljati za poboljšanje performansi PSO-a: inercija, kognitivni i socijalni parametar. Ti parametri mogu imati značajan utjecaj na učinkovitost PSO-a te se kod nekih optimizacijski problema najbolja učinkovitost može dobiti samo njihovim pravilnim postavkama.

Ovaj doktorski rad predlaže korištenje kosimulacijskog pristupa rješavanja optimizacijskog problema u kojem je paket s ugrađenim metodama računalne inteligencije *PyGMO* (*engl. Python Parallel Global Multiobjective Optimizer*) povezan s alatom za modeliranje i analizu distribucijskih mreža *OpenDSS* (*Open Distribution System Simulator*) preko sučelja.

4.4.2. *PyGMO* paket s ugrađenim metodama računalne inteligencije

PyGMO je znanstveni paket otvorenog koda s ugrađenim optimizacijskim metodama razvijenim u programskom jeziku *Python*. Razvila ga je Europska svemirska agencija [171]. Prva verzija *PyGMO*-a naziva se *PaGMO* (*engl. Parallel Global Multiobjective Optimizer*) i razvijena je u programskom jeziku *C++*. *PyGMO* se može koristiti za rješavanje jednociljnih i višeciljnih problema, s uključenim i isključenim ograničenjima, s kontinuiranim i diskretnim

varijablama, ali i za razvoj i istraživanje novih optimizacijskih metoda.

PyGMO ima ugrađene različite metode računalne inteligencije: algoritam diferencijalne evolucije, optimizaciju rojem čestica, genetski algoritam, algoritam roja pčela, NSGA-II, simulirano kaljenje i slično. Paket također omogućuje paralelno provođenje procesa optimizacije istovremeno s više rješenja tzv. paralelizacija, što rezultira bržom konvergencijom optimizacijskog problema k dobivanju optimalnog rješenja.

U sklopu ovog doktorskog rada nije predviđeno unaprjeđenje optimizacijske metode. Cilj je ovog doktorskog rada unaprjeđenje optimizacijskog okvira kao i načina modeliranja optimizacijskog problema. Za ovaj doktorski rad izabran je PSO, iako se može koristiti i bilo koja druga metoda ugrađena u *PyGMO* paket.

4.4.3. Alat primjenjen za modeliranje i analizu distribucijske mreže

Open-Source Distribution System Simulator (OpenDSS) simulacijski je alat za proračune u distribucijskim mrežama [172]. *OpenDSS* predstavlja alat otvorenog koda programa *DSS* koji je razvijen 1997. godine i inicijalno je razvijen za ispitivanje i analizu utjecaja distribuiranih izvora na distribucijsku mrežu. Izvršna verzija dodaje osnovno tekstualno skriptno sučelje pogonu za rješavanje, omogućujući korisnicima razvoj skripti i pregled rješenja. Skriptne naredbe dostupne su u svim oblicima programa, uključujući *OpenDSS-G* koji pruža grafičko sučelje.

OpenDSS se primjenjuje:

- za planiranje i analizu distribucijskih mreža
- za proračun kratkih spojeva
- za analizu utjecaja distribuiranih izvora
- za simulaciju godišnje proizvodnje i potrošnje električne energije
- za simulaciju vjetroagregata
- za analizu harmonika i međuharmonika
- za razvoj i modeliranje testnih mreža i slično.

OpenDSS provodi analizu u frekvencijskoj i vremenskoj domeni. U frekvencijskoj domeni koristi se harmonijska analiza tokova snaga. Omogućena je simulacija u vremenskoj

domeni s različitim intervalima promatranja i frekvencijom uzorkovanja. U vremenskoj domeni omogućeno je korištenje sljedećih načina analiza:

- *snapshot* analiza (analiza tokova snaga u stancionarnom stanju)
- *daily* analiza (analiza tokova snaga tijekom 24 sata)
- *yearly* analiza (analiza tokova snaga tijekom 8760 sati)
- *duty cycle* analiza (simulacija u vremenu od 1 do 5 sekundi).

Također, moguć je i stohastički Monte Carlo način rada.

OpenDSS raspolaže aplikacijskim programskim sučeljima *(engl. Application Programming Interface), API* koja su kompatibilna s programskim jezicima kao što su *MATLAB, Python i C#*. Korisnički *engl. Dynamic-link library* (DLL) model omogućava preko *engl. Component Object Model* (COM) sučelja korisniku razvoj novih studija.

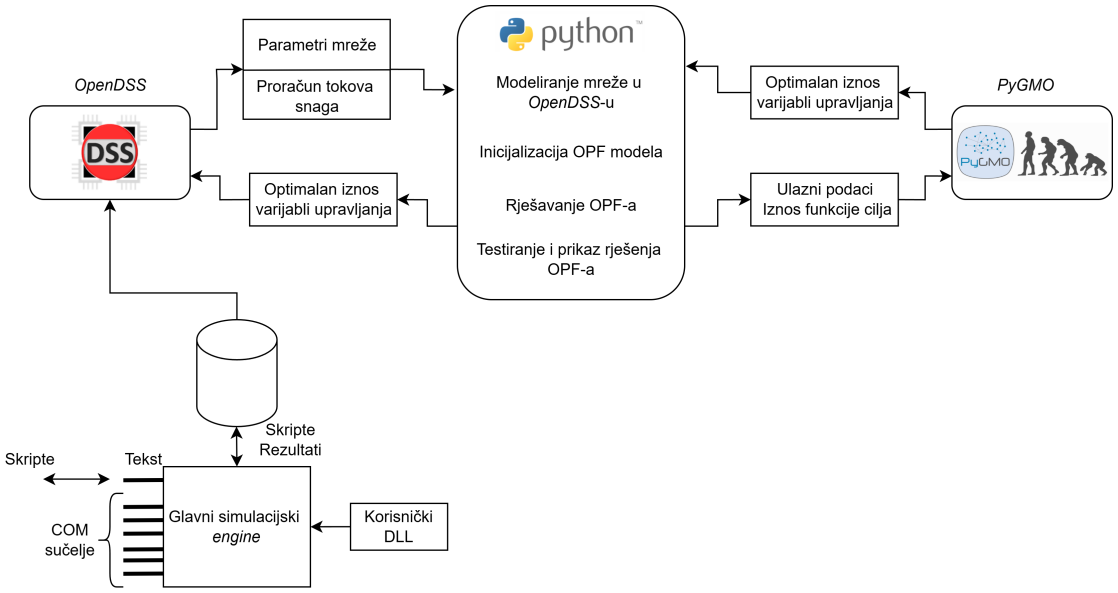
Slika 4.4 prikazuje blokovsku shemu predloženog kosimulacijskog optimizacijskog okvira s pripadajućim alatima i paketima i naglašenom strukturom *OpenDSS*-a. U realiziranom kosimulacijskom optimizacijskom okviru koristi se COM sučelje za *Python* programski jezik čime se omogućava realizacija komunikacije između *OpenDSS-a* i paketa s ugrađenim metaheurističkim optimizacijskim metodama *PyGMO* u oba smjera. Pomoću COM sučelja u *Python*-u su dostupne sve mogućnosti *OpenDSS-a* poput izrada novih modela distribucijskih mreža, modificiranje i izmjena postojećih elemenata mreže i njihovih parametara, simuliranje i analiza i uvoženje rezultata iz *OpenDSS*-a.

4.4.4. Modeli upotrebljenih elemenata distribucijske mreže u *OpenDSS-u*

Modeli elemenata u aktivnoj distribucijskoj mreži su u oba optimizacijska modela opisana optimizacijskim okvirom isti te je način na koji se oni modeliraju opisan u nastavku.

Slika 4.5 [172] prikazuje blokovsku shemu fotonaponske elektrane implementiranu u *OpenDSS*-u. Unutar modela mogu se zasebno modelirati fotonaponski niz i izmjenjivač. Svojstva koja je potrebno definirati prilikom modeliranja fotonaponske elektrane mogu se podijeliti u tri grupe:

- svojstva fotonaponskog niza
- svojstva pogonskih uvjeta



Slika 4.4: *Blokovska shema kosimulacijskog optimizacijskog okvira s pripadajućim alatima i paketima s naglašenom strukturom OpenDSS simulacijskog alata*

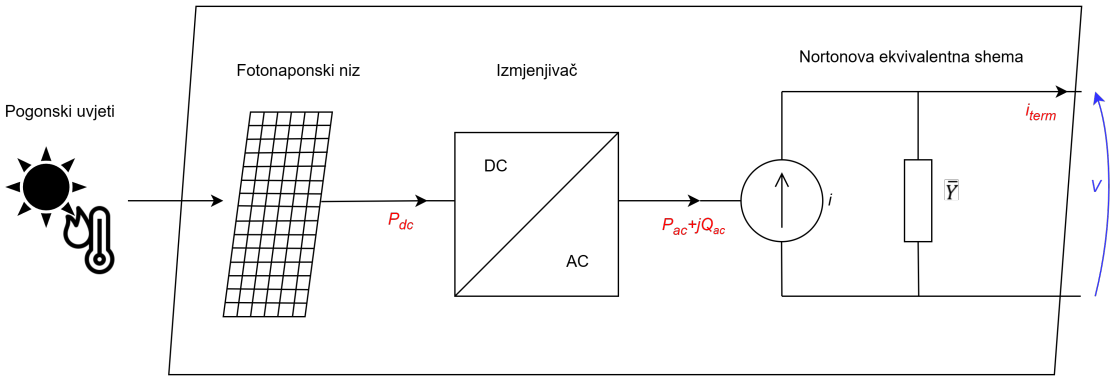
- svojstva izmjenjivača.

Svojstva fotonaponskog niza definira maksimalnu snagu na DC strani pri standardnim testnim uvjetima P_{mpp} koji odgovaraju intenzitetu sunčevog zračenju od 1 kW/m^2 pri definiranoj temperaturi od 25 °C i $P-T$ krivulju koja predstavlja korekcijski faktor po jedinici P_{mpp} kao funkciju temperature fotonaponskog niza. Svojstva pogonskih uvjeta odnose se na intenzitet sunčevog zračenja G (kW/m^2) i temperatoru okoline T (°C).

Svojstva izmjenjivača fotonaponske elektrane odnose se na AC stranu. Definiraju se kroz nazivnu snagu invertera u kVA, nazivni napon u V, faze na koje je fotonaponska elektrana priključena, ime sabirnice, faktor snage (zadano je da je konstantan), jalovu snagu (zadano je da je konstantna), snagu pri kojoj se izmjenjivač gasi ako snaga na DC strani padne ispod određene vrijednosti i slično. Stoga se pri korištenju mogućnosti izmjenjivača fotonaponske elektrane promatra samo AC strana izmjenjivača.

Osim na ovakav način fotonaponska elektrana u *OpenDSS-u* može se modelirati kao potrošač (*engl. Load*) sa suprotim predznakom (zbog smjera energije u mrežu) od stvarnog potrošača (smjer energije iz mreže).

U *OpenDSS-u* modeliraju se takozvani *power conversion* (PC) elementi koji pretvaraju energiju iz jednog oblika u drugi. Osim PC elemenata u *OpenDSS-u* se modeliraju i takozvani *power delivery* (PD) elementi koji u osnovi isporučuju snagu od jednog PC elementa do drugog. PD elemente predstavljaju transformator, vod, kondenzator, zavojnica i slično.

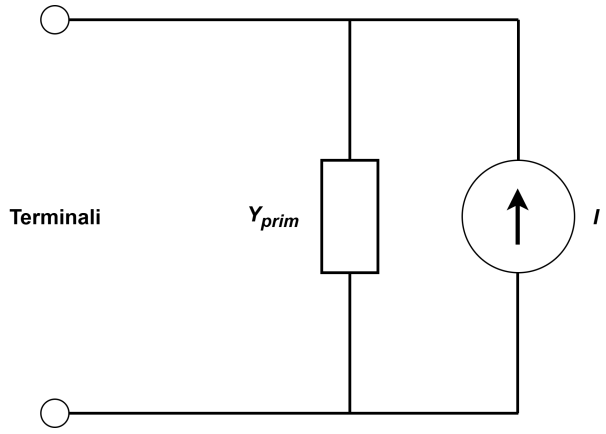


Slika 4.5: *Blokovska shema modela fotonaponske elektrane u OpenDSS-u*

PC elementi imaju samo jedan priključak na mrežu s jednim višefaznim terminalom. PC element može biti opisan jednostavno impedancijom ili setom diferencijalnih jednadžbi koje rezultiraju jednadžbom injektiranja struje u obliku $I_{Term}(t) = F(V_{Term}, [State], t)$, gdje F predstavlja funkciju koja varira s obzirom na tip provedene simulacije (analiza tokova snaga, harmonijska analiza tokova snaga, proračun kratkoga spoja...). Predstavnici PC elemenata su nelinearni potrošači (opterećenja) i generatori koji se modeliraju pomoću Nortonove ekvivalentne sheme prikazane na Slici 4.6. Nortonova ekvivalentna shema sastoji se od konstantne admitancije Y_{prim} i struje I koja kompenzira nelinearni karakteristiku elementa. Ta struja dodana je u vektor struje injektiranja u glavnom solveru, što poprilično lako omogućava implementaciju različitih modela potrošača:

- konstantni P i Q (najkorišteniji model, korišten u ovome doktorskom radu)
- konstantni Z
- konstantni P i kvadratni Q
- eksponencijalni model potrošača
- konstantni I
- konstantni P i Q fiksiran na nekoj vrijednosti
- ZIP model (konstantni Z, I i P).

U okviru ovog doktorskog istraživanja, pored neupravljivih potrošača modeliraju se i upravljivi potrošači, pri čemu se kao primjer upravljivog potrošača razmatra električno vozilo. U *OpenDSS* upravljivi potrošači se modeliraju na isti način kao i neupravljivi koristeći strujni izvor, odnosno Nortonovu ekvivalentnu shemu.



Slika 4.6: *PC element prikazan pomoću Nortonove ekvivalentne sheme u OpenDSS-u*

Prema provedenoj anketi [173] 40 % krajnjih korisnika posjeduje i fotonaponsku elektranu i električno vozilo. U anketi je ispitano 26 vlasnika električnog vozila koji su dali odgovore na 52 pitanja. Na temelju njihovih odgovora načinjen je model električnog vozila korišten za potrebe ovoga doktorskog rada.

Kako bi se električna vozila raspodijelila u distribucijskoj mreži, bez da se preferira određena lokacija koristit će se neprekidna uniforma distribucija. Pomoću uniformne distribucije može se odrediti rješenje nekog ispitivanja koje može poprimiti vrijednost iz ograničenog intervala $\langle a, b\rangle$ [174]. Drugim riječima, vjerojatnost da slučajna varijabla poprimi vrijednost unutar podintervala $\langle x_1, x_2\rangle$ ovisi isključivo o duljini tog podintervala, pod uvjetom da je u potpunosti sadržan unutar $\langle a, b\rangle$. Prema definiciji „za neprekidn slučajnu varijablu X kažemo da ima uniformnu distribuciju na intervalu $\langle a, b\rangle$, $a \leq b$, ako joj je funkcija gustoće vjerojatnosti" dana izrazom (4-11).

$$f(x) = \begin{cases} \frac{1}{b-a}, & x \in (a, b), \\ 0, & x \notin (a, b). \end{cases} \tag{4-11}$$

Funkcija distribucije uniformne slučajne varijable na $\langle a, b\rangle$ definirana je pravilom (4-12).

$$F(x) = \begin{cases} 0, & x \in (-\infty, a), \\ \frac{x-a}{b-a}, & x \in [a, b], \\ 1, & x \in [b, \infty). \end{cases} \tag{4-12}$$

5. Optimizacijski problemi modela za planiranje pogona niskonaponske aktivne distribucijske mreže

U ovom poglavlju detaljno su opisani optimizacijski problemi povezani s predloženim modelima za planiranje pogona aktivne distribucijske mreže. Fokus je stavljen na formulaciju ograničenja mehanizama (varijabli) upravljanja, funkcija cilja i ograničenja mreže.

5.1. Optimizacijski problem dvostupanjskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže

Optimizacijski problem dvostupanjskog modela planira pogon niskonaponske aktivne distribucijske mreže s funkcijom cilja minimizacije naponske devijacije u prvom stupnju i minimizacije gubitaka u drugom stupnju. Za realizaciju optimizacijskog problema korištena je optimizacija crne kutije u kosimulacijskom okruženju kako je opisano u poglavlju 4.4. Optimizacijski problem temeljen je na modelu optimalnih tokova snaga čija je opća matematička formulacija opisana u potpoglavlju 4.3.2. Predloženi model sastoji se od elemenata aktivne distribucijske mreže detaljno opisanih u poglavlju 4.4.4. Uporabom kosimulacijskog okruženja omogućen je detaljan razvoj modela aktivne distribucijske mreže u simulacijskom alatu za modeliranje i analizu mreža koji ima mogućnost proračuna tokova snaga. Iako optimizacija crne kutije ne zahtjeva poznavanje karakteristika funkcija cilja, varijabli i ograničenja u nastavku je sve matematički formulirano i opisano. Jednadžbe tokova snaga također predstavljaju ograničenja i ona su neizravno uključena u model preko alata za proračun i analizu distribucijske mreže te će i one biti formulirane i opisane jer se preko njih mogu realizirati dodatna ograničenja mreže kao i varijabli upravljanja.

5.1.1. Varijable upravljanja dvostupanjskog optimizacijskog modela za planiranje pogona aktivne distribucijske mreže

Varijable upravljanja (odluke) dvostupanjskog optimizacijskog modela za planiranje pogona aktivne distribucijske mreže predstavljene su u ovome potpoglavlju. U prvom se stupnju upravlja promjenom položaja regulacijske preklopke transformatora. Mehanizam s promjenom preklopke transformatora smješten je na strani višeg napona. Općenito distribucijski SN/NN transformatori imaju 5 položaja preklopke $[-2, -1, 0, 1, 2]$. Napon se može regulirati u rasponu od 0.95 p.u. do 1.05 p.u. s korakom od 2.50 %. Promjena preklopke transformatora matematički se opisuje varijablom koja poprima diskretne vrijednosti. Ova diskretna priroda varijable uvjetuje da se problem definira i modelira kao mješovito cjelobrojno nelinearno programiranje u kojem se kombiniraju koninuirane i diskretne varijable unutar složenog modela. Ograničenje preklopke transformatora prikazano je izrazom (5-1):

$$Tap^{\min} \leq Tap_t^{\text{num}} \leq Tap^{\max},\ \forall Tap_t^{\text{num}} \in \mathbb{Z},\ \forall t \in T \tag{5-1}$$

gdje je:

Tap_t^{num} – položaj preklopke transformatora u trenutku t
$Tap^{\min}$ – minimalni položaj preklopke transformatora
$Tap^{\max}$ – maksimalni položaj preklopke transformatora.

Budući da je preklopka transformatora mehanički element, česta promjena položaja može dovesti do habanja i smanjenja njezinog životnog vijeka. Stoga se uvodi indikator α koji broji promjene kako bi se njezino mehaničko naprezanje svelo na minimum. Ako je dođe do promjene položaja u odnosu na prethodni položaj, indikator se postavlja na 1, u suprotnom se indikator postavlja na 0. Matematički zapis dan je izrazima (5-2):

$$\text{Ako je} : |Tap_t - Tap_{t-1}| > 0,\ \alpha = 1,\ \forall t \in T \tag{5-2a}$$

$$\text{Ako je} : |Tap_t - Tap_{t-1}| = 0,\ \alpha = 0,\ \forall t \in T \tag{5-2b}$$

gdje su:

Tap_t – položaj preklopke transformatora u trenutku t

Tap_{t-1} – položaj preklopke transformatora u prethodnom promatranom trenutku $t-1$.

Izrazom (5-3) predstavljeno je ograničenje indikatora koji prati promjenu preklopke transformatora.

$$\sum_{t=1}^{t} \alpha_t \leq \beta, \ \forall t \in T, \ \beta \in \mathbb{Z} \tag{5-3}$$

gdje su:

α_t – broj promjena preklopke u vremenu t

β – cijeli broj.

Varijablu upravljanja u drugom stupnju predstavlja jalova snaga izmjenjivača aktivnog kupca (fotonaponske elektrane). Iznos jalove snage koja se nalazi na raspolaganju ovisi o iznosima djelatne i prividne snage izmjenjivača fotonaponske elektrane. Ako se modeliranje ograničenja jalove snage previše pojednostavni, optimizacijski model neće biti adekvatno realiziran. Na to prvenstveno utječe omjer R/X niskonaponske distribucijske mreže te zbog toga, ako se ograničenje ne modelira pravilno, metoda će težiti najkraćem putu rješavanja i davati prednost smanjivanju djelatne snage. Budući da je jalova snaga ovisna od djelatnoj, smanjivanjem djelatne snage doći će i do smanjenja jalove što rezultira upravljanjem djelatnom, a ne željenom jalovom snagom. Izmjenjivač ima mogućnost injektiranja (*engl. leading*) i absorbiranja (*engl. lagging*) jalove snage. Izrazi *leading* i *lagging* odnose se fazni pomak između napona i struje. *Leading* predstavlja kapacitivnu jalovu snagu kod koje struja prethodi naponu, dok *lagging* predstavlja induktivnu jalovu snagu kod koje napon prethodi struji. Paralela takvom načinu rada može se povući s upravljanjem jalovom snagom kod sinkronih generatora. *Leading* odgovara naduzbuđenom načinu rada generatora u kojem generator daje induktivnu jalovu snagu u mrežu, a troši kapacitivnu jalovu snagu iz mreže. Suprotno tomu *lagging* predstavlja poduzbuđen način rada generatora u kojem on daje u mrežu kapacitivnu jalovu snagu, a troši induktivnu jalovu snagu iz mreže. Slika 2.3a predstavlja pogonsku kartu izmjenjivača fotonaponske elektrane za upravljanje jalovom snagom. Sivom bojom označeno je područje rada izmjenjivača. Ako se iznos djelatne snage nalazi iznad područja definiranog nazivnom prividnom snagom i graničnim faktorom snage tada je iznos jalove snage određena pogonskom kartom. U suprotnom iznos jalove snage određen

je djelatnom snagom i kutem između djelatne i prividne snage. To vrijedi za oba područja rada i induktivno (*lagging*) i kapacitivno (*leading*). Matematički zapis dan je izrazima (5-4).

Ako je:

$$P_{pv} \geq S_{pv} \cdot \cos\varphi^{\text{MIN}}, \quad \forall pv \in PV, \ \forall \cos\varphi^{\text{MIN}} \in [\cos\varphi_{ind}^{\text{MIN}}, \cos\varphi_{cap}^{\text{MIN}}] \tag{5-4a}$$

Vrijedi:

$$-|\sqrt{S_{pv}^2 - P_{pv,t}^2}| \leq Q_{pv,t} \leq |\sqrt{S_{pv}^2 - P_{pv,t}^2}|, \quad \forall pv \in PV, \ \forall t \in T \tag{5-4b}$$

Ako je:

$$P_{pv} < S_{pv} \cdot \cos\varphi^{\text{MIN}}, \quad \forall pv \in PV, \ \forall \cos\varphi^{\text{MIN}} \in [\cos\varphi_{ind}^{\text{MIN}}, \cos\varphi_{cap}^{\text{MIN}}] \tag{5-4c}$$

Vrijedi:

$$-P_{pv,t} \cdot \tan\varphi \leq Q_{pv,t} \leq P_{pv,t} \cdot \tan\varphi, \quad \forall pv \in PV, \ \forall t \in T, \ \forall \varphi \in [\varphi_{ind}, \varphi_{cap}] \tag{5-4d}$$

gdje su:

P_{pv} [kW] – granični iznos djelatne snage izmjenjivača fotonaponske elektrane pv

$\cos\varphi^{\text{MIN}}$ – granični faktor snage izmjenjivača fotonaponske elektrane

S_{pv} [kVA] – nazivna prividna snaga izmjenjivača fotonaponske elektrane pv

$\cos\varphi_{ind}^{\text{MIN}}$ – minimalna vrijednost faktora snage u induktivnom području

$\cos\varphi_{cap}^{\text{MIN}}$ – minimalna vrijednost faktora snage u kapacitivnom području

$P_{pv,t}$ [kW] – iznos djelatne snage izmjenjivača fotonaponske elektrane pv u trenutku t

$Q_{pv,t}$ [kVAR] – iznos jalove snage izmjenjivača fotonaponske elektrane pv u trenutku t

φ [°] – kut između djelatne i prividne snage izmjenjivača fotonaponske elektrane.

5.1.2. Ograničenja dvostupanjskog optimizacijskog modela za planiranje pogona aktivne distribucijske mreže

Implementacijom jednadžbi tokova snaga omogućuje se analiza i optimizacija distribucijskih mreža uzimajući u obzir električna ograničenja koja se odnose na strujno-naponske prilike unutar distribucijske mreže. Jednadžbe tokova snaga uključuju tokove i djelatne i jalove snage u granama distribucijske mreže, to jest u granama (kabelima, vodovima) i

transformatorima. Korišteni simulacijski alat za modeliranje i analizu distribucijskih mreža *OpenDSS* ima prethodno razvijene i definirane elemente aktivne distribucijske mreže, ali se pomoću softvera otvorenog koda mogu dodavati funkcionalnosti elementima distribucijske mreže te ih razvijati i upravljati.

Jednadžbe tokova snaga mogu biti zapisane polarnim zapisom ili pomoću pravokutnih koordinata (kartezijski zapis). Najčešće se koristi polarni zapis temeljen na *bus injection* modelu, stoga jednažbe tokova snaga koje predstavljaju ograničenja jednakosti i dane su prema izrazima (5-5) i (5-6):

$$\sum_{k=n}^{N} |V_{n,t}||V_{k,t}||Y_{nk}| \cos(\delta_{n,t} - \delta_{k,t} - \theta_{nk}) - P_{G,t} + P_{L,t} = 0 \tag{5-5}$$

$$\sum_{k=n}^{N} |V_{n,t}||V_{k,t}||Y_{nk}| \sin(\delta_{n,t} - \delta_{k,t} - \theta_{nk}) - Q_{G,t} + Q_{L,t} = 0 \tag{5-6}$$

gdje su:

$V_{n,t}$ [p.u.] – iznos napona čvora n u trenutku t

$V_{k,t}$ [p.u.] – iznos napona čvora k u trenutku t

Y_{nk} [p.u.] – iznos nk-tog elementa matrice admitancija $\mathbf{Y}$

$\delta_{n,t}$ [°] – kut napona čvora n u trenutku t

$\delta_{k,t}$ [°] – kut napona čvora k u trenutku t

θ_{nk} [°] – kut nk-tog elementa matrice admitancija $\mathbf{Y}$

$P_{G,t}$ [p.u.] – djelatna snaga distribuiranog izvora G u trenutku t

$P_{L,t}$ [p.u.] – djelatna snaga potrošača L u trenutku t

$Q_{G,t}$ [p.u.] – jalova snaga distribuiranog izvora G u trenutku t

$Q_{L,t}$ [p.u.] – jalova snaga potrošača L u trenutku t.

Ograničenje napona svih čvorova (sabirnica) definira se s obzirom na mrežnim pravilima definirani dozvoljeni minimalni i maksimalni iznos prema izrazu (5-7):

$$V_n^{\min} \leq V_{n,t} \leq V_n^{\max}, \ \forall n \in N, \ \forall t \in T \tag{5-7}$$

gdje su:

$V_{n,t}$ [p.u.] – iznos napona čvora n u trenutku t

$V_n^{\min}$ [p.u.] – minimalni dozvoljeni iznos napona čvora n

$V_n^{\max}$ [p.u.] – maksimalni dozvoljeni iznos napona čvora n.

Ostali elementi aktivne distribucijske mreže definirani su kao ograničenje opteretivosti prividnom snagom danom izrazom (5-8):

$$S_{e,t} \leq \sqrt{P_{e,t}^2 + Q_{e,t}^2}, \ \forall e \in E, \ \forall t \in T \tag{5-8}$$

gdje su:

$S_{e,t}$ [kVA] – prividna snaga kojom element e opterećuje mrežu u vremenu t

$P_{e,t}$ [kW] – djelatna snaga kojom element e opterećuje mrežu u vremenu t

$Q_{e,t}$ [kVAR] – jalova snaga kojom element e opterećuje mrežu u vremenu t.

5.1.3. Funkcije cilja dvostupanjskog optimizacijskog modela za planiranje pogona aktivne distribucijske mreže

Optimizacijski problem prvoga stupnja modela za planiranje pogona aktivne distribucijske mreže ima zadatak zadržati napon što bliže referentnoj vrijednosti, odnosno minimizirati devijaciju napona od referentne vrijednosti (izraz (5-9)). Velika integracija fotonaponskih elektrana rezultira povećanjem tokova snaga prema mreži i u slabo opterećenim mrežama uzrokuje značajno povišenje iznosa napona.

$$\text{minimiziraj} \sum_{n=1}^{N} \sum_{t=1}^{t} (V_{n,t} - V^{\text{ref}})^2 \tag{5-9}$$

gdje su:

$V_{n,t}$ [p.u.] – iznos napona čvora n u vremenu t

V^{ref} [p.u.] – definirana referentna vrijednost napona.

Optimizacijski problem drugog stupnja modela za planiranje pogona aktivne distribucijske mreže ima zadatak minimizirati gubitke djelatne energije u promatranoj mreži. Funkcija cilja minimizacije gubitaka definirana je prividnom snagom iz koje su uz pomoć trokuta snaga dobivene djelatna i jalova snaga (5-10).

$$\text{minimiziraj} \sum_{t=1}^{t} \sqrt{(P_t^{\text{loss}})^2 + (Q_t^{\text{loss}})^2} \tag{5-10}$$

gdje su:

P_t^{loss} [kW] – gubici djelatne snage u vremenu t

Q_t^{loss} [kVAR] – gubici jalove snage u vremenu t.

Gubici djelatne snage dobiju se zbrajanjem gubitaka nastalih u transformatoru i gubitaka u vodovima (kabelima). Gubici u transformatoru nastaju zbog zagrijavanja namota uslijed prolaska struje. Gubici u vodovima nastaju također zbog zagrijavanja otpora vodiča uslijed prolaska struje. Gubici u transformatoru dani su izrazom (5-11).

$$P_{ts}^{\text{loss}} = I_{ts}^2 \cdot R_{ts} \tag{5-11}$$

gdje su:

P_{ts}^{loss} [W] – djelatni gubici u transformatoru

I_{ts} [A] – struja koja teče kroz namote transformatora

R_{ts} [Ω] – ukupni otpor namota transformatora.

Gubici u vodu dani su izrazom (5-12).

$$P_l^{\text{loss}} = I_l^2 \cdot R_l \tag{5-12}$$

gdje su:

P_l^{loss} [W] – djelatni gubici u vodu

I_l [A] – struja koja teče kroz vodiče

R_l [Ω] – ukupni otpor vodiča.

Nadalje, ukupni otpor vodiča dan je izrazom (5-13). Ukupni otpor vodiča ovisi o specifičnom otporu materijala vodiča, duljini i poporečnom presjeku voda.

$$R_l = \rho \frac{L}{A} \tag{5-13}$$

gdje su:

ρ [Ωm] – specifični otpor materijala vodiča

L [m]– duljina voda

A [m^2] – poprečni presjek voda.

Ukupni gubici djelatne snage dani su izrazom (5-14).

$$P_t^{\text{loss}} = \sum_{t=1}^{t} P_{ts,t}^{\text{loss}} + \sum_{l=1}^{l} \sum_{t=1}^{t} P_{l,t}^{\text{loss}} \tag{5-14}$$

Gubici jalove snage nastaju u jezgri transformatora i mogu se podijeliti na gubitke petlje histereze i gubitke nastale zbog vrtložnih struja. Gubici petlje histerze nastaju uslijed magnetiziranja jezgre strujom induktivnog karaktera. Gubici zbog vrtložnih struja nastaju u jezgri i uzrokuju njezino zagrijavanja. Gubici jalove snage u vodu nastoju zbog reaktivnih elemenata i predstavljaju oscilacije energije. Gubici jalove snage zapravo ne predstavljaju disipaciju energije te se u tom smislu ne uzimaju u obzir. Međutim, višak jalove snage smanjuje učinkovitost prijenosa energije jer dio kapaciteta za prijenos prividne snage zauzima jalova snaga na štetu djelatne. Također, jalova snaga doprinosi ukupnoj struji što rezultira povećanjem gubitaka djelatne snage te opterećenjem mreže.

5.2. Optimizacijski problem kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže

Kosimulacijski optimizacijski model uzima u obzir tri funkcije cilja: minimizaciju naponske devijacije, minimizaciju gubitaka i minimizaciju faktora naponske nesimetrije. Naponska nesimetrija kao i faktor naponske nesimetrije definirani su u poglavlju 3.2. Problem naponske nesimetrije predstavlja problem kvalitete električne energije, ali zbog svoga utjecaja na pogon aktivne distribucijske mreže potrebno ga je uzeti prilikom planiranja jer izravno utječe na strujno-naponske prilike u mreži. Prilikom planiranja tadicionalne distribucijske mreže nastoji se simetrirati mreža. Međutim, integracijom različitih konfiguracija aktivnih kupaca i njihove stohastičke prirode gotovo je nemoguće niskonaponsku mrežu održati simetričnom. Nesimetriji napona dodatno doprinose i različite snage i lokacije aktivnih kupaca. Ovaj model osim fotonaponskih elektrana sadržava i punionice električnih vozila. Prema rezultatima provedene ankete [173] utvrđeno je da gotovo 40 % krajnjih korisnika koji posjeduju fotonaponske elektrane istovremeno posjeduje i električno vozilo što dodatno doprinosi strujno-naponskim prilikama i problemu planiranja pogona niskonaponske aktivne distribucijske mreže.

Uzimajući u obzir prisutnost naponske nesimetrije, optimizacijski model uključuje analizu nesimetričnih tokova snaga na temelju kojih se određuju strujno-naponske prilike u pojedi-

nim fazama sustava. Prostor pretrage za dobivanje rješenja dodatno se sužava proširivanjem modela na dodatna ograničenja poput termičkog ograničenja grana i ograničenja faktora naponske nesimetrije. Varijable upravljanja koje se koriste u optimizacijskom modelu kao i u prethodnom modelu uključuju tradicionalni mehanizam (preklopka transformatora) i mogućnosti izmjenjivača aktivnih kupaca. Upravljanje mogućnostima aktivnih kupaca obuhvaća upravljanje djelatnom i jalovom snagom izmjenjivača fotonaponske elektrane te punjenjem (djelatnom snagom) električnih vozila.

Predloženi model sadržava elemente distribucijske mreže opisane u poglavlju 4.4.4. Kao i model opisan u poglavlju 5.1 i ovaj optimizacijski model realiziran je u kosimulacijskom optimizacijskom okruženju koji omogućava detaljan razvoj modela mreže i riješen pomoću optimizacije crne kutije.

5.2.1. Varijable upravljanja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže

Predloženi kosimulacijski model uključuje dostupne mehanizme upravljanja (varijable upravljanja) pogonom niskonaponske distribucijske mreže, a nalaze se na raspolaganju operatoru i potrebno ih je uzeti u obzir prilikom planiranja pogona. Osim promjene preklopke transformatora i upravljanja jalovom snagom koji su matematički modelirani i detaljno opisani u prethodnom poglavlju, ovaj model pruža mogućnost upravljanja i djelatnom snagom izmjenjivača fotonaponske elektrane kao i upravljanja punjenjem elektičnim vozilom. Ograničenja varijabli upravljanja predstavljena su u ovome poglavlju.

Ograničenje preklopke transformatora formulirano je kod dvostupanjskog modela za planiranje pogona, ali je zbog preglednosti prikazano i kod kosimulacijskog modela (5-15).

$$Tap^{\min} \leq Tap_t^{\text{num}} \leq Tap^{\max},\ \forall Tap_t^{\text{num}} \in \mathbb{Z},\ \forall t \in T \tag{5-15}$$

gdje je:

Tap_t^{num} – položaj preklopke transformatora u vremenu t

$Tap^{\min}$ – minimalni položaj preklopke transformatora

$Tap^{\max}$ – maksimalni položaj preklopke transformatora.

Indikator koji prati broj promjena preklopke definiran je izrazom (5-16).

$$\text{Ako je : } |Tap_t - Tap_{t-1}|>0,\ \alpha = 1,\ \forall t \in T \tag{5-16a}$$

$$\text{Ako je : } |Tap_t - Tap_{t-1}| = 0,\ \alpha = 0,\ \forall t \in T \tag{5-16b}$$

gdje su:

Tap_t – položaj preklopke transformatora u trenutku t

Tap_{t-1} – položaj preklopke transformatora u prethodnom promatranom trenutku $t-1$.

Ograničenje indikatora koji prati broj promjena preklopke dano je izrazom (5-17).

$$\sum_{t=1}^{t} \alpha_t \leq \beta,\ \forall t \in T,\ \beta \in \mathbb{Z} \tag{5-17}$$

gdje su:

α_t – broj promjena preklopke u vremenu t

β – cijeli broj.

Ograničenje izmjenivača fotonaponske elektrane za upravljanje jalovom snagom dano je izrazima (5-18).

Ako je:

$$P_{pv,p} \geq S_{pv,p} \cdot \cos\varphi^{\text{MIN}}, \quad \forall pv \in PV,\ \forall p \in P,\ \forall \cos\varphi^{\text{MIN}} \in [\cos\varphi_{ind}^{\text{MIN}},\ \cos\varphi_{cap}^{\text{MIN}}] \quad \text{(5-18a)}$$

Vrijedi:

$$-|\sqrt{S_{pv,p}^2 - P_{pv,p,t}^2}| \leq Q_{pv,p,t} \leq |\sqrt{S_{pv,p}^2 - P_{pv,p,t}^2}|, \quad \forall pv \in PV,\ \forall p \in P,\ \forall t \in T \quad \text{(5-18b)}$$

Ako je:

$$P_{pv,p} < S_{pv,p} \cdot \cos\varphi^{\text{MIN}}, \quad \forall pv \in PV,\ \forall p \in P,\ \forall \cos\varphi^{\text{MIN}} \in [\cos\varphi_{ind}^{\text{MIN}},\ \cos\varphi_{cap}^{\text{MIN}}] \quad \text{(5-18c)}$$

Vrijedi:

$$-P_{pv,p,t} \cdot \tan\varphi \leq Q_{pv,p,t} \leq P_{pv,p,t} \cdot \tan\varphi, \quad \forall pv \in PV,\ \forall p \in P,\ \forall t \in T,\ \forall \varphi \in [\varphi_{ind},\ \varphi_{cap}] \quad \text{(5-18d)}$$

gdje su:

$P_{pv,p}$ [kW] – granični iznos djelatne snage izmjenjivača fotonaponske elektrane

$\cos\varphi^{\text{MIN}}$ – granični faktor snage izmjenjivača fotonaponske elektrane

$S_{pv,p}$ [kVA] – nazivna prividna snaga izmjenjivača fotonaponske elektrane

$\cos\varphi_{ind}^{\text{MIN}}$ – minimalna vrijednost faktora snage u induktivnom području

$\cos\varphi_{cap}^{\text{MIN}}$ – minimalna vrijednost faktora snage u kapacitivnom području

$P_{pv,p,t}$ [kW] – iznos djelatne snage izmjenjivača fotonaponske elektrane u trenutku t

$Q_{pv,p,t}$ [kVAR] – iznos jalove snage izmjenjivača fotonaponske elektrane u trenutku t

φ [°] – kut između djelatne i prividne snage izmjenjivača fotonaponske elektrane.

Upravljanje djelatnom snagom izmjenjivača fotonaponske elektrane predstavlja obećavajuće rješenja za pogon niskonaponske aktivne distribucijske mreže zbog dominacije djelatnog otpora u odnosu na reaktanciju čitave mreže. Takav način upravljanja primjenjuje se na mreže s velikom integracijom fotonaponskih elektrana u kojima se očekuje porast tokova snaga u mrežu koji može rezulitrati porastom iznosa napona na čvorovima. Iznos snage koji se može smanjiti kreće se u intervalu od trenutne vrijednosti djelatne snage u nekom trenutku do 0. Problem koji se može pojaviti prilikom uporabe ovoga upravljačkog mehanizma nalazi se na strani aktivnog kupca u smislu nepravednog smanjivanja djelatne snage kod onih fotonaponskih elektrana koje ne uzrokuju probleme u mreži ograničavajući tim elektranama finacijsku dobit zbog nepredane energije u mrežu [21]. Ovaj doktorski rad stavlja fokus na stranu

operatora distribucijske mreže uzimajući u obzir benefite dobivene novim upravljačkim mehanizmima isključujući moguća nezadovoljstva aktivnih kupaca.

Područje rada za smanjivanje djelatne snage fotonaponskog izmjenjivača prikazano je na Slici 2.3b i označeno je crvenom bojom. Smanjivanje djelatne snage izmjenjivača fotonaponske elektrane dano je izrazom (5-19).

$$P^{\mathrm{MIN}}_{pv,p,t} \leq P^{\mathrm{APC}}_{pv,p,t} \leq P_{pv,p,t},\ \forall pv \in PV,\ \forall p \in P,\ \forall t \in T \tag{5-19}$$

gdje su:

$P_{pv,p,t}$ [kW] – djelatna snaga fotonaponske elektrane pv priključene u fazu p u trenutku t

$P^{\mathrm{MIN}}_{pv,p,t}$ [kW] – minimalna djelatna snaga fotonaponske elektrane pv priključene u fazu p u trenutku t

$P^{\mathrm{APC}}_{pv,p,t}$ [kW] – djelatna snaga koju fotonaponska elektrana pv priključena u fazu p smanjuje u trenutku t.

Električno vozilo prestavlja dodatnog potrošača u mreži te uzrokuje povećanje tokova snaga iz mreže što može rezultirati problemima pogona. Ti problemi pogona mogu se očitovati kao preniski naponi na čvorovima, povećano opterećenje mreže, povećani gubici i povećanje naponske nesimetrije u slučaju jednofaznog priključka. Paralela ovakvom načinu upravljanja može se povući sa smanjivanjem djelatne snage izmjenjivača fotonaponske elektrane s razlikom u smjeru tokova snaga. Radna točka snage punjenja može se kretati u rasponu od 0 do maksimalne snage punjenja. Kao u slučaju mehanizma smanjivanja djelatne snage izmjenjivača fotonaponske elektrane i korištenje ovoga mehanizma može izazvati nezodovoljstvno na aktivnog kupca. Rješenje toga problema nije u domeni ovoga doktorskog rada. Važno je naglasiti da se ovim doktorskim radom nastoji riješiti problem mogućeg poremećenog pogona izazvanim velikom integracijom aktivnih kupaca.

Ograničenje snage punjenja električnog vozila prikazano je izrazom (5-20).

$$P^{\mathrm{MIN}}_{ev,p,t} \leq P^{\mathrm{APC}}_{ev,p,t} \leq P_{ev,p,t},\ \forall ev \in EV,\ \forall p \in P,\ \forall t \in T \tag{5-20}$$

gdje su:

$P_{ev,p,t}$ [kW] – snaga punjenja električnog vozila ev priključenog u fazu p u trenutku t

$P^{\mathrm{MIN}}_{ev,p,t}$ [kW] – minimalna snaga punjenja električnog vozila ev priključenog u fazu p u trenutku t

$P^{\text{APC}}_{ev,p,t}$ [kW] – snaga punjenja koju električno vozilo ev priključno u fazu p smanjuje u trenutku t.

5.2.2. Ograničenja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže

Kao i u prethodnom modelu korištenjem kosimulacijskog pristupa omogućena je implementacija potpunih AC tokova snaga čijom se analizom mogu uzeti u obzir stujno-naponske prilike unutar distribucijske mreže. Iako je analiza tokova snaga uključena preko simulacijskog alata za modeliranje i analizu distribucijske mreže, jednadžbe će biti raspisane u potpunom obliku kao i ograničenja koja one omogućuju. U ovom modelu naglasak je stavljen na nesimetrične tokove snaga. Kod nesimetričnih tokova snaga komponente mreže se ne mogu kao kod simetričnih modelirati direktnom komponentom već je potrebno modelirati svaku fazu zasebno. Jednadžbe tokova snaga dane su izrazim (5-21) i (5-22).

$$\sum_{k=n}^{N}\sum_{p=1}^{P}|V_{n,p,t}||V_{k,p,t}||Y_{nk}|\cos(\delta_{n,p,t}-\delta_{k,p,t}-\theta_{nk})-P_{G,p,t}+P_{L,p,t}=0 \tag{5-21}$$

$$\sum_{k=n}^{N}\sum_{p=1}^{P}|V_{n,p,t}||V_{k,p,t}||Y_{nk}|\sin(\delta_{n,p,t}-\delta_{k,p,t}-\theta_{nk})-Q_{G,p,t}+Q_{L,p,t}=0 \tag{5-22}$$

gdje su:

$V_{n,p,t}$ [p.u.] – iznos napona čvora n faze p u trenutku t

$V_{k,p,t}$ [p.u.] – iznos napona čvora k faze p u trenutku t

Y_{nk} [p.u.] – iznos nk-tog elementa matrice admitancija $\mathbf{Y}$

$\delta_{n,p,t}$ [°] – kut napona čvora n faze p u trenutku t

$\delta_{k,p,t}$ [°] – kut napona čvora k faze p u trenutku t

θ_{nk} [°] – kut nk-tog elementa matrice admitancija $\mathbf{Y}$

$P_{G,p,t}$ [p.u.] – djelatna snaga distribuiranog izvora G u fazi p u trenutku t

$P_{L,p,t}$ [p.u.] – djelatna snaga potrošača L u fazi p u trenutku t

$Q_{G,p,t}$ [p.u.] – jalova snaga distribuiranog izvora G u fazi p u trenutku t

$Q_{L,p,t}$ [p.u.] – jalova snaga potrošača L u fazi p u trenutku t.

Ograničenje napona s obzirom na dozvoljenu minimalnu i maksimalnu vrijednost prikazano je izrazom (5-23).

$$V_n^{\min} \leq V_{n,p,t} \leq V_n^{\max},\ \forall n \in N,\ \forall t \in T \tag{5-23}$$

gdje su:

$V_{n,p,t}$ [p.u.] – iznos napona čvora n faze p u trenutku t

$V_n^{\min}$ [p.u.] – minimalni dozvoljeni iznos napona čvora n

$V_n^{\max}$ [p.u.] – maximalni dozvoljeni iznos napona čvora n.

Za sve grane distribucijske mreže l definira se dozvoljeno strujno opterećenje prema izrazu (5-24).

$$I_{l,p,t} \leq I_l^{\text{nom}},\ \forall l \in L,\ \forall p \in P,\ \forall t \in T \tag{5-24}$$

gdje su:

$I_{l,p,t}$ [A] – iznos struje kroz granu (vod, kabel) l faze p u trenutku t

I_l^{nom} [A] – nazivna struja grane (vod, kabel) l.

Faktor naponske nesimetrije ograničen je s obzirom dozvoljeni prema izrazu (5-25).

$$VUF_{n,t} \leq VUF^{\text{per}},\ \forall n \in N,\ \forall t \in T \tag{5-25}$$

gdje su:

$VUF_{n,t}$ [%] – faktor naponske nesimetrije čvora n u trenutku t

VUF^{per} [%] – dozvoljeni faktor naponske nesimetrije.

Ostali elementi aktivne distribucijske mrežee definirani su kao ograničenje opteretivosti prividnom snagom danom izrazom (5-26).

$$S_{e,p,t} \leq \sqrt{P_{e,p,t}^2 + Q_{e,p,t}^2},\ \forall e \in E,\ \forall p \in P,\ \forall t \in T \tag{5-26}$$

$S_{e,p,t}$ [kVA] – prividna snaga kojom element e opterećuje fazu p u trenutku t

$P_{e,p,t}$ [kW] – djelatna snaga kojom element e opterećuje fazu p utrenutku t

$Q_{e,p,t}$ [kVAR] – jalova snaga kojom element e opterećuje fazu p u trenutku t.

5.2.3. Funkcije cilja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže

Kao što je rečeno, ovaj model sastoji se od tri funkcije cilja koje su važne za planiranje i pogon aktivne distribucijske mreže. Prva funkcija cilja predstavlja minimizaciju naponskog odstupanja od referentne vrijednosti za svaku fazu. Funkcija cilja formulirana je prema (5-27).

$$\text{minimiziraj} \sum_{n=1}^{N} \sum_{p=1}^{P} \sum_{t=1}^{t} (V_{n,p,t} - V^{\text{ref}})^2 \tag{5-27}$$

gdje su:

$V_{n,p,t}$ [p.u.] – iznos napona čvora n, faze p u trenutku t

V^{ref} [p.u.] – definirana referentna vrijednost napona.

Druga funkcija cilja predstavlja minimizaciju gubitaka energije modelirane zbrojem gubitaka svake faze. Funkcija cilja minimizacije gubitaka predstavljana je izrazom (5-28).

$$\text{minimiziraj} \sum_{p=1}^{P} \sum_{t=1}^{t} \sqrt{(P_{p,t}{}^{\text{loss}})^2 + (Q_{p,t}^{\text{loss}})^2} \tag{5-28}$$

gdje su:

$P_{p,t}^{\text{loss}}$ [kW] – gubici djelatne snage faze p u trenutku t

$Q_{p,t}^{\text{loss}}$ [kVAR] – gubici jalove snage faze p u trenutku t.

Ukupni gubici djelatne snage svake faze predstavljaju sumu gubitaka svake faze transformatora i vodova danih izrazom (5-29).

$$P_{p,t}^{\text{loss}} = \sum_{p=1}^{P} \sum_{t=1}^{t} P_{ts,p,t}^{\text{loss}} + \sum_{l=1}^{l} \sum_{p=1}^{P} \sum_{t=1}^{t} P_{l,p,t}^{\text{loss}} \tag{5-29}$$

gdje su:

$P_{p,t}^{\text{loss}}$ – gubici djelatne snage faze p u trenutku t

$P_{ts,p,t}^{\text{loss}}$ – gubici djelatne snage transformatora ts, faze p u trenutku t

$P_{l,p,t}^{\text{loss}}$ – gubici djelatne snage grane l, faze p u trenutku t.

Treća funkcija cilja predstavlja minimizaciju faktora naponske nesimetrije. Detaljan opis faktora naponske nesimetrije i matematička formulacija dana je u Poglavlju 3.2. Faktor

naponske nesimetrije modelira se vrijednošću (modulom) bez faznog pomaka za svaki čvor. Prilikom modeliranja dovoljno je uzeti u obzir simetrične komponente i faktor naponske nesimetrije jedne faze. Druge dvije faze imaju istu vrijednost simetričnih komponenti samo im je fazni pomak zakrenut za 120°, odnosno 240° stupnjeva. Funkcija cilja minimizacije faktora naponske nesimetrije prikazana je izrazom (5-30).

$$\text{minimiziraj} \sum_{n=1}^{N} \sum_{t=1}^{t} VUF_{n,t} \tag{5-30}$$

gdje je:

$VUF_{n,t}$ [%] - faktor naponske nesimetrije čvora n u trenutku t.

5.3. Ispitivanje učinaka mehanizama upravljanja na funkcije cilja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže

Kako je spomenuto kosimulacijski model sastoji se od tri funkcije cilja prikazane skupom OF s tri elementa u skupu $OF = \{OF_1, OF_2, OF_3\}$. Svaki kosimulacijski model predstavlja jednociljni optimizacijski problem u kojem je funkcija cilja jedan element (jedna funkcija cilja) koji se nalazi skupu OF. Kada je jedan element skupa OF predstavlja funkciju cilja, tada se druga dva elementa promatraju kao varijable stanja (ovisne varijable). U tom slučaju se ispituje utjecaj jednog elementa na druga dva. Matematički se to može opisati prema izrazu 5-31.

$$\text{Ako je OF}_\text{i} \text{ funkcija cilja,} \tag{5-31a}$$

$$\text{tada su varijable} : V = OF_j \mid j \neq i,\ j \in 1, 2, 3 \tag{5-31b}$$

Drugim riječima promatra se i ispituje utjecaj funkcije cilja na varijable stanja u mreže uzimajući u obzir njihove kombinacije za dobivanje najpovoljnijeg rješenja za pogon aktivne distribucijske mreže. Prilikom pogona mreže operator ima na raspolaganju četiri mehanizma upravljanja, odnosno, implementacijom kosimulacijskog modela omogućeno je korištenje četiri varijabli upravljanja i njihovih kombinacija prikazanih skupom X koji se sastoji od n elemenata $X = \{x_1, x_2, ..., x_n\}$, gdje n predstavlja maksimalni broj varijabli

upravljanja i njihovih kombinacija. Cilj modela je ispitati koje varijable upravljanja daju najpovoljnije iznose funkcije cilja i promatranih varijabli stanja. Blokovska shema s dijagramom toka kosimulacijskog modela s naglašenom metodom za ispitivanje učinaka mehanizama upravljanja prikazana je na Slici 4.2. Na samom početku odabire se funkcija cilja i mehanizam upravljanja te se nakon toga vrši optimizacija na čijem se kraju spremaju iznosi napona, faktora naponske nesimetrije i gubitaka djelatne snage. Nakon toga provjerava se jesu li ispitani svi mehanizmi upravljanja i ako nisu, nastavi se postupak optimizacije s drugim mehanizmom upravljanja, a ako jesu, završi se prvi krug optimizacije i promijeni se funkciju cilja. Postupak se ponavlja dok se ne ispitaju sve funkcije cilja. Stoga će se opisom studija slučaja i scenarija u sljedećem poglavlju biti definirane izvedive kombinacije varijabli upravljanja.

6. Vrednovanje razvijenih optimizacijskih modela za planiranje pogona niskonaponske aktivne distribucijske mreže

U ovom poglavlju opisano je vrednovanje predloženih modeli za planiranje aktivne distribucijske mreže. U prvom dijelu opisane su postavke optimizacijskog okvira i testna mreža dvostupanjskog optimizacijskog modela. Nakon toga definirani su simulacijski slučajevi za testiranje tog modela i analizirani rezultati pojedinog simulacijskog slučaja.

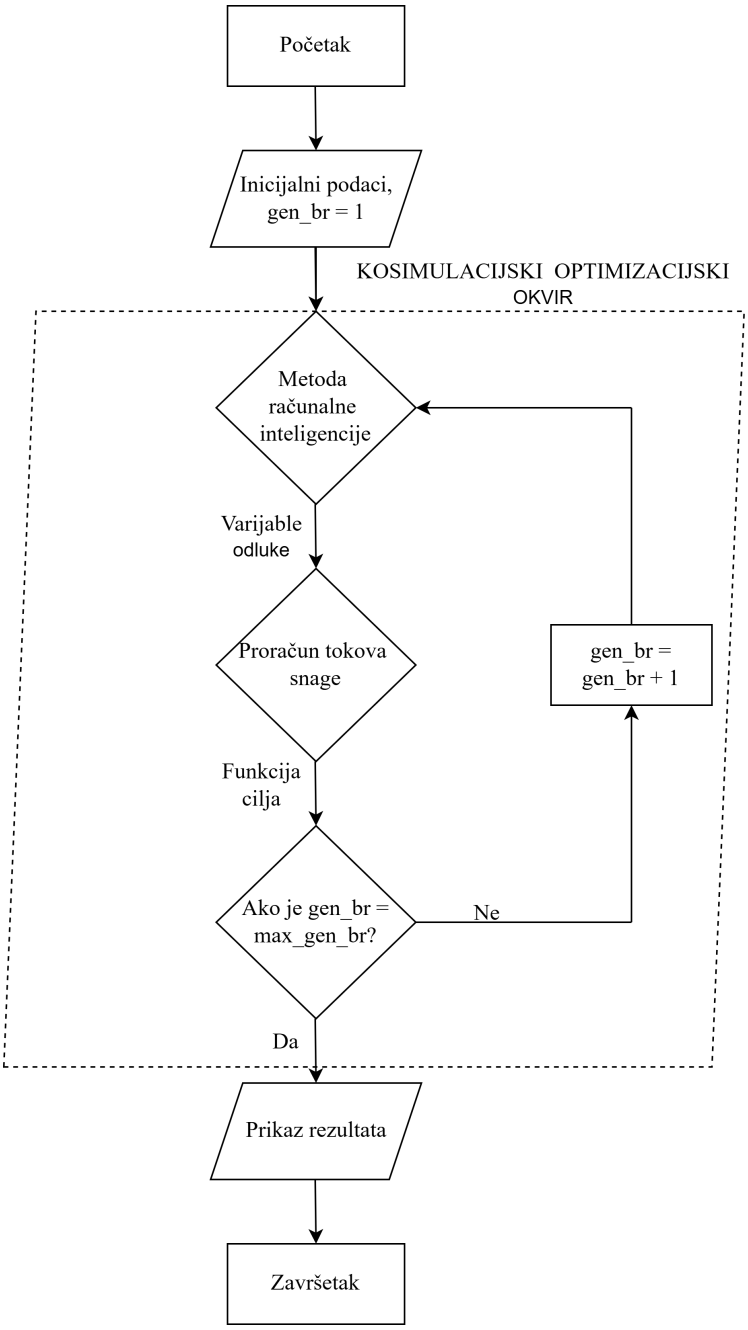
U drugom dijelu opisane su postavke optimizacijskog okvira kosimulacijskog modela kao i testna mreže. Definirani su slučajevi koji ulaze u obzir prilikom ispitivanja metode za vrednovanje učinaka mehanizama upravljanja na tri funkcije cilja važne za planiranje pogona te su naposlijetku prikazani i analizirani dobiveni rezultati.

6.1. Postavke optimizacijskog okvira i optimizacijske metode dvostupanjskog modela

Dvostupanjski model za planiranje pogona aktivne distribucijske mreže odnosi se na kratkoročno planiranje pogona mreže. Prvi stupanj predstavlja planiranje pogona kojim se upravlja konvencionalnim upravljačkim mehanizmom - regulacijskom preklopkom transformatora. Zbog mehaničke prirode preklopke transformatora optimizacija prvog stupnja provodi se za svaki sat unutar promatranog perioda od jednog dana. Dobiveni položaji preklopke transformatora prosljeđuju se drugom stupnju predstavljajući pri tome ulazne parametre drugog stupnja. Optimizacija drugog stupnja provodi se u unutarsatnom periodu za svakih 15 minuta unutar jednog dana. Vremenski korak od 15 minuta koristi se za optimizaciju pogona distribucijskih mreža.

Optimizacijska metoda primjenjena u optimizacijskom problemu planiranja pogona aktivne distribucijske mreže promatra populaciju koja se sastoji od jedinki (čestica). U ovom

doktorskom radu koristi se populacija s 50 jedinki. Broj generacija jedinki odabire se metodom pokušaj i pogreška (*engl. trial and error method*). U ovom slučaju broj generacija jedinki ponavlja se 200 puta u prvom slučaju i 400 puta u svim ostalim slučajevima. Ove karakteristike dobivene su simulacijama koje su ponavljane sve dok funkcija cilja nije konvergirala, to jest dok njezina vrijednost nije značajno promijenila u odnosu na prethodnu iteraciju. Cilj je metode pokušaj i pogreška osigurati minimalnu vrijednost funkcije cilja uz što kraće vrijeme trajanja optimizacijskog postupka. Na odabir broja generacija utječe dimenzija optimizacijskog problema – vremenski korak i broj varijabli upravljanja. Što je dimenzija problema veća, potreban je veći broj generacija jedinki. Pojednostavljeni dijagram toka optimizacijskog modela prikazan je na Slici 6.1.

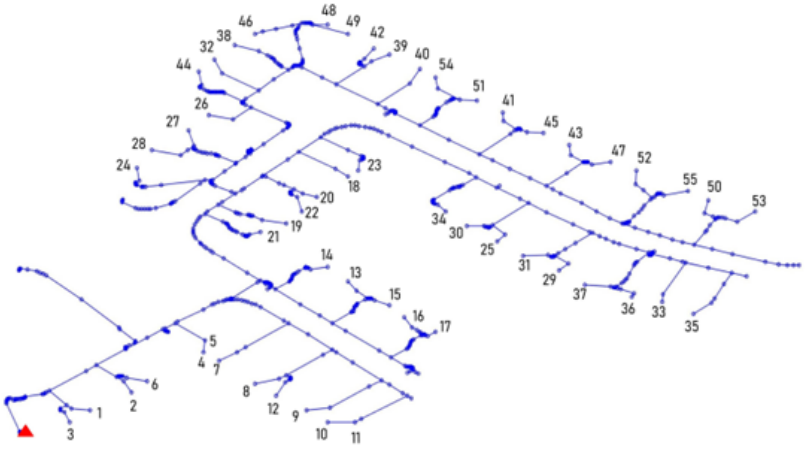


Slika 6.1: *Pojednostavljeni dijagram toka optimizacijskog modela*

6.1.1. Model testnog distribucijskog izvoda

Predloženi dvostupanjski model testiran je na izvodu niskonaponske mreže *IEEE European Low Voltage Test Feeder* (LVTF) [175] izvodu. LVTF predstavlja radijalni izvod s frekvencijom od 50 Hz i iznosom linijskog napona od 0.416 kV, a sa srednjenaponskom mrežom povezan je preko transformatorske stanice TS 11/0.416 kV. Niskonaponski izvod čine jedan transformator, 907 čvorova (sabirnica), 905 vodova i 55 potrošača. Svakom potrošaču dodijeljen je profil opterećenja (potrošnje električne energije) s rezolucijom od 1 minute tijekom

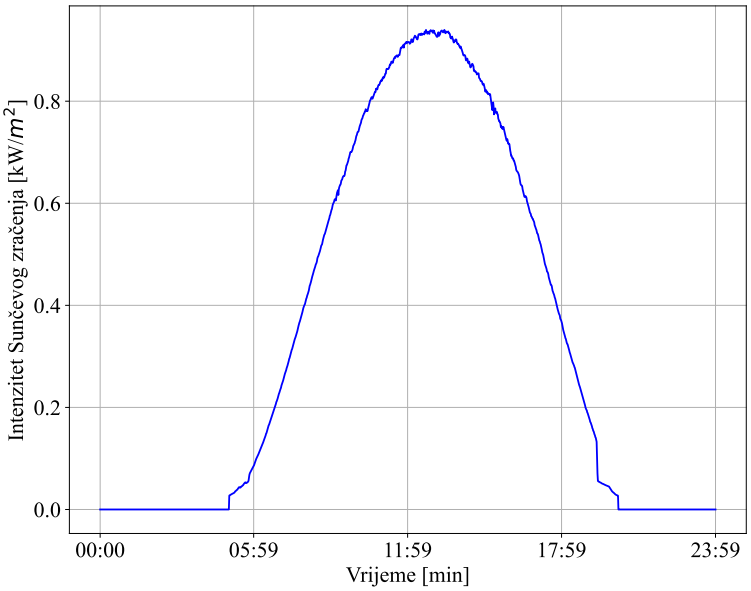
1 dana (1440 točaka podataka). Nadomjesna srednjenaponska mreža modelirana je kao naponski izvor. Referentni čvor regulira napona na 1.02 p.u., dok je početna snaga trofaznog i jednofaznog kratkog spoja postavljena je na 3 MVA. Nazivna snaga transformatora je 0.8 MVA sa spojem namota trokut-uzemljena zvijezda Dyn. Potrošači su modelirani kao konstantna P i Q opterećenja. Za svaki čvor definirano je bazno opterećenje djelatnom snagom i faktorom snage od 0.95 induktivno. Primjer triju profila opterećenja prikazani su u Prilogu P1. Jednofazna shema LVTF prikazana je na Slici 6.2. Trokutom crvene boje označena je TS, dok brojevi predstavljaju čvorove s potrošačima.



Slika 6.2: *Jednofazna shema testne mreže IEEE European Low Voltage Test Feeder*

U ovome doktorskom radu testna mreža je modificirana priključivanjem jednofaznih fotonaponskih elektrana nazivne snage 3.68 kVA. Prema Mrežnim pravilima distribucijskog sustava [176] maksimalna priključna snaga proizvođača s jednofaznim priključkom iznosi 3.68 kW. Nadalje, svako postrojenje i instalacija proizvođača moraju imati mogućnost pogona s faktorom snage od 0.90 induktivno (poduzbuđeno) do 0.90 kapacitivno (naduzbuđeno) [176]. Proizvođači izmjenjivača fotonaponske elektrane također definiraju raspon faktora snage. Prema [177] faktor snage definiran je od 0.80 induktivno do 0.80 kapacitivno.

Ulazni je podatak fotonaponskih elektrana intenzitet Sunčevog zračenja dobiven na temelju mjerenja s rezolucijom od jedne minute tijekom jednog karakterističnog sunčanog (ljetnog) dana (1440 točaka podataka). Intenzitet Sunčevog zračenja prikazan je na Slici 6.3.



Slika 6.3: *Intenzitet Sunčevog zračenja*

6.1.2. Opis simulacijskih slučajeva

Kako se ovaj optimizacijski model za planiranje pogona aktivne distribucijske mreže sastoji od dva optimizacijska stupnja i dvije funkcije cilja, moguće je podijeliti na dvije nezavisne optimizacije i izvršiti analizu svakog stupnja zasebno.

Bazni slučaj (BS) predstavlja slučaj s priključenim jednofaznim fotonaponskim elektranama svakom potrošaču bez uključenog mehanizma upravljanja. Bazni slučaj predstavlja referentni slučaj za usporedbu i analizu s ostalim slučajevima.

1. slučaj (1.S) predstavlja slučaj kada je funkcija cilja minimizacija devijacije napona, a varijabla upravljanja (odluke) je promjena preklopke transformatora. Broj promjena položaja preklopke β ograničen je na 3 promjene tijekom promatranog perioda.

2. slučaj (2.S) predstavlja slučaj kada je funkcija cilja minimizacija gubitaka, dok je varijabla odluke jalova snaga izmjenjivača fotonaponske elektrane. 2. slučaj je podijeljen na dva podslučaja.

U 1. podslučaj (1.PS) izmjenjivač fotonaposke elektrane radi uz dozvoljeni faktor snage definiran mrežnim pravilima od 0.90 induktivno do 0.90 kapacitivno.

U 2. podslučaju (2.PS) tehnologija izmjenjivača izvedena je tako da on može absorbirati i injektirati jalovu snagu neovisno o proizvodnji. U tom slučaju prati se je li u svakom trenutku zadovoljena pogonska karta kako ne bi došlo do narušavanja uvjeta maksimalne

prividne snage.

U 3. slučaju (3.S) testiran je dvostupanjski model koji kombinira 1. i 2. slučaj. Treći slučaj također je podijeljen na dva podslučaja.

U **3. podslučaju (3.PS)** kombiniraju se 1. slučaj i 1. podslučaj.

U **4. podslučaju (4.PS)** kombiniraju se 1. slučaj i 2. podslučaj. Opis ispitanih slučajeva sažet je u Tablici 6.1.

Tablica 6.1: *Opis ispitanih slučajeva.*

Slučajevi	BS	1.S	2.S		3.S	
			1.PS	2.PS	3.PS	4.PS
Bez upravljanja	✓	×	×	×	×	×
Preklopka transformatora	×	✓	×	×	✓	✓
Faktor snage 0.90	×	×	✓	×	✓	×
Puni kapacitet pogonske karte	×	×	×	✓	×	✓

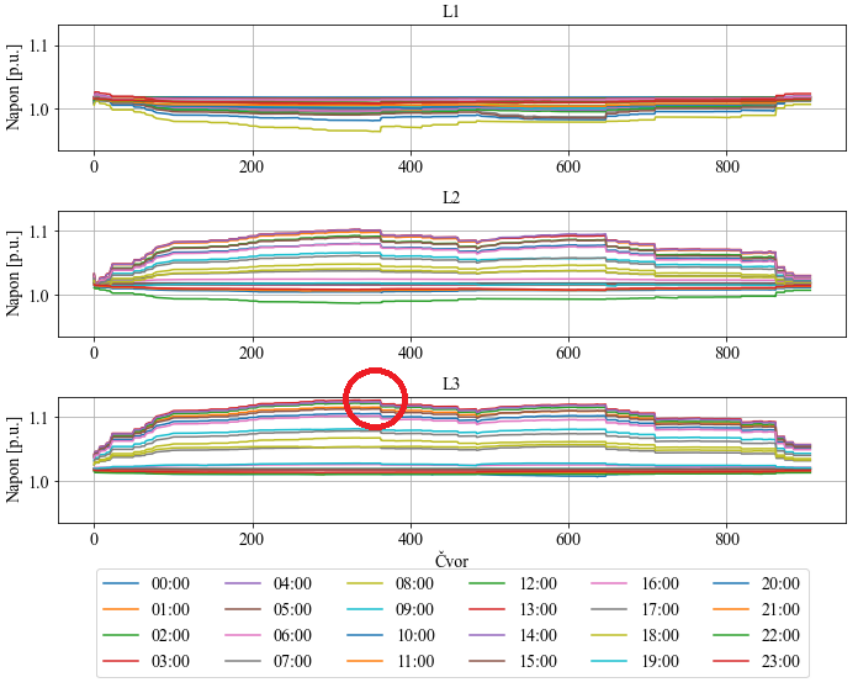
✓uključuje, × isključuje.

6.2. Rezultati dvostupanjskog modela za planiranje pogona aktivne distribucijske mreže

U ovome poglavlju prikazani su rezultati dvostupanjskog modela za planiranje pogona aktivne distribucijske mreže ispitani kroz šest simulacijskih slučajeva. Rezultati provedenih slučajeva mogu biti promatrani s više aspekata, ali u nastavku su uzeti u obzir tehnički aspekti neophodni za vrednovanje ovoga modela, a to su naponi i gubici. Rezultati ovoga poglavlja objavljeni su u [163].

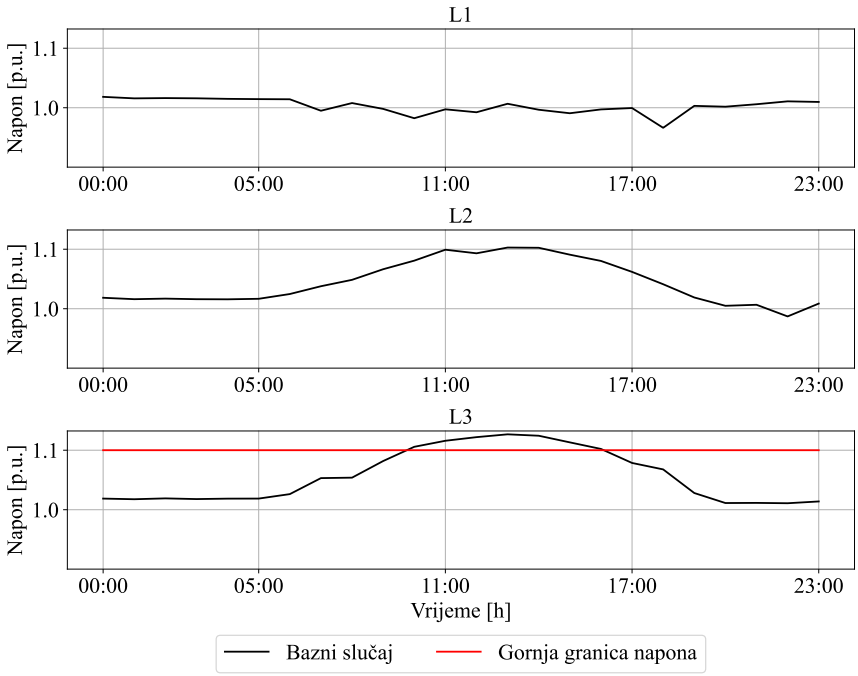
Indikativni prikaz naponskih profila dan je na Slici 6.4. Na slici su prikazani naponski profili svake faze L1, L2 i L3. Na temelju slike može se zaključiti da je faza L1 najviše opterećena, dok je faza L3 najmanje, što ukazuje na nesimetričnost mreže. Priključivanjem fotonaponske elektrane u najopterećeniju fazu L1 rezultira malom razlikom između proizvodnje i potrošnje i reduciranim tokovima snaga iz mreže i u mrežu. Na to ukazuju naponski profili faze L1 koji predstavljaju gotovo ravnu liniju i, uspoređujući ih s naponskim profilima faza L2 i L3, imaju najmanju devijaciju napona u odnosu na referentnu vrijednost. Suprotno fazi L1 faze L2 i L3 slabo su opetrećene te priključivanjem fotonaponske elektrane dolazi do povećanja tokova snaga u mrežu. Rezultat toga je povećanje napona iznad dozvoljene granice od 10 % nazivnog napona i veća devijacija napona u odnosu na referentnu vrijednost. Područje najvišeg iznosa napona označeno je crvenom bojom.

Budući da se testna mreža sastoji od 906 čvorova, za daljnju analizu odredit će se najkritičniji čvor na temelju iznosa napona u tom čvoru. Najkritičniji čvor predstavlja čvor s najvišim iznosom napona i prilikom daljnje analize označavat će referencu za sve ostale čvorove u sustavu, omogućavajući normalizaciju naponskih vrijednosti i olakšavajući analizu čitave mreže.



Slika 6.4: *Indikativni prikaz naponskog profila svakog čvora*

Kao najkritičniji čvor u sustavu identificiran je čvor 336, pri čemu napon u fazi L3 iznosi 1.13 *p.u.* Naponski profil ovog čvora prikazan je na Slici 6.5. Kod čvora 336 specifično je što je faza L1 određena samo opterećenjem i naponi se nalaze unutar granica. Naponi faze L2 i L3 u nekim dijelovima promatranog perioda prelaze dozvoljenu gornju granicu označenu crvenom linijom. U fazi L3 porast napona iznad dozvoljene granice je između 10:00 i 16:00 sati, dok je taj porast u fazi L2 vidljiv od 13:00 do 14:00 sati.



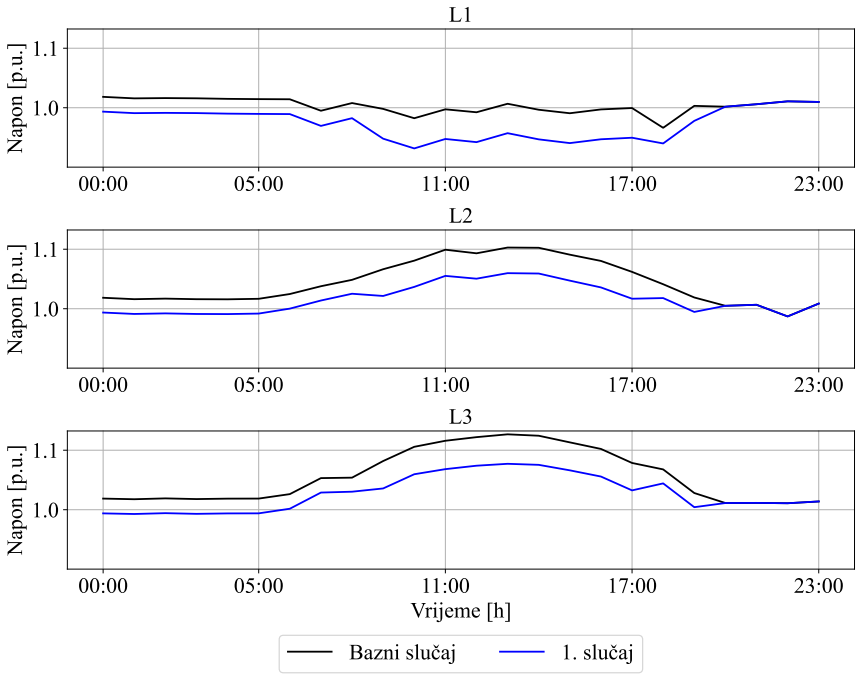
Slika 6.5: *Napon na čvoru 336 u Baznom slučaju*

Tablica 6.2 prikazuje rezultate dvostupanjskog modela za planiranje pogona aktivne distribucijske mreže dobivene optimizacijom. Tablica obuhvaća vrijednosti funkcije cilja. U prvom slučaju vrijednost je izražena u p.u. jedinicama i predstavlja ukupnu devijaciju napona u mreži dobivenu nakon optimizacije. Prilikom korištenja dvostupanjskg modela vrijednost funkcije cilja prvog stupnja je konstantna, stoga se u tablici nalazi vrijednost drugog stupnja u kVA kada je funkcija cilja minimizacija gubitaka.

Tablica 6.2: *Iznos funkcije cilja u ispitanim slučajevima.*

Slučajevi	BS	1.S	2.S		3.S	
			1.PS	2.PS	3.PS	4.PS
Iznos funkcije cilja	-	601.49 p.u.	723.32 kVA	262.80 kVA	731.81 kVA	270.09 kVA

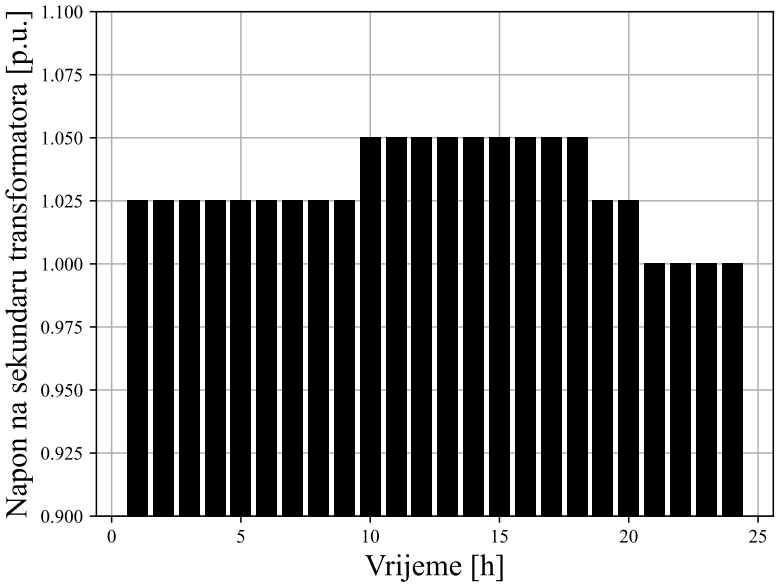
Napon na čvoru 336 u Baznom i prvom slučaju prikazan je na Slici 6.8. Porast je napona u fazama L1 i L2 reduciran i naponi su unutar dozvoljenih granica. Budući da preklopka transformatora jednako djeluje na napone svih triju faza, naponi u fazi L1 također su reducirani iako se u referentnom slučaju nalaze unutar dozvoljenih granica. Iako u fazi L1 dolazi do povećanja naponske devijacije u odnosu na referentnu vrijednost, a funkcija cilja uključuje ukupnu naponsku devijacija svih triju faza, ona je reducirana. Razlog tomu je što je u fazama L2 i L3 došlo do značajnijeg smanjenja naponske devijacije.



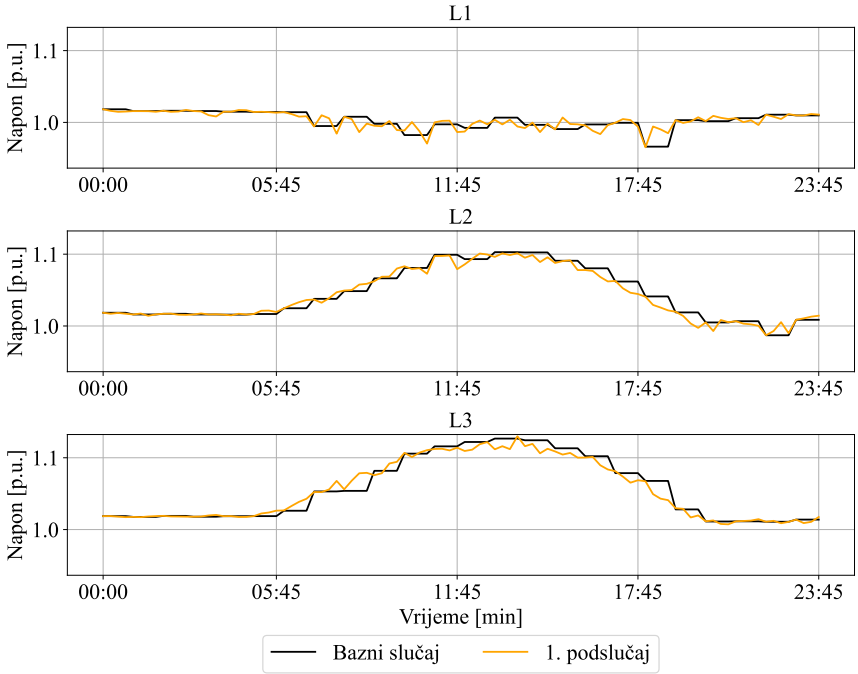
Slika 6.6: *Napon na čvoru 336 u Baznom slučaju i 1. slučaju*

Napon na sekundaru transformatora prikazan je na Slici 6.7. Zbog ograničenog broja promjene preklopke došlo je do tri promjene tijekom perioda od 24 sata. Kako se može vidjeti sa slike, napon na sekundaru se do 9:00 održavao na vrijednosti od 1.025 p.u. U 10:00 došlo je do prve promjene položaja na dolje održavajući pri tome napon sekundara na 1.05 p.u. Druga promjena nastupa u 19:00 i napon se održava na vrijednosti 1.025 p.u. Posljednja promjena događa se u 21:00 i napon sekundara se održava na 1.00 p.u.

Napon na čvoru 336 u Baznom slučaju i 2. podslučaju kada je faktor snage prema mrežnim pravilima ograničen od 0.90 induktivno do 0.90 kapacitivno prikazan je na Slici 6.8. U ovom slučaju vidljiv je potencijal korištenja jalove snage za upravljanje naponskim prilikama. Međutim, ograničenje faktora snage na 0.90 ne omogućava dovoljnu količinu jalove snage za smanjenje nedozvoljenog porasta napona. Na slici je također uočljiv rad izmjenjivača u oba režima (induktivnog i kapacitivnog). Kapacitivan režim rada vidljiv je u fazi L1 kada u dijelovima promatranog perioda dolazi do povišenja napona u odnosu na Bazni slučaj. Induktivan režim rada vidljiv je u fazama L2 i L3 kada dolazi do smanjenja napona u odnosu na Bazni slučaj.



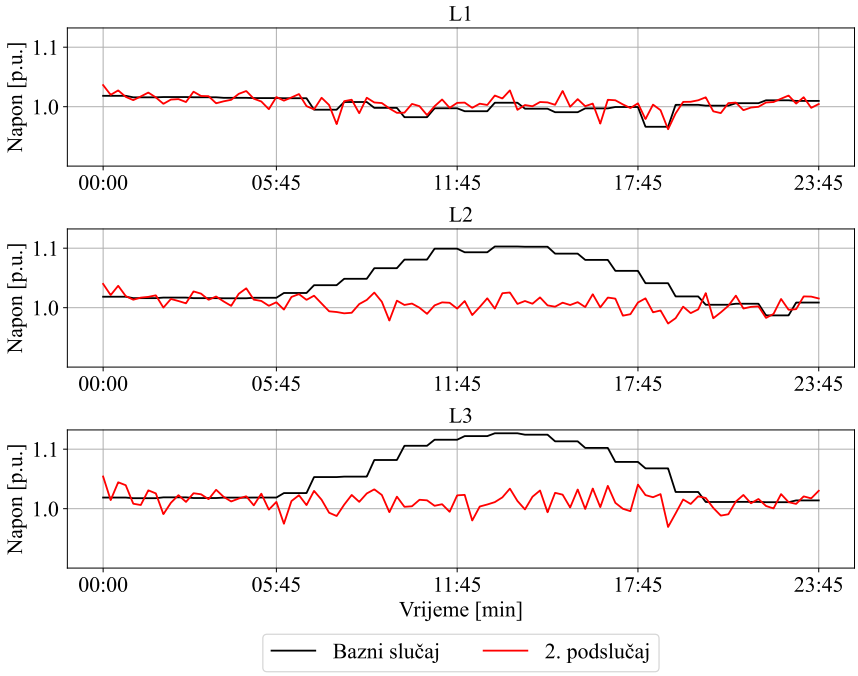
Slika 6.7: *Napon na sekundaru transformatora u 1. slučaju*



Slika 6.8: *Napon na čvoru 336 u Baznom slučaju i 1. podslučaju*

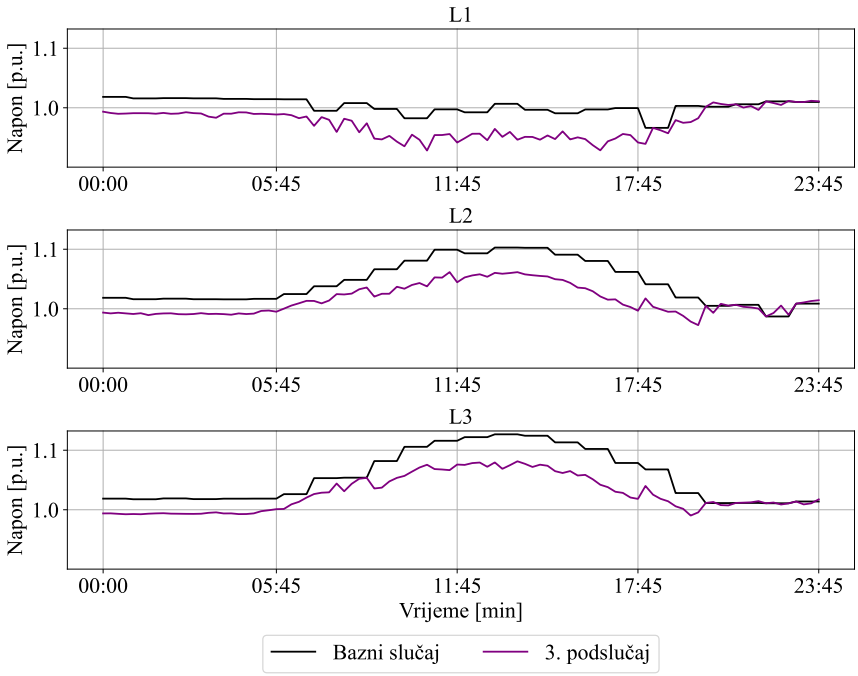
Napon na čvoru 336 u Baznom slučaju i 2. podslučaju prikazan je na Slici 6.9. Uzimajući u obzir mogućnosti upravljanja jalovom snagom u vrijeme kada nema proizvodnje, može se uočiti njena učinkovitost u reduciranju napona održavajući ga vrlo blizu vrijednosti na referentnom čvoru. U ovome podslučaju vidljiva je mogućnost rada izmjenjivača od induktivnog do kapacitivnog podižući napon faze L1 prema referentnoj vrijednosti kao i njegov potencijal

za upravljanje naponskim prilikama.



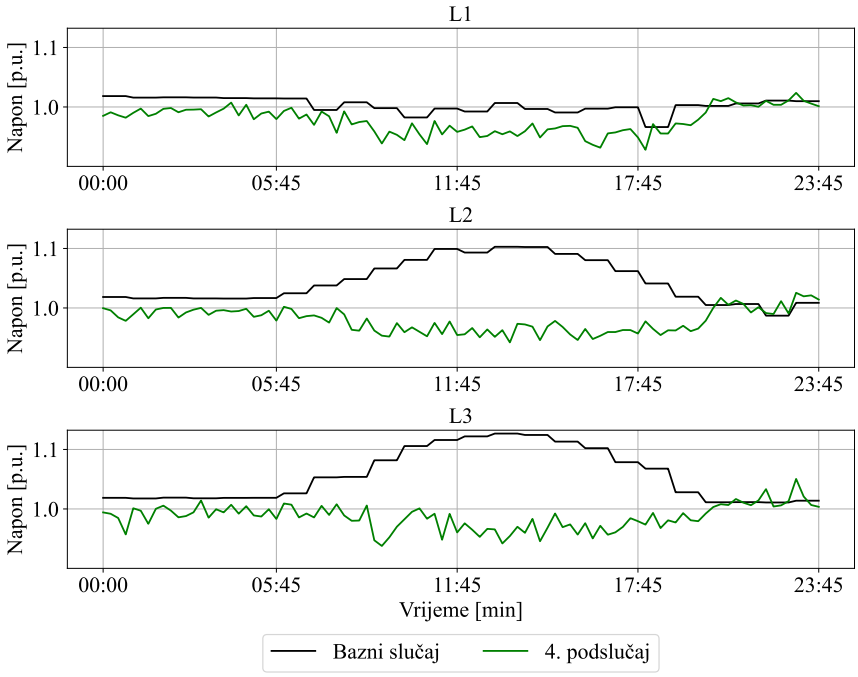
Slika 6.9: *Napon na čvoru 336 u Baznom slučaju i 2. podslučaju*

Napon na čvoru 336 u Baznom slučaju i 3. podslučaju prikazan je na Slici 6.10. Naponi su reducirani i nalaze se unutar dozvoljene granice zbog djelovanja preklopke transformatora u prvom stupnju. Kao u u 1. podslučaju ograničena količina jalove snage je nedovoljna za poticanje većih poboljšanja naponskih prilika u mreži.



Slika 6.10: *Napon na čvoru 336 u Baznom slučaju i 3. podslučaju*

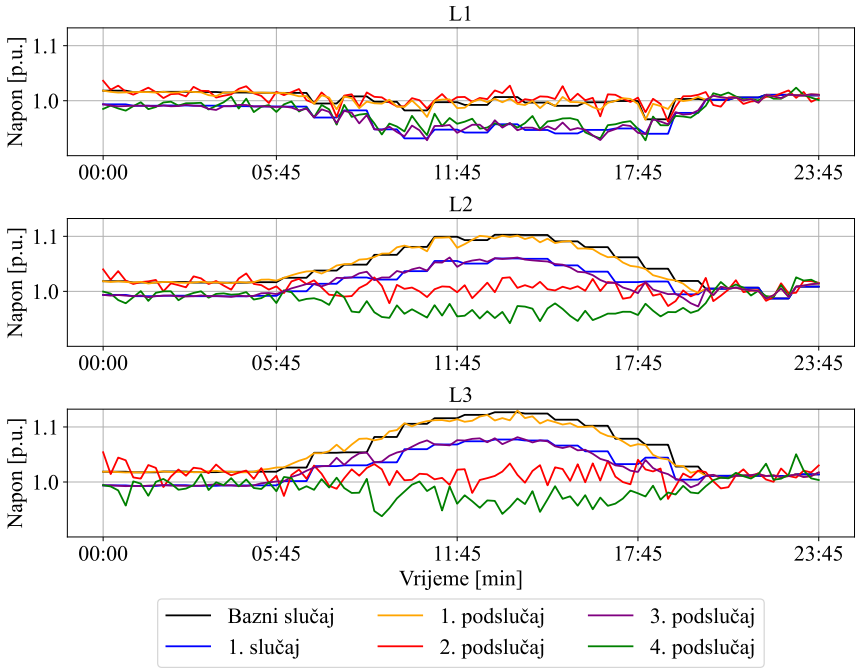
Napon na čvoru 336 u Baznom slučaju i 4. podslučaju prikazan je na Slici 6.11.



Slika 6.11: *Napon na čvoru 336 u Baznom slučaju i 4. podslučaju*

Kako je prikazano na Slici 6.3 najveći intenzitet sunčevog zračenja javlja se oko podneva. Suprotno tomu najveće opterećenje tijekom dana može se očekivati tijekom kasnog poslijepodneva i večernjih sati kako je vidljivo na slikama u Prilogu P1. Kako se proizvod-

nja i potrošnja ne preklapaju u tim periodima, dolazi do povećanja tokova snaga u mrežu uzrokujući pri tome porast napona na čvorovima. Kako je porast napona identificiran kao jedan od ključnih problema u slabo opterećenim mrežama, iznosi napona su detaljno analizirani. U Baznom slučaju može se uočiti različita opterećenost po fazama što definira mrežu nesimetričnom. Različito opterećenje faza uzrokuje varijacije u ponašanju napona prilikom integracije fotonaponske elektrane. Opterećenija faza L1 ne pokazuje značajnu devijaciju napona, dok faze L2 i L3 su slabo opterećene i u njima dolazi do značajnog porasta napona, a u nekim dijelovima dana prelazi dozvoljenu vrijednost. S obzirom na najvišu vrijednost napona odabire se najkritičniji čvor koji se analizira prezentirajući tako ponašanje ostalih čvorova u mreži. Na Slici 6.12 prikazan je napon na čvoru 336 u provedenim simulacijskim slučajevima. U Baznom slučaju vidljivo je da konvencionalni mehanizam upravljanja učinkovito upravlja naponskim prilikama održavajući ih unutar dozvoljenih granica. Ograničavanjem faktora snage prema mrežnim pravilima pokazuje potencijal u području upravljanja naponskim prilikama. U 1. i 3. podslučaju događaju se male promjene napona zbog nedovoljno jalove snage iz izmjenjivača. Međutim, zbog mogućnosti rada od induktivnog do kapacitivnog u promatranim razdobljima podiže i spušta napon nastojeći ga poravnati s referentnom vrijednosti. U 2. i 4. podslučaju učinkovito se reducira napon.



Slika 6.12: *Usporedba napona u svim slučajevima na čvoru 336*

Dobiveni gubici i maksimalne vrijednosti napona sumirani su u Tablica 6.3. Iz tablice

se može uočiti da se promjenom položaja regulacijske preklopke transformatora uspješno regulira napon, međutim, vidljiv je blagi porast gubitaka u mreži. Promjenom preklopke transformatora na niži položaj smanjuje se napon na sekundaru transformatora. Smanjenje napona na sekundaru rezultira porastom struje i posljedično većim gubicima u mreži. Upravljanjem jalovom snagom izmjenjivača postiže se smanjenje gubitaka u mreži i predstavlja obećavajuće rješenje za operatora distribucijske mreže. Pružanjem takve usluge mogu se ostvariti dobiti s obje strane – operatora sustava i vlasnika fotonaponske elektrane. Međutim, kompenzacija takvih vrsta usluga danas nije definirana, ali istraživanjima i pokazivanjem potencijala mogu doprinijeti njenom definiranju u bliskoj budućnosti.

Maksimalne se vrijednosti napona u gotovo svim slučajevima nalaze unutar dozvoljenih granica, osim u 1. podslučaju gdje se upravljanjem naponom na temelju dosadašnjih mrežnih pravila ne može ostvariti zadovoljavajući pogon mreže.

Tablica 6.3: *Gubici djelatne energije i maksimalne vrijednosti napona u svakom simulacijskom slučaju.*

Slučajevi	BS	1.S	2.S		3.S	
			1.PS	2.PS	3.PS	4.PS
Gubici djelatne energije [kWh]	645.53	652.52	632.23	181.94	642.84	187.09
Promjena u odnosu na BS [%]	-	−1.08	2.06	71.82	0.42	71.01
Maksimalni iznos napona [p.u.]	1.13	1.07	1.13	1.05	1.08	1.05

6.3. Metoda za vrednovanje učinaka mehanizma upravljanja na funkcije cilja kosimulacijskog modela

Kosimulacijski model za planiranje pogona aktivne distribucijske mreže uključuje tri funkcije cilja: minimizaciju devijacije napona, minimizaciju gubitaka djelatne snage i minimizaciju faktora naponske nesimetrije. U sklopu modela dani su na raspolaganje različiti mehanizmi upravljanja: promjena preklopke transformatora, upravljanje djelatnom i jalovom snagom izmjenjivača fotonaponske elektrane i upravljanje snagom punjenja električnog vozila. Za svaku funkciju cilja ispituju se različiti mehanizmi upravljanja i njihove kombinacije. Optimizacija se provodi unutar promatranoga perioda od 1 dana s vremenskim korakom od 15 minuta koji se koristi za optimizaciju distribucijskih mreža. U slučaju kada se kao mehanizam upravljanja koristi promjena preklopke transformatora, tada se optimizacija provodi za svaki sat. U ovome optimizacijskom modelu period od jednog dana pomaknut

za šest sati, odnosno, optimizacija kreće u 6:00 sati i završava se drugi dan u isto vrijeme kako bi se obuhvatio period dana i noći.

Kao i kod prethodnog modela, primjenjena optimizacijska metoda promatra populaciju koja se sastoji od jedinki (čestica) čiji je broj postavljen na 50. Broj generacija jedinki kao u prethodnom primjeru odabire se metodom pokušaj i progreška. Uključivanjem različitog broja varijabli upravljanja povećava se dimenzija optimizacijskog problema. Proces pronalaska rješenja ponavlja se ovisno o dimenziji problema. Za probleme u kojima se koristi jedan mehanizam upravljanja broj generacija jedinki je 200, dok za probleme koji uključuju sve mehanizme upravljanja broj generacija je 1400.

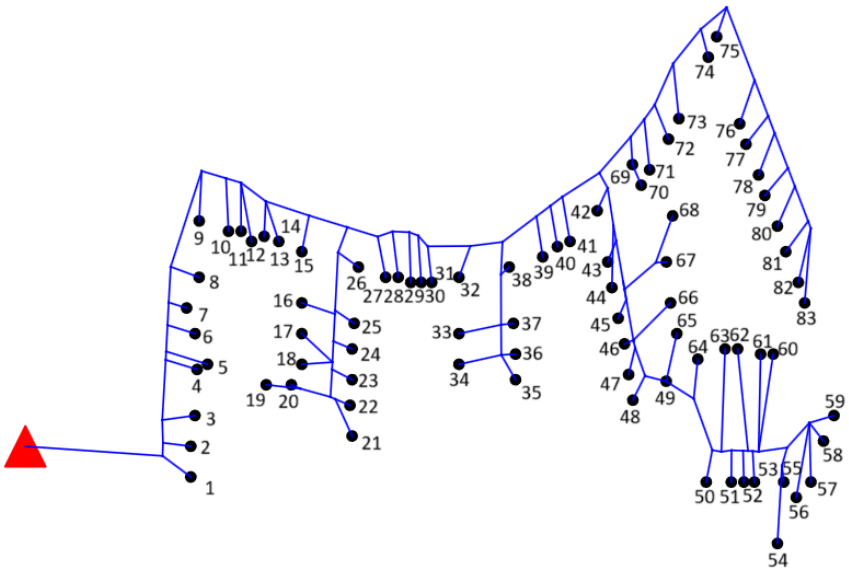
6.3.1. Model distribucijskog izvoda temeljen na javno dostupnim i stvarnim podacima

Predloženi kosimulacijski model testiran je na niskonaponskom izvodu [178]. U nedostatku realnih podataka o parametrima niskonaponske distribucijske mreže, uz ovaj model je razvijeno još 25 modela kroz projekt *Electricity North West* [178]. Promatrani izvod jedan je od tri izvoda napajanih iz TS 10/0.4 kV s frekvencijom od 50 Hz. Nazivna snaga transformatora je 0.8 MVA sa spojem namota trokut-zvijezda Dy. Izvod se sastoji od 1 transformatora, 159 čvorova, 157 vodova i 83 potrošača. Svaki potrošač ima definiram profil potrošnje s rezolucijom od 5 minuta. Potrošači su povezani u distribucijsku mrežu putem jednofaznog priključka. Primjer profila potrošnje dan je u Prilogu P3. Nadomjesna srednjenaponska mreža modelirana je kao kruta mreža. Na Slici 6.13 prikazana je jednofazna shema korištenog distribucijskog izvoda. Točkama su označeni potrošači, dok je crvenim trokutom označena TS.

Svaki potrošač ima integriranu fotonaponsku elektranu s različitim profilima proizvodnje čija je maksimalna snaga u rasponu od 2.50 do 3.68 kW. Razmještaj vozila unutar promatranog testnog izvoda modeliran je pomoću neprekidne uniformne razdiobe. Električna vozila se pune maksimalnom snagom od 3.68 kW. Primjeri profila proizvodnje, potrošnje i punjenja električnog vozila dani su u Prilogu P2, P3, P4.

6.3.2. Opis provedenih simulacijskih slučajeva

Za svaku od funkcija cilja ispitani su dostupni mehanizmi upravljanja i njihove kombinacije. Tablica 6.4 daje opsežan prikaz ispitanih simulacijskih slučajeva. Svaki slučaj za



Slika 6.13: *Model distribucijskog izvoda korištenog za testiranje kosimulacijskog modela*

sebe predstavlja jedan optimizacijski problem. Prilikom odabira mehanizama upravljanja korištena je binarna logika (svaki element može biti uključen i isključen) što rezultira s 15 mogućih kombinacija ($2^n - 1$, kada je n = 4) za svaku funkciju cilja. Osim mogućih kombinacija mehanizama upravljanja u tablici su prikazane funkcije cilje i promatrane varijable stanja.

Upravljački mehanizmi i njihova ograničenja matematički su modelirani u Poglavlju 5.2. Broj promjena preklopke β, kao i u prethodnom modelu, ograničen je na tri promjene tijekom promatranog perioda. Upravljanje jalovom snagom izmjenjivača fotonaponske elektrane definirano je mrežnim pravilima od 0.90 induktivno do 0.90 kapacitivno te je time definirana njegova mogućnost za upravljanje jalovom snagom u ispitanim slučajevima u kojima se takav način upravljanja koristi. Ograničenja smanjivanja djelatne snage izmjenjivača fotonaponske elektrane nije definirano Mrežnim pravilima distribucijskog sustava. Međutim, u Mrežnim pravilima prijenosnog sustava [179] postoje posebni uvjeti za priključenje vjetroelektrana u kojima se usred poremećenog pogona mreže po nalogu operatora može postaviti referentna vrijednost proizvodnje djelatne snage. Operator ima mogućnost postavljanja referentne vrijednosti na dva načina smanjivanjem proizvodnje od po 10 % trenutne snage proizvodnje do potpuno smanjivanja proizovdnje ili postavljanjem slobodne vrijednosti proizvodnje. Budući da trenutno nema jasne definicije ograničenja smanjivanja djelatne snage u Mrežnim pravilima distribucijskog sustava, a pretpostavka je da će ovakav način upravljanja biti značajan

za pogon distribucijske mreže (zbog omjera R/X), potrebno ga je uzeti u obzir prilikom planiranja pogona. Kako je cilj ovog doktorskog rada ispitati sve mogućnosti koje operator ima na raspolaganju, u sklopu ovoga doktorskog rada u optimizacijskom modelu definirano je da varijabla odluke može biti u intervalu od 0 do trenutne snage. Važno je naglasiti da korištenoj optimizacijskoj metodi nije moguće definirati kriterij zaustavljanja (*engl. stopping criterion*) ograničavajući iznos funkcije cilja, varijable odluke ili ograničenja na kojima bi došlo do zaustavljanje optimizacijskog postupka. Kako za upravljive potrošače poput električnog vozila ne postoje dodatni uvjeti za priljučenje na mrežu definirani mrežnim pravilima u slučaju poremećnog pogona mreže, ograničenje za smanjivanje snage punjenja izvedeno je na isti način kao i smanjivanje djelatne snage izmjenivača fotonaponske elektrane.

Tablica 6.4: *Provedeni simulacijski slučajevi.*

Mehanizam upravljanja	**Gubici [kWh]**	**Napon [p.u.]**	**VUF [%]**
PT	F V V	V F V	V V F
FN APC	F V V	V F V	V V F
FN RPC	F V V	V F V	V V F
EV APC	F V V	V F V	V V F
PT + FN APC	F V V	V F V	V V F
PT + FN RPC	F V V	V F V	V V F
PT+ EV APC	F V V	V F V	V V F
FN APC + FN RPC	F V V	V F V	V V F
FN APC + EV APC	F V V	V F V	V V F
FN RPC + EV APC	F V V	V F V	V V F
PT + FN APC + FN RPC	F V V	V F V	V V F
PT + FN APC + EV APC	F V V	V F V	V V F
PT + FN RPC + EV APC	F V V	V F V	V V F
FN APC + FN RPC + EV APC	F V V	V F V	V V F
PT+ FN APC + FN RPC + EV APC	F V V	V F V	V V F

PT - regulacijska preklopka transformatora, FN APC - upravljanje djelatnom snagom izmjenjivača fotonaponske elektrane, FN RPC - upravljanje jalovom snagom izmjenjivača fotonaponske elektrane, EV APC - upravljanje snagom punjenja električnog vozila, F - funkcija cilja, V - varijabla stanja

6.4. Rezultati ispitivanja učinaka mehanizama upravljanja na funkcije cilja minimizaciju djelatnih gubitaka, minimizaciju devijacije napona i minimizaciju faktora naponske nesimetrije kosimulacijskog modela

U ovome poglavlju prikazani su rezultati ispitivanja učinaka mehanizama upravljanja na funkcije minimizaciju djelatnih gubitaka, minimizaciju devijacije napona i minimizaciju faktora naponske nesimetrije kosimulacijskog modela. U prvom dijelu tablično su prikazane vrijednosti funkcije cilja i maksimalne i/ili minimalne vrijednosti varijabli stanja te je dodan komentar za svaki ispitani slučaj. Komentar se odnosi na to je li optimizacijski problem izvediv ili neizvediv. Ako je optimizacijski problem izvediv, to znači da su za određenu funkciju cilja ispoštovana sva ograničenja, to jest da je optimizacijskom metodom dobiveno rješenje. U suprotnom optimizacijski problem je neizvediv. U tablice se unose krajnje vrijednosti kao referenca, jer ako krajnje vrijednosti zadovoljavaju, ostale vrijednosti se nalaze iznad/ispod krajnjih. U drugom dijelu napravljena je detaljnija grafička analiza odabranih slučajeva.

Tablica 6.5 prikazuje vrijednosti gubitaka djelatne snage, napona i faktora naponske nesimetrije prije optimizacije. Iz tablice je jasno vidljivo da iznosi napona i faktora naponske nesimetrije prelaze dozvoljene granice definirane mrežnim pravilima distribucijskog sustava i normom koja definira kvalitetu napona u javnim distribucijskih mrežama. Ovaj ispitani simulacijski slučaj predstavlja referentni (bazni) slučaj za sve ostale simulacijske slučajeve.

Tablica 6.5: *Vrijednosti gubitaka djelatne snage, napona i faktora naponske nesimetrije prije optimizacije.*

Gubici [kWh]	**Maks. napon [p.u]**	**Min. napon [p.u.]**	**VUF [%]**
164.98	1.19	0.85	2.41

Tablica 6.6 prikazuje iznos funkcije cilja i varijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija gubitaka. Funkcija cilja pri svakoj iteraciji se penalizira množenjem s 10000 dok/ako se ne zadovolje sva ograničenja. Na temelju dobivenih rezultata može se zaključiti da ni u jednom slučaju kada je primijenjena samo jedna varijabla upravljanja (mehanizam upravljanja) nije moguće zadovoljiti sva ograničenja, odnosno optimizacijski problem je neizvediv. To se očituje funkcijom cilja koja poprima vrijednost reda veličine od 10^{11} do 10^{15}. Iako uporaba većine mehanizama upravljanja pri funkciji cilja minimizacije gubitaka rezultira neizvedivim rješenjem, analizom dobivenih vrijednosti

varijabli stanja moguće je izvesti određene zaključke.

Važno je naglasiti da funkcija cilja, iako se mjeri na temelju fizikalnih veličina, ne predstavlja direktnu fizikalnu veličinu, već je ona njezin matematički pokazatelj, odnosno vrijednost funkcije cilja je sintetički pokazatelj promatrane fizikalne veličine te nije u izravnoj vezi s fizikalnim modelom sustava.

Promjenom položaja regulacijske preklopke transformatora pri funkciji cilja minimizacije gubitaka nije moguće zadovoljiti sve uvjete (ograničenja) mreže. Regulacijskom preklopkom moguće je samo upravljati naponskim prilikama u mreži (regulacijska preklopka diže iznose napona kako bi se smanjila struja, a posljedično tome i gubici). Maksimalni iznos napona izreguliran je u slučajevima kada je mehanizam upravljanja djelatna snaga izmjenjivača fotonaponskih elektrana, dok je ovako definiran mogući iznos jalove snage nedovoljan da bi se iznos napona smanjio unutar dozvoljene granice. Minimalni iznos napona uspješno se regulira upravljanjem snagom punjenja električnog vozila i promjenom preklopke transformatora.

Može se uočiti negativna korelacija između upravljanja jalovom snagom i faktora naponske nesimetrije pri funkciji cilja minimizacija gubitaka. Upravljanjem isključivo jalovom snagom izmjenjivača fotonaponskih elektrana dovodi do povećanja faktora naponske nesimetrije od 29.46 % u odnosu na referentnu vrijednost. To se također očituje pri kombinaciji upravljanja jalovom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila gdje dolazi do povećanja od 27.41 % u odnosu na referentnu vrijednost. Iz dobivenih rezultata može se uvidjeti da se pri upravljanju jalovom snagom i kombinacijama s jalovom snagom dodatno opterećuju čvorišta rezultirajući povećanjem faktora naponske nesimetrije. Ograničenje faktora snage na 0.90 ukazuje na nedostatnost jalove snage za učinkovito upravljanje i optimizaciju pogona aktivne distribucijske mreže što je posebice uočljivo kod maksimalnog iznosa napona. Zbog nedostatnosti i mrežnih ograničenja povezanih s upravljanjem jalovom snagom izvedivo rješenje optimizacijskog problema postignuto je kombiniranim upravljanjem djelatnom snagom izmjenjivača fotonaponske elektrane i snagom punjenja električnog vozila. U tom slučaju proizvodnja fotonaponskih elektrana reducirana je na 1746.30 kW, odnosno za 77.12 % u odnosu na referentnu vrijednost koja iznosi 7631.62 kW. Snaga punjenja reducirana je na 641.02 kW, odnosno za 81.83 % u odnosu na referentnu vrijednost koja iznosi 3528.20 kW. U tom slučaju faktor naponske nesimetrije iznosi 0.53 %, te je reduciran za 78.01 % u odnosu na referentnu vrijednost.

Izvedivo rješenje dobiveno je i kombinacijom upravljanja regulacijskom preklopkom, djelatnom snagom izmjenjivača fotonaponske elektrane i snagom punjenja električnog vozila. U tom slučaju regulacijska preklopka održava napon na sekundaru transformatora na 0.95 p.u. tijekom promatranog perioda, osim u zadnjem satu kada je iznos napona na sekundaru 1.05 p.u. Ukupna proizvodnja fotonaponskih elektrana u tom slučaju je reducirana na 2097.74 kW, odnosno 72.51 % u odnosu na referentnu vrijednost. Snaga punjenja električnih vozila iznosi 1049.14 kW, što predstavlja smanjenje od 70.26 % u odnosu na referentnu vrijednost. U promatranom slučaju faktor naponske nesimetrije je reduciran 67.22 % u odnosu na referentnu vrijednost.

Može se uočiti da je pri kombinaciji upravljanja regulacijskom preklopkom transformatora, jalovom snagom izmjenjivača fotonaponskih elektrana i snage punjenja električnih vozila riješen problem preniskog napona i faktora naponske nesimetrije, dok problem previsokog napona nije, čineći optimizacijski problem neizvedivim za dobivanje rješenja.

Izvedivo rješenje dobije se i pri kombinaciji upravljanja djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana te snagom punjenja električnog vozila. Najniža vrijednost funkcije cilja dobivena je u ovom slučaju. Iznos ukupne djelatne snage koju izmjenjivač daje u mrežu u tom slučaju reduciran je s 7631.62 kW na 1743.23 kW, odnosno 77.16 %. Iznos apsolutne vrijednosti jalove snage izmjenjivača u tom slučaju je 2819.93 kVAR. Važno je naglasiti da se uzima u obzir apsolutna vrijednost zbog induktivnog i kapacitivnog načina rada definiranog suprotnim predznacima. Snaga punjenja električnog vozila u tom slučaju svedena je na minimum. U ovom slučaju faktor naponske nesimetrije ima najnižu vrijednost, smanjenu za 80.91 % u odnosu na referentnu vrijednost.

Kombinacijom svih dostupnih mehanizama upravljanja također je dobiveno izvedivo rješnje kada je funkciji cilja minimizacija gubitaka. Regulacijskom preklopkom transformatora napon se, kao i u primjeru s djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila, održava na 0.95 p.u. tijekom promatranog vremena, osim u zadnjem satu kada je napon sekundara 1.05 p.u. Djelatna snaga fotonaponskih elektrana reducirana je za 76.09 % u odnosu na referentnu vrijednost. Jalova snaga u tom slučaju iznosi 2943.58 kVAR. Naponska nesimetrije reducirana je za 74.69 %.

Tablica 6.6: *Iznos funkcije cilja i varijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija gubitaka.*

Mehanizam upravljanja	**Iznos funkcije cilja [kVAh]**	**Maks/Min napon [p.u.]**	**VUF [%]**	**Komentar**
PT	$2.43 \cdot 10^{15}$	1.22/0.92	2.11	Neizvedivo
FN APC	$1.94 \cdot 10^{15}$	1.06/0.85	2.41	Nezvedivo
FN RPC	$7.23 \cdot 10^{15}$	1.13/0.85	3.12	Nezvedivo
EV APC	$8.44 \cdot 10^{15}$	1.19/0.93	2.31	Neizvedivo
PT + FN APC	$1.39 \cdot 10^{15}$	1.11/0.91	2.11	Neizvedivo
PT + FN RPC	$6.78 \cdot 10^{15}$	1.17/0.91	3.25	Neizvedivo
PT + EV APC	$7.72 \cdot 10^{15}$	1.23/0.94	2.14	Neizvedivo
FN APC + FN RPC	$1.57 \cdot 10^{15}$	1.06/0.85	2.41	Neizvedivo
FN APC + EV APC	142.53	1.01/0.97	0.53	Izvedivo
FN RPC + EV APC	$8.44 \cdot 10^{15}$	1.13/0.97	3.32	Neizvedivo
PT + FN APC + FN RPC	$1.42 \cdot 10^{15}$	1.11/0.91	2.11	Neizvedivo
PT + FN APC + EV APC	339.99	1.09/0.93	0.79	Izvedivo
PT + FN RPC + EV APC	$5.71 \cdot 10^{11}$	1.21/0.93	1.99	Neizvedivo
FN RPC + FN APC + EV APC	113.07	1.01/0.97	0.46	Izvedivo
PT + FN APC + FN RPC + EV APC	143.24	1.06/0.93	0.61	Izvedivo

Tablica 6.7 prikazuje iznos funkcije cilja i vrijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija devijacije napona. Kao i u slučaju kada je funkcija cilja minimizacija gubitaka, izvedivo rješenje ne može se ostvariti isključivo jednim mehanizmom upravljanja. Kada je mehanizam upravljanja kombinacija djelatne snage izmjenjivača fotonaponskih elektrana i snage punjenja električnih vozila, njihova kombinacija s regulacijskom preklopkom i jalovom snagom izmjenjivača fotonaponskih elektrana i kombinacija svih dostupnih mehanizama upravljanja dobije se izvedivo rješenje optimizacijskog problema. U svim ostalim slučajevima dobije se neizvedivo rješenje. To se očituje iznosima funkcije cilja reda veličine od 10^{11} do 10^{15}. Kao i u slučaju kada je funkcija cilja minimizacija gubitaka, iako primjena različitih mehanizama upravljanja ne rezultira uvijek izvedivim rješenjem, moguće je provesti analizu i izvesti općenite zaključke o utjecaju različitih mehanizama upravljanja kada je funkcija cilja minimizacija devijacije napona.

U usporedbi s referentnim slučajem, u kojem gubici djelatne snage iznose 164.98 kWh, pri optimizaciji funkcije cilja minimizacije devijacije napona, najmanje smanjenje gubitaka postiže se kada se pojedinačno primjenjuje samo regulacijska preklopka transformatora, jalova snaga izmjenjivača fotonaponskih elektrana ili upravljanje snagom punjenja električnih vozila. Najmanji gubici djelatne snage ostvaruju se kada je mehanizam upravljanja temeljen na kombinaciji djelatne snage izmjenjivača fotonaponskih elektrana i snage za punjenje električnih vozila što rezultira smanjenjem od 96.31 % u odnosu na referentnu vrijednost. Najniža vrijednost funkcije cilja (najmanja devijacija napona) dobivena je upravljanjem djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Taj je rezultat postignut smanjenjem struje koju fotonaponske elektrane ubrizgavaju u mrežu, kao i struje koju punjači električnih vozila povlače iz mreže, čime se dodatno smanjuje strujno opterećenje uzrokovano aktivnim kupcima.

U niskonaponskim distribucijskim mrežama s visokim R/X omjerom, promjene u djelatnoj snazi snažnije utječu na naponski profil što se može uočiti prilikom istovremenog upravljanja djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Faktor je naponske nesimetrije u tom slučaju reduciran za 77.17 % u odnosu na referentni slučaj. Ukupni iznos djelatne snage fotonaponskih elektrana pri takvoj kombinaciji upravljačkih mehanizama je 1859.85 kW, što je smanjenje od 75.63 % u odnosu na referentnu vrijednost od 7631.62 kW. Snaga punjenja električnih vozila reducirana je na 1023.21 kW, odnosno za 71 % u odnosu na referentu vrijednost od 3528.20 kW.

Kombinacijom upravljanja regulacijskom preklopkom transformatora, djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila dobiveno je izvedivo rješenje. U ovom slučaju došlo je do tri promjene položaja regulacijske preklopke tijekom promatranog perioda. Djelatna snaga koju proizvode fotonaponske elektrane iznosi 3026.83 kW, što je smanjenje od 60.33 % u odnosu na referentnu vrijednost. Snaga punjenja reducirana je na 1462.26 kW, to jest 58.56 % u odnosu na referentnu vrijednost snage punjenja. Faktor naponske nesimetrije iznosi 0.96 %, što predstavlja smanjenje od 60.17 % u odnosu na referentnu vrijednost.

Izvedivo rješenje dobiveno je i upravljanjem kombinacijom djelatne i jalove snage izmjenjivača fotonaponskih elektrana i snage punjenja električničnih vozila. Djelatna snaga izmjenjivača fotonaponskih elektrana reducirana je na 2690.72 kW, to jest 64.74 % u odnosu na početnu vrijednost. Apsolutna vrijednost jalove snage izmjenjivača fotonaponskih elektrana u tom slučaju iznosi 3302.93 kVAR. Snaga punjenja je maksimalno reducirana. Faktor naponske nesimetrije iznosi 1.52 % što je smanjenje od 36.93 % u odnosu na referentnu vrijednost. Može se uočiti da je faktor naponske nesimetrije većeg iznosa u odnosu kada se upravljanje vrši samo djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Taj porast uzrokovan je jalovom snagom izmjenjivača fotonaponskih elektrana.

Kombinacijom upravljanja jalovom snagom izmjenjivača fotonaponske elektrane i punjenjem električnog vozila maksimalni iznosi napona nalaze se unutar dozvoljenih granica (maksimalni iznos napona je 1.09, dok je minimalni iznos napona 0.95). U ovom slučaju faktor naponske nesimetrije raste te je kao i kod primjera kada je funkcija cilja minimizacija gubitaka prikazana negativna korelacija između jalove snage i faktora naponske nesimetrije kada je on promatran kao varijabla stanja. Porast naponske nesimetrije vidljiv je i pri samostalnom korištenju jalove snage kao upravljačkog mehanizma. U takvom slučaju neujednačene raspodjele fotonaponskih elektrana po fazama uz dodatno opterećenje mreže jalovom snagom rezultira povećanjem naponske nesimetrije u mreži. Također, pri kombinaciji upravljanja djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana i upravljanja snagom punjenja električnih vozila faktora naponske nesimetrije veći je u usporedbi s upravljanjem djelatnom snagom izmjenjivača i snagom punjenja. Može se uočiti da upravljanje kombinacijom regulacijske preklopke transformatora, jalove snage izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila naponi se nalaze unutar dozvoljenih

granica (maksimalni napon iznosi 1.09 p.u., dok minimalni iznosi 0.94 p.u.). Međutim, kao i u prethodnim primjerima u kojima se jalova snaga koristi kao mehanizam upravljanja došlo je do povećanja faktora naponske nesimetrije.

Nadovezujući se na slučaj kada je mehanizam upravljanja kombinacija djelatne i jalove snage izmjenjivača fotonaponskih elektrana i snaga punjenja električnih vozila, u slučaju njihove kombinacije s regulacijskom preklopkom transformatora, može se, također, uočiti da je faktor naponske nesimetrije viši u odnosu kada je primjenjeno upravljanje djelatnim snagama. Djelatna snaga je reducirana za 59.68 % u odnosu na referentnu vrijednost. Snaga punjenja je reducirana za 56.88 % u odnosu na referentnu vrijednost. Jalova snaga iznosi 3055.72 kVAR. Došlo je do dvije promjene položaja regulacijske preklopke transformatora u ovom slučaju. U ovome ispitanom slučaju djelatna snaga fotonaponskih elektrana i snaga punjenja električnih vozila su najmanje smanjenje u usporedbi s ostalim ispitanim slučajevima kada je funkcija cilja minimizacija devijacije napona.

Tablica 6.7: *Iznos funkcije cilja i varijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija devijacije napona.*

Mehanizam upravljanja	**Iznos funkcije cilja [p.u.]**	**Gubici [kWh]**	**VUF [%]**	**Komentar**
PT	$3.12 \cdot 10^{14}$	135.73	2.13	Neizvedivo
FN APC	$1.20 \cdot 10^{15}$	97.11	2.41	Nezvedivo
FN RPC	$1.67 \cdot 10^{15}$	150.24	2.47	Nezvedivo
EV APC	$4.65 \cdot 10^{14}$	132.11	2.31	Neizvedivo
PT + FN APC	$9.45 \cdot 10^{14}$	65.58	2.41	Neizvedivo
PT + FN RPC	$2.87 \cdot 10^{19}$	135.58	3.47	Neizvedivo
PT + EV APC	$5.52 \cdot 10^{15}$	115.69	2.39	Neizvedivo
FN APC + FN RPC	$1.16 \cdot 10^{15}$	72.18	2.41	Neizvedivo
FN APC + EV APC	76.16	6.09	0.55	Izvedivo
FN RPC + EV APC	$1.61 \cdot 10^{11}$	83.42	4.11	Neizvedivo
PT + FN APC + FN RPC	$9.54 \cdot 10^{14}$	69.89	2.41	Neizvedivo
PT + FN APC + EV APC	174.04	11.80	0.96	Izvedivo
PT + FN RPC + EV APC	$1.69 \cdot 10^{11}$	79.22	3.82	Neizvedivo
FN RPC + FN APC + EV APC	32.51	6.54	1.52	Izvedivo
PT + FN RPC + FN APC + EV APC	123.06	14.33	1.42	Izvedivo

Tablica 6.8 prikazuje iznos funkcije cilja i vrijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija faktora naponske nesimetrije. Kao i kod prethodne dvije funkcije cilja, jednim mehanizmom upravljanja nije moguće dobiti izvedivo rješenje. Vrijednost je funkcije cilja u tim slučajevima reda veličine od 10^{13} do 10^{17}. Upravljanjem kombinacijom triju mehanizama upravljanja dobiveno je izvedivo rješenje optimizacijskog problema – upravljanjem djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila, njihovom kombinacijom upravljanja s regulacijskom preklopkom transformatora i jalovom snagom izmjenjivača fotonaponskih elektrana. Iako, kao i kod prethodnih funkcija cilja, upravljanjem većinom mehanizama ne ostvaruje se izvedivo rješenje, moguće je donijeti određene zaključke o utjecaju mehanizama upravljanja na funkciju cilja i promatrane varijable stanja.

Gubici djelatne snage najveći su pri upravljanju samo jalovom snagom izmjenjivača fotonaponskih elektrana. Pri tome iznos gubitaka uvećan je za 2.75 % u odnosu na referentnu vrijednost od 164.98 kWh. Gubici su neznačajno reducirani kada su mehanizmi upravljanja regulacijska preklopka transformatora, njezina kombinacija s jalovom snagom izmjenjivača fotonaponskih elektrana i pri kombinaciji upravljanja djelatnom i jalovom snagom izmjenjivača fotonaponski elektrana. U tri izvediva slučaja gubici su reducirani na iznose ispod 15 kWh. Usporedbom s gubicima djelatne snage kada je funkcija cilja minimizacija devijacije može se uočiti da su gubici djelatne snage pri funkciji cilja minimizacije faktora naponske nesimetrije veći.

Maksimalni iznosi napona moguće je izregulirati upravljanjem djelatnom snagom izmjenjivača fotonaponske elektrane i kombinacijom upravljanja djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana. Minimalni iznos napona izreguliran je upravljanjem snagom punjenja električnih vozila i regulacijskom preklopkom transformatora. Također, uočljivo je da su naponi, iako su unutar dozvoljenih granica, višeg iznosa u odnosu na napone kada je funkcija cilja minimizacija gubitaka.

Pri kombinaciji upravljanja jalovom snagom izmjenjivača fotonaponskih elektrana i smanjivanjem snage punjenja električnih vozila maksimalna vrijednost faktora naponske nesimetrije iznosila je 1.20 %, međutim, nisu ispoštovana sva mrežna ograničenja (gornja granica napona, strujno ograničenje grana) pa je optimizacijski problem neizvediv. Usporedno s funkcijama cilja minimizacije gubitaka djelatne snage i devijacije napona u kojima se upravljanjem jalovom snagom fotonaponskog izmjenjivača i njezinom kombinacijom s drugim me-

hanizmima upravljanja faktor naponske nesimetrije povećava, u slučaju kada je funkcija cilja minimizacija faktora naponske nesimetrije, a upravljanje vrši istim mehanizmima ona se smanjuje.

Kada su mehanizmi upravljanja djelatna snaga izmjenjivača fotonaponskih elektrana i snaga punjenja električnih vozila dobiveno je izvedivo rješenje. Djelatna snaga smanjena je za 60.64 % u odnosu na referentnu vrijednost. Snaga punjenja reducirana je za 61.57 % u odnosu na referentnu vrijednost.

Izvedivo rješenje dobiveno je kada je mehanizam upravljanja regulacijska preklopka transformatora, djelatna snaga izmjenjivača fotonaponskih elektrana i snaga punjenja električnih vozila. Pri tome ukupna djelatna snaga fotonaponskih elektrana je 3052.51 kW, što predstavlja smanjenje od 60% u odnosu na referentnu vrijednost. Snaga punjenja električnih vozila smanjena je za 59.64 % u odnosu na referentnu vrijednost. Regulacijska preklopka transformatora u tom slučaju održava napon na sekundaru na 0.95 p.u. većinu promatranog vremena, osim u zadnjem satu kada se napon na sekundaru održava na 1.05 p.u. Kao i u slučaju kada je funkcija cilja minimizacija gubitaka, porastom napona smanjuje se struja i opterećenje mreže rezultirajući smanjenim faktorom naponske nesimetrije.

Kada upravljački mehanizam predstavlja kombinaciju djelatne i jalove snage izmjenjivača fotonaponskih elektrana i snagu punjenja električnog vozila, maksimalna vrijednost faktora naponske nesimetrije iznosi 0.45 %, dok se obje krajnje vrijednosti napona nalaze unutar definiranih granica, a gubici djelatne snage su usporedno s ostalim vrijednostima gubitaka u tablici najmanji (reducirani za 97.92 % u odnosu na referentni slučaj). U tom slučaju ukupan iznos djelatne snage fotonaponskih elektrana nakon smanjivanja proizvodnje je 3491.86 kW (smanjenje od 55.89 % u odnosu na početnu vrijednost koja iznosi 7631.62 kW), dok je apsolutna vrijednost jalove snage 3054.60 kVAR.

Za razliku od prethodne dvije funkcije cilja u slučaju minimizacije faktora naponske nesimetrije kada se upravljanje vrši svim dostupnim mehanizmima nije dobiveno izvedivo rješenje jer nije ispoštovano ograničenje promjena položaja regulacijske preklopke transformatora. Može se primijetiti da se djelatna snaga izmjenjivača fotonaponskih elektrana te snaga punjenja električnih vozila najmanje smanjuju u odnosu na njihova smanjenja koja se pojavljuju kod prethodne dvije funkcije cilja.

Tablica 6.8: *Iznos funkcije cilja i varijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija faktora naponske nesimetrije.*

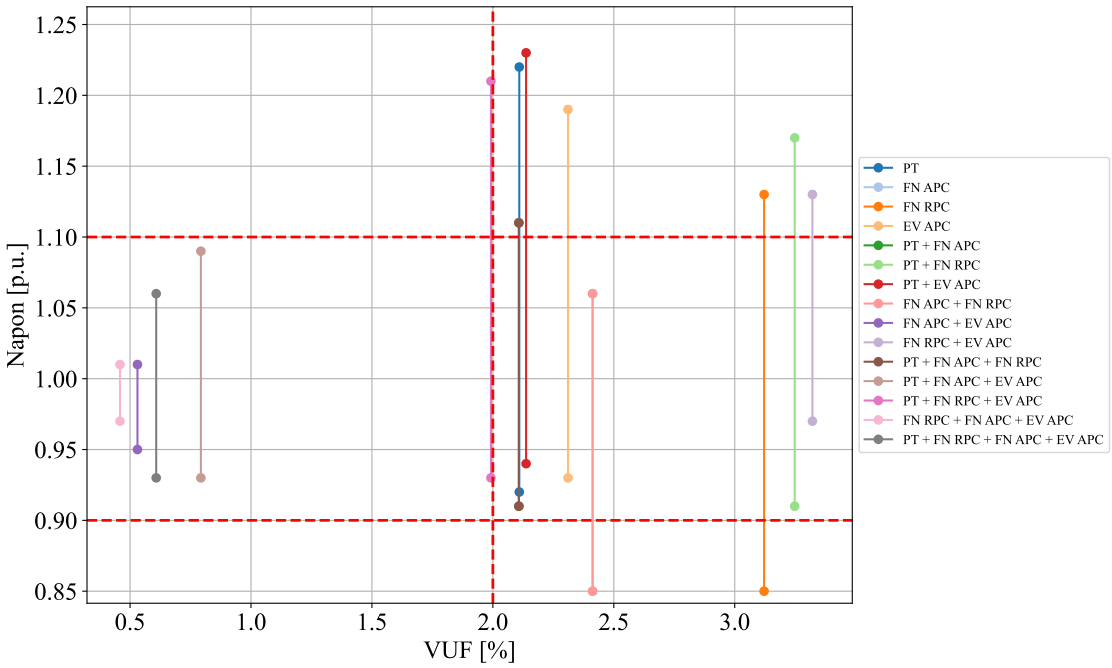
Mehanizam upravljanja	**Iznos funkcije cilja [%]**	**Maks/Min napon [p.u.]**	**Gubici [kWh]**	**Komentar**
PT	$5.53 \cdot 10^{15}$	1.22/0.92	148.71	Neizvedivo
FN APC	$2.33 \cdot 10^{14}$	1.06/0.85	67.74	Nezvedivo
FN RPC	$5.02 \cdot 10^{16}$	1.19/0.85	169.51	Neizvedivo
EV APC	$6.92 \cdot 10^{13}$	1.19/0.93	105.42	Neizvedivo
PT + FN APC	$1.74 \cdot 10^{17}$	1.11/0.91	62.32	Neizvedivo
PT + FN RPC	$6.50 \cdot 10^{19}$	1.18/0.89	114.86	Neizvedivo
PT + EV APC	$6.37 \cdot 10^{17}$	1.23/0.99	96.87	Neizvedivo
FN APC + FN RPC	$1.81 \cdot 10^{17}$	1.07/0.85	78.49	Neizvedivo
FN APC + EV APC	42959.64	1.02/0.94	11.90	Izvedivo
FN RPC + EV APC	$3.20 \cdot 10^{13}$	1.19/0.93	114.28	Neizvedivo
PT + FN APC + FN RPC	$1.66 \cdot 10^{21}$	1.11/0.91	69.69	Neizvedivo
PT + FN APC + EV APC	52089.75	1.09/0.92	14.15	Izvedivo
PT + FN RPC + EV APC	$3.11 \cdot 10^{13}$	1.25/0.99	100.65	Neizvedivo
FN RPC + FN APC + EV APC	40806.17	1.06/0.96	12.61	Izvedivo
PT + FN RPC + FN APC + EV APC	$6.35 \cdot 10^{8}$	1.09/0.93	22.34	Neizvedivo

U nastavku doktorskog rada prikazana je grafička analiza dobivenih rezultata. Detaljna grafička obrada rezultata provedena je u slučaju dobivenog izvedivog rješenja.

Nastavljajući se na Tablicu 6.6, Slika 6.14 prikazuje maksimalni i minimalni iznos napona i faktor naponske nesimetrije kada je funkcija cilja minimizacija gubitaka. Crvenom linijom označene su gornja i donja granica napona definiran mrežnim pravilima i dozvoljena vrijednost faktora naponske nesimetrije definirana normom. Izvedivo rješenje ostvareno je pri četiri kombinacije mehanizama upravljanja – djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila, njihovom kombinacijom s regulacijskom preklopkom transformatora i jalovom snagom izmjenjivača fotonaponskih elektrana i kombinacijom svih dostupnih mehanizama upravljanja. S obzirom na faktor naponske nesimetrije, najveća koncentracija rješenja nalazi se između 2.0 i 2.5 %. Referentna vrijednost faktora naponske nesimetrije je 2.41 % što znači da pri funkciji cilja minimizaciji gubitaka mehanizmi upravljanja nisu imali značajnog učinka na faktor naponske nesimetrije. Najveća koncentracija rješenja s obzirom na faktor naponske nesimetrije javlja se kada su mehanizmi upravljanja promjena položaja regulacijske preklopke transformatora, snaga punjenja električnih vozila, njihova kombinacija, kombinacija djelatne i jalove snage izmjenjivača fotonaponskih elektrana i njihova kombinacija s regulacijskom preklopkom. Faktor naponske nesimetrije nalazi se unutar dozvoljenih granica u slučaju kada je mehanizam upravljanja kombinacija regulacijske preklopke transformatora i djelatna i jalova snaga izmjenjivača fotonaponskih elektrana, ali gornja granica napona (ograničenja) nije ispoštovan čineći optimizacijski problem neizvedivim. U tri slučaja došlo je značajnog povećanja faktora naponske nesimetrije iznad 3.0 % – kada je mehanizam upravljanja jalova snaga izmjenjivača fotonaponskih elektrana, njezina kombinacija s regulacijskom preklopkom transformatora i kombinacija jalove snage izmjenjivača fotonaponskih elektrana i snage punjenja električnih vozila. Kada je funkcija cilja minimizacija gubitaka, nastoji se smanjiti struja u granama i transformatoru. Fotonaponske elektrane injektiraju struju u distribucijsku mrežu koja u uvjetima smanjene proizvodnje uzrokuje povećanje gubitaka. Za punjenje električnih vozila povlači se dodatna struja iz mreže koja uzrokuje povećanje gubitaka. Smanjenjem struje koja se injektira u mrežu i koja se vuče iz mreže smanjuju se i gubici te se izravno smanjuje opterećenje čvora rezultirajući smanjenom faktoru naponske nesimetrije. Jalovom snagom izmjenjivača dodatno se opterećuju čvorovi što rezultira povećanjem faktora naponske nesimetrije. Iako je u tim slučajevima došlo do blagog smanjenja napona, opterećenje čvora jalovom snagom se

dodatno povećalo što dovodi do povećanja faktora naponske nesimetrije.

S obzirom na krajnje vrijednosti napona može se uočiti kako izvedivost optimizacijskog problema ovisi o parametrima mreže. Kako je već navedeno, omjerom R/X karakteriziran je utjecaj mehanizma upravljanja na naponske prilike. Pri korištenju snage punjenja električnih vozila i primjenom regulacijske preklopke transformatora uspješno se regulira problem preniskoga napona. Problem previsokog napona rješen je kada su mehanizmi upravljanja djelatna snaga izmjenjivača fotonaponskih elektrana i kada je ona u kombinaciji s jalovom snagom izmjenjivača fotonaponskih elektrana.



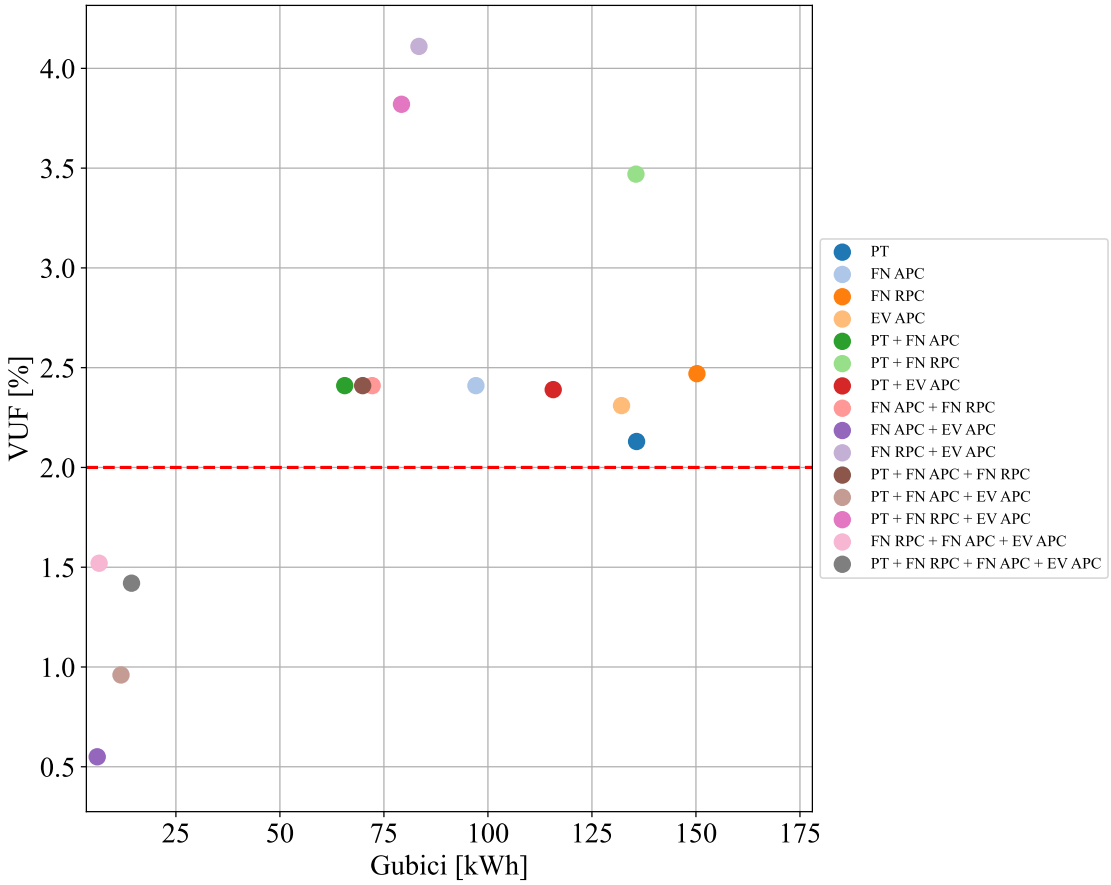
Slika 6.14: *Utjecaj mehanizama upravljanja na funkciju cilja minimizaciju gubitaka*

Slika 6.15 prikazuje maksimalni iznos faktora naponaske nesimetrije i gubitke djelatne snage kada je funkcija cilja minimizacija devijacije napona. Crvenom linijom prikazana je dozvoljena vrijednost faktora naponske nesimetrije. Nastavljajući se na Tablicu 6.7, vidljivo je da se faktor naponske nesimetrije u četiri slučaja nalazi ispod dozvoljene granice – pri upravljanju djelatnom snagom fotonaponskih elektrana i snagom punjenja električnih vozila, njihovom kombinacijom s regulacijskom preklopkom transformatora i kombinacijom s jalovom snagom izmjenjivača fotonaponskih elektrana te kombinacijom dostupnih mehanizama upravljanja. U ta četiri slučaja gubici su djelatne snage manji od 25 kWh. Niti u jednom drugom slučaju nije ispoštovano ograničenje faktora naponske nesimetrije. U tri slučaja faktor naponske nesimetrije se povećao iznad 2.50 % – kombinacijom regulacijske preklopke i jalove snage izmjenjivača, kombinacijom jalove snage izmjenjivača fotonapon-

skih elektrana i snage punjenja električnih vozila te njihovom kombinacijom s regulacijskom preklopkom. Najveća koncentracija rješenja s obzirom na faktor naponske nesimetrije nalaze se u rasponu od 2.0 do 2.5 %. Budući da je referentna vrijednost faktora naponske nesimetrije 2.41 %, može se uočiti su preostali mehanizmi upravljanja i njihove kombinacije vrlo malo utjecali na promjenu faktora naponske nesimetrije. Gubici su u svim slučajevima reducirani u odnosu na referentni slučaj. U slučajevima kada je faktor naponske nesimetrije iznad 2.5 %, jalovom snagom se dodatno opterećuju čvorovi rezultirajući porastom faktora naponske nesimetrije. Međutim, pod djelovanjem drugih mehanizama reduciraju se gubici. Gubici su najveći kada je mehanizam upravljanja jalova snaga izmjenjivača fotonaponskih elektrana.

Funkcija cilja minimizacija devijacije napona, iako često upotrebljena u znanstvenim radovima, pokazuje određene nedostatke prilikom optimizacije pogona. Funkcija cilja u tom obliku ne uzima u obzir važnost čvorova u smislu ne diferencira ozbiljnost devijacije. Na pojedinim čvorovima dolazi do većih odstupanja od referentne vrijednosti napona koja prelaze dozvoljene granice, što dovodi do narušavanja normalnog pogona. Također, postoje i manje devijacije na čvorovima koje ne prelaze dozvoljenu vrijednost, a pri optimizaciji se tretiraju jednako kao i veće devijacije. Postavlja se i pitanje značaja naponskih devijacija za pogon s obzirom na to da su dozvoljene granice napona već definirane mrežnim pravilima i sve vrijednosti unutar tih granica smatraju se zadovoljavajućim za pogon.

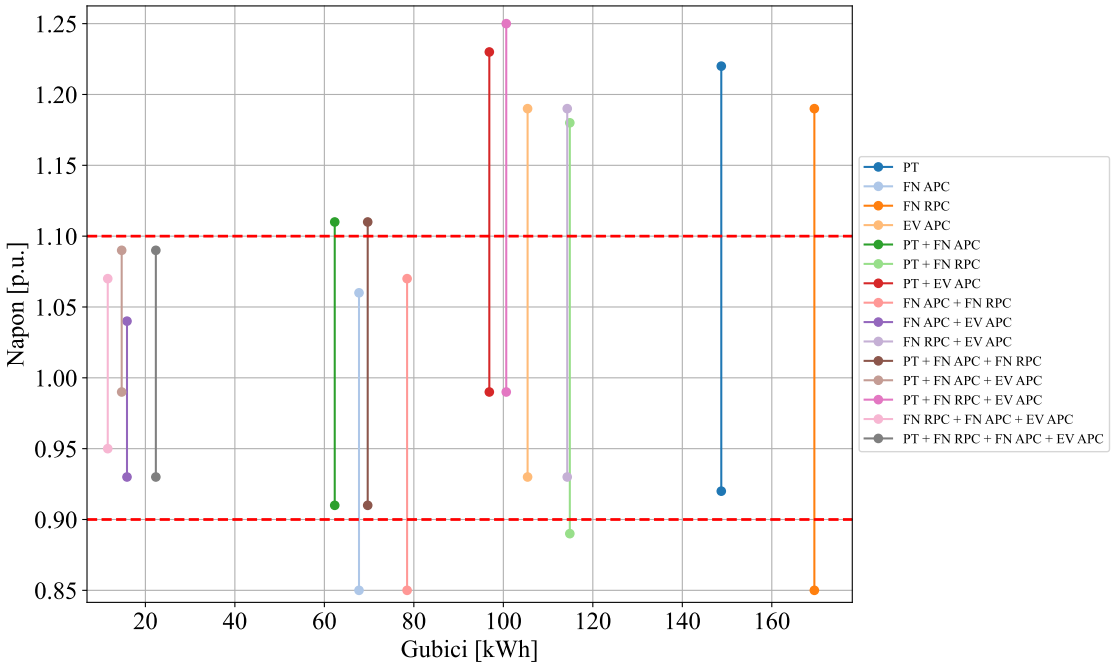
Slika 6.16 prikazuje iznose krajnjih vrijednosti napona i gubitaka kada je funkcija cilja minimizacija faktora naponske nesimetrije. Kako je i prikazano u Tablici 6.8, izvediva rješenja dobivena korištenjem triju mehanizma upravljanja – kombinaciju djelatne snage izmjenjivača fotonaponskih elektrana i snage punjenja električnih vozila, kombinaciju regulacijske preklopke transformatora, djelatne snage izmjenivača fotonaponskih elektrana i snage punjenja električnih vozila te kombinaciju djelatne i jalove snage izmjenjivača fotonaponskih elektrana i snage punjenja električnih vozila. U funkciji cilja minimizaciji faktora naponske nesimetrije, upravljački mehanizam nastoji smanjiti djelatnu snagu izmjenjivača fotonaponskih elektrana isključivo u onim slučajevima u kojima se problem nesimetrije napona pojavljuje. Budući da nesimetrija ne utječe jednako na sve faze, smanjenje snage ne provodi se globalno, već selektivno – samo u mjeri nužnoj za minimizaciju faktora naponske nesimetrije i osiguranje da napon ostane unutar dopuštene gornje granice. Analogna razmatranja mogu se primijeniti pri mehanizmu upravljanja smanjenju punjenja električnih vozila. To rezultira većom



Slika 6.15: *Utjecaj mehanizama upravljanja na funkciju cilja minimizaciju devijacije napona*

devijacijom napona u odnosu na slučajeve kada je funkcija cilja minimizacija gubitaka. Može se uočiti da regulacijska preklopka, bilo samostalno ili u kombinaciji s drugim upravljačkim mehanizmima, učinkovito doprinosi minimizaciji problema preniskog napona. Na temelju toga može se zaključiti da električna vozila u većoj mjeri pridonosi povećanju faktora naponske nesimetrije. Pri mehanizmu upravljanja promjeni položaja regulacijske preklopke transformatora, jalovoj snazi izmjenjivača fotonaponskih elektrana, kombinaciji regualcijske preklopke transformatora i jalove snage izmjenjivača fotonaponskih elektrana te kombinaciji preklopke transformatora, jalove snage izmjenjivača fotonaponskih elektrana i snage punjenja električnih vozila dobiveni su najnepovoljniji iznosi maksimalnog napona, veći i od referetne vrijednosti. Najveća devijacija napona i gubici su pri upravljanju jalovom snagom izmjenjivača fotonaponskih elektrana. Gubici djelatne snage su u izvedivim slučajevima manji od 20 kWh.

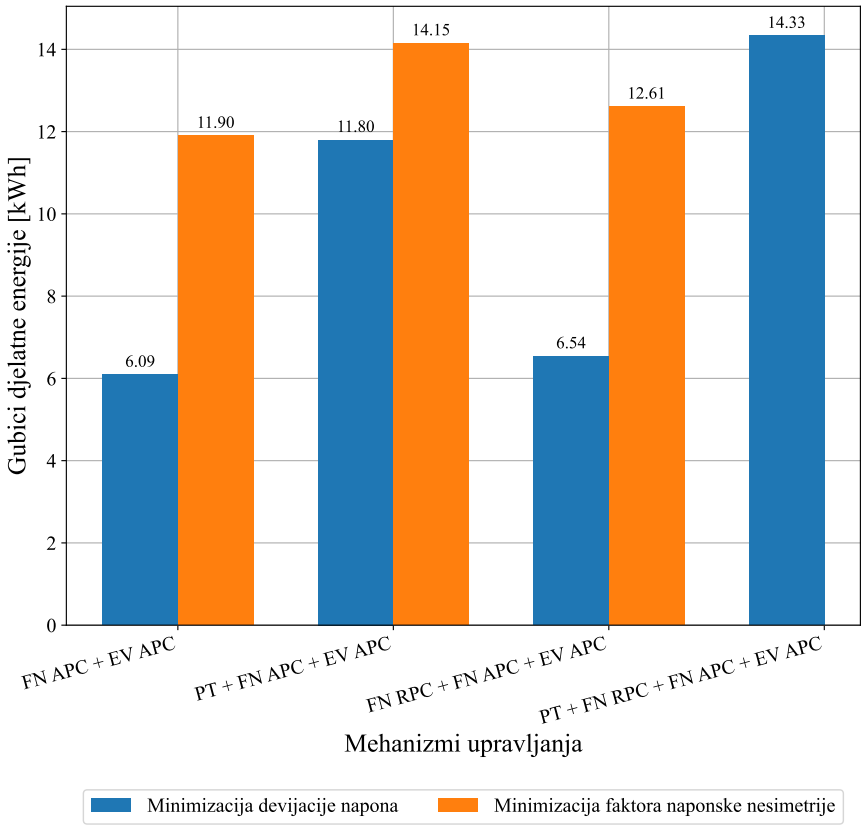
U nastavku su uspoređene vrijednosti promatranih varijabli stanja u izvedivim scenarijima. Na Slici 6.17 prikazan je iznos gubitaka djelatne snage za dvije različite funkcije cilja:



Slika 6.16: *Utjecaj mehanizama upravljanja na funkciju cilja minimizaciju naponske nesimetrije*

minimizaciju devijacije napona te minimizaciju faktora naponske nesimetrije. Općenito se može zaključiti da su gubici djelatne energije značajno manji u slučaju kada je funkcija cilja minimizacija naponske devijacije. Najniža je vrijednost gubitaka u slučaju kada su mehanizmi upravljanja djelatna snaga izmjenjivača fotonaponskih elektrana i snaga punjenja električnih vozila. Ako se uzme u obzir samo funkcija cilja minimizacija faktora naponske nesimetrije, gubici su, također, najmanji u slučaju kada je upravlja djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Smanjujući velike injekcije struje u mrežu nastale zbog utjecaja fotonaponskih elektrana kao i struje potrebne za punjenje električnih vozila, smanjuju se i gubici. Kada je funkcija cilja minimizacija naponskog odstupanja, utječe se na sve fotonaponske elektrane i električna vozila, a kada je funkcija cilja minimizacija faktora naponske nesimetrije, utječe samo na one koji doprinose naponskoj nesimetriji. Uključivanjem regulacijske preklopke transformatora u optimizacijski model, kod obje funkcije cilja, dolazi do povećanja gubitaka djelatne energije u odnosu na scenarije u kojima se ona ne koristi kao upravljački mehanizam, dakle gubici su najveći kada se koriste svi raspoloživi mehanizmi upravljanja.

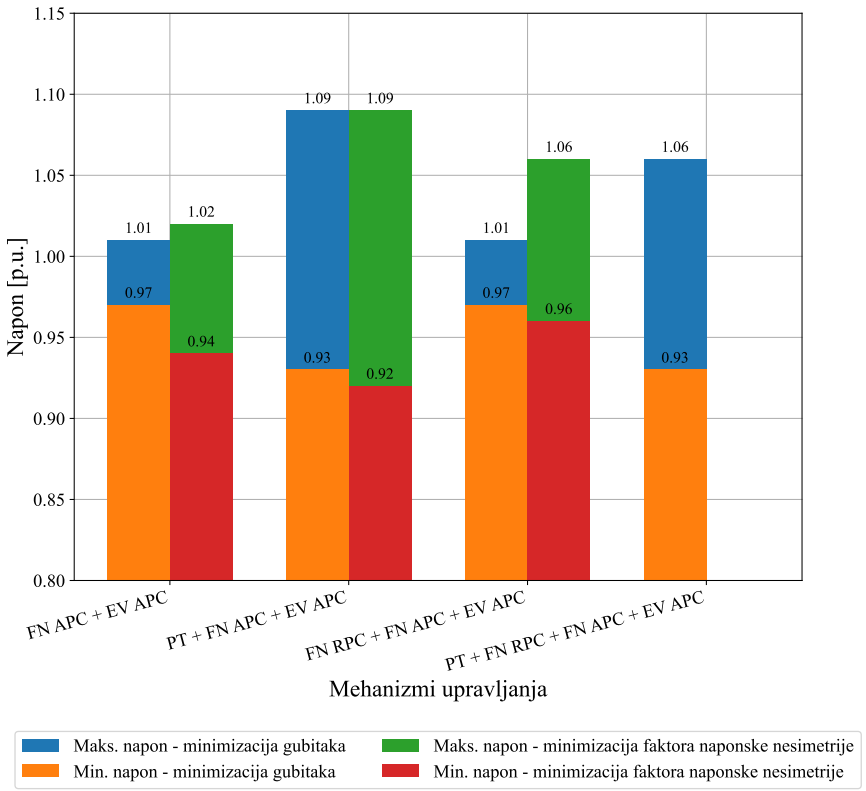
Na slici 6.18 prikazana je usporedba maksimalnih i minimalnih vrijednosti napona za dvije različite funkcije cilja: minimizaciju gubitaka snage i minimizaciju faktora naponske nesimetrije. Najmanja devijacija napona, odnosno najmanja razlika između maksimalnog i



Slika 6.17: *Usporedba iznosa gubitaka kada su funkcije cilja minimizacija devijacije napona i minimizacija faktora naponske nesimetrije*

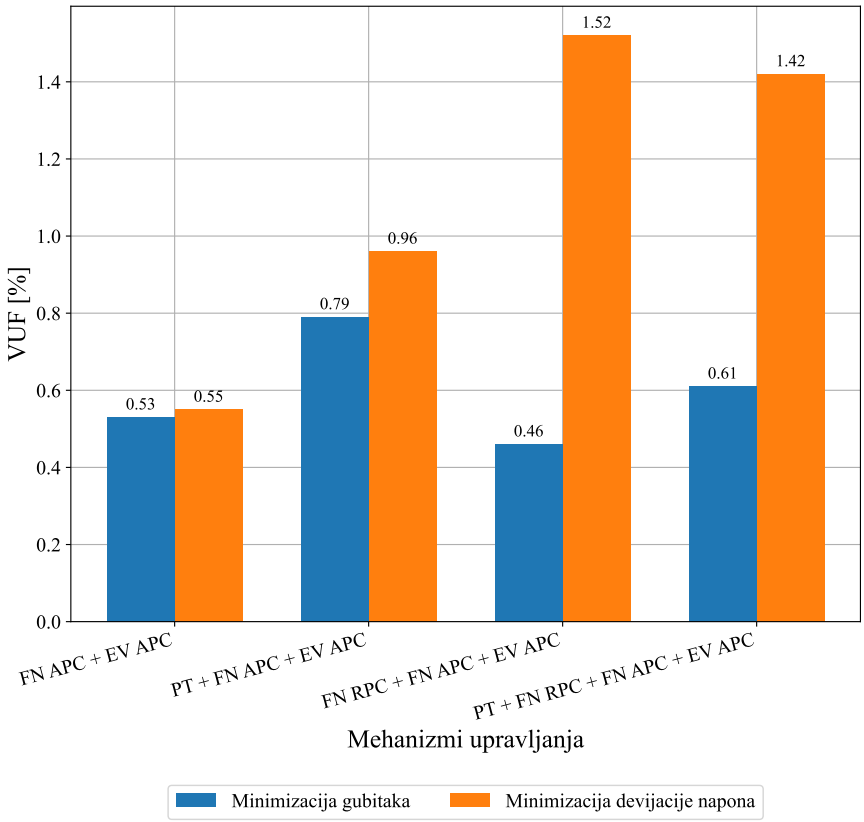
minimalnog napona, ostvarena je u slučajevima kada je funkcija cilja minimizacija gubitaka, uz primjenu upravljačkih mehanizama koji uključuju djelatnu snagu izmjenjivača fotonaponskih elektrana, snagu punjenja električnih vozila te njihovu kombinaciju s jalovom snagom izmjenjivača fotonaponskih elektrana. Dobiveni rezultati jasno ukazuju na značajan utjecaj promjena djelatne snage na iznose napona u niskonaponskoj distribucijskoj mreži, što vrijedi za obje funkcije cilja. Usporedbom rezultata za iste mehanizme upravljanja uočava se da je devijacija napona manja kada je funkcija cilja minimizacija gubitaka. S druge strane, najveće devijacije napona za obje funkcije cilja zabilježene su u slučajevima kada upravljanje uključuje regulacijsku preklopku transformatora, djelatnu snagu izmjenjivača fotonaponskih elektrana i snagu punjenja električnih vozila. U tim slučajevima regulacijska preklopka prilagođava napon na sekundaru transformatora prema vrijednosti od 0.95 p.u. podižući ga u odnosu na najnižu zabilježenu vrijednost kako bi se smanjila struja i rasteretili čvorovi te se potom izravno utječe na pojedinu funkciju cilja promjenom djelatne snage. Značajna razlika u iznosima napona vidljiva je kada su mehanizmi upravljanja djelatna i jalova snaga izmjenjivača fotonaponskih elektrana i snaga punjenja električnih vozila. Tako dobiveno

rješenje može ukazati na povećano opterećivanje čvora jalovom snagom.



Slika 6.18: *Usporedba iznosa maksimalnog i minimalnog napona kada su funkcije cilja minimizacija gubitaka i minimizacija faktora naponske nesimetrije*

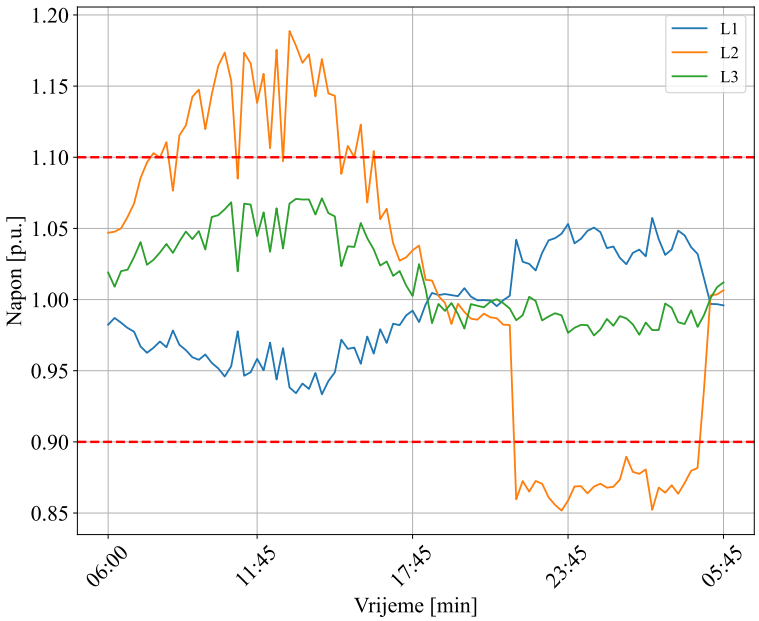
Slika 6.19 prikazuje usporedbu iznosa faktora naponske nesimetrije kada su funkcije cilja minimizacija gubitaka i minimizacija devijacije napona. Kao što je vidljivo, vrijednost faktora naponske nesimetrije značajno je niža u slučajevima kada je funkcija cilja minimizacija gubitaka. Ovaj rezultat može se dovesti u vezu sa smanjenjem opterećenja u granama i čvorovima mreže, čime se uspostavlja korelacija između ovih varijabli. Najniži faktor naponske nesimetrije javlja se u slučaju kada je funkcija cilja minimizacija gubitaka, a mehanizam upravljanja djelatna i jalova snaga izmjenjivača fotonaponskih elektrana i snaga punjenja. U suprotnom, kada je funkcija cilja minimizacija devijacije napona, a isti mehanizam upravljanja, faktor naponske nesimetrije je najveći. Kao što je već prikazano, upravljanjem djelatnom snagom postižu se najpovoljnije naponske prilike u mreži, što posljedično rezultira poboljšanjem faktora naponske nesimetrije. Međutim, u slučaju kada faktor naponske nesimetrije nije modeliran kao funkcija cilja, upravljanjem jalovom snagom on se povećava. Pri ovakvom načinu upravljanja (koje uključuje jalovu snagu) i funkciji cilja minimizaciji devijacije napona, djelatnim snagama se uspješno reducirao faktor naponske nesimetrije, ali jalovom snagom se dodatno opterećuju čvorovi i on ostaje nešto višeg iznosa.



Slika 6.19: *Usporedba iznosa faktora naponske nesimetrije kada su funkcije cilja minimizacija gubitaka i minimizacija devijacije napona*

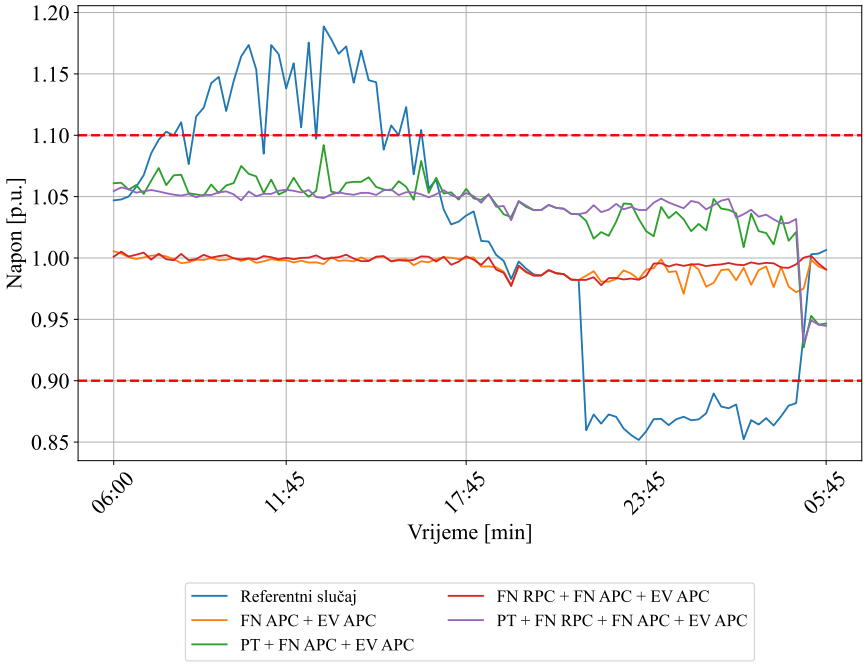
Promatrana mreža se sastoji od 159 čvorova (uključujući referentni čvor), i jasan je prikaz svih triju faza u promatranom vremenu (45504 podataka) gotovo nemoguć zbog količine podataka. Zbog toga se izabiru čvorovi na kojim se javljaju maksimalni i minimalni iznosi napona u referentnom slučaju. Analizom je utvrđeno da se na istom čvoru (157. čvoru) javljaju oba krajnja iznosa napona i on se u daljnjem tekstu naziva najkritičniji čvor. Naponski profil svih triju faza najkritičnijeg čvora prikazan je na Slici 6.20. Crvenim linijama označene su dozvoljene granice napona definirane mrežnim pravilima. Na temelju naponskog profila može se uočiti različita opterećenost pojedine faze. Analiza naponskih profila po fazama pokazuje da se vrijednosti napona u fazama L1 i L3 tijekom cjelokupnog promatranog razdoblja nalaze unutar granica definiranih normom. Suprotno tome, u fazi L2 dolazi do prekoračenja dozvoljene granice napona tijekom perioda proizvodnje iz fotonaponske elektrane, što je posljedica smanjene lokalne potrošnje električne energije u tim trenucima. Ova pojava ukazuje na neravnotežu između lokalne proizvodnje i potrošnje. Uz to, u večernjim satima uočava se izražen pad napona u fazi L2, prvenstveno uzrokovan naglim porastom potrošnje električne energije, osobito zbog simultanog punjenja električnih vozila. Za potrebe analize

kao reprezentativan primjer cjelokupnog promatranog razdoblja i svih čvorova odabrani su naponski profili faze L2, koji će biti prikazani kroz dobivene izvedive scenarije.



Slika 6.20: *Naponski profil najkritičnijeg čvora*

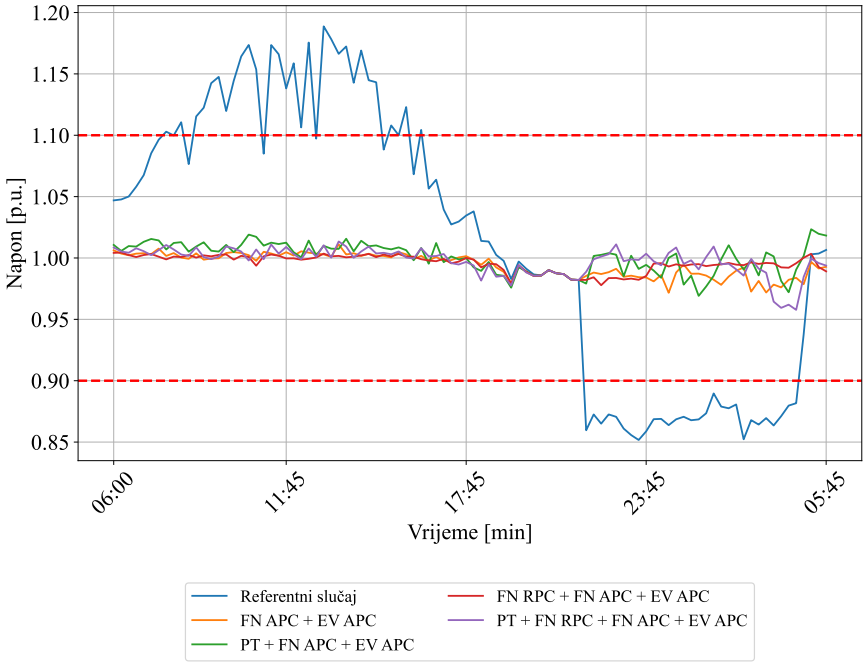
Slika 6.21 prikazuje usporedbu naponskog profila najkritičnije faze pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija gubitaka. Kada regulacijska preklopka nije mehanizam upravljanja, iznosi napona nalaze se oko referentne vrijednosti od 1.00 p.u. Usporedbom naponskog profila u slučaju upravljanja djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila, s profilom u kojem se primjenjuje isti mehanizam uz dodatno upravljanje jalovom snagom izmjenjivača, uočava se da je naponska krivulja ima manju devijaciju. Ova razlika ukazuje na pozitivan utjecaj jalove snage u slučaju manjih odstupanja napona. Kada je regulacijska preklopka uključena kao mehanizam upravljanja, iznosi napona su većeg iznosa i nalaze se oko vrijednosti od 1.05 p.u. Na temelju analiziranih naponskih profila može se zaključiti da regulacijska preklopka transformatora povećava napon na sekundarnoj strani transformatora s ciljem smanjenja struje i pripadajućih gubitaka u mreži, nastojeći pritom održati viši iznos napona. Nakon toga aktiviraju se dodatni mehanizmi regulacije kako bi se napon održao unutar definiranih granica. Naponski profil i u ovom i u ovom slučaju ima manju devijaciju kao u drugim scenarijima u kojima je, uz upravljanje djelatnim snagama, aktivirano i upravljanje jalovom snagom izmjenjivača fotonaponskih elektrana.



Slika 6.21: *Naponski profil najkritičnije faze kada je funkcija cilja minimizacija gubitaka*

Usporedba naponskog profila najkritičnije faze pri različitim mehanizmima upravljavanja kada je funkcija cilja minimizacija devijacije napona prikazana je na Slici 6.22. Devijacija napona je u svim slučajevima reducirana i iznosi napona se nalaze oko referentne vrijednosti. Usporedbom devijacija u svim slučajevima, ona je malo izraženija kada mehanizmi upravljanja uključuju regulacijsku preklopku transformatora. Kao što je već rečeno ranije, vidljiv je značajan utjecaj promjene djelatne snage na iznose napona u niskonaponskoj distribucijskoj mreži na temelju dobivenih napnskih profila.

Posljednja usporedba naponskih profila prikazana je na Slici 6.23 kada je funkcija cilja minimizacija faktora naponske nesimetrije. Uspoređujući ovu sliku s prethodne dvije 6.21 i 6.22, može se uočiti da je na ovoj slici devijacija napona u svim izvedivim rješenjima puno izraženija. Također, uočava se da naponi u slučaju primjene ove funkcije cilja postižu znatno veće vrijednosti u odnosu na druge dvije funkcije cilja. Kao i u slučaju kada je funkcija cilja minimizacija gubitaka, u slučaju kada je regulacijska preklopka uključena, naponi su značajno povećani prema vrijednosti od 1.05 p.u. Najmanja devijacija je kada se upravlja djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Za razliku od prethodne dvije funkcije cilja u kojima se jalovom snagom ostvaruje manja devijacija, u slučaju promatrane funkcije cilja javlja se veća devijacija napona. Na temelju prikazane Slike 6.23, kao i slika 6.19 i 6.18, može se zaključiti da faktor naponske nesimetrije prvenstveno ovisi o nesimetriji u raspodjeli opterećenja i izvora energije po fazama i ne

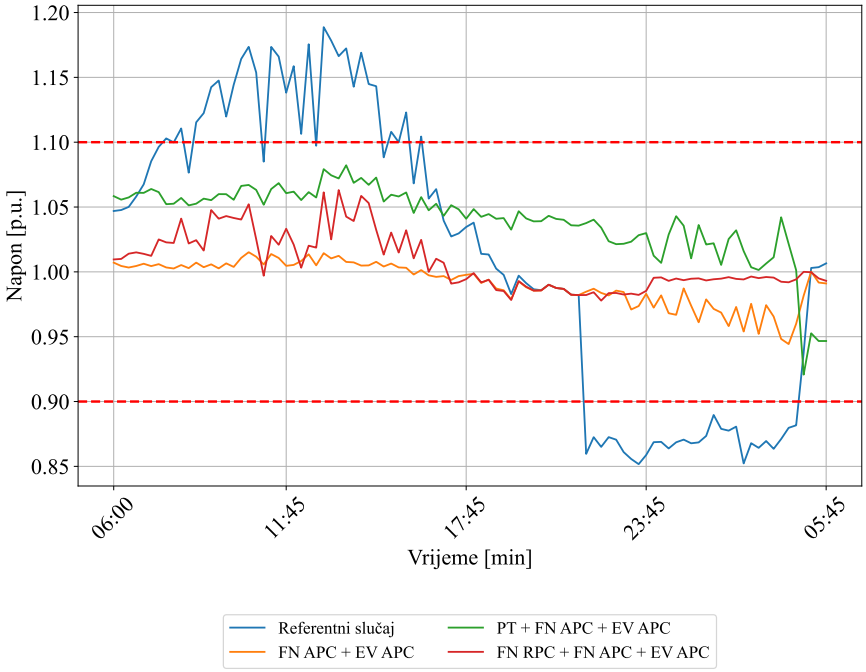


Slika 6.22: *Naponski profil najkritičnije faze kada je funkcija cilja minimizacija devijacije napona*

mora imati utjecaja na iznos napona i obrnutno.

U nastavku će biti prikazani gubici djelatne energije koji su u ovom modelu promatrani kao funkcija cilja i kao varijabla stanja u vremenu kako bi se vidjelo u kojim su trenutcima oni povišeni i sniženi. Gubici jalove energije pri svim funkcijama cilja prikazani su u Prilozima na Slikama P5, P6 i P7. Gubici povezani s jalovom energijom ne mogu se izravno kvantificirati i u pravilu se ne uzimaju u obzir pri normalnom pogonu mreže. Ipak, povećanje jalove energije u mreži može utjecati na njezin kapacitet, opterećenje elemenata i ukupnu učinkovitost, zbog čega su ti učinci uzeti u obzir u analizi. Gubici djelatne energije kada je funkcija cilja minimizacija gubitaka prikazani su na Slici 6.24. Vidljiv je porast gubitaka u referentnom slučaju u vrijeme proizvodnje iz fotonaponskih elektrana, te u vrijeme punjenja električnih vozila. Najveći gubici djelatne energije javljaju se oko 13:00 sati i iznose oko 4.75 kWh. Kako je ranije uočeno, gubici djelatne energije su najmanji kada se upravlja djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila.

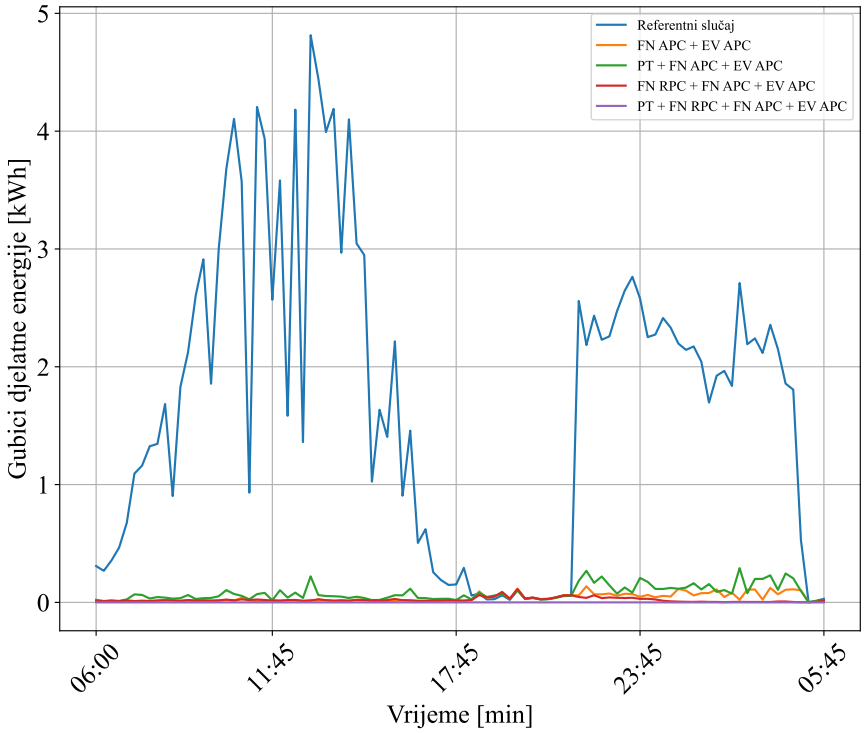
Gubici djelatne energije kada je funkcija cilja minimizacija devijacije napona prikazani su na Slici 6.25. U odnosu na prethodnu sliku, gubici su većeg iznosa tijekom promatranog vremena. Kada je funkcija cilja minimizacija devijacije napona, može se vidjeti mali porast gubitaka prilikom upravljanja regulacijskom preklopkom transformatora. Također, može se uočiti kako pri uključenom upravljanju jalovom snagom izmjenjivača fotonaponskih



Slika 6.23: *Naponski profil najkritičnije faze kada je funkcija cilja minimizacija faktora naponske nesimetrije*

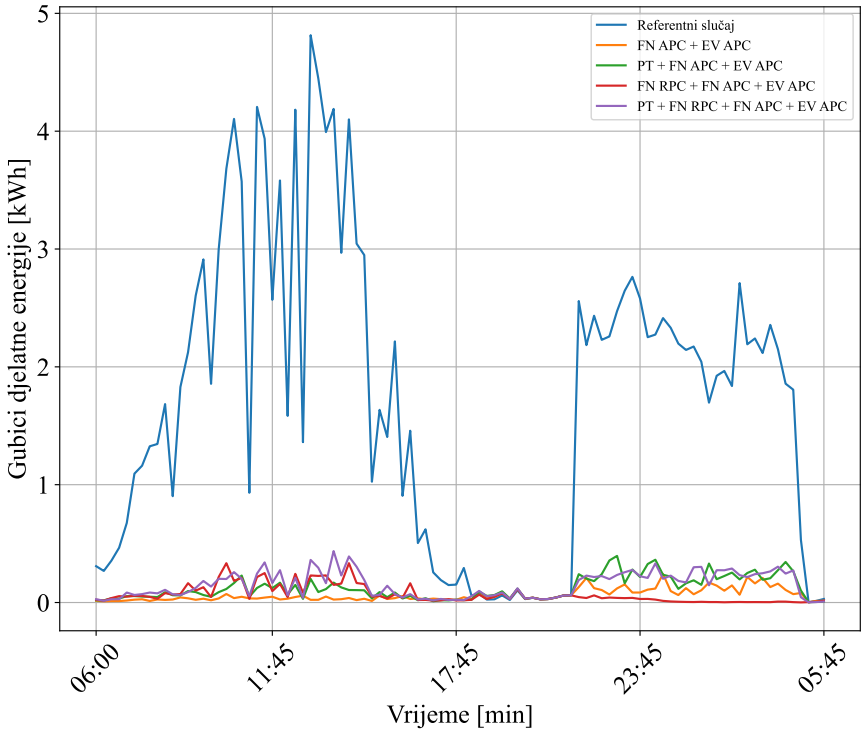
elektrana gubici su malo veći. U vremenu kada nema djelovanja aktivnih kupaca, gubici su nepromjenjivi u odnosu na referentni slučaj. U vremenu kada se pune električna vozila, gubici su najmanji u slučaju kada se upravlja djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Gubici su značajno sniženi pri upravljanju djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. U preostalim slučajevima gubici u promatranim trenutcima su približno jednaki onima u prethodnoj funkciji cilja.

Gubici djelatne energije kada je funkcija cilja minimizacija faktora naponske nesimetrije prikazani su na Slici 6.26. U usporedbi s gubicima energije kada je funkcija cilja minimizacija devijacije napona, gubici su umjereno povećani. Pri upravljanju radom fotonaponskih izmjenjivača uočava se povećanje energetskih gubitaka prilikom upravljanja jalovom snagom. Minimalni gubici javljaju se kada se upravlja isključivo djelatnom snagom izmjenjivača, dok su nešto veći u slučajevima kada je aktivirana i regulacija pomoću preklopke transformatora. U trenutcima upravljanja snagom punjenja električnih vozila, najniži gubici zabilježeni su kada se istovremeno upravlja djelatnom i jalovom snagom fotonaponskih izmjenjivača te snagom punjenja električnih vozila. U preostalim scenarijima gubici su približno jednaki onima u prethodne dvije funkcije cilja. Nešto veća povišenja u oba slučaja vidljiva su na kraju promatranog perioda.



Slika 6.24: *Gubici djelatne energije kada je funkcija cilja minimizacija gubitaka*

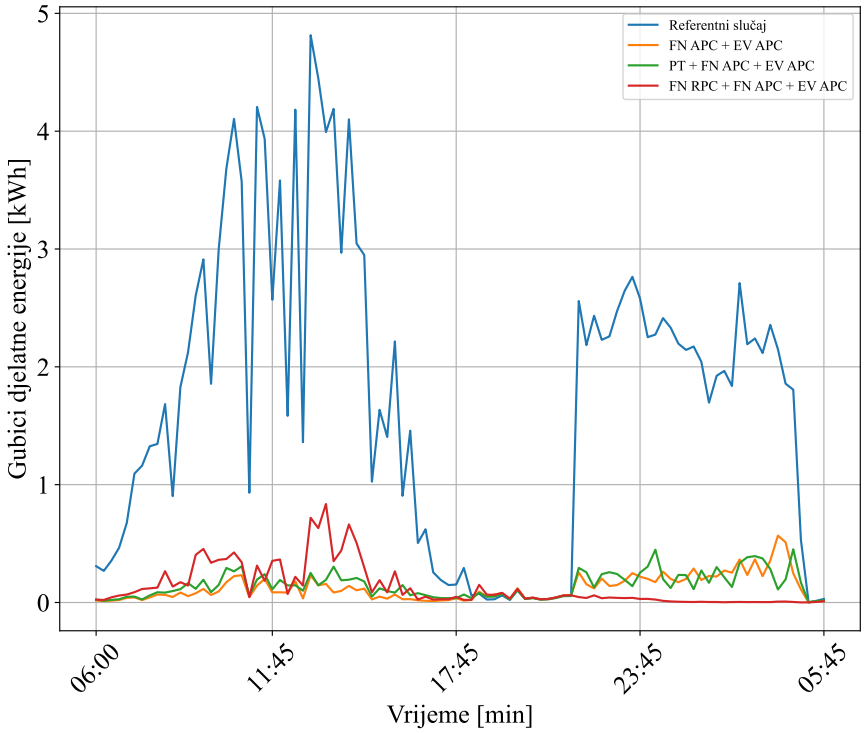
Kao jedan od ključnih kriterija za planiranje pogona smatra se opterećenje grana promatrane mreže. S obzirom na to da promatrana distribucijska mreža obuhvaća 157 grana, što upućuje na veliki skup podataka, identificirana je najkritičnija grana. Njezino opterećenje je analizirano i prikazano te služi kao referentna vrijednost za usporedbu i prikaz opterećenja ostalih grana u mreži. Utvrđeno je da je najkritičnija grana ona kojom je promatrani distribucijski izvod spojen s transformatorskom stranicom. U referentnom slučaju u vrijeme velike proizvodnje iz fotonaponskih elektrana dolazi do preopterećenja grane iznad dozvoljene granice označene crvenom linijom označenom na Slici 6.27. Najveće opterećenje javlja se u ranim prijepodnevnim satima. U trenutcima kada nema djelovanja aktivnih kupaca, opterećenje promatrane grane je ispod 20 %. Kada je funkcija cilja minimizacija gubitaka, najveće opterećenje u svim promatranim vremenskim trenutcima zabilježeno je u slučaju kada se upravlja regulacijskom preklopkom transformatora, djelatnom snagom izmjenjivača fotonaponskih elektrana te snagom punjenja električnih vozila. Usporedbom ovakvog načina upravljanja s pristupom u kojem se regulira isključivo djelatna snaga izmjenjivača i snaga punjenja električnih vozila, može se zaključiti da povećano opterećenje proizlazi iz utjecaja regulacijske preklopke transformatora. Njezinim djelovanjem napon na sekundarnoj strani transformatora održava se relativno niskim (što je prikazano nekoliko slika ispod), što



Slika 6.25: *Gubici djelatne energije kada je funkcija cilja minimizacija devijacije napona*

posljedično dovodi do povećanja strujnog opterećenja u pojedinim granama mreže. Ovaj način upravljanja moguće je dodatno usporediti s pristupom koji uključuje upravljanje svim dostupnim mehanizmima. Iz takve usporedbe proizlazi zaključak da upravljanje jalovom snagom izmjenjivača fotonaponskih elektrana, kada je funkcija cilja minimizaciju gubitaka, rezultira smanjenjem ukupnog opterećenja u mreži, odnosno jalovom snagom izmjenjivača kompenzira se jalova snaga na vodu. Najveće je opterećenje u izvedivim slučajevima malo manje od 40 %.

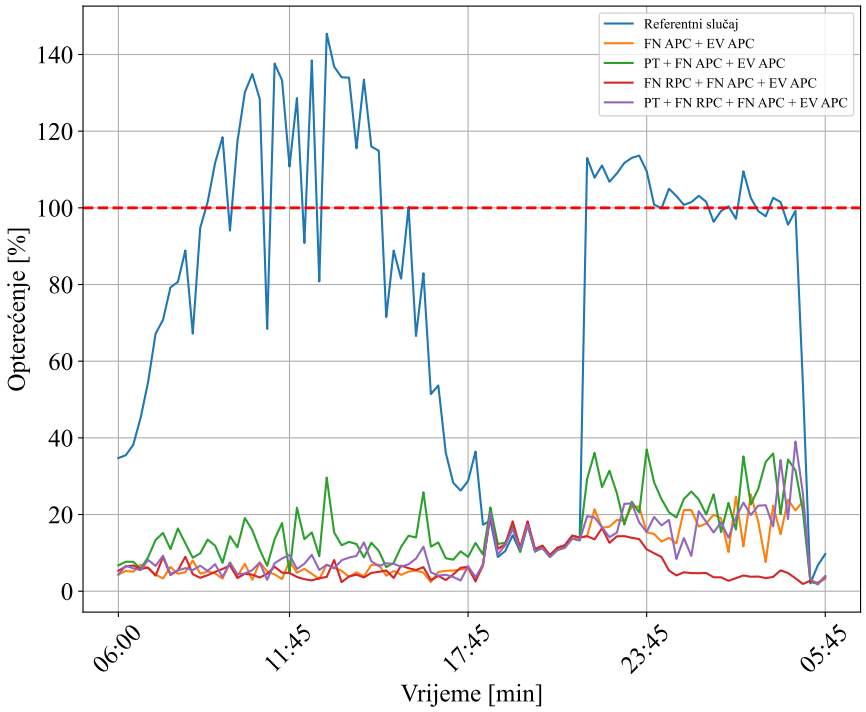
Suprotno rezultatima opterećenja najkritičnije grane dobivenim u slučaju kada je funkcija cilja minimizacija gubitaka, pri funkciji cilja minimizaciji devijacije napona zabilježeno je veće opterećenje te grane kako je prikazano na Slici 6.28. Osnovna pretpostavka zasniva se na činjenici da se smanjivanjem iznosa napona povećava struja u mreži. Međutim, u mreži s velikom integracijom fotonaponskih elektrana dolazi do velikih tokova snaga u mrežu i velikih injekcija struje. Upravljanjem djelatnom snagom smanjuju se tokovi snaga i struje prema mreži što rezultira smanjenjem opterećenja. Analogno tome, može se izvesti zaključak i za snagu punjenja električnih vozila. Stoga se najmanje opterećenje javlja pri upravljanju djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenjenja električnih vozila u kombinacijama gdje se takva upravljanja isključivo koriste. Za razliku od prethodne



Slika 6.26: *Gubici djelatne energije kada je funkcija cilja minimizacija faktora naponske nesimetrije*

funkcije cilja, upravljanjem jalovom snagom izmjenjivača fotonaponskih elektrana u svim kombinacijama povećava se opterećenje grane. Preklopka transformatora održava napon sekundara na većim vrijednostima što ukazuje na povećanje opterećenja pri takvom načinu upravljanja (prikazano nekoliko slika ispod). Najveće opterećenje prelazi iznos od 40 %.

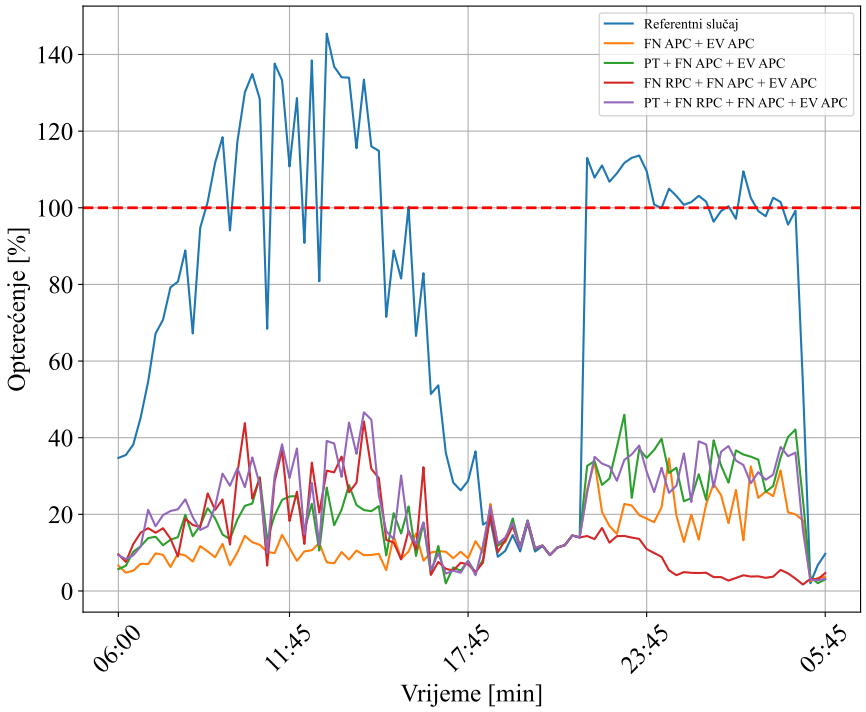
Opterećenje najkritičnije grane kada je funkcija cilja minimizacija faktora naponske nesimetrije prikazano je na Slici 6.29. U slučaju kada je funkcija cilja minimizacija faktora naponske nesimetrije, opterećenje najkritičnije grane veće je u usporedbi s rezultatima dobivenim funkcijom cilja minimizacijom gubitaka. Glavni razlog tome leži u načinu djelovanja upravljačkih mehanizama u kojima se optimizacijom fokusira prvenstveno na faze u kojima se javlja naponska nesimetrija. Umjesto ravnomjerne raspodjele upravljačkog učinka na sve faze mreže kao u slučaju prethodne dvije funkcije cilja, u ovom slučaju su učinci „lokalizirani". Iako se na taj način minimizira naponska nesimetrija, takav pristup često dovodi do neravnomjernog opterećenja vodova, odnosno povećanja struja u pojedinim granama, što posljedično povećava ukupno opterećenje mreže. Usporedbom upravljanja djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjena električnih vozila s njihovom kombinacijom s jalovom snagom izmjenjivača može se zaključiti da i u ovom slučaju jalova snaga opterećuje mrežu. Budući da su u ovom modelu iznosi jalovih snaga relativno mali, oni



Slika 6.27: *Opterećenje najkritičnije grane kada je funkcija cilja minimizacija gubitaka*

ne uzrokuju prevelik porast opterećenja koji bi narušio pogon. Kao u slučaju kada je funkcija cilja minimizacija gubitaka, regulacijskom preklopkom je opterećenje nešto veće nego u slučajevima kada je ona isključena. Najveće opeterećenje voda iznosi oko 50 %.

Završni dio analize prikazuje vrijednosti mehanizama upravljanja za svaki izvedivi slučaj za različite funkcije cilja. Analiza je izvršena na principu usporedbe iznosa mehanizama upravljanja u referentnom slučaju (slučaju bez ikakvog upravljanja) i pri različitim mehanizmima upravljanja. Iznosi djelatnih i jalovih snaga prikazani su na Slici 6.30, dok je napon na sekundaru transformatora prikazan na Slici 6.31. Ukupna snaga fotonaponskih elektrana znatno je smanjena pri primjeni upravljanja djelatnom snagom izmjenjivača fotonaponskih sustava, snagom punjenja te njihovom kombinacijom s upravljanjem jalovom snagom. Snaga punjenja u potpunosti je reducirana pri istovremenom upravljanju djelatnim snagama fotonaponskih elektrana i električnih vozila te jalovom snagom izmjenjivača fotonaponskih elektrana. Značajno smanjenje snage punjenja uočeno je i u slučaju kombiniranog upravljanja djelatnom snagom izmjenjivača i snagom punjenja te kombinacijom svih dostupnih mehanizama upravljanja. Uočljivo je da su ukupne djelatne snage nakon optimizacije većeg iznos u slučajevima kada je uključeno upravljanje preklopkom transformatora. Sa slike 6.31 može se vidjeti da preklopka transformatora održava napon sekundara u gotovo cijelom promatranom vremenu na 0.95 p.u. U tom slučaju rješava se problem preniskih napona

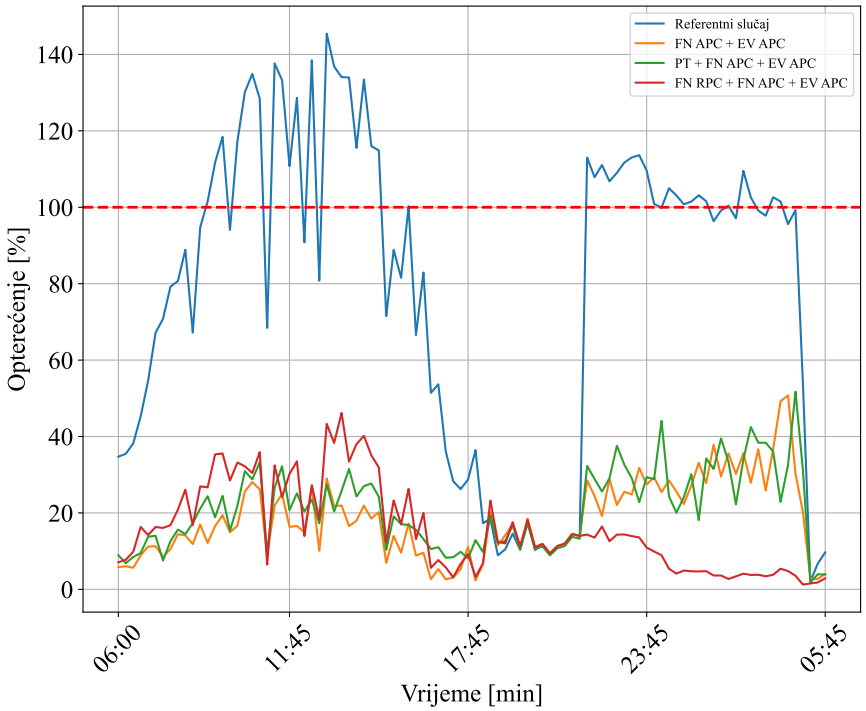


Slika 6.28: *Opterećenje najkritičnije grane kada je funkcija cilja minimizacija devijacije napona*

i održava napon na višim vrijednostima što smanjuje potrebu za značajnijim smanjenjem djelatnih snaga kao što je slučaj kada preklopka transformatora nije mehanizam upravljanja. Apsolutna vrijednost jalove snage u oba slučaja je oko 3000 kVAR. Slika P8 prikazuje primjer djelatne i jalove snage jedne fotonaponske elektrane kada je mehanizam upravljanja njihova kombinacija sa snagom punjenja električnih vozila.

U oba ispitana slučaja kada je funkcija cilja minimizacija gubitaka, regulacijska preklopka dva puta promijeni položaj održavajući pri tome napon sekundara gotovo cijelo vrijeme na 0.95 p.u. osim u zadnjem satu kada ga održava na 1.05 p.u. Ta promjena povezana je sa značajnim padom napona u posljednjem satu koji je prikazan na Slici 6.21.

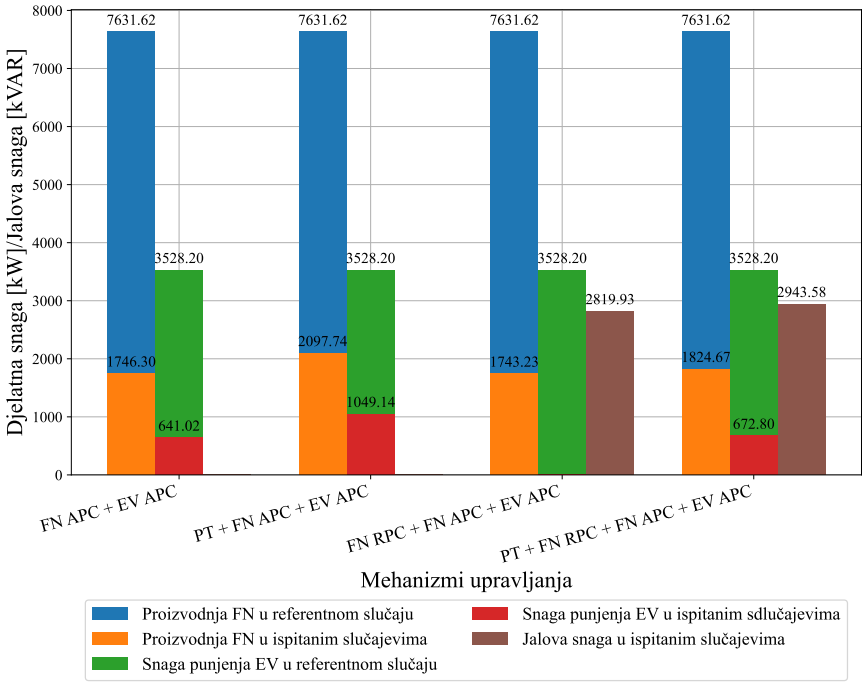
Iznosi djelatnih i jalovih snaga prije i nakon optimizacije prikazani su na Slici 6.32, dok su iznosi napona sekundara transformatora u slučajevima kada je jedan od mehanizama upravljanja regulacijska preklopka transformatora prikazani na Slici 6.33. Analizom i usporedbom s vrijednostima snaga prikazanim na Slici 6.30 uočava se da se pri funkciji cilja minimizaciji devijacije napona pojavljuju veće vrijednosti snaga nakon optimizacije. Međusobnom usporedbom mehanizama upravljanja, najveća redukcija snaga javlja se u slučaju kada se upravlja djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila, osim u slučaju njihove kombinacije s jalovom snagom izmjenjivača kada je



Slika 6.29: *Opterećenje najkritičnije grane kada je funkcija cilja minimizacija faktora naponske nesimetrije*

snaga punjenja potputno reducirana. Najveće vrijednosti snaga nakon optimizacije dobivene su u slučaju u kojem su istovremeno primijenjeni svi dostupni mehanizmi upravljanja. Kao i u slučaju prethodne funkcije cilja, kada je jedan od mehanizama upravljanja regulacijska preklopka transformatora, dolazi do manjeg smanjenja djelatnih snaga (ograničava se prekomjerno smanjenje djelatne snage). To upućuje na zaključak da njezina primjena pozitivno doprinosi smanjenju djelatnih gubitaka u smislu da ograničava njihovo dodatno smanjenje kao što je slučaj kada je preklopka isključena. Jalova snaga izmjenjivača najveća je pri upravljanju djelatnom i jalovom snagom izmjenjivača i snagom punjenja električnih vozila i iznosi 3302.93 kVAR, dok je u slučaju primjene svih dostupnih mehanizama njezin iznos 2843.94 kVAR. Ti iznosi mogu se povezati s blago uvećanim iznosim gubitaka jalove energije u vrijeme proizvodnje fotonaponskih elektrana prikazanih Slikom P6. Slika P9 prikazuje primjer djelatne i jalove snage jedne fotonaponske elektrane kada je mehanizam upravljanja njihova kombinacija sa snagom punjenja električnih vozila.

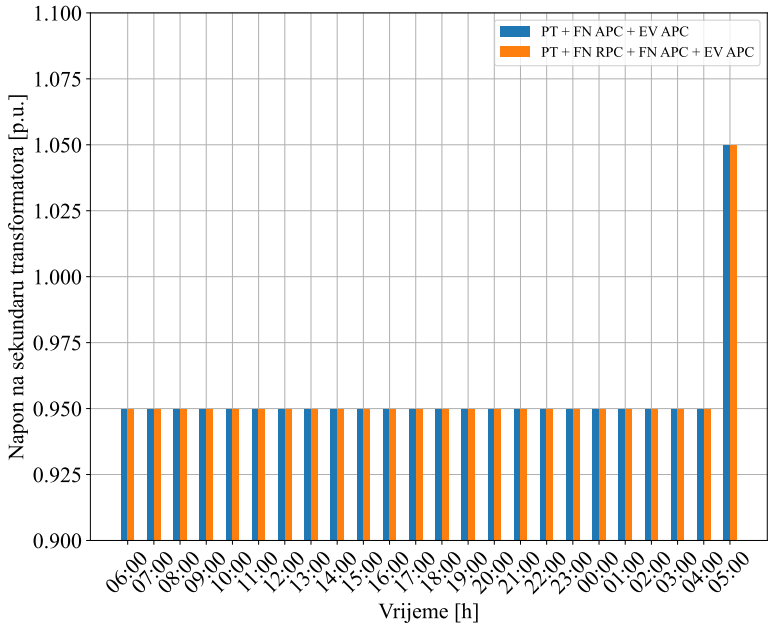
U slučaju kada se upravlja regulacijskom preklopkom transformatora i djelatnim snagama aktivnih kupaca regulacijska preklopka odradila je maksimalno dozvoljeni broj promjena položaja. U vrijeme proizvodnje iz fotonaponskih elektrana napon na sekundaru održava se na 1.0 p.u. Napon na sekundarnoj strani transformatora promijenjen je u 21:00 sat na



Slika 6.30: *Iznosi mehanizama upravljanja kada je funkcija cilja minimizacija gubitaka*

vrijednost od 0.975 p.u. Prije toga, u 00:00 sati, zabilježena je jedna promjena na vrijednost od 1.0 p.u., koja se može povezati s padom napona u tom razdoblju, što je vidljivo na Slici 6.22. Do kraja promatranog razdoblja, napon sekundara ostaje na vrijednosti od 0.975 p.u. U scenariju s primjenom svih dostupnih mehanizama upravljanja zabilježene su dvije promjene položaja regulacijske preklopke. Tijekom proizvodnje iz fotonaponskih elektrana napon se održava na 1.0 p.u., dok se nakon završetka proizvodnje snižava na 0,975 p.u. sve do posljednjeg sata, kada se ponovno povećava na 1.0 p.u. kao reakcija na pad napona prikazan na Slici 6.22. U slučaju funkcije cilja usmjerene na minimizaciju devijacije napona dolazi do većeg broja promjena položaja regulacijske preklopke transformatora u usporedbi s ostalim funkcijama cilja. Razlog tome je činjenica da je primarna svrha ove funkcije održavanja naponskih prilika u mreži, zbog čega pokazuje najveću osjetljivost na promjene napona.

U usporedbi s funkcijama cilja minimizacije gubitaka i minimizacije naponske devijacije, ukupno smanjenje djelatne snage fotonaponskih elektrana i snage punjenja električnih vozila značajno je manje kada je funkcija cilja minimizacija faktora naponske nesimetrije kako je prikazano na Slici 6.34. Kako je ranije rečeno, to je posljedica činjenice da se redukcija snage provodi isključivo u fazama u kojima se pojavljuje izražena naponska nesimetrija uzrokovana djelovanjem aktivnih kupaca. Usporedbom iznosa djelatnih snaga, može se uočiti da kao i kod prethodnih funkcija cilja, djelatna snaga se najviše smanjila kada se upravlja djelatnom

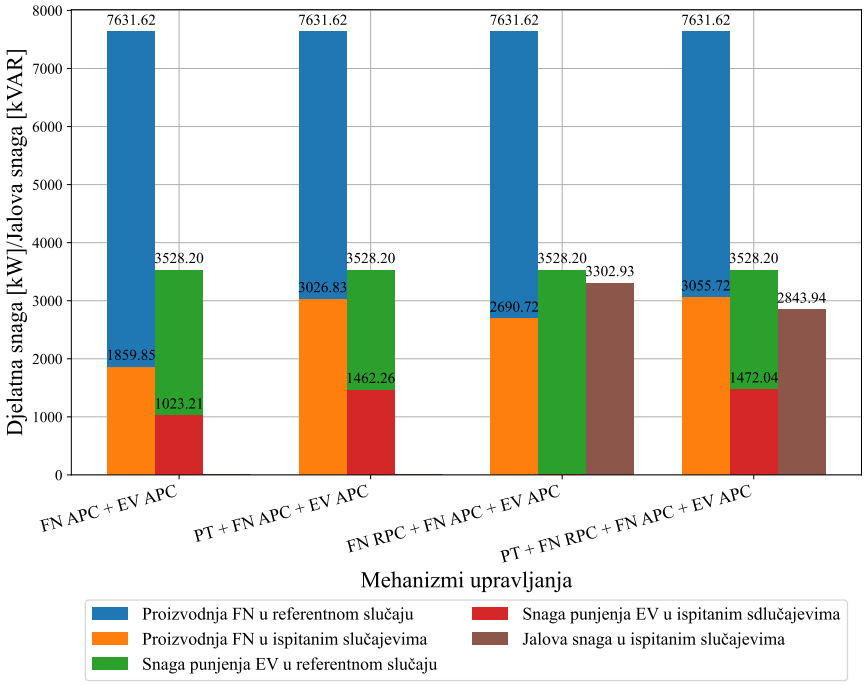


Slika 6.31: *Napon na sekundaru transformatora kada je funkcija cilja minimizacija gubitaka*

snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Također, najveće smanjenje ukupne snage punjenja ostvareno je u slučaju upravljanja djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana te snagom punjenja električnih vozila. Ponašanje regulacijske preklopke transformatora u ovom je slučaju analogno onome zabilježenom pri optimizaciji s funkcijom cilja minimizacijom gubitaka. Vrijednost jalove snage u slučajevima u kojima je omogućeno njezino upravljanje relativno je visoka, što je dodatno vidljivo blago povećanim gubicima jalove energije prikazanim na Slici P7. Slika P10 prikazuje primjer djelatne i jalove snage jedne fotonaponske elektrane kada je mehanizam upravljanja njihova kombinacija sa snagom punjenja električnih vozila.

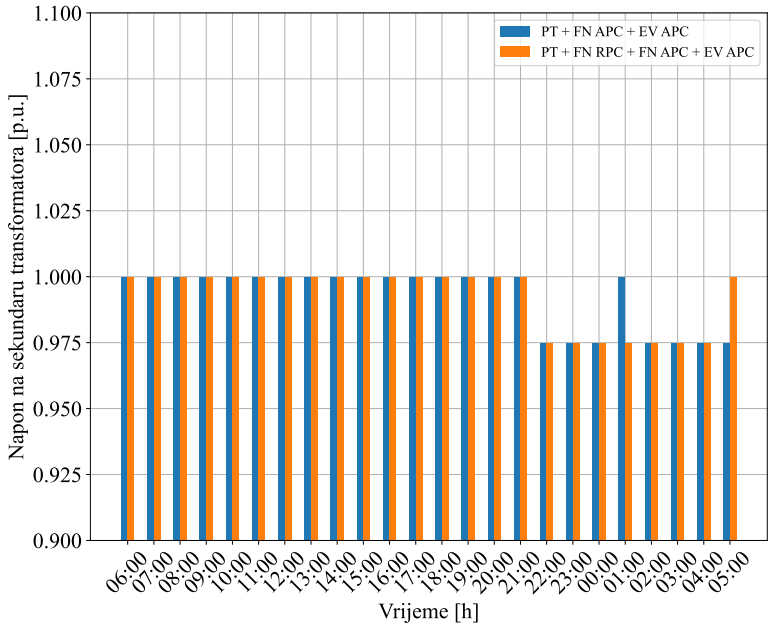
Iznos napona na sekundaru transformatora u slučaju kada je preklopka transformatora jedan od mehanizama upravljanja prikazan je na Slici 6.35. Regulacijska preklopka promijenila je položaj jednom u tijeku promatranog perioda. U tom slučaju gotovo čitavo vrijeme održava se napon na sekundaru transformatora na 0.95 p.u., osim u posljednjem trenutku kada je napon na 1.05 p.u. što je rezultiralo značajnim padom napona vidljivog na Slici 6.23. Kao i kod funkcije cilja minimizacije gubitaka, regulacijska preklopka neizravno utječe na funkciju cilja. Njezino djelovanje prvenstveno je usmjereno na regulaciju napona, pri čemu izravno doprinosi smanjenju opterećenja čvora.

Ovim je modelom analiziran utjecaj različitih mehanizama upravljanja na tri najčešće



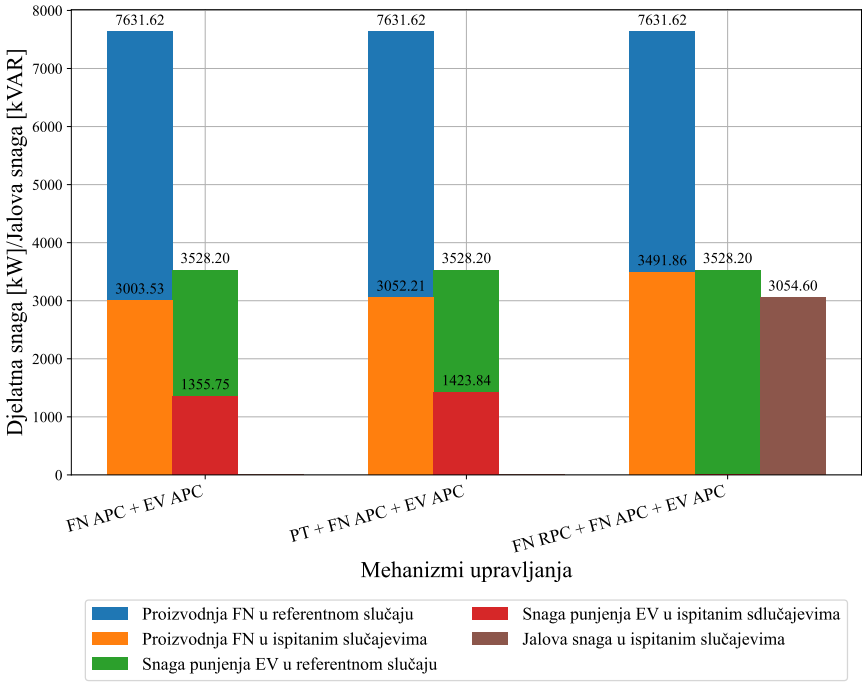
Slika 6.32: *Iznosi mehanizama upravljanja kada je funkcija cilja minimizacija devijacije napona*

korištene funkcije cilja u planiranju pogona aktivne distribucijske mreže: minimizaciju gubitaka, minimizaciju devijacije napona te minimizaciju faktora naponske nesimetrije. Razmatrana su četiri mehanizma upravljanja: promjena položaja regulacijske preklopke transformatora, upravljanje djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana te upravljanje snagom punjenja električnih vozila, uključujući i njihove međusobne kombinacije. Za svaku funkciju cilja provedena je optimizacija za ukupno 15 različitih kombinacija mehanizama upravljanja, što rezultira s ukupno 45 optimizacijskih slučajeva. Prilikom provođenja optimizacije s jednom od triju funkcija cilja, preostale dvije promatrane su kao varijable stanja. Uz to, analiziran je i utjecaj optimizacije na druge mrežne varijable, poput opterećenja grana te vrijednosti mehanizama upravljanja na kraju optimizacije. Odluka o odabiru najprikladnije funkcije cilja može se sagledati iz više aspekata. Jedan od njih odnosi se na postizanje najmanjih vrijednosti varijabli stanja za pojedini mehanizam upravljanja. U slučaju kada je funkcija cilja minimizacija gubitaka, najmanja devijacija napona (razlika između maksimalnog i minimalog iznosa napona) i najmanji faktor naponske nesimetrije, javljaju se pri upravljanju djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Kada je funkcija cilja minimizacija devijacije napona najmanji iznos gubitaka djelatne energije i faktora naponske nesimetrije javlja se pri upravljanju djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja



Slika 6.33: *Napon na sekundaru transformatora kada je funkcija cilja minimizacija devijacije napona*

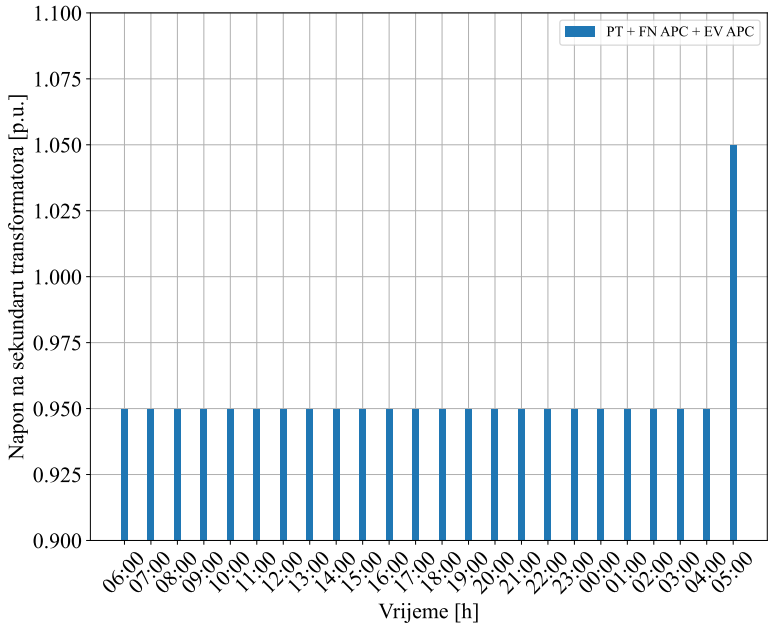
električnih vozila. Najmanji gubici djelatne energije i najmanja devijacija napona pojavljuje se pri upravljanju djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Usporedbom rezultata za sve tri funkcije cilja može se zaključiti da optimizacijski model s funkcijom cilja minimizacijom gubitaka pruža najpovoljnija rješenja. Usporedba najpovoljnijih rješenja za svaku od funkcija cilja pokazuje da se ona u pravilu postiže upravljanjem djelatnim snagama aktivnih kupaca (te u jednom slučaju i jalovom snagom izmjenjivača fotonaponskih elektrana). Ovo upućuje na zaključak da parametri mreže značajno utječu na učinkovitost pojedinih mehanizama upravljanja. S druge strane, to ne znači da ostali mehanizmi upravljanja ne mogu dovesti do rješenja, već da je za njihovo učinkovito djelovanje u pravilu potrebna znatno veća razina aktivacije kako bi se postigli usporedivi rezultati. Osim veće aktivacije moguće ih je iskoristiti pri manjem poremećaju u mreži i ciljano (ako nema drugih značajnih problema u mreži). Primjer je toga kada se upravlja jalovom snagom kojom je iznos napona reducira, ali nedovoljno za normalan pogon, dok se s druge strane povećava faktor naponske nesimetrije. Funkcija cilja minimizacija devijacije napona pokazala je određene nedostatke u kontekstu pogona, prvenstveno zbog nemogućnosti razlikovanja između manjih i većih devijacija, koje se pritom tretiraju jednako. Analizom je utvrđena negativna korelacija između upravljanja jalovom snagom



Slika 6.34: *Iznos mehanizama upravljanja kada je funkcija cilja minimizacija faktora naponske nesimetrije*

i faktora naponske nesimetrije kada se potonji promatra kao varijabla stanja. Zaključno, funkcije cilja minimizacije gubitaka i minimizacije faktora naponske nesimetrije pokazuju vrlo slično ponašanje tijekom optimizacije, budući da obje djeluju na opterećenje — pri čemu se u prvom slučaju utječe na opterećenje grana, a u drugom na opterećenje čvorova. Nasuprot tome, funkcija cilja minimizacija naponske devijacije ne pokazuje osjetljivost na faktor naponske nesimetrije, već se on zadržava unutar propisanih granica isključivo zbog primjene ograničenja definiranih u optimizacijskom modelu. Razlog je prvenstvno što se pri minimizaciji naponske devijacije tretira sve faze jednako.

Drugi od aspekata promatranja povezan s odabirom najprikladnije funkcije cilja, odnosi se na iznose mehanizama upravljanja nakon optimizacije. Kada je funkcija cilja minimizacija gubitaka, najmanja redukcija djelatne snage, a da se dobije izvedivo rješenje, postignuta je pri upravljanju regulacijskom preklopkom transformatora, djelatnom snagom izmjenjivača fotonaponskih elektrana i snagom punjenja električnih vozila. Također, u oba slučaja u kojima je upotrebljena preklopka dolazi do samo jedne promjene položaja. Kada je funkcija cilja minimizacija devijacije napona, najmanje smanjenje snaga dobiveno je kada se upravlja svim dostupnim mehanizmima. U oba slučaja u kojima se koristi preklopka transformatora, ona 2 ili 3 puta promijeni položaj. Kod funkcije cilja minimizacije faktora naponske nesimetrije najmanje smanjenje djelatne snage fotonaponske elektrane dobiva se pri kombinaciji djelatne



Slika 6.35: *Napon na sekundaru transformatora kada je funkcija cilja minimizacija faktora naponske nesimetrije*

i jalove snage izmjenjivača fotonaponskih elektrana i snage punjenja, dok se snaga električnih vozila najmanje reducira pri upravljanju regulacijskom preklopkom transformatora i djelatnim snagama aktivnih kupaca. U tom slučaju, regulacijska preklopka transformatora kada je mehanizam upravljanja, promijenila je položaj samo jedan puta. Usporedbom prema iznosu mehanizama upravljanja najprikladnija je funkcija cilja minimizacija faktora naponske nesimetrije.

Pri planiranju pogona aktivne niskonaponske distribucijske mreže, važno je sveobuhvatno sagledati potencijalne tehničke izazove i nepravilnosti pogona. Stoga je, prije optimizacija planiranja pogona, nužno provesti temeljitu preliminarnu analizu mreže. Cilj ove analize jest identifikacija svih varijabli čije vrijednosti odstupaju od propisanih tehničkih normi i mrežnih pravila, kako bi se optimizacijski postupak mogao usmjeriti na sve moguće probleme, a time bi se povećala učinkovitost i preciznost planiranja.

7. Zaključak

Integracija aktivnih kupaca u niskonaponsku distribucijsku mrežu donosi izazove u planiranju pogona. Aktivni kupci mogu negativno utjecati na pogon mreže uzrokovanjem preniskih ili previsokih napona u čvorovima, povećanjem opterećenja vodova, porastom gubitaka te smanjenjem učinkovitosti rada zaštitnih uređaja. Jedna je od glavnih karakteristika niskonaponskih distribucijskih mreža nesimetričnost koja se dodatno može pogoršati integracijom jednofaznih aktivnih kupaca. Stoga se u znanstvenim radovima razvija velik interes za ovo područje u smislu predlaganja rješenja za ublažavanje mogućih negativnih učinaka aktivnih kupaca. Konvencionalni upravljački mehanizmi koji uspješno rješavaju probleme u pasivnim mrežama pokazali su se nedovoljno učinkovitim u aktivnim mrežama. Budući da su aktivni kupci spojeni na mrežu preko elemenata energetske elektronike, poput izmjenjivača i pretvarača, oni imaju mogućnost upravljanja izlaznom djelatnom i jalovom snagom. U kombinaciji s konvencionalnim mehanizmima upravljanja, omogućuje se razvoj fleksibilnijeg i učinkovitijeg planiranja i pogona aktivne distribucijske mreže. Jedni od najčešćih ciljeva koji se postavljaju pred operatora mogu biti tehničke prirode te su oni stavljeni u fokus ovoga rada. Optimizacijski modeli koji se do pojave aktivnih kupaca nisu primjenjivali na distribucijskoj razini postaju ključan alat za planiranje i pogon aktivnih distribucijskih mreža. U literaturi se razvijeni modeli najčešće testiraju na srednjenaponskim distribucijskim mrežama, što može dovesti do degradacije primjenjivosti i učinkovitosti predloženih rješenja u kontekstu niskonaponskih mreža.

Tijekom razvoja optimizacijskih modela temeljenih na formulaciji optimalnih tokova snaga s ciljem njihove primjene na niskonaponskim distribucijskim mrežama, pojavljuju se specifični izazovi povezani s adekvatnim modeliranjem. Naime, klasične formulacije optimalnih tokova snaga, razvijene primarno za primjenu na prijenosnim mrežama, ne mogu se izravno primijeniti na distribucijskoj razini uslijed pojednostavljenih preliminarnih pretpostavki na kojima ti modeli zasnivaju, a koje nisu primjenjive na distribucijskoj razini. Potpuni model optimalnih tokova snaga gotovo je nemoguće riješiti analitičkom metodom te

se u znanstvenim radovima često origalni problem transformira na razinu na kojoj je analitičkom metodom moguće dobiti izvedivo rješenje. Shodno tome, nastoji se pronaći kompromis između detaljnog matematičkog modela optimizacijskog problema i adekvatne metode rješavanja. Jedan od mogućih načina za dobivanje izvedivog rješenja bez transformacije je modeliranje u kosimulacijskom okruženju. Temeljem sveobuhvatnog pregleda znanstvenih radova istraživanje ovoga doktorskog rada usmjereno je na sljedeće izvorne znanstvene doprinose: dvostupanjski optimizacijski model za planiranje pogona niskonaponske aktivne distribucijske mreže s ciljem poboljšanja naponskih prilika i smanjivanja gubitaka koristeći kombinaciju tradicionalnog mehanizma upravljanja i mogućnosti izmjenjivača, kosimulacijski model za planiranje pogona niskonaponske aktivne distribucijske mreže s funkcijama cilja smanjenja naponskih odstupanja, naponske nesimetrije i djelatnih gubitaka i metoda za vrednovanje učinaka mehanizama upravljanja na funkcije cilja kosimulacijskog modela za planiranje pogona niskonaponske aktivne distribucijske mreže.

Prvi izvorni znanstveni doprinos realiziran je kao dvostupanjski optimizacijski model za planiranje pogona aktivne distribucijske mreže s velikim udjelom fotonaponskih elektrana. Preliminarnom analizom utvrđeni problemi kod planiranja pogona distribucijske mreže u pravom stupnju rješavaju se konvencionalnim mehanizmom (varijablom) upravljanja promjenom položaja regulacijske preklopke transformatora, a funkcija cilja je minimizacija devijacije napona. Dobiveni položaji regulacijske preklopke transformatora predstavljaju ulazni podatak za drugi stupanj u kojem se kao mehanizam upravljanja koristi mogućnost izmjenjivača aktivnog kupca – upravljanje jalovom snagom izmjenjivača fotonaponskih elektrana s funkcijom cilja minimizacijom gubitaka. Optimizacijski problem realiziran je u kosimulacijskom okruženju povezivanjem simulacijskoj okruženja za proračun tokova snaga i optimizacijskog okruženja. Optimizacija prvog stupnja provedena za svaki sat unutar promatranog perioda, dok je optimizacija drugog stupnja provedena na 15-minutnoj razini za unutar promatranog perioda.

Drugi izvorni znanstveni doprinos ostvaren je razvojem kosimulacijskog modela za planiranje pogona aktivne distribucijske mreže koji ne integrira samo strujno-naponske prilike u mreži već i uzima u obzir i parametare kvalitete električne energije. Optimizacijski model sastoji se od triju funkcije cilja: minimizacije gubitaka, minimizacije devijacije napona i minimizacije faktora naponske nesimetrije. Mehanizmi upravljanja kosimulacijskog modela uključuju dostupni konvencionalni mehanizam upravljanja, promjenu položaja regulacijske

preklopke transformatora i mogućnosti aktivnih kupaca – upravljanje djelatnom i jalovom snagom izmjenjivača fotonaponskih elektrana i upravljanje snagom punjenja električnih vozila. Razvoj optimizacijskog modela temelji se na rezultatima provedene ankete prema kojoj gotovo 40 % vlasnika fotonaponskih elektrana ujedno posjeduje električno vozilo kao i na spoznaji da niskonaponske mreže s visokom razinom integracije jednofaznih aktivnih kupaca pokazuju izrazitu nesimetričnost, što dovodi do narušavanja pogona mreže.

Treći znanstveni doprinos zasniva se na razvoju metode za vrednovanje učinaka mehanizama upravljanja na funkcije cilja kosimulacijskog modela za planiranje pogona aktivne distribucijske mreže. Metoda se zasniva na isptivanju svih dostupnih mehanizama upravljanja za svaku funkciju cilja. Pri vrednovanju učinaka mehanizama upravljanja, osim što se provjerava izvedivost dobivenog rješenja, analiziraju se dobivene vrijednosti varijabli stanja koje odgovaraju preostalim dvijema funkcijama cilja.

Vrednovanjem dvostupanjskog modela za planiranje pogona aktivne distribucijske mreže utvrđeno je da se upravljanjem promjenom položaja regulacijske preklopke transformatora uspješno izregulira previsok napon uzrokovan velikom integracijom fotonaponskih elektrana, ali s blago povećanim gubicima koji se potom smanje jalovom snagom izmjenjivača fotonaponskih elektrana. Na temelju dobivenih rezultata zaključeno je da, sukladno mrežnim pravilima koja ograničavaju dopušteni faktor snage, a time posredno i mogućnost upravljanja jalovom snagom, nije moguće ostvariti značajniji utjecaj u slučaju većeg poremećaja pogona. Prilagođavanjem mrežnih pravila i daljnjim razvojem tehnologija izmjenjivača kojim će se omogućiti veća količina jalove snage, a da se istovremeno ne smanjuje djelatna snaga doprinijelo bi većim mogućnostima i boljoj iskoristivosti jalove snage za pogon.

Analiza metode za vrednovanje kosimulacijskog pristupa podijeljena je u tri dijela. U prvom dijelu prikazana su sva rješenja optimizacijskih problema, identificirana su ona izvediva te su određeni mehanizmi upravljanja pomoću kojih je ta rješenja moguće ostvariti. Mehanizmi upravljanja pri kojima je moguće ostvariti izvedivo rješenje ovise o parametrima mreže. Zbog dominacije ukupnog otpora mreže u odnosu na njenu reaktanciju, izvediva rješenja ostvarena su mehanizmima upravljanja koji uključuju upravljanje djelatnim snagama fotonaponskih elektrana i snage punjenja električnih vozila. Takav ishod vidljiv je kod svih triju funkcija cilja. U drugom dijelu prikazana je grafička analiza izvedivih rješenja s naglaskom na strujno-naponske i iznose faktora naponske nesimetrije. Temeljem dobivenih rezultata utvrđeno je da se pri funkciji cilja minimizacija gubitaka dobiju najmanji iznosi

promatranih varijabli stanja. U posljednjem dijelu analize prikazani su iznosi mehanizama upravljanja izvedivih rješenja za svaku funkciju cilja. Analizom iznosa mehanizama upravljanja utvrđeno je da se najmanja redukcija djelatnih snaga javlja pri funkciji cilja minimizaciji faktora naponske nesimetrije kao i najmanji broj promjena položaja regulacijske preklopke transformatora.

Prema mišljenju autorice doktorskog rada razvijeni optimizacijski modeli za planiranje pogona niskonaponske aktivne distribucijske mreže, kao i metode za vrednovanje učinka mehanizama upravljanja u odnosu na različite funkcije cilja, imaju potencijal za daljnji razvoj i nadogradnju u više smjerova. Jedan od mogućih smjerova nadogradnje modela uključuje integraciju uređaja za regulaciju jalove snage, poput DSTATCOM-a, s ciljem smanjenja potrebe za angažiranjem djelatne snage aktivnih kupaca. Mogući smjer daljnjeg istraživanja uključuje razvoj komunikacijske infrastrukture kojom će se nadgledati elementi mreže i vršiti penalizacija samo onih aktivnih kupaca koji narušavaju normalan pogon, a ne svih kako je trenutno prikazano. Mogući daljnji smjer istraživanja uključuje osim tehničkog i ekonomski aspekt. U tom je kontekstu važno uzeti u obzir i perspektivu aktivnog kupca, kako bi se njegovo sudjelovanje u pružanju fleksibilnih usluga operatoru distribucijske mreže potaknulo na način koji je opravdan i ekonomski isplativ, osobito kada je riječ o smanjenju djelatne snage. Primjerice, dostupna je procijenjena cijena gubitaka djelatne snage po MWh u distribucijskoj mreži, dok vlasnik fotonaponske elektrane smanjenjem proizvodnje trpi financijski gubitak zbog smanjenih prihoda od prodaje električne energije. U tom smislu moguć smjer istraživanja odnosi se na pronalaženje kompromisa između tehničkog i ekonomskog aspekta planiranja i pogona distribucijske mreže.

Literatura

[1] IEA. Electricity 2024. Technical report, Paris, 2024. https://www.iea.org/reports/electricity-2024 (pristup: 1. travnja 2025.).

[2] IRENA, 2024. https://www.irena.org/ (pristup: 1. travnja 2025.).

[3] Alan Toffler. *The Third Wave: Learning for Tomorrow, the Futurists, the Schoolhouse and the City*. William Morrow and Company, Inc.: New York, NY, USA, 1st ed. edition, 1980.

[4] Tarmo Korõtko, Argo Rosin, and Roya Ahmadiahangar. Development of prosumer logical structure and object modeling. In *2019 IEEE 13th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG)*, pages 1–6, 2019.

[5] Jie Cao, Zhan Bu, Yuyao Wang, Huan Yang, Jiuchuan Jiang, and Hui Jia Li. Detecting Prosumer-Community Groups in Smart Grids from the Multiagent Perspective. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 49(8):1652–1664, 2019.

[6] A. J.Dinusha Rathnayaka, Vidyasagar M. Potdar, Tharam S. Dillon, Omar K. Hussain, and Elizabeth Chang. A methodology to find influential prosumers in prosumer community groups. *IEEE Transactions on Industrial Informatics*, 10(1):706–713, 2014.

[7] Hongming Yang, Tonglin Xiong, Jing Qiu, Duo Qiu, and Zhao Yang Dong. Optimal operation of DES/CCHP based regional multi-energy prosumer with demand response. *Applied Energy*, 167:353–365, 2016.

[8] Nian Liu, Minyang Cheng, Xinghuo Yu, Jiangxia Zhong, and Jinyong Lei. Energy-Sharing Provider for PV Prosumer Clusters: A Hybrid Approach Using Stochastic Programming and Stackelberg Game. *IEEE Transactions on Industrial Electronics*, 65(8):6740–6750, 2018.

[9] Arnob Ghosh, Vaneet Aggarwal, and Hong Wan. Exchange of Renewable Energy among Prosumers using Blockchain with Dynamic Pricing. (April), 2018.

[10] Georges El Rahi, S. Rasoul Etesami, Walid Saad, Narayan B. Mandayam, and H. Vincent Poor. Managing Price Uncertainty in Prosumer-Centric Energy Trading: A Prospect-Theoretic Stackelberg Game Approach. *IEEE Transactions on Smart Grid*, 10(1):702–713, 2019.

[11] Santiago Grijalva and Muhammad Umer Tariq. Prosumer-based smart grid architecture enables a flat, sustainable electricity industry. *IEEE PES Innovative Smart Grid Technologies Conference Europe, ISGT Europe*, 2011.

[12] Saskia Lavrijssen and Arturo Carrillo Parra. Radical prosumer innovations in the electricity sector and the impact on prosumer regulation. *Sustainability (Switzerland)*, 9(7):1–21, 2017.

[13] Julia Merino, Inés Gómez, Jesús Fraile-Ardanuy, Maider Santos, Andrés Cortés, Joseba Jimeno, and Carlos Madina. Fostering DER integration in the electricity markets. *Distributed Energy Resources in Local Integrated Energy Systems*, pages 175–205, jan 2021.

[14] Council of the European Union European Parliament. DIRECTIVE (EU) 2019/944 OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL on common rules for the internal market for electricity and amending Directive 2012/27/EU, 2019. http://data.europa.eu/eli/dir/2019/944/oj (pristup: 7. siječnja 2025.).

[15] Hrvatski Sabor. Zakon o tržištu električne energije, 2021. https://narodne-novine.nn.hr/clanci/sluzbeni/2021{_}10{_}111{_}1940.html(pristup: 7. siječnja 2025.).

[16] HEP ODS. Desetogodišnji plan razvoja distribucijske mreže HEP - Operatora distribucijskog sustava d.o.o. https://www.hep.hr/ods/razvoj-mreze/planovi-razvoja-mreze/arhiva-ranijih-desetogodisnjih-planova/758 (pristup: 19. veljače 2025.).

[17] F. M. Aboshady, Ioana Pisica, Ahmed F. Zobaa, Gareth A. Taylor, Oguzhan Ceylan, and Aydogan Ozdemir. Reactive power control of pv inverters in active distribution grids with high pv penetration. *IEEE Access*, 11:81477–81496, 2023.

[18] Olufunke Abolaji Balogun, Yanxia Sun, and Peter Anuoluwapo Gbadega. Coordination of smart inverter-enabled distributed energy resources for optimal pv-bess integration and voltage stability in modern power distribution networks: A systematic review and bibliometric analysis. *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, 10:100800, 2024.

[19] Ieee standard for interconnection and interoperability of distributed energy resources with associated electric power systems interfaces. *IEEE Std 1547-2018 (Revision of IEEE Std 1547-2003)*, pages 1–138, 2018.

[20] Yasin Zabihinia Gerdroodbari, Reza Razzaghi, and Farhad Shahnia. Decentralized control strategy to improve fairness in active power curtailment of pv inverters in low-voltage distribution networks. *IEEE Transactions on Sustainable Energy*, 12(4):2282–2292, 2021.

[21] Olufunke Abolaji Balogun, Yanxia Sun, and Peter Anuoluwapo Gbadega. Optimal pv active power curtailment in a pv-penetrated distribution network using optimal smart inverter volt-watt control settings. *Energy Reports*, 12:5396–5419, 2024.

[22] Daniel Gebbran, Sleiman Mhanna, Yiju Ma, Archie C. Chapman, and Gregor Verbič. Fair coordination of distributed energy resources with Volt-Var control and PV curtailment. *Applied Energy*, 286(January):116546, 2021.

[23] Hui Chen, Weiping Zhu, Liguo Liu, Mingming Shi, Wenqiang Xie, and Chenyu Zhang. Power fl ow analysis and volt / var control strategy of the active distribution network based on data-driven method. *Science and Technology for Energy Transition*, 21, 2025.

[24] Moein Manbachi, Hassan Farhangi, Ali Palizban, and Siamak Arzanpour. Smart grid adaptive volt-var optimization: Challenges for sustainable future grids. *Sustainable Cities and Society*, 28:242–255, 2017.

[25] Saran Satsangi and G.B. Kumbhar. Review on volt/var optimization and control in electric distribution system. In *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)*, pages 1–6, 2016.

[26] Hamed Ahmadi and Jose Dommel. A framework for volt-var optimization in distribution systems. *IEEE Transactions on Smart Grid*, 6, 05 2015.

[27] Mihovil Ivas, Ante Marušić, Juraj George Havelka, and Igor Kuzle. P-q capability chart analysis of multi-inverter photovoltaic power plant connected to medium voltage grid. *International Journal of Electrical Power & Energy Systems*, 116:105521, 2020.

[28] Abdelfatah Ali, David Raisz, and Karar Mahmoud. Sensitivity-based and optimization-based methods for mitigating voltage fluctuation and rise in the presence of pv and phevs. *International Transactions on Electrical Energy Systems*, 27, 11 2017.

[29] Muammar Zainuddin, Frengki Surusa, Muhammad Asri, and Aprian Mokoagow. Reactive power control of solar photovoltaic inverters for grid code compliance support. *International Journal of Applied Power Engineering (IJAPE)*, 12:300, 07 2023.

[30] Michael Liu, Andreas Procopiou, Kyriacos Petrou, Luis Ochoa, Tom Langstaff, Justin Harding, and John Theunissen. On the fairness of pv curtailment schemes in residential distribution networks. In *2021 IEEE Power & Energy Society General Meeting (PESGM)*, pages 1–1, 2021.

[31] Michael Z. Liu, Andreas T. Procopiou, Kyriacos Petrou, Luis F. Ochoa, Tom Langstaff, Justin Harding, and John Theunissen. On the fairness of pv curtailment schemes in residential distribution networks. *IEEE Transactions on Smart Grid*, 11(5):4502–4512, 2020.

[32] Michael Z. Liu, Luis F. Ochoa, and Steven H. Low. On the implementation of opf-based setpoints for active distribution networks. *IEEE Transactions on Smart Grid*, 12(4):2929–2940, 2021.

[33] SeokJu Kang, Jinah Noh, and Jung-Wook Park. Active distribution management system based on smart inverter control of pv/ess integrated system. *IEEE Transactions on Industrial Electronics*, 69(8):7994–8003, 2022.

[34] Michael Z. Liu, Andreas T. Procopiou, Kyriacos Petrou, Luis F. Ochoa, Tom Langstaff, Justin Harding, and John Theunissen. On the Fairness of PV Curtailment Schemes in Residential Distribution Networks. *IEEE Transactions on Smart Grid*, 11(5):4502–4512, 2020.

[35] Wei Liu, Zhenhuan Ding, Huaying Zhang, and Mingxing Zhu. Multiobjective Optimal Power Flow for Distribution Networks Utilizing a Novel Heuristic Algorithm - Grey Wolf Equilibrium Optimizer. *IEEE Systems Journal*, 18(1):174–185, 2024.

[36] Felipe Gonzalez Venegas, Marc Petit, and Yannick Perez. Active integration of electric vehicles into distribution grids: Barriers and frameworks for flexibility services. *Renewable and Sustainable Energy Reviews*, 145:111060, 2021.

[37] Katarina Knezović, Mattia Marinelli, Antonio Zecchino, Peter Bach Andersen, and Chresten Traeholt. Supporting involvement of electric vehicles in distribution grids: Lowering the barriers for a proactive integration. *Energy*, 134:458–468, 2017.

[38] Constance Crozier, Matthew Deakin, Thomas Morstyn, and Malcolm Mcculloch. Coordinated electric vehicle charging to reduce losses without network impedances. *IET Smart Grid*, 06 2020.

[39] Ali Raza, Li Jingzhao, Yazeed Ghadi, Muhammad Adnan, and Mansoor Ali. Smart home energy management systems: Research challenges and survey. *Alexandria Engineering Journal*, 92:117–170, 2024.

[40] Wanjun Yin, Leilei Jia, and Jianbo Ji. Energy optimal scheduling strategy considering v2g characteristics of electric vehicle. *Energy*, 294:130967, 2024.

[41] Choton K. Das, Octavian Bass, Ganesh Kothapalli, Thair S. Mahmoud, and Daryoush Habibi. Overview of energy storage systems in distribution networks: Placement, sizing, operation, and power quality. *Renewable and Sustainable Energy Reviews*, 91:1205–1230, 2018.

[42] Giuliano Rancilio, Filippo Bovera, Matteo Spiller, Marco Merlo, and Maurizio Delfanti. Bess and the ancillary services markets: A symbiosis yet? impact of market design on performance. *Applied Energy*, 375:124153, 2024.

[43] Ammar Muqbel, Ali T. Al-Awami, and Masood Parvania. Optimal planning of distributed battery energy storage systems in unbalanced distribution networks. *IEEE Systems Journal*, 16(1):1194–1205, 2022.

[44] Hosna Khajeh, Chethan Parthasarathy, Elahe Doroudchi, and Hannu Laaksonen. Optimized siting and sizing of distribution-network-connected battery energy storage system providing flexibility services for system operators. *Energy*, 285:129490, 2023.

[45] Nhi T. A. Nguyen, Duong D. Le, Godfrey G. Moshi, Cristian Bovo, and Alberto Berizzi. Sensitivity analysis on locations of energy storage in power systems with wind integration. *IEEE Transactions on Industry Applications*, 52(6):5185–5193, 2016.

[46] Pramuk Unahalekhaka and Panot Sripakarach. Reduction of reverse power flow using the appropriate size and installation position of a bess for a pv power plant. *IEEE Access*, 8:102897–102906, 2020.

[47] Mahardira Dewantara, Lesnanto Multa Putranto, Roni Irnawan, and Sarjiya. Minimization of power losses through optimal placement and sizing from solar power and battery energy storage system in distribution system. In *2020 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, pages 400–405, 2020.

[48] Philipp Fortenbacher, Johanna L. Mathieu, and Göran Andersson. Modeling and optimal operation of distributed battery storage in low voltage grids. *IEEE Transactions on Power Systems*, 32(6):4340–4350, 2017.

[49] Krit Wichitkrailat, Suttichai Premrudeepreechacharn, Apirat Siritaratiwat, and Sirote Khunkitti. Optimal sizing and locations of multiple besss in distribution systems using crayfish optimization algorithm. *IEEE Access*, 12:94733–94752, 2024.

[50] Sirote Khunkitti, Punyawoot Boonluk, and Apirat Siritaratiwat. Optimal location and sizing of bess for performance improvement of distribution systems with high dg penetration. *International Transactions on Electrical Energy Systems*, 2022(1):6361243, 2022.

[51] Salem Alshahrani, Mohammed Abido, and Muhammad Khalid. Active/reactive power losses minimization based on optimal location of battery energy storage system. *Renewable Energy and Power Quality Journal*, 18:594–598, 06 2020.

[52] Jinwei Fu, Tianrui Li, Shilei Guan, Yan Wu, Kexin Tang, Yan Ding, and Zhi Song. Three-Phase Four-Wire OPF-Based Collaborative Control of PV Inverter and ESS for

Low-Voltage Distribution Networks With High Proportion PVs. *Frontiers in Energy Research*, 8(January):1–13, 2021.

[53] Ioannis Mexis, Grazia Todeschini, and Zhongfu Zhou. Coordinated Control of Three Single-Phase BESS Inverters Using Local Measurements to Mitigate Voltage Unbalance. *IEEE Transactions on Energy Conversion*, 37(4):2941–2951, 2022.

[54] Zainal Arifin, Aditya Firmanto, Sirilus Dwirawan, and Dede Alwani. Battery energy storage system (bess) as a voltage control at substation based on the defense scheme mechanism. *SINERGI*, 28:209–218, 06 2024.

[55] Zhenming Li, Yunfeng Yan, Donglian Qi, Shuo Yan, and Minghao Wang. Distributed voltage optimization control of bess in ac distribution networks with high pv penetration. *Energies*, 15(11), 2022.

[56] J. Carpentier. Contribuition to the economic dispatch problem (in French). *Bull. Soc. FranQ. Elect*, 8:431–447, 1962.

[57] Hermann W. Dommel and William F. Tinney. Optimal Power Flow Solutions. *IEEE Transactions on Power Apparatus and Systems*, PAS-87(10):1866–1876, 1968.

[58] J. L. Carpentier. Optimal Power Flows: Uses, Methods and Developments. *IFAC Proceedings Volumes*, 18(7):11–21, 1986.

[59] James A. Momoh, M. E. El-Hawary, and Ramababu Adapa. A review of selected optimal power flow literature to 1993 part i: nonlinear and quadratic Programming Approaches. *IEEE Transactions on Power Systems*, 14(1):96–103, 1999.

[60] Adapa R. Momoh, J. A, M. E. El-Hawary M. E. A review of selected optimal power flow literature to 1993. ii. Newton, linear programming and interior point methods. *IEEE Transactions on Power Systems*, 14(1):96–104, 1999.

[61] M. Huneault and F. D. Galiana. A Survey Of The Optimal Power Flow LiteratureA Survey Of The Optimal Power Flow Literature. *IEEE Transactions on Power Systems*, 6(2):762–770, 1991.

[62] Xuemin Zhang, Y.H. Song, Qiang Lu, and Shengwei Mei. Dynamic available transfer capability (atc) evaluation by dynamic constrained optimization. *IEEE Transactions on Power Systems*, 19(2):1240–1242, 2004.

[63] A.-A. Fouad and T. Jianzhong. Stability constrained optimal rescheduling of generation. *IEEE Transactions on Power Systems*, 8(1):105–112, 1993.

[64] M. Aganagic and S. Mokhtari. Security constrained economic dispatch using nonlinear dantzig-wolfe decomposition. *IEEE Transactions on Power Systems*, 12(1):105–112, 1997.

[65] L. Chen, Y. Taka, H. Okamoto, R. Tanabe, and A. Ono. Optimal operation solutions of power systems with transient stability constraints. *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, 48(3):327–339, 2001.

[66] James A. Momoh. Chapter 12 Optimal Power Flow. In *Electric Power System Applications of Optimization*, pages 383–437. CRC Press, Taylor & Francis Group, second edi edition, 2008.

[67] G. C. Contaxis, C. Delkis, and G. Korres. Decoupled Optimal Load Flow Using Linear or Quadratic Programming. *IEEE Power Engineering Review*, PER-6(5):26, 1986.

[68] P. N. Biskas and A. G. Bakirtzis. A decentralized solution to the Security Constrained DC-OPF problem of multi-area power systems. *2005 IEEE Russia Power Tech, PowerTech*, 18(3):1007–1013, 2005.

[69] Narayan S. Rau. Issues in the path toward an RTO and standard markets. *IEEE Transactions on Power Systems*, 18(2):435–443, 2003.

[70] Stephen Frank, Ingrida Steponavice, and Steffen Rebennack. Optimal power flow: A bibliographic survey I Formulations and deterministic methods. *Energy Systems*, 3(3):221–258, 2012.

[71] K.C. Almeida and F.D. Galiana. Critical cases in the optimal power flow. *IEEE Transactions on Power Systems*, 11(3):1509–1518, 1996.

[72] Vijay Babu Pamshetti and Shiv Pujan Singh. Optimal coordination of PV smart inverter and traditional volt-VAR control devices for energy cost savings and voltage regulation. *International Transactions on Electrical Energy Systems*, 29(7):1–24, 2019.

[73] Sadaf Rahimi Far, Ali Moeini, Ambrish Chandra, and Innocent Kamwa. ADMM-Based Multi-Objective Control Scheme for Mitigating the Impact of High Penetration DER

Integration in the Modern Distribution Systems. *IEEE Access*, 11(April):38589–38603, 2023.

[74] Xiangjing Su, Mohammad A.S. Masoum, and Peter J. Wolfs. Optimal PV inverter reactive power control and real power curtailment to improve performance of unbalanced four-wire LV distribution networks. *IEEE Transactions on Sustainable Energy*, 5(3):967–977, 2014.

[75] G. Carpinelli, F. Mottola, D. Proto, and P. Varilone. Minimizing unbalances in low-voltage microgrids: Optimal scheduling of distributed resources. *Applied Energy*, 191:170–182, 2017.

[76] Chiyang Zhong, A. P. Sakis Meliopoulos, Boqi Xie, Jiahao Xie, and Kaiyu Liu. Multi-Stage Quadratic Flexible Optimal Power Flow with a Rolling Horizon. *IEEE Transactions on Smart Grid*, 12(4):3128–3137, 2021.

[77] Shaoyun Ge, Zhengyang Xu, Hong Liu, Mengyi Liu, Zan Yang, and Chenghao Zhang. Coordinated voltage control for active distribution network considering the impact of energy storage. *Energy Procedia*, 158(2018):1122–1127, 2019.

[78] Moataz Ammar and Adel M. Sharaf. Optimized Use of PV Distributed Generation in Voltage Regulation: A Probabilistic Formulation. *IEEE Transactions on Industrial Informatics*, 15(1):247–256, 2019.

[79] Oğuzhan Ceylan, Guodong Liu, and Kevin Tomsovic. Coordinated distribution network control of tap changer transformers, capacitors and PV inverters. *Electrical Engineering*, 100(2):1133–1146, 2018.

[80] Seok Il Go, Sang Yun Yun, Seon Ju Ahn, and Joon Ho Choi. Voltage and Reactive Power Optimization Using a Simplified Linear Equations at Distribution Networks with DG. *Energies*, 13(13), 2020.

[81] Vinay Kumar Tatikayala and Shishir Dixit. Multi-stage voltage control in high photovoltaic based distributed generation penetrated distribution system considering smart inverter reactive power capability. *Ain Shams Engineering Journal*, (xxxx):102265, 2023.

[82] Stavros Karagiannopoulos, Costas Mylonas, Petros Aristidou, and Gabriela Hug. Active Distribution Grids Providing Voltage Support: The Swiss Case. *IEEE Transactions on Smart Grid*, 12(1):268–278, 2021.

[83] Mohammad A.A. Al-Ja'Afreh and Geev Mokryani. Voltage unbalance mitigation in low voltage distribution networks using time series three-phase optimal power flow. *2021 56th International Universities Power Engineering Conference: Powering Net Zero Emissions, UPEC 2021 - Proceedings*, 2021.

[84] Yoongun Jung, Changhee Han, Dongwon Lee, Sungyoon Song, and Gilsoo Jang. Adaptive volt–var control in smart pv inverter for mitigating voltage unbalance at pcc using multiagent deep reinforcement learning. *Applied Sciences (Switzerland)*, 11(19), 2021.

[85] Pedro P. Vergara, Juan S. Giraldo, Mauricio Salazar, Nanda K. Panda, and Phuong H. Nguyen. A Mixed-integer Linear Programming Model for Defining Customer Export Limit in PV-rich Low-voltage Distribution Networks. *Journal of Modern Power Systems and Clean Energy*, 11(1):191–200, 2023.

[86] Changfu Li, Vahid R. Disfani, Hamed Valizadeh Haghi, and Jan Kleissl. Coordination of OLTC and smart inverters for optimal voltage regulation of unbalanced distribution networks. *Electric Power Systems Research*, 187(June):106498, 2020.

[87] Singh S.P. Shailendra, S., Pamshetti, V.B., Thakur, A.K. Multistage multiobjective Volt/VAR control for smart grid-enabled CVR with solar PV penetration. *IEEE Systems Journal*, 15(2):2767–2778, 2020.

[88] Cuo Zhang, Yan Xu, Zhao Yang Dong, and Rui Zhang. Multi-Objective Adaptive Robust Voltage/VAR Control for High-PV Penetrated Distribution Networks. *IEEE Transactions on Smart Grid*, 11(6):5288–5300, 2020.

[89] Ruipeng Xu, Cuo Zhang, Yan Xu, Zhaoyang Dong, and Rui Zhang. Multi-Objective Hierarchically-Coordinated Volt/Var Control for Active Distribution Networks with Droop-Controlled PV Inverters. *IEEE Transactions on Smart Grid*, 13(2):998–1011, 2022.

[90] Rabih A. Jabr. Linear Decision Rules for Control of Reactive Power by Distributed Photovoltaic Generators. *IEEE Transactions on Power Systems*, 33(2):2165–2174, 2018.

[91] Renbo Wu and Shuqin Liu. Deep learning based muti-objective reactive power optimization of distribution network with PV and EVs. *Sensors*, 22:4321, 2022.

[92] Jian Xu, Jing Wang, Siyang Liao, Yuanzhang Sun, Deping Ke, Xiong Li, Ji Liu, Yibo Jiang, Congying Wei, and Bowen Tang. Stochastic multi-objective optimization of photovoltaics integrated three-phase distribution network based on dynamic scenarios. *Applied Energy*, 231(May):985–996, 2018.

[93] Hanshen Li, Wenxia Liu, and Lu Yu. Centralized-local PV voltage control considering opportunity constraint of short-term fluctuation. *Global Energy Interconnection*, 6(1):81–91, 2023.

[94] Qingmian Chai, Cuo Zhang, Ziyuan Tong, Shuai Lu, Wen Chen, and Zhao Yang Dong. PV Inverter Reliability Constrained Volt/Var Control with Power Smoothing via a Convex-Concave Programming Method. *IEEE Transactions on Industrial Informatics*, 19(1):109–120, 2023.

[95] Haoran Ji, Chengshan Wang, Peng Li, Jinli Zhao, Guanyu Song, Fei Ding, and Jianzhong Wu. A centralized-based method to determine the local voltage control strategies of distributed generator operation in active distribution networks. *Applied Energy*, 228(July):2024–2036, 2018.

[96] Xiuling Jin, Zohre Moradi, and Rohollah Rashidi. Optimal Operation of Distributed Generations in Four-Wire Unbalanced Distribution Systems considering Different Models of Loads. *International Transactions on Electrical Energy Systems*, 2023, 2023.

[97] Vineeth Vijayan, Abheejeet Mohapatra, Sri Niwas Singh, and Chaman Lal Dewangan. An Efficient Modular Optimization Scheme for Unbalanced Active Distribution Networks with Uncertain EV and PV Penetrations. *IEEE Transactions on Smart Grid*, 14(5):3876–3888, 2023.

[98] C. SiMa X. Su, Y. Liu, S. Tian, P. Ling, Y. Fu, S. Wei. A Multi-Stage Coordinated Volt-Var Optimization for Integrated and Unbalanced Radial Distribution Networks. *Energies*, 13(4877):19, 2020.

[99] Wei Ma, Wei Wang, Zhe Chen, and Ruonan Hu. A centralized voltage regulation method for distribution networks containing high penetrations of photovoltaic power. *International Journal of Electrical Power and Energy Systems*, 129(December 2020):106852, 2021.

[100] Dan Jin, Hsiao Dong Chiang, and Peng Li. Two-Timescale Multi-Objective Coordinated Volt/Var Optimization for Active Distribution Networks. *IEEE Transactions on Power Systems*, 34(6):4418–4428, 2019.

[101] Zhengfa Zhang, Filipe Faria da Silva, Yifei Guo, Claus Leth Bak, and Zhe Chen. Double-layer stochastic model predictive voltage control in active distribution networks with high penetration of renewables. *Applied Energy*, 302(August):117530, 2021.

[102] Ashraf Ramadan, Mohamed Ebeed, and Salah Kamel. Performance Assessment of a Realistic Egyptian Distribution Network Including PV Penetration with DSTATCOM. *Proceedings of 2019 International Conference on Innovative Trends in Computer Engineering, ITCE 2019*, pages 426–431, 2019.

[103] Hyeongjin Lee, Jae Chul Kim, and Sung Min Cho. Optimal volt-var curve setting of a smart inverter for improving its performance in a distribution system. *IEEE Access*, 8:157931–157945, 2020.

[104] Fei Ding, Yingchen Zhang, Jeffery Simpson, Andrey Bernstein, and Subramanian Vadari. Optimal energy dispatch of distributed PVS for the next generation of distribution management systems. *IEEE Open Access Journal of Power and Energy*, 7(1):287–295, 2020.

[105] Hyeong Jin Lee, Kwang Hoon Yoon, Joong Woo Shin, Jae Chul Kim, and Sung Min Cho. Optimal parameters of volt-var function in smart inverters for improving system performance. *Energies*, 13(9):13–16, 2020.

[106] Emiliano Dall'Anese, Sairaj V. Dhople, Brian B. Johnson, and Georgios B. Giannakis. Decentralized optimal dispatch of photovoltaic inverters in residential distribution systems. *IEEE Transactions on Energy Conversion*, 29(4):957–967, 2014.

[107] Keyan Liu, Huiyu Zhan, Yuhan Wei, and Tianyuan Kang. A dynamic optimization method for power distribution network operation with high ratio photovoltaics. *IET Generation, Transmission and Distribution*, 16(21):4417–4432, 2022.

[108] Shilpa Kalambe and Ganga Agnihotri. Loss minimization techniques used in distribution network: bibliographical survey. *Renewable and Sustainable Energy Reviews*, 29:184–200, 2014.

[109] D. Shirmohammadi and H.W. Hong. Reconfiguration of electric distribution networks for resistive line losses reduction. *IEEE Transactions on Power Delivery*, 4(2):1492–1498, 1989.

[110] J. J. Grainger and S. H. Lee. Optimum size and location of shunt capacitors for reduction of losses on distribution feeders. *IEEE Transactions on Power Apparatus and Systems*, PAS-100(3):1105–1118, 1981.

[111] H.L. Willis. Analytical methods and rules of thumb for modeling dg-distribution interaction. In *2000 Power Engineering Society Summer Meeting (Cat. No.00CH37134)*, volume 3, pages 1643–1644 vol. 3, 2000.

[112] Farhad Shahnia, Ritwik Majumder, Arindam Ghosh, Gerard Ledwich, and Firuz Zare. Voltage imbalance analysis in residential low voltage distribution networks with rooftop pvs. *Electric Power Systems Research*, 81(9):1805–1814, 2011.

[113] Benvindo R. Pereira, Geraldo R. Martins da Costa, Javier Contreras, and José R. Sanches Mantovani. Optimal distributed generation and reactive power allocation in electrical distribution systems. *IEEE Transactions on Sustainable Energy*, 7(3):975–984, 2016.

[114] Mohamed E. Elkhatib, Ramadan El Shatshat, and Magdy M. A. Salama. Decentralized reactive power control for advanced distribution automation systems. *IEEE Transactions on Smart Grid*, 3(3):1482–1490, 2012.

[115] Ali Safayet, Poria Fajri, and Iqbal Husain. Reactive Power Management for Overvoltage Prevention at High PV Penetration in a Low-Voltage Distribution System. *IEEE Transactions on Industry Applications*, 53(6):5786–5794, 2017.

[116] Markus Kraiczy, Thomas Stetz, and Martin Braun. Parallel operation of transformers with on load tap changer and photovoltaic systems with reactive power control. *IEEE Transactions on Smart Grid*, 9(6):6419–6428, 2018.

[117] Xiangyu Li, Christine Yip, Zhao Yang Dong, Cuo Zhang, and Bo Wang. Hierarchical control on EV charging stations with ancillary service functions for PV hosting capacity maximization in unbalanced distribution networks. *International Journal of Electrical Power and Energy Systems*, 160(January 2023):110097, 2024.

[118] Tripti Gangwar, Narayana Prasad Padhy, and Premalata Jena. Energy Management Approach to Battery Energy Storage in Unbalanced Distribution Networks. *IEEE Transactions on Industry Applications*, 60(1):1345–1356, 2024.

[119] Ramin Ebadi, F. M. Aboshady, Oguzhan Ceylan, Ioana Pisica, and Aydogan Ozdemir. Multi-Criteria Decision Making in Optimal Operation Problem of Unbalanced Distribution Networks Integrated With Photovoltaic Units. *IEEE Access*, 12(March):79481–79495, 2024.

[120] K. Rushikesh Babu and Dheeraj K. Khatod. Smart Inverter-Based Distributed Volt/Var Control for Voltage Violation Mitigation of Unbalanced Distribution Networks. *IEEE Transactions on Power Delivery*, 39(3):1481–1490, 2024.

[121] Izzah Afandi, Ashish P. Agalgaonkar, and Sarath Perera. Integrated Volt/Var Control Method for Voltage Regulation and Voltage Unbalance Reduction in Active Distribution Networks. *Energies*, 15(6), 2022.

[122] Kshitij Girigoudar, Mengqi Yao, Johanna L. Mathieu, and Line A. Roald. Integration of Centralized and Distributed Methods to Mitigate Voltage Unbalance Using Solar Inverters. *IEEE Transactions on Smart Grid*, 14(3):2034–2046, 2023.

[123] Brett A. Robbins and Alejandro D. Domínguez-García. Optimal Reactive Power Dispatch for Voltage Regulation in Unbalanced Distribution Systems. *IEEE Transactions on Power Systems*, 31(4):2903–2913, 2016.

[124] Raju Wagle, Pawan Sharma, Charu Sharma, and Mohammad Amin. Optimal power flow based coordinated reactive and active power control to mitigate voltage violations in smart inverter enriched distribution network. *International Journal of Green Energy*, 00(00):1–17, 2023.

[125] Wentian Lu, Mingbo Liu, and Qingkai Liu. Increment-Exchange-Based Decentralized Multiobjective Optimal Power Flow for Active Distribution Grids. *IEEE Systems Journal*, 14(3):3695–3704, 2020.

[126] Yih Der Lee, Wei Chen Lin, Jheng Lun Jiang, Jia Hao Cai, Wei Tzer Huang, and Kai Chao Yao. Optimal individual phase voltage regulation strategies in active distribution networks with high PV penetration using the sparrow search algorithm. *Energies*, 14(24), 2021.

[127] Gerardo Humberto Valencia-Rivera, Maria Torcoroma Benavides-Robles, Alonso Vela Morales, Ivan Amaya, Jorge M. Cruz-Duarte, José Carlos Ortiz-Bayliss, and Juan Gabriel Avina-Cervantes. A systematic review of metaheuristic algorithms in electric power systems optimization. *Applied Soft Computing*, 150:111047, 2024.

[128] Zongjie Wang, Abdollah Younesi, M. Vivienne Liu, Ge Claire Guo, and C. Lindsay Anderson. Ac optimal power flow in power systems with renewable energy integration: A review of formulations and case studies. *IEEE Access*, 11:102681–102712, 2023.

[129] R. Bacher. Netzleittechnik und Optimierung elektrischer Netze. (October), 2000.

[130] Steven H. Low. Convex relaxation of optimal power flow - Part i: Formulations and equivalence. *IEEE Transactions on Control of Network Systems*, 1(1):15–27, 2014.

[131] Stephen Frank, Ingrid Steponavice, and Steffen Rebennack. Optimal power flow: A bibliographic survey II Non-deterministic and hybrid methods. *Energy Systems*, 3(3):259–289, 2012.

[132] J. Zhu, H., Liu, H. Fast Local Voltage Control Under Limited Reactive Power: Optimality and Stability Analysis. *IEEE TRANSACTIONS ON POWER SYSTEMS*, pages 1–10, 2015.

[133] Christian Utama, Christian Meske, Johannes Schneider, and Carolin Ulbrich. Reactive power control in photovoltaic systems through (explainable) artificial intelligence. *Applied Energy*, 328(September):120004, 2022.

[134] Temitayo O. Olowu, Mohamadsaleh Jafari, and Arif I. Sarwat. A Multi-Objective Optimization Technique for Volt-Var Control with High PV Penetration using Genetic Algorithm. *2018 North American Power Symposium, NAPS 2018*, 2019.

[135] Capuder Tomislav Gržanić Mirna, Zidar Matija. KONVEKSNI OPTIMIZACIJISKI MODELI ZA POGON I PLANIRANJE NAPREDNIH DISTRIBUCIJSKIH MREŽA. In *13. savjetovanje HRO CIGRÉ*, pages 1–9, Šibenik, 2017.

[136] Steven H. Low. Convex relaxation of optimal power flow—part ii: Exactness. *IEEE Transactions on Control of Network Systems*, 1(2):177–189, 2014.

[137] Wu F.F. Baran M. E. Optimal Capacitor Placement on radial distribution systems. *IEEE Trans. Power Delivery*, 4(1):725–734, 1989.

[138] Wu F.F. Baran M. E. Optimal sizing of capacitors placed on a radial distribution system. *IEEE Transactions on Power Delivery*, 4(1):735–743, 1989.

[139] Ibrahim Anwar Ibrahim and M. J. Hossain. Low Voltage Distribution Networks Modeling and Unbalanced (Optimal) Power Flow: A Comprehensive Review. *IEEE Access*, 9:143026–143084, 2021.

[140] Roberto Ruggeri, Riccardo Primi, Pier Paolo Danieli, Bruno Ronchi, and Francesco Rossini. A General Framework for Active Distribution Network Planning. In *Cigre*, number 1, Lisabon, 2013.

[141] Reza Dashti and Mojtaba Rouhandeh. Power distribution system planning framework (a comprehensive review). *Energy Strategy Reviews*, 50:101256, 2023.

[142] Abdollah Rastgou. Distribution network expansion planning: An updated review of current methods and new challenges. *Renewable and Sustainable Energy Reviews*, 189:114062, 2024.

[143] Vahid Vahidinasab, Mahdi Tabarzadi, Hamidreza Arasteh, Mohammad Iman Alizadeh, Mohammad Mohammad Beigi, Hamid Reza Sheikhzadeh, Kamyar Mehran, and

Mohammad Sadegh Sepasian. Overview of electric energy distribution networks expansion planning. *IEEE Access*, 8:34750–34769, 2020.

[144] Simon Gill, Ivana Kockar, and Graham W. Ault. Dynamic optimal power flow for active distribution networks. *IEEE Transactions on Power Systems*, 29(1):121–131, 2014.

[145] David Trebolle, Per Hallberg, Gunnar Lorenz, Pavla Mandatova, and Jorge Tello Guijarro. Active distribution system management. In *22nd International Conference and Exhibition on Electricity Distribution (CIRED 2013)*, pages 1–4, 2013.

[146] Sima Davarzani, Ioana Pisica, Gareth A. Taylor, and Kevin J. Munisami. Residential demand response strategies and applications in active distribution network management. *Renewable and Sustainable Energy Reviews*, 138:110567, 2021.

[147] Joaquín Lazo and David Watts. Stochastic model for active distribution networks planning: An analysis of the combination of active network management schemes. *Renewable and Sustainable Energy Reviews*, 191(June 2023):114156, 2024.

[148] Hamid Soleimani Bidgoli and Thierry Van Cutsem. Combined Local and Centralized Voltage Control in Active Distribution Networks. *IEEE Transactions on Power Systems*, 33(2):1374–1384, 2018.

[149] Yongxi Zhang, Yan Xu, Hongming Yang, and Zhao Yang Dong. Voltage regulation-oriented co-planning of distributed generation and battery storage in active distribution networks. *International Journal of Electrical Power & Energy Systems*, 105:79–88, 2019.

[150] Abhishek Kumar, Nand K. Meena, Arvind R. Singh, Yan Deng, Xiangning He, R.C. Bansal, and Praveen Kumar. Strategic integration of battery energy storage systems with the provision of distributed ancillary services in active distribution systems. *Applied Energy*, 253:113503, 2019.

[151] Syed Ali Abbas Kazmi, Muhammad Khuram Shahzad, and Dong Ryeol Shin. Multi-objective planning techniques in distribution networks: A composite review. *Energies*, 10(2), 2017.

[152] Ming Wu, Lingfeng Kou, Xiaogang Hou, Yu Ji, Bin Xu, and Hongjun Gao. A bi-level robust planning model for active distribution networks considering uncertainties of renewable energies. *International Journal of Electrical Power & Energy Systems*, 105:814–822, 2019.

[153] Xiaomin Xu, Dongxiao Niu, Luyao Peng, Shipeng Zheng, and Jinpeng Qiu. Hierarchical multi-objective optimal planning model of active distribution network considering distributed generation and demand-side response. *Sustainable Energy Technologies and Assessments*, 53:102438, 2022.

[154] Cuo Zhang, Yan Xu, Zhaoyang Dong, and Jayashri Ravishankar. Three-stage robust inverter-based voltage/var control for distribution networks with high-level pv. *IEEE Transactions on Smart Grid*, 10(1):782–793, 2019.

[155] Milad Kabirifar, Mahmud Fotuhi-Firuzabad, Moein Moeini-Aghtaie, and Niloofar Pourghaderi. Multistage active distribution network integrated planning incorporating energy storage systems and active network management. *2020 IEEE 4th International Conference on Intelligent Energy and Power Systems, IEPS 2020 - Proceedings*, pages 163–168, 2020.

[156] Xinwei Shen, Mohammad Shahidehpour, Shouzhen Zhu, Yingduo Han, and Jinghong Zheng. Multi-stage planning of active distribution networks considering the co-optimization of operation strategies. *IEEE Transactions on Smart Grid*, 9(2):1425–1433, 2018.

[157] Tomislav Antić, Tomislav Capuder, and Martin Bolfek. A comprehensive analysis of the voltage unbalance factor in pv and ev rich non-synthetic low voltage distribution networks. *Energies*, 14(1), 2021.

[158] HRN EN 50160:2023: Naponske karakteristike električne energije iz javnih distribucijskih mreža (EN 50160:2022). https://repozitorij.hzn.hr/norm/HRN+EN+50160{%}3A2023 (pristup: 19. veljače 2025.).

[159] Beenish Sultana, M.W. Mustafa, U. Sultana, and Abdul Rauf Bhatti. Review on reliability improvement and power loss reduction in distribution system via network reconfiguration. *Renewable and Sustainable Energy Reviews*, 66:297–310, 2016.

[160] Mohamed E El-Hawary, Me El-Hawary, A Bose, Am DiCaprio, PJM Interconnection, Ar El-Kieb, TJ Hammons, JH Jones, Sa P Kundur, Power Tech Labs, FN Lee, A Papalexopoulos, Pacific Gas, M Poloujadoff, Universite Pierre, Marie Curie, N Rau, M Shahidehpour, WL Snyder, A Dy, C Booth, JR McDonald, A Carter, GM Burt, and J Clark. Power Engineering Letters. *IEEE Power Engineering Review*, (May):49–51, 2001.

[161] M. Mejbaul Haque and Peter Wolfs. A review of high pv penetrations in lv distribution networks: Present status, impacts and mitigation measures. *Renewable and Sustainable Energy Reviews*, 62:1195–1208, 2016.

[162] Marina Dubravac, Krešimir Fekete, Danijel Topić, and Marinko Barukčić. Voltage Optimization in PV-Rich Distribution Networks—A Review. *Applied Sciences (Switzerland)*, 12(23), 2022.

[163] Marina Dubravac, Matej Žnidarec, Krešimir Fekete, and Danijel Topić. Multi-stage operation optimization of pv-rich low-voltage distribution networks. *Applied Sciences*, 14(1), 2024.

[164] Marina Dubravac, Zvonimir Šimić, Danijel Topić, Goran Knežević, and Krešimir Fekete. Analysis of PV and EV Chargers Integration Impact on Radial LV Distribution Network. *2023 8th International Conference on Smart and Sustainable Technologies, SpliTech 2023*, pages 1–5, 2023.

[165] Marina Dubravac, Matej Žnidarec, Krešimir Fekete, and Danijel Topié. A new co-simulation approach of active power curtailment for voltage optimization in pv-rich distribution networks. In *2023 IEEE 6th International Conference and Workshop Óbuda on Electrical and Power Engineering (CANDO-EPE)*, pages 000065–000070, 2023.

[166] Marina Dubravac, Danijel Topić, Krešimir Fekete, Zvonimir Šimić, Rene Prenc, and Michele Rojnić. Active power curtailment and reactive power control in pv-rich low-voltage distribution network. In *2024 20th International Conference on the European Energy Market (EEM)*, pages 1–6, 2024.

[167] Lennart H. Söder and Mikael Amelin. Efficient operation and planning of power systems. 2011.

[168] Pyomo. https://pyomo.readthedocs.io/en/stable/ (pristup 17. veljače 2025.).

[169] J. Kennedy and R. Eberhart. Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks*, volume 4, pages 1942–1948 vol.4, 1995.

[170] Tareq M. Shami, Ayman A. El-Saleh, Mohammed Alswaitti, Qasem Al-Tashi, Mhd Amen Summakieh, and Seyedali Mirjalili. Particle swarm optimization: A comprehensive survey. *IEEE Access*, 10:10031–10061, 2022.

[171] Francesco Biscani and Dario Izzo. A parallel global multiobjective framework for optimization: pagmo. *Journal of Open Source Software*, 5(53):2338, 2020.

[172] Electric Power Research Institute. OpenDSS Documentation. https://opendss.epri.com/IntroductiontoOpenDSS.html (pristup 12. veljače 2025.).

[173] Nemanja Mišljenović, Matej Žnidarec, Goran Knežević, and Danijel Topić. Electric vehicles as flexible assets for households and system operators: Survey results. In *2024 International Conference on Smart Systems and Technologies (SST)*, pages 1–7, 2024.

[174] Mirta Benšić and Nenad Šuvak. *Uvod u vjerojatnost i statistiku.* Number January. 2014.

[175] IEEE. IEEE Low Voltage Test Feeder. https://cmte.ieee.org/pes-testfeeders/resources/ (pristup: 2. travnja 2025.).

[176] HEP – Operator distribucijskog sustava. Mrežna pravila distribucijskog sustava, 2018. https://narodne-novine.nn.hr/clanci/sluzbeni/2018{_}08{_}74{_}1539.html (pristup: 2. travnja 2025.).

[177] Growatt. https://en.growatt.com/ (pristup 2. travnja 2025.).

[178] ENWL, "LV network models". https://www.enwl.co.uk/zero-carbon/innovation/smaller-projects/low-carbon-networks-fund/low-voltage-network-solutions/{%}0A (pristup: 5. travnja 2025.).

[179] HRVATSKI OPERATOR PRIJENOSNOG SUSTAVA D.D. Mrežna pravila prijenosnog sustava, 2024. https://narodne-novine.nn.hr/clanci/sluzbeni/2024{_}01{_}10{_}199.html (pristup: 5. travnja 2025.).

Popis slika

2.1. Konfiguracija aktivnog kupca 10
2.2. Metode lokalnog upravljanja. 12
2.3. Mogućnosti izmjenjivača fotonaponske elektrane za optimizaciju pogona distribucijske mreže 13
2.4. Sheme sustava upravljanja aktivnom distribucijskom mrežom 22

3.1. Jednopolna shema distribucijske mreže 30
3.2. Primjer naponske nesimetrije u elektroenergetskom sustavu 32

4.1. Blokovska shema dvostupanjskog modela za planiranje pogona aktivne distribucijske mreže 37
4.2. Blokovska shema kosimulacijskog modela s uključenom metodom vrednovanja učinaka mehanizama upravljanja na funkcije cilja za planiranje pogona aktivne distribucijske mreže 39
4.3. Blokovska shema kosimulacijskog optimizacijskog okruženja sustava za planiranje pogona aktivne distribucijske mreže 43
4.4. Blokovska shema kosimulacijskog optimizacijskog okvira s pripadajućim alatima i paketima s naglašenom strukturom *OpenDSS* simulacijskog alata . . . 48
4.5. Blokovska shema modela fotonaponske elektrane u *OpenDSS-u* 49
4.6. PC element prikazan pomoću Nortonove ekvivalentne sheme u *OpenDSS-u* . 50

6.1. Pojednostavljeni dijagram toka optimizacijskog modela 70
6.2. Jednofazna shema testne mreže *IEEE European Low Voltage Test Feeder* . . 71
6.3. Intenzitet Sunčevog zračenja 72
6.4. Indikativni prikaz naponskog profila svakog čvora 74
6.5. Napon na čvoru 336 u Baznom slučaju 75
6.6. Napon na čvoru 336 u Baznom slučaju i 1. slučaju 76

6.7. Napon na sekundaru transformatora u 1. slučaju 77
6.8. Napon na čvoru 336 u Baznom slučaju i 1. podslučaju 77
6.9. Napon na čvoru 336 u Baznom slučaju i 2. podslučaju 78
6.10. Napon na čvoru 336 u Baznom slučaju i 3. podslučaju 79
6.11. Napon na čvoru 336 u Baznom slučaju i 4. podslučaju 79
6.12. Usporedba napona u svim slučajevima na čvoru 336 80
6.13. Model distribucijskog izvoda korištenog za testiranje kosimulacijskog modela 83
6.14. Utjecaj mehanizama upravljanja na funkciju cilja minimizaciju gubitaka . . . 97
6.15. Utjecaj mehanizama upravljanja na funkciju cilja minimizaciju devijacije napona 99
6.16. Utjecaj mehanizama upravljanja na funkciju cilja minimizaciju naponske nesimetrije 100
6.17. Usporedba iznosa gubitaka kada su funkcije cilja minimizacija devijacije napona i minimizacija faktora naponske nesimetrije 101
6.18. Usporedba iznosa maksimalnog i minimalnog napona kada su funkcije cilja minimizacija gubitaka i minimizacija faktora naponske nesimetrije 102
6.19. Usporedba iznosa faktora naponske nesimetrije kada su funkcije cilja minimizacija gubitaka i minimizacija devijacije napona 103
6.20. Naponski profil najkritičnijeg čvora 104
6.21. Naponski profil najkritičnije faze kada je funkcija cilja minimizacija gubitaka 105
6.22. Naponski profil najkritičnije faze kada je funkcija cilja minimizacija devijacije napona 106
6.23. Naponski profil najkritičnije faze kada je funkcija cilja minimizacija faktora naponske nesimetrije 107
6.24. Gubici djelatne energije kada je funkcija cilja minimizacija gubitaka 108
6.25. Gubici djelatne energije kada je funkcija cilja minimizacija devijacije napona 109
6.26. Gubici djelatne energije kada je funkcija cilja minimizacija faktora naponske nesimetrije 110
6.27. Opterećenje najkritičnije grane kada je funkcija cilja minimizacija gubitaka . 111
6.28. Opterećenje najkritičnije grane kada je funkcija cilja minimizacija devijacije napona 112
6.29. Opterećenje najkritičnije grane kada je funkcija cilja minimizacija faktora naponske nesimetrije 113

6.30. Iznosi mehanizama upravljanja kada je funkcija cilja minimizacija gubitaka . 114
6.31. Napon na sekundaru transformatora kada je funkcija cilja minimizacija gubitaka 115
6.32. Iznosi mehanizama upravljanja kada je funkcija cilja minimizacija devijacije napona 116
6.33. Napon na sekundaru transformatora kada je funkcija cilja minimizacija devijacije napona 117
6.34. Iznos mehanizama upravljanja kada je funkcija cilja minimizacija faktora naponske nesimetrije 118
6.35. Napon na sekundaru transformatora kada je funkcija cilja minimizacija faktora naponske nesimetrije 119

P1. Primjeri profila potrošnje korišteni u dvostupanjskom modelu za planiranje pogona aktivne distribucijske mreže 149
P2. Primjeri profila proizvodnje korišten u kosimulacijskom modelu za planiranje pogona aktivne distribucijske mreže 151
P3. Primjeri profila potrošnje korišteni u kosimulacijskom modelu za planiranje pogona aktivne distribucijske mreže 152
P4. Snaga punjenja električnih vozila korištena kod kosimulacijskom modelu za planiranje pogona aktivne distribucijske mreže 153
P5. Gubici jalove energije kada je funkcija cilja minimizacija gubitaka 153
P6. Gubici jalove energije kada je funkcija cilja minimizacija devijacije napona . 154
P7. Gubici jalove energije kada je funkcija cilja minimizacija faktora naponske nesimetrije 154
P8. Primjer iznosa djelatne i jalove snage jedne fotonaponske elektrane kada je funkcija cilja minimizacija gubitaka, a mehanizam upravljanja djelatna i jalova snaga izmjenjivača i snaga punjenja električnog vozila 155
P9. Primjer iznosa djelatne i jalove snage jedne fotonaponske elektrane kada je funkcija cilja minimizacija devijacije napona, a mehanizam upravljanja djelatna i jalova snaga izmjenjivača i snaga punjenja električnog vozila 155
P10. Primjer iznosa djelatne i jalove snage jedne fotonaponske elektrane kada je funkcija cilja minimizacija faktora naponske nesimetrije, a mehanizam upravljanja djelatna i jalova snaga izmjenjivača i snaga punjenja električnog vozila 156

Popis tablica

2.1. Sustavi za upravljanje u pasivnim i aktivnim mrežama s obzirom na različite aspekte promatranja 20

3.1. Dopuštena opterećenja vodova i transformatora za planiranje pogona distribucijske mreže [16]. 29

6.1. Opis ispitanih slučajeva. 73

6.2. Iznos funkcije cilja u ispitanim slučajevima. 75

6.3. Gubici djelatne energije i maksimalne vrijednosti napona u svakom simulacijskom slučaju. 81

6.4. Provedeni simulacijski slučajevi. 84

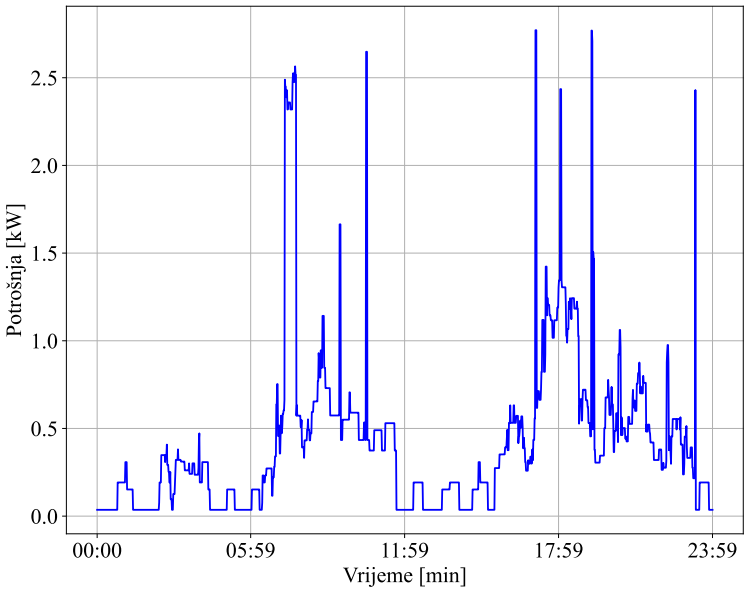
6.5. Vrijednosti gubitaka djelatne snage, napona i faktora naponske nesimetrije prije optimizacije. 85

6.6. Iznos funkcije cilja i varijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija gubitaka. 88

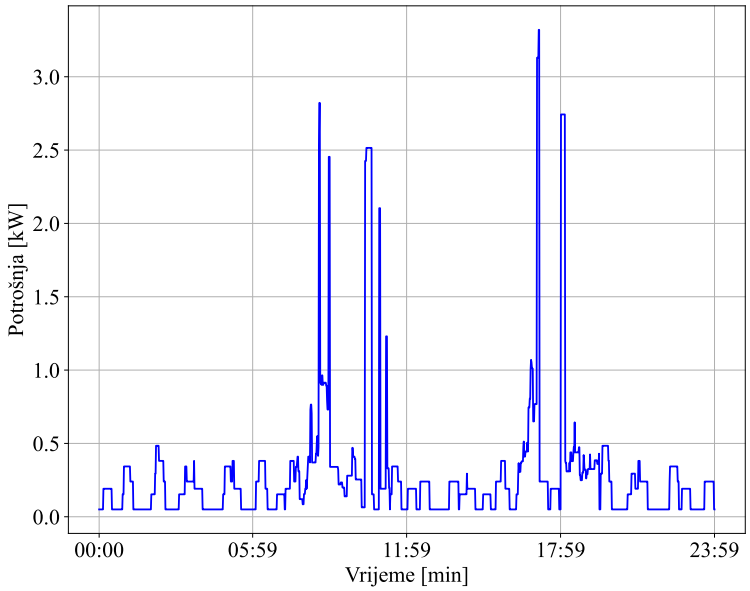
6.7. Iznos funkcije cilja i varijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija devijacije napona. 92

6.8. Iznos funkcije cilja i varijabli stanja pri različitim mehanizmima upravljanja kada je funkcija cilja minimizacija faktora naponske nesimetrije. 95

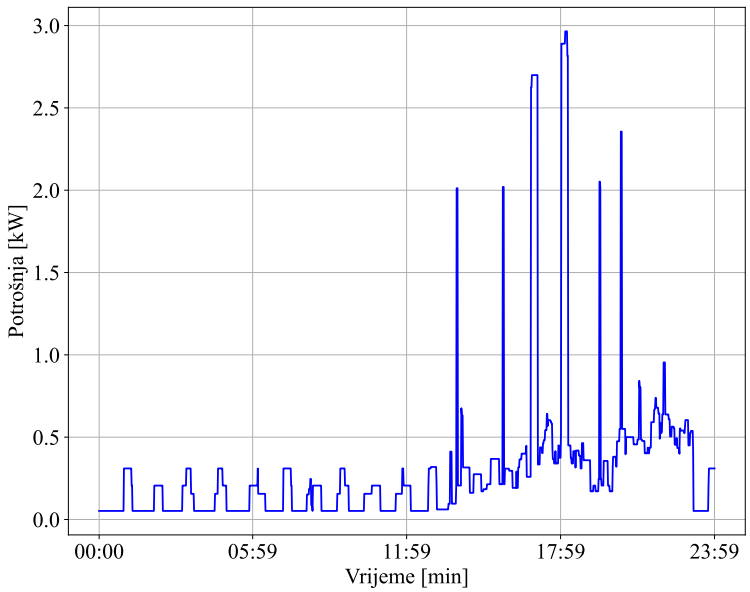
Prilozi



(a) *Profil potrošnje 1*

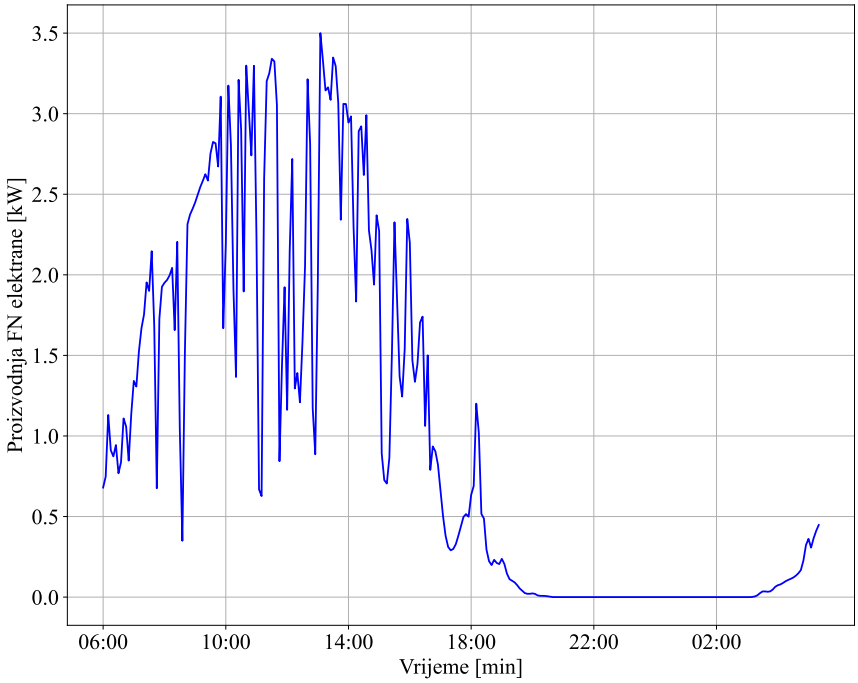


(b) *Profil potrošnje 2*

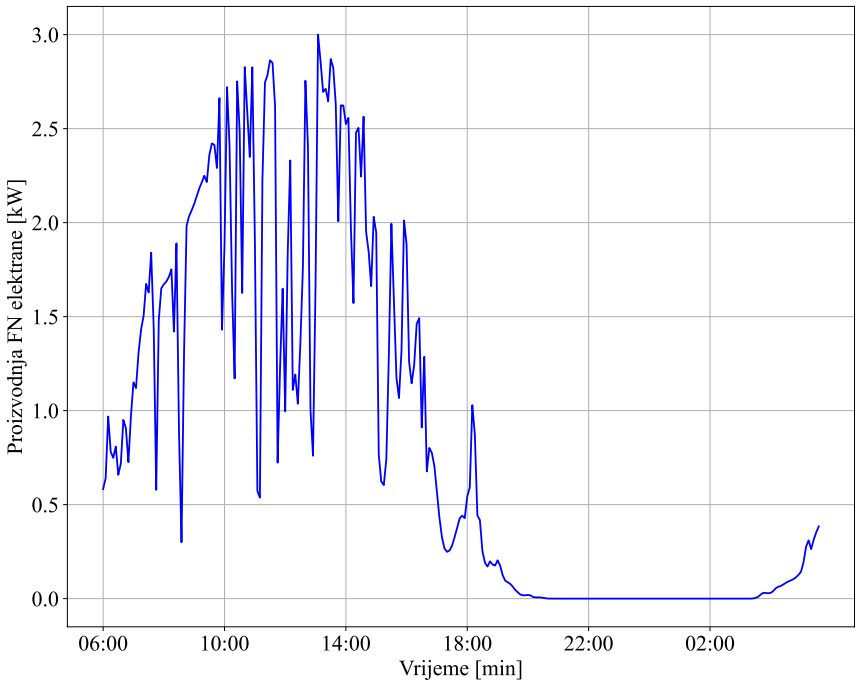


(c) *Profil potrošnje 3*

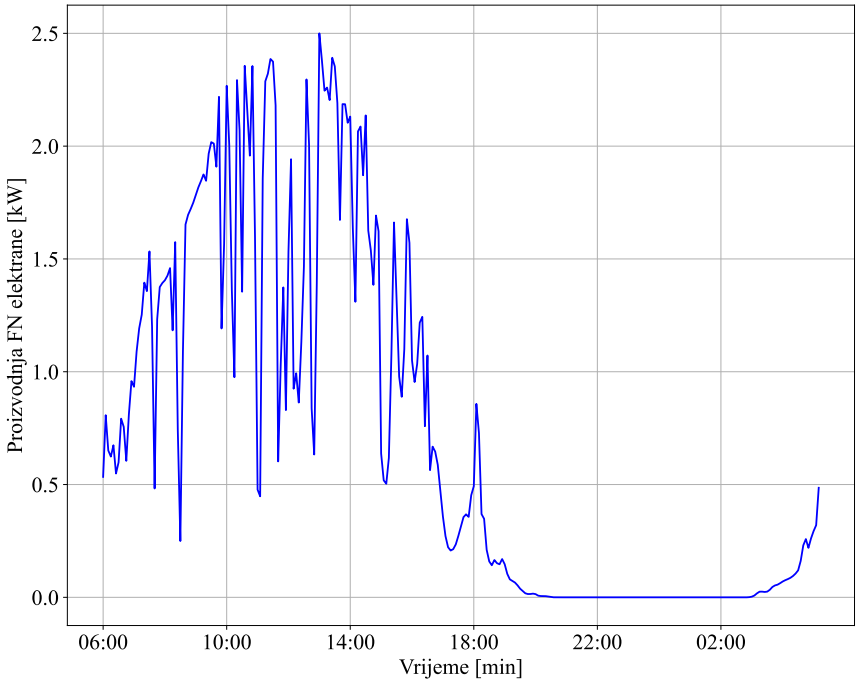
Slika P1: *Primjeri profila potrošnje korišteni u dvostupanjskom modelu za planiranje pogona aktivne distribucijske mreže*



(a) *Profil proizvodnje iz fotonaponske elektrane 1*

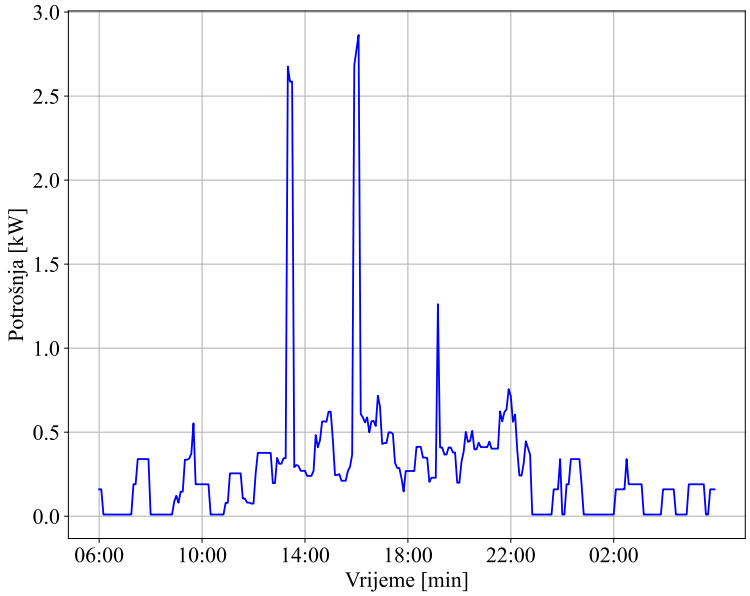


(b) *Profil proizvodnje iz fotonaponske elektrane 3*

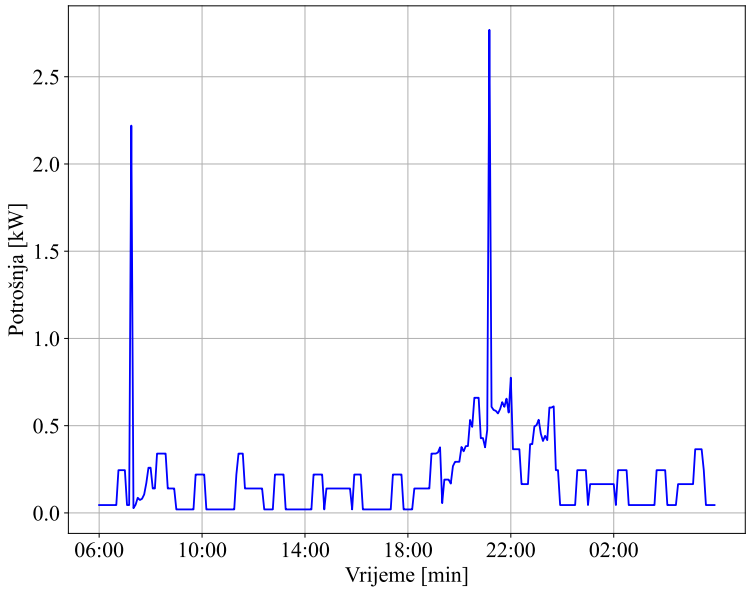


(c) *Profil proizvodnje iz fotonaponske elektrane 2*

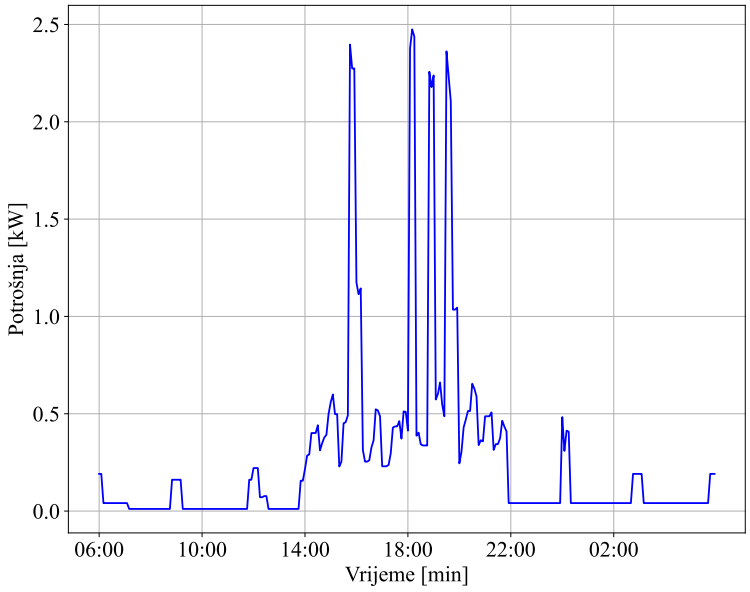
Slika P2: *Primjeri profila proizvodnje korišten u kosimulacijskom modelu za planiranje pogona aktivne distribucijske mreže*



(a) *Profil potrošnje 1*

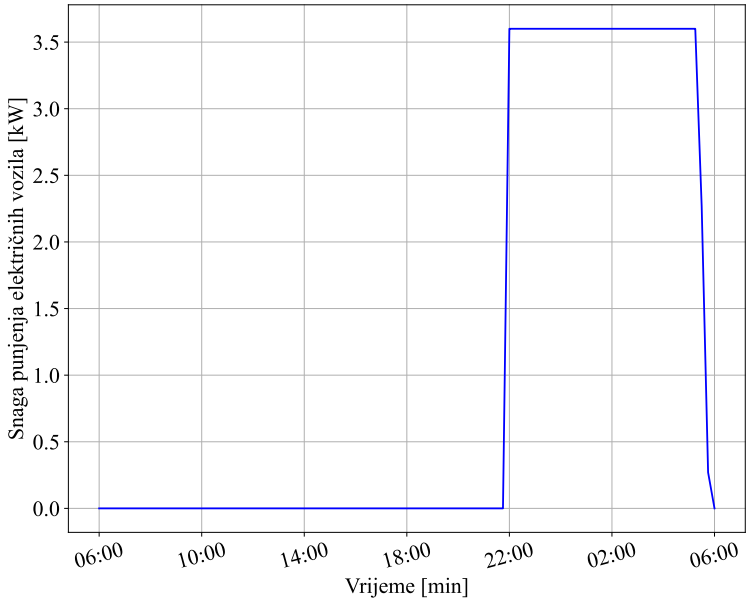


(b) *Profil potrošnje 2*

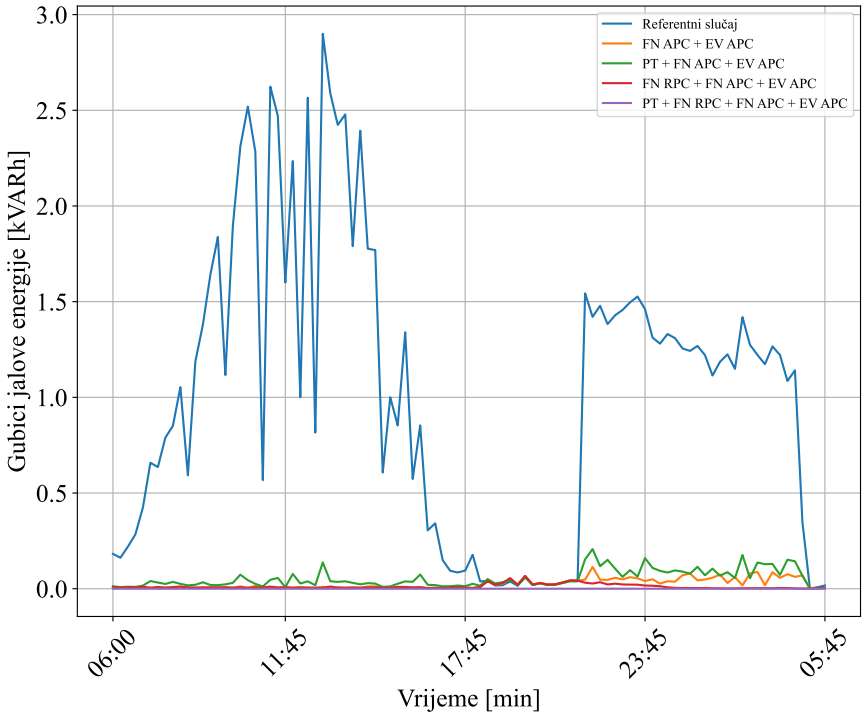


(c) *Profil potrošnje 3*

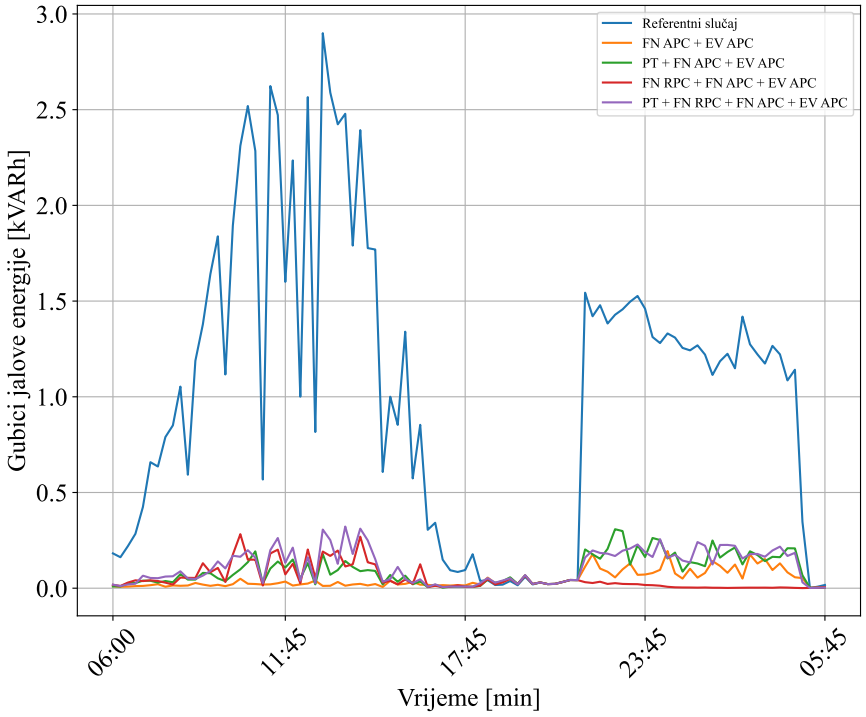
Slika P3: *Primjeri profila potrošnje korišteni u kosimulacijskom modelu za planiranje pogona aktivne distribucijske mreže*



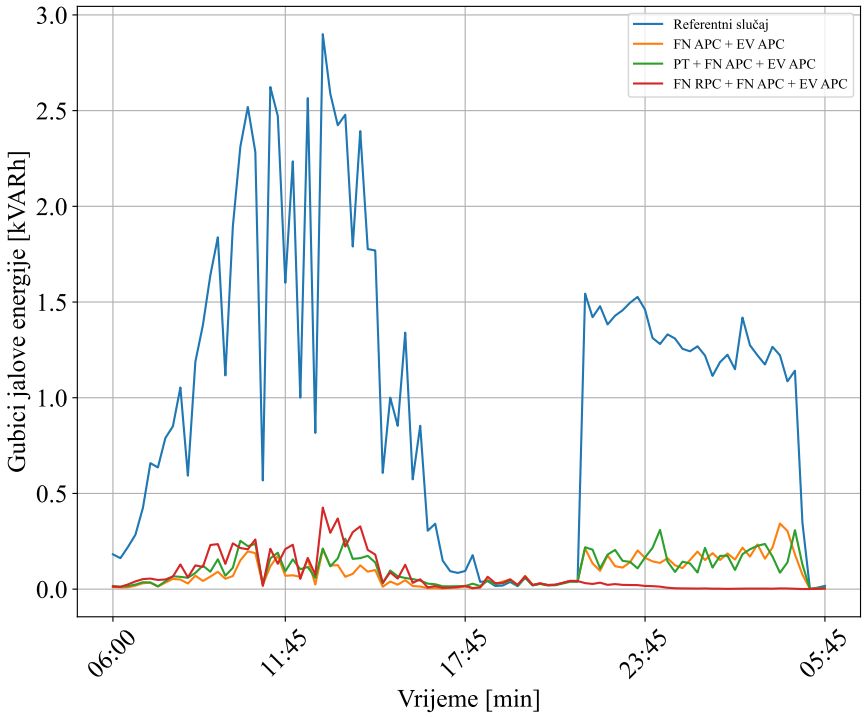
Slika P4: *Snaga punjenja električnih vozila korištena kod kosimulacijskom modelu za planiranje pogona aktivne distribucijske mreže*



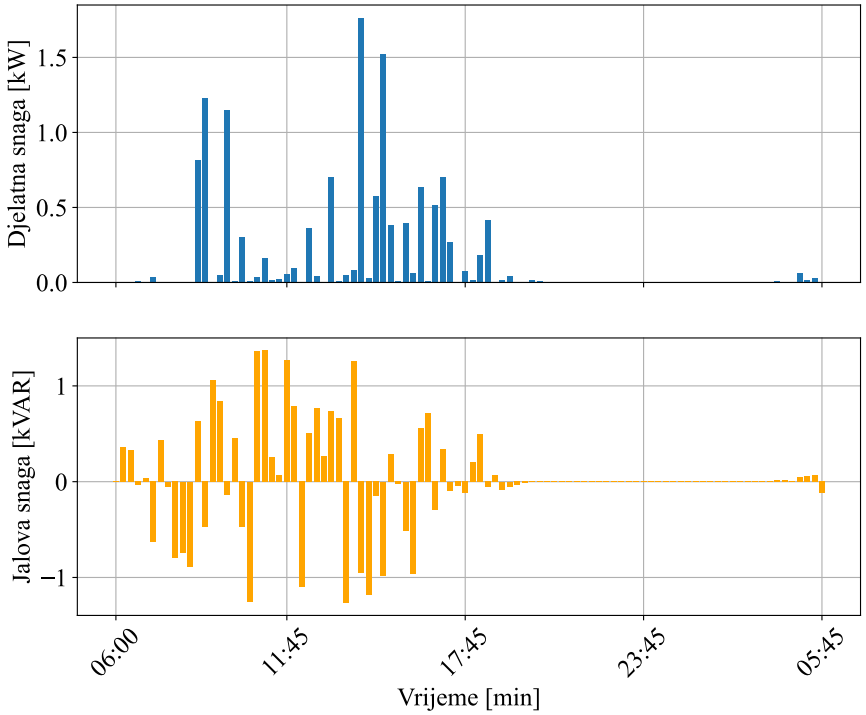
Slika P5: *Gubici jalove energije kada je funkcija cilja minimizacija gubitaka*



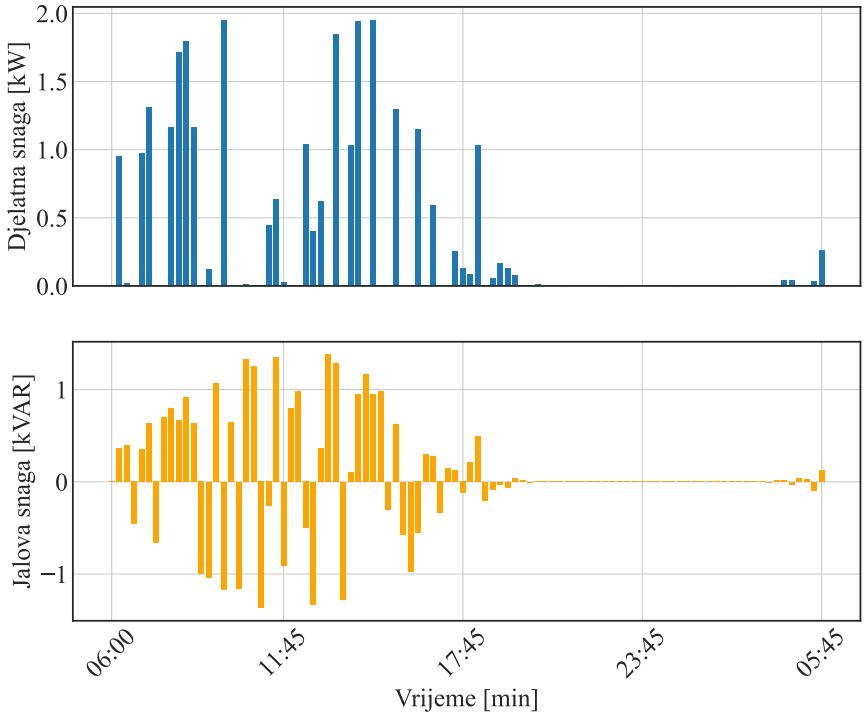
Slika P6: *Gubici jalove energije kada je funkcija cilja minimizacija devijacije napona*



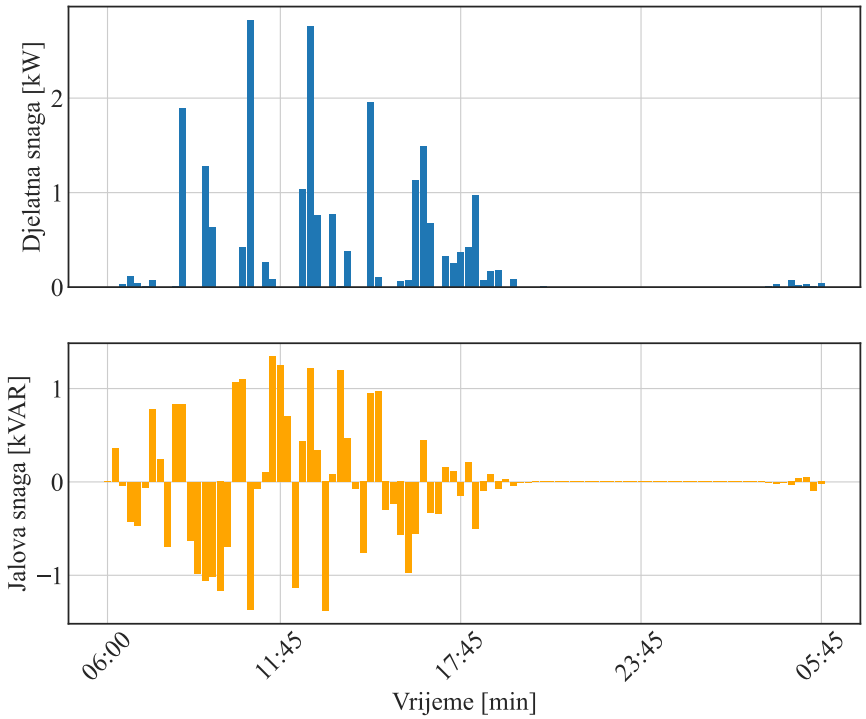
Slika P7: *Gubici jalove energije kada je funkcija cilja minimizacija faktora naponske nesimetrije*



Slika P8: *Primjer iznosa djelatne i jalove snage jedne fotonaponske elektrane kada je funkcija cilja minimizacija gubitaka, a mehanizam upravljanja djelatna i jalova snaga izmjenjivača i snaga punjenja električnog vozila*



Slika P9: *Primjer iznosa djelatne i jalove snage jedne fotonaponske elektrane kada je funkcija cilja minimizacija devijacije napona, a mehanizam upravljanja djelatna i jalova snaga izmjenjivača i snaga punjenja električnog vozila*



Slika P10: *Primjer iznosa djelatne i jalove snage jedne fotonaponske elektrane kada je funkcija cilja minimizacija faktora naponske nesimetrije, a mehanizam upravljanja djelatna i jalova snaga izmjenjivača i snaga punjenja električnog vozila*

Sažetak

U okviru doktorskog rada razvijeni su i prikazani optimizacijski modeli za planiranje pogona aktivne distribucijske mreže. Dvostupanjski model planiranja pogona niskonaponske aktivne distribucijske mreže sastoji se od dva međusobno povezana optimizacijska problema (stupnja) koji se razlikuju s obzirom na funkcije cilja, mehanizme upravljanja te vremenski korak. U oba stupnja definirane su tehničke funkcije cilja. U prvom je stupnju cilj minimizacija devijacije napona, pri čemu se upravljanje provodi konvencionalnim mehanizmom - regulacijskom preklopkom transformatora. U drugom je stupnju funkcija cilja minimizacija gubitaka, dok mehanizam upravljanja uključuje mogućnosti izmjenjivača aktivnih kupaca. Dodatno, razvijen je kosimulacijski optimizacijski model za planiranje pogona aktivne distribucijske mreže koji uključuje tri funkcije cilja minimizaciju devijacije napona, gubitaka i faktora naponske nesimetrije. Razvijeni model uzima u obzir raspoložive mehanizme za upravljanje pogonom niskonaponske aktivne distribucijske mreže - regulacijsku preklopku transformatora i mogućnosti izmjenjivača aktivnih kupaca. Oba optimizacijska modela formulirana su kao problemi mješovitog cjelobrojnog nelinearnog programiranja unutar kosimulacijskog okruženja što omogućuje implementaciju metoda računalne inteligencije za pronalaženje rješenja blizu optimalnog. Naposlijetku je analiziran učinak svakog upravljačkog mehanizma na ostvarenje pojedine funkcije cilja u okviru kosimulacijskog modela, uz pretpostavku da se preostale dvije funkcije cilja tretiraju kao varijable stanja.

Razvijeni modeli za planiranje pogona aktivne distribucijske mreže primijenjeni su na testnim mrežama na temelju kojih su doneseni općeniti zaključci. Sukladno važećim pravilima i tehničkim ograničenjima koja se odnose na upravljanje jalovom snagom izmjenjivača aktivnih kupaca, mogućnost korištenja jalove snage ograničena je na uvjete manjih poremećaja u pogonu, dok se u slučaju većih odstupanja pokazuje nedostatnom za učinkovito upravljanje. Parametri niskonaponske distribucijske mreže uvelike utječu na učinkovitost mehanizama upravljanja neovisno o funkciji cilja favorizirajući pri tome upravljanje djelatnom snagom izmjenjivača aktivnih kupaca.

Ključne riječi: niskonaponska aktivna distribucijska mreža, planiranje pogona, obnovljivi izvori energije, električna vozila, kosimulacijski optimizacijski problem, metoda vrednovanje mehanizama upravljanja.

Abstract

As part of the doctoral thesis, optimization models for the operation planning of an active distribution network were developed and presented. The two-stage optimization model for a low-voltage active distribution network operation scheduling consists of two interconnected optimization problems (stages) that differ according to objective function, control mechanisms, and time step. The first stage aims to minimize voltage deviation, with control implemented through a conventional mechanism — the transformer on-load tap changer. The objective function of the second stage is active power losses minimization, while the control mechanism includes the capabilities of the prosumer's inverter. Additionally, a cosimulation optimization model for a low-voltage active distribution network operation scheduling is developed. The model contains three objective functions: voltage deviation minimization, active power losses minimization and voltage unbalance factor minimization. The developed model takes into account the available control mechanisms for the operation of a low-voltage active distribution network – the transformer tap changer and the capabilities of active customers' inverters. Both optimization models are formulated as mixed-integer nonlinear programming problems within a co-simulation environment, enabling the implementation of computational intelligence methods for obtaining near-optimal solutions. At the end, the effect of each control mechanism on the achievement of each objective function within the co-simulation model was analyzed, assuming that the remaining two objective functions are treated as state variables.

The proposed models for active distribution network operation planning were applied to test networks, based on which general conclusions were made. Following the applicable regulations and technical constraints related to the reactive power management of prosumers' inverters, the possibility of utilizing reactive power is limited to minor disturbances in operation. However, in the case of major deviations, it proves insufficient for effective management. Distribution network parameters have a significant impact on the effectiveness of control mechanisms, regardless of the objective function, favoring active power control of

prosumers' inverters over other mechanisms.

Keywords: low-voltage active distribution network, operation scheduling, renewable energy resources, electric vehicles, cosimulation optimization problem, mechanisms control validation method.

Životopis

Marina Dubravac rođena je 24. srpnja 1997. godine u Osijeku. Završava 2016. godine Gimnaziju Antuna Gustava Matoša Đakovo te ostvaruje izravan upis na Preddiplomski sveučilišni studij elektrotehnike na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek. Preddipomski studij završava 2019. godine i upisuje Diplomski sveučilišni studij elektrotehnike kojeg završava 2021. godine. Iste godine zapošljava se kao asistent za rad na projektu Hrvatske zaklade za znanost - Distribucijska elektroenergetska mreža s velikim udjelom aktivnih kupaca te upisuje Poslijediplomski doktorski studij elektrotehnike i računarstva, modul Elektroenergetika. Dobiva priznanje Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek 2023. godine za iznadprosječne rezultate ostvarene polaganjem ispita i objavljivanjem znanstvenih radova na Poslijediplomskom doktorskom studiju elektrotehnike i računarstva.

Uže su joj područje istraživanja optimizacija planiranja i pogona aktivnih distribucijskih mreža i integracija aktivnih kupaca u elektroenergetski sustav. Do sada je objavila 3 znanstvena rada u časopisima citiranim u Web of Science Core Collection bazi, kao i više od 10 znanstvenih radova objavljenih u zbornicima međunarodnih znanstvenih konferencija. Kao suradnik održava nastavu na sveučilišnom prijediplomskom, stručnom prijediplomskom i sveučilišnom diplomskom studiju iz kolegija Osnove elektroenergetskog sustava, Analiza elektroenergetskog sustava, Elektroenergetske mreže i vodovi, Prijenos i distribucija električne energije i Elektroenergetska postrojenja.